

KOCATEPEİİBFD

Afyon Kocatepe Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi
Afyon Kocatepe University Journal of Economics and Administrative Sciences

Yılda İki Defa Yayımlanan Akademik, Uluslararası ve Hakemli Dergi
Biannually Published Academic, International, and Peer-Reviewed Journal

ISSN: 1302-1966 | eISSN: 2651-4117 | Cilt/Volume: 26 | Sayı/Issue: Özel Sayı | Yıl/Year: Ekim/October 2024



Afyon Kocatepe Üniversitesi
İktisadi ve İdari Bilimler
Fakültesi Dergisi

Cilt: 26 | Sayı: Özel Sayı | Yıl: Ekim 2024



Afyon Kocatepe University
Journal of Economics and
Administrative Sciences

Volume: 26 | Issue: Special Issue | Year: October 2024

ISSN: 1302-1966

eISSN: 2651-4117

Yayıncı: Afyon Kocatepe Üniversitesi İktisadi ve İdari Bilimler Fakültesi
Publisher: Afyon Kocatepe University Faculty of Economics and Administrative Sciences

Afyon Kocatepe Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi

ISSN: 1302-1966 / eISSN: 2651-4117

Dergi Kısa Adı: KOCATEPEİİBFD

Derginin Sahibi

Prof. Dr. Gökhan Demirtaş, Afyon Kocatepe Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dekanı (TR), ORCID: 0000-0002-6757-5613, demirtas@aku.edu.tr

Özel Sayı Editör Kurulu Üyeleri

Editör: Doç. Dr. Beyza Mina Ordu-Akkaya, Ankara Sosyal Bilimler Üniversitesi, İşletme Bölümü (TR), ORCID: 0000-0003-4353-3977

Alan Editörü: Doç. Dr. Görkem Ataman, Yaşar Üniversitesi, İşletme Bölümü (TR), ORCID: 0000-0002-8290-2248

Editör Yardımcısı: Arş. Gör. Yunus Yıldırım, Afyon Kocatepe Üniversitesi, İşletme Bölümü (TR), ORCID: 0000-0002-2447-4142

Dil Editörü:

Dr. Öğr. Üyesi Şahin Eray Kırdım, Ankara Yıldırım Beyazıt Üniversitesi, Uluslararası İlişkiler Bölümü (TR), ORCID:0000-0003-4207-6559

Yayın Kurulu Üyeleri

Prof. Dr. Cantürk Kayahan, Afyon Kocatepe Üniversitesi (TR), ckayahan@aku.edu.tr, ORCID: 0000-0003-4777-1470

Prof. Dr. Erkan Akar, Afyon Kocatepe Üniversitesi (TR), akar@aku.edu.tr, ORCID: 0000-0001-5222-8371

Prof. Dr. Ferudun Kaya, Bolu Abant İzzet Baysal Üniversitesi (TR), ferudunk@ibu.edu.tr, ORCID: 0000-0002-8930-9711

Prof. Dr. Gökhan Demirtaş, Afyon Kocatepe Üniversitesi (TR), demirtas@aku.edu.tr, ORCID: 0000-0002-6757-5613

Prof. Dr. Hassanuddeen Abd Aziz, International Islamic University Malaysia (MY), ahassan@iiu.edu.my

Prof. Dr. İhsan Cemil Demir, Afyon Kocatepe Üniversitesi (TR), icdemir@aku.edu.tr, ORCID: 0000-0002-4756-0617

Prof. Dr. Mustafa Fişne, Afyon Kocatepe Üniversitesi (TR), fisne@aku.edu.tr, ORCID: 0000-0001-7691-1255

Prof. Dr. Uğur Sadioğlu, Hacettepe Üniversitesi (TR), ugursadi@hacettepe.edu.tr, ORCID: 0000-0002-2454-4163

Prof. Dr. Hatice Özutku, Afyon Kocatepe Üniversitesi (TR), hozutku@aku.edu.tr, ORCID: 0000-0003-0425-4967

Doç. Dr. Dan Marius Voicilas, Romanian Academy (RO), dmvoici@yahoo.com, ORCID: 0000-0003-3411-8958

Doç. Dr. Dimitrina Stoyancheva, Trakia University (BG), dimitrina.stoyancheva@trakia-uni.bg, ORCID: 0000-0002-5417-5274

Doç. Dr. Edgardo Sica, University of Foggia (IT), edgardo.sica@unifg.it, ORCID: 0000-0001-9054-8309

Doç. Dr. Gratiela Dana Boca, Technical University of Cluj Napoca (RO), gratiela.boca@econ.utcluj.ro, ORCID: 0000-0003-3684-2384

Doç. Dr. Mohammad Nurunnabi, Prince Sultan University (SA), mnurunnabi@psu.edu.sa, ORCID: 0000-0003-0848-3556

Doç. Dr. Osman Uslu, Afyon Kocatepe Üniversitesi (TR), ousluu@aku.edu.tr, ORCID: 0000-0002-0571-6281

Dr. Öğr. Üyesi Richard Kotter, Northumbria University (UK), richard.kotter@northumbria.ac.uk, ORCID: 0000-0003-2741-5620

Danışma Kurulu Üyeleri

Prof. Dr. Abdullah Yalaman, Osmangazi Üniversitesi İşletme Bölümü (TR), abdullah.yalaman@gmail.com, ORCID: 0000-0002-4721-6576

Prof. Dr. Ethem Kadri Pektaş, Afyon Kocatepe Üniversitesi Siyaset Bilimi ve Kamu Yönetimi Bölümü (TR), pektas@aku.edu.tr, ORCID: 0000-0002-8157-8861

Prof. Dr. Mehmet Ali Köseoğlu, Metropolitan State University College of Business and Management (US), mehmet.koseoglu@metrostate.edu, ORCID: 0000-0001-9369-1995

Prof. Dr. Mehmet Altın, University of Central Florida Rosen College of Hospitality Management (US), mehmetaltin@outlook.com, ORCID: 0000-0002-2297-7125

Prof. Dr. Muhammad Shahbaz, Beijing Institute of Technology Department of International Trade and Finance (CN), muhdshahbaz77@gmail.com, ORCID: 0000-0003-4916-7648

Prof. Dr. Şuayıp Özdemir, Afyon Kocatepe Üniversitesi İşletme Bölümü (TR), sozdemir@aku.edu.tr, ORCID: ORCID:0000-0002-6799-8480

Prof. Dr. Şaban Nazlıoğlu, Pamukkale Üniversitesi Uluslararası Ticaret ve Finansman Bölümü (TR), snazlioglu@pau.edu.tr, ORCID: 0000-0002-3607-3434

Sekretarya:

Arş. Gör. Arzu Gözde Akgül, Afyon Kocatepe Üniversitesi İşletme Bölümü (TR), ORCID: 0000-0002-8294-283X

Afyon Kocatepe University Journal of Economics and Administrative Sciences

ISSN: 1302-1966 / eISSN: 2651-4117

Short Title: KOCATEPEİİBFD

Owner

Prof. Gökhan Demirtaş, Afyon Kocatepe University Dean of the Faculty of Economics and Administrative Sciences (TR), ORCID: 0000-0002-6757-5613

Special Issue Editorial Board Members

Editor: Assoc. Prof. Beyza Mina Ordu-Akkaya, Ankara University of Social Sciences, Department of Business Administration (TR), ORCID: 0000-0003-4353-3977

Field Editor: Assoc. Prof. Görkem Ataman, Yaşar University, Department of Business Administration (TR), ORCID: 0000-0002-8290-2248

Editorial Assistant: Res.Assist. Yunus Yıldırım, Afyon Kocatepe University, Department of Business Administration (TR), ORCID: 0000-0002-2447-4142

Language Editor:

Assist. Prof. Şahin Eray Kırdım, Ankara Yıldırım Beyazıt University, Department of International Relations (TR), ORCID:0000-0003-4207-6559

Members of the Publication Board

Prof. Cantürk Kayahan, Afyon Kocatepe University (TR), ckayahan@aku.edu.tr, ORCID: 0000-0003-4777-1470

Prof. Erkan Akar, Afyon Kocatepe University (TR), akar@aku.edu.tr, ORCID: 0000-0001-5222-8371

Prof. Ferudun Kaya, Bolu Abant İzzet Baysal University (TR), ferudunk@ibu.edu.tr, ORCID: 0000-0002-8930-9711

Prof. Gökhan Demirtaş, Afyon Kocatepe University (TR), demirtas@aku.edu.tr, ORCID: 0000-0002-6757-5613

Prof. Hassanuddeen Abd Aziz, International Islamic University Malaysia (MY), ahassan@iiu.edu.my

Prof. İhsan Cemil Demir, Afyon Kocatepe University (TR), icdemir@aku.edu.tr, ORCID: 0000-0002-4756-0617

Prof. Mustafa Fişne, Afyon Kocatepe University (TR), fisne@aku.edu.tr, ORCID: 0000-0001-7691-1255

Prof. Uğur Sadioğlu, Hacettepe University (TR), ugursadi@hacettepe.edu.tr, ORCID: 0000-0002-2454-4163

Prof. Hatice Özutku, Afyon Kocatepe University (TR), hozutku@aku.edu.tr, ORCID: 0000-0003-0425-4967

Assoc. Prof. Dan Marius Voicilas, Romanian Academy (RO), dmvoici@yahoo.com, ORCID: 0000-0003-3411-8958

Assoc. Prof. Dimitrina Stoyancheva, Trakia University (BG), dimitrina.stoyancheva@trakia-uni.bg, ORCID: 0000-0002-5417-5274

Assoc. Prof. Edgardo Sica, University of Foggia (IT), edgardo.sica@unifg.it, ORCID: 0000-0001-9054-8309

Assoc. Prof. Gratiela Dana Boca, Technical University of Cluj Napoca (RO), gratiela.boca@econ.utcluj.ro, ORCID: 0000-0003-3684-2384

Assoc. Prof. Mohammad Nurunnabi, Prince Sultan University (SA), mnurunnabi@psu.edu.sa, ORCID: 0000-0003-0848-3556

Assoc. Prof. Osman Uslu, Afyon Kocatepe University (TR), ouslu@aku.edu.tr, ORCID: 0000-0002-0571-6281

Assist. Prof. Richard Kotter, Northumbria University (UK), richard.kotter@northumbria.ac.uk, ORCID: 0000-0003-2741-5620

Members of the Advisory Board

Prof. Abdullah Yalaman, Osmangazi University Department of Business Administration (TR), abdullah.yalaman@gmail.com, ORCID: 0000-0002-4721-6576

Prof. Ethem Kadri Pektaş, Afyon Kocatepe University Department of Political Science and Public Administration (TR), pektas@aku.edu.tr, ORCID: 0000-0002-8157-8861

Prof. Mehmet Ali Köseoğlu, Metropolitan State University College of Business and Management (US), mehmet.koseoglu@metrostate.edu, ORCID: 0000-0001-9369-1995

Prof. Mehmet Altın, University of Central Florida Rosen College of Hospitality Management (US), mehmetaltin@outlook.com, ORCID: 0000-0002-2297-7125

Prof. Muhammad Shahbaz, Beijing Institute of Technology Department of International Trade and Finance (CN), muhdshahbaz77@gmail.com, ORCID: 0000-0003-4916-7648

Prof. Şuayıp Özdemir, Afyon Kocatepe University Department of Business Administration (TR), sozdemir@aku.edu.tr, ORCID: ORCID:0000-0002-6799-8480

Prof. Şaban Nazlıoğlu, Pamukkale University Department of International Trade and Finance (TR), snazlioglu@pau.edu.tr, ORCID: 0000-0002-3607-3434

Secretary

Res. Assist. Arzu Gözde Akgül, Afyon Kocatepe University Department of Business Administration (TR), ORCID: 0000-0002-8294-283X

İletişim

Afyon Kocatepe Üniversitesi. Ahmet Necdet Sezer Kampüsü. İktisadi ve İdari Bilimler Fakültesi.
Gazlıgöl Yolu, 03200. Afyonkarahisar, Türkiye

Telefon 0 272 218 2000 | **Faks** 0 272 218 2021 | **E-Posta** iibfdergisi@aku.edu.tr

İnternet Sitesi www.dergipark.org.tr/akuiibfd

Amaç & Kapsam ve Dergi Hakkında

Afyon Kocatepe Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi, 1999 yılından bu yana yayımlanmakta olan uluslararası, hakemli ve akademik dergi statüsündedir. Dergide iktisadi ve idari bilimler alanına giren temel sosyal bilim alanlarındaki çalışmalar yayımlanmaktadır. Bu temel alanlar, işletme, iktisat, maliye, siyaset bilimi ve hukuk konularını kapsamaktadır.

Derginin kapsamına nitel veya nicel yöntemler kullanan uygulamalı araştırma makaleleri girmektedir. Derleme makaleler, kitap değerlendirmeleri vb. diğer çalışma türleri dergimizde değerlendirmeye alınmamaktadır. Dergi, gönderilen tüm çalışmalar için iThenticate yazılımı ile intihal ve benzerlik taraması yapmakta olup, editöryal inceleme sonrasında hakeme gönderilmesine karar verilen çalışmalar çift-körleme hakemlik esasına göre değerlendirilmektedir.

Dergimizde kabul alan çalışmalar için 1 ay içerisinde DOI, cilt ve sayı numarası atanarak tam metin erken görünüm uygulaması yapılmaktadır.

Güncel İndeks ve Dizin Bilgileri

ICJ JOURNALS
MASTER LIST

DOAJ DIRECTORY OF
OPEN ACCESS
JOURNALS

Crossref

SOBIAD

ISC

ULAKBİM

ERIH
EUROPEAN REFERENCE INDEX FOR THE
HUMANITIES AND SOCIAL SCIENCES

TRDİZİN

EBSCO
Discovery
Service

Yazım Kuralları ve Makale Gönderimi

Dergimizin yazım kuralları ve yazım şablonu www.dergipark.org.tr/akuiibfd adresinde bulunmakta olup, makale gönderimi de bu adres üzerindeki DergiPark sisteminde yapılmaktadır. Dergimize gönderilen çalışmalar editöryal inceleme sonrasında hakem değerlendirmesine geçme kararı alınması durumunda en az iki hakem tarafından değerlendirilir ve değerlendirme süreci çift-körleme yöntemiyle yapılır. Dergimizde yazarlardan gönderim ve makale işletim ücreti başta olmak üzere hiçbir ad altında ödeme alınmamaktadır. Dergimiz yazar ve hakemlere herhangi bir ad altında herhangi bir ödeme yapmamaktadır.

Tüm makaleler CC-BY-NC 4.0 lisansı ile lisanslanmakta ve ücretsiz açık erişim olarak bilimsel literatüre sunulmaktadır.



Contact

Afyon Kocatepe Üniversitesi. Ahmet Necdet Sezer Kampüsü. İktisadi ve İdari Bilimler Fakültesi.
Gazlıgöl Yolu, 03200. Afyonkarahisar, Türkiye

Office +90 272 218 2000 | **Fax** +90 272 218 2021 | **E-Mail** iibfdergisi@aku.edu.tr

Web www.dergipark.org.tr/akuiibfd

Aim & Scope and About the Journal

Afyon Kocatepe Journal of Economics and Administrative Sciences is an international, peer-reviewed, and academic Journal published since 1999. The journal covers research in social sciences, particularly in economics and administrative sciences. The coverage includes but is not limited to empirical research in business administration, economics, public finance, political science, and law.

The journal only accepts applied qualitative or quantitative research articles. Review articles, book reviews, etc., are not considered in the journal.

The journal monitors all submissions through iThenticate software for similarity and against plagiarism. Submissions that passed the editorial review are subjected to double-blind peer-review.

Accepted manuscripts are assigned with DOI, volume, and issue number within one month and published as a full-text Early View version.

Abstracting and Indexing

ICJ JOURNALS
MASTER LIST

DOAJ DIRECTORY OF
OPEN ACCESS
JOURNALS

Crossref

SOBIAD

ISC

ULAKBİM

ERIH PLUS
EUROPEAN REFERENCE INDEX FOR THE
HUMANITIES AND SOCIAL SCIENCES

TRDİZİN

EBSCO
Discovery
Service

Author Guidelines and Submission

Authors may find the author guidelines and Journal template on www.dergipark.org.tr/akuiibfd, and submissions are open through the DergiPark system, which is available on the website. All submissions to the journal are subjected to editorial review. After the decision to initiate the peer-review process, all manuscripts are reviewed by at least two reviewers under the double-blind peer-review approach. The journal does not charge authors fees, including submission fees or APCs. Additionally, the journal does not provide any payments to authors or reviewers under any status.

All articles in this journal are licensed under CC-BY-NC 4.0 and freely provided to the scientific community as open-access articles.



KOCATEPEİİBFD Cilt 26 Sayı Özel Sayı Makale Listesi

KOCATEPEİİBFD Vol. 26 Special Issue Article List

Yazarlar Authors	Araştırma Makaleleri Research Articles	Sayfalar Pages
Ceylan Bozpolat	Yapay zekâ pazarlama teknolojisinin çevrimiçi satın alma niyetine etkisinde algılanan risk ve güvenin rolü The role of perceived risk and trust in the effect of artificial intelligence marketing technology on online purchase intention	1-16
Yunus Emre Gür Kamil Abdullah Eşidir Şahin Göktuğ Kaldırımçı	Makine öğrenimi ile binek otomobil ihracat tahmini: MLP ve RBF modeli kullanımı Passenger car export forecasting with machine learning: Using MLP and RBF model	17-34
Nermin Kişi Mehmet Akif Özer	İnsan kaynakları yönetiminde yapay zekâ teknolojisinin benimsenmesi üzerine güç alanı analizi Force field analysis on the adoption of artificial intelligence technology in human resource management	35-52
Özen Akçakanat	Yapay zekâ kaygısının teknoloji kaynaklı işsizlik endişesi üzerine etkisi: Muhasebe meslek mensupları üzerine bir araştırma The impact of artificial intelligence anxiety on technology-induced unemployment concerns: A study on accounting professionals	53-67
Furkan Göktaş Fatih Güçlü	Belirsiz kriter ağırlıkları altında yeni bir ÇKKV yöntemi: Yapay zekâ sohbet robotlarına (ChatGPT4, Copilot, Gemini) dayalı portföy seçimi üzerine bir uygulama A novel MCDM method under uncertain criteria weights: An application on portfolio selection based on artificial intelligence chatbots (ChatGPT4, Copilot, Gemini)	68-80
Keti Ventura Tuğberk Karabaşak	Çevrimiçi perakendecilikte sohbet robotu kullanımında etkileşim, güven antropomorfizm ve kullanım seviyesinin müşteri memnuniyetine etkisi The impact of interaction, trust, anthropomorphism, and usage level of chatbots on customer satisfaction in online retailing	81-100
Selim Sürücü Berk Küçük Mustafa Kemal Aydın	An example of the application of artificial intelligence models in human resources processes İnsan kaynakları süreçlerinde yapay zekâ modellerinin uygulanmasına bir örnek	101-116
Fatih Bıyıklı Tunga Bozdoğan Ömer Orbay Çetin	Kişilik özelliklerinin yapay zekâ tutumuna etkisinde statü kaygısının ılımlaştırıcı rolü: Muhasebe meslek mensupları üzerine ampirik bir çalışma The mediating role of status anxiety in the effect of personality traits on artificial intelligence attitude: An empirical study on accounting professionals	117-132
Elvettin Akman Duygu Aksu Yağmur Can	Kamu Denetçiliği Kurumu'nun kamu personel rejimi konusunda almış olduğu tavsiye kararlarını ChatGPT değerlendirebilir mi? Can ChatGPT evaluate the recommendations of the Ombudsman's office on public personnel regime?	133-149
Mustafa Yurtsever	Çalışan yıpranmasını tahmin etmede analitik bir yaklaşım: Topluluk öğrenme yöntemi An analytical approach to predicting employee attrition: Ensemble learning method	150-160

Research Article (Special Issue) | Araştırma Makalesi (Özel Sayı)

Yapay zekâ pazarlama teknolojisinin çevrimiçi satın alma niyetine etkisinde algılanan risk ve güvenin rolü

Ceylan Bozpolat | Dr. Öğr. Üyesi, Nevşehir Hacı Bektaş Veli Üniversitesi, ceylanakdogan@gmail.com, [0000-0002-9672-8308](tel:0000-0002-9672-8308)

Corresponding author/Sorumlu yazar: Ceylan Bozpolat ✉ ceylanakdogan@gmail.com

Öz

Yapay zekâ pazarlama teknolojisi, çevrimiçi alışveriş yapan tüketicilere kişiselleştirilmiş satın alma deneyimi, işletmelere ise müşteri ihtiyaçlarını etkin bir şekilde karşılama imkânı tanımaktadır. Bu çalışma, yapay zekâ pazarlama teknolojisi deneyiminin, çevrimiçi satın alma niyeti üzerindeki etkisinde ilgili teknolojiye olan güvenin ve algılanan riskin rolünü ortaya koymak amacıyla yapılmıştır. Bu bağlamda yapay zekâ pazarlama teknolojisinin deneysel unsurları doğruluk, içgörü ve etkileşim olmak üzere üç boyutta ele alınmış; güven, algılanan risk ve satın alma niyetinin de dahil olduğu SOR modeline dayanan kavramsal bir model geliştirilmiştir. Ardından çevrimiçi alışveriş geçmişi bulunan kişilere çevrimiçi anket yöntemi ile 480 örnek hacimli nicel bir çalışma gerçekleştirilmiştir. Kartopu örnekleme yöntemi ile toplanan veriler, SmartPLS 4 programı kullanılarak Kısmi En Küçük Kareler Varyans Temelli Yapısal Eşitlik Modellemesi (PLS-SEM) ile analiz edilmiştir. Sonuçlar, içgörü ve etkileşim deneyiminin teknolojiye olan güveni pozitif bir şekilde etkilediğini, doğruluk deneyiminin ise güven üzerinde herhangi bir etkisi olmadığını göstermiştir. Tüketicilerin risk algılarının azalmasında yapay zekâ pazarlama teknolojisinin deneysel unsurlarının tamamının pozitif bir etkisi olduğu tespit edilmiştir. Güven ve deneysel unsurlar dolayısıyla azalan algılanan risk, çevrimiçi satın alma niyetini pozitif ve anlamlı bir şekilde etkilemektedir. Ayrıca yapay zekâ pazarlama teknolojisi deneyim unsurları ile çevrimiçi satın alma niyeti arasındaki ilişkide güven ve algılanan risk değişkenlerinin seri aracı etkisi olduğu bulunmuştur.

Anahtar Kelimeler: Yapay Zekâ Pazarlama Teknolojisi, Güven, Algılanan Risk, Çevrimiçi Satın Alma Niyeti **JEL Kodları:** M30, M31, M39

The role of perceived risk and trust in the effect of artificial intelligence marketing technology on online purchase intention

Abstract

Artificial intelligence marketing technology provides online consumers with a personalized purchasing experience and businesses the opportunity to effectively meet customer needs. This study was conducted to reveal the role of trust in the relevant technology and perceived risk in the effect of artificial intelligence marketing technology experience on online purchasing intention. In this context, the experiential elements of artificial intelligence marketing technology are discussed in three dimensions: accuracy, insight, and interaction. A conceptual model based on the SOR model was developed, including trust, perceived risk, and purchase intention. Then, a quantitative study was conducted with a sample size of 480 people using an online survey method for people with online shopping history. Data collected by snowball sampling method were analyzed by Partial Least Squares Variance Based Structural Equation Modeling (PLS-SEM) using the SmartPLS 4 program. The results showed that the experience of insight and interaction positively affected trust in technology, while the experience of accuracy had no effect on trust. It has been determined that all the experiential elements of artificial intelligence marketing technology have a positive effect on reducing consumers' risk perceptions. Reduced perceived risk due to trust and experiential factors positively and significantly affects online purchase intention. In addition, it was found that trust and perceived risk variables had a serial mediating effect on the relationship between artificial intelligence marketing technology experiential elements and online purchasing intention.

Keywords: Artificial Intelligence Marketing Technology, Trust, Perceived Risk, Online Purchase Intention **JEL Codes:** M30, M31, M39

Extended Summary

This study was conducted to reveal the role of trust in the relevant technology and perceived risk in the effect of artificial intelligence marketing technology experience on online purchasing intention. In this context, the experiential elements of artificial intelligence marketing technology were discussed in three dimensions: accuracy, insight and interaction, and a conceptual model based on the SOR model was developed, including trust, perceived risk and purchase intention. Personalized purchasing experience supported by artificial intelligence marketing technology accelerates the behavioral process by offering convenience

How to cite this article / Bu makaleye atıf vermek için:

Bozpolat, C. (2024). Yapay zekâ pazarlama teknolojisinin çevrimiçi satın alma niyetine etkisinde algılanan risk ve güvenin rolü. *KOCATEPEİİBFD*, 26(Özel Sayı), 1-16. <https://doi.org/10.33707/akuiibfd.1403109>

to consumers. Businesses can meet customer needs effectively. As a result of all these positive results, more research is needed to better understand the subject. This situation inspired the current research.

This study has many contributions to marketing literature. First of all, since there are few studies dealing with the marketable experience features of artificial intelligence technology, which is still described as virgin, it offers new information to academics who want to do research in this field. In addition, a research model is proposed that can lead to a better understanding of the purchasing mechanism by exploring the related effects of two opposite variables, namely trust and perceived risk, on the effect of artificial intelligence-supported marketing technologies on purchase intention.

This research is a quantitative study with a sample size of 480, in which an online survey method was applied to people with a history of online shopping. In the analysis of the data collected by the snowball sampling method, firstly, confirmatory factor analysis was performed with the help of the SmartPLS 4 program to test the measurement model. Then, construct validity and reliability were evaluated. Finally, variance-based structural equation modeling (PLS-SEM) was performed with the Partial Least Squares method to test the hypothesized relationships in the research model. The results showed that the experience of insight and interaction positively affected trust in technology, while the experience of accuracy had no effect on trust. In addition, it has been determined that all the experiential elements of artificial intelligence marketing technology have a positive effect on reducing consumers' risk perceptions. Reduced perceived risk due to trust and experiential factors positively and significantly affects online purchase intention. In addition, it was found that trust and perceived risk variables had a serial mediating effect on the relationship between artificial intelligence marketing technology experiential elements and online purchasing intention.

Online shopping sites and application makers should increase the efficiency of the technological infrastructure to strengthen the accuracy experience of technology and consumers should be introduced to search habits with images and sounds. Designing search interfaces to provide effective and accurate results can motivate consumers to use these features. The insight experience with the artificial intelligence algorithm should be constantly enriched with elements that will create benefits. The focus of the insight experience is making intelligent recommendations using artificial intelligence technology. Increasing the number of platforms using recommendation systems may create usage habits among consumers. Problems experienced in the system can be minimized with smart virtual assistants, which are the focal point of the interaction experience. However, in order for virtual assistants to offer solutions to problems that are close to the human brain, their software must be constantly updated using both internal and external information.

Experiential elements should be seen as one of the important components of artificial intelligence-supported platforms due to their contribution to profitability for businesses and the reduction of transaction costs for consumers. All these recommendations can make the consumer's technological experience unique, create trust, and reduce perceived risk, thus making the purchase intention sustainable.

Despite the possible contributions mentioned above, this research has some limitations, as in every research. Although the research was conducted on a sample representative of the average internet user, it does not reflect all Turkish internet users. 5.4% of the sample consists of consumers aged 60 and over. It is possible that this group's perception of trust and risk is higher than that of young and experienced consumers. In order to increase the generalizability of the findings, age, and frequency of use control variables can be added to the model in future studies. The research model based on the SOR model can be expanded within the framework of the Theory of Planned Behavior to include actual purchasing behavior and attitude. More research is needed in different samples to clarify the question of whether trust reduces perceived risk or whether trust increases when perceived risk decreases.

Giriş

Yapay zekâ son zamanlarda popüler bir kavram olsa da bu teknolojinin pazarlama alanındaki potansiyeli hala araştırmacıların ilgisini çekmektedir (Haleem vd., 2022; Kopalle vd., 2022; Nalbant & Aydın, 2023). Yapay zekâ pazarlama teknolojisi, markaların/işletmelerin müşteri ihtiyaçlarını tanımlamak ve bu ihtiyaçlara hızlı ve doğru bir şekilde cevap vermek için eş zamanlı algoritma verilerini takip etmelerini sağlayan inovatif bir teknolojidir. Bu teknoloji mevcut müşterileri elde tutmak ve potansiyel müşterileri çekmek için tüketici davranışını tahminleme bakımından ipuçları sunmaktadır (Khrais, 2020, s.2). Sahip olduğu bu yetenek müşterinin gelecekteki davranışını yönlendirme içgörüsünü barındırmaktadır (Verma vd., 2021, s.1). Yapay zekâ teknolojisinin pazarlama alanındaki bu başarısı her ne kadar 2017 yılı ve sonrasındaki araştırmaların odağı olsa da geçmişi robot keşif araştırmalarının olduğu 1980'lere dayanmaktadır. Son zamanlarda popülerleşmesinin nedeni ise teknolojik olanak sağlayan platformların gelişmesi, büyük verinin zenginleşmesi ve analiz edilmesi olarak söylenebilir (Vlačić vd., 2021, s.188). Bu bağlamda tüketiciler, rakipler ve mevcut işletme hakkında bilgi gücünü elinde tutan pazarlama yapay zekâsı, çevrimiçi alışverişlerde içerik öneren sistemler ve tüketicilerin işletme ya da marka ile gelecekteki etkileşimlerini tahmin eden gizli özelliklerini tanımlayan modeller aracılığıyla pazarlama uzmanlarına rekabet gücünü artıracak stratejiler üretmektedir (Overgoor vd., 2019, s.2; Beyari &

Garamoun, 2022, s.1). Teknolojinin sunduğu eş zamanlı ve kişiselleştirilmiş tavsiyeler hem çevrimiçi satın alma oranını artırmakta (Yin & Qiu, 2021, s.1) hem de müşteri memnuniyetini pozitif olarak etkilemektedir (Chen vd., 2021, s.1524).

Günümüz yapay zekâ teknolojisi çeşitli formatlardaki verileri işleme kapasitesine sahiptir. Makine öğrenmesi sayesinde sayısal verilerin yanı sıra metin, görsel ve sesleri kullanarak kullanıcılara çözüm önerileri sunmaktadır (Jarek & Mazurek, 2019, s.47). Örneğin Apple'ın yapay zekâ destekli akıllı asistanı Siri'nin algoritması sesli komutları yorumlama, kullanıcısının konuştuğu anahtar kelimeleri anlama ve sonrasında dahili komutlar üzerinden cevap verme becerisine sahiptir. Getirilen son güncellemelerde, verilen izinler doğrultusunda kendisine sorulan sorulara tahmine dayalı bilgiler vermektedir (Hasan vd., 2021, s.591). Benzer bir şekilde giyim sektöründe faaliyet gösteren kurumsal e-perakendecilerin çoğu uygulamalarına görsel tahminleme yapan algoritmaları eklemiştir. Bu eklenti ile müşterilerin aradıkları ürünlere hızlı bir şekilde ulaşmalarına imkân vererek satın alma ihtimallerinin artması beklenmektedir. Tüm bu olumlu özelliklerin gerçekleşmesi teknolojiye olan güven ve tüketicinin algıladığı risk düzeyine bağlıdır. Yapay zekâ pazarlama teknolojisinin hem işletmeler hem de tüketiciler açısından sürdürülebilir olması için güven ve algılanan risk özelliklerinin anlaşılması gerekmektedir. Yapay zekâ teknolojileri, öğrenme algoritmalarına kodlanmamış durumlarda her zaman dengeli ve beklenen davranışlar sergileyebilmektedir (Ajenaghughru vd., 2020, s.118). Bu durum ise yapay zekânın güvenilirliği sorunsalını gündeme getirmektedir. Çevrimiçi alışverişte yapay zekâ, büyük veri üzerinden kişiselleştirilmiş önerilerde bulunmaktadır. Büyük verinin eksik, yanlış ve yetersiz olması algoritmik önyargıya neden olmakta ve kullanıcının eylemlerini istenmeyen yönde etkileyebilmektedir. Ayrıca algoritmaların verileri işleme şeklinin mahremiyete, satın alma kararlarındaki özerkliğe olan müdahalesi de kullanıcıların ilgili teknolojiye güven düzeylerini etkileyebilmektedir (Stanciu & Rîndaşu, 2021, s.50). Öte yandan kullanıcılar arasında yapay zekâyı teknolojinin çalışma şekline yönelik eksik ve yanlış bilgidir kaynaklı abartılı etkileşimler (siber güvenlik tehdidi gibi) ilgili teknolojiye olan güveni sarsabilmektedir. Risk, güven problemlerinin olduğu ortamlarda ortaya çıkmaktadır. Algoritmik önyargı, siber güvenlik açığı gibi sorunlar aynı zamanda teknolojinin risklerini de oluşturmaktadır. Güven yapay zekâ teknolojinin benimsenmesine katkıda bulunurken algılanan riskin artması teknolojiye direnç gelişmesine neden olabilir (Crockett vd., 2020). Bu bağlamda güven ve riskin çevrimiçi satın alma niyetindeki çok yönlü etkisinin araştırılması ihtiyacı bulunmaktadır. Bitkina vd. (2020) yapay zekâ teknolojisinin algılanan performans özelliklerinin kullanıcının güven düzeyini etkilediğini başka bir ifadeyle algılanan güvenin yapay zekâ teknoloji performansının geliştirilmesi ile artırılacağını ifade etmişlerdir. Öte yandan güven kavramıyla zıt özellikler taşıyan algılanan risk teknolojik belirsizliklerden kaynaklı olumsuz duyguları harekete geçirmekte ve satın alma niyetini etkilemektedir (Udo vd., 2010, s.481). Mevcut çalışma ise yapay zekâ pazarlama teknolojisi deneyim özelliklerinin, algılanan riski negatif yönde etkileyeceği varsayımına dayanmaktadır. Azalan algılanan riskin ise satın alma niyetini pozitif yönde etkileyeceğini öngörmektedir.

Bu bağlamda SOR (Uyaran-Organizma-Tepki) modeli referans alınarak yapay zekâ pazarlama teknolojisinin deneyimsel özellikleri olan doğruluk, içgörü ve etkileşim unsurları uyaran olarak tanımlanmıştır. Akıllı öneri sistemlerinin sunduğu doğru ve kişiselleştirilmiş önerilerin, sanal asistanların alışveriş destek hizmetleri satın alma niyetini belirleyen bir dışsal uyarıcı olduğu varsayılmıştır. Deneyimsel uyaranların kullanıcılarda yarattığı duygusal ve zihinsel sürecin çıktıları olmaları öngörüsü ile güven ve algılanan risk kavramları organizma olarak belirlenmiştir.

Bu çalışmanın pazarlama literatürüne birçok katkısı bulunmaktadır. İlk olarak henüz bakir olarak nitelendirilen yapay zekâ teknolojisinin pazarlanabilir deneyim özelliklerini ele alan az sayıda çalışma olması nedeniyle bu alanda araştırma yapmak isteyen akademisyenlere yeni bilgiler sunmaktadır. Ayrıca yapay zekâ destekli pazarlama teknolojilerinin satın alma niyetine etkisinde güven ve algılanan risk olmak üzere iki zıt değişkenin bağlantılı etkilerini keşfederek satın alma mekanizmasının daha iyi anlaşılmasına yol açabilecek bir araştırma modeli önerilmektedir.


Mevcut çalışma dört bölümden oluşmaktadır. İlk bölüm, yapay zekâ pazarlama teknolojisinin doğruluk, içgörü ve etkileşim olmak üzere üç boyutunun güven ve algılanan risk üzerindeki etkisine ve bunların satın alma niyeti üzerindeki etkisine ilişkin bir literatür taraması sunmaktadır. Bölüm 2'de çevrimiçi pazarlama ve yapay zekâ alanında yapılan ampirik araştırmanın ayrıntılarına yer verilmektedir. Bölüm 3'te araştırma verilerinin analiz sonuçları özetlenmektedir. Tartışma, sınırlamalar ve gelecekteki araştırmalar için önerilerin olduğu Bölüm 4 ile makale sonlandırılmaktadır.

1. Literatür

Mevcut çalışmanın teorik altyapısı SOR (Uyaran-Organizma-Tepki) modeline dayanarak oluşturulmuştur. Tüketici davranışlarını açıklamada sıklıkla kullanılan bu model, dışsal uyarıcıların organizmayı başka bir ifadeyle duyguları tetiklemesi sonucunda davranışın yani tepkinin şekillendiği görüşünü savunmaktadır (Baber & Baber, 2022, s.3). Dışsal uyarıcılar, bireysel duygu durumlarını uyaran çevresel faktörler; organizma, bireyin çevresel bir uyarana karşı verdiği duygusal ve zihinsel süreç; tepki ise, bireyin duygusal ve zihinsel süreci ile ilişkili nihai davranışı olarak tanımlanmaktadır (Ming vd., 2021, s.302). SOR modelinin geçerliliğini sınanan çok sayıda çalışma bulunmaktadır. Zhu vd. (2019) Y kuşağının çevrimiçi yeniden satın alma niyetinin çevrimiçi ortam ipuçlarından ve organizmadan etkilendiğini tespit etmişlerdir. Benzer bir şekilde Çin'de yapılan bir diğer çalışmada web sitesi

uyaranlarının (çevresel uyaranlar) tüketicilerin çevrimiçi alışverişe ve duygusal satın almaya yönelik tutumlarını olumlu yönde etkilediği ve tutumlarının ise yeniden satın alma niyetlerini pozitif yönde etkilediği sonucuna varılmıştır (Peng & Kim, 2014, s.159). Her ne kadar çevrimiçi alışveriş araştırmalarında SOR modeli sıklıkla kullanılmış olsa da yapay zekâ pazarlama teknolojilerinin dışsal uyarıcı olarak ele alındığı sınırlı sayıda çalışma bulunmaktadır (Yin & Qiu, 2021). Öte yandan ulusal literatürde SOR modelinin yapay zekâ pazarlama teknolojileri bağlamında uygulanmasında eksiklik olduğundan bu çalışma, modelin Türkiye’de nasıl çalıştığının sonuçlarını sunarak bu konudaki boşluğu gidermektedir. Bu doğrultuda mevcut çalışmada yapay zekâ pazarlama teknolojilerinin deneyim unsurları (doğruluk, içgörü ve etkileşim) uyaran (S) olarak kullanılmıştır. Tüketicilerin yapay zekâ pazarlama teknolojisine ilişkin sezgisel algı durumlarını (O) keşfetmek için tüketici güveni ve algılanan riski kullanılmıştır. Çevrimiçi satın alma niyeti ise (R) olarak temsil edilmektedir. Şekil 1 bu bağlamda oluşturulmuş araştırma modeli ve hipotezlerini göstermektedir.

Şekil 1. Araştırma Modeli ve Hipotez Haritası



Kaynak: Yazar tarafından oluşturulmuştur.

Çalışmanın sonraki kısmında araştırma modelinin rasyonelitesine ilişkin olarak yapay zekâ pazarlama teknolojisi deneyim unsurlarının güven ve algılanan risk ile ilişkisi ardından bu değişkenlerin çevrimiçi satın alma niyeti ile ilişkisini değerlendiren literatür taraması sunulmuştur.

1.1. Yapay Zekâ Pazarlama Teknolojisi ve Güven

Nihai davranışlar üzerinde önceki deneyimlerin etkisinin olduğunu söylemek yanlış olmayacaktır. Yin & Qiu (2021) çalışmalarında yapay zekâ pazarlama teknolojisine çevrimiçi satın alma niyetine etkisinde teknolojinin doğruluk, içgörü ve etkileşim olmak üzere üç deneyimsel unsurunun etkiye sahip olduğunu vurgulamışlardır. Eş zamanlı iyileştirmelerle etkin müşteri deneyimine uygun doğru stratejiler sunan yapay zekâ teknolojisi, tüketicilere arzu edilen satın alma karar serüvenini yaşatmaktadır. Ek olarak tüketici tercihlerinin marka satış teklifleri ile optimum bir şekilde eşleşmesine olanak tanıyarak hem tüketicilerin doğru kararlar almasına hem de işletme tekliflerinin verimliliğinin artmasına yardımcı olmaktadır (Kumar vd., 2019, s.8). Akıllı arama motorlarına girilen metin, ses ve görseller problemi tanımlayarak potansiyel ürünleri tüketicilere sunmaktadır. Böylece internetteki bilgi gürültüsünü elimine ederek tüketicinin istediği ürüne doğru bir şekilde ulaşmasına yardımcı olmaktadır. Tüm bu özellikler bütünü teknolojinin doğruluk deneyimini yansıtmaktadır (Yin & Qiu, 2021, s.3). Diğer deneyimsel unsur olan içgörü ise büyük veriyi kullanarak tüketicilere kişiselleştirilmiş ve özelleştirilmiş içerik sunma olarak tanımlanmaktadır. Akıllı öneri sistemleri, çok sayıda tüketiciye birebir pazarlama imkânı tanımakta ve kişisel satın alma kalıplarından yola çıkarak satın alma potansiyeli olabilecek ürünleri listelemektedir. “Bunları da beğenebilirsin” özelliği ile tahminleme yaparak zihinsel çabayı en aza indirmektedir (Yin & Qiu, 2021, s.3; Alam vd., 2023, s.5). Son olarak etkileşim deneyimi, akıllı müşteri danışmanları diğer bir ifadeyle akıllı sanal asistanlar ile tüketici-işletme iletişiminin (sipariş öncesi bilgi alma, sipariş, kargo takip, faturalama ve ödeme konularındaki geribildirim) yürütülmesi süreçlerini kapsamaktadır. Sanal asistanlar sorulan sorulara yanıt verebilir, karar sürecinin hızlanmasına katkıda bulunabilir (Yin & Qiu, 2021, s.4).

Olumlu geçmiş deneyimler güven üzerinde pozitif etkiye sahiptir (Hafizoğlu & Sen, 2019, s. 1). Güvenme istekliliğindeki kişilerarası farklılıkların incelendiği bir diğer çalışmada geçmiş deneyimler güven üzerinde itici gücü olarak ele alınmıştır (Schwerter & Zimmermann, 2020, s.413). Bu çalışmalarda deneyim, fiziksel yönü ile değerlendirilirken mevcut çalışmada, yapay zekâ pazarlama teknolojisine sunduğu hizmet (akıllı öneri, tavsiye, kişiselleştirilmiş altyapı ve sanal asistan) deneyimi ele alınmaktadır. Bu bağlamda ilgili teknolojinin doğruluk deneyimi yaşatmasının, tüketici güvenini olumlu yönde etkileyebileceği varsayılmaktadır. Aini vd. (2023, s.209) tarafından yapılan çalışmada hava kalite tahmin doğruluğu, yapay zekâ destekli hava kalitesi tahmin uygulamalarına ilişkin kullanıcı güvenini etkileyen önemli bir husus olarak belirlenmiştir. Benzer bir şekilde Kim vd. (2021) tüketici davranış kalıplarını belirleyebilmek için toplanan verilerle geliştirilen algoritmaların, tüketicilerle etkili ilişkiler kurabilmek için doğru olması gerektiğini belirtmişlerdir. Yazarlar yapay zekâ teknolojisinin sunduğu bilgilerin kesinliğinin, yapay zekâ teknolojisine

önerilerine olan güveni büyük ölçüde etkilediğini ve bu durumun ise kişileri daha yüksek davranışsal niyetlere yönlendireceğini vurgulamıştır. Ayrıca net ve doğru bilginin, kaliteli iletişim ve içerikle ilişkili olduğu ifade edilmiştir. Bu ise kişiselleştirilmiş önerileri kapsayan içgörü deneyimi ile ilişkilendirilebilir. Viberg & Halldén (2023, s.53) tarafından yapılan çalışmada, yeni teknolojiyle ilgili geçmiş deneyimlerin, kişiselleştirilmiş yapay zekâ içeriklerine duyulan güven üzerinde etkili olduğu tespit edilmiştir. Yazarlara göre tüketicilerin kişiselleştirilmiş içerikten ne beklediklerini anlamak önemlidir. Tüketici yapay zekâdan satın alma kararını kolaylaştıracak kişisel öneriler bekliyorsa ve tüketicinin bu beklentisi karşılanırsa yapay zekâda kişileştirmenin kullanılmasına duyulan güven o derece doğrulanmaktadır. Hollanda’da bir kahve markası mobil uygulaması özelinde yapılan bir diğer çalışmada, yapay zekâ destekli uygulama içi önerilerle gerçekleşen kişisel müşteri-marka etkileşiminin güveni etkileyip etkilemediği araştırılmıştır. Çalışma sonuçları güvenin yapay zekâ destekli kişiselleştirilmiş uygulama önerilerinden doğrudan ve güçlü bir şekilde etkilendiğini göstermiştir (Rooij, 2022, s.38). Başka bir çalışmada yapay zekâ destekli hizmetler kişiselleştirilmiş olduğunda tüketiciler kullandığı teknolojiye güvenmeye başladığı ifade edilmiştir (Ameen vd., 2021, s. 9). Diğer taraftan çevrimiçi alışverişte sanal asistanların sunduğu hizmetleri içeren etkileşim deneyiminin güven üzerinde etkisi olduğu varsayılmaktadır. Sanal asistanların tüketici sorularını doğru, ilgili ve zamanında yanıtlaması yapay zekâ algoritmasının kullanılabilirliğine bağlıdır. Zhang vd. (2021)’e göre algılanan kullanım kolaylığı, kullanıcıların yapay zekâ sanal asistanlarına güvenme davranışıyla pozitif yönde ilişkilidir. Birçok araştırma teknoloji kullanımını daha işlevsel hale getiren unsurların tüketicilerin çevrimiçi ortamlara olan güveninde belirleyici olduğunu ortaya koymuştur (Wirtz vd., 2018; Pitardi & Marriott, 2021). Yapay zekâ teknolojisinin doğruluk, içgörü ve etkileşim unsurlarının deneysel çıktıları ne kadar pozitifse tüketici güven seviyesi de bir o kadar pozitif olacaktır (Alam vd., 2023, ss. 17-18). Mevcut araştırma, sonuçları paylaşılan bu araştırmaları referans olarak aşağıda sıralanan hipotezleri öne sürmektedir:

H1: Yapay zekâ pazarlama teknolojisinin doğruluk deneyimi, tüketicilerin güven seviyelerini pozitif yönde etkiler.

H2: Yapay zekâ pazarlama teknolojisinin içgörü deneyimi, tüketicilerin güven seviyelerini pozitif yönde etkiler.

H3: Yapay zekâ pazarlama teknolojisinin etkileşim deneyimi, tüketicilerin güven seviyelerini pozitif yönde etkiler.

1.2. Yapay Zekâ Pazarlama Teknolojisi ve Algılanan Risk

Algılanan risk, bir mal/hizmet veya teknolojinin benimsenmesinde önemli bir faktördür (Antony vd., 2006, s.1889). Kim vd. (2008) çalışmalarında algılanan riski, tüketicinin çevrimiçi satın almalarında istenmeyen sonuçlarla ilgili olası belirsizliğe olan inancı olarak tanımlamışlardır. Bu tanım algılanan riskin çok boyutlu (Jacoby & Kaplan, 1972) yapısını çevrimiçi satın alma özelinde açıklamaktadır. Bhatnagar vd. (2000, s.101) bu bağlamda algılanan riski; bilgi riski, finansal risk ve ürün riski olmak üzere üç boyutta değerlendirilmektedir. Bilgi riski, veri tabanına kaydedilen kişisel bilgilerin güvenliği ve mahremiyeti ile ilgilidir ve çevrimiçi işlemlerde toplanan kişisel verilerin uygunsuz bir şekilde kullanılma olasılığı anlamına gelmektedir (Naiyi, 2004, s.178). Tüketicilerin çevrimiçi alışverişlerde kredi kartı ve kişisel bilgilerin çalınması veya izinsiz kullanılması konusunda endişe duyması bilgi riskini açıklayan bir örnektir. Finansal risk, çevrimiçi satın alımdan kaynaklanan para kaybı olasılığıdır. Ödeme işlemlerinde yaşanan dolandırıcılık, ürün fiyatının kıyaslandığında en düşük olmaması gibi ihtimaller finansal risk doğurmaktadır (Bhatti vd., 2019, s.345). Ürün veya performans riski, satın alınan ürünün tüketici beklentisini karşılayamayacağı algısıdır (Ko vd., 2004, s.21). Eksik, yanlış ya da gecikmeli teslimat, görselle uyumsuz ya da kırık, bozuk ürün gönderimi çevrimiçi satın almadan kaynaklı ürün risklerindedir. Ürün ve finansal risk unsurları literatürde çok sayıda çalışmanın odağı olmasına rağmen bilgi riski boyutu özellikle yapay zekâ pazarlama teknolojisi destekli çevrimiçi satın alımlarda sınırlı bir şekilde ele alınmıştır. Bu durum algılanan riskin bilgi riski boyutunu inceleme açısından mevcut çalışmaya ilham kaynağı olmuştur.

Daha önce yapılmış çalışmalar, geçmiş deneyimlerin risk algı düzeyini azalttığı kanısını taşımaktadır. Pires vd. (2004) çalışmalarına artan internet satın alma deneyiminin algılanan riski azalttığını ve ayrıca önceki internet satın alımlarından duyulan memnuniyetin, yeniden satın alma niyetine olan pozitif etkisinde düşük algılanan risk düzeyinin önemli olduğunu ortaya çıkarmışlardır. Bir başka çalışmada turistlerin geçmiş deneyimleri ile destinasyonu ziyaret etme niyetleri arasındaki ilişkide algılanan riskin anlamlı bir etkiye sahip olduğu bulunmuştur (Sharifpour vd., 2014, s.307). Malezya seyahat şirketlerinin web sitelerine turistleri çekmede alışveriş deneyiminin ve algılanan riskin satın alma niyeti üzerindeki etkilerinin araştırıldığı çalışmada ise geçmiş internet alışveriş deneyiminin düşük seviyede belirsizliğe yol açabileceği ve dolayısıyla algılanan risk düzeyini azaltabileceği belirtilmektedir (Mohseni vd., 2018, s.636). Hint tüketicilerin e-perakendecilik deneyimlerinin araştırıldığı çalışmada, çevrimiçi satın alma deneyimleri olmasına rağmen algılanan risk düzeylerinin arttığı tespit edilmiştir. Yeniden çevrimiçi satın alma niyetlerini şekillendiren tutumlarının ise algılanan riskten etkilenmediği bulunmuştur (Mathew & Mishra, 2014). Çevrimiçi müşteri deneyiminin sık ve seyrek satın alma davranışı bağlamında incelendiği bir diğer çalışmada algılanan risk düzeyi satın alma sıklığına göre farklılaşmaktadır. Seyrek satın alan tüketicilerde, memnuniyetin yeniden satın alma niyetine etkisinde algılanan risk kısmi aracı role sahiptir. Başka bir ifadeyle geçmiş çevrimiçi satın alımlarında tatmin edici deneyim yaşayan tüketiciler, algıladıkları risklere rağmen yine de satın alma niyetinde olabilirler. Öte yandan, sık çevrimiçi satın alım yapan tüketicilerin yeniden satın alma niyetlerinde algılanan risk herhangi bir etkiye sahip değildir (Martin vd., 2015, s.89). Tüm bu çalışmalar genel müşteri deneyiminin algılanan riski nasıl etkilediğini açıklamaya çalışırken mevcut çalışmada daha özele inilerek yapay zekâ pazarlama teknolojisinin üç

deneyimsel unsurunun (doğruluk, içgörü ve etkileşim) algılanan risk ile ilişkisine odaklanılmıştır. Yapay zekâ algoritması yardımıyla doğru seçimler veya satın alma kararları veren tüketiciler kullanıma bağlı olarak sisteme aşına olmaktadır. Aşinalık, bir teknolojiyi kullanırken edinilen önceki deneyim ve bilgiler olarak açıklanmaktadır (Maseeh vd., 2021, s. 1782). Bu durum yapay zekâ pazarlama teknolojisinin doğruluk deneyimi ile ilişkilendirilebilir. Teknolojiyi deneyimleyen tüketici teknolojiye aşına olmakta bu ise o teknolojiden kaynaklı olası risk algısını azaltabilmektedir (Shavit vd., 2016, s.1069). Akıllı öneri sistemleri gibi tavsiye araçları, tüketicilerin dijital ayak izlerini takip ederek kişiselleştirilmiş tekliflerde bulunmakta ve böylece kullanıcılara içgörü deneyimi yaşatmaktadır. Her ne kadar literatürde birçok çalışma yapay zekânın gizlilik ve mahremiyet riski içerdiğini (Curzon vd., 2021, s. 97; Hasan vd., 2021) ileri sürse de büyük veri için gerekli bilgi izinin verilmesi tüketicilere daha iyi hizmet sunma bakımından da değerlendirilmelidir. Friedman vd. (2015, s. 652)'e göre tüketiciler, bireysel çıkarlar karşılığında bazı kişisel bilgileri paylaşmaya istekli olabilmektedirler. Tavsiye sistemleri ile paylaşılan bu bilgiler sayesinde kullanıcılara daha iyi hizmet ve ürünler sunulabilmektedir. Diğer taraftan akıllı öneri sistemleri tüketicilerin ilgi alanlarına göre önerilerde bulunarak webde gezinme, seçenekleri değerlendirme ve karar verme aşamalarında karmaşıklığı ve bilgi kirliliğini azaltmakta bu ise satın alma kararını kolaylaştırmaktadır (Rohden & Zeferino, 2023, s. 2037). Zaman tasarrufu ve aradığını hızlı bir şekilde bulma durumlarında ise sistemin risklerini göz ardı edilebilmektedir. Bu bağlamda mevcut çalışma etkili öneri algoritmalarına sahip yapay zekâ pazarlama teknolojisinin tüketicilerin risk algılarını azaltabileceğini öngörmektedir. Mevcut çalışmada ayrıca akıllı sanal asistanlar üzerinden tüketicilerle etkileşime girilmekte bu deneyimin ise tüketicilerin yapay zekâ pazarlama teknolojisine ilişkin risk algılarını azaltacağı varsayılmaktadır. Trivedi (2019, s. 96-98) çalışmasında Chatbot olarak ifade ettiği akıllı sanal asistanların veriyi işleyerek satın alım sürecindeki riskleri ve bu konudaki tüketici endişesini azalttığını ve tüketicilere kolaylık sunduğunu belirtmiştir. Ayrıca chatbotların ilgili bilgiyi doğru zamanda sağlamasının ve bu yeni teknolojinin performans risk algılarını azaltmanın müşteri deneyimini etkileyebileceğini vurgulamıştır. Bir başka çalışmada sohbet robotlarının insan müşteri hizmet temsilcilerine kıyasla tüketici sorularını eş zamanlı, yüksek doğrulukta cevaplamak için hızlı bir şekilde veri bankalarına erişebileceği ve yorulmadan objektif cevaplar verebileceği ifade edilmiştir. Yazarlar ek olarak tüketicilerin algılanan gizlilik riskinin, sohbet robotları ile kıyaslandığında insan müşteri hizmet temsilcileri için daha yüksek olduğunu bulgulamıştır (Song vd., 2022, s.11). Bu bağlamda akıllı sanal asistanların sağladığı etkileşim deneyiminin tüketicilerin risk algısını azaltabileceği öngörülmüştür. Tüm bu öngörüler doğrultusunda aşağıdaki hipotezler oluşturulmuştur.

H4: Yapay zekâ pazarlama teknolojisinin doğruluk deneyimi, tüketicilerin risk algılarını negatif yönde etkiler.

H5: Yapay zekâ pazarlama teknolojisinin içgörü deneyimi, tüketicilerin risk algılarını negatif yönde etkiler.

H6: Yapay zekâ pazarlama teknolojisinin etkileşim deneyimi, tüketicilerin risk algılarını negatif yönde etkiler.

1.3. Güven, Algılanan Risk ve Çevrimiçi Satın Alma Niyeti

Önceki çalışmalar çevrimiçi satın alma niyetinin öncüllerinden birinin güven olduğunu göstermiştir (Hong & Cha, 2013; Bashir vd., 2018). Tüketicilerin güven algılarının, davranışsal niyetlerle doğrudan ilişkiye sahip tutumu pozitif etkilediği benzer bir şekilde tutumun da davranışsal niyetleri pozitif bir şekilde etkilediği görülmüştür. Çevrimiçi alışverişin deneyimsel çıktılarının yorumlanmasında etkili olabilecek algılanan kullanışlılığın da güvenle ilişkili olduğu belirtilmiştir (Zhu vd., 2009). Ürdün'de tüketicilerin e-mağazalardan satın alma niyetlerini etkileyen faktörlerin araştırıldığı çalışmada, ödeme yöntemleri ve algılanan kullanım kolaylığı değişkenleri arasındaki ilişkilerin güven değişkeni aracılığıyla yönetildiği vurgulanmıştır (Abu-Shamaa vd., 2016). Güven aynı zamanda tüketicilerin risk algılarını hafifletici bir rol oynamaktadır (McKnight vd., 2002, s.335). Tüketicilerin çevrimiçi alışverişte yaşadığı güven eksikliği, algılanan risk ve deneyim eksikliğinden kaynaklanmaktadır. Bu nedenle güven ile satın alma niyeti arasındaki ilişkide algılanan riskin aracı rolü göz ardı edilmemelidir (Qalati vd., 2021, s.15). Tayvan'da yapılmış bir başka çalışmada teknolojik özellikler ile bireysel talepler arasındaki uyum ile satın alma niyeti arasındaki ilişkinin ürün riski ve bilgi gizliliği riski ile yönetildiği doğrulanmıştır (Chen & Huang, 2017, s.1418). Algılanan risk ne kadar azsa bireysel talepler ile uyum gösteren teknoloji, tüketicileri bir o kadar satın alma niyetine motive etmektedir. Bu doğrultuda aşağıdaki hipotezler önerilmiştir:

H7: Yapay zekâ pazarlama teknolojisine olan güven, tüketicilerin risk algılarını negatif yönde etkiler.

H8: Yapay zekâ pazarlama teknolojisine olan güven, çevrimiçi satın alma niyetini pozitif yönde etkiler.

H9: Tüketicilerin yapay zekâ pazarlama teknolojisine ilişkin azalan risk algıları, çevrimiçi satın alma niyetini pozitif yönde etkiler.

Öte yandan Melezzya'da gerçekleştirilen bir çalışmada algılanan risklerin, paket servis (yiyecek) çevrimiçi sipariş modelinin satın alma niyeti üzerindeki etkisinde güven önemli aracı role sahip olduğu tespit edilmiş ancak algılanan risk ve güvenin karşılaştırmalı etkileri incelendiğinde zaman ve psikolojik riskten ziyade güvenin satın alma niyetinde daha belirleyici olduğu görülmüştür (Munikrishnan vd., 2023, s.28). Meksikalı tüketiciler özelinde yapılan bir diğer çalışmada, çevrimiçi değerlendirmeler sonucunda oluşan güvenin, elektronik alışverişte algılanan riskin azaltılmasına yardımcı olduğu kanıtlanmıştır. Ancak aynı çalışmada algılanan riskin çevrimiçi satın alma niyeti üzerinde doğrudan anlamlı bir etkisi bulunamamıştır. Bu bulgu katılımcıların çoğunluğunun iyi

eğitimli ve çevrimiçi alışveriş deneyimi fazla olan tüketicilerden oluşması ile açıklanmıştır. Yazarlara göre sık sık çevrimiçi alışveriş yapan tüketicilerin karar verme sürecinde algılanan risk önemli bir rol oynamamaktadır. Çalışmada ayrıca gelişmiş ve gelişmekte olan pazar ayrımı bağlamında genellemeler yapabilmek için farklı örneklerde konunun incelenmesi gerekliliği vurgulanmıştır (Ventre & Kolbe, 2020, s.294). Bu bağlamda gelişmekte olan Türkiye pazarında algılanan riskin çevrimiçi satın alma niyetini nasıl etkilediğini belirleyebilmek için yapılan mevcut çalışma literatüre katkı sağlamaktadır.

Yukarıda el alınan çalışmalar, güven ve algılanan risk kavramlarının birbiri ile yakın ilişkili olduğunu göstermiştir. Bu çalışmaların çoğu algılanan riskin güven aracılığıyla kontrol edilebileceğini savunmaktadır. Diğer taraftan Mayer vd. (1995)'den alıntılanan Hong & Cha (2013, s.928) algılanan riskin güvenin öncülü mü yoksa sonucu mu olduğu yönündeki soruyu gündeme getirmiştir. Yazarlar bu sorunsalı, algılanan risk türlerinin çevrimiçi satın alma niyetine etkisini ve güvenin bu ilişkiye nasıl aracılık ettiğini belirleyebilmek için aracı ve aracılı olmak üzere iki model ile test etmişlerdir. Sonuçlarda, aracı modelde ödeme, performans ve finansal risklerin satın alma niyetini negatif bir şekilde etkilediği; aracılı modelde ise performans riski ile satın alma niyeti arasındaki ilişkide e-satıcıya olan güvenin tam aracı olduğunu görülmüştür. İki model birlikte değerlendirildiğinde çevrimiçi satıcıların riski azaltma çabaları güveni artırdığı sürece satın alma niyetini pozitif olarak değiştirebileceği söylenebilir. Bu doğrultuda mevcut çalışmada çevrimiçi satın alma niyetinin iki zıt öncülü olan güven ve algılanan riskin literatüre göre tartışmalı etkilerini değerlendirebilmek adına aşağıdaki hipotezler önerilmiştir:

H10: Yapay zekâ pazarlama teknolojisinin deneyimsel unsurları ile çevrimiçi satın alma niyeti arasındaki ilişkide güven ve algılanan risk seri aracı role sahiptir.

2. Araştırma Yöntemi

Önceki bölümlerde oluşturulmuş araştırma çerçevesini test etmek için, tüketicilerin çevrimiçi alışveriş yaparken yapay zekâ pazarlama teknolojisi deneyimlerinin satın alma niyetlerini nasıl etkilediğini, bu ilişkide güven ve algılanan risk değişkenlerinin etkilerini kontrol eden ampirik bir çalışma gerçekleştirilmiştir. Bu çalışmaya ilişkin ayrıntılara ise sonraki bölümde yer verilmiştir.

2.1. Veri Toplama Aracının Geliştirilmesi

Araştırma modelindeki yapısal ilişkileri test etmek için literatüre dayalı bir ölçek kullanılmıştır. Çevrimiçi alışverişte yapay zekâ pazarlama teknolojisinin deneyimsel unsurlarının (doğruluk, içgörü ve etkileşim) ölçümü, her biri üç madde olmak üzere dokuz madde ile gerçekleştirilmiş ve Yin & Qiu (2021, s.8)'un çalışmasından alınmıştır. Tüketicinin çevrimiçi alışverişte yapay zekâ pazarlama teknolojisinin tüketici çıkarını ne ölçüde gözetceği olarak ifade edilen güven ve bu teknolojik deneyime ilişkin istenmeyen sonuçlarla ilgili belirsizlik ihtimali olarak tanımlanan algılanan risk yapılarını ölçmek için Hasan vd., (2021, s.594)'den alınan altı madde kullanılmıştır. Son olarak tüketicinin yapay zekâ pazarlama teknolojisi destekli bir çevrimiçi alışveriş platformunda ürün satın alma olasılığını ölçen çevrimiçi satın alma niyeti yapısı dört madde ile ölçülmüş ve Yin & Qiu (2021, s.9)'dan alınmıştır. Toplamda elde edilen 19 ifade için 5'li Likert tekniği kullanılarak cevaplayıcılardan bu ifadelerle katılıp katılmama (1=kesinlikle katılmıyorum 5= kesinlikle katılıyorum) durumlarını belirtmeleri istenmiştir. Bu ifadelerin yer aldığı kısım anketin ikinci bölümünü oluşturmaktadır. İkinci kısımda yer alan ifadelerin ayrıntılarına ilişkin bilgiler Ek.1'de yer almaktadır. Anketin ilk kısmında ise cevaplayıcıların cinsiyet, yaş, eğitim ve gelir olmak üzere temel demografik özelliklerini ve çevrimiçi alışveriş geçmişi (yıl bazlı) ve çevrimiçi alışveriş sıklığı gibi satın alma alışkanlıklarını tanımlayan sorular yer almaktadır. Ölçüm aracı tasarlandıktan sonra 48 kişilik pilot bir grup cevaplayıcı üzerinden ön incelemeye tutulmuştur. Cevaplayıcılardan gelen öneriler doğrultusunda ortalama bir tüketicinin rahatlıkla cevaplayabilmesi için akıllı arama (ses, metin, görsel), akıllı öneri sistemleri ve sanal müşteri hizmetleri asistanı olmak üzere yapay zekâ pazarlama teknolojisinin deneyimsel unsurlarının tanımlandığı ön açıklama ile anket nihai halini almıştır. Yapılan ön analizler (tüm ifadelerin faktör yükleri 0.50'nin üzerinde ve α katsayısı 0.87) araştırmanın bir sonraki aşamasına geçmeye uygun sonuçlar sunmuştur.

2.2. Katılımcılar ve Süreç

Araştırmanın evrenini e-ticaret siteleri üzerinden çevrimiçi alışverişte bulunan tüketiciler oluşturmaktadır. Özbek & Sırakaya (2022, s.469)'nın çalışmasında Türkiye'de performanslarına göre en çok kullanılan e-ticaret platformları sırasıyla Trendyol, Hepsiburada, GittiGidiyor, N11 ve Morhipo olarak belirlenmiştir. Mevcut çalışmada e-ticaret sitelerinden kastedilen hem bu popüler e-ticaret siteleri hem de markalara ait e-mağazaların web siteleri ve uygulamalarıdır. 2023 yılı TÜİK Hanehalkı Bilişim Teknolojileri Kullanım Araştırması'na göre 16-74 yaş aralığındaki bireylerin internet kullanım oranı %87,1 iken bu grubun neredeyse yarısı interneti mal veya hizmet satın alma/sipariş verme; %75,5'i ise giyim, ayakkabı ve aksesuar satın alma amacıyla kullanmaktadır (TÜİK, 2023). Yüksek internet kullanım becerisine sahip bu kitleye ulaşmak için Google Forms aracılığıyla oluşturulmuş anket formu kullanılmıştır. Ayrıca araştırma konusunun online anket yapmaya uygun olması bu anket türüne olan sınırlamaları esnetmektedir. Araştırmaya katılacak kişilerin seçiminde olasılıksız örnekleme yöntemlerinden kartopu örnekleme kullanılmıştır. Ana uygulamaya geçmeden önce araştırmanın etik izni alınmıştır. İzin sonrası anket ilk olarak araştırmacı tarafından anketi cevaplamaya uygun bir gruba Whatsapp üzerinden iletilmiştir. Bu gruptan ise gönüllülük esasına göre cevaplamaya uygun başka kişilere anketi iletmeleri Bozpolat (2024).

istenmiştir. İstenen örnek hacmine ulaşıncaya kadar bu süreç Aralık 2023 dönemi itibarıyla sürdürülmüştür. Nihayetinde geçerli 480 anket, hipotezlerin testi için gerekli örneklem büyüklüğünün sınırlarını belirlemiştir. Marsh vd. (1988) ölçekte kullanılan ifade sayısının en az on katı örneklem büyüklüğünün olmasının bu konudaki problemleri azaltacağını belirtmişlerdir. Bu bağlamda en az 190 anketin varlığı örneklem yeterliliği için uygundur. Tablo 1 araştırma katılanların tanımlayıcı özelliklerini göstermektedir.

Tablo 1. Katılımcı Profili (n=480)

Demografi	Kategori	Sıklık (n)	Yüzde (%)
Cinsiyet	Kadın	251	52,3
	Erkek	229	47,7
Yaş	18-29	55	11,5
	30-39	227	47,3
	40-49	132	27,5
	50-59	40	8,3
	60 ve üzeri	26	5,4
Mezuniyet Durumu	Lise ve altı	52	10,8
	Ön Lisans	91	19,0
	Lisans	151	31,5
	Yüksek Lisans	92	19,2
	Doktora	94	19,6
Gelir	15.000 TL ve altı	94	19,6
	15.001 TL-25.000 TL	116	24,2
	25.001 TL-35.000 TL	120	25,0
	35.001 TL-45.000 TL	106	22,1
	45.001 TL ve üzeri	44	9,2
Çevrimiçi Alışveriş Geçmişi	2 yıldan az	71	14,8
	2-5 yıl	150	31,3
	6-9 yıl	169	35,2
	10 yıl ve üzeri	90	18,8
Çevrimiçi Alışveriş Yapma Sıklığı	Yılda 1-2 kez	87	18,1
	2-3 ayda bir	147	30,6
	Ayda bir	131	27,3
	Ayda 2 ve daha fazla	115	24,0

Katılımcıların %52'si kadın, %48'i erkek ve çoğunluğu 30-39 yaş aralığında olan kişilerdi. Eğitim düzeylerine bakıldığında katılımcıların yarısından fazlasının en az lisans ve üzeri eğitime sahip olduğu görülmektedir. Tablo 1'e göre geliri 15.000 TL ve altında olanların oranı %19,6 iken 45.000 TL ve üzeri olanların oranı %9,2'dir. Katılımcıların büyük çoğunluğu 15.001 TL ile 45.000 TL aralığında gelire sahiptir. Katılımcıların %50'den fazlası 5 yıldan fazla sürede çevrimiçi alışveriş konusunda deneyimlidir. Benzer bir şekilde katılımcıların yarısından fazlası ayda en az bir kez çevrimiçi alışveriş yapmaktadır.

2.3. İstatistiksel Analiz

Toplanan verilerin analizinde ilk olarak ölçüm modelini test etmek için doğrulayıcı faktör analizi ardından yapı geçerlilik ve güvenilirlik analizleri, son olarak araştırma modelindeki hipotez yollarının varsayılan ilişkilerinin nasıl olduğunu sınamak için Kısmi En Küçük Kareler yöntemi ile varyans tabanlı yapısal eşitlik modellemesi (PLS-SEM) yapılmıştır. Araştırma kapsamında yapılan analizlerde SPSS 22 ve SmartPLS 4 programlarından yararlanılmıştır.

3. Sonuçlar

3.1. Ölçüm Modelinin Değerlendirilmesi

Yapısal eşitlik modellemesini kurmadan önce yapılar arasındaki ilişkilerin belirlenmesi gerekmektedir. Bu kapsamda reflektif ve formatif ölçüm modeli olmak üzere iki ölçüm modeli bulunmaktadır. Sosyal bilimlerde, ölçekteki ifadelerin ait oldukları yapıyı yansıttıkları yaklaşımını benimseyen reflektif ölçüm modelinden sıklıkla yararlanılmaktadır. Ana ölçüm aracındaki tüm değişkenler reflektif yapıya sahipse modelleme reflektif ölçüm; en az bir tanesi formatif yani ölçüm ifadeleri, yapının nedeni şeklinde tanımlandıysa formatif ölçüm modeli dikkate alınarak yapılmaktadır (Aksay & Ünal, 2016, s.7). Mevcut çalışmada tüm değişkenler reflektif olarak belirlenmiştir. Bu nedenle sonraki analizlerde reflektif değişkenli yapısal modelleme yapılmıştır. Reflektif ölçüm modelini doğrulamak ve hipotezleri test etmek için SmartPLS 4 programı kullanılmıştır. Program üzerinden analizler yapılırken ilk olarak consistent PLS-SEM algoritması (model reflektif yapıda olduğundan) ile ölçüm modelinin faktörel yapısı doğrulanmıştır. Ardından 5000 kişilik bootstrapping (önyükleme) örnekleme ile her yapının iç tutarlılığı (geçerlilik ve güvenilirlik) değerlendirilmiştir.

Tablo 2. Ölçüm Modelinin İç tutarlılığı ve Yakınsak Geçerliliğine İlişkin Sonuçlar

Yapı	İfadeler	Faktör Yükü	Ort.	Std. Sapma	Alfa	Birleşik Güvenilirlik	AVE
Doğruluk Deneyimi	DD1	0,753	0,746	0,064	0,802	0,967	0,711
	DD2	0,942	0,942	0,007			
	DD3	0,824	0,821	0,031			
İçgörü Deneyimi	İD1	0,834	0,832	0,021	0,742	0,762	0,653
	İD2	0,780	0,775	0,040			
	İD3	0,810	0,811	0,021			
Etkileşim Deneyimi	ED1	0,770	0,768	0,031	0,835	0,881	0,750
	ED2	0,899	0,899	0,011			
	ED3	0,921	0,921	0,012			
Güven	G1	0,812	0,812	0,014	0,765	0,768	0,679
	G2	0,835	0,834	0,019			
	G3	0,825	0,823	0,022			
Algılanan Risk	AR1	0,843	0,842	0,018	0,890	0,899	0,822
	AR2	0,951	0,951	0,004			
	AR3	0,923	0,923	0,009			
Çevrimiçi Satın Alma Niyeti	ÇSN1	0,877	0,877	0,016	0,914	0,918	0,795
	ÇSN2	0,922	0,921	0,009			
	ÇSN3	0,909	0,909	0,011			
	ÇSN4	0,858	0,857	0,015			

Ölçüm modelindeki yapıların güvenilirliği için Cronbach Alfa ve birleşik güvenilirlik değerleri üzerinden iç tutarlılık tahmin edilmiştir. Tablo 2'ye göre modeldeki tüm yapıların alfa ve birleşik güvenilirlik katsayıları Hair vd. (2017) tarafından eşik değer olarak kabul edilen 0,70 değerinin üzerindedir. Modeldeki yapıları oluşturan ifadelerin faktör yüklerinin 0,70'den büyük, AVE değerlerinin ise 0,50'den büyük olması ölçüm modelinin yakınsak geçerliliğe sahip olduğunu göstermektedir (Fornell & Larcker, 1981; Hair vd., 2017). Tablo 2'deki ilgili değerler incelendiğinde faktör yüklerinin 0,753-0,951 aralığında olduğu görülmektedir. Tüm faktör yüklemeleri SmartPLS bootstrapping sonucuna göre anlamlıydı (t değerleri > 11,744, p < 0,001). Bu sonuç yapılarıdaki ifadelerin ilgili olduğu yapıyı iyi bir şekilde temsil ettiği anlamına gelmektedir (Hong & Cha, 2013, s.933). Yapılan analizler sonucunda ölçüm modelinin yakınsak geçerliliğinin sağlandığı söylenebilir.

Ölçüm modelinin ayırışma geçerliliğini hesaplamak için AVE katsayılarının karekök değerleri ve yapılar arası korelasyon katsayıları dikkate alınmıştır. Tablo 3'te kalın punto ile yazılmış değerler AVE'nin karekökünü, parantez içinde yazılı değerler ise yapılar arası korelasyonu göstermektedir. Fornell & Larcker (1981)'e göre AVE'nin karekökünün yapılar arası korelasyondan yüksek olması ayırışma geçerliliğinin sağlandığını göstermektedir.

Tablo 3. Ayırışma Geçerliliğine İlişkin Sonuçlar

Yapı	Doğruluk Deneyimi	İçgörü Deneyimi	Etkileşim Deneyimi	Güven	Algılanan Risk	Çevrimiçi Satın Alma Niyeti
Doğruluk Deneyimi	0,843					
İçgörü Deneyimi	(0,470)	0,808				
Etkileşim Deneyimi	(0,474)	(0,397)	0,866			
Güven	(0,372)	(0,453)	(0,455)	0,824		
Algılanan Risk	(0,401)	(0,436)	(0,407)	(0,524)	0,907	
Çevrimiçi Satın Alma Niyeti	(0,298)	(0,475)	(0,341)	(0,693)	(0,524)	0,892

Ayrıca Henseler vd. (2015) ayırışma geçerliliği için SmartPLS eklentisinde HTMT değerlerinin incelenmesini, teorik olarak benzer yapılarıya sahip ölçüm modelinde bu değer 0,90'ın; farklı yapılarıda ise 0,80'in altında olması gerektiğini belirtmişlerdir. Tablo 4'te yer alan değerler HTMT katsayısını göstermekte ve eşik değer olarak kabul edilen katsayının altında olduğunu ve dolayısıyla modelin ayırışma geçerliliğinin sağlandığını ortaya koymaktadır.

Tablo 4. HTMT Katsayıları

Yapı	Doğruluk Deneyimi	İçgörü Deneyimi	Etkileşim Deneyimi	Güven	Algılanan Risk	Çevrimiçi Satın Alma Niyeti
Doğruluk Deneyimi	-					
İçgörü Deneyimi	0,615	-				
Etkileşim Deneyimi	0,559	0,529	-			
Güven	0,431	0,567	0,551	-		
Algılanan Risk	0,436	0,516	0,448	0,630	-	
Çevrimiçi Satın Alma Niyeti	0,319	0,539	0,375	0,723	0,578	-

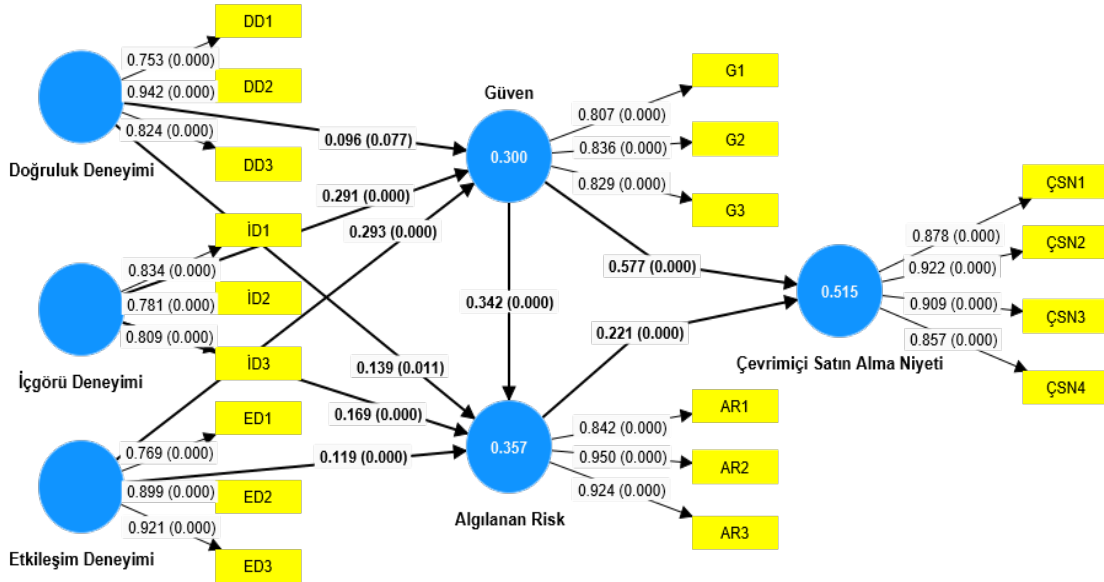
Son olarak bağımsız değişkenler arasında çoklu doğrusal bağlantı sorununun olup olmadığını tespit etmek için VIF katsayılarına bakılmıştır. İfadelerin VIF değerleri 1.270-4.900 aralığındadır ve eşik değer olan 5'in altındadır (Hair vd., 2019, s.10). Bu bağlamda modelde çoklu doğrusal bağlantı sorunu yoktur. Ölçüm modelinin doğrulandığını gösteren kanıtlar sonrasında yapısal modeldeki

hipotez yollarının anlamlılığını değerlendirebilmek için ek analizler yapılmış ve sonuçları aşağıdaki bölümde özetlenmiştir.

3.2. Yapısal Modelin Değerlendirilmesi

Yapısal modeli sınamak için Kısmi En Küçük Kareler Yöntemi ile 5000 kişilik consistent PLS-SEM bootstrapping (önyükleme) örneklemleri (%95 güven aralıklı) algoritma kullanılmıştır. Şekil 2'deki yol katsayıları (β) yapılar arasındaki etkinin gücünü, parantez içindeki değerler ise t istatistiğini göstermektedir. Yapıları temsil eden dairelerin içindeki değerler ise R^2 'yi (modelin ne kadar iyi performansı olduğu) ifade etmektedir (Kim vd., 2008, s.554).

Şekil 2. Yapısal Model Ölçüm Sonuçları



Şekil 2'deki sonuçlara göre içgörü ($\beta=0,291$, $t=5,435$, $p<0,001$) ve etkileşim ($\beta=0,293$, $t=6,891$, $p<0,001$) deneyimi tüketicilerin güven seviyelerini pozitif yönde etkilerken doğruluk deneyiminin ($\beta=0,096$, $t=1,765$, $p>0,05$) herhangi bir etkisi bulunamamıştır. Dolayısıyla H1 hipotezi reddedilirken H2 ve H3 hipotezleri desteklenmiştir. Deneyime dayalı risk algısı öncüllerinden (doğruluk → $\beta=0,139$, $t=2,538$, $p<0,05$, içgörü → $\beta=0,169$, $t=4,228$, $p<0,001$ ve etkileşim → $\beta=0,119$, $t=3,562$, $p<0,001$ deneyimi) algılanan riske giden üç hipotezli yol anlamlı bulunmuş ve H4, H5 ve H6 hipotezleri doğrulanmıştır. Güvenden algılanan riske ve çevrimiçi satın alma niyetine; algılanan riskten ise çevrimiçi satın alma niyetine giden yollar anlamlı bulunmuş ve H7, H8 ve H9 hipotezleri kabul edilmiştir. Ayrıca çevrimiçi satın alma niyetinin R^2 değerinin 0,515 olduğu görülmekte bu ise çevrimiçi satın alma niyetindeki %51,5 varyansın yapay zekâ pazarlama teknolojisinin deneyimsel unsurlarına olan güven ve azalan risk algısı ile açıklandığı anlamına gelmektedir. Hair vd. (2011, s. 147)'e göre 0,50 üzeri R^2 değeri, bağımsız değişkenlerin bağımlı değişken üzerinde orta düzey bir etkiye sahip olduğunu göstermektedir. Güven ve algılanan riskin R^2 değerleri ise 0,25 üzeri bir değer aldığından yapay zekâ pazarlama teknolojisinin deneyimsel unsurları güven ve algılanan risk üzerinde düşük düzeyde bir etkiye sahiptir. Anlamlı R^2 değeri elde edildikten sonra bu etkinin büyüklüğü Cohen (1988) tarafından önerilen f^2 değeri ile değerlendirilmiştir. Cohen (1988)'e göre f^2 değerinin 0,02 olması zayıf; 0,15 olması orta ve 0,35 olması ise güçlü etki anlamına gelmektedir. Analiz sonucunda yapay zekâ pazarlama teknolojisi deneyimsel unsurlarının tamamının güven ve algılanan risk üzerinde zayıf etki derecesine sahip olduğu görülmüştür ($0,030 < f^2 < 0,091$). Öte yandan güven, çevrimiçi satın alma niyetini güçlü bir şekilde ($f^2=0,498 > 0,35$) etkilerken aynı etki algılanan risk ($f^2=0,074$) bağlamında gerçekleşmemiştir. Araştırma modelindeki bağımlı değişkenlerin tahmin gücünü hesaplamak için PLS Predict eklentisi üzerinden Q^2 değerleri elde edilmiştir. Bu değerlerin 0,02 ve üzeri olması zayıf, 0,15 ve üzeri olması orta, 0,35 ve üzeri olması güçlü tahmin ediciliği göstermektedir (Hair vd., 2014). Güven, algılanan risk ve çevrimiçi satın alma niyetinin Q^2 değerleri sırasıyla 0,286, 0,265 ve 0,225 olarak bulunmuştur. Bu doğrultuda modelin orta düzey tahmin ediciliğe sahip olduğu söylenebilir.

3.2.1 Aracı Etkiler

Aracılık analizi Hair vd. (2017)'nin yaklaşımlarına göre yürütülmüştür. Buna göre ilk olarak bağımsız değişkenden bağımlı değişkene giden doğrudan yolun anlamlılığını değerlendirilmiştir. Bu yolun anlamlı olması durumunda aracı değişken eklenerek bağımsızdan aracıya ve aracıdan bağımlıya gidene yollar değerlendirilmelidir. Tüm yolların anlamlı olması durumunda aracı etkiden bahsedilmektedir. Anlamlı aracı etkinin boyutunu tespit etmek için ise PLS-SEM analizlerinde VAF değeri hesaplanmaktadır (Hair vd., 2017a). VAF değeri dolaylı etkilerin toplam etkilere bölünmesiyle elde edilmektedir. Çıkan değer 0,80'den büyük olması tam aracılık, 0,20 ile 0,80 arasında olması kısmi aracılık, 0,20'den küçük olması ise aracılık yok olarak kabul edilmektedir (Hair vd., 2014). Yapay zekâ pazarlama teknolojisinin deneyim unsurlarından (doğruluk, içgörü, etkileşim) çevrimiçi satın alma niyetine güven ve algılanan risk üzerinden giden yollar seri aracılığa imkân vermektedir. Tablo 5'te araştırma modelindeki seri aracılıkların etki boyutları

sunulmaktadır.

Tablo 5. Aracı Etkiler

Aracı Yollar	Doğrudan	Dolaylı	Toplam	VAF	Güven Aralıkları		Sonuç
	Etki	Etki	Etki	Değeri	%2,5	%97,5	
DD→G→AR→ÇSN	0,304	0,104	0,408	0,254	0,060	0,158	Kısmi Aracı
İD→G→AR→ÇSN	0,500	0,129	0,629	0,205	0,083	0,179	Kısmi Aracı
ED→G→AR→ÇSN	0,355	0,125	0,480	0,260	0,084	0,173	Kısmi Aracı

Not: DD Doğruluk Deneyimi, İD İlgörü Deneyimi, ED Etkileşim Deneyimi, G Güven, AR Algılanan Risk, ÇSN Çevrimiçi Satın Alma Niyeti

Yapılan analizler ve hesaplamalar sonucunda yapay zekâ pazarlama teknolojisi deneyim unsurları (Doğruluk $0,20 < VAF = 0,254 < 0,80$ İlgörü $0,20 < VAF = 0,205 < 0,80$ Etkileşim $0,20 < VAF = 0,260 < 0,80$) ile çevrimiçi satın alma niyeti arasındaki ilişkide güven ve algılanan risk isimli ardışık değişkenler ile seri aracılık gerçekleşmektedir. Bu ilişkilerdeki VAF değerleri incelendiğinde kısmi aracılığın söz konusu olduğu görülmektedir. Bu doğrultuda H10 hipotezi kabul edilmiştir.

Tartışma

Son zamanlarda yaşanan pandemik olaylar ve sonrasında değişen satın alma alışkanlıkları, satıcı işletmeler ile akademisyenlerin odağını çevrimiçi bağlama çevirmiştir. Satıcı işletmeler, internet mecrasında var olabilmek için yapay zekâ ve büyük verinin sunmuş olduğu avantajları kullanmakta akademisyenler ise çevrimiçi kanallarda kullanılan yapay zekâ teknolojilerinin etkinliğini artırmak için araştırmalar yapmaktadır. Yapılan araştırmalarda tüketicilerin güven ve risk algı düzeylerinin çevrimiçi satın alma kararında etkili olduğu kabul edilmiştir (Kim vd., 2008; Ling vd., 2011; Lăzăroiu vd., 2020). Bu araştırmaların çoğu genel olarak e-ticarette tüketici davranışını incelerken mevcut araştırma, konuyu yapay zekâ pazarlama teknolojisi bağlamında ele almıştır. Bu bağlamda, yapay zekâ pazarlama teknolojisinin doğruluk, içgörü ve etkileşim olmak üzere üç deneysel unsurunun bu teknolojiye ilişkin güveni ve risk algı düzeylerini etkileyebileceğini; güven ve azalan risk algısının ise satın alma niyetini olumlu olarak etkileyebileceğini savunan bir model tasarlanmıştır. Araştırma sonuçları, yapay zekâ pazarlama teknolojisinin sunduğu metin, görsel ve ses ile arama yapma algoritmasının, tüketicinin istediği ürünleri doğru bir şekilde almasına yardımcı olması özelliğinin, bu teknolojiye ilişkin güveni etkilemediğini göstermektedir. Yin & Qiu (2021, s.12)'nin çalışmasının sonuçları ile benzer bir şekilde Türkiye, gelişmiş dünya pazarlarının aksine satın alma sürecinde teknolojinin bu özelliğinden (akıllı arama) sınırlı bir şekilde yararlanmaktadır. Tüketiciler metin ile aramayı görsel ve ses ile aramaya göre daha fazla tercih etmektedirler. Kullanım oranı az olan bu özelliklerin, daha fazla kullanılması teknolojiye olan güvene olumlu katkı sağlayabilir. Alam vd. (2023, s.18)'e göre tüketicilerin yapay zekâ pazarlama teknolojisini kullanım miktarı artıca, yapay zekâyâ güvenmeye başlama olasılıkları da o kadar artmaktadır. Öte yandan yapay zekâ pazarlama teknolojisinin gezinme (tarama) alışkanlıklarına göre öneride bulunması, alışveriş geçmişi ve kullanıcı bilgileri doğrultusunda kişiselleştirilmiş bir arayüz sağlaması, "bu ürünleri de beğenebilirsiniz", "sizin için öneriler" gibi satın alınma potansiyeli olan ürünler sunması teknolojiye ilişkin güveni pozitif bir şekilde etkilemektedir. Diğer bir ifadeyle yapay zekâ pazarlama teknolojisinin içgörü deneyimi teknolojiye olan güveni artırmaktadır. Ayrıca çevrimiçi alışveriş ortamları olan web sayfaları ve uygulamalarındaki sanal müşteri hizmetleri asistanının tüketicinin sorularına zamanında ve doğru bir şekilde cevap vermesi de teknolojiye olan güveni pozitif bir şekilde etkilemektedir. Bulgular sıralanan bu etkileşim unsurlarının güveni, içgörü unsurlarına kıyasla daha az etkilediğini göstermektedir. Çevrimiçi alışverişte yapay zekâ destekli sanal asistanlar ile henüz siparişin teslimatı ile ilgili sınırlı iletişim söz konusudur (Yin & Qiu, 2021). Bu durum ise güven oluşturmada sanal etkileşimin (insan-makine) yetersiz kalması ile açıklanabilir.

Yapay zekâ pazarlama teknolojisinin doğruluk, içgörü ve etkileşim konusundaki deneysel gücü, tüketicilerin risk algılarını azaltmaktadır. Teknolojinin sahip olduğu akıllı arama ve öneri sistemlerini, kişiselleştirilmiş satın alma arayüzlerini ve sanal müşteri hizmetleri asistanlarını daha önce deneyimlemiş tüketiciler çevrimiçi satın alımlarda teknolojiyi daha az riskli bulmaktadır. Başka bir ifadeyle tüketiciler kişisel bilgilerini (telefon, adres, kimlik ve kart şifresi gibi) vermekten ve bu bilgilerin veri tabanına kaydolmasından kaynaklı belirsizlik ve kayıplardan daha az endişe duymaktadırlar. Araştırma örnekleminin %54'ünün beş yıldan daha fazla çevrimiçi satın alma deneyimine ve en az ayda bir kez satın alma sıklığına sahip olması, tecrübeli tüketicilerin yaşadıkları deneyimlerine güvenerek teknolojiyi ortalama bir tüketiciden daha az riskli bulduklarını söylemek yanlış olmayacaktır. Bu bulgu önceki deneyimlerinden memnun tüketicilerin düşük seviyede belirsizlikten kaynaklı olarak risk algılarının azalacağını vurgulayan Mohseni vd. (2018)'nin çalışma sonuçlarını desteklemektedir. Öte yandan e-perakendecilikte çevrimiçi satın alma deneyimi olmasına rağmen tüketicilerin algılanan risk düzeylerinin arttığını tespit eden Mathew & Mishra (2014)'nin çalışmasından farklılaşmaktadır. Özetle tüketicilerin davranışsal niyetlerinin pozitif yönde etkileyebilmek için algılanan riski azaltmada öncül olan deneysel unsurların (doğruluk, içgörü ve etkileşim) iyileştirilmesi faydalı olabilir.

Yapay zekâ pazarlama teknolojisinin içgörü ve etkileşim deneyimi sonucunda oluşan güvenin, tüketicilerin çevrimiçi satın alma niyetlerinde pozitif rol oynadığı tespit edilmiştir. Satın alma niyetinin temel belirleyicisi olan tutum, tüketicilerin güven algılarından pozitif bir şekilde etkilenmektedir. Zhu vd. (2009)'e göre tüketicilerin satın alma niyetlerini artırmak için onların tutumlarında belirleyici rol oynayan güvenin olumlu yönde desteklenmesi gerekmektedir. Mevcut araştırmanın sonuçları bu bulgu ile tutarlıdır.

Bozpolat (2024).

Güveni tanımlayan tüketicinin yapay zekâ pazarlama teknolojisinin çıkarlarına uygun bir şekilde hareket ettiğine ve görevini çok iyi yerine getirdiğine olan inancı ne kadar güçlüyse çevrimiçi satın alma niyeti o kadar yüksek olacaktır. Teknolojiye olan güvenin ise deneysel unsurlardan etkilendiği unutulmamalıdır. Benzer bir şekilde tüketicilerin azalan risk algılarının satın alma niyetlerini pozitif bir şekilde etkilediği bulgulanmıştır. Bu bulgu Chen & Huang (2017)'in çalışma sonuçları ile tutarlıdır. Diğer yandan Ventre & Kolbe (2020)'nin sonuçlarından farklılaşmaktadır. Çevrimiçi alışveriş sıklığı az ve risk algısı yüksek tüketicilerin satın alma niyeti daha önce yaşamış oldukları tatmin edici deneyimlere bağlıdır. Yaşadıkları deneyimlerden memnun olan tüketiciler, teknolojik deneyimden çok önceki memnuniyet düzeylerine odaklandıklarından risklerin farkında olarak yine de satın alma niyetinde olabilirler (Pires vd., 2004). Ancak bu durum çevrimiçi alışveriş geçmişi ve sıklığı fazla olan tüketiciler için geçerli değildir. Algılanan risk onların yeniden satın alma niyetlerini etkilememektedir (Martin vd., 2015). Diğer bir ifadeyle teknolojiyi deneyimleme miktarı artıkça teknolojinin mevcut riski satın alma niyetinde bir sorun oluşturmamaktadır. Ancak mevcut araştırmanın örneklem karakteristiği çevrimiçi alışveriş geçmişi ve sıklığı fazla olan tüketicilerden oluşmasına rağmen sonuçların bu yönlü çıkmaması daha fazla araştırma yapma ihtiyacı doğurmaktadır. Son olarak yapılan aracılık analizinde, yapay zekâ pazarlama teknolojisi deneyim unsurlarından, güven ve algılanan risk yoluyla çevrimiçi satın alma niyetine giden seri bir aracılık etkisi tespit edilmiştir. Bu bulgu, güven ve seri olarak algılanan risk yoluyla deneysel unsurların çevrimiçi satın alma niyeti üzerinde önemli bir dolaylı etkisi olduğunu göstermektedir. Başka bir ifadeyle yapay zekâ pazarlama teknolojisinin deneysel unsurları sonucunda oluşan güven, tüketicilerin risk algılarını azaltmakta bu durum ise çevrimiçi satın alma niyetini olumlu yönde etkilemektedir.

Mevcut araştırma teorik ve pratik çıkarımlar sunmaktadır. SOR modelini yapay zekâ pazarlama teknolojisi ve Türkiye özelinde uyarlayarak literatüre katkı sağlamaktadır. Modelde güven ve algılanan risk, sezgisel algı değişkenleri olarak kategorize edilerek organizma olarak ele alınmıştır. Bu bağlamda araştırma sonuçları yapay zekâ teknolojisinin pazarlama amaçlı kullanılmasına ilişkin ulusal literatürdeki eksikliği gidermektedir. Ayrıca çalışma, gelişmekte olan Türkiye pazarına ilişkin veriler sunduğundan uluslararası literatürde ülke bazlı karşılaştırmalar yapmaya imkân veren bulgular içermektedir. Çevrimiçi alışveriş siteleri ve uygulama yapıcılarının teknolojinin doğruluk deneyimini güçlendirmek için teknolojik altyapının verimliliğini artırmalı ve tüketicilere resim ve ses ile arama alışkanlıkları kazandırılmalıdır. Arama arayüzlerinin etkin ve doğru sonuçlar verecek şekilde tasarlanması tüketicileri bu özellikleri kullanma konusunda motive edebilir. Yapay zekâ algoritması ile içgörü deneyimi sürekli olarak katma değer yaratacak unsurlarla zenginleştirilmelidir. İçgörü deneyiminin odak noktası yapay zekâ teknolojisini kullanarak akıllı önerilerde bulunmaktır. Öneri sistemlerini kullanan platform sayısının artması tüketicilerde kullanım alışkanlığı yaratabilir. Etkileşim deneyiminin odak noktası olan akıllı sanal asistanlar ile sistemde yaşanan problemler en aza indirgenebilir. Ancak sanal asistanların sorunlara insan beynine yakın çözüm önerilerinde bulunabilmesi için yazılımları gerek dahili gerekse harici bilgiyi kullanarak sürekli olarak güncellenmelidir. Deneysel unsurlar işletmeler açısından karlılığa, tüketiciler açısından işlem maliyetlerinin azaltılmasına katkısı nedeniyle yapay zekâ destekli platformların önemli bileşenlerinden biri olarak görülmelidir. Tüm bu tavsiyeler tüketicinin teknolojik deneyimini benzersiz yaparak güvenin oluşmasını ve algılanan riskin ise azalmasını sağlayarak satın alma niyetini sürdürülebilir kılabılır.

Yukarıda ifade edilen muhtemel katkılara rağmen her çalışmada olduğu gibi bu araştırmanın da birtakım sınırlamaları mevcuttur. Araştırma her ne kadar ortalama internet kullanıcılarını temsil eden bir örneklem üzerinden gerçekleşse de Türk internet kullanıcılarının tamamını yansıtmamaktadır. Örneklemin %5,4'lük kısmı 60 yaş ve üzeri tüketicilerden oluşmaktadır. Bu grubun güven ve risk algısının genç ve deneyimli tüketicilere göre fazla olması olasıdır. Bulguların genellenebilirlik gücünü artırabilmek için ileriki çalışmalarda yaş ve kullanım sıklığı kontrol değişkenleri modele eklenebilir. SOR modeline dayanan araştırma modeli Planlı Davranış Teorisi çerçevesinde genişletilerek gerçek satın alma davranışı ve tutum dahil edilebilir. Güven mi algılanan riski azaltır yoksa algılanan risk azalınca mı güven artar sorusunu netleştirmek adına farklı örneklerde daha fazla araştırmaya ihtiyaç vardır.



This research article has been licensed with Creative Commons Attribution - Non-Commercial 4.0 International License. Bu araştırma makalesi, Creative Commons Atıf - Gayri Ticari 4.0 Uluslararası Lisansı ile lisanslanmıştır.

Yazar Katkıları

Yazar çalışmayı tek başına hazırladığını beyan etmiştir.

Teşekkür Beyanı

Yazar teşekkür beyanında bulunmamıştır.

Destek Beyanı

Yazar destek beyanında bulunmamıştır.

Çıkar Çatışması

Yazar herhangi bir çıkar çatışması beyan etmemiştir.

Etik Beyanı

Yazar çalışma için Nevşehir Hacı Bektaş Veli Üniversitesi'nden 28/11/2023 tarih ve 2023.14.319/14 sayılı karar ile Etik Kurul Onayı alındığını beyan etmiştir.

Sorumlu Özel Sayı Editörleri

Doç. Dr. Beyza Mina Ordu-Akkaya, Ankara Sosyal Bilimler Üniversitesi

Doç. Dr. Görkem Ataman, Yaşar Üniversitesi

Arş. Gör. Yunus Yıldırım, Afyon Kocatepe Üniversitesi

Kaynakça/References

- Abu-Shamaa, R., Abu-Shanab, E., & Khasawneh, R. (2016). Payment methods and purchase intention from online stores: An empirical study in Jordan. *International Journal of E-Business Research (IJEBR)*, 12(2), 31-44. <https://doi.org/10.4018/IJEBR.2016040103>
- Aini, Q., Sembiring, I., Setiawan, A., Setiawan, I., & Rahardja, U. (2023). Perceived accuracy and user behavior: Exploring the impact of AI-based air quality detection application (AIKU). *Indonesian Journal of Applied Research (IJAR)*, 4(3), 209-218. <https://doi.org/10.30997/ijar.v4i3.356>
- Ajenaghughrure, I. B., da Costa Sousa, S. C., & Lamas, D. (2020). *Risk and trust in artificial intelligence technologies: A case study of autonomous vehicles*. 13th International Conference on Human System Interaction, Tokyo, Japan. <https://doi.org/10.1109/HSI49210.2020.9142686>
- Aksay, B., & Ünal, A. Y. (2016). Yapısal Eşitlik Modellemesi Kapsamında Formatif Ve Reflektif Ölçüm. *Cag University Journal of Social Sciences*, 13(2), 1-21. <https://dergipark.org.tr/en/download/article-file/696237>
- Alam, S. S., Masukujjaman, M., Mohamed Makhbul, Z. K., Helmi Ali, M., Ahmad, I., & Al Mamun, A. (2023). Experience, Trust, eWOM Engagement and Usage Intention of AI Enabled Services in Hospitality and Tourism Industry: Moderating Mediating Analysis. *Journal of Quality Assurance in Hospitality & Tourism*, 1-29. <https://doi.org/10.1080/1528008X.2023.2167762>
- Ameen, N., Tarhini, A., Reppel, A., & Anand, A. (2021). Customer experiences in the age of artificial intelligence. *Computers in Human Behavior*, 114, 106548. 1-14. <https://doi.org/10.1016/j.chb.2020.106548>
- Antony, S., Lin, Z., & Xu, B. (2006). Determinants of escrow service adoption in consumer-to-consumer online auction market: an experimental study. *Decision Support Systems*, 42(3), 1889-1900. <https://doi.org/10.1016/j.dss.2006.04.012>
- Baber, R., & Baber, P. (2022). Influence of social media marketing efforts, e-reputation and destination image on intention to visit among tourists: application of SOR model. *Journal of Hospitality and Tourism Insights*, 6(5), 2298-2316. <https://doi.org/10.1108/JHTI-06-2022-0270>
- Bashir, S., Anwar, S., Awan, Z., Qureshi, T. W., & Memon, A. B. (2018). A holistic understanding of the prospects of financial loss to enhance shopper's trust to search, recommend, speak positive and frequently visit an online shop. *Journal of Retailing and Consumer Services*, 42, 169-174. <https://doi.org/10.1016/j.jretconser.2018.02.004>
- Beyari, H., & Garamoun, H. (2022). The Effect of Artificial Intelligence on End-User Online Purchasing Decisions: Toward an Integrated Conceptual Framework. *Sustainability*, 14(15), 1-17. <https://doi.org/10.3390/su14159637>
- Bhatnagar, A., Misra, S., & Rao, H. R. (2000). On risk, convenience, and Internet shopping behavior. *Communications of the ACM*, 43(11), 98-105. <https://dl.acm.org/doi/fullHtml/10.1145/353360.353371>
- Bhatti, A., Saad, S., & Gbadebo, S. M. (2019). Effect of financial risk, privacy risk and product risk on online shopping behavior. *Pakistan Journal of Humanities and Social Sciences*, 7(4), 342-356. <https://doi.org/10.52131/pjhs.2019.0704.0091>
- Bitkina, O. V., Jeong, H., Lee, B. C., Park, J., Park, J., & Kim, H. K. (2020). Perceived trust in artificial intelligence technologies: A preliminary study. *Human Factors and Ergonomics in Manufacturing & Service Industries*, 30(4), 282-290. <https://doi.org/10.1002/hfm.20839>
- Chen, J. S., Le, T. T. Y., & Florence, D. (2021). Usability and responsiveness of artificial intelligence chatbot on online customer experience in e-retailing. *International Journal of Retail & Distribution Management*, 49(11), 1512-1531. <https://doi.org/10.1108/IJRDM-08-2020-0312>
- Chen, Y. S., & Huang, S. Y. (2017). The effect of task-technology fit on purchase intention: The moderating role of perceived risks. *Journal of Risk Research*, 20(11), 1418-1438. <https://doi.org/10.1080/13669877.2016.1165281>
- Cohen, J. (1988). *Statistical power analysis for the behavioral sciences (2nd ed.)*. Lawrence Erlbaum Associates, Publishers
- Crockett, K., Garratt, M., Latham, A., Colyer, E., & Goltz, S. (2020). *Risk and trust perceptions of the public of artificial intelligence applications*. International Joint Conference on Neural Networks (IJCNN), Glasgow, UK <https://doi.org/10.1109/IJCNN48605.2020.9207654>
- Curzon, J., Kosa, T. A., Akalu, R., & El-Khatib, K. (2021). Privacy and artificial intelligence. *IEEE Transactions on Artificial Intelligence*, 2(2), 96-108. <https://doi.org/10.1109/TAI.2021.3088084>
- Fornell, C., & Larcker, D. F. (1981). Evaluating structural equation models with unobservable variables and measurement error. *Journal of Marketing Research*, 18(1), 39-50. <https://doi.org/10.1177/002224378101800104>
- Friedman, A., Knijnenburg, B.P., Vanhecke, K., Martens, L., & Berkovsky, S. (2015). privacy aspects of recommender systems. In: Ricci, F., Rokach, L., Shapira, B. (Eds) *Recommender Systems Handbook*. Springer, Boston, MA. <https://doi.org/10.1007/978->
- Bozpolat (2024).

[1-4899-7637-6 19](https://doi.org/10.1145/3324300)

- Hafizoğlu, F. M., & Sen, S. (2019). Understanding the influences of past experience on trust in human-agent teamwork. *ACM Transactions on Internet Technology (TOIT)*, 19(4), 1-22. <https://doi.org/10.1145/3324300>
- Hair Jr, J. F., Hult, G. T. M., Ringle, C. M., & Sarstedt, M. (2017a). *A primer on partial least squares structural equation modeling (PLS-SEM)*. Second Edition, Sage Publications. Thousand Oaks, California.
- Hair, J. F., Matthews, L. M., Matthews, R. L., & Sarstedt, M. (2017). PLS-SEM or CB-SEM: updated guidelines on which method to use. *International Journal of Multivariate Data Analysis*, 1(2), 107- 123. <https://doi.org/10.1504/IJMDA.2017.087624>
- Hair, J. F., Risher, J. J., Sarstedt, M., & Ringle, C. M. (2019). When to use and how to report the results of PLS-SEM. *European Business Review*, 31(1), 2-24. <https://doi.org/10.1108/EBR-11-2018-0203>
- Hair, J.F., Sarstedt, M., Hopkins, L. & Kuppelwieser, V.G. (2014). Partial least squares structural equation modeling (PLS-SEM): An emerging tool in business research. *European Business Review*, 26(2), 106-121. <https://doi.org/10.1108/EBR-10-2013-0128>
- Hair, J. F., Ringle, C. M., & Sarstedt, M. (2011). PLS-SEM: Indeed a silver bullet. *Journal of Marketing theory and Practice*, 19(2), 139-152. <https://doi.org/10.2753/MTP1069-6679190202>
- Haleem, A., Javaid, M., Qadri, M. A., Singh, R. P., & Suman, R. (2022). Artificial intelligence (AI) applications for marketing: A literature-based study. *International Journal of Intelligent Networks*, 3, 119-132. <https://doi.org/10.1016/j.ijin.2022.08.005>
- Hasan, R., Shams, R., & Rahman, M. (2021). Consumer trust and perceived risk for voice-controlled artificial intelligence: The case of Siri. *Journal of Business Research*, 131, 591-597. <https://doi.org/10.1016/j.jbusres.2020.12.012>
- Henseler, J., Ringle, C. M., & Sarstedt, M. (2015). A new criterion for assessing discriminant validity in variance-based structural equation modeling. *Journal of the Academy of Marketing Science*, 43, 115-135. <https://doi.org/10.1007/s11747-014-0403-8>
- Hong, I. B., & Cha, H. S. (2013). The mediating role of consumer trust in an online merchant in predicting purchase intention. *International Journal of Information Management*, 33(6), 927-939. <https://doi.org/10.1016/j.ijinfomgt.2013.08.007>
- Jacoby, J., & Kaplan, L. B. (1972). *The components of perceived risk*. In Proceedings of the 3rd Annual Conference of the Association for Consumer Research, Chicago, IL, USA, 3–5 November, pp. 382–393.
- Jarek, K., & Mazurek, G. (2019). Marketing and artificial intelligence. *Central European Business Review*, 8(2). 46-55. <https://doi.org/10.18267/j.cebr.213>
- Khrais, L. T. (2020). Role of artificial intelligence in shaping consumer demand in E-commerce. *Future Internet*, 12(12), 1-14. <https://doi.org/10.3390/fi12120226>
- Kim, D. J., Ferrin, D. L., & Rao, H. R. (2008). A trust-based consumer decision-making model in electronic commerce: The role of trust, perceived risk, and their antecedents. *Decision Support Systems*, 44(2), 544-564. <https://doi.org/10.1016/j.dss.2007.07.001>
- Kim, J., Giroux, M., & Lee, J. C. (2021). When do you trust AI? The effect of number presentation detail on consumer trust and acceptance of AI recommendations. *Psychology & Marketing*, 38(7), 1140-1155. <https://doi.org/10.1002/mar.21498>
- Ko, H., Jung, J., Kim, J., & Shim, S. W. (2004). Cross-cultural differences in perceived risk of online shopping. *Journal of Interactive Advertising*, 4(2), 20-29. <https://doi.org/10.1080/15252019.2004.10722084>
- Kopalle, P. K., Gangwar, M., Kaplan, A., Ramachandran, D., Reinartz, W., & Rindfleisch, A. (2022). Examining artificial intelligence (AI) technologies in marketing via a global lens: Current trends and future research opportunities. *International Journal of Research in Marketing*, 39(2), 522-540. <https://doi.org/10.1016/j.ijresmar.2021.11.002>
- Kumar, V., Rajan, B., Venkatesan, R., & Lecinski, J. (2019). Understanding the role of artificial intelligence in personalized engagement marketing. *California Management Review*, 61(4), 1-21. <https://doi.org/10.1177/0008125619859317>
- Lăzăroiu, G., Neguriță, O., Grecu, I., Grecu, G., & Mitran, P. C. (2020). Consumers' decision-making process on social commerce platforms: Online trust, perceived risk, and purchase intentions. *Frontiers in Psychology*, 11, 890, 1-7. <https://doi.org/10.3389/fpsyg.2020.00890>
- Ling, K. C., Daud, D. B., Piew, T. H., Keoy, K. H., & Hassan, P. (2011). Perceived risk, perceived technology, online trust for the online purchase intention in Malaysia. *International Journal of Business and Management*, 6(6), 167-182. <https://doi.org/10.5539/ijbm.v6n6p167>
- Marsh, H. W., Balla, J. R., & McDonald, R. P. (1988). Goodness-of-fit indexes in confirmatory factor analysis: The effect of sample size. *Psychological Bulletin*, 103(3), 391-410. <https://doi.org/10.1037/0033-2909.103.3.391>
- Martin, J., Mortimer, G., & Andrews, L. (2015). Re-examining online customer experience to include purchase frequency and perceived risk. *Journal of Retailing and Consumer Services*, 25, 81-95. <https://doi.org/10.1016/j.jretconser.2015.03.008>

- Maseeh, H. I., Jebarajakirthy, C., Pentecost, R., Arli, D., Weaven, S., & Ashaduzzaman, M. (2021). Privacy concerns in e-commerce: A multilevel meta-analysis. *Psychology & Marketing, 38*(10), 1779-1798. <https://doi.org/10.1002/mar.21493>
- Mathew, P. M., & Mishra, S. (2014). Online retailing in India: Linking internet usage, perceived risks, website attributes and past online purchase behaviour. *The Electronic Journal of Information Systems in Developing Countries, 65*(1), 1-17. <https://doi.org/10.1002/j.1681-4835.2014.tb00466.x>
- McKnight, D. H., Choudhury, V., & Kacmar, C. (2002). Developing and validating trust measures for e-commerce: An integrative typology. *Information Systems Research, 13*(3), 334-359. <https://doi.org/10.1287/isre.13.3.334.81>
- Ming, J., Jianqiu, Z., Bilal, M., Akram, U., & Fan, M. (2021). How social presence influences impulse buying behavior in live streaming commerce? The role of SOR theory. *International Journal of Web Information Systems, 17*(4), 300-320. <https://doi.org/10.1108/IJWIS-02-2021-0012>
- Mohseni, S., Jayashree, S., Rezaei, S., Kasim, A., & Okumus, F. (2018). Attracting tourists to travel companies' websites: the structural relationship between website brand, personal value, shopping experience, perceived risk and purchase intention. *Current Issues in Tourism, 21*(6), 616-645. <https://doi.org/10.1080/13683500.2016.1200539>
- Munikrishnan, U. T., Huang, K., Mamun, A. A., & Hayat, N. (2023). Perceived risk, trust, and online food purchase intention among Malaysians. *Business Perspectives and Research, 11*(1), 28-43. <https://doi.org/10.1177/227853372111043968>
- Naiyi, Y. E. (2004). Dimensions of consumer's perceived risk in online shopping. *Journal of Electronic Science and Technology, 2*(3), 177-182.
- Nalbant, K. G., & Aydın, S. (2023). Development and transformation in digital marketing and branding with artificial intelligence and digital technologies dynamics in the Metaverse universe. *Journal of Metaverse, 3*(1), 9-18. <https://doi.org/10.57019/jmv.1148015>
- Overgoor, G., Chica, M., Rand, W., & Weishampel, A. (2019). Letting the computers take over: Using AI to solve marketing problems. *California Management Review, 61*(4), 156-185. <https://doi.org/10.1177/0008125619859318>
- Özbek, A., & Sırakaya, Ö. (2022). Türkiye'de kullanılan e-ticaret platformlarının performanslarının karşılaştırılması. *Kırıkkale Üniversitesi Sosyal Bilimler Dergisi, 12*(2), 469-492. <https://dergipark.org.tr/en/download/article-file/2218809>
- Peng, C., & Kim, Y. G. (2014). Application of the stimuli-organism-response (SOR) framework to online shopping behavior. *Journal of Internet Commerce, 13*(3-4), 159-176. <https://doi.org/10.1080/15332861.2014.944437>
- Pires, G., Stanton, J., & Eckford, A. (2004). Influences on the perceived risk of purchasing online. *Journal of Consumer Behaviour: An International Research Review, 4*(2), 118-131. <https://doi.org/10.1002/cb.163>
- Pitardi, V., & Marriott, H. R. (2021). Alexa, she's not human but... Unveiling the drivers of consumers' trust in voice-based artificial intelligence. *Psychology & Marketing, 38*(4), 626-642. <https://doi.org/10.1002/mar.21457>
- Qalati, S. A., Vela, E. G., Li, W., Dakhan, S. A., Hong Thuy, T. T., & Merani, S. H. (2021). Effects of perceived service quality, website quality, and reputation on purchase intention: The mediating and moderating roles of trust and perceived risk in online shopping. *Cogent Business & Management, 8*(1), 1-20. <https://doi.org/10.1080/23311975.2020.1869363>
- Rohden, S. F., & Zeferino, D. G. (2023). Recommendation agents: A analysis of consumers' risk perceptions toward artificial intelligence. *Electronic Commerce Research, 23*(4), 2035-2050. <https://doi.org/10.1007/s10660-022-09626-9>
- Rooij, S. V. (2022). *Taking it personally? A study on the effects of trust and privacy in the context of AI-enabled personalization*. Master Thesis, MSc Marketing, Radboud University.
- Schwerter, F., & Zimmermann, F. (2020). Determinants of trust: The role of personal experiences. *Games and Economic Behavior, 122*, 413-425. <https://doi.org/10.1016/j.geb.2020.05.002>
- Sharifpour, M., Walters, G., Ritchie, B. W., & Winter, C. (2014). Investigating the role of prior knowledge in tourist decision making: A structural equation model of risk perceptions and information search. *Journal of Travel Research, 53*(3), 307-322. <https://doi.org/10.1177/0047287513500390>
- Shavit, T., Lahav, E., & Rosenboim, M. (2016). Don't fear risk, learn about it: How familiarity reduces perceived risk. *Applied Economics Letters, 23*(15), 1069-1072. <https://doi.org/10.1080/13504851.2015.1133892>
- Song, M., Xing, X., Duan, Y., Cohen, J., & Mou, J. (2022). Will artificial intelligence replace human customer service? The impact of communication quality and privacy risks on adoption intention. *Journal of Retailing and Consumer Services, 66*, 102900, 1-17. <https://doi.org/10.1016/j.jretconser.2021.102900>
- Stanciu, V., & Rîndaşu, S. M. (2021). Artificial Intelligence in retail: Benefits and risks associated with mobile shopping applications. *Amfiteatru Economic, 23*(56), 46-64. <https://doi.org/10.24818/EA/2021/56/46>
- Trivedi, J. (2019). Examining the customer experience of using banking chatbots and its impact on brand love: The moderating role of perceived risk. *Journal of Internet Commerce, 18*(1), 91-111. <https://doi.org/10.1080/15332861.2019.1567188>

- Tüik (2023, 21 Kasım). *Hanehalkı Bilişim Teknolojileri Kullanım Araştırması*. [https://data.tuik.gov.tr/Bulten/Index?p=Hanehalki-Bilisim-Teknolojileri-\(BT\)-Kullanim-Arastirmasi-2023-49407](https://data.tuik.gov.tr/Bulten/Index?p=Hanehalki-Bilisim-Teknolojileri-(BT)-Kullanim-Arastirmasi-2023-49407)
- Udo, G. J., Bagchi, K. K., & Kirs, P. J. (2010). An assessment of customers'e-service quality perception, satisfaction and intention. *International Journal of Information Management*, 30(6), 481-492. <https://doi.org/10.1016/j.ijinfomgt.2010.03.005>
- Ventre, I., & Kolbe, D. (2020). The impact of perceived usefulness of online reviews, trust and perceived risk on online purchase intention in emerging markets: A Mexican perspective. *Journal of International Consumer Marketing*, 32(4), 287-299. <https://doi.org/10.1080/08961530.2020.1712293>
- Verma, S., Sharma, R., Deb, S., & Maitra, D. (2021). Artificial intelligence in marketing: systematic review and future research direction. *International Journal of Information Management Data Insights*, 1(1), 1-8. <https://doi.org/10.1016/j.ijime.2020.100002>
- Viberg, E., & Halldén, L. (2023). *Do consumers trust it?: Exploring consumers trust in artificial intelligence personalization*. Bachelor Thesis, Linnaeus University, Sweden.
- Vlačić, B., Corbo, L., e Silva, S. C., & Dabić, M. (2021). The evolving role of artificial intelligence in marketing: A review and research agenda. *Journal of Business Research*, 128, 187-203. <https://doi.org/10.1016/j.jbusres.2021.01.055>
- Wirtz, J., Patterson, P. G., Kunz, W. H., Gruber, T., Lu, V. N., Paluch, S., & Martins, A. (2018). Brave new world: service robots in the frontline. *Journal of Service Management*, 29(5), 907-931. <https://doi.org/10.1108/JOSM-04-2018-0119>
- Yin, J., & Qiu, X. (2021). AI technology and online purchase intention: Structural equation model based on perceived value. *Sustainability*, 13(10), 1-16. <https://doi.org/10.3390/su13105671>
- Zhu, B., Kowatthanakul, S., & Satanasavapak, P. (2019). Generation Y consumer online repurchase intention in Bangkok: Based on Stimulus-Organism-Response (SOR) model. *International Journal of Retail & Distribution Management*, 48(1), 53-69. <https://doi.org/10.1108/IJRDM-04-2018-0071>
- Zhu, D. S., O'Neal, G. S., Lee, Z. C., & Chen, Y. H. (2009). *The effect of trust and perceived risk on consumers' online purchase intention*. International Conference on Computational Science and Engineering, 4(August), Vancouver, BC, Canada, 771-776.

Research Article (Special Issue) | Araştırma Makalesi (Özel Sayı)

Makine öğrenimi ile binek otomobil ihracat tahmini: MLP ve RBF modeli kullanımı

Yunus Emre Gür
Kamil Abdullah Eşidir
Şahin Göktuğ Kaldırımçı

Arş. Gör. Dr., Fırat Üniversitesi, yegur@firat.edu.tr, [0000-0001-6530-0598](https://orcid.org/0000-0001-6530-0598)

Dr., Fırat Kalkınma Ajansı, abdullahesidir@yahoo.com, [0000-0002-8106-1758](https://orcid.org/0000-0002-8106-1758)

Arş. Gör., Atatürk Üniversitesi, ksahin@atauni.edu.tr, [0009-0009-5925-9053](https://orcid.org/0009-0009-5925-9053)

Corresponding author/Sorumlu yazar: Yunus Emre Gür ✉ yegur@firat.edu.tr

Öz

Yapay Sinir Ağları (YSA), makine öğrenmesi alanında yaygın olarak kullanılan etkili bir yöntemdir ve tahmin yapmada başarılı sonuçlar sağlayabilir. YSA, biyolojik sinir sisteminden ilham alınarak matematiksel bir model oluşturur. Bu çalışmada, Türkiye'nin aylık binek otomobil ihracatını tahmin etmek için Yapay Sinir Ağı yaklaşımlarından Multilayer Perceptron (MLP) ve Radial Basis Function (RBF) modelleri kullanılmıştır. Geliştirilen sinir ağı modelleri, Türkiye'nin aylık binek otomobil ihracatını tahmin etmek için tasarlanmıştır. Bağımlı değişken olarak binek otomobil ihracat değeri kullanılırken, bağımsız değişkenler arasında Türkiye'nin aylık binek otomobil ithalatı, Amerikan Doları Kuru, Türkiye ithalatı, yeni otomobil satış adedi, motorlu kara taşıtları üretim endeksi ve yurt dışı üretici fiyat endeksi gibi faktörler bulunmaktadır. Türkiye İstatistik Kurumu ve Türkiye Cumhuriyet Merkez Bankası'ndan elde edilen aylık veriler (Ocak 2010 - Kasım 2023, 167 ay süresince) kullanılarak, Aralık 2023 ile Haziran 2024 arasındaki 7 aylık binek otomobil ihracat değerleri tahmin edilmiştir. İki farklı sinir ağı modelinin performansı karşılaştırılarak, tahminlerin farklılıkları ve sonuçları analiz edilmiştir. Bu çalışma, MLP modelinin RBF modele göre daha iyi sonuçlar verdiği sonucuna ulaşmıştır. Elde edilen sonuçlar, gelecekte binek otomobil ihracatının nasıl şekillenebileceği hakkında önemli bilgiler sunmaktadır.

Anahtar Kelimeler: Otomobil İhracatı, Yapay Sinir Ağları, Multilayer Perceptron (MLP), Radial Basis Function (RBF) ve İhracat Tahmini

JEL Kodları: C13, C32, C58

Passenger car export forecasting with machine learning: Using MLP and RBF model

Abstract

Artificial neural networks (ANN) are an effective method widely used in the field of machine learning and can provide successful results in making predictions. ANN creates a mathematical model inspired by the biological nervous system. This study uses multilayer perceptron (MLP) and radial basis function (RBF) models to predict Turkey's monthly passenger car exports. The neural network models are designed to forecast Turkey's monthly passenger car exports. The dependent variable is the value of passenger car exports. In contrast, the independent variables include Turkey's monthly passenger car imports, the USD exchange rate, Turkey's imports, the number of new car sales, the motor vehicle production index, and the foreign producer price index. Using monthly data obtained from the Turkish Statistical Institute and the Central Bank of the Republic of Turkey (January 2010–November 2023, 167 months), passenger car export values for seven months between December 2023 and June 2024 are estimated. The differences and results of the forecasts are analyzed by comparing the performance of two different neural network models. This study concludes that the MLP model gives better results than the RBF model. The obtained results provide important information about how passenger car exports may be shaped in the future.

Keywords: Automobile Export, Artificial Neural Networks, Multilayer Perceptron (MLP), Radial Basis Function (RBF) and Export Forecasting

JEL Codes: C13, C32, C58

Extended Summary

The automotive sector has a key role in economies with its high-added value, employment, and contribution to technological development. This sector generates a large business volume and supports economic growth by receiving materials from various industries. Export increases have been observed even during times of crisis, but events such as the 2008 global crisis and the 2020 COVID-19 pandemic caused temporary declines in exports and imports. Turkey's automobile industry is strategically important for

How to cite this article / Bu makaleye atıf vermek için:

Gür, Y. E., Eşidir, K. A., & Kaldırımçı, Ş. G. (2024). Makine öğrenimi ile binek otomobil ihracat tahmini: MLP ve RBF modeli kullanımı. *KOCATEPEİİBFD*, 26(Özel Sayı), 17-34. <https://doi.org/10.33707/akuiibfd.1426338>

its economic future and has become an important European production and export center. The Customs Union Agreement with the EU in 1996 gave the sector a significant boost. While exports and imports have steadily increased, it should not be forgotten that imports are also significant and sometimes lead to a trade deficit. This study aims to forecast Turkey's monthly passenger car exports using MLP and RBF artificial neural network models. These forecasts are based on data such as Turkey's automobile exports and imports, exchange rates, automobile sales, and production indices. The forecasts have the potential to anticipate economic developments and guide policymakers and industry participants in strategic planning.

This study forecasts passenger car exports using Python and artificial neural networks. With the right data and model architecture, artificial neural networks can predict export values. Model parameters and network structure should be set appropriately for model performance. The forecasters use MLP and RBF. The models are based on Turkey's monthly passenger car export value. Independent variables include Turkey's monthly passenger car imports, US dollar exchange rate, imports, new car sales, motor vehicle production index, and foreign producer price index. Monthly data from the Turkish Statistical Institute (January 2010–November 2023, 167 months~13 years) is used to estimate passenger car export values from December 2023 to June 2024.

As this study shows, there are many variables that affect vehicle exports. These include a country's economy, growth, exchange rates, consumer preferences, market trends, and export-import dependence. These variables can affect vehicle demand, design, production, and current account balance. In this study, TurkStat data is used to construct a model that includes dependent and independent variables. Moreover, the Dickey-Fuller test determines the stationarity of the data set variables. Using this statistical procedure, each variable in a multivariate data set should be independently tested for stationary time series. Additionally, time series analysis of independent variable data was conducted using ARIMA models, yielding forecasts for the independent variables for the period from December 2023 to June 2024. Python software was employed to forecast independent variable data. This software facilitated the automatic stationarization of the dataset. Given the inherent inability of MLP and RBF analyses to handle missing data, an approach was adopted where independent variable data for the prediction period were complete.

Regression, correlation, and mean percentage error (MAPE) values are considered performance measures. The MLP model gave better results in regression, correlation, and MAPE values than RBF; therefore, it was concluded that it modeled the relationships in the data set better and that its predictions were more accurate. Both models provided a fair comparison using the same number of observations (N = 167). In both models, 117 samples (70%) are used for training, and 50 samples (30%) are used for testing. The MAPE value was calculated as 12% in the MLP model and 18% in the RBF model. The motor vehicle production index was the most effective independent variable in both models.

The MLP model forecasts passenger car exports between 743 million USD and 957 million USD, while the RBF model forecasts 817 million USD. MLP's forecasts are more accurate, especially in March and November 2023. The RBF model underpredicts in some months but is closer to the export values. Both models reveal seasonal effects and general trends and perform differently over time. We conclude the analysis with the December 2023–June 2024 forecasts of both models. These forecasts suggest that further research is needed to understand how the models perform across market conditions and timeframes. The comparison reveals that MLP outperforms RBF. The MLP model can be improved and adjusted in the future. Additional features, data, and hyperparameter settings can be considered to improve model accuracy. Obtain more and better data to improve the model's performance. Adding new data can help the model provide more complete findings. Adding exogenous elements to the model, such as the economy, exchange rates, and international markets, can also improve future forecasts. This research only compared MLP and RBF models, but future studies could compare other machine learning or statistical models. This technique determines the most appropriate forecasting strategy. Hence, more powerful models, more data, and external variables can help the automobile industry make better decisions.

Giriş

Otomotiv sektörü, ekonomilerde kilit bir rol oynamaktadır çünkü yüksek katma değer yaratması, istihdama doğrudan ve dolaylı katkı sağlaması ve teknolojik gelişimi öncülük etmesi gibi faktörler taşımaktadır. Otomotiv sektörü, demir-çelik, lastik-plastik, tekstil, cam, boya, elektrik-elektronik gibi birçok sektörden malzeme ve hizmet tedarik ederken, pazarlama, bakım-onarım, yedek parça satışı, finansman ve sigortacılık gibi geniş bir yelpazede iş hacmi oluşturarak ekonomik büyümeyi destekler. Bu sektör aynı zamanda, gelişmiş ve gelişmekte olan ekonomilerde büyümeyi destekleyen önemli bir faktör olarak ortaya çıkar ve teknolojik ilerlemeyi hızlandırarak diğer sektörlerin büyümesine katkıda bulunur (Karakaş, 2019: 318).

Oluşturduğu temel ile bu sektör, demir-çelik, tekstil, cam, lastik, petro-kimya gibi farklı sektörlerden malzemeleri alarak bunları işleyip çeşitli ürünlere dönüştürmekte ve sonuç olarak tarım, ulaştırma ve turizm gibi birçok sektörde kullanılmak üzere önemli bir rol üstlenmektedir. İhracat tarafında bakıldığında, 1992-2020 arası otomotiv sektörünün sürekli bir ihracat artışı gösterdiği söylenebilir. Kriz dönemleri, örneğin 2000 ve 2001 yıllarında olduğu gibi, sektör ihracatında bile artışlar görmüştür. Fakat 2008'deki küresel kriz, ihracatta düşüşe neden olmuştur. Bu düşüşe rağmen, sonrasında bir toparlanma yaşanmıştır. İç pazarda ise talebe

bağlı olarak ithalat önemli ölçüde yükselmiştir. 1994'teki ekonomik kriz döneminde iç talep azaldığından ithalat düşmüş; fakat sonraki yıllarda yeniden artış göstermiştir. Benzer şekilde, 2001 yılında yaşanan kriz döneminde de benzer bir düşüş gözlemlenmiştir (Nur ve Çalbörü, 2023: 40).

Türkiye'nin otomobil endüstrisi, ülkenin ekonomik geleceği için stratejik bir öneme sahiptir. Teknoloji ve bilgi temelli üretimler ulusal ve yerel kalkınmanın en önemli unsurudur (Yoğunlu, 2022). Avrupa'nın önde gelen ülkeleri arasında yer alarak otomobil üretimi ve ihracatında başarılı bir konum elde etmiştir. Otomobil ihracatı, Türkiye'nin dış ticaret dengesine olumlu etkiler sağlamakta ve aynı zamanda istihdam olanakları sunarak ülkenin ekonomik büyümesini desteklemektedir. 1980'li yılların ortalarında benimsenen serbest piyasa politikalarıyla birlikte Türkiye'de ithalat oranlarında belirgin bir artış gözlenmiştir. Bu dönemde alınan liberal ekonomi politikaları, yerli üretimi zorlamış ve dışarıdan gelen ürünlere olan talebi artırmıştır. Ancak bu durum, özellikle otomotiv sektörü gibi stratejik öneme sahip sektörlerde üretim ve ihracat rakamlarını olumsuz etkileyerek dış ticaret açığının artmasına neden olmuştur. Buna rağmen, Türkiye'nin 1996 yılında Avrupa Birliği ile imzaladığı Gümrük Birliği Anlaşması, otomotiv sektörüne dönük önemli sonuçlar doğurmuştur. Bu anlaşma sayesinde Türkiye, Avrupa'dan birçok üreticinin üretim üssü haline gelmiş ve otomotiv üretiminde büyük bir ivme kazanmıştır. Türkiye'nin en büyük otomobil ihracatı yaptığı ülkeler arasında Almanya, Fransa, Birleşik Krallık, İtalya ve İspanya yer almaktadır (Çokşen, 2023: 16-17).

Bununla birlikte, Harmonize Sistem (HS) kodu, uluslararası ticarete mal ve hizmetleri sınıflandırmak için kullanılan bir kodlama sistemidir. Çalışmada, TÜİK veri tabanından alınan 8703 HS4 kodlu "Binek otomobilleri ve insan taşımak üzere imal edilmiş diğer motorlu taşıtlar (steysin vagonlar ve yarış arabaları dâhil)" dış ticaret verileri kullanılmıştır. Tablo 1'de, Türkiye'nin 2000 yılı ile 2022 yılları arası döneme ait binek otomobil dış ticaret değerleri yer almaktadır. Türkiye'nin binek otomobil ihracatında, 2000 yılından itibaren sürekli bir artış trendi görülmektedir. İhracat değeri 2000 yılında 629 milyon dolar iken, 2022 yılında 9 milyar 269 milyon dolara yükselmiştir. 2017 yılında 11 milyar 815 milyon dolar ile binek otomobilde ihracat zirvesi görülmüştür. İthalat değerlerinde ise dalgalanma görülmektedir. 2000 yılında 2 milyar 596 milyon dolar olan ithalat değeri, 2022 yılında 7 milyar 808 milyon dolara yükselmiştir. En yüksek ithalat değeri ise 2011 yılında 8 milyar 477 milyon dolar olarak kaydedilmiştir.

Tablo 1.Yıllara Göre Türkiye Binek Otomobil Dış Ticaret Değerleri (HS: 8703)

Yıllar	İhracat (Milyon USD)	İthalat (Milyon USD)	Yıllar	İhracat (Milyon USD)	İthalat (Milyon USD)
2000	629	2.596	2012	6.069	7.251
2001	973	588	2013	6.856	9.130
2002	1.298	814	2014	7.256	7.721
2003	2.198	2.220	2015	6.900	9.227
2004	3.934	4.215	2016	8.356	9.842
2005	4.373	4.298	2017	11.815	8.607
2006	5.645	4.271	2018	12.442	5.906
2007	6.840	4.749	2019	11.898	3.382
2008	7.474	4.554	2020	9.536	7.762
2009	6.086	4.267	2021	9.497	6.698
2010	6.210	6.822	2022	9.269	7.808
2011	6.486	8.477			

Kaynak: TÜİK, 2024.

Türkiye, binek otomobil dış ticaretinde aktif bir ihracatçı konumunda bulunmaktadır. Bununla birlikte, ithalatın da ihracat kadar kritik bir rol oynadığı ve bazen ticaret açığının ortaya çıktığı unutulmamalıdır. Yukarıdaki Tablo 1 incelendiğinde, özellikle 2013-2016 döneminde ithalat değerlerinde gözle görülür bir artış meydana gelmiş ve bu dönemde dış ticaret açığı daha belirgin hale gelmiştir. Diğer yandan, 2008 küresel mali krizi sırasında, Türkiye'nin ihracat ve ithalat değerlerinde bir düşüş yaşanmıştır. Ancak, krizin etkileri geçici olmuş ve hızla toparlanma görülmüştür. 2020'de ise dünya çapında yaşanan COVID-19 pandemisi, otomobil sektöründe daralmaya neden olmuştur (Çokşen, 2023: 31). Bu dönemde Türkiye'nin binek otomobil ihracat ve ithalat değerleri de olumsuz yönde etkilenmiştir. Türkiye'nin binek otomobil ve diğer motorlu taşıtlar ticaretinde ihracatın ithalatı aştığı gözlenmektedir. Bu durum, Türkiye'nin bu sektörde uluslararası pazarda rekabetçi olduğunu ve dış talebi karşılayabildiğini göstermektedir. Bununla birlikte, binek otomobil ithalatının da dikkatle izlenmesi gereken yüksek değerlere sahip olduğu unutulmamalıdır.

Bu çalışmanın amacı, MLP ve RBF yapay sinir ağı modellerini kullanarak Türkiye'nin aylık binek otomobil ihracatını tahmin etmektir. Bu tahminlerde bağımlı değişken olarak Türkiye'nin aylık binek otomobil ihracatı kullanılmıştır. Bağımsız değişkenler ise; Türkiye'nin aylık binek otomobil ithalatı, aylık Amerikan Dolar Kuru, aylık Türkiye ithalatı, aylık yeni otomobil satış adedi, motorlu kara taşıtları üretim endeksi ve yurt dışı üretici fiyat endeksi değerlerini içermiştir. Bu veriler, Türkiye İstatistik Kurumu ve Türkiye Cumhuriyet Merkez Bankası veri kaynaklarından temin edilmiştir. Toplamda Ocak 2010 ile Kasım 2023 arası 167 aya, yani 13 yıla ait veriler kullanılmıştır. Bu veriler doğrultusunda kullanılan modeller, Aralık 2023 ile Haziran 2024 arasındaki 7 aylık dönem için

binek otomobil ihracat değerlerini tahmin etmek için kullanılmıştır. İki farklı sinir ağı modelinin performansı kıyaslanmış ve tahmin sonuçları arasındaki farklar yorumlanmıştır.

Bununla birlikte, bu çalışma, binek otomobil ihracatının gelecekteki değerlerini tahmin ederek, olası ekonomik gelişmeleri önceden tespit etmeyi hedeflemektedir. Bu öngörüler, dış ticaret dengesi, istihdam ve ekonomik büyüme gibi alanlarda rehberlik sağlayabilir. Ayrıca, ekonomi politika yapımcılarına ve sektör katılımcılarına gelecekteki olası senaryoları değerlendirme ve uygun stratejiler geliştirme konusunda yardımcı olabilir. Elde edilen sonuçlar, işletmelerin ve karar alıcıların binek otomobil ihracatını etkileyen faktörleri daha iyi anlamalarına ve bu faktörleri göz önünde bulundurarak daha bilinçli kararlar almalarına imkân tanıyabilir. Endüstri açısından bakıldığında ise, bu tür modellerle sektörün gelecekteki performansını tahmin etmek, işletmelerin rekabetçilik çabalarına destek sunabilir. Genel olarak, bu çalışma, otomotiv sektörünün ekonomik önemini ve gelecekteki gelişimini anlamak, planlamak ve yönlendirmek bakımından büyük bir önem taşımaktadır.

1. Literatür İncelemesi

Makine öğrenmesi algoritmaları ile tahminleme çalışmaları, akademik literatürde oldukça geniş bir yer kaplamaktadır ve çeşitli alanlarda yoğun şekilde kullanılmaktadır. Makine öğrenmesi, veri analizi, tahmin, sınıflandırma ve kümeleme gibi birçok farklı problemin çözümünde etkili bir yaklaşım olarak öne çıkmaktadır. Özellikle büyük veri setlerinin olduğu alanlarda, gelecekteki değerleri tahmin etmek veya belirli olayların olasılığını değerlendirmek amacıyla makine öğrenmesi modelleri sıkça kullanılmaktadır. Makine öğrenmesi algoritmaları, karmaşık ilişkileri anlama ve gelecekteki olayları tahmin etme konularında büyük veri setleri üzerinde yapılan analizlerde ve öğrenme süreçlerinde önemli bir rol oynamaktadır. Bu sebeple, literatürde makine öğrenmesi tabanlı tahminleme çalışmalarının sayısı oldukça fazladır. Bu bağlamda, son yıllarda yapılan bazı örnek çalışmalara göz atıldığında;

Karaatlı vd. (2012)'nin çalışmasında, Türkiye'de yeni otomobil satış rakamlarının yapay sinir ağları (YSA) yöntemi kullanılarak tahmin edilmesi amaçlanmıştır. Çalışma, Ocak 2007'den Haziran 2011'e kadar olan aylık verileri kapsamakta ve otomobil satışlarını etkileyen çeşitli makroekonomik göstergeleri bağımsız değişken olarak kullanmaktadır. Araştırmada, gayri safi yurtiçi hasıla, reel kesim güven endeksi, yatırım harcamaları, tüketim harcamaları, tüketici güven endeksi, dolar kuru ve zaman gibi değişkenler ele alınmıştır. Çalışmanın sonuçları, YSA modelinin otomobil satış tahmininde kullanılabilecek etkili bir yöntem olduğunu göstermektedir.

Akyurt (2015)'un çalışmasında, Ocak 2011 - Eylül 2015 döneminde aylık yerli otomobil satış verileri kullanılarak, geri yayılım algoritması ile eğitilmiş ileri beslemeli yapay sinir ağı modeli uygulanmıştır. Modelin amacı, Türkiye'de üretilen yerli otomobillere olan talebi tahmin etmektir. Çalışmanın sonuçları, mevsimsel etkilerden arındırılmış veri seti kullanıldığında, gecikme uzunluğunun 2 ve gizli nöron sayısının 7 olduğu modelin en iyi tahmin sonuçlarını verdiğini göstermiştir. Bu bulgular, yerli otomobil satışlarına ilişkin gelecekteki taleplerin tahmin edilmesinde yapay sinir ağlarının etkili bir araç olabileceğini ortaya koymaktadır.

Topal (2019)'un çalışmasında, Türkiye'deki bir otomobil markasının satış miktarlarının tahmini için çevrimiçi tüketici bütünleşmesi ve arama motoru verileri kullanılarak yapay sinir ağları metodolojisi uygulanmıştır. Çalışma, Facebook marka sayfası ve Google Trends üzerinden elde edilen verileri kullanarak, 2012-2017 yılları arasında oluşturulan gönderiler ve bu gönderilere yapılan etkileşimler ile arama trend verilerine dayanmaktadır. Veriler Min-Max yöntemiyle normalleştirilmiş ve Bayesian Regülasyon geri yayılım yöntemiyle analiz edilmiştir. Çalışmanın sonuçları, çevrimiçi tüketici bütünleşmesi ve arama motoru verilerinin, yapay sinir ağları yöntemiyle Türkiye'deki bir otomobil markasının satış miktarlarını tahmin etmede etkili kullanılabileceğini göstermiştir. Analiz, %74 korelasyon ve %1 ortalama hata değeri ile yüksek bir tahmin başarısı sağlamıştır. Bu bulgular, sosyal medya ve arama motoru verilerinin, tüketici eğilimlerini ve markaya olan ilgiyi yansıttığı ve satış tahminlerinde değerli bir kaynak olabileceğini ortaya koymaktadır. Bu sonuçlar, pazarlama ve satış stratejilerinin geliştirilmesinde veriye dayalı yaklaşımların önemini vurgulamaktadır.

Karakaş (2019)'ın çalışmasında, Türkiye'nin otomotiv sektöründen elde edilen ihracat gelirlerini tahmin etmek için ARIMA modeli geliştirilmiştir. 2013-2018 yılları arasındaki aylık ihracat verileri kullanılarak, en uygun modelin ARIMA (1,2,1)(0,1,1) olduğu bulunmuştur. Bu model kullanılarak 2019 yılı için aylık ihracat geliri tahminleri yapılmış ve gerçekleşen verilerle karşılaştırıldığında, modelin doğru tahminler yaptığı gözlemlenmiştir. Modelin başarısı, düşük ortalama mutlak yüzde hata (MOYH) değeri ile desteklenmiştir, bu da modelin yüksek doğruluk derecesine sahip olduğunu gösterir. Ayrıca, otomotiv ihracat gelirlerine etki eden diğer değişkenlerin de analizi için farklı yöntemlerin kullanılabileceği ve bu yöntemlerin sonuçlarının kıyaslanabileceği belirtilmiştir.

Yurtsever (2022)'nin yapmış olduğu bir çalışmada, Ocak 2003 - Nisan 2021 arasında ABD'deki aylık otomobil satışlarının tahmini için derin öğrenme yöntemlerinden biri olan LSTM (Uzun Kısa Süreli Bellek) modeli kullanılmıştır. Çalışma, çeşitli ekonomik göstergeleri (ham petrol fiyatı, tüketici fiyat endeksi, işsizlik oranı gibi) kullanarak otomobil satışlarını tahmin etmeye odaklanmıştır. Bulgular, LSTM modelinin, ekonomik göstergelere dayalı çok değişkenli zaman serilerinde tahmin doğruluğu

açısından iyi performans sergilediğini göstermektedir. Beşinci model en düşük RMSE ve MAPE değerlerini elde ederek en iyi sonucu vermiştir. Bu sonuçlar, LSTM modelinin otomobil satış tahmininde etkili bir araç olabileceğini göstermektedir.

Kayakuş vd. (2023), yapmış oldukları bir çalışmada, Türkiye'deki hafif ticari araç satışlarının makine öğrenmesi yöntemleriyle tahmin edilmesi amaçlanmıştır. Araştırmada, yapay sinir ağları, çoklu doğrusal regresyon ve karar ağaçları regresyonu olmak üzere üç farklı makine öğrenmesi tekniği kullanılmıştır. Veri seti, Ocak 2006 - Haziran 2022 dönemini kapsayan aylık verilerden oluşmaktadır. Çalışmanın sonuçları, yapay sinir ağlarının hafif ticari araç satış tahmininde en başarılı yöntem olduğunu göstermiştir. Bu bulgular, hafif ticari araç satış tahminlerinde makine öğrenmesi yöntemlerinin etkili bir şekilde kullanılabilirliğini ortaya koymaktadır.

Lasya vd. (2023), belirli parametrelere dayanarak kullanılmış arabanın fiyatını tahmin etmek amacıyla birden fazla makine öğrenmesi modeli kullanmışlardır. Bir dizi strateji bir araya getirilerek, kullanılmış bir arabanın maliyetini tahmin eden bir tahmin modeli oluşturulmuştur. Çalışmada doğrusal regresyon ve regresyon ağaçları gibi Sinir Ağı Modelleri uygulanmıştır. Önceki müşteri bilgileri ve bir dizi göstergelere dayanarak kullanılmış bir arabanın maliyetini tahmin edebilecek sentetik veriler oluşturulmuştur. Dolayısıyla, müşterilerin geçmiş verilerini kullanarak yeni sonuçlar tahmin edebilmiş ve tahmin edilen sonuçlar karşılaştırılmıştır.

2. Araştırmanın Metodolojisi

Bu çalışmada, yapay sinir ağları ile binek otomobil ihracat tahmini yapılırken python yazılımı kullanılmıştır. Yapay sinir ağları, doğru veri setleri ve uygun model yapılandırması ile ihracat değer tahminlerinde başarılı sonuçlar verebilmektedir. Tasarlanan modelin performansı için, model parametreleri ve ağ yapısının dikkatli biçimde ayarlanması önem arz etmektedir. Tahmin modelleri olarak MLP ve RBF modelleri kullanılmıştır. Tasarlanan modellerin bağımlı değişkeni, Türkiye'nin aylık binek otomobil ihracat değeridir. Bağımsız değişkenler ise Türkiye aylık binek otomobil ithalatı, aylık Amerikan Dolar kuru, aylık Türkiye ithalatı, aylık yeni otomobil satış adedi, motorlu kara taşıtları üretim endeksi ve yurt dışı üretici fiyat endeks (YD-ÜFE) değeridir. Türkiye İstatistik Kurumu'ndan (TÜİK) alınan aylık veriler (Ocak 2010 - Kasım 2023, 167 ay~13 yıl) kullanılarak, Aralık 2023 ile Haziran 2024 arasında gerçekleşecek 7 aylık binek otomobil ihracat değerleri tahmin edilmiştir.

2.1. Model Kurulumu ve Değişkenlerin Seçimi

Otomobil sektöründeki ihracatı etkileyen faktörler çeşitlilik gösterebilmektedir. Model kurulumu için literatürdeki bazı yayınlar ve akademik çalışmalar incelendiğinde, otomobil ihracatını etkileyebilecek faktörler tarafımızca tespit edilmiş aşağıdaki gibi sıralanmıştır:

Ekonomik Durum ve Büyüme: Bir ülkenin ekonomik performansı, otomobil ihracatını etkileyen en önemli faktörlerden biridir. Ekonomik büyüme, tüketici güveni ve gelir düzeyi otomobil talebini etkileyebilir (Ray, 2012).

Döviz Kuru: Yabancı para birimleri karşısındaki yerel para biriminin değeri, otomobil ihracatını etkileyen faktörlerden biridir. Örneğin, yerel para biriminin zayıflığı ihracatı artırabilir (Gagnon ve Knetter, 1995).

Tüketici Tercihleri: Hedef pazarların tüketici tercihleri ve ihtiyaçları, otomobil modellerinin tasarımını ve özelliklerini etkilemektedir (Gomez-Ibanez ve Harrison, 1982).

Talep ve Pazar Trendleri: İhracatçılar, hedef pazarlardaki talep ve tüketici tercihleri konusunda bilgi sahibi olmalıdır. Pazar trendleri, ürün tasarımından üretim süreçlerine kadar birçok yönü etkileyebilir (İnançlı ve Konak, 2011).

İhracatın İthalata Bağımlılığı: Otomotiv endüstrisinin yoğun bir şekilde teknolojiye odaklı üretimi, bu sektörde sermaye malları ve ithal edilen ara malzemelere olan talebi artırmıştır (Gerni vd., 2007). Aynı zamanda, Türkiye'deki bu sektörün ileriye dönük güçlü bağlantıları ve yerli ürünler ile ithal mallar arasındaki yüksek derecedeki değiştirme esnekliği, sektöre dair neredeyse her türlü parametre değişikliğinin cari hesap dengesini doğrudan etkileyebileceği anlamına gelmektedir (Aktaş, 2007).

Bu faktörler, otomobil ihracat tahminlerinde önemli bir rol oynamaktadır. Analizde, TÜİK verileri kullanılmıştır. Yukarıdaki bilgiler doğrultusunda; otomobil ihracat tahmini için kullanılacak olan bağımsız değişkenleri tarafımızca oluşturulmuştur. Bağımsız değişkenler, Türkiye aylık binek otomobil ithalatı, aylık Amerikan Dolar kuru, aylık Türkiye ithalatı, aylık yeni otomobil satış adedi, motorlu kara taşıtları üretim endeksi ve yurt dışı üretici fiyat endeks (YD-ÜFE) değeri olarak tarafımızca belirlenmiştir. Bu bağımsız değişkenlerin seçiminde birçok önemli neden bulunmaktadır. Döviz kurları, bir ülkenin para biriminin başka bir para birimi karşısındaki değerini temsil etmektedir ve uluslararası ticaret üzerinde doğrudan bir etkiye sahiptir. Bir ülkenin para birimi değer kaybettiğinde, o ülkenin ürünleri yabancı alıcılar için daha ucuz hale gelir, bu da ihracatın artmasına yol açabilir. Tersine, para birimi değer kazandığında, ürünler daha pahalı hale gelir ve bu da ihracatın azalmasına neden olabilir. Bu ilişki, döviz kurlarının otomobil ihracatı tahminlerinde önemli bir değişken olmasının nedenidir (Williamson, 2009). Buna ek olarak, otomobil sektörünün ekonomi üzerindeki etkisi ve tüketici talebi, üretim ve ithalat gibi faktörlerin sektör performansını nasıl etkileyebileceği üzerine yapılan çalışmalar, seçilen değişkenlerin önemini vurgulamaktadır. Örneğin, Deloitte Insights'ın otomobil sektörü üzerine yaptığı bir analiz,

pandemi sürecinde otomobil sektörünün nasıl etkilendiğini ve tüketici talebinin, üretim ve ithalatın bu süreçte nasıl değiştiğini detaylandırmaktadır (Samaddar ve Bachman, 2022). Bu tür analizler, aylık otomobil ithalatı ve ihracatının, yeni otomobil satışlarının ve üretim endekslerinin, bir ülkenin ekonomik performansını ve otomobil sektörünün sağlığını nasıl etkileyebileceğine dair içgörüler sunmaktadır.

Bununla birlikte, bu değişkenlerin seçimi, otomobil ihracatı tahminlerini doğrudan etkileyebilecek bir dizi faktörü kapsamaktadır. Örneğin, aylık binek otomobil ithalatı ve ihracatı, küresel ve yerel ekonomik koşulların yanı sıra tüketici talebinin ve rekabetçi dinamiklerin bir yansımasıdır. Aylık yeni otomobil satışları, ekonomik büyüme, tüketici güveni ve satın alma gücü gibi makroekonomik göstergelerle yakından ilişkilidir. Motorlu kara taşıtları üretim endeksi, sektörün üretim kapasitesi ve teknolojik yetkinliği hakkında bilgi vermektedir (Athukorala ve Veeramani, 2019). Yurtdışı üretici fiyat endeksi (YD-ÜFE), bir ülkenin ihracat fiyatlarının zaman içindeki değişimlerini ölçer ve bu da mal ve hizmetlerin uluslararası rekabetçiliğini etkileyebilir. Bir ülkenin YD-ÜFE'si artarsa, bu genellikle o ülkenin mallarının ve hizmetlerinin yurt dışında daha pahalı hale geldiğini gösterir, bu da ihracat talebinin azalmasına neden olabilir. Ters durumda, YD-ÜFE'nin düşmesi, ürünlerin yurt dışında daha ucuz hale gelmesi ve ihracat talebinin artması anlamına gelir. Bu bağlamda, YD-ÜFE'nin otomobil ihracatı tahminlerinde kullanılması, uluslararası pazarlardaki fiyat rekabetçiliği değişikliklerini yansıtır (de Soyres vd., 2020).

Bu değişkenlerin her biri, otomobil ihracatı tahminlerinde önemli bir rol oynamaktadır çünkü birbiriyle ve genel ekonomik durumla karmaşık ilişkiler içindedir. Bu nedenle, tahmin modellerinde bu değişkenler kullanılarak, otomobil ihracatının gelecekteki trendlerinin daha doğru bir şekilde çizilebileceği ve hem yerel hem de uluslararası pazar dinamiklerinin kapsamlı bir analizinin sağlanabileceği düşünülmektedir. Bu yaklaşım, ekonomik tahminler ve uluslararası ticaret üzerine yapılan genel çalışmalarla uyumludur ve sektörün genel performansını anlamada kritik bir öneme sahiptir.

Bununla birlikte, Python yazılımında, “describe()” fonksiyonu kullanılarak seçilen değişkenlerin minimum, maksimum, ortalama, standart sapma, ve yüzdelik değerleri (örneğin, %25, %50, %75) hesaplanmıştır. Ayrıca “mode()” fonksiyonu ile de her bir sütunun modu (en sık görülen değer) hesaplanmıştır. Bu istatistiksel bilgiler Tablo 2’de gösterilmiştir.

Tablo 2. Değişkenlere Ait İstatistiksel Bilgiler

Değişkenler	Otomobil Satış Adedi	MKT Üretim Endeksi	Amerikan Dolar Kuru	Türkiye İthalatı	Yurt Dışı ÜFE	Otomobil İhracat	Otomobil İthalat
Veri Miktarı	167	167	167	167	167	167	167
Ortalama Değer	51.971,01	103,82	5,94	20.037.934.326,41	327,45	733.708.113,13	684.340.362,31
Standart Sapma	17.139,46	27,92	6,19	4.239.147.609,36	339,56	237.112.692,28	317.378.875,18
Minimum Değer	18.249	38	1,43	11.691.248.394	99,41	132.736.062	67.981.047
%25'lik Değer	40.165	82,75	1,91	17.173.453.502,5	121,63	562.121.092,5	490.175.547
Medyan (%50)	49.861	102,8	3,47	19.318.698.045	170,41	669.935.193	650.331.963
%75'lik Değer	62.874	124,75	6,845	21.462.821.857	358,91	941.542.040	840.839.971
Maksimum Değer	95.960	166,2	28,64	31.837.035.091	1590,07	1.275.289.384	1.965.232.835
Mod	18.249	95,5	1,79	11.691.248.394	99,72	132.736.062	67.981.047

Açıklama: Minimum Değerler: Her bir değişken için gözlemlenen minimum değerler.

Maksimum Değerler: Her bir değişken için gözlemlenen maksimum değerler.

Ortalama Değerler: Her bir değişkenin ortalama (mean) değerleri.

Standart Sapma: Her bir değişkenin değerlerinin dağılımının ne kadar yaygın olduğunu gösteren standart sapma değerleri.

Medyan (%50): Her bir değişken için medyan değeri. Veri setindeki değerler küçükten büyüğe sıralandığında, ortadaki değer medyandır.

Yüzdelik Değerler (%25 ve %75): Her bir değişken için alt ve üst çeyrek değerleri. Veri dağılımının %25'lik ve %75'lik dilimlerdeki değerlerdir.

Mod: Her bir değişken için en sık gözlemlenen değerdir.

2.2. Dickey-Fuller Testi

Bu çalışmada, verisetindeki değişkenlerin durağan olup olmadığını kontrol etmek için Dickey-Fuller testi uygulanmıştır. Dickey-Fuller testi, bir zaman serisinin durağan olup olmadığını belirlemek için kullanılan bir istatistiksel testtir (Paparoditis ve Politis, 2018). Bu çalışmada kullanılan veriseti birden fazla değişkenli bir veri seti olduğundan, her bir değişken için ayrı ayrı Dickey-Fuller testi uygulamak gerekmektedir. Bu test, bir zaman serisinin birim kök içerip içermediğini kontrol etmektedir. Dickey-Fuller testinin temel formu şu şekildedir:

$$\Delta y_t = a + \beta_t + \gamma y_{t-1} + \delta \Delta y_{t-1} + \epsilon_t \quad (1)$$

Burada, Δ fark operatörüdür. y_t , zaman serisinin t zamanındaki değeridir. a , sabittir (eğer modelde sabit yoksa bu terim yoktur).

β_t , zamana bağlı eğilimi temsil eder (eğer modelde zamana bağlı eğilim yoksa bu terim yoktur). γ , birim kök testinin ana parametresidir. $\delta\Delta y_{t-1}$, geçmiş dönemlerin farklarının katsayısıdır. ϵ_t , hata terimidir. Testin ana odak noktası γ katsayısıdır. Eğer $\gamma = 0$ ise bu zaman serisinin bir birim köke sahip olduğu ve durağan olmadığı anlamına gelir. Eğer $\gamma < 0$ ise bu zaman serisinin durağan olduğunu gösterir. Test, genellikle $H_0: \gamma = 0$ (null hipotezi, yani zaman serisi durağan değildir) ve $H_1: \gamma < 0$ (alternatif hipotez, yani zaman serisi durağandır) arasında ayırım yapar (Phillips ve Perron, 1998).

Dolayısıyla, birim kök varsa, zaman serisi durağan değildir. Bu bilgiler doğrultusunda, aşağıdaki hipotezler oluşturulmuştur;

H_0 : Seri durağan değildir (birim kök içermektedir).

H_1 : Seri durağandır (birim kök yoktur).


Gözlem serilerinin p-değerleri %1, %5 veya %10 düzeyinde anlamlı ise H_0 reddedilmektedir. Her bir değişken için Dickey-Fuller test sonuçları Tablo 3'te gösterilmiştir.

Tablo 3. Değişkenlere Ait Dickey-Fuller Testi Sonuçları

Değişkenler	p-değerleri	Test İstatistiği	%1'lik Kritik Değer	%5'lik Kritik Değer	%10'luk Kritik Değer
Binek Otomobil İhracat Değeri	0.00371	-3.21821	-2.77354	-2.88049	-2.57687
Binek Otomobil İthalat Değeri	0.00435	-4.15348	-3.47327	-2.88019	-2.57234
Amerikan Dolar Kuru	0.00278	-5.15348	-3.47412	-2.88074	-2.57701
Aylık Türkiye İthalatı	0.00394	-4.60110	-3.47382	-2.88062	-2.57694
Aylık Yeni Otomobil Satış Adedi	0.00497	-3.60110	-3.47363	-2.88048	-2.57671
Motorlu Kara Taşıtları Üretim Endeksi (2015=100)	0.00417	-5.35454	-3.47512	-2.88058	-2.57344
Yurt Dışı ÜFE	0.00490	-5.95748	-3.47468	-2.88749	-2.57774

Tablo 3'teki Dickey-Fuller test sonuçlarına göre, analiz edilen tüm değişkenler için Dickey-Fuller test istatistikleri ve p-değerleri %1, %5 ve %10 anlamlılık düzeylerindeki kritik değerlerin altındadır. Bu sonuçlar, tüm değişkenlerin zaman içinde sabit bir ortalamaya ve varyansa sahip olduğunu yani durağan olduğunu göstermektedir. Bu, ekonometrik modellerin kurulması ve zaman serisi analizlerinin yapılması için önemlidir, çünkü durağan veriler bu tür analizlerde daha güvenilir sonuçlar sağlamaktadır. Durağanlık, bu değişkenlerin zaman içinde sabit bir ortalamaya, sabit bir varyansa ve sabit bir otokorelasyona sahip olduğunu gösterir, bu da onları öngörülebilir ve analiz için uygun hale getirmektedir.

Ayrıca, çalışmanın veri setindeki her değişken ile diğer faktörler arasındaki ilişkiyi gösteren korelasyon matrisi Şekil 1'de gösterilmektedir. İki değişken arasında pozitif bir korelasyon olduğunda pozitif bir bağlantı, negatif bir korelasyon olduğunda ise negatif bir bağlantı vardır. Korelasyon değeri 1 veya -1 olduğunda değişkenler arasında tam bir bağlantı vardır. Bu korelasyon matrisini analizi python yazılımında pandas ve matplotlib kütüphanelerini kullanarak yapılmıştır.



Korelasyon matrisindeki 1.00 değerleri, değişkenlerin kendileriyle mükemmel pozitif ilişkisini gösterir; bu, matrisin simetrik yapısından kaynaklanan beklenen bir sonuçtur. “Yurtdışı ÜFE” ile “Amerikan Dolar Kuru” arasındaki ilişki dışında, diğer 1.00 değerleri her değişkenin kendisiyle olan ilişkisini ifade etmekte ve özel bir ilişkiyi göstermemektedir. Diğer yüksek değerler, değişkenler arasındaki güçlü ilişkilere işaret etmektedir. Örneğin, “Otomobil ihracatı” ve “Motorlu Kara Taşıtları Üretim Endeksi” arasında 0.81 gibi yüksek bir pozitif korelasyon vardır. Bu durumda, 0.81 gibi yüksek bir pozitif korelasyon değeri, otomobil ihracat miktarındaki artışların motorlu kara taşıtları tüketim endeksinde de benzer artışlara yol açtığını veya bu endekste artışların otomobil ihracatını pozitif yönde etkilediğini gösterir. Başka bir deyişle, bir ülkede otomobil ihracatı ne kadar yüksekse, o ülkenin motorlu kara taşıtları tüketim endeksi de o kadar yüksek olma eğilimindedir. Bu ilişki, otomobil ihracatının bir ülkenin ekonomik performansı ve tüketici güveni gibi faktörlerle ilişkili olabileceğini düşündürmektedir. Diğer taraftan, “Otomobil İhracatı” ve “Otomobil Satış Adedi” arasında 0.55 gibi orta seviye bir korelasyon göze çarpmaktadır. Bu, ithalat miktarlarının arttıkça ihracatın da eğilim olarak arttığına işaret etmektedir, fakat bu ilişki mükemmel değildir ve diğer faktörlerin de ihracat üzerinde etkili olabileceğini göstermektedir. Ayrıca, “Amerikan Dolar Kuru” ve “TR İhracatı” arasında 0.73 gibi oldukça yüksek bir korelasyon bulunmaktadır. Bu, dolar kurundaki değişikliklerin TR ihracat miktarlarını önemli ölçüde etkileyebileceğini düşündürülebilir. Ancak, korelasyon nedensellik anlamına gelmez ve bu durumda dolar kurunun ihracat üzerindeki doğrudan etkisinin olup olmadığı, ek analizlerle daha ayrıntılı incelenmelidir. Bu matrisin bir diğer ilginç noktası ise “Yurt Dışı ÜFE” ve “Otomobil İthalatı” arasındaki 0.48’lik korelasyondur. Bu orta düzeyde pozitif korelasyon, yurt dışındaki üretici fiyat endeksinin artışı ile otomobil ithalatı artışı arasında bir ilişki olabileceğini gösterse de, bu ilişki yine de nispeten zayıftır. Son olarak, en düşük korelasyon değerlerinden biri olan 0.10, “Otomobil İhracatı” ve “Otomobil Satış Adedi” arasında görülmektedir. Bu, beklenmedik bir sonuç olarak kabul edilebilir çünkü genellikle üretim miktarı ile ihracat miktarı arasında daha yüksek bir ilişki beklenmektedir. Ancak, bu düşük korelasyon, bu iki değişken arasındaki ilişkinin diğer faktörlerden etkilenebileceğini ya da veri setindeki belirli bir zaman dilimi için özgül bir durumu yansıttığını gösteriyor olabilir. Genel olarak, bir korelasyon matrisinin yorumlanması sırasında sadece sayısal değerlere değil, aynı zamanda bu değerlerin temsil ettiği ekonomik ve sosyal bağlamlara da dikkat etmek önemlidir. Bu matristeki korelasyonlar, değişkenlerin birbiriyle olan ilişkilerini anlamada bir başlangıç noktası sağlasa da, daha derin analizler ve kontekst anlayışı gereklidir. Örneğin, ekonometrik modeller, zaman serisi analizleri ve nedensellik testleri gibi daha gelişmiş istatistiksel yöntemler, bu korelasyonların altında yatan nedenleri ve mekanizmaları anlamak için kullanılabilir.

Çalışmada, Python yazılımı kullanılarak aylık binek otomobil ihracat değerlerinin tahmini hedeflenmiştir. Bu nedenle gerekli Python kütüphanelerinin içe aktarılması çalışmanın ilk adımdır. Bu kütüphaneler modellerin oluşturulmasını, verilerin işlenmesini ve sonuçların görselleştirilmesini sağlamaktadır. NumPy, Pandas, Matplotlib, Scikit-learn ve TensorFlow kullanılan kütüphanelerdir. Pandas, veri kümesini bir Excel dosyasından yüklemek için kullanılmıştır. Ek olarak, NaN değerleri “data.dropna()” kullanılarak veri setinden çıkarılmıştır. Daha sonra, veri çerçevesi bağımsız değişkenlere (X) ve bağımlı değişkenlere (Y) bölünmüştür. Verileri normalleştirmek için min-max ölçeklendirme yöntemi kullanılmıştır. Bu, her bir özelliği 0 ile 1 arasında bir değere dönüştürerek modelin performansını artırmaktadır.

$$x_{scaled} = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (2)$$

Veri standardizasyonundan sonra, veri seti, modellerin eğitimi ve testi için uygun bir biçimde %70’i eğitim ve %30’u test olmak üzere alt kümelerine ayrılmıştır. Veri setinin %70 eğitim ve %30 test olarak ayrılması kararını literatüre dayandırmak gerekirse, Kohavi (1995) ve Breiman vd. (1984) gibi çalışmalar, veri setlerinin eğitim ve test olarak nasıl bölüneceği üzerine kapsamlı rehberlik sağlamaktadır. Bu çalışmalar, modelin genelleme kabiliyetini doğru bir şekilde test etmek için yeterli miktarda verinin ayrılmasının önemini vurgulamaktadır. %70-%30 ayrımı, veri setinin boyutuna ve modelin karmaşıklığına bağlı olarak genellikle iyi bir denge sağladığı için yaygın bir uygulamadır. Bu oran, modelin yeterli miktarda eğitim verisi ile eğitilmesini ve modelin performansının etkili bir şekilde değerlendirilmesini sağlamaktadır. Bununla birlikte, tahminlerin gerçek değerlere ne kadar yakın olduğu ve hangi bağımsız değişkenlerin tahminler üzerinde daha fazla etkisi olduğu da değerlendirilmiştir. Doğru ve güvenilir sonuçlar için sinir ağı modellerinin dikkatli bir şekilde oluşturulması, veri kalitesi ve özelliklerin seçimi önemlidir. MLP ve RBF modellerinin performansları karşılaştırılmış, analiz sonucu elde edilen tahminlerin farkları ve sonuçları yorumlanmıştır. R², MAPE, MSE, RMSE gibi tahmini istatistiksel ölçütler kullanılarak modellerin performansı değerlendirilmiştir. R² (R-kare), modelin verilerin varyansını ne kadar iyi açıkladığını gösterir ve 0 ile 1 arasında değer almaktadır; 1, modelin veriyi mükemmel açıkladığını gösterir. MAPE (Ortalama Mutlak Yüzde Hata), tahminlerin gözlemlerden ne kadar sapma gösterdiğinin yüzdesel bir ölçüsüdür. MSE (Ortalama Kare Hata) ve RMSE (Kök Ortalama Kare Hata), hataların karelerinin ortalamasıdır; düşük değerler daha iyi tahminler anlamına gelmektedir. Bu metriklerin kullanımı ve önemi, tahmin modelinin performansını değerlendirme konusunda kritik öneme sahiptir ve geniş çapta kabul görmüş standartlardır. Hyndman ve Koehler’in (2006) çalışması, tahmin hatalarını değerlendirmede kullanılan çeşitli metriklerin önemini ve nasıl kullanılacağını detaylandırmaktadır. Özellikle, model performansını değerlendirme konusunda önemli bir kaynaktır. Bu istatistiksel veriler denklem 3, 4, 5 ve 6 kullanılarak hesaplanabilmektedir.

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (3)$$

$$MAPE = \frac{\sum_{t=1}^n \frac{u_t}{\bar{y}_t} * 100}{n} \quad (4)$$

$$MSE = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (5)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{N}} \quad (6)$$

Bununla birlikte, otomobil ihracat değerlerinin gelecek tahmini için, Arima modelleri kullanılarak bağımsız değişkenlere ait verilerin zaman serileri analizi yapılmış ve Aralık 2023 ile Haziran 2024 arasındaki dönem için bağımsız değişkenlerin gelecek tahminleri elde edilmiştir. Bağımsız değişkenlerin gelecek tahmini için python yazılımı kullanılmıştır. Öte yandan, MLP ve RBF analizlerinde yapısı gereği eksik veriler ile çalışmadığından ötürü, tahminleme işleminde, tahmin dönemine ait bağımsız değişken verilerinin eksik olmadığı bir yaklaşım benimsenmiştir.

2.3. Multi-Layer Perceptron (MLP)

MLP, "Çok Katmanlı Algılayıcı" (Multi-Layer Perceptron) anlamına gelmektedir ve yapay sinir ağları ailesine aittir. Bir MLP, birden fazla katmandan (genellikle bir giriş katmanı, bir veya daha fazla gizli katman ve bir çıkış katmanı) oluşan bir beslemeli ileri yayılım (feedforward) sinir ağıdır. Her katman, bir önceki katmandan gelen sinyalleri alır, bir aktivasyon fonksiyonu uygular ve sonucu bir sonraki katmana iletir. MLP'ler, karmaşık problemleri modellemek ve çok boyutlu verilerden tahminler yapmak için kullanılmaktadır (Wilamowski, 2009).

Bir MLP'nin temel bileşeni olan her bir nöron (veya birim), girdilerin ağırlıklandırılmış toplamını alır, buna bir bias (sabit) ekler ve sonucu bir aktivasyon fonksiyonundan geçirerek çıktı üretir. Matematiksel olarak bir nöronun çıktısı şöyle ifade edilebilir:

$$a_j = f(\sum_{i=1}^n W_{ij}x_i + b_j) \quad (7)$$

Burada, a_j j . nöronun aktivasyonunu veya çıktısını, f aktivasyon fonksiyonunu (örneğin, sigmoid, tanh veya ReLU), W_{ij} , i . Girdi ile j . nöron arasındaki ağırlığı, x_i , i . girdi değerini, b_j , j . nöronun bias değerini temsil etmektedir.

MLP'deki her katman, bir önceki katmandaki tüm nöronlardan sinyal alır ve bu sinyalleri ağırlıklarla çarparak toplar. Her bir nöronun çıktısı, sonraki katmana girdi olarak aktarılır. Bu süreç, çıkış katmanına kadar devam eder. Çıkış katmanında, final aktivasyon fonksiyonu genellikle problemin türüne (regresyon, sınıflandırma, vb.) göre seçilir. Örneğin, bir regresyon problemi için çıkış katmanında genellikle lineer bir aktivasyon fonksiyonu kullanılırken, sınıflandırma problemlerinde softmax aktivasyon fonksiyonu tercih edilebilir. MLP'lerde öğrenme süreci, genellikle geri yayılım (backpropagation) algoritması ve bir optimizasyon algoritması (örneğin, stokastik gradyan inişi) kullanılarak gerçekleştirilir. Bu süreçte, ağırlık çıkışlarındaki hatalar hesaplanır ve bu hatalar, ağırlık değerlerini güncelleyerek minimize edilmektedir (Boughrara vd., 2016). Ağırlıkların güncellenmesi matematiksel olarak şu şekilde ifade edilebilmektedir:

$$w_{ij}^{(yeni)} = w_{ij}^{(eski)} - \eta \frac{\partial E}{\partial w_{ij}} \quad (8)$$

Burada, $w_{ij}^{(yeni)}$ güncellenmiş ağırlık değeri, $w_{ij}^{(eski)}$ mevcut ağırlık değeri, η öğrenme oranı (learning rate), E hata fonksiyonu (örneğin, MSE), $\frac{\partial E}{\partial w_{ij}}$ hata fonksiyonunun ağırlığa göre kısmi türevidir.

Bu optimizasyon süreci, ağırlık tahminleri gerçek değerlere yaklaştığı ve hata oranı kabul edilebilir bir seviyeye düştüğü noktaya kadar iteratif olarak devam etmektedir. Ağırlık performansı, genellikle bir doğrulama (validation) veri seti üzerinde değerlendirilir ve aşırı öğrenme (overfitting) gibi sorunlara karşı koruma sağlamak için çeşitli düzenleme (regularization) teknikleri uygulanabilir.

2.4. Radial Basis Function (RBF)

Radial Basis Function (RBF) Sinir Ağı, girdi verileri ve çıkışlar arasındaki ilişkiyi modellemek için radyal baz fonksiyonları kullanan bir tür yapay sinir ağıdır. RBF ağları, özellikle fonksiyon yaklaşımı, zaman serisi tahmini, sınıflandırma ve sistem tanımlama gibi alanlarda kullanılır. Bu ağlar genellikle üç katmandan oluşur: bir giriş katmanı, bir gizli katman ve bir çıkış katmanı (Yingwei vd., 1998).

RBF ağlarının temel bileşeni, gizli katmandaki her bir nöronun bir radyal baz fonksiyonuna sahip olmasıdır. Bu fonksiyon, genellikle bir Gauss fonksiyonu şeklinde olup, girdi vektörü ile nöronun merkezi arasındaki uzaklığa bağlı olarak bir değer döndürür. Yani, her nöron girişler ile kendi merkezi arasındaki uzaklığa göre aktivasyon sağlamaktadır. RBF sinir ağının tipik bir matematiksel formülasyonu şöyledir:

$$\phi(x) = \exp\left(-\frac{\|x-c\|^2}{2\sigma^2}\right) \quad (9)$$

Burada, x girdi vektörü, c merkez vektörü (her bir RBF nöronu için bir merkez vektörü bulunur), σ ölçek parametresi (bazen her bir RBF nöronu için farklı olabilir), $\|x - c\|$ girdi vektörü ile merkez vektörü arasındaki öklid mesafesi, $\phi(x)$ radial basis fonksiyonunun çıktısıdır ve aktivasyon fonksiyonu olarak işlev görmektedir.

RBF sinir ağındaki her bir gizli katman nöronu için, girdi ile merkez arasındaki bu mesafeyi hesaplayarak bir aktivasyon değeri üretilir. Sonra, bu aktivasyonlar ağırlıklandırılarak çıkış katmanına iletilir ve bir çıktı üretilir. Çıkış genellikle, gizli katman nöronlarının çıktılarının ağırlıklı toplamı olarak hesaplanmaktadır:

$$y(x) = \sum_{j=1}^N w_j \cdot \phi(\|x - c_j\|) \quad (10)$$

Burada, $y(x)$ RBF ağına girdi x için hesapladığı tahmin edilen değer, N gizli katmandaki nöron sayısı, w_j çıkış katmanına bağlanan j . nöronun ağırlığı, $\phi(\|x - c_j\|)$ j . nöronun aktivasyon fonksiyonudur.

Bu ağırlıklar genellikle bir çeşit öğrenme algoritması kullanılarak optimize edilmektedir. En yaygın yöntemlerden biri, merkezleri ve ölçek parametrelerini seçmek için bir önbelleme (clustering) algoritması kullanmaktır, daha sonra çıkış ağırlıklarını en küçük kareler yöntemi ile ayarlamaktır. Bu yaklaşım, RBF ağına veri üzerinde iyi bir genelleme yapmasını ve veri setindeki karmaşık ilişkileri öğrenmesini sağlar. RBF ağlarının avantajı, özellikle küçük ve orta ölçekli problemlerde, hızlı eğitilebilir olmaları ve genellikle tek bir gizli katman ile iyi sonuçlar verebilmeleridir. Bununla birlikte, büyük veri setleri ve çok sayıda giriş özelliği içeren durumlarda eğitim süresi ve ağı karmaşıklığı artabilir (Sing vd., 2003).

3. Uygulama ve Bulgular

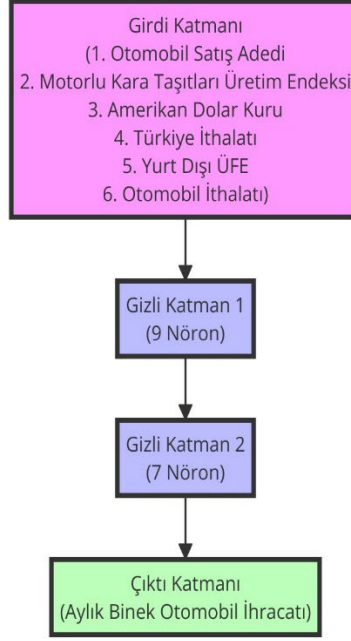
Çalışmada, YSA'nın iki farklı modeli (MLP ve RBF) kullanılarak, Türkiye'nin aylık binek otomobil ihracat değerleri tahmin edilmiştir. Modellerin bağımlı değişkeni, Türkiye'nin aylık binek otomobil ihracatıdır. Modellerde 6 adet bağımsız değişken bulunmaktadır.

Çalışmada, MLP ve RBF modellerindeki hiperparametrelerin otomatik olarak seçimi için Bayes Optimizasyon tekniği kullanılmıştır. Bu yöntem, model performansını maksimize edecek hiperparametre kombinasyonlarını belirlemek üzere olasılıksal bir model kullanmaktadır. Bayes Optimizasyonu, önceki denemelerden elde edilen bilgileri kullanarak hiperparametre arama alanında en umut verici bölgelere odaklanır, böylece daha az deneme ile daha iyi sonuçlar elde etmeyi amaçlamaktadır (Wu vd., 2019). Bu süreçte, Python yazılımı ve ilgili kütüphaneler aracılığıyla otomatik bir hiperparametre ayarlama işlemi gerçekleştirilmiştir.

Python'da Bayes Optimizasyonu için sıklıkla kullanılan kütüphaneler arasında Scikit-Optimize (skopt) ve Hyperopt bulunmaktadır. Scikit-Optimize, Gaussian Process tabanlı optimizasyon işlemleri için kullanıcı dostu bir arayüz sunar. Hyperopt, Bayes Optimizasyonu yanı sıra rastgele arama ve TPE (Tree of Parzen Estimators) gibi farklı algoritmaları da destekler ve geniş bir kullanım alanına sahiptir. Bu kütüphaneler, hiperparametre optimizasyonu sürecini kolaylaştırmak için geliştirilmiş ve Python ekosisteminde yaygın olarak kullanılmaktadır. Bayes Optimizasyonu, hedef fonksiyonun $f(x)$ olduğu durumlarda kullanılmaktadır. Bu yöntemde, hedef fonksiyon üzerine bir Gaussian Process (GP) prior varsayılır ve her adımda GP'nin güncellenmesiyle posteriori elde edilmektedir. Hiperparametrelerin her bir kombinasyonu için elde edilen performans değerlendirme sonuçlarına göre, "Acquisition Function" kullanılarak sonraki en iyi hiperparametre değerleri tahmin edilmektedir. Bu süreç, belirlenen iterasyon sayısı kadar veya durdurma kriteri karşılanana kadar devam etmektedir. Bu optimizasyon yöntemi, hesaplama maliyeti yüksek fonksiyonlar için uygundur çünkü her adımda elde edilen bilgiyi maksimize etmeye çalışır (Feurer ve Hutter, 2019). Sonuç olarak, hem MLP hem de RBF modelinde, gizli katman sayısı, nöron sayısı ve aktivasyon fonksiyonu gibi hiperparametreler, Bayes Optimizasyon tekniği kullanılarak otomatik olarak seçilmiştir.

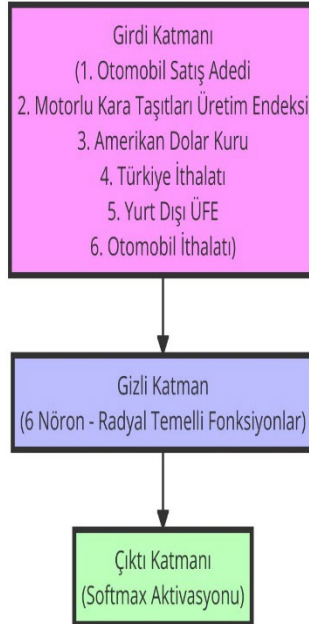
Çalışmada tasarlanan MLP modelinin; 6 adet girdi katmanı (bağımsız değişkenler), iki adet gizli katmanı ve bir adet çıktı katmanı vardır (Bias birimleri hariç). Şekil 2'de tasarlanan MLP modelinin katmanları gösterilmiştir. MLP modeli, iki adet gizli katmana sahiptir. Birinci gizli katmanda 9 adet birim (nöron) bulunurken, ikinci gizli katmanda 7 adet nöron bulunmaktadır. Gizli katmanlar, verinin karmaşıklığını yakalamak ve modelin öğrenme yeteneğini artırmak için kullanılan katmanlardır. Hem gizli katmanlarda hem de çıktı katmanında hiperbolik tanjant aktivasyon fonksiyonu kullanılmıştır. Hiperbolik tanjant, girişleri -1 ile 1 arasında sınırlayan ve non-linear davranışı olan bir fonksiyondur. Çıktı katmanı, bağımlı değişkeni temsil etmektedir. Daha önce de bahsedildiği gibi, hiperparametrelerin otomatik olarak seçimi için Bayes Optimizasyon tekniği kullanılmıştır. Çıktı katmanında bir adet birim bulunmaktadır. Bu birim, Türkiye'nin aylık binek otomobil ihracatını tahmin etmektedir.

Şekil 2. MLP Modelinin Katmanları



Bununla birlikte, Şekil 3'te RBF modelinin mimarisi ve katmanları gösterilmiştir. Giriş katmanı, bağımsız değişkenleri temsil etmektedir. MLP modelinde kullanılan aynı 6 adet değişken, RBF modelinde de kullanılmıştır. RBF modelinde bir adet gizli katman bulunmaktadır. Bu katman, giriş verilerini daha yüksek boyutta temsil eden radyal temelli fonksiyonlardan oluşmaktadır. Gizli katman altı adet birim (nöron) içermektedir. Aktivasyon fonksiyonu olarak softmax kullanılmıştır. Softmax fonksiyonu, çıktıları olasılık dağılımı şeklinde normalize eden bir fonksiyondur. Daha önce de bahsedildiği gibi, hiperparametrelerin otomatik olarak seçimi için Bayes Optimizasyon tekniği kullanılmıştır.

Şekil 3. RBF Modelinin Katmanları



Tablo 4, MLP modelinin katman yapılarını, mimarisini ve özelliklerini açıklamaktadır. Aktivasyon fonksiyonu olarak her iki gizli katmanda da hiperbolik tanjant (Hyperbolic Tangent) kullanılmıştır. Hiperbolik tanjant, gizli katmanlardaki nöronların çıkışlarını sınırlayan ve genellikle sigmoidal bir şekle sahiptir. Hata fonksiyonu, modelin performansını ölçmek için kullanılmaktadır. Modelde hata karelerinin toplamı (Sum of Squares) hata fonksiyonu olarak seçilmiştir. Bu fonksiyon, modelin tahminlerinin gerçek değerlerle olan farkını hesaplayarak modelin performansını ölçmektedir. MLP, karmaşık ilişkileri modelleyebilen ve tahmin yeteneği yüksek bir model türüdür.

Tablo 4.MLP Modelinin Katman Yapıları ve Özellikleri

Giriş Katmanı	Bağımsız Değişkenler	Yeni Otomobil Satış Adedi
		Motorlu Kara Taşıtları Üretim Endeksi
		Amerikan Dolar Kuru
		Türkiye İthalat Değeri
		Yurt Dışı ÜFE Değeri
		Türkiye Otomobil İthalat Değeri
Giriş Katmanı Değişken Sayısı (a)		6
Gizli Katman	Gizli Katman Sayısı	2
	Birinci gizli katmandaki birim sayısı(a)	9
	İkinci gizli katmandaki birim sayısı(a)	7
	Aktivasyon Fonksiyonu	Hiperbolik Tanjant
Çıktı Katmanı	Bağımlı Değişken sayısı	1
	Çıktı katmanındaki birim sayısı	1
	Aktivasyon Fonksiyonu	Hiperbolik Tanjant
	Hata Fonksiyonu	Hata Kareler Toplamı
	Bağımlı Değişken	Türkiye Aylık Otomobil İhracatı

a: Bias birimi hariç

Tablo 5, MLP (Çok Katmanlı Algılayıcı) ve RBF (Radyal Baz Fonksiyonu) modellerinde işleme tabi tutulan test ve eğitim verilerini göstermektedir. Her iki modelde de eğitim verisi olarak 117 adet örneklem (%70) kullanılmıştır. Ayrıca, test verisi olarak da 50 adet örneklem (%30) kullanılmıştır. Toplamda geçerli 167 adet veri seti (%100) bulunmaktadır. Hariç tutulan (excluded) veri olmamıştır. Tablo 5, her iki modelin de eğitim ve test verilerini aynı oranda kullandığını göstermektedir.

Tablo 5. MLP ve RBF Modelinde İşleme Tabi Tutulan Test ve Eğitim Verileri


		MLP		RBF	
		Adet	Yüzde	Adet	Yüzde
Örneklem	Eğitim Verisi	117	% 70	117	% 70
	Test Verisi	50	% 30	50	% 30
Geçerli Veriler		167	% 100	167	% 100
Toplam Veri		167		167	

Tablo 6, modellerdeki bağımsız değişkenlerin önem derecesini göstermektedir. MLP modeline etki eden en önemli bağımsız değişken, motorlu kara taşıtları üretim endeksi'dir ve normalize önem değeri %100'dür. Diğer değişkenlerin normalize önem değerleri ise %10,7 ile %39,5 arasında değişmektedir. RBF modelinde ise en önemli bağımsız değişken yine motorlu kara taşıtları üretim endeksi'dir, normalize önem değeri %100'dür. Diğer değişkenlerin normalize önem değerleri ise %20,8 ile %50,3 arasında değişmektedir. Her iki modelde de motorlu kara taşıtları üretim endeksi en önemli bağımsız değişkendir.

Tablo 6. Bağımsız Değişkenlerin Önem Analizi

Bağımsız Değişkenler	Önem	MLP		RBF	
		Önem	Normalize Önem	Önem	Normalize Önem
Yeni Otomobil Satış Adedi	0,047	0,174	% 10,7	0,174	% 50,3
Motorlu Kara Taşıtları Üretim Endeksi	0,443	0,346	% 100	0,346	% 100
Amerikan Dolar Kuru	0,175	0,167	% 39,5	0,167	% 48,1
Türkiye İthalatı	0,108	0,082	% 24,3	0,082	% 23,6
Yurt Dışı ÜFE Değeri	0,111	0,159	% 25	0,159	% 45,9
Türkiye Binek Otomobil İthalat Değeri	0,117	0,072	% 26,4	0,072	% 20,8

Şekil 4'te bağımsız değişkenlerin önemi grafik ortamında ifade edilmiştir. Her iki modelde motorlu kara taşıtları üretim endeksi'nin tahmin edilen değişken üzerinde en önemli etkiye sahip olduğu görülmektedir. Diğer bağımsız değişkenler de modele katkı sağlamaktadır, ancak farklı önem derecelerine sahiptirler.



Bu çalışmada kullanılan değişkenler zaman serisi verileri olduğu için, bu verilerin gelecek değerleri ARIMA, SARIMA, Holt-Winters gibi zaman serisi tahmin yöntemleri kullanılabilir. Bu yöntemler, geçmiş verilerin trendlerini, mevsimselliklerini ve diğer özelliklerini analiz ederek gelecek değerleri tahmin etmektedir. Öncelikle bağımsız değişkenlerin her birinin gelecek 7 aylık değerlerini tahmin etmek için ARIMA (AutoRegressive Integrated Moving Average) modeli tercih edilmiştir. Python yazılımında, "pmdarima" kütüphanesinin "auto_arima" fonksiyonu, en uygun ARIMA model parametrelerini otomatik olarak bulmak için kullanılmıştır. "auto_arima" fonksiyonu, ARIMA modelinin üç ana parametresi olan p (autoregressive terimlerin sayısı), d (entegrasyon derecesi) ve q (moving average terimlerin sayısı) için en uygun değerleri belirlemektedir. Daha sonra bu kapsamda belirlenen model parametreleri kullanılarak, gelecek 7 ay için tahminler oluşturulmuştur. ARIMA modeli ile gerçekleştirilen bağımsız değişkenlerin gelecek tahminlerine ilişkin değerler ve en iyi model sonuçları Tablo 7'de gösterilmiştir.

Tablo 7. ARIMA Modeli ile Bağımsız Değişkenlerin Gelecek 7 Aylık Tahminleri

Değişkenler	ARIMA En İyi Model	Aralık 2023	Ocak 2024	Şubat 2024	Mart 2024	Nisan 2024	Mayıs 2024	Haziran 2024
Otomobil Satış Adedi	(1,0,1)(0,0,0)[0]	79.182	79.024	78.866	78.708	78.550	78.393	78.237
MKT Üretim Endeksi (2015=100)	(0,1,1)(0,0,0)[0]	147.2	147.7	148.2	148.7	149.1	149.6	150.1
Amerikan Dolar Kuru	(4,2,1)(0,0,0)[0]	29.32	30.27	31.22	32.05	32.90	33.76	34.59
Türkiye İthalatı	(1,1,0)(0,0,0)[0]	27.506.800.000	27.493.720.000	27.499.180.000	27.496.900.000	27.497.850.000	27.497.460.000	27.497.620.000
Yurt Dışı ÜFE	(2,2,2)(0,0,0)[0]	1679.33	1751.81	1802.80	1846.05	1894.48	1950.98	2011.30
Otomobil İthalat	(4,0,2)(0,0,0)[0]	1.451.593.000	1.314.580.000	1.230.122.000	1.203.006.000	1.204.926.000	1.189.612.000	1.135.984.000

Tablo 8'de sunulan model performans ölçütleri, iki farklı yapay sinir ağı modeli olan Çok Katmanlı Algılayıcı (MLP) ve Radyal Taban Fonksiyonu (RBF) ağlarının tahmin performanslarını karşılaştırmaktadır. Her iki modelin performansı, R^2 , Ortalama Mutlak Yüzde Hata (MAPE), Ortalama Kare Hata (MSE) ve Kök Ortalama Kare Hata (RMSE) değerleri üzerinden değerlendirilmiştir. Ayrıca, her iki model için de veri setindeki örnek sayısı (N) 167 olarak belirtilmiştir. Bu değerlendirme, her bir ölçütün ne anlama geldiğini ve modeller arasındaki farkları anlamamıza yardımcı olmaktadır. R^2 değeri, modelin verilerin varyansını ne kadar iyi açıkladığını göstermektedir. 1'e yakın değerler, modelin veri setindeki varyansı yüksek oranda açıkladığını ve dolayısıyla tahminlerin

doğruluğunun yüksek olduğunu gösterir. Bu durumda, MLP modelinin (0,865) RBF modeline (0,765) göre veri setindeki değişkenliği daha iyi açıkladığı ve dolayısıyla daha iyi bir performans sergilediği görülmektedir. MAPE, tahmin edilen değerlerin gerçek değerlerden ne kadar sapma gösterdiğinin yüzdesel bir ifadesidir. Daha düşük MAPE değerleri, modelin tahminlerinin gerçek değerlere daha yakın olduğunu ve dolayısıyla daha iyi performans gösterdiğini belirtmektedir. Bu açıdan bakıldığında, MLP modelinin (% 12) RBF modeline (%18) göre daha az hata ile tahmin yaptığı görülmektedir. MSE, hataların karelerinin ortalamasıdır ve modelin tahmin hatalarının büyüklüğünü ölçmektedir. Daha düşük MSE değerleri, daha iyi model performansını göstermektedir. MLP modeli (0,45), RBF modeline (0,78) göre daha düşük MSE değerine sahip olduğu için, tahminlerinde daha az hata yapmıştır. RMSE, MSE'nin kareköküdür ve hata büyüklüklerinin ölçülmesinde kullanılır, birimleri ölçülen değerlerle aynıdır. RMSE değeri de tıpkı MSE gibi, daha düşük olduğunda daha iyi model performansı anlamına gelmektedir. Bu durumda da MLP modeli (0,67), RBF modeline (0,88) göre daha iyi performans sergilemektedir.

MLP modeli, R^2 , MAPE, MSE ve RMSE değerleri açısından RBF modeline göre daha iyi performans sergilemektedir. Bu, MLP modelinin bu veri seti üzerinde tahminlerde daha doğru ve daha az hatalı olduğunu göstermektedir. Her iki model de aynı veri seti (N=167) üzerinde değerlendirilmiş olup, MLP modelinin bu özel durumda genel olarak daha iyi bir tercih olduğu sonucuna varılabilir.

Tablo 8. Modellerin Performans Ölçütleri

Hata İstatistikleri	MLP	RBF
R^2	0,865	0,765
MAPE	0,12	0,18
MSE	0,45	0,78
RMSE	0,67	0,88
N sayısı	167	167

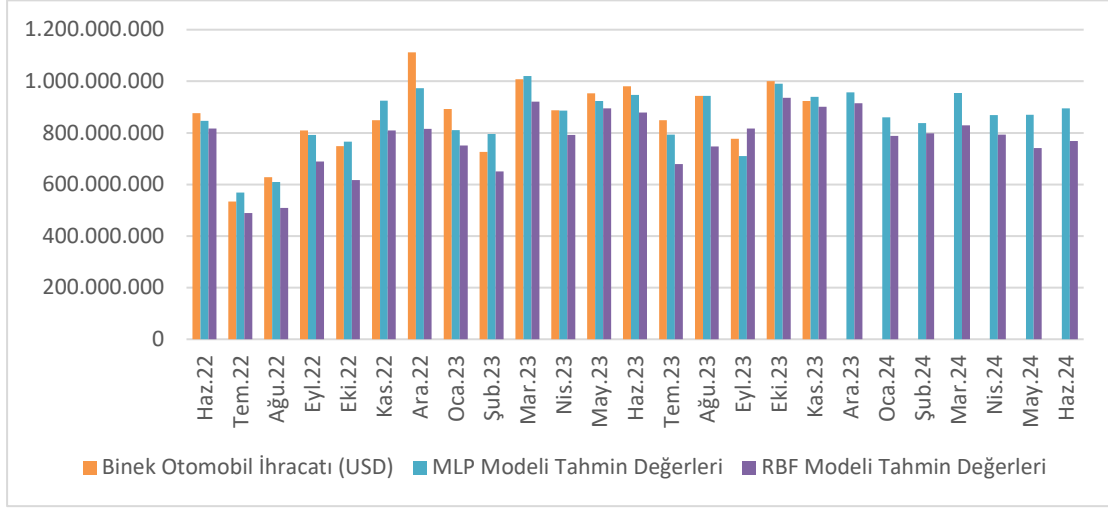
Tablo 9, MLP ve RBF modellerinin binek otomobil ihracatı tahmin değerlerini içermektedir. MLP modeline göre, önümüzdeki dönemde binek otomobil ihracat değerleri 743 milyon dolar ile 957 milyon dolar arasında değişim gösterecektir. RBF modelinde ise 817 milyon dolarlık ihracat değeri tahmin edilmiştir. Tabloya bakıldığında, genellikle tahmin edilen değerlerin gerçek değerlere yakın olduğu görülmektedir.

Tablo 9. MLP ve RBF Modelleri Binek Otomobil İhracat Tahmin Değerleri

Aylar	Binek Otomobil İhracatı (USD)	MLP Modeli Tahmin Değerleri	RBF Modeli Tahmin Değerleri
Haz.22	875.831.451	846.877.280	817.316.644
Tem.22	533.793.358	568.275.863	489.365.741
Ağu.22	628.683.279	610.166.727	509.378.148
Eyl.22	809.093.581	791.959.991	689.459.784
Eki.22	748.409.511	765.993.866	617.399.978
Kas.22	849.040.243	924.521.368	809.428.578
Ara.22	1.111.587.580	973.673.183	815.732.512
Oca.23	892.464.498	810.824.989	750.634.642
Şub.23	726.378.278	795.148.661	650.498.728
Mar.23	1.007.483.583	1.019.905.052	920.996.345
Nis.23	886.984.413	886.175.514	792.197.378
May.23	952.954.769	923.483.022	894.544.771
Haz.23	980.663.330	946.772.921	878.994.516
Tem.23	849.614.776	793.097.491	678.487.578
Ağu.23	943.216.553	943.973.458	747.814.973
Eyl.23	776.611.857	709.525.405	817.316.642
Eki.23	1.000.184.780	990.255.877	935.456.665
Kas.23	922.989.219	939.850.839	900.780.452
Ara.23		957.538.406	914.378.741
Oca.24		859.747.065	787.698.427
Şub.24		837.947.807	798.543.209
Mar.24		954.290.682	829.677.315
Nis.24		868.795.024	793.198.703
May.24		870.510.715	741.048.689
Haz.24		894.883.191	768.703.436

Şekil 5, MLP ve RBF modellerinin tahmin ettiği değerleri gerçek değerlerle daha açık bir şekilde karşılaştırmak amacıyla grafiksel olarak sunulmuştur. RBF modelinde, MLP'ye kıyasla daha düşük ihracat değerleri tahmin edilmiştir.

Şekil 5. MLP ve RBF Modellerinin Binek Otomobil İhracat Tahmin Değerleri



Genel olarak MLP (Çok Katmanlı Algılayıcı) modeli, gerçek ihracat değerlerine oldukça yakın tahminler yapmış gibi görünmektedir. Özellikle Mart 2023 ve Kasım 2023 dönemlerinde, modelin tahminleri gerçek değerlere oldukça yakındır. Bu, modelin bu aylar için ihracat dinamiklerini iyi öğrendiğini ve veriye iyi uyduğunu göstermektedir. Tahminler genel olarak gerçek değerlere yakın olsa da, belirli aylarda ve modeller arasında farklılıklar bulunmaktadır. Modeller, daha fazla veri ile eğitilip ayarlandığında veya daha karmaşık teknikler kullanıldığında daha iyi sonuçlar verebilmektedir. Buna ek olarak, RBF (Radial Basis Function) modeli ise bazı aylarda gerçek değerlerden daha düşük tahminler yapmıştır. Özellikle Temmuz 2022 ve Ağustos 2022 gibi aylarda, modelin tahminleri gerçek değerlerin altında kalmıştır. Ancak Mart 2023 ve Ekim 2023 gibi dönemlerde RBF modelinin tahminleri gerçekleşen ihracat değerlerine yaklaşmaktadır. MLP modeli genellikle RBF modeline kıyasla daha yüksek tahminler yapmıştır. Her iki modelin performansının aylara göre değiştiği gözlemlenmektedir. Bazı aylarda MLP, bazılarında ise RBF daha iyi performans göstermiştir. Bu durum, farklı zaman dilimlerinde ve piyasa koşullarında hangi modelin daha iyi performans gösterdiğini anlamak için daha detaylı bir analize ihtiyaç olduğunu göstermektedir. MLP ve RBF modellerinin her ikisi de mevsimsel etkileri ve genel trendi yansıtır gibi görünmektedir. Özellikle yüksek ihracat değerleri için (örneğin Aralık 2022 ve Mart 2023) her iki model de yüksek tahminler yapmış, bu durum modellerin mevsimsel etkileri kısmen yakalayabildiğini düşündürülebilir. Tablonun sonunda, Aralık 2023'ten Haziran 2024'e kadar olan aylar için her iki modelin gelecek tahmin değerleri verilmiştir.

Sonuç, Tartışma ve Öneriler

Yapay sinir ağları yöntemi, tahmin yapmada kullanılan bir makine öğrenmesi yöntemidir. Bir yapay sinir ağı, veri analizi ve öğrenme yoluyla eğitildikten sonra yeni verilere dayalı tahminler yapabilir. Bu yöntem, çeşitli alanlarda kullanılabilir ve geniş bir uygulama alanına sahiptir. Yapay sinir ağları, tahmin yetenekleri ve geniş kullanım alanlarıyla popüler bir yöntemdir.

Türkiye otomobil sektörü ve ihracatı, ülke ekonomisi için stratejik öneme sahip bir sektördür. Otomobil ihracatı, ekonomik büyümeyi destekleyen döviz geliri ve istihdam oluşturma potansiyeli barındırmaktadır. Otomobil sektörü, devlet politikalarının ve ekonomik planlamaların önemli bir bileşenidir. Tahmin modelleri, otomobil ihracatının gelecekteki performansını değerlendirmek ve politika yapıcılarına rehberlik etmek için kullanılabilir. Otomobil üreticileri ve yatırımcılar, otomobil ihracatına ilişkin tahminlere dayanarak stratejilerini belirler. Bu nedenle, doğru ve güvenilir tahminler, yatırımcıların kararlarını destekleyebilir ve riskleri azaltabilir. Otomobil sektörü rekabetçi bir ortamda faaliyet göstermektedir. Doğru tahminler, otomobil üreticilerine ve ihracatçılara, talep ve pazar olanaklarını önceden görebilmeleri için avantaj sağlayabilir.

Bu çalışma, yapay sinir ağlarının (MLP ve RBF) performansını değerlendirerek Türkiye'nin binek otomobil ihracat tahminleri konusunda önemli bilgiler sunmaktadır. Elde edilen sonuçlar, Karakaş (2019) tarafından geliştirilen ARIMA modeliyle yaptığı ihracat tahminleri çalışması ve diğer literatürdeki benzer uygulamalarla karşılaştırıldığında, MLP'nin yüksek doğruluk derecesine işaret eden korelasyon skorları ile öne çıktığı görülmektedir. Bunun yanı sıra, MAPE değerlerinin düşük olması, modelin tahmin başarısını destekler niteliktedir. Bu çalışmada MLP'nin RBF'ye göre daha üstün performans gösterdiği belirtilmiş, bu da Lasya vd. (2023) tarafından yapılan çalışmalarla uyumlu bir sonuçtur. Bununla birlikte, bizim çalışmamız, Türkiye'nin aylık binek otomobil ihracatını tahmin etme üzerine odaklanırken, Karaatlı vd. (2012), Akyurt (2015), Topal (2019) ve Kayakuş vd. (2023) çalışmaları farklı otomobil pazar segmentlerinde ve satış tahminlerinde yapay sinir ağları (YSA) ve diğer makine öğrenmesi yöntemlerinin kullanımını incelemektedir. Karaatlı vd. (2012) ve Akyurt (2015), yeni ve yerli otomobil satışlarını, makroekonomik göstergeler ve mevsimsel etkileri dikkate alarak modellemişlerdir. Topal (2019), çevrimiçi verileri ve tüketici bütünleşmesini kullanarak bir otomobil markasının satış miktarlarını tahmin ederken, Kayakuş vd. (2023) hafif ticari araç satışlarını farklı makine öğrenmesi teknikleriyle değerlendirmiştir. Her biri, YSA ve makine öğrenmesinin otomobil pazarı tahminlerinde etkili olduğunu göstermekle birlikte, Gür vd. (2024).

yapmış olduğumuz çalışma, bu yöntemleri Türkiye'nin otomobil ihracatı bağlamında genişletmekte ve derinleştirmektedir, böylece bu alanda yeni bir perspektif sunmaktadır. Bu çalışmalar arasındaki temel fark, uygulama alanlarının çeşitliliği ve kullanılan veri setlerinin özgünlüğüdür. Çalışmamız, bu metodolojileri Türkiye'nin otomobil ihracatı bağlamında ele alarak, literatüre özgün bir katkı sunmaktadır.

Her iki modelde de eğitim verisi olarak 167 adet örneklem (% 70) ve test verisi olarak da 50 adet örneklem (% 30) kullanılmıştır. MLP modelinde MAPE değeri %12 ve RBF modelinde ise %18'dir. Her iki modelde de motorlu kara taşıtları üretim endeksi en önemli bağımsız değişkendir. Bununla birlikte iki modelin performansı karşılaştırıldığında, MLP modelinin RBF modeline göre daha iyi performans gösterdiği görülmüştür. Bu nedenle, gelecekte yapılacak çalışmalarda MLP modelinin daha fazla geliştirilmesi ve ayarlanması düşünülebilir. Modelin doğruluğunu artırmak için daha fazla özellik veya veri kullanımı, hiperparametre ayarları ve ağ yapısı gibi faktörler göz önünde bulundurulabilir. Model performansının artırılması için daha fazla ve yüksek kalitede veri toplanması önemlidir. Veri miktarı ve çeşitliliği artırılarak, modelin daha genel ve kapsamlı sonuçlar üretmesi sağlanabilir. Bununla birlikte, otomobil sektörünü etkileyen dışsal faktörlerin (örneğin ekonomik durum, döviz kurları, dünya piyasaları gibi) modelde dikkate alınması gelecekteki tahminlerin daha hassas ve gerçekçi olmasını sağlayabilir. Öte yandan, bu çalışmada sadece MLP ve RBF modelleri ele alınmıştır. Gelecekte, farklı makine öğrenimi yöntemleri veya istatistiksel modellerle de karşılaştırmalar yapılabilir. Bu şekilde, en iyi tahmin yönteminin belirlenmesi sağlanabilir.

Sonuç olarak, bu çalışma gelecekte otomobil ihracatını tahmin etmek için daha gelişmiş modeller geliştirme, daha fazla veri toplama ve dışsal faktörleri dâhil etme gibi adımları içerebilir. Bu tavsiyeler, otomobil sektörünün rekabetçi ortamında daha doğru ve bilinçli kararlar alınmasına yardımcı olabilir.



This research article has been licensed with Creative Commons Attribution - Non-Commercial 4.0 International License. Bu araştırma makalesi, Creative Commons Atıf - Gayri Ticari 4.0 Uluslararası Lisansı ile lisanslanmıştır.

Yazar Katkıları

Yazarlar çalışmaya katkı oranlarını bu şekilde beyan etmişlerdir: Yunus Emre Gür %35, Kamil Abdullah Eşidir %35, Şahin Göktuğ Kaldırımcı %30

Teşekkür Beyanı

Yazarlar teşekkür beyanında bulunmamışlardır.

Destek Beyanı

Yazarlar destek beyanında bulunmamışlardır.

Çıkar Çatışması

Yazarlar herhangi bir çıkar çatışması beyan etmemişlerdir.

Etik Beyanı

Yazarlar çalışma için Etik Kurul Onayı alınmasına gerek olmadığını beyan etmişlerdir.

Sorumlu Özel Sayı Editörleri

Doç. Dr. Beyza Mina Ordu-Akkaya, Ankara Sosyal Bilimler Üniversitesi

Doç. Dr. Görkem Ataman, Yaşar Üniversitesi

Arş. Gör. Yunus Yıldırım, Afyon Kocatepe Üniversitesi

Kaynakça/References

- Aktaş C. (2007). Otomobil İhracatı ve İthalatı Fiyat Endeksi Verilerinin Farklı Varyanslılığının İncelenmesi. *İstanbul Ticaret Üniversitesi Sosyal Bilimler Dergisi*, 6(11), 149-162.
- Akyurt, İ. Z. (2015). Talep Tahmininin Yapay Sinir Ağlarıyla Modellenmesi: Yerli Otomobil Örneği. *Ekonometri ve İstatistik Dergisi*, 23, 147-157.
- Athukorala, P. C., & Veeramani, C. (2019). From import substitution to integration into global production networks: The case of the Indian automobile industry. *Asian Development Review*, 36(2), 72-99.
- Boughrara, H., Chtourou, M., Ben Amar, C., & Chen, L. (2016). Facial expression recognition based on a mlp neural network using constructive training algorithm. *Multimedia Tools and Applications*, 75, 709-731.
- Breiman, L., Friedman, J., Stone, C.J., & Olshen, R.A. (1984). *Classification and Regression Trees*. CRC press.
- Çokşen, E. (2023). *Covid-19'un Otomotiv Sektörüne Etkileri ve Bir Analiz*. [Yayımlanmamış Doktora Tezi] Marmara Üniversitesi.
- de Soyres, F., Frohm, E., & Gunnella, V. (2020). *How Global Value Chains Change the Trade-Currency Relationship*. FEDS Notes.
- Feurer, M., & Hutter, F. (2019). Hyperparameter optimization. *İçinde: Automated machine learning: Methods, systems, challenges*. (ss. 3-33). Springer.
- Gagnon, J. E., & Knetter, M. M. (1995). Markup Adjustment and Exchange Rate Fluctuations: Evidence From Panel Data On Automobile Exports. *Journal of International Money and Finance*, 14(2), 289-310.
- Gerni C., Emsen Ö. S., & Değer, M. K. (2008). *İthalata Dayalı İhracat ve Ekonomik Büyüme: 1980-2006 Türkiye Deneyimi*, 2. Ulusal İktisat Kongresi , İzmir.
- Gomez-Ibanez, J. A., & Harrison, D. (1982). Imports and the Future of the US Automobile Industry. *The American Economic Review*, 72(2), 319-323.
- Hyndman, R. J., & Koehler, A. B. (2006). Another look at measures of forecast accuracy. *International journal of forecasting*, 22(4), 679-688.
- İnançlı, S., & Konak, A. (2011). Türkiye'de İhracatın İthalata Bağımlılığı: Otomotiv Sektörü. *Eskişehir Osmangazi Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 6(2), 343-362.
- Karaatlı, M., Helvacıoğlu, Ö. C., Ömürbek, N., & Tokgöz, G. (2012). Yapay sinir ağı yöntemi ile otomobil satış tahmini. *Uluslararası Yönetim İktisat ve İşletme Dergisi*, 8(17), 87-100.
- Karakaş, E. (2019). Türkiye'nin Otomotiv İhracat Gelirinin Arima Modeli ile Tahmin Edilmesi. *Yaşar Üniversitesi E-Dergisi*, 14(55), 318-328.
- Kayakuş, M., Terzioğlu, M., Yağmur, A., & Erdoğan, D. (2023). Türkiye'deki Hafif Ticari Araç Satışlarının Makine Öğrenmesi Yöntemleriyle Tahmin Edilmesi. *Gazi Mühendislik Bilimleri Dergisi*, 9(4-ICAIAME 2023), 100-112.
- Kohavi, R. (1995). A study of cross-validation and bootstrap for accuracy estimation and model selection. *İçinde: Ijcai* (Vol. 14, No. 2, ss. 1137-1145).
- Lasya, C. L., Pooja, S., Jeyashree, S., Ambhika, C., & Eswari, G. (2023). Forecasting Pre-Owned Car Prices Using Machine Learning. *İçinde 2023 2nd International Conference on Smart Technologies and Systems for Next Generation Computing (ICSTSN)* (ss. 1-6). IEEE.
- Nur, H. B., & Çalbörü, M. (2023). Türkiye'de Sektörlerin Dış Ticaret ve İstihdamdaki Yeri: Türkiye Otomotiv Sektörü Analizi. *Stratejik Ve Sosyal Araştırmalar Dergisi*, 7(1), 35-53.
- Paparoditis, E., & Politis, D. N. (2018). The asymptotic size and power of the augmented Dickey-Fuller test for a unit root. *Econometric Reviews*, 37(9), 955-973.
- Phillips, P. C., & Perron, P. (1988). Testing for a unit root in time series regression. *biometrika*, 75(2), 335-346.
- Ray, S. (2012). Economic Performance of Indian Automobile Industry: An Econometric Appraisal. *Business Intelligence Journal*, 5(1), 151-162.
- Samaddar, M., & Bachman, D. (2022). No longer a smooth drive: How automobiles' role in the US economy has evolved. *Deloitte Insights*. <https://www2.deloitte.com/us/en/insights/economy/spotlight/automobile-impact-us-economy.html> Erişim Tarihi: 19.02.2024
- Sing, J. K., Basu, D. K., Nasipuri, M., & Kundu, M. (2003, October). Improved k-means algorithm in the design of RBF neural networks. *İçinde TENCON 2003. Conference on Convergent Technologies for Asia-Pacific Region* (Vol. 2, ss. 841-845). IEEE.
- Türkiye İstatistik Kurumu (TÜİK) Verileri, <https://data.tuik.gov.tr/> Erişim tarihi: 10.01.2024
- Topal, İ. (2019). Çevrimiçi Tüketici Bütünleşmesi Ve Arama Motoru Verileri Kullanılarak Yapay Sinir Ağları İle Otomobil Satış
- Gür vd. (2024).

Tahmini. *Nevşehir Hacı Bektaş Veli Üniversitesi SBE Dergisi*, 9(2), 534-551.

- Wilamowski, B. M. (2009). Neural network architectures and learning algorithms. *IEEE Industrial Electronics Magazine*, 3(4), 56-63.
- Williamson, J. (2009). Exchange rate economics. *Open Economies Review*, 20, 123-146.
- Wu, J., Chen, X. Y., Zhang, H., Xiong, L. D., Lei, H., & Deng, S. H. (2019). Hyperparameter optimization for machine learning models based on Bayesian optimization. *Journal of Electronic Science and Technology*, 17(1), 26-40.
- Yingwei, L., Sundararajan, N., & Saratchandran, P. (1998). Performance evaluation of a sequential minimal radial basis function (RBF) neural network learning algorithm. *IEEE Transactions on neural networks*, 9(2), 308-318.
- Yoğunlu, A., (2022). *Yenilik Ekosistem Yaklaşımına Dayalı Teknoloji Geliştirme Bölgeleri*. Gazi Kitabevi.

Research Article (Special Issue) | Araştırma Makalesi (Özel Sayı)

İnsan kaynakları yönetiminde yapay zekâ teknolojisinin benimsenmesi üzerine güç alanı analizi

Nermin Kişi

Mehmet Akif Özer

Doç. Dr., Zonguldak Bülent Ecevit Üniversitesi, ncelik@beun.edu.tr, [0000-0002-6247-5445](https://orcid.org/0000-0002-6247-5445)Prof. Dr., Ankara Hacı Bayram Veli Üniversitesi, mehmet.ozzer@hbv.edu.tr, [0000-0003-2220-2271](https://orcid.org/0000-0003-2220-2271)Corresponding author/Sorumlu yazar: Nermin Kişi ✉ ncelik@beun.edu.tr

Öz

Artan küreselleşme ile birlikte sürekli değişen iş dünyasında, teknolojik yenilikler hayatta kalmanın kritik bir belirleyicisi olarak kabul edilmektedir. Bu nedenle, modern çağın işletmeleri iş süreçlerinde yeni teknolojileri kullanmaya yönelmektedir. Günümüzde en çok tartışılan ve en yaygın kullanılan teknolojilerinden biri yapay zekâdır. İşletmelerin mevcut sistemlerinden bu ileri teknoloji sistemlerine geçişi kapsamlı bir planlama süreci gerektirir. Bu açıdan, işletmelerde yapay zekâya dayalı uygulamaları benimsemeye temel faktörleri keşfetmek önemli bir araştırma konusudur. Özellikle, İnsan Kaynakları Yönetimi (İKY)'nde yapay zekâ kullanımına geçiş karmaşık ve zorlu bir süreç olduğundan, bu konuda daha fazla araştırma yapılmasına ihtiyaç duyulmaktadır. Bu çalışmanın amacı, yapay zekâya dayalı İKY uygulamalarının benimsenmesini etkileyen itici ve kısıtlayıcı güçleri belirlemektir. Bu amaca ulaşmak için, çalışmada Güç Alanı Analizi Modeli çerçevesinde sistematik literatür taraması yöntemi kullanılmıştır. Bulgular İKY'de yapay zekânın benimsenmesini teşvik eden temel itici güçlerin örgütsel hazırbulunuşluk ve algılanan faydalar olduğunu ortaya koymuştur. Ayrıca, teknolojik değişime karşı olumsuz tepkiler, veri gizliliği ve güvenliğiyle ilgili endişeler, algoritmik önyargıdan kaynaklanan hatalar ve duygusal zekâ eksikliği İKY'de yapay zekânın benimsenmesinde karşılaşılan kısıtlayıcı güçler olarak tanımlanmıştır.

Anahtar Kelimeler: Örgütsel Değişim, İnsan Kaynakları Yönetimi, Yapay Zekâ, Güç Alanı Analizi **JEL Kodları:** O15, O33

Force field analysis on the adoption of artificial intelligence technology in human resource management

Abstract

Technological innovations are recognized as a critical determinant of survival in a constantly changing business world with increasing globalization. Therefore, businesses of the modern era tend to utilize new technologies in their business processes. Artificial intelligence is one of the most discussed and widely used technologies today. The transition of businesses from their existing systems to these advanced technology systems requires a comprehensive planning process. In this respect, it is an important research topic to explore the key factors in adopting artificial intelligence-based applications in businesses. As the transition to the use of artificial intelligence in Human Resource Management (HRM) is a particularly complex and challenging process, more studies are needed on this topic. The aim of this study is to determine the driving and restraining forces affecting the adoption of artificial intelligence-based HRM practices. In order to achieve this aim, a systematic literature review method in line with the Force Field Analysis Model has been used in the study. The findings have revealed that the main driving forces encouraging the adoption of artificial intelligence in HRM are organizational preparedness and perceived benefits. Moreover, negative reactions to technological change, concerns regarding data privacy and security, algorithmic bias errors, and the lack of emotional intelligence have been identified as restraining forces in the adoption of artificial intelligence in HRM.

Keywords: Organizational Change, Human Resource Management, Artificial Intelligence, Force Field Analysis **JEL Codes:** O15, O33

Extended Summary

Globalization and the continually changing business environment compel organizations to adopt technological innovations to gain a competitive advantage. Contemporary businesses are turning to new technologies with the aim of transforming and enhancing their business processes. Artificial intelligence emerges as a prominent, widely utilized, and extensively discussed topic in this technological transformation. However, the transition from traditional business systems to artificial intelligence-based systems demands not only a technical integration process but also a strategic planning and adaptation process. In particular, the adoption

How to cite this article / Bu makaleye atıf vermek için:Kişi, N., & Özer, M. A. (2024). İnsan kaynakları yönetiminde yapay zekâ teknolojisinin benimsenmesi üzerine güç alanı analizi. *KOCATEPEİİBFD*, 26(Özel Sayı), 35-52. <https://doi.org/10.33707/akuiibfd.1406096>

of artificial intelligence in the field of Human Resources Management (HRM) is a complex process that requires special attention. In an area where the human factor is paramount, a detailed understanding of the driving and constraining forces related to the adoption of artificial intelligence becomes of great importance.

This study investigates the factors influencing the adoption of artificial intelligence-based HRM applications using the Force Field Analysis Model. The primary research questions addressed in the study are as follows: What are the driving forces that support the adoption of artificial intelligence-based applications in HRM? What are the restraining forces complicating the adoption of artificial intelligence-based applications in HRM? Studies on integrating artificial intelligence in HRM have utilized various methods, including literature reviews, surveys, interviews, Analytical Hierarchy Processes, and Fuzzy Topsis. While some focused on attitudes towards new technology, others examined its impact on specific HRM functions. In contrast to existing research, this study identifies the forces influencing artificial intelligence adoption in HRM in line with the Force Field Analysis Model, a widely recognized tool for understanding and implementing change.

Identifying driving and restraining forces involved a systematic literature review method utilizing the Web of Science (WoS) database. On November 28, 2023, a query was executed with the criteria TITLE "human resource management" or "human resources management" or "HRM" and TITLE "artificial intelligence" or "AI," resulting in 59 WoS publications. After filtering for English language and article type, 36 publications were obtained. Two publications were excluded due to the unavailability of full text or withdrawal. Following the exclusion of publications that were not focused on driving and restraining forces for artificial intelligence-based HRM adoption (4 publications), the final sample comprised 30 publications. Utilizing Microsoft Word and Microsoft Excel, content analysis organized the data into basic categories.

The findings indicate various factors that influence the adoption of artificial intelligence-based HRM applications. The main driving forces are organizational preparedness and perceived benefits. Organizational preparedness encompasses having adequate financial resources, advanced technological infrastructure, a supportive attitude from top management, and employees possessing necessary skills, while perceived benefits include enhancing efficiency and productivity, improving decision-making activities, encouraging creativity and innovation, and reinforcing employee engagement. On the other hand, identified restraining forces hindering the adoption involve negative reactions to technological change, concerns related to data privacy and security, algorithmic bias errors, and a lack of emotional intelligence. In this study, the Force Field Analysis, assessing the adoption of artificial intelligence in HRM, seeks to enable practitioners to effectively leverage driving forces while reducing and eliminating restraining forces. As a result of this approach, the emergence of enhanced artificial intelligence applications is anticipated, leading towards progress from the current equilibrium state to the desired state.

The key insights offered by this study contribute to businesses' understanding of the transition process to artificial intelligence-based applications in HRM, addressing potential forces and ensuring the effective integration of this technology. However, further research is necessary to explore the role of artificial intelligence-based applications in HRM. The current study's dataset is limited to English articles from the WoS database. Future research could enhance the scope by exploring different databases, incorporating various languages, and considering different publication types for a more comprehensive perspective. Furthermore, the current study is based on secondary data. For future research, utilizing primary data is recommended to gain a better understanding of the potential impacts of artificial intelligence applications on HRM. In this context, studies assessing the readiness levels of managers and employees for artificial intelligence usage in HRM processes could be conducted. Moreover, conducting new research to explore how different groups perceive the driving and restraining forces identified in this study, which are related to the adoption of artificial intelligence-based transformation, would be valuable.

Giriş

Günümüzde yeni teknolojilerin benimsenmesi ve iş dünyasına entegrasyonu tercihten ziyade gereklilik haline gelmiştir. İşletmeler sürekliliği ve büyümeyi sağlamak için ileri teknolojileri iş hedefleriyle uyumlu hale getirme çabası içine girmişlerdir. Bu teknoloji uygulamaları, işletme içindeki işleyişleri modern hale getirerek organizasyonları yeniden yapılandırırken, makinelerin ve insanların üretkenliklerini ve verimliliklerini artırmaktadır. Yapay zekânın iş dünyasında kullanılmaya başlanması, bu tür iş dönüşümüne bir örnektir. Hâlihazırda yapay zekâyı kullanan işletmeler, tedarik zinciri ve lojistik yönetimi, pazarlama, finans, üretim ve operasyon yönetimi, araştırma ve geliştirme gibi temel iş süreçlerinde kademeli bir dönüşüme tanık olmuşlardır. Son zamanlarda İnsan Kaynakları Yönetimi (İKY) alanında da bu teknolojinin etkileri gözle görülür hale gelmiş ve iş süreçlerinin daha etkili şekilde yönetilmesi amacıyla insan-makine iş birliğine daha fazla önem verilmeye başlanmıştır (Saxena, 2020, s. 152). Bu bağlamda, dünya genelinde 803 şirketin katıldığı Dünya Ekonomik Forumu tarafından yapılan anket çalışmasında, iş hedeflerine ulaşmak için gelecek beş yıl içinde iş süreçlerini otomasyonla hızlandırma stratejisini benimsemeyi planlayan şirketlerin oranı %80 olarak belirlenmiştir (World Economic Forum, 2023, s. 50).

Geleneksel İKY işlevlerinde önemli değişiklikler meydana getiren yapay zekâ teknolojisinin, otomasyona olan güveni görünür hale

getirerek mevcut iş süreçlerini geliştirdiğini gösteren kanıtlar mevcuttur. Örneğin, McKinsey & Company (2022), farklı bölgeleri, endüstrileri, şirketleri, uzmanlık alanlarını ve çalışma sürelerini temsil eden 1,492 katılımcıyla gerçekleştirdiği bir anket çalışmasıyla, bu şirketlerin 744'ünün en az bir örgütsel işlevde yapay zekâ teknolojisini benimsediğini ve bu teknolojinin şirket gelirlerini artırdığını, aynı zamanda maliyetleri azalttığını tespit etmiştir. İKY alanında yapay zekâ teknolojisini ilk benimseyen şirketlerden biri olan IBM, yapay zekânın iş sorunlarını hızla çözme, yeni yetenekleri çekme ve geliştirme, çalışan deneyimini iyileştirme, analitik karar destek sağlama ve İKY bütçelerinin etkili bir şekilde kullanılmasına yardımcı olma gibi nedenlerle İKY alanında etkili bir araç olduğunu vurgulamaktadır (IBM, 2021, s. 3). Bununla birlikte, birçok işletme yöneticisi bu teknolojinin nasıl çalıştığını ve gerçekte ne işe yaradığını anlamakta zorlanmaktadır (Eubanks, 2022, s. 3). Ayrıca, literatürde, işletmelerin üretim, pazarlama ve muhasebe gibi alanlarında yapay zekâ üzerine yapılan çalışmalara kıyasla, İKY alanında yapılan çalışmaların sayısı göreceli olarak daha azdır.

İnsan zekasının yapay zekâ ile etkin bir birleşimi, İKY süreçlerini etkin bir şekilde dönüştürerek İKY sorunlarını çözmede önemli bir rol oynayabilir. Günümüzde İKY profesyonellerinin en önemli yetkinliklerinden biri, yapay zekâ teknolojisini kullanarak çeşitli İKY fonksiyonlarını yerine getirebilme becerisidir. Aday arama ve seçme, özgeçmiş inceleme, adaylarla iletişim kurma, mülakatları planlama, performans değerlendirme ve geri bildirim alma gibi rutin İKY işlevlerinin otomasyonu, bu süreçlere harcanan süreyi azaltmaya ve verimliliği artırmaya yardımcı olur (Tsymbaliuk vd., 2022, ss. 152, 160). Bu avantajlar yöneticileri İKY'de yapay zekâ teknolojisini benimsemeye yöneltebilir. Bununla birlikte, bazı unsurlar İKY'de yapay zekâ teknolojisini benimsemesini zorlaştırabilir. Örneğin, yapay zekâ kullanımının çalışanlar tarafından öğrenilmesi zorlu bir süreçtir. Bu durum, çalışanların işlerini güvence altına alıp alamayacakları konusunda endişe duymalarına neden olabilir. Yapay zekâyı etkin bir şekilde kullanabilecek adayları seçmek, yöneticilerin karşılaştığı temel zorluklardan biridir (Zahidi vd., 2020, s. 93). Ayrıca, önyargılı programlama, veri güvenliği, gizlilik ve tarafsızlık gibi etik sorunlar da yapay zekâ teknolojisini benimsemesinde karşılaşılan zorluklar arasında yer almaktadır (Sriram vd., 2021, ss. 3985-3986).

Bu çalışmada, İKY'de yapay zekânın benimsenmesinde etkili olan faktörlerin belirlenmesi amaçlanmıştır. Çalışma kapsamında incelenen başlıca araştırma soruları şu şekildedir: İKY'de yapay zekâyı dayalı uygulamaların benimsenmesini destekleyen itici güçler nelerdir? İKY'de yapay zekâyı dayalı uygulamaların benimsenmesini zorlaştıran kısıtlayıcı güçler nelerdir? Bu sorulara yanıt bulmak için çalışmanın geri kalan kısmı şu şekilde yapılandırılmıştır: İlk olarak, İKY'de yapay zekâ teknolojisini benimsenmesi konusunda ilgili yapılan çalışmalar incelenmiştir. Ardından, çalışmanın modeli ve yöntemi tanımlanmıştır. Daha sonra, Güç Alanı Analizi Modeli çerçevesinde sistematik literatür taraması yöntemiyle İKY'de yapay zekâ teknolojisini benimsenmesinde etkili olan itici ve kısıtlayıcı güçler belirlenmiştir. Son olarak, çalışmanın sonuçları, sınırlılıkları ve geleceğe yönelik çalışma önerilerinde bulunulmuştur.

1. Literatür Taraması

Yapay zekâ teknolojileri, yönetim sistemlerinde köklü değişimlere sebep olmaktadır. Bu teknoloji, özellikle İKY fonksiyonlarını yerine getirmek için etkili çözümler sunmaktadır. Literatürde İKY'de yapay zekânın benimsenmesi ile ilgili nitel ve nicel çalışmalar mevcuttur. Bu çalışmalardan bazıları aşağıdaki gibi özetlenebilir.

Hmoud (2021) rekabet baskısı, üst yönetimin desteği, performans beklentisi ve İKY rolleri ile İKY uygulayıcılarının yapay zekâyı benimsemeye yönelik tutumları arasındaki ilişkiyi incelemeyi amaçlamıştır. Araştırmacı, yapay zekâ kullanımının işletmelere önemli avantajlar sunarak yaygınlaşacağını vurgulamış ve politika yapıcılarının bu teknolojinin İKY üzerindeki etkilerini anlamalarının önemli olduğunu belirtmiştir. Al-Alawi vd. (2021) yapay zekâ teknolojisini İKY üzerindeki etkilerinin yanı sıra, yöneticilerin kuruluş içinde sürekli öğrenme ve beceri kazanma ortamını destekleme rolünü ikincil verilere dayanarak incelemişlerdir. Araştırmanın bulguları, işin sürekliliği ve örgütsel büyüme için yapay zekâ teknolojisini benimsemenin gerekliliği yönündedir. Ayrıca, çalışanlar için sürekli öğrenme ve beceri kazandırma ortamının yaratılmasında ve teşvik edilmesinde yapay zekânın önemli bir rol oynadığı ortaya konulmuştur. Jaiswal vd. (2022) yapay zekânın benimsenmesinin çalışanların beceri geliştirme gereksinimini artırdığını iddia etmektedir. Bu iddiayı desteklemek için, Hindistan'daki bilgi teknolojisi sektöründe çok uluslu şirketlerde çalışan 20 deneyimli çalışanla görüşmüşlerdir. Analiz sonuçları, çalışanların veri analizi, dijital, bilişsel, karar verme ve sürekli öğrenme olmak üzere beş kritik beceriyi geliştirmesi gerektiğini göstermiştir.

Tsymbaliuk vd. (2022) 88 insan kaynakları yöneticisinin katılımıyla Ukrayna merkezli şirketlerde İKY'de yapay zekânın uygulanabilirliğini, kullanım alanlarını, yaygınlaşma beklentilerini ve sonuçlarını değerlendirmeyi amaçlayan bir anket uygulamıştır. Bulgular, yapay zekânın İKY'de kullanımının doğal bir süreç olduğunu ve rutin İKY işlevlerini yerine getirmek için yapay zekâ teknolojisini uygun olabileceğini göstermektedir. Panda (2020), birincil ve ikincil veriler kullanarak, yapay zekânın İKY uygulamalarındaki rolünü, yapay zekâ ile İKY arasındaki ilişkiyi, yapay zekânın İKY için sağladığı avantajları ve uygulama sırasında karşılaşılan zorlukları araştırmayı amaçlamıştır. Bulgular, yapay zekânın özellikle işe alım süreçlerinde insan zekâsı gibi akıllı bir şekilde çalıştığını ve dijital çağda geleneksel işe alım sistemleri yerine, işe alım sürecinin otomatikleştirilmesinin önemli hale geldiğini göstermektedir.

Mathew vd. (2021), yapay zekânın İKY uygulamaları için bir devrim olduğunu belirterek, ikincil verilerle İKY’de yapay zekânın kullanım nedenlerini ve işe alım sürecinde karşılaşılan zorlukları araştırmışlardır. Çalışmada, bu teknolojinin işe alım süreçlerinde kullanılmasının avantajları arasında pozisyonlara uygun adayların seçilmesi, işe alım maliyetlerinin düşmesi ve işe alım süresinin kısılması yer almaktadır. Ayrıca, yapay zekâ tarafından kullanılan verilerin güvenliği ve gizliliği konusunda belirsizliklere dikkat çekmişlerdir. Bhatt (2022), Delphi, Analitik Hiyerarşi Süreci ve Bulanık Topsis yöntemlerini kullanarak yaptığı çalışmada, işe alım süreçlerinde yapay zekânın benimsenmesini araştırmıştır. Bulgular, bilgi güvenliği ve yatırım getirisinin işe alımda yapay zekâ teknolojisinin benimsenmesindeki en önemli unsurlar olduğunu ve işe uygun adayları çekme ve ön inceleme aşamalarında yapay zekâ kullanımının uygun olduğunu göstermiştir. Pan vd. (2022), işe alım faaliyetlerinde şirketlerin yapay zekâ teknolojisini benimseme davranışlarını anlamak için teknoloji, organizasyon ve çevre modelini işlem maliyeti teorisiyle bütünleştirmiştir. Araştırma, Güney Çin’in Guangzhou şehrinde 297 şirketin insan kaynakları ve üst düzey yöneticilerine yönelik bir anket gerçekleştirilerek yapılmıştır. Elde edilen sonuçlar, şirketlerin yapay zekâya yönelik algılanan karmaşıklık düzeyinin yapay zekânın benimsenmesini kısıtladığını, teknoloji yeterliliği ve düzenleyici desteğin yapay zekânın benimsenmesini teşvik ettiğini göstermektedir.

Mehrotra ve Khanna (2022) İKY’de otomasyonun işverenler tarafından kabul edilme düzeylerini ve işe alım uzmanlarının çalışanları işe almak için yapay zekâyı kullanma eğilimlerini belirlemeyi amaçlamışlardır. Bu amaca ulaşmak için, bilişim teknolojileri şirketlerinde çalışan dört uzmanla yarı yapılandırılmış görüşmeler gerçekleştirmişler ve toplanan verileri tematik analiz yöntemiyle çözümlenmişlerdir. Yapay zekânın işe alım sürecinde geçen süreyi önemli ölçüde azaltmaya yardımcı olmasına rağmen, işletmelerin işe alım, değerlendirme ve mülakat gibi İKY süreçlerinde yapay zekâyı kullanmalarının değişken olduğu ve bu teknoloji kullanımının henüz yaygın hale gelmediği bulgularına ulaşmışlardır.

Kshetri (2021) Küresel Güney ülkelerinde faaliyet gösteren şirketlerin İKY departmanlarında yapay zekâ teknolojisini kullanımını inceleyerek, çalışanları işe alma, seçme, geliştirme, elde tutma ve verimli kullanma amacıyla kullanılan yapay zekâ araçlarına dair vaka çalışmalarını incelemiş ve özellikle yolsuzluk, adam kayırmacılığı ve yetersiz kayıt tutma sistemlerinin yaygın olduğu ülkelerde bu araçların daha yüksek katma değer sağladığı sonucuna varmıştır. Hossin vd. (2021), Bangladeş’te gerçekleştirdikleri bir araştırmada, yapay zekânın İKY uygulamalarında benimsenmesinin önemini, sağladığı faydaları ve içsel/dışsal zorlukları değerlendirmişlerdir. Yapay zekâya dayalı İKY uygulamalarının performans, yetenek gelişimi, öğrenme ve geliştirme ve çalışanları elde tutma konularında büyük potansiyel taşıdığını vurgulamışlardır. Ancak, finansal kısıtlamalar, çalışanları teknoloji kullanımına ikna etme, iş güvencesi kaygıları ve sürekli eğitim ihtiyacı gibi faktörlerin, yeni teknolojinin benimsenmesinde karşılaşılan temel zorluklar olduğunu belirtmişlerdir.

Islam vd. (2022) teknolojinin kabulü ve kullanımına ilişkin birleşik teori çerçevesinde Bangladeş’te üretim ve hizmet firmalarında çalışan 283 İKY uzmanı ile anket yaparak, işe alım faaliyetlerinde yapay zekâya dayalı teknolojilerin benimsenmesinin ana öncüllerini belirlemeyi amaçlamışlardır. Çalışmalarında çaba beklentisi, kolaylaştırıcı koşul, algılanan güvenilirlik, performans beklentisi ve sosyal etki faktörlerinin yapay zekâ teknolojisini benimsenmesi üzerindeki etkilerini incelemişlerdir. Benzer şekilde, Tanantong ve Wongras (2024), teknolojinin kabulü ve kullanımına ilişkin birleşik teoriyi kullanarak, Tayland’ın Bangkok şehrinde 364 insan kaynakları ve işe alım uzmanının işe alımda yapay zekâyı benimseme niyetini etkileyen faktörleri araştırmışlardır. Çalışma, algılanan değer, algılanan özerklik, çaba beklentisi ve kolaylaştırıcı koşullar gibi birçok faktörün, işe alım için yapay zekâyı benimseme niyetini önemli ölçüde etkilediğini ortaya koymuştur.

Singh ve Shaurya (2021), Birleşik Arap Emirlikleri’nde faaliyet gösteren şirketlerde yapay zekânın İKY uygulamaları üzerindeki etkilerini yarı yapılandırılmış görüşmeler ve anket yöntemiyle keşfetmeyi amaçlamışlardır. Çalışma kapsamında, yapay zekâ yazılımı geliştiren şirketlerin yanı sıra işe alım süreçlerinde aktif olarak yapay zekâ yazılımlarını kullanan şirketlerle iletişim kurmuşlardır. Tematik analiz ve kısmi en küçük kareler modellemesi yoluyla verileri analiz etmişlerdir. Yapay zekânın İKY işlevlerini önemli ölçüde değiştirdiğini ve yeni teknolojinin benimsenmesiyle ortaya çıkan yeni iş türleri için eğitim faaliyetlerinin gerekliliğini vurgulamışlardır. Goswami vd. (2023) Hindistan ilaç sektöründe etkili İKY uygulamaları oluşturmak için yapay zekânın benimsenmesini kolaylaştıran faktörleri görev-teknoloji uyumu teorisine dayalı bir model geliştirerek araştırmışlardır. Bu amaçla, Hindistan’daki eczane firmalarında üst düzey ve uzman İKY pozisyonlarında görev yapan 160 çalışanla görüşme sağlanmıştır. Bulgular, örgüt kültürü ve algılanan faydaların yapay zekânın benimsenmesiyle pozitif bir ilişki içinde olduğunu göstermiştir.

Öte yandan, Chilunjika vd. (2022) Güney Afrika’da kamu sektöründe faaliyet gösteren işletmelerde İKY ve yapay zekâyı entegre etmenin fırsatlarını, karşılaşılan zorlukları ve gelecekteki beklentileri araştırmışlardır. Kitaplar, kitap bölümleri ve dergi makaleleri gibi yazılı eserlerden topladıkları verileri, içerik analizi ve tematik analiz yöntemlerini kullanarak incelemişlerdir. Araştırmanın sonuçları, yapay zekânın rutin görevleri üstlenerek İKY personelinin stratejik yönetim alanına daha fazla odaklanmasını sağladığını, işe alımda önyargıyı en aza indirmeye yardımcı olduğunu ve bu durumun Güney Afrika’daki kamu hizmetlerinin iyileştirilmesine katkı sağlayabileceğini ortaya koymuştur. Yapay zekâ destekli İKY’nin kurumsal üretkenliği artırmak için önemli bir strateji olduğunu belirten Malik vd. (2023), sistematik literatür taramasından elde edilen içgörülere dayanarak, insan kaynakları

yöneticilerine yapay zekâyı benimseme ve uygulama konusunda rehberlik edecek stratejik bir çerçeve sunmuşlardır. Araştırmacılar, bir örgütün teknolojik değişimi yönetme eğilimi ve bu tür değişikliklerle başa çıkma esnekliğinin, çalışanlar ve kurum açısından faydalı olabileceğini belirtmişlerdir.


Nitekim İKY’de yapay zekâ teknolojisini benimseme konusunda yapılan çalışmalarda sistematik literatür taraması, anket, mülakat, Analitik Hiyerarşi Süreci ve Bulanık Topsis gibi çeşitli yöntemler kullanılmıştır. Bu çalışmalardan bazıları yöneticilerin ve çalışanların yeni teknolojiye geçişe yönelik tutumlarını ele alırken, bazıları bu teknolojinin İKY fonksiyonları üzerindeki etkilerini incelemiş ve bazıları da bu teknolojinin getirdiği faydaları ve zorlukları ortaya koymuştur. Mevcut çalışmalardan farklı olarak, bu çalışmada İKY departmanlarında yapay zekâ teknolojisinin benimsenmesinde etkili olan faktörler Güç Alanı Analizi Modeli çerçevesinde sistematik literatür taraması yöntemiyle belirlenmiştir.

2. Yöntem

Bu çalışmada, yapay zekâyı dayalı İKY uygulamalarının benimsenmesinde etkili olan faktörlerin belirlenmesi amacıyla Güç Alanı Analizi Modeli kullanılmıştır. Güç Alanı Analizi, değişim süreçlerini anlamak için kullanılan kavramsal bir yaklaşımı temsil etmektedir. Araştırmada, bu analiz, İKY’de yapay zekâ uygulamalarının benimsenmesindeki itici ve kısıtlayıcı güçlerin belirlenmesinde bir kılavuz olarak kabul edilmektedir. Analiz, sistematik literatür taraması yoluyla ikincil verilerden yararlanılarak gerçekleştirilmiş olup, veriler içerik analizi yöntemi kullanılarak çözümlenmiştir.

2.1. Güç Alanı Analizi

İlk kez Lewin (1951) tarafından ortaya atılan Güç Alanı Analizi, bir problem çözme ve eylem planlama metodu olarak kullanılmaktadır. Bu analiz yönteminde “güç” bir kuruluşun durumunu değiştirecek şekilde hareket eden bir etkiyi ifade etmektedir. Bu güçlerin grafiksel tasviri ile bir güç alanı diyagramı çizilebilir. Bu diyagram, mevcut durumu açıklayan faktörleri (güçleri) göstermektedir (Schwering, 2003, s. 361). Kısaca değişimi anlama, planlama ve uygulama amacıyla yaygın olarak kullanılan bir araç olan Güç Alanı Analizi, örgütsel dinamikleri ele alırken özel bir yöne veya çözüme odaklanmak yerine, değişimi bütüncül bir bakış ile ifade etmeyi amaçlamaktadır (Swanson ve Creed, 2014, s. 32). Değişim sürecinde etkileşimli güç dinamiklerini vurgulamayı hedefleyen bu analitik yaklaşımın görsel temsili Şekil 1’de görüldüğü gibidir.



Kaynak: Thomas, 1985, s. 54

Buna göre, bir örgüt “a” konumundan “b” konumuna geçmek için bir değişiklik uygulama niyetindedir. Bu değişikliği etkileyen bir dizi güç mevcuttur. Bu güçler, “a”dan “b”ye doğru olan geçişi teşvik eden ve oklarla temsil edilen etmenlerdir. Aynı zamanda, “b”den “a”ya doğru hareketi sağlayan, oklarla temsil edilen ve değişime direnen güçler de mevcuttur. Her bir gücün göreceli etkisi, ilgili okun uzunluğu ile ifade edilmektedir. Bu güçlerin tanımlanması, yönetimin yeni stratejileri uygularken örgütün olası yönünü ve hareket hızını daha iyi değerlendirmesine yardımcı olmaktadır (Thomas, 1985, ss. 54-55). Söz konusu itici ve kısıtlayıcı güçlerin belirlenmesinde literatür taraması, yarı yapılandırılmış görüşme, araştırmacı deneyimi veya eleştirel düşünce gibi çeşitli yöntemlerden yararlanılabilir (Swanson ve Creed, 2014, s. 35).

Güç Alanı Analizi, planlama sürecinin birden çok aşamasında yinelemeli olarak kullanılabilir. Örneğin, bu analiz eylem planı geliştirmeden önce teknik bir sorunu veya stratejik yapıyı belirlemek için kullanılabilir. Bu durumda şu soruyu yanıtlamaya yardımcı olur: Mevcut durumumuzu açıklayan faktörler nelerdir? Bu aşamada analiz mevcut duruma yönelik ilk tepkileri belirlemek için kullanılır. Bu ilk teşhis ve eylem planlamasının ardından, plan uygulamasını yöneten yardımcı ve engelleyici güçleri keşfetmek için Güç Alanı Analizi yeniden başlatılabilir. Buradaki kilit soru şudur: Mevcut durumdan arzu edilen geleceğe geçişte hangi faktörlerin

etkisi olacaktır? (Schwering, 2003, s. 362). Dolayısıyla, Güç Alanı Analizi durumu bütünsel bir perspektifle ele alarak, değişim üzerinde etkili unsurları anlamada kullanılan bir tekniktir.

Literatürde Güç Alanı Analizi'nin örgütlerde teknolojik bir yeniliğe geçiş (Levi ve Lawn, 1993), çevresel stratejileri benimseme (Mak ve Chang, 2019) ve entelektüel sermaye yönetimi (Capatina vd., 2017) gibi birçok alanda kullanım örnekleri mevcuttur. Mevcut çalışmalardan farklı olarak, bu çalışmada Güç Alanı Analizi işletmelerin İKY departmanlarında yapay zekâ teknolojisinin benimsenmesini etkileyen itici ve kısıtlayıcı güçleri belirlemek için kullanılmaktadır.

2.2. Verilerin Toplanması ve Analizi

Bu çalışmada, yapay zekâyâ dayalı İKY uygulamalarının benimsenmesini etkileyen itici ve kısıtlayıcı güçleri belirlemek amacıyla sistematik bir literatür taraması yoluyla elde edilen veriler içerik analizi yöntemiyle incelenmiştir. Sistematik literatür taraması, nihai örneklemin seçilmesine yönelik sistemli ve objektif bir yaklaşım benimsemektedir. Bu süreç, iyi tanımlanmış bir yayın arama kriteri ile başlamakta ve ilgili tüm yayınların belirlenmesi için ilgi kontrolü aşamasından geçilmesiyle devam etmektedir (Hussain vd, 2023). Bu bağlamda, ilk adımda, belge araması için kullanılacak veri tabanı seçilmiş ve arama sorgusu özel olarak tasarlanmıştır. Sorgulanan veri tabanı Web of Science (WoS) olarak seçilmiş ve arama anahtar kelimeleri "Yapay Zekâ" ve "İnsan Kaynakları Yönetimi" olarak belirlenmiştir. Buna göre, 28 Kasım 2023 tarihinde WoS veri tabanında başlık alanında TITLE "human resource management" or "human resources management" or "HRM" and TITLE "artificial intelligence" or "AI" şeklinde bir arama sorgusu gerçekleştirilmiştir. Bu arama sorgusu ile WoS'tan 59 yayın elde edilmiştir. Yayın dili olarak İngilizce, yayın türü olarak makale seçildiğinde, toplam 36 yayına ulaşılmıştır. Ancak, bir makalenin tam metni görüntülenemediği ve bir diğeri geri çekildiği için, bu iki yayın çalışma kapsamının dışında tutulmuştur. Geriye kalan 34 yayının içeriği incelenerek, yapay zekâyâ dayalı İKY uygulamalarının benimsenmesini etkileyen itici ve kısıtlayıcı güçlere odaklanmayan çalışmalar (4 yayın) analiz dışında bırakılmıştır. Bu sayede, çalışmanın nihai örneklemini oluşturan 30 yayın belirlenmiştir. Verilerin analizinde, Microsoft Word ve Microsoft Excel programları birlikte kullanılarak, tüm işlem adımları bu programlar aracılığıyla gerçekleştirilmiştir. Analiz sürecinde izlenen adımlar, Tablo 1'de ayrıntılı bir şekilde sunulmuştur.

Tablo 1. İçerik Analizinde İzlenen Adımlar

No	Adım	Açıklama
1	Verilerin toplaması	İlgili literatürden yapay zekâyâ dayalı İKY uygulamalarının benimsenmesini etkileyen itici ve kısıtlayıcı güçlerle ilgili makalelerin toplanması.
2	Verilerin Excel'e aktarılması	Seçilen makalelerin yazarları, yayın tarihleri, başlıkları gibi ayrıntılı bilgilerinin Excel tablosuna aktarılması.
3	Excel belgesinin hazırlanması	Excel belgesinin analiz sürecini desteklemesi için uygun bir yapıya dönüştürülmesi. Her makalenin, itici ve kısıtlayıcı güçlere atıfta bulunduğu sütunların oluşturulması.
4	Kodlama yapılıma	Excel'deki her makalenin içeriğinin itici ve kısıtlayıcı güçlere göre sistematik bir biçimde kodlanması.
5	Kodlanmış verilerin sıralanması	Makalelerde belirtilen itici ve kısıtlayıcı güçlerin, sıklıklarının ve göreceli etkilerinin belirlenmesi
6	Sonuçların Word'e aktarılma	Kodlanmış verilerin göreceli etkileriyle birlikte Word belgesine aktarılması. Verilerin organize edilmesi ve sunulması için uygun bir yapı oluşturulması.
7	Metnin yapılandırılması	Metnin sistemli bir şekilde düzenlenmesi. İtici ve kısıtlayıcı güçler altında alt başlıklar oluşturulması ve bulguların bu alt başlıklar altında sunulması.

Kaynak: Ose (2016, s. 149)'den uyarlanmıştır.

Buna göre, seçilen makalelerden elde edilen veriler, Microsoft Excel elektronik tablosuna aktarılmıştır. Bu tablo, makalelerin yazarları, yayın yılları, başlıkları, yayınlandığı dergiler, kullanılan temel araştırma yöntemleri, araştırılan ülkeler ve sektörler ile incelenen İKY fonksiyonları gibi temel özellikleri içermiştir. Ardından, Excel belgesi, analiz sürecini desteklemek amacıyla uygun bir yapıya dönüştürülmüş, her makalenin itici ve kısıtlayıcı güçlere atıfta bulunduğu sütunlar oluşturulmuştur. Çalışmanın bir sonraki adımında, bu 30 yayının içeriği, içerik analizi yöntemiyle iki bağımsız araştırmacı tarafından değerlendirilmiştir. İçerik analizi, görsel ve sözel veriler gibi çeşitli veri türlerini ayrıntılı bir şekilde inceleyerek ve bu verileri belirli kategorilere dönüştürerek, daha etkili bir analiz ve yorumlama imkânı sağlamaktadır (Harwood ve Garry, 2003, s. 479). Bu bağlamda, her makalenin içeriği, Excel'de itici ve kısıtlayıcı güçlere göre kodlanmıştır. Makalelerde belirtilen güçlerin sıklıkları ve göreceli etkileri belirlenmiştir. Kodlanmış veriler, göreceli etkileriyle birlikte Word belgesine aktarılarak, verilerin organize edilmesi ve sunulması için uygun bir yapı oluşturulmuştur. Metin, itici ve kısıtlayıcı güçler altında başlıklarla sistemli bir şekilde düzenlenmiş ve bulgular bu başlıklar altında sunulmuştur.

3. Bulgular ve Tartışma

Bu çalışmada, örneklem kapsamında yer alan 30 yayının tanımlayıcı özellikleri analiz edilmiş ve yapay zekâyâ dayalı İKY uygulamalarının benimsenmesini etkileyen faktörler belirlenmiştir. Çalışmada, bu faktörler itici güçler ve kısıtlayıcı güçler olmak üzere iki ana kategoriye ayrılmıştır. Temel itici güçler, örgütsel hazırbulunuşluk ve algılanan faydalar unsurları içerirken; kısıtlayıcı güçler teknolojik değişime karşı olumsuz tepkiler, veri gizliliği ve güvenliğiyle ilgili endişeler, algoritmik önyargıdan kaynaklanan hatalar ve duygusal zeka eksikliği olarak tanımlanmıştır. Ayrıca, yapay zekâyâ dayalı İKY uygulamalarının benimsenmesini etkileyen faktörler Güç Alanı Analizi Modeli çerçevesinde görselleştirilmiş ve bu faktörlerin göreceli etkileri belirlenmiştir.

3.1. Yayınların Tanımlayıcı Özellikleri

Yayınların tanımlayıcı özellikleri yayın yılları, yayımlandığı dergiler, kullanılan temel araştırma yöntemleri, araştırılan ülkeler ve sektörler ile incelenen İKY fonksiyonlarına göre belirlenmiştir. İlk olarak, yayın yılına göre, 1996-2021 yılları arasında 8 makale, 2022-2023 yılları arasında 22 makale yayımlanmıştır. Bu veriler, yapay zekâya dayalı İKY araştırmalarında son yıllarda artan bir eğilimin olduğunu göstermektedir. İkincisi, incelenen makaleler, 26 farklı dergide yayımlanmıştır. Bu dergiler arasında en fazla yayın yapanlar, Human Resource Management Review (4 makale) ve International Journal of Manpower (2 makale)'dir. Applied Artificial Intelligence, Asia Pacific Journal of Human Resources, Employee Relations, Frontiers in Psychology, Journal of Management, Knowledge Management Research & Practice, Personnel Review, Public Personnel Management, Information Systems Frontiers ve Sustainability gibi dergiler de bu alana katkı sağlayan dergiler arasında yer almaktadır. Üçüncüsü, makalelerde en sık kullanılan araştırma yöntemleri anket yöntemi (8 makale), modelleme (4 makale) ve sistematik literatür taraması (4 makale) olarak belirlenmiştir. Diğer yöntemler arasında deneysel çalışma, kavram analizi, görüşme, vaka çalışması, bibliyometrik analiz ve anlatsal inceleme gibi yöntemler bulunmaktadır. Dördüncüsü, Almanya, İsviçre, Çin, Hindistan, Bangladeş, Malezya, Birleşik Arap Emirlikleri, Suudi Arabistan ve Kuzey Amerika gibi çeşitli ülkelerde gerçekleştirilen uygulamalı çalışmalarda; bilişim teknolojisi, enerji, sağlık, eğitim, gıda, bankacılık, sigortacılık, inşaat, elektronik, otomotiv ve turizm gibi çeşitli sektörler odaklanılmıştır. Bu çeşitlilik, konunun küresel ölçekte yaygın bir ilgi alanı olduğunu ve farklı sektörlerde yapay zekâya dayalı İKY uygulamalarının incelendiğini göstermektedir. Bu durum, çalışma sonuçlarının geniş bir kitleye uygulanabilirliğini ve etkisini artırabilir. Son olarak, makalelerin İKY fonksiyonlarına göre dağılımı incelendiğinde, işe alım fonksiyonunun (16 makale) en çok incelenen fonksiyon olduğu görülmektedir. Bunu sırasıyla eğitim ve geliştirme (12 makale), performans değerlendirme (9 makale), ücretlendirme ve ödül yönetimi (6 makale), kariyer yönetimi (3 makale) ve çalışan sağlığı ile refahı (1 makale) izlemektedir. Bu bulgular, makalelerin belirli İKY fonksiyonlarına odaklanma eğiliminde olduğunu göstermektedir.

3.2. İKY'de Yapay Zekânın Benimsenmesine Yönelik İtici Güçler

İşletmeleri İKY departmanlarında yapay zekâ teknolojisini kullanmaya yönelten bir dizi itici güç bulunmaktadır. Bu itici güçler örgütsel hazırbulunuşluk ve algılanan faydalar olmak üzere iki temel grupta sınıflandırılabilir.

3.2.1. Örgütsel Hazırbulunuşluk

Yapay zekânın benimsenmesi için temel koşullardan birinin örgütsel hazırbulunuşluk olduğunu vurgulanmaktadır (Agarwal, 2023, s. 75). Teknoloji benimseme sürecinde gerekli olan örgütsel kaynakların hazır olma ve mevcut durumu ifade eden örgütsel hazırbulunuşluk (Priksat vd., 2023, s. 8), yapay zekâya dayalı İKY uygulamalarının benimsenmesini etkileyen itici faktörlerden biridir. Bu kapsamda, finansal kaynakların yeterli olması, teknolojik altyapının gelişmiş olması, üst yönetimin destekleyici tutum sergilemesi ve çalışanların gerekli becerilere sahip olması gibi faktörler, yapay zekânın İKY'de benimsenmesini teşvik eden temel unsurlar arasında yer almaktadır.

Finansal kaynakların yeterli olması: Şirketlerin yapay zekâ teknolojisini benimsemesinde kritik öneme sahip olan finansal hazırbulunuşluk, örgütlerin yeni teknolojilere yatırım yapma konusundaki hazır olma durumunu ve yetkinliğini ifade etmektedir (Priksat vd., 2023, s. 8). Agarwal (2023, s. 72)'a göre, şirketlerin yapay zekâyı benimsemesi için yeterli finansal kaynaklara sahip olmaları gerekmektedir. Finansal kaynaklar, yapay zekâ projelerinin başarılı bir şekilde hayata geçirilmesi için kritik öneme sahiptir. Bu kaynaklar, projelerin deneme ve doğrulama süreçlerini finanse etmek, çalışanların becerilerini geliştirmek ve yapay zekâ çözümlerine ayrılan bütçeyi belirlemek gibi alanlarda kullanılmaktadır (Chowdhury vd., 2023, s. 10). Dolayısıyla, yapay zekâ projelerinin etkili bir şekilde yönetilmesi için sağlam bir mali altyapıya ihtiyaç vardır. Bu durum, şirketlerin yapay zekâ teknolojisini benimseme sürecinde finansal hazırbulunuşluğun stratejik bir faktör olduğunu ortaya koymaktadır.

Teknolojik altyapının gelişmiş olması: Bir örgütün mevcut teknolojik altyapısı, yapay zekâ teknolojisinin İKY alanına ne kadar etkili bir şekilde entegre edilebileceğini belirleyen kilit bir unsurdur (Priksat vd., 2023, s. 7). İKY'de yapay zekâ uygulamalarının benimsenmesi için, şirketin iş süreçlerini destekleyen güçlü bir teknoloji altyapısının olması gereklidir (Sithambaram ve Tajudeen, 2023, s. 827). Bu altyapı, veri depolama, veri yönetimi, veri temizleme ve birleştirme, işlem gücü, ağ bant genişliği, bulut tabanlı çözümler, algoritmalar ve yazılım programları gibi unsurları içermektedir (Chowdhury vd., 2023, s. 10). Dolayısıyla, kurumsal bir bilgi teknolojisi ortamında, altyapının, sistemin varlığı, işleyişi ve yönetimi için gerekli olan donanım, yazılım, ağ kaynakları ve hizmetlerden oluştuğu açıktır. Bu teknolojik altyapı, iş süreçlerini optimize etmek ve verimliliği artırmak için gerekli olan unsurları barındırmaktadır. Yapay zekâ uygulamaları daha bağlantılı, karmaşık ve dijital hale geldikçe, altyapı sistemleri, artan talebi karşılamak ve hizmetleri sürdürmek için daha önemli hale gelmektedir. Teknik ve altyapısal destek eksikliği, yapay zekâ teknolojisinin edinilmesi ve uygulanması sürecinde belirsizlikler yaratabilir. Yeterli altyapı ve hazırlık olmayan örgütlerde, yapay zekâ uygulamalarının başarısız olma ihtimalinin yüksek olduğu belirtilmektedir. Bu nedenle, altyapının, İKY'de yapay zekâ uygulamalarının benimsenmesi ve başarılı bir şekilde uygulanması üzerinde önemli bir etkisi olduğu söylenebilir (Islam vd., 2022, ss. 6, 16; Qahtani ve Alsmairat, 2023, s. 143). Ayrıca, güçlü bir teknolojik sistem ve bunu sürdürmek için finansal kaynaklara sahip

olan şirketlerin, veri altyapısını modernize edebilme ve yapay zekânın benimsenmesi ve kullanımı için daha yüksek bir özümseme kapasitesine sahip olabilecekleri ifade edilmektedir (Agarwal, 2023, s. 75). Bu bağlamda, özellikle gelişmiş ülkelerde politika yapıcıların, teknolojik altyapıyı geliştirme konusunda teşvik edici adımlar attıkları görülmektedir (Arslan vd., 2022, s. 83).

Üst yönetimin destekleyici tutum sergilemesi: Yapay zekâ uygulamalarına ilişkin alınan kararlar, yöneticilerin bu teknolojiye yönelik tutumlarıyla doğrudan ilişkilidir (Böhmer ve Schinnenburg, 2023, s. 1061). Bu nedenle, departmanların tüm seviyelerindeki yöneticiler, yapay zekâ destekli uygulamaların çalışanlar tarafından olumlu bir şekilde karşılanmasını teşvik etmek için iş birliği yapmalıdır (Xiao vd., 2023). Özellikle, üst düzey yöneticilerin yapay zekâyâ dayalı uygulamalara geçiş konusundaki istekliliği kritik öneme sahiptir (Agarwal, 2023, s. 72). Bu bağlamda, yapay zekâ destekli teknolojilerin kabul edilmesi, üst yönetimin desteğini ve liderliğini gerektirir (Islam vd., 2022, s. 16). Yapay zekâ yeteneklerinin geliştirilmesi için kullanılan kaynaklardan biri olan liderlik, kaynak tahsisi, sermaye fonları sağlama, çalışanların ihtiyaçlarını, iş hedeflerini ve öncelikleri anlama, stratejik yönelim, çalışanlar ve ekiplerle iyi çalışma ilişkileri geliştirme, açık iletişim mekanizmalarını takip etme gibi unsurları içermektedir (Chowdhury vd., 2023, s. 10). Bu çerçevede, İKY liderleri ve üst yönetim, yapay zekânın İKY sistemlerine entegrasyonunun sadece bir departmanla sınırlı olmadığını, tüm şirket için avantajlı olabileceğinin farkında olmalıdır (Agarwal, 2023, ss. 75-76). Bu nedenle, üst yönetimin, yeni teknolojiye geçiş sürecinde faydaları maksimize ederken, riskleri azaltmaya yönelik bir çaba sarf etmesi beklenmektedir (Prikshtat vd., 2022, s. 237). Yapay zekâ destekli makineler ve süreçler, kişisel bilgisayarlar veya eski bilişim teknolojilerine kıyasla çok daha karmaşıktır. Bu karmaşıklık nedeniyle, bazı çalışanların, robotlarla çalışırken endişe düzeyleri yüksektir. Bu durum, çalışanların yapay zekâ sistemlerini takım üyeleri olarak kabul etme ve iş hayatındaki bu yeni gerçeği benimseme konusundaki tutumlarını etkileyebilir. Bu endişeler, yöneticiler için stratejik bir zorluk oluşturabilir (Arslan vd., 2022, s. 84). Bu bağlamda, yöneticiler, bu teknolojilerle daha rahat çalışabilmeleri için çalışanlarına eğitim ve destek programları sunarak, yapay zekâ destekli sistemlerle iş gücünün etkileşimini artırabilir.

Çalışanların gerekli becerilere sahip olması: İş süreçlerinde yapay zekânın etkin kullanımı, çalışanların yeni beceriler öğrenmesini gerektirir (Chilunjika vd., 2022, s. 10; Konovalova vd., 2022, s. 88; Agarwal, 2023, s. 72; Chowdhury vd., 2023, s. 13). Özellikle, çalışanların bilişim teknolojileri becerileri, İKY’de yapay zekâ kullanımının başlatılması, benimsenmesi, rutin hale getirilmesi ve genişletilmesi süreçleriyle pozitif bir şekilde ilişkilendirilmiştir (Prikshtat vd., 2023, s. 9). Bu bağlamda, teknik beceriler istatistik, programlama, tasarım ve iş analitiği gibi alanlarda yapay zekâ çözümlerinin uygulanmasını desteklerken; iş becerileri yapay zekânın uygulanacağı alanları anlamayı, teknolojinin sınırlarını ve yeteneklerini değerlendirmeyi, iş süreçlerini modellemeyi ve yapay zekâ çözümlerini yönetip denetlemeyi içermektedir (Chowdhury vd., 2023, s. 10). Ayrıca, bu süreçlerde, çalışanların sosyal, yönetsel, teknolojik ve ahlaki becerilere sahip olması, başarılı örgütsel değişim için hayati bir önem taşımaktadır (Malik vd., 2023, s.12). Bu nedenle, çalışanların, yapay zekâ teknolojisinin kullanımını, avantajlarını ve beklenen sonuçlarını daha iyi kavraması için eğitim programları düzenlenmelidir (Qahtani ve Alsmairat, 2023, s. 143).

3.2.2. Algılanan Faydalar

Yapay zekâyâ dayalı İKY uygulamalarının benimsenmesini etkileyen bir diğer itici faktör algılanan faydalardır (Agarwal, 2023, s. 75). Belirli bir sistemi kullanmanın iş performansını artıracığına inanma derecesi olarak tanımlanan algılanan faydalar, yöneticilerin yapay zekâyı benimsemeleri için etkili faktörler arasında yer almaktadır. Yapay zekâ uygulamalarının faydalarına inanan ve yeterli becerilere sahip kullanıcıların yapay zekâyı işlerinde faydalı olarak algılamaları daha olasıdır (Qahtani ve Alsmairat, 2023, s. 143). Bu bağlamda, bu çalışmada, etkinliği ve verimliliği artırma, karar verme faaliyetlerini iyileştirme, yaratıcılığı ve yenilikçiliği teşvik etme ve çalışan adanmışlığını güçlendirme gibi faktörler, algılanan faydalar kapsamında yapay zekânın benimsenmesini teşvik eden temel faktörler olarak belirlenmiştir.

Etkinliği ve verimliliği artırma: İKY, çalışanları en üst düzeyde etkinlik ve verimliliğe teşvik etme konusunda kritik bir rol oynar. Günümüzde bu hedefe ulaşmak için uygun araçları sağlamak ve akıllı otomasyon teknolojilerini benimsemek kaçınılmazdır (Qahtani ve Alsmairat, 2023, s. 142). Bu bağlamda, yapay zekâ destekli İKY sistemlerine geçiş, maliyetleri azaltmak, etkinliği ve verimliliği artırmak için bir strateji olarak kabul edilmektedir (Agarwal, 2023, s. 72; Malik vd., 2023, s. 1; Prikshtat vd., 2023, s. 4; Weber, 2023, s. 1). İnsan kaynakları yöneticileri, yapay zekâ araçlarının insanlar gibi görevleri yerine getirmesine imkan tanıyabilir. Bu teknolojiler, yöneticilere üretken veri analizleri yapmalarında ve faaliyetlerini istedikleri sonuçlara yönlendirmelerine yardımcı olabilir (Qamar vd., 2021, s. 1362). Bu şekilde, işlemleri optimize etme, İKY’nin iş yükünü azaltma, çalışma verimliliğini artırma ve sistem performansını geliştirme amaçlanmaktadır (Song ve Wu, 2021, s. 1).

Özellikle işe alım sürecinde adayların yeterliliklerini değerlendirmek ve en uygun yetenekleri seçmek için yapay zekâ teknolojilerinden yararlanılmaktadır (Zhang ve Yuan, 2022, s. 1, 8; Islam vd., 2022, s. 1). Yapay zekâ örgütlerin daha geniş bir işe alım havuzuna erişmesini sağlayarak, işe alım ve seçimde verimliliği artırma potansiyeline sahiptir. Ayrıca, İKY’yi temel alan yapay zekâ araçları, adayları işe alım süresini, maliyetleri ve kaynak kullanımını azaltma açısından etkilidir. İşe alımda kullanılan metriklerin sayısı ve çeşitliliği yapay zekâ ile artırılabilir. Nitekim yapay zekâ, örgüte en iyi yetenekleri çekme ve onları elde tutma gibi İKY işlevlerini yerine getirmede önemli bir araç olarak ortaya çıkabilir (Kshetri, 2021, ss. 970, 985).

İşe alım sürecinde adayların sorularına hızlı yanıt verebilen dijital sanal asistanlar veya sohbet robotları, İKY'ye e-posta gönderme ihtiyacını ortadan kaldıracaktır. Bu dijital asistanlar, adayların özgeçmişlerini kullanarak işe uygunluklarını analiz edebilir ve bu şekilde yüksek kaliteli adayları belirleyip örgüte çekebilir. Otomatik olarak adayları ön değerlendirmeye tabi tutabilir ve etkili ve adil bir değerlendirme süreci yürüterek adaylarda güven oluşturabilir. Ayrıca, aday deneyimini geliştirmek amacıyla geri bildirim sağlayabilir. Aynı zamanda, bu asistanlar adaylara iş rollerini öğrenmelerinde yardımcı olabilir ve benzer iş rollerinde çalışanları örnek olarak gösterebilir (Chowdhury vd., 2023, s. 17).

Diğer taraftan, yapay zekâ bireysel performans yönetiminin yanı sıra eğitim ve kariyer geliştirme faaliyetlerine de katma değer sağlar (Agarwal, 2023, s. 76). Birçok şirket, çalışan performansını izleme sistemlerini kullanarak çalışma saatlerini kontrol etmek ve iş verimliliğini değerlendirmek amacıyla yapay zekâ teknolojilerinden yararlanmaktadır (Konovalova vd., 2022, s. 92). Ayrıca, yapay zekâ, çalışanların eğitim ihtiyaçlarını tespit etmeye yönelik içgörülerin belirlenmesine de olanak sağlar (Qahtani ve Alsmairat, 2023, s. 147). Bu da çalışanların geliştirilmesi, elde tutulması ve verimli bir şekilde kullanılması üzerinde potansiyel olarak olumlu bir etki yaratır (Kshetri, 2021, s. 970).

Karar verme faaliyetlerini iyileştirme: İKY alanındaki yapay zekâ uygulamaları, özellikle karar verme faaliyetlerini destekleyerek iş süreçlerine önemli katkılar sağlamaktadır (Qamar vd., 2021, s. 1351). İKY içindeki birçok görevin etkili ve hızlı bir şekilde tamamlanabilmesi için yaygın olarak kullanılan yapay zekâ teknolojisi (Aydın ve Turan, 2023, s. 1), yöneticilere etkili karar alma konusunda yardımcı olmaktadır (Sithambaram ve Tajudeen, 2023, ss. 839-840). Bununla birlikte, yapay zekâ büyük veri setlerini hızlı ve doğru bir şekilde işleyerek daha kaliteli karar sonuçları elde etmeyi mümkün kılar (Johnson vd., 2022, s. 541). Bu özellikler, yapay zekânın yönetsel karar süreçlerini kolaylaştırıcı ve kararların etkinliğini artırıcı bir rol oynadığını göstermektedir (Almarashda vd., 2021, s. 74; Lawler, 1996, s. 85).

Ayrıca, rutin idari görevlerin ve gereksiz evrak işlerinin azaltılmasının, yapay zekâ ile İKY entegrasyonundan kaynaklanan potansiyel avantajlar arasında olduğu belirlenmiştir (Chilunjika vd., 2022, s. 1; Johnson vd., 2022, s. 551). Özellikle uzman sistemler İKY yöneticilerine çalışan seçimi konusunda karar destek sistemleri olarak yardımcı olabilir (Qamar vd., 2021, s. 1362). Bu bağlamda, yapay zekâ, adayların özgeçmiş bilgilerini kullanarak kısa listeler oluşturmak için önemli bir fırsat sunmaktadır (Aydın ve Turan, 2023, s. 12). Yapay zekâya dayalı İKY araçları, bir yandan işe alım sürecinde tekrarlayan işleri daha hızlı gerçekleştirirken (Mohamad vd., 2022, s. 80), öte yandan işe alım maliyetlerini azaltma potansiyeli taşımaktadır (Kshetri, 2021, s. 985; Qahtani ve Alsmairat, 2023, s. 147).

Yaratıcılığı ve yenilikçiliği teşvik etme: Günümüz iş dünyasında, yaratıcılık ve yenilik, örgütlerin rekabet gücünü sürdürebilmeleri için temel faktörler arasında yer almaktadır (Baldegger vd., 2020, s. 72). Bu bağlamda, hızla değişen yenilik trendleri karşısında rekabet avantajı elde etmek, yapay zekâ teknolojisinin İKY süreçlerinde benimsenmesini zorunlu kılmaktadır (Qahtani ve Alsmairat, 2023, s. 142). Yapay zekâ, yaratıcılığı ve yenilikçiliği destekleyerek iş kalitesini artırır ve etkili iş yeniliklerine olanak tanır (Chowdhury vd., 2023, s. 10; Almarashda vd., 2021, s. 74; Palos-Sanchez vd., 2022, ss. 3647-3648).

Ayrıca, yapay zekâ çalışanların bireysel beceri setleri, ilgi alanları ve öğrenme tarzlarına odaklanarak, kişiselleştirilmiş eğitim ve gelişim programları oluşturabilir (Konovalova vd., 2022, s. 88). Bu, çalışanların kişisel ve profesyonel gelişimini destekler ve örgüt içinde yeni fikirlerin ve yeteneklerin ortaya çıkmasına katkı sağlar. Yapay zekâ kullanımının yaygınlaşması, çalışanların ve yöneticilerin daha düşük İKY maliyetleriyle yenilikçiliğe odaklanmalarına olanak tanır. Bu yaklaşım, aynı zamanda her bir çalışanın özel ihtiyaçlarına daha iyi yanıt verme ve örgüt içinde yenilik yapma yeteneğini artırma potansiyeline sahiptir (Malik vd., 2023, s. 6). Nitekim yapay zekâ uygulamalarıyla yenilikçiliği destekleyen bir örgüt yapısının ortaya çıkması kaçınılmazdır (Palos-Sanchez vd., 2022, s. 3647).

Ek olarak, büyük veri analitiği yetenekleri ile İKY verilerini derinlemesine analiz edebilen yapay zekâ araçları, işgücü eğilimlerini ve ihtiyaçlarını belirlemede önemli bir bilgi kaynağıdır (Böhmer ve Schinnenburg, 2023, s. 1079). Bu sayede, örgüt gelecekteki beceri taleplerini önceden tahmin ederek, yenilikçi stratejiler belirleme ve çalışanların gelecekteki iş gereksinimlerine uyum sağlama kapasitesini güçlendirme imkanına sahip olabilir. Yapay zekâ tarafından sağlanan bu önemli içgörüler, örgütün sürdürülebilir başarıya ulaşmasında kritik bir rol oynayabilir. Yenilikçi stratejilerle desteklenen çalışanlar, değişen iş dünyasında rekabet avantajı sağlayarak örgütün rekabet gücünü artırabilirler.

Çalışan adanmışlığını güçlendirme: Yapay zekâ, çalışanlara kişiselleştirilmiş bir deneyim sunarak günlük ihtiyaçlarını, rutin görevlerini ve programlarını etkili bir şekilde yönetme fırsatı sağlar. Otomatik takvim yönetimi, toplantı planlaması, sorulara etkili cevaplar verme, zamanında öneriler ve uyarılar sunma gibi işlevler, yapay zekâ tarafından kolaylıkla gerçekleştirilir. Bu süreç, ekip içindeki adanmışlığı artırmayı ve benzer profillere sahip çalışanlar arasında etkili bir işbirliği sağlamayı amaçlar. Ayrıca, yapay zekâ kariyer gelişimini desteklemek amacıyla mentor atanması gibi uygulamaları da içerir (Chowdhury vd., 2023, s. 17). Bu sayede kişiselleştirilmiş kariyer danışmanlığına daha fazla entegre olur (Bankins, 2021, s. 841) ve çalışanların bireysel ihtiyaçlarına odaklanarak daha etkili bir rehberlik sağlar.

Yapay zekânın İKY üzerindeki etkilerinden biri, çalışan deneyimini anlama, duygusal durumları analiz etme ve refahlarını yönetme becerisidir (Konovalova vd., 2022, s. 88). Yapay zekâ, çalışanların geri bildirimlerini alarak ve adanmışlık platformlarını yönetme olanağı sunarak, çalışanların işleriyle duygusal olarak daha bağlantılı hissetmelerine katkıda bulunur (Malik vd., 2023, s. 10). İşletmeler, yapay zekâyâ dayalı İKY sistemleri aracılığıyla çalışanların durumunu anlık olarak değerlendirip, elde edilen bilgileri kullanarak işletme politikalarını hızlıca düzenleyebilir. Bu yaklaşım, iş gücünün sürekli olarak güçlendirilmesine ve bu sayede şirketin gelişim hedeflerine daha etkin bir şekilde ilerlemesine olanak tanır (Yang, 2022, s. 11). Bu süreçte, yapay zekâ çalışanların ihtiyaçlarına daha duyarlı ve hızlı bir şekilde yanıt verme yeteneği sayesinde, örgüt kültürü üzerinde olumlu bir etki bırakarak İKY süreçlerini daha etkin hale getirebilir.

Çalışan adanmışlığını artırmada etkili bir rol oynayan yapay zekâ, aynı zamanda personel devir hızını azaltmaya da katkı sağlayabilir (Mohamad vd., 2022, s. 80). Personel devir hızını öngörmede yardımcı olan yapay zekâ kullanımının, bu durumdan kaynaklanan üretkenlik azalışının da önüne geçtiği gözlemlenmektedir (Palos-Sanchez vd., 2022, ss. 3647-3648). Bu şekilde, yapay zekâ, işletmelerin İKY süreçlerini daha öngörülebilir ve verimli bir şekilde yönetmelerine katkıda bulunarak, iş gücü istikrarını artırabilir ve şirketin uzun vadeli başarılarına katkı sağlayabilir.

3.3. İKY'de Yapay Zekânın Benimsenmesine Yönelik Kısıtlayıcı Güçler

İKY alanında yapay zekânın benimsenmesini etkileyen bir dizi itici güç bulunmasına rağmen, uygulayıcılar potansiyel sorunları ifade eden kısıtlayıcı güçler konusunda da bilinçli olmalıdır. Bu kısıtlayıcı güçler, dört temel grupta sınıflandırılabilir.

Teknolojik değişime karşı olumsuz tepkiler: Hem İKY çalışanları hem de yöneticileri arasında gözlemlenen yapay zekâ uygulamalarına dair endişeler, yapay zekânın İKY alanında kullanım sürecini yavaşlatabilir (Palos-Sanchez vd., 2022, s. 3649). Çalışanların yapay zekâ destekli İKY'ye yönelik çeşitli bakış açıları sergileme eğiliminde oldukları ve bu bakış açılarının İKY'nin etkinliği üzerinde etkili olduğu belirtilmektedir (Xiao vd., 2023). İKY alanındaki yapay zekâ konusu henüz çok yeni olduğundan, bu teknolojiye yönelik çekinceler taşıyan çalışanların varlığı söz konusudur (Baldegger vd., 2020, s. 77). Bu bağlamda, İKY görevleri için veri bilimi tekniklerinin uygulanmasıyla ilgili karşılaşılan zorluklardan biri, çalışanların algoritmalar tarafından alınan kararlara karşı olumsuz tepkiler göstermeleridir (Tambe vd., 2019, s. 15). Hem İKY çalışanları hem de yöneticileri arasında gözlemlenen yapay zekâ uygulamalarına dair endişeler, yapay zekânın İKY alanında kullanım sürecini yavaşlatabilir (Palos-Sanchez vd., 2022, s. 3649).

Yapay zekâyâ dayalı uygulamaların iş hayatına entegrasyonu, çalışanlarda teknolojik kaygı seviyelerini artırabilir. Geleneksel teknolojilere kıyasla daha karmaşık olan yapay zekâ araçları, kullanıcıları yeni ve belirsiz faktörlerle karşı karşıya bırakarak, teknoloji kullanımına dair olumsuz duyguları tetikleyebilir. Bu durum, teknolojiye uyum sürecinde yaşanan hayal kırıklığı ve endişe düzeyinin artmasına neden olabilir (Konovalova vd., 2022, s. 92-93). Özellikle teknolojik gelişmelerin gerisinde kalma ve iş kaybı endişesi, yapay zekânın yaygın olarak benimsenmesini engelleyen önemli faktörlerden biridir (Arslan vd., 2022, s. 75; Chilunjika vd., 2022, ss. 7-8; Johnson vd., 2022, s. 549). Bu korku, çalışanların teknolojinin sunduğu potansiyeli tam anlamıyla keşfetmelerini zorlaştırırken, yapay zekânın iş süreçlerine entegrasyonunu dirençle karşılamalarına da neden olabilir. Bu açıdan, yapay zekâ teknolojisine bir takım üyesi olarak duyulan güven düzeyi, değişimi kabul etme sürecini etkileyecektir (Konovalova vd., 2022, s. 93).

Çalışanların yapay zekâ destekli İKY uygulamalarına dair ortak bir algı geliştirmeleri koşuluyla, bu uygulamaların çalışanlara fayda sağlayabileceği belirtilmektedir (Xiao vd., 2023). Ancak, bu olumlu algının oluşabilmesi için yöneticilerin, çalışanlarına yapay zekânın getirdiği avantajları ve iş süreçleri üzerine etkilerini anlatan doğru bilgi aktarımını sağlamaları gerekmektedir (Baldegger vd., 2020, s. 77). Çalışanların yapay zekâ ile ilgili bilince sahip olmalarını teşvik etmek ve bu teknolojiyi bir fırsat olarak görmelerini sağlamak, örgüt içinde daha olumlu bir kabulü destekleyebilir.

Veri gizliliği ve güvenliğiyle ilgili endişeler: Yapay zekâ araçları genellikle e-posta iletileri, sosyal medya içerikleri ve kurum içi sohbetler gibi çeşitli uygulamalardan veriler toplamaktadır (Johnson vd., 2022, s. 554). Ancak, bilişim teknolojilerinin yanlış kullanımı ve verilerin istenmeyen alıcılara paylaşımı durumunda, kişisel bilgilerin kötüye kullanılması ve web sitelerine sızması, çalışanların refahını olumsuz etkileyebilir (Arslan vd., 2022, s. 78). Başka bir deyişle, insan davranışının dijital izlerinden çıkarım yapmaya yönelik çabalar, gizlilik ve etik konularında ciddi sorunlara neden olabilir. Bu endişeler, çalışanların gizliliklerinin ihlal edildiğini düşündüklerinde olumsuz etkiler yaratabilir (Tambe, 2019, ss. 26, 35). Veri gizliliği ve güvenliği konuları, yapay zekânın özellikleri nedeniyle ortaya çıkan etik sorunlar arasında önemli bir yer tutmaktadır (Qamar vd., 2021, s. 1362; Prikshat vd., 2022, s. 231; Malik vd., 2023, ss. 6-7). Yapay zekânın İKY alanında kullanılması, kötüye kullanım vakaları, siber saldırılar ve gizlilik kayıpları gibi potansiyel tehditleri içermektedir (Konovalova vd., 2022, s. 93). İKY departmanı kimlik numaraları ve banka hesap numaraları gibi çalışanların kişisel bilgilerini içerdiği için siber saldırılara karşı daha savunmasızdır. Uygun güvenlik önlemleri alınmazsa, bu durum siber saldırılara maruz kalma ve Kişisel Verilerin Korunması Kanunu'yla ilgili hükümlerin ihlali gibi olumsuz sonuçlara yol açabilir (Sithambaram ve Tajudeen, 2023, s. 834).

Bu endişeler, İKY'de yapay zekâyı benimsemek ve uygulamak için yasal ve sosyal açıdan sorumlu yaklaşımları gündeme
 Kişi ve Özer (2024).

getirmektedir (Malik vd., 2023, ss. 6-7). Bu bağlamda, yapay zekâ tarafından alınan kararlarda teknolojinin etik ve insan odaklı bir biçimde kullanılmasını sağlamak son derece önemlidir (Bankins, 2021, s. 873). İKY’de yapay zekâ kullanımı için paydaşlarla etkileşimde bulunarak güçlü etik ilkeler geliştirmek, sürdürülebilir bir yapay zekâ uygulamasının anahtarıdır (Priksat vd., 2022, s. 241). Ayrıca, bu sorunları etkili bir şekilde çözmek için yöneticiler, İKY görevleri için kişisel verileri toplarken gizlilik endişelerinin bilincinde olmalı ve veri gizliliği ilkelerine tam uyum sağlamalıdır (Bankins, 2021, s. 845; Priksat vd., 2022, s. 228). Buna ek olarak, yöneticiler çalışanları eğitmek ve farkındalık yaratmak için gerekli adımları atmalıdır (Qamar vd., 2021, s. 1362). Eğitim ve etkili İKY uygulamaları, yeni teknolojilere olan güveni destekleyebilir ve bu teknolojilerin iş ortamında etkili bir şekilde kullanılmasına olanak tanıyabilir (Arslan vd., 2022, s. 77).

Algoritmik önyargıdan kaynaklanan hatalar: Yapay zekâ sistemlerinin kararlarını şekillendiren algoritmalar, bir dizi kural veya prosedürü kullanarak, verilere dayalı tahminler ve çıkarımlar yapar (Bankins vd., 2022, s. 861). Bu teknoloji, hassas ve güvenilir bilgi üretimini sağlayan algoritmaların kullanımına dayanmaktadır. (Böhmer ve Schinnenburg, 2023: 1059; Agarwal, 2023, s. 70). Ancak, yapay zekâ algoritmaları evrimleşip geliştikçe, beraberinde artan riskler de ortaya çıkar (Rodgers vd., 2023, s. 16). Yapay zekâ çözümlerinin İKY’de benimsenmesi sürecinde karşılaşılan önemli bir sorun, tahmin modellerini eğitmek için gerekli İKY verilerinin miktarı ve kalitesiyle ilgilidir. Başarılı bir şekilde geliştirilmiş çözümler, tahmin yeteneklerini artırmak için doğru İKY verileri kullanmaktadır (Malik vd., 2023, s. 9). Çünkü yapay zekâ verilerden beslendiği ölçüde başarılı olabilir. Verilerin eksikliği durumunda, yapay zekâ sisteminin önyargılı bir seçim yapma olasılığı bulunmaktadır (Aydın ve Turan, 2023, s. 2). Önyargılı veri setlerinin kullanımı, geçmişteki önyargı kalıplarını devam ettirebilecek sonuçlara yol açabilir (Bankins, 2021, s. 845). Örneğin, işe alım sürecinde uzman sistem, önyargılara maruz kalarak, belirli bir cinsiyete, belirli becerilere, geçmişlere, etnik gruplara vb. öncelik tanınmasına neden olabilir. Ayrıca, İKY faaliyetleri arasında adayları eleme ve performansları değerlendirme gibi süreçler de önyargılara açık hale gelebilir (Qamar vd., 2021, ss. 1354-1355). Dolayısıyla, yapay zekâ ile ilişkilendirilen araçlar ve prosedürler, önyargı ve ayrımcılık endişelerini ortaya çıkarabilir (Johnson vd., 2022, s. 539; Bankins vd., 2022, s. 867; Konovalova vd., 2022, s. 91).

Yapay zekâ kararlarında oluşabilecek önyargıları ele almak için sisteme veri aktarımına büyük bir titizlikle yaklaşmak gereklidir. Yöneticiler, kararlarının potansiyel sonuçlarını göz önünde bulundurarak, bu kararları etik bir bakış açısıyla değerlendirmelidir (Qamar vd., 2021, ss. 1354-1355). Karar alma süreçlerinde şeffaflık, açıklanabilirlik ve önyargıları ortadan kaldırma gibi etik, hukuki ve ahlaki konular ön planda tutulmalıdır (Malik vd., 2023, s. 9). Makine öğrenmesi algoritmalarının büyük ve çeşitli veri setleri ile eğitilmesi gerekmektedir. Büyük miktarda veri, algoritmaların daha fazla öğrenmesine ve yapay zekâ kararlarını daha akılcı hale getirmesine olanak tanır (Kshetri, 2021, s. 984). Yeni algoritmik yaklaşımların benimsenmesiyle, yapay zekâ sistemlerindeki önyargılarla ilişkilendirilen riskler önemli ölçüde azaltılabilir (Rodgers vd., 2023, s. 16). Bu şekilde, yapay zekâ kullanımı etik standartlara uygun, adil ve şeffaf bir şekilde gerçekleştirilebilir.

Duygusal zeka eksikliği: İKY performans değerlendirmeleri, iş-yaşam dengesi, sağlık ve genel iyi olma gibi hassas konuları ele aldığı için duygusal zeka gerektiren görevleri barındırır. Bu tür konular bazen insanlar arası etkileşimi gerektirirken, bazıları özel insan becerilerini gerektirdiği için, insan kaynakları yöneticileri ve çalışanları arasında insan dokunuşuna olan ihtiyaç önemli hale gelmektedir (Bankins, 2021, s. 847). Yapay zekâ teknolojisinin büyük veri işleme kapasitesi sayesinde tekrarlayan görevleri insanlardan daha etkin bir şekilde yerine getirebilmesi avantaj sağlasa da, bu sistemler duyguları, hisleri, istekleri ve ihtiyaçları değerlendirmede insanlar kadar yetkin değildir (Kshetri, 2021, s. 982). Yapay zekânın hızlı ve sürekli çalışma, zaman ve görev optimizasyonu avantajlarına rağmen, temel yumuşak becerilere sahip olmaması, özellikle iş ortamındaki duygusal zeka gerektiren konularda kısıtlamalara yol açar (Palos-Sanchez vd., 2022, s. 3649). Bu durum, insanların algoritmalara aşırı güvenmeye başlamasıyla eleştirel düşünme, duygusal zeka ve sezgi gibi insan düşünme süreçlerinin göz ardı edilebileceği bir noktaya kadar gidebilir (Johnson vd., 2022, s. 552), bilgisayar tabanlı sistemlerin karar alma süreçlerine kör bir güven oluşturabilir ve insanların kendi içgüdüsel düşünme yeteneklerini ihmal etmelerine neden olabilir.

Yapay zekânın özellikle sosyal etkileşim ve yöneticilerin ve çalışanların duygusal zekası gibi modern yönetimin benzersiz insan öğelerine temel bir tehdit oluşturma olasılığı düşük görünmektedir (Konovalova vd., 2022, s. 93). Hızlı veri analizi ve rutin görevlerdeki başarısıyla yapay zekâ iş süreçlerini geliştirebilir, ancak karmaşık duygusal durumları anlama, empati kurma ve sosyal ilişkileri yönetme gibi alanlarda insan katkısı oldukça önemlidir (Arslan vd., 2022, s. 78). Gelecekte bu tür insana özgü yeteneklerin daha da önemli hale geleceği vurgulanmaktadır (Mohamad vd., 2022, s. 83).


3.4. İKY’de Yapay Zekânın Benimsenmesi ve Güç Alanı Analizi

Genel olarak, örgütlerin yapay zekâyı iş süreçlerine entegre etmeye başlaması, bu teknolojinin İKY fonksiyonunda da benimsenmesini tetikleyebilir. Yapay zekâ uygulamaları daha verimli, hızlı ve etkili çözümler sunarak, İKY süreçlerinde dönüşümü beraberinde getirir. Örneğin, yapay zekâ destekli işe alım sistemleri, adayları daha objektif bir şekilde değerlendirebilir ve işe alım sürecini hızlandırabilir. Ayrıca, yapay zekâ destekli eğitim ve geliştirme programları, çalışanların becerilerini daha iyi anlamak ve bireysel eğitim ihtiyaçlarını belirlemek için kullanılarak, iş gücünün daha yetkin hale gelmesine katkı sağlayabilir. Bununla birlikte,

yapay zekâ destekli performans değerlendirme sistemleri, veri odaklı geribildirimlerle çalışanların performansını iyileştirebilir. Dolayısıyla, yapay zekâ uygulamalarının İKY fonksiyonunda benimsenmesi, çalışan performansını, memnuniyetini ve deneyimini artırmanın yanı sıra, örgütlerin başarısını ve rekabetçiliğini de geliştirebilir.

Yapay zekâ teknolojisinin hızla büyümesiyle birlikte, yakın gelecekte modern işletmelerde bu teknolojinin yaygın olarak benimsenmesi ve geleneksel İKY süreçlerinin geride kalmış olarak değerlendirilmesi öngörülmektedir (Ahmed, 2018, s. 978). Bu bağlamda, İKY’de yapay zekânın benimsenmesini etkileyen itici ve kısıtlayıcı faktörlerin belirlenmesi, araştırmacılar ve uygulayıcılar için önemli çıkarımlar sağlayacaktır. Bu tür analizler, işletmelerin yapay zekâ entegrasyonu için daha etkili stratejiler geliştirmelerine yardımcı olabilir. Çalışma kapsamında 3.2 ve 3.3 başlıkları altında ayrıntılı olarak ele alınan temel bulguların görsel temsili Şekil 2’de görüldüğü gibidir.

Şekil 2. İKY’de Yapay Zekânın Benimsenmesinin İtici ve Kısıtlayıcı Güçleri



Kaynak: Yazarlar tarafından oluşturulmuştur.

Yapay zekânın benimsenmesinde önemli olan itici güçlerden biri, örgütsel hazırbulunuşluktur. Örgütsel hazırbulunuşluk, finansal kaynaklar, teknolojik altyapı, üst yönetimin istekliliği ve çalışanların beceri düzeyi gibi faktörlerin bir araya gelmesiyle oluşur (Agarwal, 2023, s. 72). Bir şirketin bu alandaki hazır olma durumunu doğru bir şekilde değerlendirmesi, yapay zekânın başarılı bir şekilde benimsenme olasılığını artırır ve yapay zekânın iş değerinden tam olarak yararlanmak için kritik önem taşır. Bu nedenle, şirketler varlıkları, yetenekleri ve taahhütleri doğrultusunda yapay zekâ teknolojisini benimseme hedefine ne kadar hazır olduklarını dikkatlice gözden geçirmelidirler (Jöhnik vd., 2021, s. 5). Bunun yanı sıra, algılanan faydalar da, İKY’de yapay zekâ teknolojisini benimsemesi üzerinde olumlu bir etkiye sahiptir. Bu faktör, yapay zekânın sağlayacağı faydaların, teknolojiyi kabul etme ve kullanma olasılığının arttığını göstermektedir (Goswami vd., 2023, s. 10). Yapay zekâ teknolojisi, İKY’de işe alım, eğitim, performans değerlendirmesi ve kariyer yönetimi gibi birçok fonksiyon üzerinde önemli etkiler yaratmaktadır. Bu bağlamda, yapay zekâ ve ilgili otomasyon teknolojileri en yetenekli çalışanları işletmeye çekmeye, onlara hızlı ve etkili eğitim ve gelişim fırsatları sunmaya, büyük miktarda çalışan verisini işlemeye ve daha iyi iş kararları almaya yardımcı olmaktadır. İKY fonksiyonlarında teknolojinin sağladığı bu destekleyici rol, artan çalışan katılımı, iş tatmini, çalışan bağlılığı, çalışan adanmışlığı ve iş performansı gibi olumlu sonuçları beraberinde getirmektedir. Bu durum, işletmelerin performanslarını, etkinliklerini, verimliliklerini, müşteri memnuniyetini ve hizmet kalitesini iyileştirme potansiyeli kazanmasına olanak tanır. (Budhwar vd., 2022, ss. 1077, 1087).

Yapay zekâyâ dayalı İKY uygulamaları, yöneticilere bir dizi kritik iş zorluğunu daha etkili bir şekilde çözme imkanı sunmaktadır. Bu uygulamalar, rutin İKY görevlerini otomatikleştirme, kişiselleştirilmiş eğitim modülleri oluşturma ve iş süreçlerini daha verimli hale getirme gibi avantajlar sağlar (Saxena, 2020, s. 152). İKY ekipleri, rutin görevlerin otomatik hale gelmesiyle daha az operasyonel görev üstlendiğinden, yaratıcı ve stratejik görevlere daha fazla odaklanabilir. Mentorluk, geri bildirimler sunma, çalışanları motive etme ve güçlü örgütsel ilişkiler kurma gibi faaliyetlere daha fazla zaman ayırarak, şirketin genel başarısını olumlu bir etkiler (Ahmed, 2018, s. 973). Aynı zamanda, bu uygulamalar İKY işlevlerine harcanan zamanı azaltarak karar verme sürecini hızlandırır ve İKY tarafından alınan kararların tarafsızlık, nesnellik ve şeffaflığına katkıda bulunur. İnsan faktöründen kaynaklanan hataları en aza indirgeyerek, önyargı, dikkatsizlik, bilgisizlik gibi sorunları ortadan kaldırır. Ayrıca, bazı İKY işlevlerinin uygulanmasındaki maliyetleri düşürerek, işletmelere ekonomik fayda sağlar (Tymbaliuk vd., 2022, s. 154). Böylece, yapay zekâ, daha doğru, verimli, şeffaf, kaliteli ve maliyet etkin İKY uygulamalarının geliştirilmesine katkı sağlar (Mathew vd., 2021, s. 216).

Bu itici güçlerin yanı sıra İKY’de yapay zekâ teknolojisini benimsenmesinde gerek insan gerekse teknoloji kaynaklı birtakım kısıtlayıcı güçler bulunmaktadır. Bu güçlerden ilki, değişime direnç ile ilgilidir. İşsizlik kaygısı, yeni teknolojiyi öğrenememe korkusu ve algoritmalara güvenmeme gibi nedenlerle çalışanlar teknolojik değişime karşı dirençler de (Mittal ve Gujral, 2020, s. 2792;

Eubanks, 2022, s. 206); eğitim faaliyetleri, etkin liderlik yaklaşımları ve destekleyici örgüt kültürü uygulamaları ile bu direncin üstesinden gelinebilir (Budhwar vd., 2022, s. 1087). İkincisi, veri gizliliği ve güvenliğiyle ilgili endişelerdir. Çalışan verilerinin korunması ve kullanılmasında yasal çerçeve göz önünde bulundurulmalı ve yetkisiz erişimi engelleyici tedbirler alınmalıdır (Saxena, 2020, s. 157). Üçüncüsü, algoritmik önyargıdan kaynaklanan hatalardır. Programlama aşamasında doğru ve yeterli veri setinin kullanılması yoluyla önyargıları azaltmak veya yok etmek mümkündür (Parikh, 2021). Dördüncüsü, duygusal zeka eksikliğidir. Etik, yasal ve toplumsal boyutları dikkate alarak duygusal yapay zekâ uygulamalarından yararlanılabilir ve yapay zekânın insanlarla etkileşimleri iyileştirilebilir (Schuller ve Schuller, 2018, ss. 41, 45). Bu kısıtlayıcı güçlerin etkili bir şekilde yönetilmesi, yapay zekânın İKY alanındaki benimsenmesini kolaylaştırabilir.

Bu çalışmada, İKY’de yapay zekânın benimsenmesini değerlendirmek için kullanılan Güç Alanı Analizi Modeli, uygulayıcıların hem itici güçlerden etkin bir şekilde yararlanmalarına hem de kısıtlayıcı güçleri azaltmalarına ve ortadan kaldırmalarına yardımcı olacak önemli bilgiler sunmayı amaçlamaktadır. Bu yaklaşımın bir sonucu olarak, güçlendirilmiş yapay zekâ uygulamalarının ortaya çıkması ve mevcut denge durumundan istenen duruma doğru bir ilerleme beklenmektedir. Ancak, teknolojik yeniliklerin benimsenmesini etkileyen güçlerin öncelik ve etki dereceleri kültürel, coğrafi, sektörel ve personel özelliklerine bağlı olarak değişebilir. Bu nedenle, yöneticilerin kendi örgüt yapılarına uygun analizler gerçekleştirmeleri ve güç unsurlarını düşük, orta ve yüksek düzeylerde derecelendirmeleri önemlidir. Bu yaklaşım, daha esnek ve özelleştirilmiş stratejiler oluşturmak için bir çerçeve sağlar. İKY’de yapay zekâ teknolojisinin benimsenmesi sürecinde başarı, bu tür analizlerin dikkatlice yapılması ve elde edilen sonuçların doğru bir şekilde değerlendirilmesi ile mümkün olacaktır.

Bununla birlikte, Tablo 2’de sunulan çalışma bazındaki analizler, İKY’de yapay zekâya dayalı uygulamaların benimsenmesinde en yaygın görülen itici ve kısıtlayıcı faktörleri belirleyerek, genel bir değerlendirme yapmaya imkan sağlamaktadır. Bulgulara göre, çalışmaların %40’ında etkinlik ve verimliliği artırma, %33’ünde karar verme faaliyetlerini iyileştirme ve %27’sinde yaratıcılığı ve yenilikçiliği teşvik etme İKY’de yapay zekâya dayalı uygulamaların benimsenmesini destekleyen itici güçler olarak öne çıkmaktadır. Ayrıca, çalışmaların %33’ünde algoritmik önyargı kaynaklı hatalar, %30’unda veri gizliliği ve güvenliği endişeleri ve %27’sinde teknolojik değişime olumsuz tepkiler İKY’de yapay zekânın benimsenmesinde karşılaşılan başlıca kısıtlayıcı güçler olarak tanımlanmıştır. Bu bulgular, çalışmanın örneklemini temel alarak, yapay zekâya dayalı İKY uygulamalarının benimsenmesini etkileyen faktörlerin göreceli önemini anlamaya katkı sağlayabilir.

Tablo 2. İtici ve Kısıtlayıcı Güçlerin Çalışmalara Göre Dağılımı

Yazar(lar) (Yıl)	İG1	İG2	İG3	İG4	İG5	İG6	İG7	İG8	KG1	KG2	KG3	KG4
Agarwal (2023)	x	x	x	x	x						x	
Almarashda vd. (2021)						x	x					
Arslan vd. (2022)		x	x						x	x		x
Aydın ve Turan (2023)						x					x	
Baldegger vd. (2020)							x		x			
Bankins (2021)								x		x	x	x
Bankins vd. (2022)											x	
Böhmer ve Schinnenburg (2023)			x				x				x	
Chilunjika vd. (2022)				x		x			x			
Chowdhury vd. (2023)	x	x	x	x	x		x	x				
Islam vd. (2022)		x	x		x							
Johnson vd. (2022)						x			x	x	x	x
Konovalova vd. (2022)				x	x		x	x	x	x		x
Kshetri (2021)					x	x					x	x
Lawler ve Elliot (1996)						x						
Malik vd. (2023)				x	x		x	x		x	x	
Mohamad vd. (2022)						x		x				x
Palos-Sanchez vd. (2022)							x	x	x			x
Prikshat vd. (2022)	x		x							x		
Prikshat vd. (2023)		x		x	x							
Qahtani ve Alsmairat (2023)		x		x	x	x	x					
Qamar vd. (2021)					x	x				x	x	
Rodgers vd. (2023)											x	
Sithambaram ve Tajudeen (2023)		x				x				x		
Song ve Wu (2021)					x							
Tambe vd. (2019)									x	x		
Weber (2023)					x							
Xiao vd. (2023)			x						x			
Yang, Y. (2022)								x				
Zhang ve Yuan (2022)					x							

İG: itici güç. KG: kısıtlayıcı güç.

Sonuç

Bilgi ve iletişim çağının getirdiği teknolojik gelişmeler, modern işletmelerin varlıklarını sürdürebilmeleri için temel fonksiyonlarını yeniden düşünmelerini zorunlu kılmaktadır. Yapay zekâ, son zamanlarda birçok alanda yaygın bir şekilde kullanılarak bilim ve teknoloji alanında devrim niteliğinde değişikliklere neden olmuştur. Bu teknolojinin işletmelerde kullanılması, üretim, pazarlama, finans, tedarik zinciri ve İKY gibi çeşitli işlevler üzerinde belirgin etkiler yaratmıştır. Bu bağlamda, yeni teknolojiye uyum sürecinin etkin bir şekilde yönetilmesi kritik bir öneme sahiptir. Bu çalışmada, yapay zekâya dayalı İKY uygulamalarının benimsenmesindeki itici ve kısıtlayıcı güçler Güç Alanı Analizi Modeli çerçevesinde sistematik literatür taraması yöntemiyle incelenmiştir. Bu Model, işletme yöneticilerine, örgütsel değişimi etkileme potansiyeli olan güçleri tanımlama ve anlama konusunda yardımcı olmayı hedefler. Yöneticiler, bu analiz çerçevesinde itici güçlerden yararlanmak ve kısıtlayıcı güçleri azaltmak için yeni eylem planları geliştirebilirler.

Yapay zekâya dayalı İKY uygulamalarının benimsenmesini etkileyen temel itici güçlerden biri olan örgütsel hazırbulunuşluk, finansal kaynakların yeterli olması, teknolojik altyapının gelişmiş olması, üst yönetimin destekleyici tutum sergilemesi ve çalışanların gerekli becerilere sahip olması gibi alt faktörlerle yakından ilişkilidir. Öncelikle, finansal kaynakların yeterli olması, yapay zekâ uygulamalarının geliştirilmesi, uygulanması ve sürdürülmesi için gerekli olan bütçenin sağlanması açısından önemlidir. Gelişmiş teknolojik altyapı ise, yapay zekâ uygulamalarının verimli bir şekilde entegre edilmesi için gerekli donanım ve yazılımı sağlar. Üst yönetimin destekleyici tutumu, çalışanların yeni teknolojileri kabul etme ve kullanma isteğini artırarak benimsenme sürecini kolaylaştırır. Ayrıca, çalışanların gerekli becerilere sahip olması, yapay zekâ sistemlerinin etkin bir şekilde kullanılabilmesi için önemlidir. Bu alt faktörlerin bir araya gelmesi, örgütsel hazırbulunuşluğun sağlanmasına ve yapay zekâ uygulamalarının başarılı bir şekilde benimsenmesine katkıda bulunur.

Bununla birlikte, işletmelere rekabet avantajı kazanma potansiyeli sunan yapay zekâ teknolojisi, İKY alanında bir dizi faydayı beraberinde getirmektedir. Yapay zekâ, işe alma, eğitim ve geliştirme, performans değerlendirme ve kariyer yönetimi gibi İKY işlevlerine destek olurken, aynı zamanda etkinlik, verimlilik ve genel iş performansı üzerinde belirgin etkiler sağlamaktadır. Bu ileri teknoloji, rutin görevlerin daha hızlı, doğru ve maliyet etkin bir şekilde gerçekleştirilmesine katkıda bulunarak, İKY çalışanlarının daha yaratıcı, yenilikçi ve stratejik görevlere odaklanmalarını mümkün kılar. Bu da karar alma süreçlerini iyileştirir, gelecekteki zorluklara daha iyi hazırlanmayı sağlar ve çalışan adanmışlığını artırır. Çalışanlar, yapay zekâya dayalı İKY uygulamalarının faydalarını olumlu bir şekilde değerlendirdiklerinde, bu uygulamaları benimseme eğiliminde olacaklardır. Bu durum, algılanan faydaların, çalışanların yapay zekâya dayalı İKY uygulamalarına yönelik tutumlarını etkileyen önemli bir itici güç olduğunu göstermektedir.

Ancak, yapay zekâ teknolojisinin benimsenmesi sürecinde bazı kısıtlayıcı güçlerle de karşılaşmaktadır. Bu güçler arasında teknolojik değişime karşı olumsuz tepkiler, veri gizliliği ve güvenliği endişeleri, algoritmik önyargı hataları ve duygusal zeka eksikliği gibi faktörler bulunmaktadır. Teknolojik değişime karşı gösterilen olumsuz tepkiler, yeni teknolojiye uyum sağlama konusundaki direnci temsil ederken; veri gizliliği ve güvenliği endişeleri, kişisel bilgilerin korunması ve verilerin yetkisiz erişimden korunması konularındaki hassasiyeti ifade etmektedir. Algoritmik önyargı hataları, yapay zekâ algoritmalarının bilinçsizce ayrımcılık yapabileme riskini belirtirken, duygusal zeka eksikliği, yapay zekâ sistemlerinin insan duygularını tanıma ve doğru bir şekilde yorumlama yeteneğinin sınırlı olması durumunu ifade etmektedir. Bu kısıtlayıcı güçler, yapay zekâ araçlarının etkinliğini azaltabilir ve İKY uygulamalarındaki başarıyı engelleyebilir. Ancak, bu zorlukların üstesinden gelebilmek için alınacak tedbirlerin, yapay zekâ araçlarının daha etkili ve güvenilir hale gelmesine katkı sağlayabileceği düşünülmektedir.

Bu çalışmanın, yapay zekâya dayalı İKY uygulamalarının benimsenmesindeki itici ve kısıtlayıcı güçlere dair sağladığı temel anlayış, İKY alanında yapay zekâ konusuna ilgi duyan araştırmacılara ve bu teknolojiyi uygulamayı düşünen profesyonellere teknolojik dönüşüm sürecini daha iyi anlama konusunda önemli bir rehberlik sunabilir. Bununla birlikte, İKY alanında yapay zekâya dayalı uygulamaların rolünü derinlemesine inceleyen daha fazla araştırmaya ihtiyaç vardır. İlk olarak, bu çalışmanın veri seti sadece WoS veri tabanından elde edilen İngilizce makalelerle sınırlıdır. Gelecekteki çalışmalarda farklı veri tabanları incelenerek farklı diller ve farklı yayın türlerinin dâhil edilmesiyle çalışmanın kapsamı genişletilebilir. İkinci olarak, mevcut çalışma ikincil verilere dayanmaktadır. Gelecekteki çalışmalarda, İKY'ye yönelik yapay zekâ uygulamalarının potansiyel etkilerini anlamak amacıyla birincil verilerin kullanılması önerilebilir. Bu kapsamda, yöneticilerin ve çalışanların İKY süreçlerinde yapay zekâ kullanımına yönelik hazır bulunuşluk düzeylerini değerlendiren çalışmalar yürütülebilir. Ayrıca, yapay zekâya dayalı dönüşüm sürecinden etkilenebilecek grupların, bu çalışmada belirlenen itici ve kısıtlayıcı güçlere yönelik algılarını inceleyen yeni araştırmalar başlatılabilir.



This research article has been licensed with Creative Commons Attribution - Non-Commercial 4.0 International License. Bu araştırma makalesi, Creative Commons Atıf - Gayri Ticari 4.0 Uluslararası Lisansı ile lisanslanmıştır.

Yazar Katkıları

Yazarlar çalışmaya eşit oranda katkı sağladıklarını beyan etmişlerdir.

Teşekkür Beyanı

Yazarlar teşekkür beyanında bulunmamışlardır.

Destek Beyanı

Yazarlar destek beyanında bulunmamışlardır.

Çıkar Çatışması

Yazarlar herhangi bir çıkar çatışması beyan etmemişlerdir.

Etik Beyanı

Yazarlar çalışma için Etik Kurul Onayı alınmasına gerek olmadığını beyan etmişlerdir.

Sorumlu Özel Sayı Editörleri

Doç. Dr. Beyza Mina Ordu-Akkaya, Ankara Sosyal Bilimler Üniversitesi

Doç. Dr. Görkem Ataman, Yaşar Üniversitesi

Arş. Gör. Yunus Yıldırım, Afyon Kocatepe Üniversitesi

Kaynakça/References

- Agarwal, A. (2023). AI adoption by human resource management: A study of its antecedents and impact on HR system effectiveness. *Foresight*, 25(1), 67-81. <https://doi.org/10.1108/FS-10-2021-0199>
- Ahmed, O. (2018). Artificial intelligence in HR. *International Journal of Research and Analytical Reviews*, 5(4), 971-978. <https://doi.org/10.31221/osf.io/cfwvm>
- Al-Alawi, A. I., Sanosi, S. K. & Althawadi, A. H. (2021). *Effects of technology and digital innovations on the human resources ecosystem*. 2021 International Conference on Decision Aid Sciences and Application, 7th-8th December 2021, Online, 502-510, <https://doi.org/10.1109/DASA53625.2021.9682279>.
- Almarashda, H., Baba, I., Ramli, A., Memon, A. & Rahman, I. (2021). Human resource management and technology development in artificial intelligence adoption in the UAE energy sector. *Journal of Applied Engineering Sciences*, 11(2) 69-76. <https://doi.org/10.2478/jaes-2021-0010>
- Arslan, A., Cooper, C., Khan, Z., Golgeci, I. & Ali, I. (2022). Artificial intelligence and human workers interaction at team level: A conceptual assessment of the challenges and potential HRM strategies. *International Journal of Manpower*, 43(1), 75-88. <https://doi.org/10.1108/IJM-01-2021-0052>
- Aydın, E. & Turan, M. (2023). An AI-based shortlisting model for sustainability of human resource management. *Sustainability*, 15(3), 1-15. <https://doi.org/10.3390/su15032737>
- Baldegger, R., Caon, M. & Sadiku, K. (2020). Correlation between entrepreneurial orientation and implementation of AI in human resources management. *Technology Innovation Management Review*, 10(4), 72-79. <http://doi.org/10.22215/timreview/1348>
- Bankins, S. (2021). The ethical use of artificial intelligence in human resource management: A decision-making framework. *Ethics and Information Technology*, 23, 841-854. <https://doi.org/10.1007/s10676-021-09619-6>
- Bankins, S., Formosa, P., Griep, Y. & Richards, D. (2022). AI decision making with dignity? Contrasting workers' justice perceptions of human and AI decision making in a human resource management context. *Information Systems Frontiers*, 24, 857-875. <https://doi.org/10.1007/s10796-021-10223-8>
- Bhatt, P. (2022). AI adoption in the hiring process-important criteria and extent of AI adoption. *Foresight*, 25(1), 144-163. <https://doi.org/10.1108/FS-07-2021-0144>
- Böhmer, N. & Schinnenburg, H. (2023). Critical exploration of AI-driven HRM to build up organizational capabilities. *Employee Relations*, 45(5), 1057-1082. <https://doi.org/10.1108/ER-04-2022-0202>
- Budhwar, P., Malik, A., De Silva, M. T. T. & Thevisuthan, P. (2022). Artificial intelligence-challenges and opportunities for international HRM: A review and research agenda. *The International Journal of Human Resource Management*, 33(6), 1065-1097. <https://doi.org/10.1080/09585192.2022.2035161>
- Capatina, A., Bleoju, G., Matos, F. & Vairinhos, V. (2017). Leveraging intellectual capital through Lewin's Force Field Analysis: The case of software development companies. *Journal of Innovation & Knowledge*, 2(3), 125-133. <https://doi.org/10.1016/j.jik.2016.07.001>
- Chilunjika, A., Intauno, K. & Chilunjika, S. R. (2022). Artificial intelligence and public sector human resource management in South Africa: Opportunities, challenges and prospects. *SA Journal of Human Resource Management*, 20, 1-12. <https://doi.org/10.4102/sajhrm.v20i0.1972>
- Chowdhury, S., Dey, P., Joel-Edgar, S., Bhattacharya, S., Rodriguez-Espindola, O., Abadie, A. & Truong, L. (2023). Unlocking the value of artificial intelligence in human resource management through AI capability framework. *Human Resource Management Review*, 33(1), 1-21. <https://doi.org/10.1016/j.hrmr.2022.100899>
- Eubanks, B. (2022). *Artificial intelligence for HR: Use AI to support and develop a successful workforce* (2nd. Ed.). Kogan Page, London, N.Y.
- Goswami, M., Jain, S., Alam, T., Deifalla, A. F., Ragab, A. E. & Khargotra, R. (2023). Exploring the antecedents of AI adoption for effective HRM practices in the Indian pharmaceutical sector. *Frontiers in Pharmacology*, 14, 1-14. <https://doi.org/10.3389/fphar.2023.1215706>
- Harwood, T. G. & Garry, T. (2003). An overview of content analysis. *The Marketing Review*, 3, 479-498.
- Hmoud, B. (2021). The adoption of artificial intelligence in human resource management. *Forum Scientiae Oeconomia*, 9(1), 105-118. https://doi.org/10.23762/fso_Vol9_no1_7
- Hossin, M. S., Ulfy, M. A., Ali, I. & Karim, M. W. (2021). Challenges in adopting artificial intelligence (AI) in HRM practices: A study on Bangladesh perspective. *International Fellowship Journal of Interdisciplinary Research*, 1(1), 66-73. <https://doi.org/10.5281/zenodo.4480245>
- Hussain, S. M., Ahmad, N., Fazal, F. & Menegaki, A. N. (2023). The impact of female directorship on firm performance: A systematic literature review. *Review of Managerial Science*. <https://doi.org/10.1007/s11846-023-00677-2>
- IBM (2021, October). *The business case for AI in HR: Insights and tips on getting started*. <https://www.ibm.com/downloads/cas/A5YLEPBR>
- Islam, M., Mamun, A. A., Afrin, S., Ali Quaosar, G. M. A. & Uddin, Md. A. (2022). Technology adoption and human resource

- management practices: The use of artificial intelligence for recruitment in Bangladesh. *South Asian Journal of Human Resources Management*, 9(2), 324-349. <https://doi.org/10.1177/23220937221122329>
- Jaiswal, A., Arun, C. J. & Varma, A. (2022). Rebooting employees: Upskilling for artificial intelligence in multinational corporations. *The International Journal of Human Resource Management*, 33(6), 1179-1208. <https://doi.org/10.1080/09585192.2021.1891114>
- Johnson, B. A. M., Cogburn, J. D. & Llorens, J. J. (2022). Artificial intelligence and public human resource management: Questions for research and practice. *Public Personnel Management*, 51(4), 538-562. <https://doi.org/10.1177/00910260221126498>
- Jöhnk, J., Weißert, M. & Wyrтки, K. (2021). Ready or not AI comes-An interview study of organizational AI readiness factors. *Business & Information Systems Engineering*, 63, 5-20. <https://doi.org/10.1007/s12599-020-00676-7>
- Konovalova, V., Mitrofanova, E., Mitrofanova, A. & Gevorgyan, R. (2022). The impact of artificial intelligence on human resources management strategy: Opportunities for the Humanisation and Risks. *Wisdom*, 2(1), 88-96. <https://doi.org/10.24234/wisdom.v2i1.763>
- Kshetri, N. (2021). Evolving uses of artificial intelligence in human resource management in emerging economies in the Global South: Some preliminary evidence. *Management Research Review*, 44(7), 970-990. <https://doi.org/10.1108/MRR-03-2020-0168>
- Lawler, J. J., & Elliot, R. (1996). Artificial intelligence in HRM: An experimental study of an expert system. *Journal of Management*, 22(1), 85-111. <https://doi.org/10.1177/014920639602200104>
- Levi, D. & Lawn, M. (1993). The driving and restraining forces which affect technological innovation in organizations. *The Journal of High Technology Management Research*, 4(2), 225-240. [https://doi.org/10.1016/1047-8310\(93\)90006-2](https://doi.org/10.1016/1047-8310(93)90006-2)
- Lewin, K. (1951). *Field theory in social science: Selected theoretical papers*. Harper & Row, New York, NY.
- Mak, A. H. N. & Chang, R. C. Y. (2019). The driving and restraining forces for environmental strategy adoption in the hotel industry: A force field analysis approach. *Tourism Management*, 73, 48-60. <https://doi.org/10.1016/j.tourman.2019.01.012>
- Malik, A., Budhwar, P. & Kazmi, B. A. (2023). Artificial intelligence (AI)-assisted HRM: Towards an extended strategic framework. *Human Resource Management Review*, 33(1), 1-16. <https://doi.org/10.1016/j.hrmmr.2022.100940>
- Mathew, S., Oswal, N. & Ateeq, K. (2021). Artificial intelligence (AI): Bringing a new revolution in human resource management (HRM). *Grenze International Journal of Engineering and Technology*, Jan Issue, 211-218.
- McKinsey & Company (2022, December). *The state of AI in 2022- and a half decade in review*. <https://www.mckinsey.com/~media/mckinsey/business%20functions/quantumblack/our%20insights/the%20state%20of%20ai%20in%202022%20and%20a%20half%20decade%20in%20review/the-state-of-ai-in-2022-and-a-half-decade-in-review.pdf?shouldIndex=false>
- Mehrotra, S. & Khanna, A. (2022). Recruitment through AI in selected Indian companies. *Metamorphosis*, 21(1), 31-39. <https://doi.org/10.1177/097262252110662>
- Mittal, N. & Gujral, H. K. (2020). Realization of artificial intelligence in human resource management best practices. *Mukt Shabd Journal*, 9(7), 2786-2795.
- Mohamad, Z., Chaudhary, R., Iyer, S., Sutarto & Khan, S. (2022). A probing: How artificial intelligence is beneficial in different fields of human resource management. *Pacific Business Review (International)*, 15(4), 80-89.
- Ose, S. O. (2016). Using Excel and Word to structure qualitative data. *Journal of Applied Social Science*, 10(2), 147-162. <https://doi.org/10.1177/1936724416664948>
- Palos-Sanchez, P. R., Baena-Luna, P., Badicu, A. & Infante-Moro, J. C. (2022). Artificial intelligence and human resources management: A bibliometric analysis. *Applied Artificial Intelligence*, 36(01), 3628-3655. <https://doi.org/10.1080/08839514.2022.2145631>
- Pan, Y., Froese, F., Liu, N., Hu, Y. & Ye, M. (2022). The adoption of artificial intelligence in employee recruitment: The influence of contextual factors. *The International Journal of Human Resource Management*, 33(6), 1125-1147. <https://doi.org/10.1080/09585192.2021.1879206>
- Panda, P. (2020). The future transformation of HR functions which apstole by artificial intelligence. *Brindavan Journal of Management and Computer Science*, 1(1), 127-135.
- Parikh, N. (2021, October 14). *Understanding bias in AI-enabled hiring*. <https://www.forbes.com/sites/forbeshumanresourcescouncil/2021/10/14/understanding-bias-in-ai-enabled-hiring/?sh=410312cd7b96>
- Prikshat, V., Patel, P., Varma, A. & Ishizaka, A. (2022). A multi-stakeholder ethical framework for AI-augmented HRM. *International Journal of Manpower*, 43(1), 226-250. <https://doi.org/10.1108/IJM-03-2021-0118>
- Prikshat, V., Malik, A. & Budhwar, P. (2023). AI-augmented HRM: Antecedents, assimilation and multilevel consequences. *Human Resource Management Review*, 33(1), <https://doi.org/10.1016/j.hrmmr.2021.100860>.
- Qahtani, E. H. A. L. & Alsmairat, M. A. K. (2023). Assisting artificial intelligence adoption drivers in human resources management: A mediation model. *Acta Logistica*, 10(1), 141-150. <https://doi.org/10.22306/al.v10i1.371>
- Qamar, Y., Agrawal, R. K., Samad, T. A. & Chiappetta Jabbour, C. J. (2021). When technology meets people: The interplay of artificial
- Kişi ve Özer (2024).

- intelligence and human resource management. *Journal of Enterprise Information Management*, 34(5), 1339-1370. <https://doi.org/10.1108/JEIM-11-2020-0436>
- Rodgers, W., Murray, J. M., Stefanidis, A., Degbey, W. Y. & Tarba, S. Y. (2023). An artificial intelligence algorithmic approach to ethical decision-making in human resource management processes. *Human Resource Management Review*, 33(1), 1-19. <https://doi.org/10.1016/j.hrmr.2022.100925>
- Saxena, A. (2020). The growing role of artificial intelligence in human resource. *EPRA International Journal of Multidisciplinary Research*, 6(8), 152-158. <https://doi.org/10.36713/epra2013>
- Schuller, D. & Schuller, B. W. (2018). The age of artificial emotional intelligence. *Computer*, 51(9), 38-46. <https://doi.org/10.1109/MC.2018.3620963>
- Schwering, R. E. (2003). Focusing leadership through force field analysis: New variations on a venerable planning tool. *Leadership & Organization Development Journal*, 24(7), 361-370. <https://doi.org/10.1108/01437730310498587>
- Singh, A. & Shaurya, A. (2021). Impact of artificial intelligence on HR practices in the UAE. *Humanities and Social Sciences Communications*, 8, 1-9. <https://doi.org/10.1057/s41599-021-00995-4>
- Sithambaram, R. A. & Tajudeen F. P. (2023). Impact of artificial intelligence in human resource management: A qualitative study in the Malaysian context. *Asia Pacific Journal of Human Resources*, 61, 821-844. <https://doi.org/10.1111/1744-7941.12356>
- Song, Y. & Wu, R. (2021). Analysing human-computer interaction behaviour in human resource management system based on artificial intelligence technology. *Knowledge Management Research & Practice*, <https://doi.org/10.1080/14778238.2021.1955630>
- Sriram, V. P., Mathur, A., Aarthy C, C. J., Basumatary, B., Mamgain, P. & Pallathadka, H. (2021). Model based using artificial intelligence to overcome the human resource problem in the healthcare industry. *Annals of the Romanian Society for Cell Biology*, 25(4), 3980-3992.
- Swanson, D. J. & Creed, A. S. (2014). Sharpening the focus of force field analysis. *Journal of Change Management*, 14(1), 28-47. <https://doi.org/10.1080/14697017.2013.788052>
- Tambe, P., Cappelli, P. & Yakubovich, V. (2019). Artificial intelligence in human resources management: Challenges and a path forward. *California Management Review*, 61(4), 15-42. <https://doi.org/10.1177/0008125619867910>
- Tanantong, T. & Wongras, P. A. (2024). UTAUT-based framework for analyzing users' intention to adopt artificial intelligence in human resource recruitment: A case study of Thailand. *Systems*, 12(1), 1-27. <https://doi.org/10.3390/systems12010028>
- Thomas, J. (1985). Force field analysis: A new way to evaluate your strategy. *Long Range Planning*, 18(6), 54-59. [https://doi.org/10.1016/0024-6301\(85\)90064-0](https://doi.org/10.1016/0024-6301(85)90064-0)
- Tsybaliuk, S., Vasylyk, A. & Bilyk, O. (2022). Artificial intelligence in HR: Practices and prospects of the spread in Ukraine. *The Eurasia Proceedings of Science, Technology, Engineering & Mathematics (EPSTEM)*, 17, 152-160. <https://doi.org/10.55549/epstem.1176076>
- Weber, P. (2023). Unrealistic optimism regarding artificial intelligence opportunities in human resource management. *International Journal of Knowledge Management*, 19(1), 1-19. <https://doi.org/10.4018/IJKM.317217>
- World Economic Forum (2023, May). *Future of jobs report 2023*. https://www3.weforum.org/docs/WEF_Future_of_Jobs_2023.pdf
- Xiao, Q., Yan, J. & Bamber, G. J. (2023). How does AI-enabled HR analytics influence employee resilience: Job crafting as a mediator and HRM system strength as a moderator. *Personnel Review*, <https://doi.org/10.1108/PR-03-2023-0198>
- Yang, Y. (2022). Artificial intelligence-based organizational human resource management and operation system. *Frontiers in Psychology*, 13, 1-11. <https://doi.org/10.3389/fpsyg.2022.962291>
- Zahidi, F., Imam, Y., Hashmi, A. U. & Baig, M. M. (2020). Impact of artificial intelligence on HR management-A review. *Dogo Rangsang Research Journal*, 10(6), 92-99.
- Zhang, J. & Yuan, Y. (2022). Multi-dimensional post competency evaluation model in human resource management under the background of artificial intelligence. *Mathematical Problems in Engineering*, 2022, 1-10. <https://doi.org/10.1155/2022/9730127>

Research Article (Special Issue) | Araştırma Makalesi (Özel Sayı)

Yapay zekâ kaygısının teknoloji kaynaklı işsizlik endişesi üzerine etkisi: Muhasebe meslek mensupları üzerine bir araştırma

Özen Akçakanat | Doç. Dr., Süleyman Demirel Üniversitesi, ozenakcakanat@sdu.edu.tr, [0000-0002-7223-3028](https://orcid.org/0000-0002-7223-3028)Corresponding author/Sorumlu yazar: Özen Akçakanat ✉ ozenakcakanat@sdu.edu.tr

Öz

Yapay zekâ, son yıllarda üzerinde en fazla konuşulan konulardan birisi olarak karşımıza çıkmaktadır. Buradan yola çıkılarak bu çalışmada, yapay zekânın günümüz insanında yarattığı endişe üzerinde durulmuştur. Bu bağlamda, yapay zekâ teknolojisi sebebiyle sonraki yıllarda işlerini kaybetme durumuyla karşılaşması mümkün görülen mesleklerden birisi olan muhasebe çalışanlarının, teknoloji kaynaklı işsizlik endişeleri üzerine bir araştırma gerçekleştirilmiştir. Araştırma Antalya ve Isparta illerinde görev yapan muhasebe meslek mensupları örnekleminde gerçekleştirilmiş olup kolayda örnekleme yöntemiyle 291 meslek mensubuna ulaşılmıştır. Çalışmada, Yapay Zekâ Kaygısı ile Teknoloji Kaynaklı İşsizlik Endişesi Ölçekleri kullanılarak veriler toplanmıştır. Araştırma neticesinde muhasebe meslek mensuplarının yapay zekâ kaygı seviyelerinin orta düzeyde olduğu görülmüştür. Çalışmada, yapay zekâ kaygısının öğrenme, iş değişimi ve yapay zekâ yapılandırması boyutlarının teknoloji kaynaklı işsizlik endişesinin tüm boyutlarını pozitif ve anlamlı şekilde etkilediği sonucuna ulaşılmıştır. Çalışmada ayrıca, yapay zekâ kaygısının sosyoteknik körlük boyutunun ise teknoloji kaynaklı işsizlik endişesinin tüm boyutlarını negatif ve anlamlı şekilde etkilediği tespit edilmiştir. Son olarak muhasebe meslek mensuplarının yapay zekâ kaygı düzeylerinin yaş artışına paralel olarak yükseldiği de belirlenmiştir.

Anahtar Kelimeler: Yapay Zekâ, Yapay Zekâ Kaygısı, Teknoloji Kaynaklı İşsizlik Endişesi, Muhasebe Meslek Mensupları **JEL Kodları:** M41

The impact of artificial intelligence anxiety on technology-induced unemployment concerns: A study on accounting professionals

Abstract

Artificial intelligence has become one of the most discussed topics in recent years. Based on this, this study examines the concerns that artificial intelligence creates in today's people. In this context, research was done on the technology-induced unemployment concerns of accounting employees, one of the professions that are likely to lose their jobs in the coming years because of artificial intelligence technology. The research was conducted among a sample of accounting professionals working in Antalya and Isparta provinces, and 291 professionals were reached by convenience sampling method. The study collected data using the Artificial Intelligence Anxiety and Technology-Induced Unemployment Concern Scales. The research showed that accounting professionals' artificial intelligence anxiety levels were medium. The study concluded that the learning, job replacement, and artificial intelligence configuration dimensions of artificial intelligence anxiety positively and significantly affect all dimensions of technology-induced unemployment concern. The study also found that the sociotechnical blindness dimension of artificial intelligence anxiety negatively and significantly affects all dimensions of technology-induced unemployment concern. Finally, it was also found that the artificial intelligence anxiety levels of accounting professionals increase in parallel with the increase in age.

Keywords: Artificial Intelligence, Artificial Intelligence Anxiety, Technology-Induced Unemployment Concern, Accounting Professionals**JEL Codes:** M41

Extended Summary

The main purpose of this study is to reveal the anxiety levels of accounting professionals towards artificial intelligence. The study also aims to reveal the effect of artificial intelligence anxiety on technology-induced unemployment concerns.

In recent years, there has been a belief that artificial intelligence technology will eliminate many professions. In this context, many studies have been published in the form of reviews that show that professionals who are in the accounting profession will also be affected by this situation. Based on this, it is considered as the original value of this study to determine whether the members of the accounting profession are actually concerned about such a concern, and if there is such a concern, to find out what effect it

How to cite this article / Bu makaleye atıf vermek için:

Akçakanat, Ö. (2024). Yapay zekâ kaygısının teknoloji kaynaklı işsizlik endişesi üzerine etkisi: Muhasebe meslek mensupları üzerine bir araştırma.

KOCATEPEİİBFD, 26(Özel Sayı), 53-67. <https://doi.org/10.33707/akuiibfd.1458358>

has on technology-induced unemployment concern.

In this study, the population of the research was determined to be accounting professionals. Using the convenience sampling method, data were collected from Antalya and Isparta provinces, and analyses were carried out on a total of 291 valid questionnaire forms. Within the scope of this study, two scales were used to obtain data. The first of these scales is the Artificial Intelligence Anxiety Scale, which consists of 4 dimensions and 21 items. The scale is graded on a 7-point Likert scale with 1= Not at all and 7= Completely. There are no reverse-scored items on the scale, and an increase in the score obtained from the scale is explained as a high level of artificial intelligence anxiety. The second scale used in the study is the Technology-Induced Unemployment Concern Scale. The scale consists of 3 dimensions and 12 items. The scale is graded on a 5-point Likert scale and corresponds to 1= Strongly Disagree and 5= Strongly Agree. There are no reverse-scored items on the scale, and an increase in the score obtained from the scale is explained as a high level of technology-induced unemployment.

In the analysis conducted by considering the whole scale for artificial intelligence anxiety, it was determined that accounting professionals have a moderate level of artificial intelligence anxiety. When the situation is evaluated in terms of the variable of technology-induced unemployment concern, it is determined that the members of the accounting profession have less than the medium level of technology-induced unemployment concern.

In the correlation analysis, the relationships between all dimensions of both scales were found to be positive and significant. In this study, hypothesis tests were performed using the structural equation modeling technique, and 8 out of 12 hypotheses were supported. According to the results of the research, it was determined that the learning dimension of artificial intelligence anxiety has a positive and significant effect on the lack of technical skills and incremental technological improvements dimensions of technology-induced unemployment concern. It was also determined that the job replacement dimension of artificial intelligence anxiety has a positive and significant effect on the lack of technical skills, incremental technological improvements, and technological disruption dimensions of technology-induced unemployment concern. The study also reported that the artificial intelligence configuration dimension of artificial intelligence anxiety has a positive and significant effect on the lack of technical skills, incremental technological improvements, and technological disruption dimensions of technology-induced unemployment concern. Finally, the one-way analysis of variance (ANOVA) revealed significant differences in all sub-dimensions of artificial intelligence anxiety in terms of age variables. It was determined that the participants' artificial intelligence anxiety levels increased with the increase in age.

The limitations of this study include the cross-sectional collection of research data, the fact that the data are based on self-reports of professional members, and the relatively insufficient sample size. In future studies, it is suggested that researchers should conduct a similar study with a sample representing all accounting professionals in Turkey. In addition, monitoring the change in anxiety about artificial intelligence through longitudinal studies can be considered as another suggestion.

Giriş

Yapay zekâ 1950'lerden bu yana geliştirilen ve özellikle son on yılda iyice ön plana çıkan bir teknoloji olarak göze çarpmaktadır. Günümüzde pek çok film ve dizi yapay zekânın yükselişine ve bunun insanlık için ne anlama gelebileceğine odaklanmakta ve bu da yapay zekânın popülerliğini giderek artırmaktadır. Google, Microsoft ve Amazon gibi internet devleri de yapay zekâyâ öncülük etmekte ve günlük yaşamlarımız sohbet botları, satın alma tahmini, haber üretimi gibi yapay zekâ sistemlerinden giderek daha fazla etkilenmektedir. Yapay zekâ ile ilgili bu gelişmelerden muhasebe alanının da etkilenmemesi pek tabii mümkün değildir.

Yapay zekânın muhasebe mesleği ile ilgili uzun bir geçmişi vardır. Muhasebe ve denetim alanında 25 yılı aşkın süredir uygulanmaktadır (Greenman, 2017). Ernst and Young (EY) ve PricewaterhouseCoopers (PwC) gibi mesleğin en büyük firmaları, düzensiz işlemleri veya tutarsızlık kalıplarını tespit etmek için denetim ve mali inceleme prosedürlerinde yapay zekâ teknolojilerinden yararlanmaktadır. Muhasebe yazılımı sağlayıcısı SAP yakın zamanda, Microsoft Copilot ve Salesforce'un benzer teklifleri gibi müşterilere SAP uygulamalarında görevleri gerçekleştirirken bağlamsal bilgiler ve yardım sağlama sözü veren Joule adlı yapay zekâ asistanını piyasaya sürmüştür. Joule'un firmalara, finansal verileri analiz etme, satış eğilimlerini tahmin etme ve karar verme gibi konularda yardımcı olacağı ifade edilmektedir. Bunlar, üretken yapay zekâdan yararlanmaya yeni başlayan muhasebe ürünleri ve platformlarından yalnızca birkaç örnektir. Sage'den Epicor'a, Microsoft Dynamics'den , Xero'ya ve QuickBooks'a kadar diğer büyük hizmet sağlayıcıları da benzeri heyecan verici işleri gerçekleştirmektedir (Marks, 2024).

Günümüzde yapay zekânın muhasebenin neredeyse tüm yönlerine dahil edilmesi, muhasebe meslek mensuplarında korku ve tedirginlik doğurmaktadır. Oxford Üniversitesi'nin 2015 yılında yaptığı bir araştırma, muhasebe meslek mensuplarının gerçekleştirdikleri işleri makinelerin devralması nedeniyle, mevcut işlerini kaybetme ihtimalinin yüzde 95 olduğunu göstermektedir (Griffin, 2016). The Wall Street Journal, ABD Çalışma Bürosu'nun endişe verici istatistiklerine atıfta bulunarak muhasebeci ve

denetçilerin %17'sinin (altı kişiden biri) 2020 ve 2021'de mesleği bıraktığını bildirmiştir. Bu, 300.000 muhasebeci ve denetçinin, yeterli sayıda yeni giriş olmadan meslekten ayrılması anlamına gelmektedir (Oliver, 2023).

Yapay zekânın muhasebe mesleğinde istihdam ve işten çıkarma üzerindeki etkilerine ilişkin iki farklı görüş bulunmaktadır. İlk görüşe göre, yapay zekânın muhasebede kullanılması, veri girişi ve analizi gibi rutin işleri otomatikleştirme potansiyeline sahiptir ve bu da düşük vasıflı bireyler için istihdam kaybına yol açabilecektir. İkinci görüş ise yapay zekânın muhasebede uygulanmasının yeni işlerin yaratılmasına ve ekonomik genişlemeye yol açabileceğini ifade etmektedir. Bu görüşe göre, uzmanlaşmış işgücü ihtiyacının artması sonucunda özellikle yüksek vasıflı iş görenler için yeni iş fırsatları doğabilecektir (Saleem vd., 2023).

Bu bilgilerin ışığında bu çalışmada, muhasebe meslek mensuplarının yapay zekâ kaygılarının ortaya çıkarılması hedeflenmiştir. Çalışmada ayrıca yapay zekâ araç ve tekniklerinin doğal bir uzantısı olarak teknoloji kaynaklı işsizlik endişesi de muhasebe meslek mensupları özelinde incelenmiştir. Çalışma bu iki değişken arasındaki etkileşimi ortaya çıkarması bakımında ulusal yazında ilk çalışma olmaktadır. Bu kapsamda yazına katkıda bulunacağı değerlendirilmektedir.

1. Kavramsal Çerçeve

Bu ana başlık altında çalışmanın iki ana değişkenine yönelik açıklamalara yer verilecektir.

1.1. Yapay Zekâ Kaygısı

Kaplan ve Haenlein (2019) yapay zekâyı, bir sistemin verileri okuma ve yorumlama, ondan öğrenme ve esnek adaptasyon yoluyla belirli görevleri başarmak için öğrendiklerini uygulama yeteneği olarak tanımlamaktadır. Yapay zekâ kaygısı, kontrolden çıkan yapay zekâyâ ilişkin korku veya tedirginlik duygularını ifade eder. Yapay zekâ kaygısı, yapay zekâ teknolojilerinin kişisel veya toplumsal yaşamda oluşturduğu değişikliklerden ve sorunlardan kaynaklanan aşırı korku olarak tanımlanabilir (Wang ve Wang, 2022, s. 622). Wang ve Wang (2022) yapay zekâ kaygısını; yapay zekânın iş hayatı üzerindeki olumsuz etkilerinden duyulan korkuyu ifade eden *iş değiştirme kaygısı*, yapay zekânın insanlara bağımlılığının tam olarak anlaşılmasından kaynaklanan kaygıyı ifade eden *sosyoteknik körlük*, insansı yapay zekâyâ ilişkin korkuyu ifade eden *yapay zekâ yapılandırma kaygısı* ve yapay zekâ teknolojilerini öğrenmeye ilişkin kaygıyı ifade eden *yapay zekâ öğrenme kaygısı* boyutları altında sınıflandırmıştır.

İş değiştirme, özellikle yapay zekâ teknolojilerinin benimsenmesi nedeniyle görevlerin otomasyonundan ve işini kaybetmekten doğrudan etkilenen bireyler için yapay zekâ kaygısında rol oynayabilir. Otomasyon nedeniyle yerinden edilmiş veya yerinden edilme riskiyle karşı karşıya olan bireyler, gelecekteki iş beklentileri konusunda kaygı ve belirsizlik yaşayabilir. Araştırmalar işten çıkarmanın, iş tatmininin ve yaşam tatmininin azalması ve fiziksel sağlığın bozulması gibi bir dizi olumsuz sonuca yol açabileceğini göstermiştir. Ancak yapay zekânın benimsenmesi nedeniyle iş yerinden edilmekten tüm bireyler aynı şekilde etkilenmemektedir. Bazı bireyler, yapay zekâ teknolojilerinin benimsenmesinin bir sonucu olarak oluşturulan yeni rollere geçiş yapabilirken, diğerleri yapay zekâ sistemlerine ilişkin gerekli becerileri kazanmak için eğitim ve öğretime ihtiyaç duyabilir. Bazı araştırmalar, otomasyondan etkilenen bireyleri destekleyen politika ve programlar aracılığıyla işten çıkarılmayla ilgili kaygının azaltılabileceğini öne sürmektedir (Hopcan vd., 2023).

Yapay zekânın ortaya çıkışı, rutin, tekrarlanan operasyonel görevlerin otomasyonu yoluyla geleneksel muhasebe işlevini sürekli olarak değiştirmektedir. Yapay zekâ ile otomatikleştirilmiş süreçlerin, akıllı algoritmaların ve finansal robotların veri girişi, mutabakat, muhasebe ve finansal raporlama görevlerini basitleştirme yeteneği, veri doğruluğunu artırır ve muhasebecileri zaman alıcı görevlerden kurtarır. Onların müşterilere ve firma performansına daha fazla değer sağlayacak finansal analiz, stratejik planlama ve müşteri danışmanlık hizmetleri gibi katma değerli sorumluluklara daha fazla odaklanmalarına olanak tanır (Paderanga vd., 2023, s. 64).

Günümüzde muhasebe alanında yapay zekâ uygulamaları defter tutma, hesaplama, defter kapatma, hesap yönetimi, hesap raporlama, vergi raporlama gibi günlük muhasebe görevlerini otomatik olarak tamamlayabilmektedir. 2017'de PwC tarafından düzenlenen Vergi Robotları Forumu gelecekte robot akış otomasyonlarının, veri toplama, muhasebe kayıtları tutma, çalışma sayfası denetimi ve verileri vergi sistemine dönüştürme, vergi beyanı hazırlama ve vergi dahil olmak üzere elle çalıştırılan, çok tekrarlanan ve zaman alan vergi işlerinin yerini alabileceğine dikkat çekmiştir. McKinsey tarafından Temmuz 2016'da yayınlanan bir raporda yapay zekânın, muhasebeciler ve denetçiler tarafından gerçekleştirilen faaliyetlerin yaklaşık %86'sını otomatik hale getirebileceği belirtilmektedir. McKinsey raporu, muhasebe faaliyetleriyle ilgili otomasyonun, makine öğrenimi, bilgisayarlar ve yazılım kullanan otomasyonla daha az maliyetli olduğunu öne sürmektedir. Yine raporda muhasebe görevlerinin %86'sı için yapay zekânın, uygun maliyetli ve kâr getiren bir çözüm olabileceği, ancak işlevlerin %14'ü için insan dikkatinin gerekli olabileceği belirtilmiştir. Bu kapsamda, yapay zekânın kullanıma sunulması muhasebe mesleğini de yavaş yavaş dönüştürmüş ve muhasebe mesleği alanında yaşanan bu gelişmeler mesleğe ilişkin yapay zekâ kaygısını da beraberinde getirmiştir (Peng ve Chang, 2019, s. 379).

Her ne kadar yapay zekâ uygulamaları rutin görevlerin otomasyonuna yol açsa da muhasebe mesleğini yürütmek, yalnızca Akçakanat (2024).

tekrarlanan ve şüphesiz doğuştan gelen belirli işlemlerin çözümlendiği otomasyonun uygulanmasını içermez. Muhasebeciler, genellikle verilen çözümün en uygun çözüm olmasını sağlayacak şekilde uygulama, tahmin etme, seçme, yorumlama veya akıl yürütme işlevini yürütmektedir. Bu bağlamda muhasebe profesyonellerinin, belirli değerleri (gerçeğe uygun değer, kalıntı değer, geri kazanılabilir tutar) oluşturmak için tahminlerle hareket etmeleri gerekmektedir. Yine meslek mensupları, muhasebe uygulamalarının çeşitli yöntem veya politikalarını (stokların finansal tablo dışı bırakılmasına yönelik değerlendirme yöntemlerine ilişkin seçeneklerin ifadesi, amortisman yöntemlerine yönelik seçeneklerin görünümü, maddi duran varlıklara ilişkin temel veya alternatif muhasebe uygulamalarının uygulanmasına ilişkin seçeneklerin sunulması vb.) tercih etmektedirler. Muhasebecilerin halihazırda kullandıkları mesleki akıl yürütmenin ne kadarı algoritmalar tarafından devralınabilir/varsayılabilir? Ne yazık ki bu sorunun kesin cevabı ancak gelecekte, pek çok faktörün analizi yapılarak verilebilecektir (Brabete ve Goagara, 2022, s. 37).

1.2. Teknoloji Kaynaklı İşsizlik Endişesi

Keynes (1930) tarafından öne sürülen teknolojik işsizlik kavramı, önemli teknolojik gelişmelerin, özellikle de otomasyonu kapsayanların, insani görevlerin makineler ve otomatikleştirilmiş süreçler tarafından ele geçirilmesi nedeniyle iş değiştirmeye ve bunun sonucunda işsizliğe yol açabileceğini ifade etmektedir. Teknolojinin ilerleyen evrimiyle birlikte makinelerin daha önce insanlar tarafından yürütülen rolleri üstlenebileceği önermesine dayanan teknolojik işsizlik kavramı, insanın işgücü talebindeki potansiyel düşüşünü belirlemektedir. Organizasyonlar teknolojiye giderek daha fazla yöneldikçe, bunun genel etkisi bazı insan rollerinin eskimesidir (Rawashdeh, 2023, s. 8). Dünyadaki yıkıcı teknolojik gelişmelerin sonucu ortaya çıkan teknolojik işsizlik kaygısı, çalışanlarda iş ile ilgili oluşan güvensizlik duygusudur. Teknolojik işsizlik kaygısı, bireylerde artan düzeyde strese neden olur, öz motivasyonu düşürür, işe bağlılığı ve iş performansını azaltır ve çalışanların karar alma süreçlerine daha az katılımına yol açar (Civelek ve Pehlivanoğlu, 2020, s. 67).

Teknolojik işsizlikle ilgili endişeler yeni ortaya çıkan bir olgu değildir. Gerçekten de son yıllarda dijital teknolojiler, muhasebeci, kasiyer ve telefon operatörlerinin işlevleri de dahil olmak üzere birçok işin yerini almaktadır. Son zamanlarda, gelişmiş ekonomilerdeki işgücü piyasalarının zayıf performansı, ekonomistler arasında teknolojik işsizlikle ilgili tartışmayı yoğunlaştırmaktadır. Sürekli yüksek işsizlik oranlarının ardındaki itici güçler hakkında devam eden anlaşmazlıklar olsa da bazı bilim insanları bilgisayar kontrollü ekipmanların son zamanlardaki işsizlik artışının olası bir açıklaması olduğuna işaret etmektedir. Bilgisayarlaşmanın işgücü piyasası sonuçları üzerindeki etkisi olarak, rutin yoğun mesleklerde (yani esas olarak karmaşık algoritmalar tarafından kolayca gerçekleştirilebilen, iyi tanımlanmış prosedürleri takip eden görevlerden oluşan meslekler) istihdamı azalttığını kanıtlayan literatürde pek çok çalışma bulunmaktadır (Frey ve Osborne, 2017, s. 255).

Dünya Ekonomik Forumu (2023) tarafından yapılan bir araştırma, yapay zekâ ve sosyo-ekonomik koşulların birleşik etkisinden dolayı 14 milyonluk net iş kaybı öngörmektedir. Önümüzdeki beş yıl içinde küresel olarak 83 milyon işin yerinden edileceği ve yalnızca 69 milyon işin yaratılacağı tahmin edilmektedir. Muhasebe meslek mensuplarının veri girişi, kayıt tutma, denetim ve raporlamadaki rolünün ortadan kalkabileceği ve yerini yapay zekânın kullanımıyla veri analizi ve danışmanlık işlevlerinin alabileceği düşünülmektedir (Paderanga vd., 2023, s. 62). Nitekim 2016'da Wal-Mart, tekrarlanan faaliyetlerin çoğu muhasebe yazılımları (Xero ve QuickBooks) ile otomatikleştirildiğinden, nakit akışı yönetimi ve satıcı taleplerinin işlenmesiyle ilgilenen 7.000 çalışanını işten çıkarmıştır (Akhter ve Sultana, 2018, s. 148). Dijitalleşme ve yapay zekâ muhasebe mesleği için birtakım endişeler ortaya çıkarsa da dijital devrim sonucunda muhasebe mesleğinde meydana gelecek değişimlerin bir meydan okuma ve fırsatlar birikimi olarak algılanması gerektiği, IFAC (Uluslararası Muhasebe Federasyonu) Başkanı Charles Tilley tarafından ifade edilmiştir. Charles Tilley "Muhasebe profesyonellerinin değişimi kaçınılmaz olarak kabul etmeleri ve sektördeki gelecekteki rollerini şekillendirmek için proaktif bir şekilde çalışmaları durumunda bu fırsatların çok büyük olduğunu" belirtmiştir (Brabete ve Goagara, 2022, s. 34).


2. Araştırmanın Metodolojisi

Bu başlık altında araştırmanın amacı, modeli, hipotezleri, evren ve örnekleme ile araştırmada kullanılan veri toplama araçları hakkında bilgiler verilecektir.

2.1. Araştırmanın Amacı, Modeli ve Hipotezleri

Bu araştırmanın temel amacı muhasebe meslek mensuplarının yapay zekâyâ yönelik kaygı düzeylerini ortaya çıkartmaktır. Çalışmada ayrıca, yapay zekâ kaygısının teknoloji kaynaklı işsizlik endişesi üzerine etkisinin de ortaya koyulması hedeflenmiştir. Bu amaçla çalışmanın modeli Şekil 1'de gösterildiği gibi oluşturulmuştur.

Şekil 1. Araştırmanın Modeli



Kaynak: Yazar tarafından oluşturulmuştur.

Şekil 1’de gösterilen model uyarınca araştırmanın 12 adet hipotezi bulunmaktadır. Bu hipotezlere aşağıda yer verilmiştir.

H₁= Yapay zekâ kaygısının *öğrenme* boyutu, teknoloji kaynaklı işsizlik endişesinin *teknik beceri eksikliği* boyutunu pozitif ve anlamlı etkiler.

H₂= Yapay zekâ kaygısının *öğrenme* boyutu, teknoloji kaynaklı işsizlik endişesinin *sürekli teknolojik gelişmeler* boyutunu pozitif ve anlamlı etkiler.

H₃= Yapay zekâ kaygısının *öğrenme* boyutu, teknoloji kaynaklı işsizlik endişesinin *yıkıcı teknolojik gelişmeler* boyutunu pozitif ve anlamlı etkiler.

H₄= Yapay zekâ kaygısının *iş değişimi* boyutu, teknoloji kaynaklı işsizlik endişesinin *teknik beceri eksikliği* boyutunu pozitif ve anlamlı etkiler.

H₅= Yapay zekâ kaygısının *iş değişimi* boyutu, teknoloji kaynaklı işsizlik endişesinin *sürekli teknolojik gelişmeler* boyutunu pozitif ve anlamlı etkiler.

H₆= Yapay zekâ kaygısının *iş değişimi* boyutu, teknoloji kaynaklı işsizlik endişesinin *yıkıcı teknolojik gelişmeler* boyutunu pozitif ve anlamlı etkiler.

H₇= Yapay zekâ kaygısının *sosyoteknik körlük* boyutu, teknoloji kaynaklı işsizlik endişesinin *teknik beceri eksikliği* boyutunu pozitif ve anlamlı etkiler.

H₈= Yapay zekâ kaygısının *sosyoteknik körlük* boyutu, teknoloji kaynaklı işsizlik endişesinin *sürekli teknolojik gelişmeler* boyutunu pozitif ve anlamlı etkiler.

H₉= Yapay zekâ kaygısının *sosyoteknik körlük* boyutu, teknoloji kaynaklı işsizlik endişesinin *yıkıcı teknolojik gelişmeler* boyutunu pozitif ve anlamlı etkiler.

H₁₀= Yapay zekâ kaygısının *yapay zekâ yapılandırması* boyutu, teknoloji kaynaklı işsizlik endişesinin *teknik beceri eksikliği* boyutunu pozitif ve anlamlı etkiler.

H₁₁= Yapay zekâ kaygısının *yapay zekâ yapılandırması* boyutu, teknoloji kaynaklı işsizlik endişesinin *sürekli teknolojik gelişmeler* boyutunu pozitif ve anlamlı etkiler.

H₁₂= Yapay zekâ kaygısının *yapay zekâ yapılandırması* boyutu, teknoloji kaynaklı işsizlik endişesinin *yıkıcı teknolojik gelişmeler* boyutunu pozitif ve anlamlı etkiler.

2.2. Araştırmanın Evreni ve Örneklemi

Bu çalışmada araştırmanın evreni muhasebe meslek mensupları olarak belirlenmiştir. Çalışmanın bu meslek grubu özelinde gerçekleştirilmesinin sebebi, muhasebecilerin yapay zekânın öncelikli olarak ele geçireceği ilk on meslek grubu arasında sayılmasından kaynaklanmaktadır (Prigg, 2019). ManpowerGroup (2016) tarafından 43 ülkede 18.000’i aşkın çalışanla gerçekleştirilen bir çalışmada da dijital devrim neticesinde istihdamın en az artacağı sektör muhasebe ve finans sektörü olarak raporlanmıştır. Tüm bu kaygılar doğrultusunda, yeminli mali müşavir (YMM), serbest muhasebeci mali müşavir (SMMM), serbest muhasebeci (SM) unvanını kullanan kişilere ulaşılmaya çalışılmıştır. Çalışmada ayrıca, çok yakın bir zaman diliminde muhasebe meslek mensubu olması beklenen SMMM stajyerleri de evrene dahil edilmiştir. Evrenin tamamına ulaşmak hem zaman hem de maddi açıdan çok zor olacağı için örneklem seçimine gidilmiştir. Bu kapsamda kolayda örneklem yöntemi kullanılarak Antalya ve

Isparta illerinden veriler toplanmıştır. Türkiye Serbest Muhasebeci Mali Müşavirler ve Yeminli Mali Müşavirler Odaları Birliği (TÜRMOB)'nin web sayfasında meslek mensupları sayılarının illere göre dağılımına yer verilmiştir. Buradan elde edilen bilgiler ışığında bu iki ilde toplamda 4054 meslek mensubunun çalıştığı tespit edilmiştir (TÜRMOB, 2024). SMMM stajyerlerinin sayısı bilinmemektedir. Sonuç olarak dağıtılan formlardan geriye dönen 291 geçerli anket formu üzerinden analizler gerçekleştirilmiştir.

2.3. Araştırmada Kullanılan Veri Toplama Araçları

Bu çalışma kapsamında verilerin elde edilmesinde iki ölçekten yararlanılmıştır. Aşağıda bu ölçeklerle ilgili ayrıntılı bilgi verilmiştir.

Bu ölçeklerden ilki Yapay Zekâ Kaygısı Ölçeği olup 4 boyut ve 21 maddeden oluşmaktadır. Ölçeğin orijinal versiyonu Wang ve Wang (2022) tarafından geliştirilmiştir. Ölçeğin Türk kültürüne uyarlama çalışması ise Terzi (2020) tarafından gerçekleştirilmiştir. Ölçeğin boyutları sırasıyla Öğrenme (8 madde), İş Değişimi (6 madde) Sosyoteknik Körlük (4 madde) ve Yapay Zekâ Yapılandırması (3 madde) şeklinde isimlendirilmiştir. Ölçek 7'li Likert şeklinde derecelendirilmiş ve 1= Hiç, 7= Tamamen'e karşılık gelmektedir. Ölçekte ters puanlanmış madde bulunmamakta ve ölçekten elde edilen puanın artması yapay zekâ kaygısının yüksek olması şeklinde açıklanmaktadır. Orijinal çalışmada iç tutarlılık güvenilirlik katsayıları öğrenme için .97, iş değişimi için .91, sosyoteknik körlük için .91 ve yapay zekâ yapılandırması için .96 olarak belirlenmiştir. Uyarlama çalışmasında ise bu katsayılar sırasıyla .89, .95, .89 ve .95 şeklinde tespit edilmiştir. Ölçeğe ilişkin örnek maddeler, *"bir yapay zekâ tekniğiyle/ürünüyle ilişkili tüm özel işlevleri anlamayı öğrenmek beni endişelendiriyor"*, *"bir yapay zekâ tekniğinin/ürününün bizi bağımlı kılabileceğinden korkuyorum"*, *"bir yapay zekâ tekniğinin/ürününün kötü amaçlı kullanılabilirliğinden korkuyorum"* ve *"İnsansı yapay zekâ tekniklerini/ürünlerini (örneğin insansı robotları) ürkütücü buluyorum"* şeklindedir.

Çalışmada kullanılan ikinci ölçek Teknoloji Kaynaklı İşsizlik Endişesi Ölçeği'dir. Ölçek 3 boyut ve 12 maddeden meydana gelmiştir. Ölçek Civelek ve Pehlivanoglu (2020) tarafından geliştirilmiştir. Ölçeğin boyutları Teknik Beceri Eksikliği (4 madde), Sürekli Teknolojik Gelişmeler (4 madde) ve Yıkıcı Teknolojik Gelişmeler (4 madde) şeklindedir. Ölçek 5'li Likert şeklinde derecelendirilmiş ve 1= Kesinlikle Katılmıyorum, 5= Kesinlikle Katılıyorum'a karşılık gelmektedir. Ölçekte ters puanlanmış madde bulunmamakta ve ölçekten elde edilen puanın artması teknoloji kaynaklı işsizlik endişenin yüksek olması şeklinde açıklanmaktadır. Orijinal çalışmada iç tutarlılık güvenilirlik katsayıları teknik beceri eksikliği için .77, sürekli teknolojik gelişmeler için .82 ve yıkıcı teknolojik gelişmeler için .78 olarak bildirilmiştir. Ölçeğe ilişkin örnek maddeler, *"teknoloji geliştikçe performans olarak geri kalacağımı düşünüyorum"*, *"teknolojik gelişmelerden dolayı iş süreçlerindeki değişimin gelecekte beni mutsuz edeceğini düşünüyorum"* ve *"yeni çıkan teknolojilerden dolayı bundan sonraki hayatımı işsiz olarak geçirebileceğim endişesini taşıyorum"* şeklindedir.

Araştırmada ayrıca 5 sorudan (yaş, cinsiyet, medeni durum, kıdem, unvan) oluşan demografik bilgi formu da kullanılmıştır.

2.4. Veri Toplama ve Analiz Prosedürü

Belirlenen örneklemden veri toplamak için öncelikle Süleyman Demirel Üniversitesi Etik Kurulu'ndan 05 Mart 2024 tarih ve 146 toplantı sayılı kararı ile etik kurul onayı alınmıştır. Verilerin bir kısmı yüz yüze görüşme yolu ile diğer bir kısmı ise oluşturulan elektronik anket formu aracılığı ile toplanmıştır. Ulaşan 316 adet anket formundan 12 adeti gelişiğüz doldurulma, 8 adeti çok fazla cevaplanmamış soru bırakma ve 5 adeti de demografik bilgilere yer vermeme sebepleri ile elenmiş ve geriye 291 adet geçerli form kalmıştır.

Toplanan verilerin analizinde SPSS ve AMOS programlarından yararlanılmıştır. Veriler öncelikle SPSS'e girilmiş ve uç değer analizi yapılmıştır. Ardından boş hücrelere seri ortalamaları atanmış ve veri seti analize hazır hale getirilmiştir. Katılımcıların çalışmada kullanılan 2 değişkene yönelik tutumları aritmetik ortalama, standart sapma, çarpıklık ve basıklık katsayıları gibi betimsel istatistiklerle ortaya koyulmuştur. Kullanılan ölçeklerin yapısal geçerlilikleri doğrulayıcı faktör analizi (DFA) yoluyla sınanmıştır. Değişkenler arası ilişkiler Pearson korelasyon analizi, güvenilirliğe ilişkin katsayılar ise Cronbach Alpha iç tutarlılık katsayıları ile belirlenmiştir. Geliştirilen hipotezlerin sınanması için yapısal eşitlik modeli (YEM) kurularak yol analizi gerçekleştirilmiştir. Son olarak tek yönlü varyans analizi (ANOVA) ile yaş değişkeni açısından katılımcıların yapay zekâ kaygı düzeylerinin boyutlar bazında farklılaşma durumu incelenmiştir. Bu çalışmada tüm analizler %95 güvenilirlik seviyesi dikkate alınarak gerçekleştirilmiştir.

3. Bulgular

Çalışmanın bu kısmında alt başlıklar halinde öncelikle katılımcılara ilişkin demografik özelliklere ilişkin bulgular sunulacaktır. Takibinde ise toplanan verilerin geçerlilik ve güvenilirlik analizlerine ilişkin bilgilere yer verilecektir. Sonraki başlık altında ise çalışmada kullanılan 2 değişkene ait betimsel istatistikler incelenecek olup ayrıca boyutlar bazında ilişkiler de korelasyon analizi yoluyla verilecektir. Bir diğer başlık altında ise kurulan YEM modeli ile geliştirilen hipotezlerin test edilmesi yoluna gidilecektir. Son başlıkta ise katılımcıların yapay zekâ kaygılarının yaş değişkenine göre farklılaşma durumu test edilecektir.

3.1. Katılımcılara İlişkin Demografik Bulgular

Katılımcılara ilişkin demografik bulgular Tablo 1’de gösterilmiştir. Tablodan görülebileceği gibi katılımcıların %69.4 gibi önemli bir kısmı erkek muhasebe meslek mensuplarından oluşmaktadır. Katılımcıların %65.9’u evli olup yaş ortalamaları 38.83 (SS=10.93) olarak belirlenmiştir. Katılımcıların en küçüğü 22 en büyüğü 70 yaşındadır. Kıdem durumları açısından Tablo 1 incelendiğinde ortalama kıdem sürelerinin 14.82 (SS=10.33) yıl olduğu görülmektedir. En az kıdeme sahip çalışan 1 yıldır bu mesleği yapmaktayken en çok kıdeme sahip çalışanın ise kıdemi 41 yıldır. Son olarak Tablo 1’de unvanlarına göre meslek mensuplarının dağılımına bakıldığında, %59.5’inin SMMM, %25.1’inin SMMM Stajyeri, %14.8’inin SM ve %0.7’sinin ise YMM olarak görev yaptıkları tespit edilmiştir.

Tablo 1. Örneklemen Demografik Özellikleri (n=291)

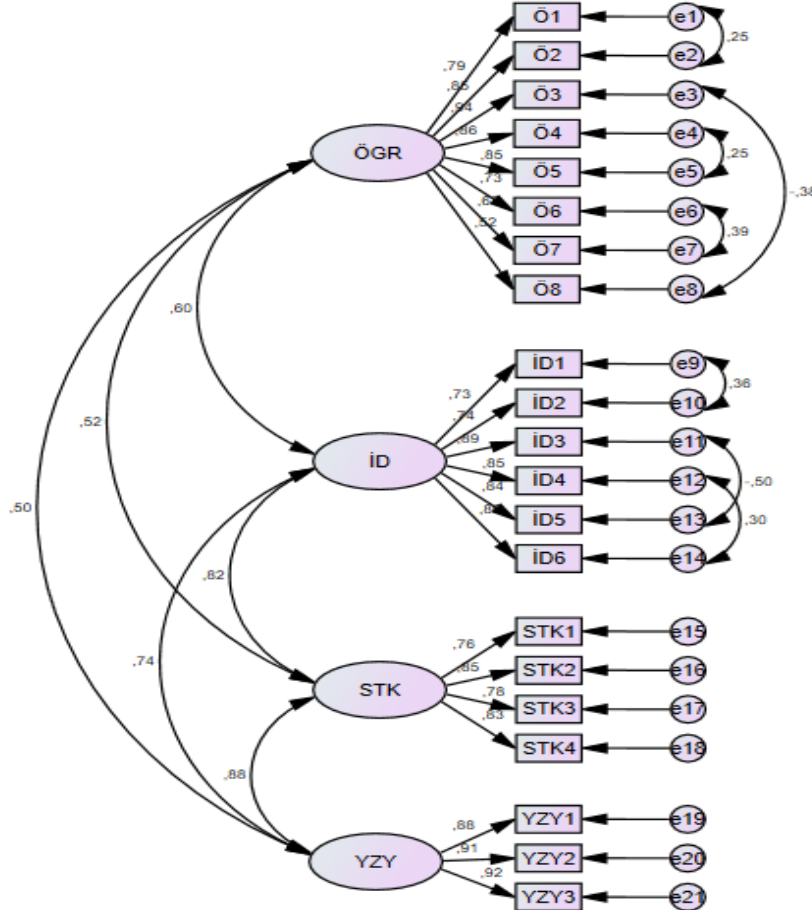
Özellikler	Frekans	Yüzde%
Cinsiyet		
Kadın	89	30.6
Erkek	202	69.4
Medeni Durum		
Evli	192	65.9
Bekar	99	34.1
Yaş		
Ort. = 38.83 (SS=10.93); Min.=22, Maks.=70		
Kıdem		
Ort. = 14.82 (SS=10.33); Min.=1, Maks.=41		
Unvan		
SMMM Stajyeri	73	25.1
SM	43	14.8
SMMM	173	59.5
YMM	2	0.7

Kaynak: Yazar tarafından oluşturulmuştur.

3.2. Geçerlilik ve Güvenilirlik Bulguları


Bu çalışmada geçerlilik analizleri AMOS programı kullanılarak gerçekleştirilen DFA ile sınanmıştır. Bu kapsamda çalışmada kullanılan ölçeklere ilişkin DFA program çıktıları Şekil 2 ve Şekil 3’te gösterilmiştir.

Şekil 2. Yapay Zekâ Kaygısı (YZK) Ölçeği DFA Sonuçları



Kaynak: Yazar tarafından oluşturulmuştur.

Şekil 3. Teknoloji Kaynaklı İşsizlik Endişesi (TKİE) Ölçeği DFA Sonuçları



Kaynak: Yazar tarafından oluşturulmuştur.

Şekil 2 ve Şekil 3 incelendiğinde görülebileceği gibi her bir ölçeğin tüm boyutlarında madde faktör yükleri .50'nin üzerinde gerçekleşmiştir. İki ölçekte orijinal halleri ile doğrulanmış ve hiçbir madde analiz dışına çıkartılmamıştır. Uyum iyiliği değerlerini iyileştirebilmek için programın önerdiği modifikasyonlar gerçekleştirilmiştir. Bu kapsamda yapay zekâ kaygısı ölçeği için 7, teknoloji kaynaklı işsizlik endişesi ölçeği için ise 2 modifikasyon yapılmıştır. Tablo 2'de modifikasyonlar neticesinde ulaşılan uyum iyiliği değerlerine yer verilmiştir.

Tablo 2. Uyum Değerleri

Değişkenler	χ^2/sd	CFI	IFI	NFI	GFI	TLI	RMSEA
YZK	2,208	.96	.96	.93	.90	.95	.065
TKİE	2,532	.94	.94	.91	.93	.92	.059

Kaynak: Yazar tarafından oluşturulmuştur.

Tablo 2 incelendiğinde görülebileceği gibi, araştırmada kullanılan her iki ölçeğin de uyum iyiliği değerlerinin kabul edilebilir uyum seviyesinde olduğu tespit edilmiştir. Kabul edilebilir uyum istatistikleri için $2 \leq \chi^2 / sd \leq 3$ (Kline, 2011), $.90 \leq CFI, IFI, NFI, GFI, TLI \leq .95$ (Baumgartner ve Homburg, 1996; Bentler, 1980; Bentler ve Bonett, 1980; Marsh vd., 2006) ve $.05 \leq RMSEA \leq .08$ (Browne ve Cudeck, 1993) eşik değerleri baz alınmıştır.

Güvenilirlik analizi için gerçekleştirilen testlerde, α katsayılarının eşik değer olarak kabul edilen .70'in üzerinde oldukları tespit edilmiştir (Hair vd., 2010; Nunnally, 1978). Bu katsayılar bir sonraki başlıkta yer alan Tablo 3'te verilmiştir.

Bu analizler neticesinde, ölçeklerin geçerlilik ve güvenilirlik açısından herhangi bir sorun teşkil etmedikleri söylenebilir.

3.3. Betimsel İstatistikler ve Değişkenler Arası İlişkiler

Çalışmada bu başlık altında, kullanılan değişkenlerin boyutlar bazında ortalama, standart sapma, çarpıklık ve basıklık gibi betimsel istatistikleri verilmiştir. Ayrıca yine boyutlar bazındaki ilişkileri ortaya koyabilmek adına Pearson korelasyon analizi gerçekleştirilmiştir. Elde edilen sonuçlar Tablo 3'te gösterilmiştir.

Tablo 3. Boyutlar Arası İlişkiler

Değişkenler	1	2	3	4	5	6	7
1. ÖĞR	(.92)						
2. İD	.592**	(.92)					
3. STK	.484**	.744**	(.88)				
4. YZY	.483**	.686**	.786**	(.93)			
5. TBE	.441**	.318**	.273**	.356**	(.74)		
6. STG	.534**	.516**	.402**	.473**	.614**	(.78)	
7. YTG	.413**	.400**	.292**	.389**	.475**	.574**	(.80)
Ort.	2.57	4.10	4.38	3.97	2.11	2.49	2.19
SS	1.389	1.801	1.723	1.948	.978	1.030	1.033
Çarpıklık	.830	-.046	-.290	-.019	-.785	.414	.732
Basıklık	-.082	-.946	-.852	-1.181	.117	-.523	-.260

Kaynak: Yazar tarafından oluşturulmuştur.

Tablo 3'te öncelikle değişkenlerin almış oldukları aritmetik ortalamalar değerlendirilmiştir. Yapay zekâ kaygısı için ölçeğin bütünü ele alınarak gerçekleştirilen analizde, katılımcıların kaygı seviyeleri 3.55 (SS= 1.398) düzeyinde tespit edilmiştir. Ölçeğin derecelendirilmesinin 7'li Likert tarzında olduğu düşünüldüğünde, muhasebe meslek mensuplarının orta seviyeye yakın bir yapay zekâ kaygısı taşıdıkları değerlendirilmiştir. Boyutlar bazında bu kaygı düzeyleri değerlendirildiğinde, sosyoteknik körlük boyutunun 4.38 (SS= 1.723) ortalama ile en yüksek kaygı izlenen boyut olduğu görülmüştür. Katılımcıların yapay zekâ ekseninde en düşük kaygı taşıdıkları boyut ise 2.57 (SS= 1.389) ortalama ile öğrenme boyutu olmuştur.

Yine Tablo 3'te teknoloji kaynaklı işsizlik endişesi değişkeni açısından durum değerlendirildiğinde, ölçeğin bütünü için 2.26 (SS= .850) ortalama değer elde edilmiştir. Ölçeğin derecelendirilmesinin 5'li Likert tarzında olduğu düşünüldüğünde, muhasebe meslek mensuplarının orta seviyeden daha az teknoloji kaynaklı işsizlik endişesi taşıdıkları şeklinde yorumlanmıştır. Boyutlar bazında katılımcıların teknoloji kaynaklı işsizlik endişeleri değerlendirildiğinde, en yüksek endişe seviyesinin 2.49 (SS= 1.030) ortalama ile sürekli teknolojik gelişmeler boyutunda olduğu tespit edilmiştir. Katılımcıların bu bağlamda en düşük endişe taşıdıkları boyut ise 2.11 (SS= .978) ortalama değer ile teknik beceri eksikliği boyutu olmuştur.


Tablo 3'te görülebileceği gibi verilerin normal varsayımlarını sınamak maksadıyla çarpıklık ve basıklık katsayıları hesaplanmıştır. Bu katsayıların ± 2 sınırları içerisinde olması beklenmektedir (Tabachnick ve Fidell, 2013). Bu kapsamda değişkenlere ilişkin çarpıklık katsayıları -.785 ile .830, basıklık katsayıları ise -1.181 ile .117 aralıklarında değişmektedir. Bu sonuçlardan yola çıkılarak verilerin normal dağılım gösterdiği sonucuna ulaşılmıştır.

Tablo 3'te ayrıca değişkenler arası ilişkiler boyutlar bazında incelenmiştir. Bu kapsamda yapay zekâ kaygısının tüm boyutları ile teknoloji kaynaklı işsizlik endişesinin tüm boyutları arasındaki ilişkiler pozitif yönlü ve .01 seviyesinde anlamlı olarak tespit edilmiştir. Detaylara bakıldığında öğrenme boyutu ile; teknik beceri eksikliği ($r = .441, p < .01$), sürekli teknolojik gelişmeler ($r = .534, p < .01$) ve yıkıcı teknolojik gelişmeler ($r = .413, p < .01$) boyutları arasında pozitif yönlü ve anlamlı ilişkiler belirlenmiştir. Yine benzer şekilde iş değişimi boyutu ile; teknik beceri eksikliği ($r = .318, p < .01$), sürekli teknolojik gelişmeler ($r = .516, p < .01$) ve yıkıcı teknolojik gelişmeler ($r = .400, p < .01$) boyutları arasında da pozitif yönlü ve anlamlı ilişkiler görülmüştür. Sosyoteknik körlük boyutu açısından da aynı durum söz konusu olup bu boyut ile; teknik beceri eksikliği ($r = .273, p < .01$), sürekli teknolojik gelişmeler ($r = .402, p < .01$) ve yıkıcı teknolojik gelişmeler ($r = .292, p < .01$) boyutları arasında pozitif yönlü ve anlamlı ilişkiler tespit edilmiştir. Son olarak yapay zekâ yapılandırması boyutu ile; teknik beceri eksikliği ($r = .356, p < .01$), sürekli teknolojik gelişmeler ($r = .473, p < .01$) ve yıkıcı teknolojik gelişmeler ($r = .389, p < .01$) boyutları arasında da pozitif yönlü ve anlamlı ilişkiler raporlanmıştır.

3.4. Hipotez Testleri

Çalışma kapsamında geliştirilen hipotezler, AMOS programı aracılığı ile kurulan yapısal model yardımıyla analiz edilmiştir. Bu doğrultuda gerçekleştirilen yol analizine ilişkin gösterim Şekil 4'te verilmiştir.

Şekil 4. Yapısal Modele İlişkin Yol Analizi Gösterimi



Kaynak: Yazar tarafından oluşturulmuştur.

Şekil 4'te şekilsel gösterimi verilen yapısal modelin uyum iyiliği indeksleri değerlendirildiğinde, modelin kabul edilebilir seviyede uyum sağladığı tespit edilmiştir. Buna göre $\chi^2 /sd= 2,073$, CFI= .93, IFI= .93, NFI= .91, GFI= .84, TLI= .92, RMSEA= .061 şeklinde uyum istatistikleri raporlanmıştır. Bu uyum indekslerinden sadece GFI yukarıda belirtilen eşik değer olan .90'ın altında bir değer elde etmiştir. Baumgartner ve Homburg (1996) GFI değerinin .90'ı aşmasa da gerekliliği sağladığını ifade etmişlerdir. Yine benzer şekilde Doll, ve arkadaşları (1994) da GFI değeri .80'in üzerindeyse kabul edilebilir olduğunu belirtmişlerdir.

Yol analizi neticesinde ulaşılan sonuçlar ve hipotezlerin desteklenme durumları Tablo 4'te gösterilmiştir.

Tablo 4. Yol Analizi Sonuçları

Yol		β	SH	Hipotez	Sonuç	
ÖĞR	→	TBE	.398**	.089	H ₁	Desteklendi
ÖĞR	→	STG	.333*	.103	H ₂	Desteklendi
ÖĞR	→	YTG	.201	.124	H ₃	Desteklenmedi
İD	→	TBE	1.416***	.239	H ₄	Desteklendi
İD	→	STG	2.029***	.294	H ₅	Desteklendi
İD	→	YTG	1.870***	.338	H ₆	Desteklendi
STK	→	TBE	-3.528***	.522	H ₇	Desteklenmedi
STK	→	STG	-4.180***	.631	H ₈	Desteklenmedi
STK	→	YTG	-4.045***	.725	H ₉	Desteklenmedi
YZY	→	TBE	2.504***	.281	H ₁₀	Desteklendi
YZY	→	STG	2.903***	.337	H ₁₁	Desteklendi
YZY	→	YTG	2.800***	.388	H ₁₂	Desteklendi

*** $p < .001$; ** $p < .01$; * $p < .05$. ÖĞR= Öğrenme, İD= İş Değişimi, STK= Sosyoteknik Körlük, YZY= Yapay Zekâ Yapılandırması, TBE= Teknik Beceri Eksikliği, STG= Sürekli Teknolojik Gelişmeler, YTG= Yıkıcı Teknolojik Gelişmeler.

Kaynak: Yazar tarafından oluşturulmuştur.

Tablo 4 incelendiğinde yapay zekâ kaygısının öğrenme boyutunun, teknoloji kaynaklı işsizlik endişesinin teknik beceri eksikliği ($\beta = .398$; $p < .01$) ve sürekli teknolojik gelişmeler ($\beta = .333$; $p < .05$) boyutlarını pozitif ve anlamlı şekilde etkilediği tespit edilmiştir. Öğrenme boyutunun yıkıcı teknolojik gelişmeler boyutu üzerindeki etkisi ise anlamlı değildir ($\beta = .201$; $p > .05$). Bu bulguların ışığında Akçakanat (2024).

çalışmanın ilk iki hipotezi desteklenirken üç numaralı hipotez desteklenmemiştir.

Tablo 4’te görülebileceği gibi yapay zekâ kaygısının iş değişimi boyutunun, teknoloji kaynaklı işsizlik endişesinin teknik beceri eksikliği ($\beta= 1.416$; $p<.001$), sürekli teknolojik gelişmeler ($\beta= 2.029$; $p<.001$) ve yıkıcı teknolojik gelişmeler ($\beta= 1.870$; $p<.001$) boyutlarını pozitif ve anlamlı şekilde etkilediği tespit edilmiştir. Bu doğrultuda çalışmanın dört, beş ve altı numaralı hipotezleri desteklenmiştir.

Yine Tablo 4’e bakıldığında yapay zekâ kaygısının sosyoteknik körlük boyutunun, teknoloji kaynaklı işsizlik endişesinin teknik beceri eksikliği ($\beta= -3.528$; $p<.001$), sürekli teknolojik gelişmeler ($\beta= -4.180$; $p<.001$) ve yıkıcı teknolojik gelişmeler ($\beta= -4.045$; $p<.001$) boyutları üzerinde negatif yönde ve anlamlı bir etkisi olduğu tespit edilmiştir. Bu kapsamda çalışmanın yedi, sekiz ve dokuz numaralı hipotezleri desteklenmemiştir.

Tablo 4’te ayrıca, yapay zekâ yapılandırması boyutunun, teknoloji kaynaklı işsizlik endişesinin teknik beceri eksikliği ($\beta= 2.504$; $p<.001$), sürekli teknolojik gelişmeler ($\beta= 2.903$; $p<.001$) ve yıkıcı teknolojik gelişmeler ($\beta= 2.800$; $p<.001$) boyutlarını pozitif ve anlamlı bir şekilde etkilediği tespit edilmiştir. Bu bağlamda çalışmanın on, on bir ve on iki numaralı hipotezleri desteklenmiştir.

3.5. Fark Analizi

Çalışmada bu başlık altında, muhasebe meslek mensuplarının yapay zekâ kaygı düzeylerinin alt boyutlar bazında yaş değişkenine göre farklılaşp farklılaşmadığı tespit edilmeye çalışılmıştır. Bu kapsamda tek yönlü varyans analizi (ANOVA) gerçekleştirilmiş ve ortaya çıkan farkın kaynağını belirlemek amacıyla da post-hoc testleri uygulanmıştır. Varyansların eşit olduğu durumda post-hoc testlerinden Bonferroni, eşit olmadığı durumda ise Tamhane’s T2 ile analizler gerçekleştirilmiştir. Elde edilen sonuçlara ilişki bilgileri Tablo 5’te gösterilmiştir.

Tablo 5. Fark Analizi Sonuçları

Boyutlar	Yaş Grupları	n	Ort.	SS	Test Değerleri		Post-Hoc Testi
					F	p	
ÖĞR	30 Yaş Altı	81	2.23	1.154	4.387	.013	3-1,2
	30-45 Arası	125	2.59	1.411			
	45 Yaş Üstü	85	2.86	1.501			
İD	30 Yaş Altı	81	3.91	1.695	3.453	.033	3-1,2
	30-45 Arası	125	3.95	1.857			
	45 Yaş Üstü	85	4.53	1.847			
STK	30 Yaş Altı	81	4.04	1.744	5.960	.003	3-1,2
	30-45 Arası	125	4.24	1.670			
	45 Yaş Üstü	85	4.89	1.682			
YZY	30 Yaş Altı	81	3.68	1.726	5.062	.007	3-1,2
	30-45 Arası	125	3.77	2.038			
	45 Yaş Üstü	85	4.52	1.919			

Kaynak: Yazar tarafından oluşturulmuştur.

Tablo 5 incelendiğinde, yapay zekâ kaygısının dört alt boyutunda da yaş değişkenine göre istatistiksel olarak anlamlı farklılıklar görülmektedir. Farkın kaynağını anlamaya yönelik gerçekleştirilen post-hoc testlerinde ise farkın tüm boyutlarda 45 yaş ve üzeri grupta yer alan muhasebe meslek mensuplarının, diğer iki gruba nazaran (30 yaş altı ve 30-45 yaş arası) daha yüksek ortalamalar elde etmelerinden kaynaklandığı tespit edilmiştir.

Sonuç ve Tartışma

Çalışma sonuçları değerlendirildiğinde öncelikle muhasebe meslek mensuplarında yapay zekâ kaygı düzeyinin orta seviye civarlarında olduğu tespit edilmiştir. Katılımcılar yoğun denilebilecek bir kaygı yaşamamaktadır. Boyutlar bazında bakıldığında katılımcıların en yüksek kaygı yaşadıkları boyut sosyoteknik körlük olmuştur. Bu boyut yapay zekânın kontrolden çıkmasına yönelik “bir yapay zekâ tekniğinin/ürününün kontrolden çıkabilir ve arızalanabilir olacağından korkuyorum” tarzında maddeler içermektedir. Bu bağlamda katılımcıların gerek kamuoyundaki yapay zekâ ile ilgili tartışmalardan gerekse de film ve dizilerde bu konunun son yıllarda çokça işlenmesinden etkilendikleri düşünülmektedir. Katılımcıların yapay zekâ kaygısının en düşük olduğu boyut ise öğrenme boyutudur. Bu boyut yapay zekâ teknik ya da ürünlerini anlamaya, öğrenmeye veya kullanmaya yönelik “yapay zekâ tekniklerini/ürünlerini kullanmayı öğrenmek beni endişelendiriyor” tarzında maddeler içermektedir. Bu kapsamda ortaya çıkan sonuç, katılımcıların yapay zekâ teknik ya da ürünlerine yönelik böyle bir endişe taşımadıkları şeklinde değerlendirilmiştir. Terzi (2020) gerçekleştirdiği ölçek uyarlama çalışmasında da bu çalışmayla aynı sonuçlara ulaşmıştır. Başer ve arkadaşlarının (2021) Türkiye’de görev yapan aile hekimleri örnekleminde gerçekleştirdikleri çalışmada da sosyoteknik körlük en yüksek kaygı duyulan boyut iken en düşük kaygı ise yine öğrenme boyutunda çıkmıştır. Ergin ve arkadaşlarının (2023) Türkiye’de bir eğitim ve araştırma hastanesinde görev yapan ameliyathane hemşireleri örnekleminde gerçekleştirdikleri çalışmada da sosyoteknik körlük boyutu en yüksek kaygı duyulan boyut olmuştur. Suseno ve arkadaşlarının (2022) Çin’de insan kaynakları yöneticileri örnekleminde

gerçekleştirdikleri çalışmada katılımcıların yapay zekâ kaygı düzeylerinin düşük sayılabilecek bir seviyede gerçekleştiği tespit edilmiştir.

Bu çalışmada geliştirilen 12 hipotezden 8'i desteklenmiştir. Yapay zekâ kaygısının öğrenme boyutunun, teknoloji kaynaklı işsizlik endişesinin teknik beceri eksikliği ve sürekli teknolojik gelişmeler boyutlarını pozitif ve anlamlı bir şekilde etkilediği belirlenmiştir. Yapay zekâyâ ilişkin teknik ve ürünleri öğrenmeye yönelik kaygı seviyesinin artması ile birlikte katılımcılar daha yüksek seviyede teknik beceri eksikliği hissetmekte ve meydana gelen sürekli teknolojik gelişmelere ayak uyduramama endişeleri de bu bağlamda yükselmektedir. Çalışmanın bir başka sonucu yapay zekâ kaygısının iş değişimi boyutunun, teknoloji kaynaklı işsizlik endişesinin tüm boyutları üzerinde pozitif yönde ve anlamlı bir etkisinin olduğudur. Bu doğrultuda iş değişimi boyutu, yapay zekâ teknik ve ürünlerinin ya da insansı robotların gelecekte insanların işlerini ellerinden alabileceğine yönelik ifadeler içeren bir boyuttur. Bu boyuttaki kaygı seviyesinin yükselmesi ile katılımcıların teknolojik gelişmelere uyum sağlayamayacağı, işyerinde kendisine olan ihtiyacın zamanla azalacağı ve nihayetinde bundan sonraki hayatını işsiz olarak geçirebileceğine yönelik endişeleri de artmaktadır. Yapay zekâ kaygısının yapay zekâ yapılandırması boyutunun, teknoloji kaynaklı işsizlik endişesinin tüm boyutları üzerinde pozitif yönde ve anlamlı bir etkisinin olduğu çalışmada ulaşılan diğer bir sonuçtur. Bu boyut insansı yapay zekâ teknikleri ya da ürünlerinden özellikle insansı robotlar bağlamında yaşanan kaygıyı ifade etmektedir. Bu boyutta kaygı seviyesinin yükselmesi ile katılımcıların teknoloji kaynaklı işsizlik endişesinin tüm boyutlarındaki endişe düzeyleri de artmaktadır. Bu sonucun ortaya çıkmasında, katılımcıların insansı robotlar ile yarışabilecek düzeyde teknik bilgiye ulaşamayacakları, meydana gelen sürekli teknolojik gelişmelere ayak uyduramayacakları ve insansı robotların onların yerlerini alabileceğine olan inançlarının etkili olduğu düşünülmektedir. Çalışmada yapay zekâ kaygısının sosyoteknik körlük boyutu, teknoloji kaynaklı işsizlik endişesinin tüm boyutlarını anlamlı bir şekilde etkilemiş ancak etkinin yönü negatif olarak gerçekleşmiştir. Bu kapsamda da geliştirilen üç hipotez desteklenmemiştir. Sosyoteknik körlük yukarıda da bahsedildiği gibi katılımcıların en yüksek kaygı taşıdıkları boyuttur. Bu boyut yapay zekâ teknik ya da ürününün uygun olmayan amaçlarla kullanılabilirliği, kötü ellere düşüp ya da kontrolden çıkıp özerkliğine ilan edebileceğine yönelik kaygıları ifade etmektedir. Katılımcılar muhtemelen, böyle durumlarla karşılaşılması halinde gerekli kişiler/merciler tarafından yapay zekâ teknik ya da ürününün işlem dışı bırakılabileceği ve dolayısı ile yapay zekâ teknolojisinin yaratacağı işsizlik endişesinin de ortadan kalkabileceğini düşünmektedir. Etkinin yönünün negatif olması bu şekilde açıklanabilir görülmektedir.

Çalışmada son olarak ulaşılan sonuç ise yapay zekâ kaygısının tüm boyutlarında yaş artışı ile birlikte kaygı seviyesinin yükselmesidir. Yaş grupları bağlamında gerçekleştirilen tek yönlü varyans analizinde gruplar arasında anlamlı farklılıklar tespit edilmiştir. Özbek (2024) tarafından muhasebe meslek mensupları örnekleminde ulusal yazında gerçekleştirilen tek çalışmada ise yaş gruplarına göre yapay zekâ kaygı düzeyleri bakımından anlamlı bir farklılık tespit edilememiştir.

Çalışmanın birtakım kısıtları bulunmaktadır. Öncelikle ulaşılabilen örneklem sayısı Türkiye geneli muhasebe meslek mensuplarını temsil etmekten uzaktır ve sonuçların genellenebilme imkânı yoktur. Veriler, katılımcıların öz bildirimine dayalı olarak toplanmıştır. Bu bağlamda katılımcıların gerçek düşüncelerini forma yansıttıkları varsayılmaktadır. Araştırma verilerinin tek bir zaman diliminde kesitsel olarak toplanması da bir diğer kısıt olarak karşımıza çıkmaktadır.

Takip eden çalışmalarda araştırmacılara, Türkiye'deki tüm muhasebe meslek mensuplarını temsil eden bir örneklem ile benzer çalışmayı gerçekleştirmeleri önerilmektedir. Ayrıca gerçekleştirilecek boyamsal çalışmalar ile yapay zekâ kaygısındaki değişimin izlenmesi de bir başka öneri olarak değerlendirilebilir. Yine benzer örnekleimde, kuşaklar bağlamında yapay zekâyâ yönelik genel tutumlar, yapay zekâ hazır bulunuşluğu, yapay zekâ farkındalığı, yapay zekâ okuryazarlığı, üretken yapay zekâ kabulü gibi konuları çalışmaları araştırmacılara önerilebilir. Son bir öneri olarak ise nitel araştırma ya da karma araştırma deseni kullanılarak muhasebe meslek mensupları ile çalışmalar gerçekleştirilmesi daha derinlemesine bilgi elde edilmesine için tavsiye edilebilir.

Uygulamacılar yani muhasebe meslek mensupları bağlamında da birtakım öneriler sunulabilir. Yapay zekânın verimliliğinin cazibesi yadsınamazken, yapay zekânın kopyalayamayacağı muhakeme gücü, sezgi ve etik gibi insani unsurların korunması bir zorunluluktur. Bu bağlamda mevcut ya da potansiyel muhasebe meslek mensuplarının bu becerileri kazanması, onların gelecekte de bu mesleği devam ettirebilmeleri için önemlidir.



This research article has been licensed with Creative Commons Attribution - Non-Commercial 4.0 International License. Bu araştırma makalesi, Creative Commons Atıf - Gayri Ticari 4.0 Uluslararası Lisansı ile lisanslanmıştır.

Yazar Katkıları

Yazar çalışmayı tek başına hazırladığını beyan etmiştir.

Teşekkür Beyanı

Yazar teşekkür beyanında bulunmamıştır.

Destek Beyanı

Yazar destek beyanında bulunmamıştır.

Çıkar Çatışması

Yazar herhangi bir çıkar çatışması beyan etmemiştir.

Etik Beyanı

Yazar çalışma için Süleyman Demirel Üniversitesi'nden 05/03/2024 tarih ve 146/8 sayılı karar ile Etik Kurul Onayı alındığını beyan etmiştir.

Sorumlu Özel Sayı Editörleri

Doç. Dr. Beyza Mina Ordu-Akkaya, Ankara Sosyal Bilimler Üniversitesi

Doç. Dr. Görkem Ataman, Yaşar Üniversitesi

Arş. Gör. Yunus Yıldırım, Afyon Kocatepe Üniversitesi

Kaynakça/References

- Akhter, A., & Sultana, R. (2018). Sustainability of accounting profession at the age of fourth industrial revolution. *International Journal of Accounting and Financial Reporting*, 8(4), 139-158. <https://doi.org/10.5296/ijafr.v8i4.13689>
- Baser, A., Baktir Altuntaş, S., Kolcu, G., & Özceylan, G. (2021). Artificial intelligence anxiety of family physicians in Turkey. *Progress in Nutrition*, 23(S2), e2021275. <https://doi.org/10.23751/pn.v23iS2.12003>
- Baumgartner, H., & Homburg, C. (1996). Applications of structural equation modeling in marketing and consumer research: A review. *International Journal of Research in Marketing*, 13(2), 139-161. [https://doi.org/10.1016/0167-8116\(95\)00038-0](https://doi.org/10.1016/0167-8116(95)00038-0)
- Bentler, P. M. (1980). Multivariate analysis with latent variables: Causal modeling. *Annual Review of Psychology*, 31, 419-456. <https://doi.org/10.1146/annurev.ps.31.020180.002223>
- Bentler, P. M., & Bonett, D. G. (1980). Significance tests and goodness of fit in the analysis of covariance structures. *Psychological Bulletin*, 88, 588-606. <https://doi.org/10.1037/0033-2909.88.3.588>
- Brabete, V., & Goagara, D. (2022). Digitalization—a danger to accounting professionals. *Journal of Corporate Governance, Insurance and Risk Management*, 9(1), 25-48. <https://doi.org/10.51410/jcgirm.9.1.3>
- Browne, M. W., & Cudeck, R. (1993). Alternative ways of assessing model fit. In K. A. Bollen & J. S. Long (Eds.), *Testing structural equation models* (pp. 136-162). Beverly Hills, CA: Sage.
- Civelek, M. E., & Pehlivanoglu, M. Ç. (2020). Technological unemployment anxiety scale development. *Eurasian Business & Economics Journal*, 22, 64-76. <http://dx.doi.org/10.17740/eas.econ.2020.V22-05>
- Doll, W. J., Xia, W., & Torkzadeh, G. (1994). A confirmatory factor analysis of the end-user computing satisfaction instrument. *MIS Quarterly*, 18(4), 357-369. <https://doi.org/10.2307/249524>
- Ergin, E., Karaarslan, D., Şahan, S., & Bingöl, Ü. (2023). Can artificial intelligence and robotic nurses replace operating room nurses? The quasi-experimental research. *Journal of Robotic Surgery*, 17, 1847-1855. <https://doi.org/10.1007/s11701-023-01592-0>
- Frey, C. B., & Osborne, M. A. (2017). The future of employment: How susceptible are jobs to computerisation?. *Technological Forecasting and Social Change*, 114, 254-280. <http://dx.doi.org/10.1016/j.techfore.2016.08.019>
- Greenman, C. (2017). Exploring the impact of artificial intelligence on the accounting profession. *Journal of Research in Business, Economics, and Management*, 8(3), 1451-1454.
- Griffin, O. (2016). How artificial intelligence will impact accounting. 10 Mart tarihinde <https://www.icaew.com/technical/technology/artificial-intelligence/artificial-intelligence-articles/how-artificial-intelligence-will-impact-accounting> adresinden edinilmiştir.
- Hair, J. F., Black, W. C., Babin, B. J., & Anderson, R. E. (2010). *Multivariate data analysis* (7th ed.). Upper Saddle River, NJ: Prentice-Hall.
- Hopcan, S., Türkmen, G., & Polat, E. (2023). Exploring the artificial intelligence anxiety and machine learning attitudes of teacher candidates. *Education and Information Technologies*. <https://doi.org/10.1007/s10639-023-12086-9>
- Kaplan, A., & Haenlein, M. (2019). Siri, Siri, in my hand: Who's the fairest in the land? on the interpretations, illustrations, and implications of artificial intelligence. *Business Horizons*, 62(1), 15-25. <https://doi.org/10.1016/j.bushor.2018.08.004>
- Kline, R. B. (2011). *Principles and practice of structural equation modeling*. New York: The Guilford Press.
- ManpowerGroup. (2016). The skills revolution: Digitization and why skills and talent matter. https://www.manpowergroup.co.uk/wp-content/uploads/2017/01/the-skills-revolution_lo.pdf
- Marks, G. (2024, January 1). The (very) emerging role of AI in the accounting industry. *Forbes*. <https://www.forbes.com/sites/quickerbetteertech/2024/01/01/the-very-emerging-role-of-ai-in-the-accounting-industry/?sh=657a0063190f>
- Marsh, H. W., Hau, K. T., Artelt, C., Baumert, J., & Peschar, J. L. (2006). OECD's brief self-report measure of educational psychology's most useful affective constructs: Cross-cultural, psychometric comparisons across 25 countries. *International Journal of Testing*, 6(4), 311-360. https://doi.org/10.1207/s15327574ijt0604_1
- Nunnally, J. (1978). *Psychometric theory* (2nd ed.). New York, NJ: McGraw-Hill.
- Oliver, B. (2023, November 15). How artificial intelligence can help save accounting. 10 Mart 2024 tarihinde <https://www.journalofaccountancy.com/news/2023/nov/how-artificial-intelligence-can-help-save-accounting.html> adresinden edinilmiştir.
- Özbek, A. (2024). Muhasebe meslek mensuplarının yapay zekâ kaygılarının gelecekte istihdam edilebilirlik algıları üzerine bir çalışma. *Alanya Akademik Bakış*, 8(1), 254-267. <https://doi.org/10.29023/alanyaakademik.1329511>.

- Paderanga, C. C., Soni, A., & Nisa, N. (2023). Artificial intelligence adoption among accountants in the UAE: An integrated AI acceptance-avoidance model. *Global Scientific and Academic Research Journal of Economics, Business and Management*, 2(11), 61-86.
- Peng, Y., & Chang, J. S. (2019). An exploration on the problems of replacing accounting professions by AI in the future. In *Proceedings of the 5th International Conference on Industrial and Business Engineering* (pp. 378-382). The Hong Kong Polytechnic University, Hong Kong. <https://doi.org/10.1145/3364335.3364345>
- Prigg, M. (2019, January 2). Will an AI take your job in 2019? China's leading expert warns it will take over half of jobs within 15 years (and reveals the most at risk careers). *Daily Mail*. <https://www.dailymail.co.uk/sciencetech/article-6473413/Will-AI-job-Expert-reveals-risk-careers.html>
- Rawashdeh, A. (2023). The consequences of artificial intelligence: An investigation into the impact of AI on job displacement in accounting. *Journal of Science and Technology Policy Management*. Vol. ahead-of-print No. ahead-of-print. <https://doi.org/10.1108/JSTPM-02-2023-0030>
- Saleem, I., Abdeljawad, I., & Nour, A. I. (2023). Artificial intelligence and the future of accounting profession: Implications and challenges. In A. Hannon & A. Mahmood (Eds.), *Artificial intelligence, internet of things, and society 5.0* (pp. 327-336). Cham: Springer Nature Switzerland.
- Suseno, Y., Chang, C., Hudik, M., & Fang, E. S. (2022). Beliefs, anxiety and change readiness for artificial intelligence adoption among human resource managers: The moderating role of high-performance work systems. *The International Journal of Human Resource Management*, 33(6), 1209-1236. <https://doi.org/10.1080/09585192.2021.1931408>
- Tabachnick, B. G., & Fidell, L. S. (2013). *Using multivariate statistics* (6th ed.). Boston, MA: Pearson.
- Terzi, R. (2020). An adaptation of artificial intelligence anxiety scale into Turkish: reliability and validity study. *International Online Journal of Education and Teaching (IOJET)*, 7(4), 1501-1515.
- TÜRMOB. (2024, March 3). Meslek mensubu dağılım tablosu. 3 Mart tarihinde <https://www.turmob.org.tr/istatistikler/c8172e63-2bef-4919-a863-86e403bdfd0a/meslek-mensubu-dagilim-tablosu--sm-smmm-> adresinden edinilmiştir.
- Wang, Y. Y., & Wang, Y. S. (2022). Development and validation of an artificial intelligence anxiety scale: An initial application in predicting motivated learning behavior. *Interactive Learning Environments*, 30(4), 619-634. <https://doi.org/10.1080/10494820.2019.1674887>

Research Article (Special Issue) | Araştırma Makalesi (Özel Sayı)

Belirsiz kriter ağırlıkları altında yeni bir ÇKKV yöntemi: Yapay zekâ sohbet robotlarına (ChatGPT4, Copilot, Gemini) dayalı portföy seçimi üzerine bir uygulama

Furkan Göktaş
Fatih Güçlü

Dr. Öğr. Üyesi, Karabük Üniversitesi, furkangoktas@karabuk.edu.tr, [0000-0001-9291-3912](https://orcid.org/0000-0001-9291-3912)
Doç. Dr., Karabük Üniversitesi, fatihguclu@karabuk.edu.tr, [0000-0002-1007-4594](https://orcid.org/0000-0002-1007-4594)

Corresponding author/Sorumlu yazar: Fatih Güçlü ✉ fatihguclu@karabuk.edu.tr

Öz

Çok kriterli karar verme (ÇKKV) problemlerinin en tartışmalı noktası kriter ağırlıklandırmasıdır. Çünkü farklı kriter ağırlıkları genellikle farklı sonuçların ortaya çıkmasına neden olur. Bu çalışmanın amacı kriter ağırlıklarının belirsiz olduğu durumda ÇKKV problemlerini çözebilmek için yeni bir yöntem geliştirmektir. Bu kapsamda bu çalışmada Belirsiz Kriter Ağırlıklarıyla Olabilirlik Değerlendirme Sistemi (U-PES) önerilmiştir. Uzman bilgisinden (yapay zekâ sohbet robotlarından) ve geçmiş veriden yararlanılarak Borsa İstanbul'da işlem gören sekiz adet hisse senedi ile portföy oluşturmada U-PES kullanılmıştır. Buradaki kriterler; beklenen getiri, standart sapma ve Çevresel-Sosyal-Kurumsal Yönetim (ESG) bileşenleri olarak belirlenmiştir. Yapılan uygulamada uzman bilgisi ya da geçmiş veri ile elde edilen sonuçlar arasında genellikle pozitif ama yüksek düzeyde olmayan ilişki olduğu bulunmuştur.

Anahtar Kelimeler: Çok Kriterli Karar Verme, Portföy Seçimi, Sürdürülebilirlik, Yapay Zekâ, ChatGPT **JEL Kodları:** C61, D81, G11

A novel MCDM method under uncertain criteria weights: An application on portfolio selection based on artificial intelligence chatbots (ChatGPT4, Copilot, Gemini)

Abstract

The most controversial aspect of multi-criteria decision-making (MCDM) problems is criteria weighting. Because different criteria weights generally lead to different results. This study aims to develop a new method for solving MCDM problems with uncertain criteria weights. In this context, we propose the Possibilistic Evaluation System with Uncertain Criteria Weights (U-PES) in this study. We use U-PES to form a portfolio with eight stocks listed in Borsa Istanbul using expert knowledge (artificial intelligence chatbots) and historical data. Here, we determine the criteria as expected return, standard deviation, and Environmental-Social-Governance (ESG) components. In the application, we observe generally positive but not high-level relationships between the results obtained with expert knowledge or historical data.

Keywords: Multi-Criteria Decision Making, Portfolio Selection, Sustainability, Artificial Intelligence, ChatGPT **JEL Codes:** C61, D81, G11

Extended Summary

Multi-criteria decision-making (MCDM) methods are beneficial in various fields, such as portfolio selection. The complexity of investment decisions is higher when criteria weights are uncertain. This study aims to propose a novel MCDM method to work under this type of uncertainty. Thus, this study generalizes the MCDM method, the Possibilistic Evaluation System (PES) for uncertain criteria weights. The originality of this study is due to this. This study also contributes to the literature by expanding the application of possibility theory in financial decision-making and demonstrating the utility of AI-generated expert knowledge in portfolio selection.

PES combines the information derived from three elementary MCDM methods. Here, the maximin method reflects the pessimistic view, whereas the maximax method reflects the optimistic view. Here, the weighted sum method reflects a more rational view. PES uses the triangular fuzzy numbers and possibility theory for this unification. Possibility theory can be described as the simplest

How to cite this article / Bu makaleye atıf vermek için:

Göktaş, F. & Güçlü, F. (2024). Belirsiz kriter ağırlıkları altında yeni bir ÇKKV yöntemi: Yapay zekâ sohbet robotlarına (ChatGPT4, Copilot, Gemini) dayalı portföy seçimi üzerine bir uygulama. *KOCATEPEİİBFD*, 26(Özel Sayı), 68-80. <https://doi.org/10.33707/akuiibfd.1454952>

uncertainty theory.

We call this generalization the Possibilistic Evaluation System with Uncertain Criteria Weights (U-PES). U-PES overcomes the most controversial aspect of traditional MCDM methods: their results highly depend on the criteria weight vector. U-PES uniquely gives the alternatives' priority vector and criteria weight vector by solving a strictly concave maximization problem. The criteria weight vector is determined by the dual variables of this optimization problem, whereas the alternatives' priority vector is equal to the standardized version of its optimal solution. Since U-PES depends on a concave maximization problem, it requires special software for convex optimization, such as CVX.

We use the past data for eight stocks listed in Borsa Istanbul and expert knowledge (artificial intelligence chatbots) together to form portfolios with U-PES or equally weighted PES. Here, the artificial intelligence chatbots are ChatGPT, Copilot, and Gemini. The BIST codes of the stocks are ASELS, EREGL, KCHOL, PETKM, SASA, SISE, THYAO, and TUPRS. The criteria are expected return, standard deviation, and ESG components.

In the application, we observe generally positive but not high-level relationships between the results obtained with expert knowledge or past data. We also observe that U-PES and equally weighted PES give different but similar results. Using the entropy weights, we combine the U-PES results derived with different approaches. The stock weights are 0,1121 for ASELS, 0,0793 for EREGL, 0,3128 for KCHOL, 0,0824 for PETKM, 0,0442 for SASA, 0,2110 for SISE, 0,0598 for THYAO, and 0,0984 for TUPRS. We combine the equally weighted PES results derived with different approaches using the entropy weights. The stock weights are 0,1198 for ASELS, 0,0650 for EREGL, 0,3262 for KCHOL, 0,0779 for PETKM, 0,0297 for SASA, 0,1959 for SISE, 0,0723 for THYAO and 0,1132 for TUPRS.

The two main limitations of using MCDM methods in portfolio selection are that they are inadequate when short positions can be held in the portfolio and that the correlation structure of stocks cannot be taken into account. These two limitations also apply to this study. In addition, the total information obtained from the three elementary MCDM methods to which PES and U-PES are related constitutes a significant limitation for these methods. Future studies could develop different approaches to combine the results obtained differently. Additionally, U-PES can be used for MCDM problems other than portfolio selection.

Giriş

Harry Markowitz (1952) tarafından temelleri atılan modern portföy teorisi, risk-getiri dengesi ilkesine dayalı olarak, yatırımların riskinin çeşitlendirme yoluyla azaltılırken, belirli bir risk düzeyi için beklenen getirinin maksimize edilebileceğini ifade eder. Bu bağlamda yatırımcılar açısından, en uygun risk-getiri dengesini sağlayan portföyün seçimi önem arz etmektedir. Teoriye göre, tek başına yüksek getiri ve yüksek risk içeren bir hisse senedi, negatif korelasyon ilişkisine sahip olduğu hisse senetlerinden oluşturulan bir portföye dahil edildiğinde, portföyün riskini düşürmektedir. Portföyün riski, optimal hisse senedi sayısına ulaşıncaya kadar negatif korelasyonlu hisse senetlerinin dahil edilmesiyle hızlı bir şekilde düşmekte, bu sayının üzerinde eklenen hisse senetlerinin ise portföy riskine etkisi düşük olmaktadır. Negatif ya da düşük pozitif korelasyonlu hisse senetlerinden oluşturulan iyi çeşitlendirilmiş portföylerle, sistematik olmayan risk en aza indirilebilmektedir. Risk ve getiriye ek olarak farklı kriterler de dikkate alınmak istendiğinde portföy seçimi için Çok Kriterli Karar Verme (ÇKKV) teknikleri kullanılabilir. ÇKKV teknikleri alternatifler arasından önceden belirlenmiş kriterler çerçevesinde en uygun seçimin yapılmasına olanak vermektedir. Örneğin, Lopez-Garcia vd. (2023) UW-TOPSIS yöntemi ile hisse senetlerini karşılaştırmıştır. Bununla birlikte Saaty vd. (1980) hiyerarşik yapıları kullanarak, karar verme sürecindeki çeşitli faktörleri portföy seçimine entegre eden bir yöntem önermiştir.

Literatürdeki çalışmaların bir kısmında ise bulanık mantıktan yararlanan ÇKKV yöntemleri ile söz konusu probleme çözüm getirilmeye çalışılmıştır. Tiryaki ve Ahlatçioğlu (2009) bulanık analitik hiyerarşi sürecini (AHP), Poşpiech (2019) ise TOPSIS ve bulanık TOPSIS yöntemlerini kullanmıştır. Akbaş ve Dalkılıç (2021) üçgensel ve yamuksal bulanık sayılara dayalı iki aşamalı bir portföy seçim algoritması önermiştir. Narang vd. (2021), bulanık COPRAS yöntemini kullanarak çok kriterli bir portföy seçimi modeli geliştirmiştir. Bisht ve Kumar (2022), kriterlerin ağırlıklandırılmasının bulanık temel kriter (fuzzy Base-Criterion) yöntemi ile alternatiflerin seçiminin ise Dempster-Shafer teorisi ile gerçekleştirildiği hibrit bir yöntem önermiştir. Parkhid ve Mohammadi (2022), portföyde yer alacak hisse senetlerinin seçiminde veri zarflama yönteminin, hisse senedi ağırlıklarının ise bulanık ağırlık hedef programlama yöntemi ile belirlendiği bir yöntem ile portföy seçim problemi için bir çözüm sunmuştur. Yadav vd. (2023), özellikle sürdürülebilirlik performanslarına ilişkin yeterli bilgi bulunmayan yeni şirketlerin sürdürülebilirlik puanların hesaplanmasında ve bu şirketlerden oluşan bir portföy oluşturulmasında kullanılması amacıyla sezgisel bulanık mantığa dayalı bir yöntem önermişlerdir.

Portföy seçiminde ÇKKV yöntemlerinin kullanıldığı yukarıda bahsedilen makalelerde, kriter ağırlıkları farklı yöntemlerle belirlenmektedir. Kriter ağırlıklarını belirlemede kullanılan yöntem nesnel bir yöntem olsa bile hangi yöntemle kriter ağırlıklandırma yapılacağı öznel bir tercihtir. Dolayısıyla ÇKKV yöntemleriyle elde edilen sonuçlar söz konusu durumlarda öznel bir seçimi yansıtır. Buradaki öznellik önemli bir eleştiri konusudur (Bouslah vd., 2023). Bu nedenle TOPSIS yönteminde kriter

ağırlıklarının belirsiz olduğu durum için UW-TOPSIS yöntemi önerilmiştir (Liern ve Pérez-Gladish, 2022). Öte yandan bu yöntemde her bir alternatif için farklı kriter ağırlıklarının olması sorunu vardır (Lopez-Garcia vd., 2023).

Bu çalışmanın amacı, alternatiflerin öncelik vektörünü ve kriterlerin ağırlık vektörünü tek olarak verecek bir ÇKKV yöntemi önermektir. Bu nedenle bu çalışmada Gökteş ve Güçlü'nün (2024) önerdiği PES, belirsiz kriter ağırlıkları için genelleştirilmiştir. Söz konusu yeni yöntem Belirsiz Kriter Ağırlıklarıyla Olabilirlik Değerlendirme Sistemi (U-PES) olarak adlandırılmış ve portföy seçimi problemi için uygulanmıştır. Lopez-Garcia vd. (2023) ve Yadav vd.'ne (2023) benzer olarak buradaki kriterler beklenen getiri, risk (standart sapma) ve ESG bileşenleri (çevresel, sosyal ve yönetim skorları) olarak belirlenmiştir. Yine Yadav vd.'ne (2023) benzer olarak uzman bilgisi portföy seçiminde kullanılmıştır. Çünkü geçmiş veri geleceği yansıtmada yetersiz kalabilmektedir (Tanaka ve Guo, 1999). Bu çalışmanın Yadav vd.'nden (2023) temel farkları, kullanılan yöntemin belirsiz kriter ağırlıkları altında çalışabilmesi ve Pinochet vd. (2023) ile Svoboda ve Lande'yle (2024) benzer şekilde, uzman bilgisinin insanlar yerine yapay zekâ sohbet robotlarıyla (ChatGPT4, Copilot, Gemini) elde edilmesidir. Bu çalışmanın Lopez-Garcia vd.'nden (2023) temel farkları, kriterlerin ağırlık vektörünün tek olarak elde edilmesi ve geçmiş veriye ek olarak uzman bilgisinin kullanılmasıdır.

Çalışmada, geçmiş veriler ve yapay zekâ beklentileri doğrultusunda oluşturulan karar matrislerine dayalı hisse senedi ağırlıkları arasında, pozitif ve yüksek düzeyde olmayan bir ilişki olduğu saptanmıştır. Çalışmanın belirsiz kriter ağırlıkları altında çalışabilen ve tek bir ağırlık vektörü sağlayan bir yöntem önermesi, ayrıca yapay zekâ sohbet robotlarını uzman bilgisi olarak kullanması yönüyle literatüre katkı sağlayacağı düşünülmektedir.

Bu çalışmanın devamı şu şekilde organize edilmiştir. Birinci bölümde literatürdeki çalışmalar incelenmiştir. İkinci bölümde, PES yöntemi açıklandıktan sonra U-PES yöntemi ile ilgili teorik bilgiler verilmiştir. Üçüncü bölümde BIST Banka Dışı Likit 10 (X10XB) endeksinin bileşenleri olan sekiz farklı hisse senedi ile portföy oluşturmada PES ve U-PES ayrı ayrı kullanılmıştır. Son değerlendirmelerle çalışma sonuçlandırılmıştır.

1. Literatür Taraması

Yapay zekâ sohbet robotları, günlük hayatın her alanında kullanılmakta hem akademik çevreler hem de bireyler söz konusu robotlardan çok geniş amaçlarla yararlanmaktadır. Bu bağlamda ChatGPT, Copilot, Gemini ve benzerlerinin finansal kararlarda ve portföy seçiminde kullanımına ilişkin son yıllarda literatürdeki çalışmaların sayısı artmaktadır.

He vd. (2021), spesifik olarak portföy optimizasyonunda yararlanılması amacıyla bir yapay zekâ sohbet arayüzü önermiştir. Sohbet robotu, IBM Watson Asistanı, SS&C Algoritmik Portföy Optimizasyon Servisi ve Slack gibi servisleri kullanarak tasarlanmıştır. Bu çalışmada da kullanılan ChatGPT'nin yatırım kararlarında özellikle sınırlı finansal tecrübe ve bilgiye sahip kullanıcılar tarafından etkin bir şekilde kullanılamayacağı, ancak özellikleri uzmanlara ciddi yararlar sağlayacağı şeklinde bir görüş bulunmaktadır. Zira ChatGPT'nin doğrudan yatırım tavsiyesinde bulunmadığı, bununla birlikte kullanıcıların daha spesifik komutlar vermesi ve sohbet robotunu daha fazla veriyle eğitmesi halinde daha doğru önerilerde bulunduğu bilinmektedir (Ahangar ve Fietko, 2023). Bu görüşü destekler bir kanıt, Kim (2023) tarafından sağlanmıştır. Çalışmada ChatGPT'ye farklı ekonomik ve finansal koşullara ilişkin senaryolar sunulmuş, bu senaryolar ışığında portföy içerisine dahil edilebilecek varlıkları önermesi istenmiştir. Bu şekilde bir eğitimin ardından, ChatGPT'nin etkin bir portföy oluşturulmasına katkı sağladığı sonucuna ulaşılmıştır. Yine ChatGPT'nin tek başına bir yatırım danışmanı olarak kullanılmasından ziyade, eğitilerek ve geleneksel portföy değerlendirme yöntemlerine yardımcı olacak şekilde kullanıcıların yatırım kararlarına ciddi faydalar sağlayacağını belirten çalışmalar mevcuttur (Romanko vd., 2023; Sanjib Biswas vd., 2023).

Ahangar ve Fietko'nun (2023) aksine Ko ve Lee (2023), ChatGPT'nin yatırım konusunda bilgisi zayıf olan kullanıcılara önemli faydalar sağlayabileceğini iddia etmiştir. Yazarlar ChatGPT kullanılarak, rastgele seçilen portföylere göre daha başarılı portföyler oluşturulabileceği sonucuna ulaşmışlardır. Altan ve Kılıç (2023), eski adı Bing AI olan Copilot ile oluşturdukları portföyün risk-getirisini hesaplayarak başarısını ölçmüş, Ko ve Lee'yi (2023) destekler nitelikte, kısıtlı düzeyde finansal bilgiye sahip yatırımcılara fayda sağlayabileceği sonucuna ulaşmıştır. Diğer bir kısım çalışmada ise ChatGPT'ye belirli varlıklara ilişkin haberler bilgi olarak verilerek, bu haberler doğrultusunda tavsiyelerde bulunması istenmiştir. Bu bilgiler ışığında ChatGPT'nin genel olarak doğru tavsiyelerde bulunduğu saptanmıştır (Lopez-Lira ve Tang, 2023; Lu vd., 2023; Pelster ve Val, 2024).

ChatGPT'nin yatırım tavsiyelerini 17 robo-danışmanın tavsiyeleriyle karşılaştıran Oehler ve Horn (2024), ChatGPT'nin robo-danışmanlardan daha tutarlı tavsiyelerde bulunduğunu sonucuna ulaşmışlardır. Ullah vd. (2024) ise yatırımcıların karar alırken ChatGPT kullanımlarını araştırdıkları çalışmalarında, ChatGPT kullanımının portföy optimizasyonu, piyasa eğilimlerinin tahmini gibi konularda yatırımcılara fayda sağladığını ve finansal okur-yazarlığı artırdığını tespit etmişlerdir. Chen vd. (2023), ChatGPT'den elde edilen bilgilerle oluşturdukları grafik sinir ağlarını kullanarak hisse senedi fiyat hareketlerini tahmin etmeye çalışmış ve bu yöntemin derin öğrenme yöntemine göre daha iyi sonuç verdiği sonucuna ulaşmışlardır. Ayrıca kullandıkları model ile düşük riskli ve yüksek getirili portföyler elde etmişlerdir. Aldridge (2023) ise hisse senedi getirilerini açıklayan ve doğrusal regresyona dayanan Sermaye

Varlıkları Fiyatlama Modeli'ne (SVFM) alternatif olarak yapay zekâya dayalı makine öğrenme modeliyle hisse senedi getirilerini incelemiş ve sonuçların SVFM ile tutarlı olduğunu ifade etmiştir.

2. Yöntem

2.1. PES

Olabilirlik teorisi; olasılık teorisi ve bulanık küme teorisi ile ilişkili olan bir belirsizlik teorisidir (Dubois, 2006, Souliotis vd., 2022). Üçgensel bulanık sayıları ve olabilirlik teorisini kullanan PES ile üç temel ÇKKV yönteminden (maksimin, maksimaks ve ağırlıklı toplam yöntemlerinden) elde edilen bilgiler sentezlenir. PES'in adımları aşağıdaki gibidir (Göktaş ve Güçlü, 2024).

Adım 1: Karar matrisi $A=(a_{ij})$ Eşitlik 1'deki gibi oluşturulur. a_{ij} , i. alternatifin j. kriter için değeridir. Burada n adet alternatif ve m adet kriter vardır.

$$A = \begin{pmatrix} a_{11} & \cdots & a_{1m} \\ \vdots & \ddots & \vdots \\ a_{n1} & \cdots & a_{nm} \end{pmatrix} \quad (1)$$

Adım 2: Karar matrisi, Eşitlik 2 ile normalize edilir ve normalize edilmiş karar matrisi $B=(b_{ij})$ oluşturulur. Burada fayda (maliyet) yönlü kriter için α_j , A matrisinin j. sütununun en düşük (yüksek) değeri iken β_j en yüksek (düşük) değeridir. B matrisinin elemanları $[0,1]$ kapalı aralığında değer alır (Vafaei vd., 2016).

$$b_{ij} = \frac{|a_{ij} - \alpha_j|}{|\beta_j - \alpha_j|}, \text{ her } i, j \text{ için} \quad (2)$$

Adım 3: Kriterlerin ağırlık vektörü $\lambda=(\lambda_j)$ herhangi bir yöntemle belirlenir. Kriter ağırlıkları nonnegatiftir ve toplamları 1'i verir.

Maksimin yöntemi i. alternatif için Eşitlik 3'teki güvenlik düzeyini kullanır (Vaidogas vd., 2007).

$$B_{i,1} := \min_j b_{ij} \quad (3)$$

Ağırlıklı toplam yöntemi i. alternatif için Eşitlik 4'teki ağırlıklı toplam değerini kullanır (Vaidogas vd., 2007).

$$B_{i,2} := \sum_{j=1}^m \lambda_j b_{ij} \quad (4)$$

Maksimaks yöntemi i. alternatif için Eşitlik 5'teki iyimserlik düzeyini kullanır (Vaidogas vd., 2007).

$$B_{i,3} := \max_j b_{ij} \quad (5)$$

Adım 4: i. alternatifin bulanık faydası olarak $(B_{i,1}, B_{i,2}, B_{i,3})$ üçgensel bulanık sayısı ile verilen olabilirlik dağılımı oluşturulur. $B_{i,1}$ fayda için alt sınırdır, $B_{i,2}$ fayda için olabilirliği en yüksek olan değerdir ve $B_{i,3}$ fayda için üst sınırdır.

Alternatiflerin ağırlık vektörü $w=(w_i)$ olsun ve portföy olarak adlandırılınsın. PES, Eşitlik 6'daki ifade ile optimal kaynak dağıtım planını (w^*) bulur. Burada pay ifadesi portföyün (w) olabilirlik ortalaması iken payda ifadesi portföyün olabilirlik standart sapmasıdır. Başka bir deyişle w^* vektörü, olabilirlik performansını (birim olabilirlik standart sapması başına olabilirlik ortalamasını) maksimum yapar (Göktaş ve Duran, 2019; Göktaş ve Güçlü, 2024).

$$\text{maks} \frac{\sum_{i=1}^n w_i \left(\frac{B_{i,1} + 2B_{i,2} + B_{i,3}}{4} \right)}{\sqrt{\sum_{i=1}^n w_i^2 \left(\frac{1-B_{i,1}}{6} \right)^2}} \quad (6)$$

$$k. a. \sum_{i=1}^n w_i = 1$$

Modern Portföy Teorisindeki Tobin'in ayırım teoreminden bilindiği üzere Eşitlik 6'nın tek optimal çözümü Eşitlik 7'deki kesin konkav kuadratik maksimizasyon probleminin tek optimal çözümü standardize edilerek bulunabilir (Okhrin ve Schmid, 2006). Standardizasyon, herhangi bir vektörün elemanları toplamına bölünmesidir.

$$\text{maks}_w \sum_{i=1}^n w_i \left(\frac{B_{i,1} + 2B_{i,2} + B_{i,3}}{4} \right) - \frac{1}{2} \sum_{i=1}^n w_i^2 \left(\frac{1-B_{i,1}}{6} \right)^2 \quad (7)$$

Eşitlik 7'nin çözümünü bulmak amacıyla her bir w_i için amaç fonksiyonunun kısmi türevi alınır ve bu türev değeri 0'a eşitlenir. Buna göre Eşitlik 7'nin optimal çözümü i. alternatif için Eşitlik 8'deki gibi bulunur.

$$w_i = \frac{\left(\frac{B_{i,1} + 2B_{i,2} + B_{i,3}}{4} \right)}{\left(\frac{1 - B_{i,1}}{6} \right)^2}, \text{ her } i \text{ için} \quad (8)$$

Eşitlik 8 ile elde edilen w vektörü standardize edildiğinde Eşitlik 6'nın i. alternatif için çözümü Eşitlik 9'daki gibi bulunur. B matrisinin elemanları nonnegatif olduğundan bu çözüm nonnegatiftir.

$$w_i^* = \frac{1}{\sum_{i=1}^n \frac{B_{i,1} + 2B_{i,2} + B_{i,3}}{(1 - B_{i,1})^2}} \left(\frac{B_{i,1} + 2B_{i,2} + B_{i,3}}{(1 - B_{i,1})^2} \right), \text{ her } i \text{ için} \quad (9)$$

Adım 5: Eşitlik 9 kullanılarak, alternatiflerin öncelik vektörü $w^*=(w_i^*)$ olarak belirlenir.

Adım 6: Alternatiflerin öncelik değerleri kullanılarak, alternatifler sıralanır veya alternatiflere kaynak dağıtımı yapılır.

2.2. U-PES

Bu bölümde PES'in belirsiz kriter ağırlıkları için genel hali olan U-PES tanıtılmıştır. Buradaki ana motivasyon, kriter ağırlıkları bilinmediğinde veya kriter ağırlıklandırmanın elde edilecek sonucu etkilemesi istenmediğinde kullanılacak objektif bir yöntem önermektir. i. alternatifin ağırlıklı toplam değeri ($B_{i,2}$) için m adet senaryo oluşturulsun. j. senaryoda j. kriterin ağırlığı 1 olsun ve diğer kriterlerin ağırlıkları 0 olsun. i. alternatif için güvenlik düzeyi ($B_{i,1}$) Eşitlik 3 ile, iyimserlik düzeyi ($B_{i,3}$) Eşitlik 5 ile belirlensin. Buna göre i. alternatifin j. senaryodaki bulanık faydası ($B_{i,1}$, b_{ij} , $B_{i,3}$) üçgensel bulanık sayısıdır. Eşitlik 7'nin m adet senaryo için genel hali Eşitlik 10'daki gibidir. Eşitlik 10 en kötü durum odaklıdır yani herhangi bir portföy (w) için en kötü durum senaryosunu dikkate alır.

$$\max_w \min_j \sum_{i=1}^n w_i \left(\frac{B_{i,1} + 2b_{ij} + B_{i,3}}{4} \right) - \frac{1}{2} \sum_{i=1}^n w_i^2 \left(\frac{1 - B_{i,1}}{6} \right)^2 \quad (10)$$

Minimum fonksiyonunun tanımı nedeniyle Eşitlik 10 ile Eşitlik 11 özdeştir. Eşitlik 11 kesin konkav maksimizasyon problemidir. Burada y değişkeni en kötü durum senaryosu ile ilişkilidir. U-PES ile belirlenen alternatiflerin öncelik vektörü (w^*), Eşitlik 11'in optimal çözümünün standardize edilmiş halidir.

$$\max y - \frac{1}{2} \sum_{i=1}^n w_i^2 \left(\frac{1 - B_{i,1}}{6} \right)^2 \quad (11)$$

$$k.a. y \leq \sum_{i=1}^n w_i \left(\frac{B_{i,1} + 2b_{ij} + B_{i,3}}{4} \right), \text{ her } j \text{ için}$$

Karush-Kuhn-Tucker (KKT) koşulları kullanılarak Eşitlik 11'in i. alternatif için çözümü Eşitlik 12'deki gibi elde edilir (Lutgens ve Schotman, 2010; Gökteş ve Gökerik, 2024). Burada λ_j değeri Eşitlik 11'in j. kısıdı ile ilişkili olan dual optimalidir. Dual optimaller nonnegatiftir ve bunların toplamı 1'i verir (Lutgens ve Schotman, 2010). B matrisinin elemanları ve λ_j değerleri nonnegatif olduğundan bu çözüm de nonnegatiftir. KKT koşullarından bilindiği üzere Eşitlik 11'in j. kısıdı aktif kısıt değilse λ_j değeri 0'dır.

$$w_i = \frac{\sum_{j=1}^m \lambda_j \left(\frac{B_{i,1} + 2b_{ij} + B_{i,3}}{4} \right)}{\left(\frac{1 - B_{i,1}}{6} \right)^2}, \text{ her } i \text{ için} \quad (12)$$

Eşitlik 12, Eşitlik 13'teki gibi yeniden yazılabilir. Ağırlıklı toplam değerinin ($B_{i,2}$) tanımı Eşitlik 4'te verilmiştir. Buna göre kriter ağırlıkları bilindiğinde, Eşitlik 10'da verilen farklı senaryolara karşı gelen kuadratik fonksiyonların ağırlıklı ortalaması Eşitlik 7 ile özdeşdir. Başka bir deyişle kriter ağırlıkları bilindiğinde U-PES, PES ile özdeş sonuç vermektedir. Kriter ağırlıkları bilinmediğinde ise Eşitlik 8 ile aynı formda olan Eşitlik 13'teki sonucu vermektedir. Bu nedenlerden ötürü U-PES, belirsiz kriter ağırlıkları için PES'in genel halidir ve objektif bir şekilde belirlenen kriter ağırlıkları Eşitlik 11'in dual optimalleridir. Bununla birlikte U-PES olası tüm kriter ağırlıklarını dikkate alır ama nispeten zayıf olunan kriterlere odaklanır.

$$w_i = \frac{B_{i,1} + 2 \sum_{j=1}^m \lambda_j b_{ij} + B_{i,3}}{\left(\frac{1 - B_{i,1}}{6} \right)^2}, \text{ her } i \text{ için} \quad (13)$$

U-PES, alternatiflerin öncelik vektörü (w^*) ile birlikte kriterlerin ağırlık vektörünü (λ) de tek olarak belirler. U-PES'in ilk iki adımı PES'in ilk iki adımı ile aynıdır. PES'in üçüncü adımı, U-PES'te bulunmamaktadır. Buna göre U-PES'in diğer adımları aşağıdaki gibidir.

Adım 3: i. alternatif için güvenlik düzeyi ($B_{i,1}$) Eşitlik 3 ile, iyimserlik düzeyi ($B_{i,3}$) Eşitlik 5 ile belirlenir.

Adım 4: Olabilirlik varyansı vektörü (v) Eşitlik 14'teki gibi oluşturulur.

$$v = \begin{pmatrix} \left(\frac{1 - B_{i,1}}{6} \right)^2 \\ \vdots \\ \left(\frac{1 - B_{n,1}}{6} \right)^2 \end{pmatrix} \quad (14)$$

Adım 5: Senaryo bazlı olabilirlik ortalaması matrisi (M) Eşitlik 15'teki gibi oluşturulur.

$$M = \begin{pmatrix} \left(\frac{B_{1,1} + 2b_{11} + B_{1,3}}{4} \right) & \dots & \left(\frac{B_{1,1} + 2b_{1m} + B_{1,3}}{4} \right) \\ \vdots & \ddots & \vdots \\ \left(\frac{B_{n,1} + 2b_{n1} + B_{n,3}}{4} \right) & \dots & \left(\frac{B_{n,1} + 2b_{nm} + B_{n,3}}{4} \right) \end{pmatrix} \quad (15)$$

Eşitlik 11, konveks optimizasyon problemi olduğundan bir MATLAB yazılımı olan CVX ile çözülebilir (Grant ve Boyd, 2008). Eşitlik 11 için CVX kodu Eşitlik 16'daki gibidir.

```
cvx _ solver mosek
cvx _ begin
variables w(n) y;
dual variable lambda;
maximize (y - 0.5 * transpose(w) * diag(v) * w);
subject to
lambda : y * ones(m,1) - transpose(M) * w <= zeros(m,1);
cvx _ end
```

(16)

Adım 6: Eşitlik 11'in tek optimal çözümü Eşitlik 16'daki CVX koduyla ya da benzer bir yazılımla bulunduktan sonra standardize edilir. Standardize edilmiş çözüm (w^*) alternatiflerin öncelik vektörü olarak atanır. Kriterlerin objektif bir şekilde belirlenen ağırlık vektörü $\lambda=(\lambda_j)$ vektörüdür.

Adım 7: Alternatiflerin öncelik değerleri kullanılarak, alternatifler sıralanır veya kaynak dağıtımı yapılır.

3. Bulgular ve Tartışma

Bu çalışma kapsamına alınan hisse senetleri, Tablo 1’de görülmektedir. Söz konusu hisse senetlerinin 2023 yılındaki aylık basit getirileri kullanılarak beklenen getiri ve risk (standart sapma) hesaplanmıştır. Ayrıca bunların 2022 yılına ait çevresel, sosyal ve kurumsal yönetim skorları Thomson Reuters Eikon veri tabanından alınmıştır. Bunlar gibi X10XB endeksinin bileşenleri olan Koza Altın İşletmeleri A.Ş. (KOZAL) ve Astor Enerji A.Ş. (ASTOR) hisse senetlerinin 2022 yılına ait ESG skorları söz konusu veri tabanında bulunmadığından, bu iki hisse senedi çalışmaya dahil edilmemiştir. Söz konusu endeks, banka dışı dev şirketlerin hisse senetlerini içerdiğinden tercih edilmiştir. Bu hisse senetlerinin halka açık kısımlarının piyasa değerleri ve bunlardaki işlem hacmi oldukça yüksektir. ESG skorları yıllık finansal raporlar da baz alınarak belirlendiğinden ve 31.12.2023 tarihi itibarıyla 2023 yılına ait raporlar açıklanmamış olduğundan çalışmada tarihsel veri kullanıldığında 2022 yılına ait ESG skorları baz alınmıştır. Geçmiş veri ile yapılan analizin geleceği tam olarak yansıtmayabileceği varsayımı altında ChatGPT4, Copilot ve Gemini adlı yapay zekâ sohbet robotlarının 2024 yılına ait beklentileri, her bir kriter bazında alternatiflerin (hisse senetlerinin) sıralaması ayrı ayrı yaptırılarak alınmıştır.

Tablo 1. Çalışma Kapsamında Portföye Dahil Edilen Şirketler ve BIST Kodları

BIST Kodu	Şirket İsimleri
ASELS	ASELSAN ELEKTRONİK SANAYİ VE TİCARET A.Ş.
EREGL	EREĞLİ DEMİR VE ÇELİK FABRİKALARI T.A.Ş.
KCHOL	KOÇ HOLDİNG A.Ş.
PETKM	PETKİM PETROKİMYA HOLDİNG A.Ş.
SASA	SASA POLYESTER SANAYİ A.Ş.
SISE	TÜRKİYE ŞİŞE VE CAM FABRİKALARI A.Ş.
THYAO	TÜRK HAVA YOLLARI A.O.
TUPRS	TÜRKİYE PETROL RAFİNERİLERİ A.Ş.

Kaynak: Yazarlar tarafından oluşturulmuştur.

3.1. Geçmiş Veri

Geçmiş veri kullanılarak U-PES aşağıdaki adımlarla uygulanmıştır.

Adım 1: Karar matrisi (A) Tablo 2’deki gibi oluşturulmuştur. Burada 1 değeri ilgili kriter için en iyi verinin (beklentinin) olduğu hisse senedine karşı gelir iken, 8 değeri ilgili kriter için en kötü verinin (beklentinin) olduğu hisse senedine karşı gelir. Bu bilgi Tablo 8, Tablo 9 ve Tablo 10 için de geçerlidir.

Tablo 2. Geçmiş Veri Doğrultusunda Oluşturulan Karar Matrisi

	Ortalama Getiri	Standart Sapma	Çevresel Skor	Sosyal Skor	Yönetişim Skoru
ASELS	4	5	1	6	5
EREGL	6	1	7	8	3
KCHOL	2	4	2	1	1
PETKM	7	3	5	3	8
SASA	8	6	8	7	7
SISE	5	2	3	5	2
THYAO	3	7	4	4	4
TUPRS	1	8	6	2	6

Kaynak: Yazarlar tarafından oluşturulmuştur.

Adım 2: Eşitlik 2 ile oluşturulan normalize edilmiş karar matrisi (B) Tablo 3’teki gibidir. Normalize değer 1 ise ilgili kriter bazında ilgili alternatif en iyi değere sahip iken 0 ise ilgili kriter bazında ilgili alternatif en kötü değere sahiptir.

Tablo 3. Normalize Edilmiş Karar Matrisi

	Ortalama Getiri	Standart Sapma	Çevresel Skor	Sosyal Skor	Yönetişim Skoru
ASELS	0,5714	0,4286	1,0000	0,2857	0,4286
EREGL	0,2857	1,0000	0,1429	0,0000	0,7143
KCHOL	0,8571	0,5714	0,8571	1,0000	1,0000
PETKM	0,1429	0,7143	0,4286	0,7143	0,0000
SASA	0,0000	0,2857	0,0000	0,1429	0,1429
SISE	0,4286	0,8571	0,7143	0,4286	0,8571
THYAO	0,7143	0,1429	0,5714	0,5714	0,5714
TUPRS	1,0000	0,0000	0,2857	0,8571	0,2857

Kaynak: Yazarlar tarafından oluşturulmuştur.

Adım 3: Eşitlik 3 ile bulunan alternatiflerin güvenlik düzeyleri ($B_{i,1}$) ve Eşitlik 5 ile bulunan alternatiflerin iyimserlik düzeyleri ($B_{i,3}$) Tablo 4'teki gibidir. Güvenlik ve iyimserlik düzeyleri arttıkça ilgili alternatifin U-PES ile bulunan öncelik değerinin de artması beklenir.

Tablo 4. Alternatiflerin Güvenlik ve İyimserlik Düzeyleri

	$B_{i,1}$	$B_{i,3}$
ASELS	0,2857	1,0000
EREGL	0,0000	1,0000
KCHOL	0,5714	1,0000
PETKM	0,0000	0,7143
SASA	0,0000	0,2857
SISE	0,4286	0,8571
THYAO	0,1429	0,7143
TUPRS	0,0000	1,0000

Kaynak: Yazarlar tarafından oluşturulmuştur.

Adım 4: Eşitlik 14 ile oluşturulan olabilirlik varyansı vektörü (v) Tablo 5'teki gibidir. Olabilirlik varyansı azaldıkça ilgili alternatifin U-PES ile bulunan öncelik değerinin de artması beklenir.

Tablo 5. Olabilirlik Varyansı Vektörü

ASELS	0,0142
EREGL	0,0278
KCHOL	0,0051
PETKM	0,0278
SASA	0,0278
SISE	0,0091
THYAO	0,0204
TUPRS	0,0278

Kaynak: Yazarlar tarafından oluşturulmuştur.

Adım 5: Eşitlik 15 ile oluşturulan senaryo bazlı olabilirlik ortalaması matrisi (M) Tablo 6'daki gibidir. Örneğin, Senaryo 1'de birinci kriterin (beklenen getirinin) ağırlığı 1 iken diğer kriterlerin ağırlıkları 0'dır. Başka bir deyişle Senaryo 1'de her i için $B_{i,2}=b_{i1}$ olarak alınmıştır.

Tablo 6. Senaryo Bazlı Olabilirlik Ortalaması Matrisi

	Senaryo 1	Senaryo 2	Senaryo 3	Senaryo 4	Senaryo 5
ASELS	0,6071	0,5357	0,8214	0,4643	0,5357
EREGL	0,3929	0,7500	0,3214	0,2500	0,6071
KCHOL	0,8214	0,6786	0,8214	0,8929	0,8929
PETKM	0,2500	0,5357	0,3929	0,5357	0,1786
SASA	0,0714	0,2143	0,0714	0,1429	0,1429
SISE	0,5357	0,7500	0,6786	0,5357	0,7500
THYAO	0,5714	0,2857	0,5000	0,5000	0,5000
TUPRS	0,7500	0,2500	0,3929	0,6786	0,3929

Kaynak: Yazarlar tarafından oluşturulmuştur.

Adım 6: Eşitlik 11'in çözümü Eşitlik 16'daki CVX kodu kullanılarak bulunmuş ve sonrasında standardize edilmiştir. Buna göre alternatiflerin öncelik değerleri sırasıyla 0,1157, 0,0765, 0,4108, 0,0543, 0,0213, 0,2402, 0,0473 ve 0,0338 şeklindedir. Kriterlerin objektif bir şekilde belirlenen ağırlıkları beklenen getiri için 0,1230 ve standart sapma için 0,8770 olarak bulunmuştur. Diğer kriterlerin ağırlıkları 0'dır. Buna göre U-PES ile oluşturulan portföy (w^*), ESG bileşenlerine oranla standart sapma ve beklenen getiri kriterlerinde nispeten daha zayıftır.

Adım 7: Portföyün U-PES ile belirlenen ağırlıkları ASELS için %11,57, EREGL için %7,65, KCHOL için %41,08, PETKM için %5,43, SASA için %2,13, SISE için %24,02, THYAO için %4,73 ve TUPRS için %3,38 şeklindedir.

Entropi yöntemi kriterlerin ağırlıklarını objektif bir şekilde belirler. Bu yöntemde göre bir kriter bazında alternatiflerin farklılaşma seviyesi arttıkça ilgili kriterin ağırlığı artar (Karami ve Johansson, 2014). Bu çalışmada alternatiflerin kriterler bazındaki sıralamaları kullanıldığından farklılaşma seviyeleri aynıdır. Buna göre PES yönteminde kriter ağırlıkları Entropi yöntemiyle belirleniyorsa kriterlerin ağırlıkları eşittir. U-PES ve eşit ağırlıklı PES ile oluşturulan portföyler Tablo 7'de verilmiştir. Görüldüğü üzere U-PES ve PES, sıralaması daha yüksek olan alternatifte daha yüksek oranda kaynak dağıtımını yapar.

Tablo 7. U-PES ve Eşit Ağırlıklı PES Sonuçlarının Karşılaştırılması

	U-PES		PES	
	Öncelik	Sıra	Öncelik	Sıra
AELS	0,1157	3	0,1194	3
EREGL	0,0765	4	0,0477	6
KCHOL	0,4108	1	0,4596	1
PETKM	0,0543	5	0,0389	7
SASA	0,0213	8	0,0132	8
SISE	0,2402	2	0,2046	2
THYAO	0,0473	6	0,0659	4
TUPRS	0,0338	7	0,0506	5

Kaynak: Yazarlar tarafından oluşturulmuştur.

Spearman'ın sıra korelasyonu, sıralamalar için bulunan lineer korelasyon katsayısı olarak tanımlanabilir (Li vd., 2022). Tablo 7'de verilen sonuçların Spearman'ın sıra korelasyonu 0,81 olarak hesaplanmıştır. Ayrıca Copilot beklentileri kullanıldığında 0,83, Gemini beklentileri kullanıldığında 0,86 ve ChatGPT beklentileri kullanıldığında 0,90 olarak hesaplanmıştır. Bu değerler 0,71-0,9 arasında olduğundan yüksek düzeyde pozitif ilişkiye karşı gelmektedir (Hair vd., 2007). Başka bir deyişle U-PES ve eşit ağırlıklı PES benzer sonuçlar vermiştir.

3.2. Yapay Zekâ Sohbet Robotları

ChatGPT4 beklentileri doğrultusunda oluşturulan karar matrisi Tablo 8'deki gibidir. U-PES ile objektif bir şekilde belirlenen kriter ağırlıkları; beklenen getiri için 0, standart sapma için 0,6683, çevresel skor için 0,1873, sosyal skor için 0,1444 ve yönetim skoru için 0'dır.

Tablo 8. ChatGPT4 Beklentileri Doğrultusunda Oluşturulan Karar Matrisi

	Ortalama Getiri	Standart Sapma	Çevresel Skor	Sosyal Skor	Yönetişim Skoru
AELS	1	3	7	2	2
EREGL	4	5	3	7	6
KCHOL	6	1	8	1	1
PETKM	3	7	1	4	4
SASA	7	4	5	8	7
SISE	8	2	4	6	5
THYAO	5	8	6	3	8
TUPRS	2	6	2	5	3

Kaynak: Yazarlar tarafından oluşturulmuştur.

Copilot beklentileri doğrultusunda oluşturulan karar matrisi Tablo 9'daki gibidir. U-PES ile objektif bir şekilde belirlenen kriter ağırlıkları; beklenen getiri için 0,4539, standart sapma için 0,5461 ve diğer kriterler için 0'dır.

Tablo 9. Copilot Beklentileri Doğrultusunda Oluşturulan Karar Matrisi

	Ortalama Getiri	Standart Sapma	Çevresel Skor	Sosyal Skor	Yönetişim Skoru
AELS	8	1	6	6	6
EREGL	7	2	1	8	4
KCHOL	4	5	7	2	1
PETKM	3	6	5	4	7
SASA	6	3	8	7	8
SISE	2	7	2	5	3
THYAO	1	8	4	1	2
TUPRS	5	4	3	3	5

Kaynak: Yazarlar tarafından oluşturulmuştur.

Gemini beklentileri doğrultusunda oluşturulan karar matrisi Tablo 10'daki gibidir. U-PES ile objektif bir şekilde belirlenen kriter ağırlıkları; beklenen getiri için 0,6798, standart sapma için 0,3202 ve diğer kriterler için 0'dır.

Tablo 10. Gemini Beklentileri Doğrultusunda Oluşturulan Karar Matrisi

	Ortalama Getiri	Standart Sapma	Çevresel Skor	Sosyal Skor	Yönetişim Skoru
AELS	7	2	1	1	1
EREGL	8	1	5	5	5
KCHOL	4	5	3	3	3
PETKM	6	3	6	6	6
SASA	2	7	8	8	8
SISE	5	4	2	2	2
THYAO	1	8	4	4	4
TUPRS	3	6	7	7	7

Kaynak: Yazarlar tarafından oluşturulmuştur.

U-PES ile elde edilen portföyler Tablo 11'de birlikte verilmiştir. Buradaki son sütun, diğer sütunlardaki sonuçların ağırlıklı ortalamasıdır. Entropi yöntemi ile elde edilen ağırlıklar; geçmiş veri için 0,5824, Copilot için 0,1510, Gemini için 0,1805 ve ChatGPT4 için 0,0861 şeklindedir. Örneğin, ASELS hisse senedi için $0,1157*0,5824+0,0933*0,1510+0,0898*0,1805 +0,1675*0,0861$ işlemiyle 0,1121 değeri bulunmuştur.

Tablo 11. U-PES ile Elde Edilen Portföyler

	Geçmiş Veri	Copilot	Gemini	ChatGPT4	Entropi Ağırlıklı
ASELS	0,1157	0,0933	0,0898	0,1675	0,1121
EREGL	0,0765	0,0921	0,0574	0,1214	0,0793
KCHOL	0,4108	0,1292	0,2350	0,1347	0,3128
PETKM	0,0543	0,1103	0,1265	0,1308	0,0824
SASA	0,0213	0,0782	0,0739	0,0767	0,0442
SISE	0,2402	0,1174	0,2393	0,1180	0,2110
THYAO	0,0473	0,0851	0,0825	0,0527	0,0598
TUPRS	0,0338	0,2944	0,0957	0,1981	0,0984

Kaynak: Yazarlar tarafından oluşturulmuştur.

Tablo 11'in ilk dört sütununda verilen sonuçlar için Spearman'ın sıra korelasyon matrisi hesaplanmıştır. Bu matrisin elemanları pozitifdir. Copilot ve Gemini sonuçları ile Copilot ve ChatGPT sonuçlarının Spearman'ın sıra korelasyonlarının 0,71-0.9 arasında olduğu, diğer sıra korelasyonlarının 0,7'den düşük olduğu görülmüştür. Buna göre sadece bu ikililerin sonuçları arasında yüksek düzeyde pozitif ilişki vardır. Diğer ilişkiler pozitif yönlüdür ama daha zayıftır (Hair vd., 2007). Buna göre uzman bilgisi ya da geçmiş veri ile elde edilen sonuçlar arasında genellikle pozitif ama yüksek düzeyde olmayan ilişki vardır. Başka bir deyişle uzman bilgisi ya da geçmiş veri ile elde edilen sonuçlar arasında benzerlik olsa da bu benzerlik yüksek değildir.

Eşit ağırlıklı PES ile elde edilen portföyler Tablo 12'de birlikte verilmiştir. Buradaki son sütun, diğer sütunlardaki sonuçların ağırlıklı ortalamasıdır. Entropi yöntemi ile elde edilen ağırlıklar; geçmiş veri için 0,5202, Copilot için 0,1539, Gemini için 0,2164 ve ChatGPT4 için 0,1095 şeklindedir.

Tablo 12. Eşit Ağırlıklı PES ile Elde Edilen Portföyler

	Geçmiş Veri	Copilot	Gemini	ChatGPT4	Entropi Ağırlıklı
ASELS	0,1194	0,0763	0,1244	0,1739	0,1198
EREGL	0,0477	0,0889	0,0638	0,1159	0,0650
KCHOL	0,4596	0,1397	0,2449	0,1150	0,3262
PETKM	0,0389	0,1022	0,1138	0,1584	0,0779
SASA	0,0132	0,0513	0,0419	0,0539	0,0297
SISE	0,2046	0,1312	0,2770	0,0852	0,1959
THYAO	0,0659	0,1039	0,0695	0,0639	0,0723
TUPRS	0,0506	0,3066	0,0648	0,2337	0,1132

Kaynak: Yazarlar tarafından oluşturulmuştur.

Tablo 12'nin ilk dört sütununda verilen sonuçlar için Spearman'ın sıra korelasyon matrisi hesaplanmıştır. Bu matrisin elemanları pozitifdir. Sadece geçmiş veri ve Gemini sonuçlarının Spearman'ın sıra korelasyonunun 0,71-0.9 arasında olduğu, diğer sıra korelasyonlarının 0,7'den düşük olduğu görülmüştür. Buna göre sadece bu ikilinin sonuçları arasında yüksek düzeyde pozitif ilişki vardır. Diğer ilişkiler pozitif yönlüdür ama daha zayıftır (Hair vd., 2007). Eşit ağırlıklı PES sonuçlarına göre sadece Gemini ya da geçmiş veri ile elde edilen sonuçlar yüksek oranda birbirlerine benzemektedir.

Sonuç

Portföy seçimi, yatırımcılar için karmaşık ve belirli düzeyde finansal bilgi gerektiren bir süreçtir. Bu süreçte, modern portföy teorisine dayalı olarak, riskin minimize edilerek beklenen getirinin maksimize edilmesi hedeflenir. ÇKVV tekniklerinin portföy seçiminde kullanımı, yatırımcıların risk-getiri dengesini optimize etmelerine ve farklı kriterleri de kararlarına dahil etmelerine yardımcı olmaktadır. Ancak ÇKVV tekniklerinde kriter ağırlıklarının belirlenmesi aşaması, sonuçları subjektif bir niteliğe büründürebilmektedir. Objektif yöntemler olarak adlandırılan kriter ağırlıklandırma yöntemleri kullanılsa dahi, kullanılan her bir ağırlıklandırma yöntemi, sonuçları etkilemektedir. Bu çalışmada belirsiz kriter ağırlıkları için PES'in genel hali olan ve U-PES olarak adlandırılan yeni bir ÇKKV yöntemi önerilmiştir. Başka bir deyişle kriter ağırlıkları bilindiğinde PES ile U-PES özdeş sonuç verirken, kriter ağırlıkları bilinmediğinde U-PES kriterlerin ağırlıklarını içsel olarak belirler. Önerilen yöntem ile yapılan uygulamada yapay zekâ destekli uzman görüşleri sürece dahil edilerek, portföy seçiminde yeni bir bakış açısı sunulmuştur.

U-PES alternatiflerin öncelik vektörünü ve kriterlerin ağırlık vektörünü tek olarak belirler. Kriter ağırlıklandırma sorunsalını aştığından U-PES, PES'e oranla teorik olarak üstündür. Öte yandan PES, MS Excel kullanılarak kolayca uygulanabilirken U-PES'in uygulanması için özel yazılımlara ihtiyaç vardır. Ayrıca PES'in ilişkili olduğu üç temel ÇKKV yönteminden sadece ağırlıklı toplam yönteminin sonucu kriter ağırlıklarından etkilenir. Bu nedenle PES; TOPSIS gibi ÇKKV yöntemlerine oranla kriter ağırlıklandırmaya karşı daha az hassastır. Bu nedenle özel yazılımlara erişim imkanı yokken PES tercih edilebilir. Çalışmada U-PES, diğer ÇKKV

yöntemleriyle karşılaştırılmamıştır. Çünkü diğer ÇKKV yöntemlerine karşı U-PES'in üstün olduğu ile ilgili herhangi bir hipotez bulunmamaktadır.

Çalışmada, eşit ağırlıklı PES ve U-PES yapay zekâ sohbet robotlarına dayalı portföy seçiminde kullanılmıştır. Yapılan uygulamada uzman bilgisi ya da geçmiş veri ile elde edilen sonuçlar arasında genellikle pozitif ama yüksek düzeyde olmayan ilişki olduğu görülmüştür. Bu sonuç, Aldridge'in (2023) yapay zekâyâ dayalı model ile geçmiş veriye dayalı SVFM'yi karşılaştırdığı ve iki modelin de benzer sonuçlar verdiği bulgusuna ulaştığı çalışmasıyla paralellik göstermektedir. Genel olarak ÇKKV yöntemlerinin portföy seçiminde kullanılmasının iki temel sınırlılığı, portföyde kısa pozisyon bulundurulabiliyorken yetersiz kalmaları ve hisse senetlerinin korelasyon yapısının dikkate alınamamasıdır. Söz konusu iki sınırlılık bu çalışma için de geçerlidir. Ayrıca PES ve U-PES'in ilişkili olduğu üç temel ÇKKV yönteminden elde edilen toplam bilgi, bu yöntemler için önemli bir sınırlılık oluşturmaktadır. İlerideki çalışmalarda, farklı şekillerde elde edilen sonuçların bir araya getirilmesi için farklı yaklaşımlar geliştirilebilir. Ayrıca U-PES portföy seçiminden farklı ÇKKV problemleri için kullanılabilir.



This research article has been licensed with Creative Commons Attribution - Non-Commercial 4.0 International License. Bu araştırma makalesi, Creative Commons Atıf - Gayri Ticari 4.0 Uluslararası Lisansı ile lisanslanmıştır.

Yazar Katkıları

Yazarlar çalışmaya katkı oranlarını bu şekilde beyan etmişlerdir: Furkan Göktaş %60, Fatih Güçlü %40

Teşekkür Beyanı

Yazarlar teşekkür beyanında bulunmamışlardır.

Destek Beyanı

Yazarlar destek beyanında bulunmamışlardır.

Çıkar Çatışması

Yazarlar herhangi bir çıkar çatışması beyan etmemişlerdir.

Etik Beyanı

Yazarlar çalışma için Etik Kurul Onayı alınmasına gerek olmadığını beyan etmişlerdir.

Sorumlu Özel Sayı Editörleri

Doç. Dr. Beyza Mina Ordu-Akkaya, Ankara Sosyal Bilimler Üniversitesi

Doç. Dr. Görkem Ataman, Yaşar Üniversitesi

Arş. Gör. Yunus Yıldırım, Afyon Kocatepe Üniversitesi

Kaynakça/References

- Ahangar, R. G. ve Fietko, A. (2023). Exploring the potential of ChatGPT in financial decision making. R. Gharoie Ahangar ve M. Napier (Ed.), *Advances in Business Information Systems and Analytics* içinde (ss. 94-111). IGI Global. <https://doi.org/10.4018/978-1-6684-8386-2.ch005>
- Akbaş, S. ve Erbay Dalkılıç, T. (2021). A hybrid algorithm for portfolio selection: An application on the Dow Jones Index (DJI). *Journal of Computational and Applied Mathematics*, 398, 113678. <https://doi.org/10.1016/j.cam.2021.113678>
- Aldridge, I. (2023). The AI revolution: From linear regression to ChatGPT and beyond and how it all connects to finance. *The Journal of Portfolio Management*, 49(9), 64-77. <https://doi.org/10.3905/jpm.2023.1.519>
- Altan, İ. M. ve Kılıç, M. (2023). Science fiction to real life: BING AI as an investment advisor. *Ekonomi İşletme ve Yönetim Dergisi*, 7(2), 240-260. <https://doi.org/10.7596/iejbm.31122023.003>
- Bisht, K. ve Kumar, A. (2022). Stock portfolio selection hybridizing fuzzy base-criterion method and evidence theory in triangular fuzzy environment. *Operations Research Forum*, 3(4), 1-32. <https://doi.org/10.1007/s43069-022-00167-3>
- Bouslah, K., Liern, V., Ouenniche, J. ve Pérez-Gladish, B. (2023). Ranking firms based on their financial and diversity performance using multiple-stage unweighted TOPSIS. *International Transactions in Operational Research*, 30(5), 2485-2505. <https://doi.org/10.1111/itor.13143>
- Chen, Z., Zheng, L., Lu, C., Yuan, J. ve Zhu, D. (2023). ChatGPT informed graph neural network for stock movement prediction. *SSRN Electronic Journal*. <https://doi.org/10.2139/ssrn.4464002>
- Dubois, D. (2006). Possibility theory and statistical reasoning. *Computational Statistics & Data Analysis*, 51(1), 47-69. <https://doi.org/10.1016/j.csda.2006.04.015>
- Göktaş, F. ve Duran, A. (2019). A new possibilistic mean-variance model based on the principal components analysis: an application on the Turkish holding stocks. *Journal of Multiple-Valued Logic & Soft Computing*, 32(5-6), 455-476.
- Göktaş, F. ve Gökerik, M. (2024). A novel robust theoretical approach on social media advertisement platform selection. *International Journal of Engineering Research and Development*, 16(1), 373-382. <https://doi.org/10.29137/umagd.1398580>
- Göktaş, F. ve Güçlü, F. (2024). Yeni bir çok kriterli karar verme yaklaşımı "olabilirlik değerlendirme sistemi": Katılım fonları üzerine bir uygulama. *Black Sea Journal of Engineering and Science*, 7(1), 1-8. <https://doi.org/10.34248/bsengineering.1341340>
- Grant, M. C. ve Boyd, S. P. (2008). Graph implementations for nonsmooth convex programs. In *Recent advances in learning and control* (pp. 95-110). Springer, London. https://doi.org/10.1007/978-1-84800-155-8_7
- Hair, J. F., Money, A. H., Samouel, P. ve Page, M. (2007). Research methods for business. *Education+Training*, 49(4), 336-337. <https://doi.org/10.1108/et.2007.49.4.336.2>
- He, Y., Romanko, O., Sienkiewicz, A., Seidman, R. ve Kwon, R. (2021). Cognitive user interface for portfolio optimization. *Journal of Risk and Financial Management*, 14(4), 180. <https://doi.org/10.3390/jrfm14040180>
- Karami, A. ve Johansson, R. (2014). Utilization of multi attribute decision making techniques to integrate automatic and manual ranking of options. *Journal of Information Science and Engineering*, 30(2), 519-534. <https://doi.org/10.6688/JISE.2014.30.2.14>
- Kim, J. H. (2023). What if ChatGPT were a quant asset manager. *Finance Research Letters*, 58, 104580. <https://doi.org/10.1016/j.frl.2023.104580>
- Ko, H. ve Lee, J. (2023). Can ChatGPT improve investment decision? From a portfolio management perspective. *SSRN Electronic Journal*. <https://doi.org/10.2139/ssrn.4390529>
- Li, H., Cao, Y. ve Su, L. (2022). Pythagorean fuzzy multi-criteria decision-making approach based on Spearman rank correlation coefficient. *Soft Computing*, 26(6), 3001-3012. <https://doi.org/10.1007/s00500-021-06615-2>
- Liern, V. ve Pérez-Gladish, B. (2022). Multiple criteria ranking method based on functional proximity index: Un-weighted TOPSIS. *Annals of Operations Research*, 311(2), 1099-1121. <https://doi.org/10.1007/s10479-020-03718-1>
- López-García, A., Liern, V. ve Pérez-Gladish, B. (2023). Determining the underlying role of corporate sustainability criteria in a ranking problem using UW-TOPSIS. *Annals of Operations Research*, 1-24. <https://doi.org/10.1007/s10479-023-05543-8>
- Lopez-Lira, A. ve Tang, Y. (2023). Can ChatGPT forecast stock price movements? Return predictability and large language models. *SSRN Electronic Journal*. <https://doi.org/10.2139/ssrn.4412788>
- Lu, F., Huang, L. ve Li, S. (2023). ChatGPT, generative AI, and investment advisory. *SSRN Electronic Journal*. <https://doi.org/10.2139/ssrn.4519182>
- Lutgens, F. ve Schotman, P. C. (2010). Robust portfolio optimisation with multiple experts. *Review of Finance*, 14(2), 343-383. <https://doi.org/10.1093/rof/rfn028>

- Markowitz, H. (1952). Portfolio selection. *The Journal of Finance*, 7(1), 77-91. <https://doi.org/10.2307/2975974>
- Narang, M., Joshi, M. C. ve Pal, A. K. (2021). A hybrid fuzzy COPRAS-base-criterion method for multi-criteria decision making. *Soft Computing*, 25(13), 8391-8399. <https://doi.org/10.1007/s00500-021-05762-w>
- Oehler, A. ve Horn, M. (2024). Does ChatGPT provide better advice than robo-advisors? *Finance Research Letters*, 60, 104898. <https://doi.org/10.1016/j.frl.2023.104898>
- Okhrin, Y. ve Schmid, W. (2006). Distributional properties of portfolio weights. *Journal of Econometrics*, 134(1), 235-256. <https://doi.org/10.1016/j.jeconom.2005.06.022>
- Parkhid, M. ve Mohammadi, E. (2022). Bi-level portfolio optimization considering fundamental analysis in fuzzy uncertainty environments. *Fuzzy Optimization and Modeling Journal*, 3(3), 1-18. <https://doi.org/10.30495/fomj.2022.1949729.1055>
- Pelster, M. ve Val, J. (2024). Can ChatGPT assist in picking stocks? *Finance Research Letters*, 59, 104786. <https://doi.org/10.1016/j.frl.2023.104786>
- Pinochet, L. H. C., Moreira, M. Â. L., Fávero, L. P., Santos, M. D. ve Pardim, V. I. (2023). Collaborative work alternatives with ChatGPT based on evaluation criteria for its use in higher education: Application of the PROMETHEE-SAPEVO-M1 method. *Procedia Computer Science*, 221, 177-184. <https://doi.org/10.1016/j.procs.2023.07.025>
- Pośpiech, E. (2019). Effective portfolios – An application of multi-criteria and fuzzy approach. *Folia Oeconomica Stetinensia*, 19(1), 126-139. <https://doi.org/10.2478/fofi-2019-0009>
- Romanko, O., Narayan, A. ve Kwon, R. H. (2023). ChatGPT-based investment portfolio selection. *Operations Research Forum*, 4(4), 1-27. <https://doi.org/10.1007/s43069-023-00277-6>
- Saaty, T. L., Rogers, P. C. ve Pell, R. (1980). Portfolio selection through hierarchies. *The Journal of Portfolio Management*, 6(3), 16-21. <https://doi.org/10.3905/jpm.1980.408749>
- Sanjib Biswas, Joshi, N. ve Jayanta Nath Mukhopadhyaya. (2023). ChatGPT in investment decision making: An introductory discussion. <https://doi.org/10.13140/RG.2.2.36417.43369>
- Souliotis, G., Alanazi, Y. ve Papadopoulos, B. (2022). Construction of fuzzy numbers via cumulative distribution function. *Mathematics*, 10(18), 3350. <https://doi.org/10.3390/math10183350>
- Svoboda, I. ve Lande, D. (2024). Enhancing multi-criteria decision analysis with AI: Integrating analytic hierarchy process and GPT-4 for automated decision support. <https://doi.org/10.48550/arxiv.2402.07404>
- Tanaka, H. ve Guo, P. (1999). Portfolio selection based on upper and lower exponential possibility distributions. *European Journal of Operational Research*, 114(1), 115-126. [https://doi.org/10.1016/S0377-2217\(98\)00033-2](https://doi.org/10.1016/S0377-2217(98)00033-2)
- Tiryaki, F. ve Ahlatçioğlu, B. (2009). Fuzzy portfolio selection using fuzzy analytic hierarchy process. *Information Sciences*, 179(1-2), 53-69. <https://doi.org/10.1016/j.ins.2008.07.023>
- Ullah, R., Ismail, H. B., Islam Khan, M. T. ve Zeb, A. (2024). Nexus between ChatGPT usage dimensions and investment decisions making in Pakistan: Moderating role of financial literacy. *Technology in Society*, 76, 102454. <https://doi.org/10.1016/j.techsoc.2024.102454>
- Vafaei, N., Ribeiro, R. A. ve Camarinha-Matos, L. M. (2016). Normalization techniques for multi-criteria decision making: Analytical hierarchy process case study. In *Doctoral Conference on Computing, Electrical and Industrial Systems* (pp. 261-269). https://doi.org/10.1007/978-3-319-31165-4_26
- Vaidogas, E. R., Zavadskas, E. K. ve Turskis, Z. (2007). Reliability measures in multicriteria decision making as applied to engineering projects. *International Journal of Management and Decision Making*, 8(5-6), 497-518. <https://doi.org/10.1504/IJMDM.2007.013414>
- Yadav, S., Kumar, A., Mehlawat, M. K., Gupta, P. ve Charles, V. (2023). A multi-objective sustainable financial portfolio selection approach under an intuitionistic fuzzy framework. *Information Sciences*, 646, 119379. <https://doi.org/10.1016/j.ins.2023.119379>

Research Article (Special Issue) | Araştırma Makalesi (Özel Sayı)

Çevrimiçi perakendecilikte sohbet robotu kullanımında etkileşim, güven antropomorfizm ve kullanım seviyesinin müşteri memnuniyetine etkisi

Keti Ventura

Tuğberk Karabaşak

Prof. Dr., Ege Üniversitesi, keti.ventura@ege.edu.tr, [0000-0002-6422-0518](https://orcid.org/0000-0002-6422-0518)Doktor Adayı, Ege Üniversitesi, tugberkcarabasak@gmail.com, [0000-0002-0742-0038](https://orcid.org/0000-0002-0742-0038)Corresponding author/Sorumlu yazar: Keti Ventura ✉ keti.ventura@ege.edu.tr

Öz

Günümüzde sohbet robotları, çevrimiçi perakende ortamlarında giderek yaygınlaşmakta ve markaların müşterilerle etkileşim kurma ve hizmet sunma biçimlerini yeniden tasarlamalarına neden olmaktadır. Özellikle genç nüfus yoğunluğunun artması, yoğun iş temposu ve çevrimiçi perakendeciliğin hızla yayılması gibi nedenlerle daha iyi müşteri deneyimi yaratmak ve rekabet avantajı elde etmek amacıyla sohbet robotu hizmetlerinin giderek arttığı görülmektedir. Sohbet robotlarının çok sayıda özelliği olmasına karşın, özellikle sohbet robotlarıyla kurulan etkileşim, sohbet robotlarına yönelik güven algısı ve cansız varlıklara insani özellikler yüklenmesini ifade eden antropomorfik özellikler, kullanıcıların memnuniyet düzeylerini etkilemektedir. Bu doğrultuda araştırmanın amacı, çevrimiçi perakendecilikte kullanılan sohbet robotlarının etkileşim, güven, kullanım seviyesi ve antropomorfik özelliklere ilişkin tüketici algılarının müşteri memnuniyetine etkisini ölçmektir. Bu kapsamda örnekleme yöntemi olarak kolayda örnekleme yöntemi, veri toplama yöntemi olarak da anket tekniği kullanılarak 396 kişiye ulaşılmıştır. Elde edilen veriler SPSS 25 programında analiz edilmiştir. Araştırma sonucunda, sohbet robotlarının etkileşim, güven, antropomorfizm özellikleri ile kullanım seviyesinin müşteri memnuniyeti üzerinde olumlu bir etkiye sahip olduğunu ancak, en kuvvetli etkinin güven değişkeninden sağlandığı ortaya çıkmıştır.

Anahtar Kelimeler: Sohbet Robotu, Çevrimiçi Perakendecilik, Müşteri Memnuniyeti, Antropomorfizm **JEL Kodları:** M30, M31

The impact of interaction, trust, anthropomorphism, and usage level of chatbots on customer satisfaction in online retailing

Abstract

Today, chatbots are becoming increasingly common in online retail environments, causing brands to redesign how they interact with customers and deliver services. It is seen that chatbot services are increasing to create a better customer experience and gain a competitive advantage, especially due to the increase in the young population, busy work schedules, and the rapid spread of online retailing. Although chatbots have many features, especially interaction, the perception of trust and anthropomorphic features, which refer to the attribution of human characteristics to inanimate beings, affect users' satisfaction levels. Accordingly, this study aims to measure the effect of consumer perceptions of interaction, trust, anthropomorphic features, and chatbot usage on customer satisfaction in online retailing. In this context, 396 people were reached by using the convenience sampling method, and the survey technique was used as the data collection method. The data obtained were analyzed in the SPSS 25 program. Although the research findings show that the interaction, trust, and anthropomorphism characteristics and usage levels of chatbots positively affect customer satisfaction, the trust variable provides the strongest effect.

Keywords: Chatbot, Online Retailing, Customer Satisfaction, Anthropomorphism **JEL Codes:** M30, M31

Extended Summary

Today's world is undergoing great change and transformation in both business and daily life due to the impact of digitalization. With the spread of Internet access, mobile device ownership, and digitalization, most societies, especially young people, use these technologies in their daily activities. Especially factors such as busy work life, time, and energy costs cause consumers to shop online frequently. This situation causes businesses to be more customer-oriented in their online retailing activities and to compete in creating a better customer experience. Artificial intelligence-based technologies have recently made it necessary to redesign the service offered to understand the consumer better.

How to cite this article / Bu makaleye atıf vermek için:

Ventura, K., & Karabaşak, T. (2024). Çevrimiçi perakendecilikte sohbet robotu kullanımında etkileşim, güven antropomorfizm ve kullanım seviyesinin müşteri memnuniyetine etkisi. *KOCATEPEİİBFD*, 26(Özel Sayı), 81-100. <https://doi.org/10.33707/akuiibfd.1459114>

Chatbots, the most frequently used technologies among those, are constantly being developed to understand consumers' needs. They have many benefits, such as accelerating processes in sales and marketing activities, providing convenience, informing consumers accurately, and providing personalized services and solutions. With continuous improvements, chatbots can now serve as business personnel and provide services to improve brand-customer relationships. Although consumers may be reluctant or have ethical concerns regarding using chatbots today, some features of these robots may encourage them to use them. In particular, the ability of chatbots to interact with consumers by providing accurate information, problem solutions, and accessibility without time and space restrictions enables consumers to use this technology more frequently, which also increases service satisfaction. In addition, the accuracy and completeness of the information provided or the feeling of trust in ensuring the confidentiality of personal information will ensure that users are satisfied with the service they receive. Although traditional shopping habits prioritize the service received from real customer representatives, today, it is seen that adding human characteristics, known as anthropomorphism, to chatbots creates satisfaction in consumers. In this context, the study aims to measure the impact of consumer perceptions regarding interaction, trust, usage level, and anthropomorphic features of chatbots used in online retailing on customer satisfaction. In the literature, a single dimension has generally been considered to measure the impact of different chatbot features on customer satisfaction. However, the lack of studies that address multiple dimensions of chatbots and the fact that this research is the first attempt to fill this gap and create an infrastructure for future studies are considered the most important contributions of the study.

The field research was designed as descriptive research, and the survey technique was utilized. The main population of the research consists of consumers who reside in Turkey, are over the age of 18, and have used or intend to use chatbots. This research used a convenience sampling method, and online surveys were shared on the internet and social media platforms between November 2023 and December 2023. A total of 396 people were reached. In the survey, statements to measure perceptions of chatbot features and customer satisfaction were adapted from the scales whose validity and reliability have been proven in the literature. A 5-point Likert-type scale ("1: Strongly Disagree"; "5: Strongly Agree") was utilized. The data obtained was analyzed and interpreted using the SPSS 25.0 program.

At the end of the research, it is revealed that trust, anthropomorphism, interaction features, and the level of usage positively affect customer satisfaction. Moreover, age, education, and usage are considered partial mediators between trust, anthropomorphism, interaction, and customer satisfaction. The study's findings provide useful information for future researchers, industry professionals, and designers to better understand user profiles and create unique experiences. This study is expected to show the necessity of integrating chatbot technology into the marketing strategies of online retailers and shed light on redesigning their services. Despite its limitations, especially in consideration of 4 variables that affect customer satisfaction, this study can be improved by a more comprehensive model consisting of additional factors such as technology acceptance, emotional interaction, and user experience with a more representative sample.

Giriş

Günümüz dijital çağında yapay zekanın, özellikle de sohbet robotlarının birçok işi gerçek kişilerden devralabileceği öngörülmektedir (Letheren vd., 2020). Makine öğreniminin ve doğal dil işleme teknolojisinin geliştirilmesi ve uygulanması, birçok işletmede rutin hizmetleri gerçekleştirmek ve işlemleri kolaylaştırmak için gerçek kişiler yerine, sohbet robotlarının kullanılmasını gerektirmektedir (Wamba vd., 2021). Özellikle satıştan, satış sonrası destek ve pazarlamaya kadar pek çok alanda 7/24 hizmet sunabilen robotlar (Ashfaq vd., 2020), müşteri hizmetleri alanında önemli ölçüde dönüşümler sağlamış, bu durum da kullanıcılar ve işletmeler için büyük avantajlar yaratmıştır (Wirtz vd., 2018).

Yapay zekâ algoritmaları, müşteri alışkanlıklarını, satın alma davranışlarını, tüketici beğenilerini, yorumlarını, tepkilerini ve bunun gibi çok sayıda veriyi analiz edebilmektedir (Chatterjee vd., 2019). Özellikle müşteri ilişkileri yönetimi yazılımları günümüzde yapay zekâ kullanıcı arayüzü aracılığıyla, daha gerçekçi ve isabetli tahminlemeler ve öneriler geliştirebilmektedir (Seranmadevi ve Kumar, 2019). Bu özellikleriyle yapay zekâ teknolojileri, geleneksel perakende mağazalarını akıllı perakende mağazalarına dönüştürmekte bu da müşteri deneyimini ve alışveriş kolaylığını arttırmaktadır (Verma vd., 2021). Yapay zekâ, fiziksel mağazaların yanı sıra çevrimiçi işletmelere de rehberlik etmektedir (Verme vd., 2021). Sha ve Rajeswari (2019) yapay zekanın hızla geliştirilmesiyle artık insanların beş duyu organını takip edebildiğini, bunun da e-ticaret işlemlerinde daha iyi bir tüketici-marka ilişkisi yarattığını ifade etmiştir.

Yapay zekâ teknolojilerinden biri olan sohbet robotları erişilebilirliği, esnekliği ve düşük maliyeti nedeniyle hem son kullanıcılar hem de işletmeler tarafından sıklıkla kullanılmaktadır (Przegalinska vd., 2019; Ashfaq vd., 2020). Kullanıcılar ürün veya hizmetle ilgili bilgiler edinmek ya da çevrimiçi sipariş vermek için bu programlarla etkileşime girmektedirler. Son yıllarda insan-sohbet robotu etkileşiminin artmasıyla birlikte, kullanıcılar artık akıllı telefonlar, dizüstü bilgisayarlar, tabletler veya masaüstü bilgisayarlar gibi çeşitli cihazlar ile sohbet robotlarıyla iletişim kurabilmektedirler (Luo vd., 2019). Dijital asistan olarak da nitelendirilebilen bu

robotlarının amacı, internet üzerinden tüketicilere herhangi bir zaman ve mekân kısıtı olmadan bir satış temsilcisi gibi hizmet vermektir (Chung vd., 2020). Dolayısıyla, bu teknolojiler, tüketicilere yalnızca bilgi sağlamakla kalmamakta, aynı zamanda kişisel asistan gibi etkileşime de girmektedirler (Ashfaq vd., 2020).

İş süreçlerinde sohbet robotları yoğun bir şekilde kullanmasına rağmen, tüketicilerin bu teknolojiyi benimsemesi ve kullanması nispeten düşük düzeyde kalmaktadır (Ashfaq vd., 2020). Bu teknolojilerin, antropomorfik özellikler ile tüketicilere daha iyi hizmet deneyimleri sunmalarına olanak tanıyan sosyal, duygusal ve ilişkisel öğelerle donatılmış (Mozafari vd., 2022) olmalarına rağmen, hizmet hataları nispeten devam etmektedir (Lei vd., 2021; Michaud, 2018). Özellikle de tüketiciler nezdinde karmaşık durumları anlamada gerçek kişilerin sohbet robotlarından daha başarılı olduğuna ilişkin genel bir kanı bulunmaktadır (Forbes, 2019).

Yukarıda da detaylı anlatıldığı üzere, çevrimiçi perakendeciliğin hızla yaygınlaşmasıyla, tüketicilerin bu teknolojilere yönelik algıları müşteri memnuniyetini etkileyebilmektedir. Müşteri memnuniyetine yönelik olarak literatürde farklı tanımlar olsa da tanımların ortak özellikleri arasında müşteri memnuniyetinin (i) duygusal ya da bilişsel bir tepki olması (ii) bu tepkinin ürün, hizmet, deneyim ya da beklentiler gibi belirli bir odağının olması ve (iii) tepkinin tüketim sonrası, seçim sonrası ya da bütünsel bir deneyime dayalı olması gibi belirli bir zaman diliminde oluşması yer almaktadır (Giese, ve Cote, 2000). Locke (1967, 1969) tarafından formüle edilen Değer Algı Farklılık Teorisi'ne (Value Percept Disparity Theory) göre, müşteri memnuniyeti bilişsel-değerlendirici bir süreçle tetiklenen duygusal bir tepki süreci olmaktadır. Bu süreçte, bir nesne, eylem veya durum hakkındaki algılar veya inançlar, bireyin arzuları, istekleri ve ihtiyaçlarını içeren değerleri ile karşılaştırılmaktadır (Akintan ve diğerleri, 2020; Westbrook ve Reilly, 1983). Algılanan özellikler ile kişisel değerler arasındaki farklılık ne kadar küçükse, memnuniyet o kadar yüksek olmaktadır (Westbrook ve Reilly, 1983). Değer Algı Farklılık Teorisi temeline dayanan bu çalışma etkileşim, güven ve insansı özellikler sergileyen sohbet robotlarına yönelik algıların müşteri memnuniyetine olası etkilerinin ölçülmesine dayalı olarak tasarlanmıştır. Bu doğrultuda bu araştırmanın amacı, çevrimiçi perakendecilikte kullanılan sohbet robotlarının etkileşim, güven, kullanım seviyesi ve antropomorfik özelliklere ilişkin tüketici algılarının müşteri memnuniyetine etkisini ölçmektir. Dolayısıyla çalışmanın araştırma sorusu; "etkileşim, güven, kullanım seviyesi ve antropomorfik özellikler bütünsel olarak sohbet robotlarından memnuniyet düzeyini etkilemekte midir?" olarak belirlenmiştir. Bu konuda literatürde de çeşitli çalışmalar bulunmaktadır. Örneğin, sohbet robotlarının güven (Zehir vd., 2011; Eren, 2021), hizmet kalitesi (Yun ve Park, 2022), etkileşim (Teo vd., 2008; Chung ve Kwon, 2009; Chung vd., 2020; Cheng ve Jiang, 2022; Xu vd., 2023), antropomorfik nitelikler (Luo vd., 2019; Klein ve Martinez, 2023; Konya-Baumbach vd., 2023) gibi özelliklerinin müşteri memnuniyeti üzerindeki etkilerine ilişkin çeşitli çalışmalar yapılmıştır. Ancak, sohbet robotlarının çoklu boyutlarını bir arada ele alan çalışmaların sınırlılığı ve bu çalışmada bu faktörlerin bir bütün olarak ele alınmasıyla dijital pazarlama literatürüne önemli bir katkı sağlaması beklenmektedir. Ayrıca iş süreçlerinde yapay zekanın, özellikle de sohbet robotlarının sürekli geliştiriliyor olması ve bu teknolojilerin firmaların pazarlama süreçlerinde kullanımının gelecekte de artacağı beklentisi nedeniyle araştırmada belirlenen değişkenlerin müşteri memnuniyetine olan olası etkileri ya da yaratabileceği sorunların ortaya konması anlamında da pazarlama profesyonellerine, farkındalığın artırılması anlamında, katkı sağlaması beklenmektedir. Bu bağlamda, çalışmanın ilk bölümünde yapay zekâ kavramının kapsamına ve pazarlama alanındaki kullanım alanlarına değinildikten sonra, sohbet robotu kavramının pazarlama alanında nasıl kullanıldığına ve sohbet robotu kullanımı ile müşteri memnuniyeti ilişkisi üzerinde durulacaktır. Son bölümde de çevrimiçi gıda perakendeciliğinde sohbet robotları kullanımının müşteri memnuniyetine etkisini ölçmeye yönelik yapılan alan araştırması bulgularına, sonuçlarına ve önerilere yer verilmiştir.

1. Yapay Zekâ Kavramı ve Pazarlama Uygulamaları

Yapay zekâ, genel olarak insan zekasının makineler aracılığıyla ifade edilmesi (Siau ve Yang, 2017) veya algoritma kullanımı yoluyla insanlar gibi düşünebilen ve performans gösterebilen bilgisayarlar olarak tanımlanmıştır (Kumar vd., 2019). Yapay zekanın destekleyici teknolojisi, problem çözme ve öğrenme yeteneği de dahil olmak üzere insan zihninin işlevlerini taklit edebilmektedir (Chen vd., 2022). Bu nedenle, yapay zekâ verileri toplayabilmekte, işleyebilmekte ve tanımlayarak belirli sonuçlar çıkarabilmektedir (Jarek ve Mazurek, 2019). Başka bir deyişle, yapay zekâ, makinelerin deneyimlerden öğrenmesini ve insan benzeri işlevleri yerine getirmesini sağlayan bir teknolojidir (Davenport vd., 2020). Yapay zekanın birçok alanda olduğu gibi pazarlama disiplinde de oldukça geniş bir kullanım alanı bulunmaktadır.

1.1. Yapay Zekânın Kapsamı

Yapay zekâ, bilgisayarların insanlar tarafından çözülebilecek sorunları çözmesine yardımcı olmak amacıyla algoritmalar kullanarak akıllı makineler yaratan bir bilimdir (Bag vd., 2021). Bu teknolojinin oldukça geniş, farklı özelliklere sahip türleri mevcuttur. Genel olarak, güçlü ve zayıf yapay zekâ olmak üzere iki türü bulunmaktadır (Chen vd., 2022). Güçlü yapay zekâ, birden fazla alanda zekâ sergileyen ve çeşitli görevleri yerine getirebilen gelişmiş ve karmaşık bir makinedir. Buna karşılık, zayıf yapay zekâ, sohbet robotları gibi daha dar kapsamlı görevleri yerine getirerek belirli bir alana odaklanan nispeten basitleştirilmiş bir makineyi ifade etmektedir (Siau ve Yang, 2017). Pazarlama alanıyla ilgili uygulamaların çoğu zayıf yapay zekâ aşamasındadır.

Yapay zekâ ile ilişkili terimler arasında makine öğrenimi, derin öğrenme, doğal dil işleme ve robotik kavramları da yer almaktadır

(Chen vd., 2022). Tüm bu teknolojiler, pazarlama alanında müşteriler için olumlu bir deneyim yaratmak için kullanılmaktadır.

1.2. Pazarlamada Yapay Zekâ Uygulamaları

Pazarlama alanında ses, metin, görüntü tanıma, karar verme, otonom araçlar ve robotlar gibi çeşitli yapay zekâ uygulamaları kullanılmaktadır (Jarek ve Mazurek, 2019). Yapay zekaların her türü kendine özgü faydalar sağlayabilmekte ve bu durum da pazarlama faaliyetleri için marka-müşteri ilişkilerinin geliştirilmesine katkıda bulunabilmektedir. Örneğin, mekanik yapay zekâ standardizasyonu sağlamak için kullanılabilirken; düşünen yapay zekâ kişiselleştirme, hisseden yapay zekâ ise müşteriler ile ilişki kurma faaliyetlerine yönelik olarak kullanılabilir (Huang ve Rust 2020).

Mekanik yapay zekâ, tutarlı olma kabiliyeti nedeniyle standardizasyon faydaları sağlamaktadır (Huang ve Rust, 2021). Örneğin, işbirlikçi robotlar (cobot) paketlemeye yardımcı olabilmekte (Colgate vd. 1996), dronlar fiziksel malları dağıtabilmekte, self-servis robotlar hizmet sunabilmektedir (Mende vd., 2019; vanDoorn vd., 2017). Tüm bu uygulamalar standartlaştırılmış, tutarlı ve güvenilir sonuçlar üretmeyi amaçlamaktadır (Huang ve Rust, 2021).

Düşünen yapay zekalar, verilerden kalıpları tanıma yeteneği sayesinde kişiselleştirme imkânı tanıyabilmektedir. Metin madenciliği, yüz tanıma özellikleri (Huang ve Rust, 2021), Netflix film önerileri ya da Amazon çapraz satış önerileri gibi çeşitli kişiselleştirilmiş öneri sistemleri bunlardan bazılarıdır (Chung vd., 2016).

Hisseden yapay zekâ ise duyguları tanıma ve bunlara yanıt verme kabiliyeti sayesinde ilişki kurma ve bu ilişkileri kişiselleştirme faydası sağlayabilmektedir (Huang ve Rust, 2021). Etkileşim ve iletişim gerektiren, ilişkiyel faydalar hedefleyen pazarlama faaliyetlerinde, hisseden yapay zekâ oldukça önemli hale gelmektedir. Müşteri hizmetleri ya da satış sonrası destek hizmetleri gibi süreçlerde hisseden yapay zekâ oldukça yararlı olmaktadır (Huang ve Rust, 2021).

Yapay zekanın pazarlamadaki uygulama alanlarından en önemlilerinden biri metin madenciliği yoluyla sunulan içeriklere yönelik tüketici tepkilerini sınıflandırmak ve müşteri kayıplarını tahminleyerek, doğru stratejiler geliştirilebilmesidir (Overgoor vd., 2019). Deshpande (2019), yapay zekanın pazarlamadaki uygulama alanlarını dokuz başlıkta özetlemektedir: içerik oluşturma, karşılıklı konuşabilme, segmentasyon, tahmine dayalı analizler, kişiselleştirme, ücretli reklamlar, satış tahminleri, dinamik fiyatlandırma ve öneri sistemleri. Bu tür uygulamalar, mevcut ve potansiyel tüketicilere yönelik kişiselleştirilmiş hizmetler sunabilmekle birlikte, tüketicilerle uzun süreli bir ilişki kurulmasını ve sürdürülebilmesini sağlayabilmektedir (Stephen ve Ahmad, 2017). Özellikle son dönemde, rekabetin git gide artmasıyla birlikte oldukça önemli hale gelen kişiselleştirilmiş müşteri deneyimi yaratmada yapay zekanın tahmin, öneri ve uyarılabilmek gücü önemli bir rekabet avantajı yaratabilmektedir (Chen vd., 2022).

Doğal dil işleme, görüntü tanıma ve karar verme gibi uygulamalar pazarlama alanında bilişsel teknolojilerin kullanıldığı diğer önemli araçlardır (Jarek ve Mazurek, 2019). Özellikle, konuşulan ifadeleri ya da kelimeleri tanımlama, tamamlama ve anlama yeteneğine sahip, 7/24 kullanılabilen sohbet robotları müşteri hizmetleri, pazarlama faaliyetleri ve satış desteğinde giderek daha fazla kullanılmaya başlamıştır (Chen vd., 2022). Yapay zekanın strateji geliştirme alanında kullanılmasının en temel faydalarından biri, karar alma süreçlerinde bilişsel önyargıların ortadan kaldırılması olmaktadır (Bag vd., 2021).

Günümüzde dijital pazarlama ve sosyal medya stratejilerinin geliştirilmesinde de yapay zekanın kullanımı yadsınamayacak kadar fazladır (Verma vd., 2021). Bu teknolojiler ile müşteri profillerine göre içeriğin kişiselleştirilmesi ve özelleştirilmesi sağlanabilmekte (Huang ve Rust, 2020) aynı zamanda içeriğin etkinliği optimize edilebilmektedir (Verma vd., 2021). Aynı zamanda müşterilerin olumlu ya da olumsuz yorumları da gerçek zamanlı olarak takip edilebilmektedir (Tripathi ve Verma, 2018).

E-ticaret alanında da oldukça kullanım alanına sahip yapay zekâ teknolojileri, alışveriş sepetlerindeki ürünlerin ortak özelliklerini analiz ederek, ürün yelpazelerinin pazar yapılarını haritalandırabilmekte (Gabel vd., 2019), sosyal medya mecralarında sunulan içerik ile kullanıcı arasındaki ilişkileri keşfedebilmekte ve doğal dil işleme algoritmaları kullanarak sosyal medya içerik mühendisliğine yardımcı olabilmektedir (Lee vd., 2018).

Yapay zekanın pazarlama alanında diğer önemli kullanım alanlarından biri de tahmine dayalı analitik değerlendirmeler yapabilmek özelliğidir. Genellikle değişken pazar eğilimlerini ve müşterilerin heterojen tercihlerini tahminlemek için kullanılabilir (Huang ve Rust, 2021). Bu teknolojiler pazarlama içgörülerini (Berger vd., 2019) yaratmak için de oldukça yararlı olmaktadır. Özellikle düşünen yapay zekâ, bir pazardaki rakipleri veya oyuncuları belirlemek ve bir ürünün rekabet avantajına yönelik içgörüler elde etmek için kullanılabilir (Huang ve Rust, 2021). Bununla birlikte, son dönemde birçok işletmenin maruz kaldığı büyük veri analitiği de artık pazarlama içgörülerini üretmek için önemli bir yaklaşım haline gelmiştir (Berger vd., 2019; Chintagunta vd., 2016; Liu vd., 2016; Wedel ve Kannan 2016).

Yapay zekâ ayrıca segmentasyon, hedefleme ve konumlandırma stratejilerini geliştirmeye yönelik pazarlama faaliyetlerini de destekleyebilmektedir (Verma vd., 2021). Özellikle metin madenciliği ve makine öğrenimi algoritmaları, kârlı müşteri segmentlerinin belirlenmesi için bankacılık-finans, sanat pazarlaması, perakende ve turizm gibi sektörlerde kullanılmaktadır

(Dekimpe, 2020; Netzer vd., 2019; Pitt vd., 2020; Valls vd., 2018). Bu teknolojiler aynı zamanda ürün modelleme, hizmet inovasyonu ve tasarımlar için de önemli geliştirmeler yapabilmekte (Antons ve Breid-bach, 2018), ürün yönetimine yönelik pazarlama stratejilerin geliştirilmesine de yardımcı olabilmektedir (Dzyabura ve Hauser, 2019).

2. Sohbet Robotlarının Kapsamı ve Pazarlama

İşletmeler rekabet avantajı elde etmek, maliyetleri azaltmak ve müşteri hizmetlerinde kolaylık sağlamak amacıyla bu teknolojileri pazarlama süreçlerine dahil etmektedir.

2.1. Sohbet Robotu Kavramı

Sohbet robotu, kullanıcılarla mesajlaşma uygulamaları, web siteleri, mobil uygulamalar veya telefon üzerinden iletişim kuran yapay zekâ destekli bir hizmet aracı (Barış, 2020) olup, gerçek kullanıcılarla doğal konuşma dili aracılığıyla etkileşime giren bir makine konuşma sistemidir (Shawar ve Atwell, 2005). Bu teknoloji, girdi ve çıktı olarak doğal dili kullanarak insanlarla sohbet etmek için tasarlanmış yapay bir yapıdır (Brennan, 2006). Sohbet robotları aynı zamanda müşteriler, makine operatörleri, bakım görevlileri gibi operasyonda çalışan işletme personeli ile gerçek zamanlı olarak etkileşime girebilen konuşma motorlarıdır (Illescas-Manzano vd., 2021).

Literatürde sanal ajan (Ciechanowski vd., 2019), akıllı ajan (Hill vd., 2015), bot ajan veya otomatik program (Edwards vd., 2014), antropomorfik bilgi ajanı (Sivaramakrishnan vd., 2007) veya e-hizmet ajanı (Chung vd., 2018) gibi farklı isimler altında bulunan sohbet robotları, kişisel bir sekreter gibi çalışarak, kullanıcılara bilgi arama, arama sorgulama ve sosyal ilişkiler kurma gibi çoklu amaçlarda destek sağlayabilmektedir (Chung vd., 2018; Holzwarth vd., 2006; Huang vd., 2007). Bu teknolojiler, kullanıcıya bir uygulama, bir web sitesi, bir sohbet penceresi veya Facebook Messenger gibi bir sosyal ağ arayüzü aracılığıyla bağlanmaktadır (Illescas-Manzano vd., 2021). İşletmeler, müşterilerine olumlu deneyimler yaratmak amacıyla, eğlence ve bilgi desteği sağlayarak bu tür sanal ajanları şirket temsilcileri olarak kullanmaktadır (Chung vd., 2018; Holzwarth vd., 2006). Bununla birlikte, sohbet robotlarının kullanıcılar tarafından algılanan sözlü, görsel ya da işitsel uyarıları olumlu veya olumsuz tepkilere neden olabilmektedir (Feine vd., 2019). Bu nedenle bu teknolojilerin kullanıcılarla olan etkileşimi, bir şirket temsilcisinin müşterileriyle yaptığı yüz yüze görüşmeler kadar önem arz etmektedir.

Sohbet robotları çevrimiçi müşteri hizmetleri için yaygın olarak benimsenmiş olsa da birçok kullanıcı, algı ve empati eksikliği ya da sohbet robotlarının performansı hakkındaki belirsizlik nedeniyle onlarla etkileşime girme konusunda hala isteksiz olabilmektedir (Nguyen, 2019). Aynı zamanda kullanıcıların gizlilik endişeleri (Zamora, 2017) ve etkileşim zorluğu (Colace vd., 2017) hissetme gibi başka sorunları da bulunmaktadır.

2.2. Sohbet Robotlarının Özellikleri ve Kullanımını Etkileyen Faktörler

Sohbet robotları, kullanımı maliyet tasarrufu sağlayan, kullanıcılarla kalıcı bir ilişki sunabilen ve müşterilerle ilişkileri geliştirebilen ve farklı dillerde hizmet verebilen teknolojilerdir (Trappey vd., 2018; Hong vd., 2019). Sohbet robotları, insan müdahalesi olmadan müşteri hizmetlerini yönetebilmektedir. Özellikle, müşteri hizmetleri kapsamında sıklıkla sorulan soruları yanıtlamak gibi rutin görevleri otomatikleştirmektedir (Paschen vd., 2019). Bunun temel nedeni, geçmiş verilerin entegre yapay zekâ yeteneklerinin mantıksal yanıtlar üretmesine izin vermesidir (Paschen vd., 2019), bu durum da otomatikleştirmeyi güçlendirmektedir. Diğer taraftan, sohbet robotları ürünleri/hizmetleri, müşterilerin özel ihtiyaçlarını ve tercihlerini karşılayacak şekilde uyarlayabilmekte ve bu sayede müşterilerle olan ilişkileri geliştirebilmektedir (Chung vd., 2020). Ayrıca, her müşteriye aynı ürünleri/hizmetleri önermek yerine, her müşterinin geçmişine ve ilgi alanlarına göre farklı ürünler/hizmetler önerebilmektedir (Lin vd., 2022).

Bu teknolojiler, pazarlama faaliyetleri kapsamında markalar ve müşterileri arasındaki anlık etkileşimleri çevrimiçi olarak sürdürebilmekte ve müşterilerin karar verme süreçlerinde de onlara destek olabilmektedir (Appel vd., 2020; Klaus ve Zaichkowsky, 2020).

2.2.1. Etkileşim ve Kullanım Seviyesi

Etkileşim, siber dünyada müşteriler ve markanın sohbet robotu temsilcileri arasındaki iletişimi (Cheng ve Jiang, 2022) ifade etmektedir. Gerçek dünyadaki müşteri temsilcilerine benzer şekilde, sanal dünyada müşterilerin tek yönlü satın alımları, sanal hizmet temsilcileriyle iki yönlü iletişime dönüştürülmüş, bu da pazarlama iletişiminin dinamiklerini temelden değiştirmiştir (Chung vd., 2020). Sohbet robotlarının, müşterilere ürünler, hizmetler ya da markanın kendisi hakkında bilgi sağlayabilme özelliği de etkileşim sağlayabilmek anlamında oldukça önemlidir (Yao, 2017). Tüketiciler, diğer internet platformları yerine dijital yapay zekâ araçlarından bilgi almayı tercih edebilmektedir (Brill vd., 2019). Bunun nedeni, dijital yapay zekâ araçlarının kullanıcıların daha hızlı kararlar almasını sağlayan, aramalarla doğrudan ilgili ve hızlı bilgiler sunabilmesidir (Brill vd., 2019). Bunlara ek olarak, yapay zekâ teknolojisi müşteri bilgilerini zamanında ve anlık değerlendirme ve yanıtlayabilme kabiliyetine sahiptir (Cheng ve Jiang, 2022). Bu teknolojilere, zaman ve mekân kısıtı olmadan erişim sağlayabilme, günümüzde sohbet robotlarının pazarlama iletişimine getirdiği

en önemli özelliklerden biri haline gelmiştir (Zarouali vd., 2018).

Sohbet robotu ile gerçekleştirilen etkileşim sürecinde iletişimin türü ve iletişim mekanizması daha iyi bir hizmet kalitesi için oldukça önemli olmaktadır (Haugeland vd., 2022). Özellikle uzmanlık bilgisi verilmesinin kritik olduğu durumlarda belirli bir problemi çözmeye yönelik gerçekleştirilen görevler ile detaylı tartışma gerektiren konularda kurulan etkileşim, hizmet kalitesini arttırmakta ve kullanıcıların bu etkileşimden keyif almasını sağlamaktadır (Roller vd., 2020). Buna ek olarak, söz konusu memnuniyet düzeyi, sohbet robotlarını daha sık kullanan ve dijital bilgi düzeyi yüksek olan kişilerde daha da artmaktadır (Wiliam vd.,2019). Özellikle de sohbet robotları ile olumlu bir etkileşim nedeniyle bu teknolojiyi daha sık kullananların söz konusu robotlara olan bağlılığı da fazla olmaktadır (Malodia vd.,2024). Ancak, diğer taraftan Zeithaml ve Bitner (1996) ile Harvey (1998), teknolojik bir iletişim aracını kullanma konusunda daha deneyimli olan tüketicilerde müşteri memnuniyeti sağlamanın daha zor olduğunu ifade etmiştir. Bunun da temel nedeninin tüketicinin zaman içinde değişen ve gelişen beklentilerinin karşılanmasının daha zor olmasından kaynaklandığını belirtmiştir.

2.2.2. Güven

İnsan-bot etkileşimleri arasında doğruluk ve güvenilirlik kullanıcıların güvenini önemli ölçüde belirlemektedir (Yagoda ve Gillan, 2012). *Doğruluk*, sohbet robotlarının sağladığı pazarlama bilgilerinin kesinliğini ifade etmektedir (Cheng ve Jiang, 2022). Müşteriler, hizmetlerin zamanında, yeterli ve eksiksiz gerçekleşmesi durumunda iletişimin doğruluğuna güvenmektedir (Barry ve Crant, 2000). *Güvenilirlik* ise sohbet robotlarının inanılabilirliğini ifade etmektedir (Cheng ve Jiang, 2022). Herhangi bir bilgisayar aracılı iletişime güvenmeleri için sohbet robotlarının doğru ve eksiksiz bilgi verdiklerine ilişkin algılamalarının olmaları gerekmektedir (Edwards vd., 2014). Markaların müşterileriyle olan çevrim içi etkileşimlerinde en doğru bilgilendirmeler ile müşteri istek ve ihtiyaçlarına proaktif olarak sağlanan katılım, müşterilerin bu tür insan-bot iletişimini doğru ve güvenilir olarak algılamalarını sağlamaktadır (Chung vd., 2020). Ayrıca, sohbet robotlarının gerçek insan özellikleri barındırması, kişilerde gerçek bir kişi ile etkileşim içinde olma ve sosyallik hissi vermekte, bu durum da sosyal bulunuşluk (social presence) hissini arttırmaktadır. Kullanıcılarda sosyal bulunuşluk hissini artırması sohbet robotuna daha fazla güvenilmesini sağlamaktadır (Pantano ve Pizzi, 2020).

Diğer taraftan, sohbet robotlarının daha kişiselleştirmiş hizmetler sunmak için kişisel bilgilerin istemesi ise dijital gizlilik ve güvenlik kaygılarını da beraberinde getirmektedir. Bu tür kaygılar, tüketicilerin bu teknolojilere olan güvenlerini sorgulamalarına sebep olmakta, bu durum da sohbet robotlarını kullanma konusunda isteksiz olmalarına neden olmaktadır (de Cosmo vd., 2021).

2.2.3. Antropomorfizm

Antropomorfizm, insani özelliklerin ve karakteristiklerin insan olmayan obje, ürün, marka ya da herhangi bir nesneye yüklenmesidir. Genellikle kişiler, antropomorfik objelere karşı daha bağlı hissetmektedirler. Bu durum da tüketicilerin karar verme davranışlarını etkilemektedir (Aggarwal ve McGill, 2012). Antropomorfik sohbet robotları, insani özellikler olarak nitelendirilebilen sözlü ya da sözlü olmayan niteliklerin robotlara yüklendiği, insan algısının yaratıldığı dijital ajanlardır (Cyr vd., 2007). Sohbet robotlarının insanlaştırılmış bir etkileşim sunması ve müşteriler ile firmalar arasındaki sosyal ilişkileri geliştirmeye yardımcı olan sosyal özellikleri olması nedeniyle tüketiciler tarafından tercih edilebilmektedir (Sowa vd., 2021). Antropomorfik özellik, robotların sosyal bir aktör olarak algılanmasını sağlamakta (Balakrishnan ve Dwivedi, 2021; Murtarelli vd., 2021) ve genellikle gerçek kişileri taklit etmesi nedeniyle tüketiciler tarafından kullanımı daha kolay olarak algılanmaktadır. Bir sohbet robotunun insani özellikleri ne kadar fazla ise kullanıcılar tarafından benimsenmesi de o kadar hızlı olabilmektedir (Sheehan, 2020). Bu teknolojilerin işletmelere sağladığı maliyet avantajı ve hızın yanı sıra, robotların insani özellikleri, sunulan hizmeti müşteriler açısından daha keyifli hale getirebilmekte (Lin vd., 2022), bu durum da sohbet robotlarının benimsenmesini hızlandırabilmektedir.

3. Sohbet Robotlarının Kullanımını Etkileyen Faktörler ve Müşteri Memnuniyeti

Sohbet robotları, müşteri ihtiyaçlarını 7/24 karşılamak amacıyla kişiselleştirilmiş hizmet sunabilen teknolojik bir destektir (Chung vd., 2020). Bu teknolojiler, tüketicilere hem kişiselleştirilmiş hizmet sunabilme hem de insani özellikler ile gerçek kişiler gibi müşterilere destek olma amacına yönelik olarak tasarlanmıştır (Glavas ve Letheren, 2017). Bu özellikleriyle sohbet robotları, sosyal etkileşim sağlayabilmekte (Whang vd., 2022) ve olumlu müşteri deneyimleri yaratabilmektedirler.

Araştırmalar, sohbet robotlarının farklı bağlamlarda müşteri memnuniyetini artırdığını göstermektedir (Chung vd., 2018; Holzwarth vd., 2006). Müşteri memnuniyeti, müşterilerin ürün veya hizmetler hakkındaki olumlu beklentilerinin karşılandığı veya aştığı durumlarda ortaya çıkan bir hissiyat olarak ifade edilmektedir (de Oliveira Santini ve diğerleri, 2018). Başka bir tanımlamaya göre, müşteri memnuniyeti, bir ürün veya hizmetin kullanılması sonrasında müşterilerin tatmin düzeyini ifade etmektedir (Parker ve Mathews, 2001). Kalite, fiyat, hizmet kalitesi, marka itibarı ve genel müşteri deneyimi gibi çeşitli unsurlar müşteri memnuniyetini etkilemektedir (Shokouhyar ve diğerleri, 2020). Locke (1967, 1969) tarafından formüle edilen Değer Algı Farklılık Teorisi'ne göre de müşteri memnuniyetinin temel belirleyicisi, bireyin algıları ile değerleri arasındaki farka dayalı olmaktadır. Diğer bir ifadeyle, bireylerin ürün, hizmet ya da yaşadıkları bir deneyime karşı algılarının, arzuları, istekleri ve ihtiyaçları ile karşılaştırılması sonucu


oluşan duygusal bir tepki olduğu öne sürülmektedir. Buna göre, çevrim içi alışverişlerde bir sohbet robotu deneyimi yaşayan bir tüketici, yaşadığı deneyim sonucu algıladığı hizmet ile arzularını, isteklerin ve değerlerini karşılaştırarak memnuniyet düzeyini belirleyebilmektedir.

Sohbet robotları ile kurulan etkileşimlerde gerek sohbet robotlarının gerekse sunulan hizmetin özellerinden kaynaklı olarak müşteri memnuniyeti ya da memnuniyetsizliği sağlanabilmektedir. Örneğin, tüketicilerin insan-sohbet robotu etkileşimlerinde, sohbet robotlarının yetkinliği, müşteri memnuniyetini olumlu yönde etkilemekte ve tüketicilerin markayı başkalarına tavsiye etme niyetlerini arttırmaktadır (Kallel vd., 2023). Bu kapsamda örneğin, Chung vd. (2018), sohbet robotu kullanımının, daha yüksek müşteri memnuniyetine yol açtığını, bunun en temel nedeninin de sohbet robotlarının müşterilerle etkileşime girebilmesinden ve etkileşimli müşteri hizmetleri sunabilmesinden kaynaklandığını ifade etmiştir. Özellikle marka ve tüketiciler arasındaki ilişkilerin kurulmasında sohbet robotları ile olan etkileşim, bilgiye erişim, eğlence hissini yaratılması ve kişiselleştirilmiş hizmet, müşteri memnuniyetini olumlu yönde etkileyebilmektedir (Cheng ve Jiang, 2022). Özellikle müşterilerin sorunlarına yönelik sunulan uzmanlık bilgisi, problem çözebilme ve her an ulaşılabilir olma müşteri memnuniyetini olumlu yönde etkilemektedir. Wang vd. (2007), sohbet robotlarının tüketiciler tarafından doğru zamanda doğru soruna çözüm bulabilen bir çalışan gibi algılandığını ifade etmiştir. Holzwarth vd. (2006) de, çevrimiçi alışverişte sohbet robotlarının, tüketicilerin perakendecilerden daha fazla memnuniyet duymasına, ürüne karşı daha olumlu bir tutumun geliştirilmesine ve satın alma niyetinin artırılmasına neden olduğunu ortaya koymuştur. Bu tür teknolojiler, kişiselleştirilmiş bilgi sağlayarak kullanıcıların ihtiyaçlarını/arzularını tatmin etme ve alışveriş deneyimini daha keyifli hale getirme potansiyeline sahip olabilmektedir (Ashfaq vd., 2020). Sohbet robotu tarafından sağlanan bilgilerin kişiselleştirilmiş, anlaşılması kolay ve iyi biçimlendirilmiş olması, müşteri memnuniyeti üzerinde olumlu bir etki bırakmaktadır (Teo vd., 2008; Chung ve Kwon, 2009). Diğer taraftan, sohbet robotları tarafından sunulan düşük kaliteli ve güncel olmayan bilgi, kötü bir kullanıcı deneyimi sağlayacak olup, kullanıcılarda güvensizlik yaratabilecektir. Bu durum da müşterilerde memnuniyetsizliğe yol açabilecektir (Gao vd., 2015). Bir sohbet robotunun iyi tasarlanması ve kullanıcıların endişelerini anlayıp, sorunlarına hızlı bir şekilde yanıt verebilmesi, kullanıcıların memnuniyet düzeyini artırabilecektir (Ashfaq vd., 2020). Öte yandan, etkin bir etkileşim sağlayamayan, zayıf bir arayüz tasarımına sahip, zamanında ve doğru bilgiler veremeyen sohbet robotlarına yönelik kullanıcıların güveni azalacaktır (Gao ve Waechter, 2017), bu da memnuniyet düzeylerini düşürecektir. Müşteriler markanın çevrimiçi hizmet temsilcileriyle iletişime geçtiklerinde gerekli ve güvenilir bilgiler aldıklarında (Mimoun vd., 2017; Jiménez-Barreto vd., 2021) markaya karşı yüksek düzeyde güven, memnuniyet ve bağlılık algılamaktadırlar (Zehir vd., 2011). Güven, kullanıcıların davranışsal niyetlerini olumlu etkilemekte ve bu teknolojilerin benimsenmesini hızlandırmaktadır (Prakash vd., 2023). Örneğin, Eren (2021), tüketicilerin teknoloji tabanlı finansal ürün ve hizmetlere yönelik bankacılık hizmetlerinde sohbet robotlarına yönelik kaygılarının, müşteri memnuniyetini engelleyebildiğini, ancak sohbet robotu hizmetlerine olan güvenin müşteri memnuniyetini olumlu yönde etkilediğini ortaya koymuştur.

Sohbet robotlarının yukarıda sayılan özelliklerine ek olarak, cansız nesnelere insani özellikler yüklenmesini ifade eden antropomorfizm de sohbet robotlarının benimsenmesini etkilemektedir. Örneğin, Klein ve Martinez (2023), sohbet robotlarının antropomorfik tasarımlarının, müşteri memnuniyetini arttırdığını ortaya koymuştur. Benzer şekilde Luo vd. (2019) de insanlaştırılmış müşteri temsilcileri ile yapılan iletişimde müşteri memnuniyetinin daha yüksek olduğunu belirtmiştir. Özellikle çevrimiçi alışveriş deneyimlerinde, sohbet robotlarının insani özellikleri müşterilerde sosyal bulunuşluk hissini yaratmakta, bu durum da sohbet robotlarının etkinliğini arttırmaktadır. Daha etkin bir sohbet robotu müşterilerde güveni ve memnuniyeti olumlu yönde etkilemektedir (Konya-Baumbach vd., 2023).

Bu anlatımlardan yola çıkarak araştırma amacı doğrultusunda olarak araştırma modeli ve hipotezleri aşağıda sunulmuştur.

Şekil 1. Araştırma Modeli



Kaynak: Yazarlar tarafından oluşturulmuştur.

H₁: Bir sohbet robotuyla kurulan etkileşim, müşterilerin hizmetten memnuniyetini arttırmaktadır.

H₂: Müşterilerin bir sohbet robotuna duydukları güven, müşteri memnuniyetini arttırmaktadır.

H₃: Bir sohbet robotunun antropomorfik yapısı, müşteri memnuniyetini arttırmaktadır.

H_{4a}: Sohbet robotu kullanım seviyesi fazla olanlarda, güvenin, müşteri memnuniyetine olan etkisi sohbet robotlarını daha az kullananlara göre daha fazladır.

H_{4b}: Sohbet robotu kullanım seviyesi fazla olanlarda, antropomorfizmin, müşteri memnuniyetine olan etkisi sohbet robotlarını daha az kullananlara göre daha fazladır.

H_{4c}: Sohbet robotu kullanım seviyesi fazla olanlarda, etkileşimin, müşteri memnuniyetine olan etkisi sohbet robotlarını daha az kullananlara göre daha fazladır.

H_{4d}: Sohbet robotunu kullanım seviyesi arttıkça müşteri memnuniyeti artmaktadır.

H_{5a}: Yaşı daha büyük olanlarda, güvenin, müşteri memnuniyetine olan etkisi yaşı daha küçük olanlara göre daha fazladır.

H_{5b}: Yaşı daha büyük olanlarda, antropomorfizmin, müşteri memnuniyetine olan etkisi yaşı daha küçük olanlara göre daha fazladır.

H_{5c}: Yaşı daha büyük olanlarda, etkileşimin, müşteri memnuniyetine olan etkisi yaşı daha küçük olanlara göre daha fazladır.

H_{6a}: Eğitim seviyesi daha yüksek olanlarda, güvenin, müşteri memnuniyetine olan etkisi eğitim seviyesi daha düşük olanlara göre daha fazladır.

H_{6b}: Eğitim seviyesi daha yüksek olanlarda, antropomorfizmin, müşteri memnuniyetine olan etkisi eğitim seviyesi daha düşük olanlara göre daha fazladır.

H_{6c}: Eğitim seviyesi daha yüksek olanlarda, etkileşimin, müşteri memnuniyetine olan etkisi eğitim seviyesi daha düşük olanlara göre daha fazladır.

4. Alan Araştırması

Bu bölümde çevrimiçi perakendecilikte kullanılan sohbet robotlarının farklı özelliklerinin müşteri memnuniyetine olan etkisine yönelik araştırma bulgularına yer verilmiştir.

4.1. Araştırmanın Amacı ve Kapsamı

Günümüzde sohbet robotları, çevrimiçi perakende ortamlarında giderek yaygınlaşmakta ve markaların müşterilerle etkileşim kurma ve hizmet sunma biçimlerini değiştirmektedir. Bununla birlikte özellikle gençler tarafından yoğunlukla kullanılan çevrimiçi hizmetler ve bu süreçlerde müşteri deneyimini arttırmaya yönelik olarak kullanılan sohbet robotlarının kullanımı gelecekte daha da artacaktır. Deloitte (2022)'un araştırmasına göre, ülkemizde 2021 yılında e-ticaret düzeyi 161 milyar lira olarak gerçekleştirilmiş olup, bu rakam bir önceki yıla göre yüzde 49 artmıştır. Artışın en fazla olduğu alan da perakende sektördür. Çevrimiçi perakendeciliğe ilginin her geçen gün artıyor olması nedeniyle söz konusu alanda tüketicilerin pazarlama süreçlerinde kullanılan robotların memnuniyet düzeylerini ne şekilde etkilediğini ölçümlemek büyük önem arz etmektedir. Bu araştırma, tüketicilerin çevrimiçi perakende mağazalarda sohbet robotları kullanımında etkileşim, güven, kullanım seviyesi ve antropomorfizm algılarının müşteri memnuniyetine olan etkisini ölçmek amacıyla gerçekleştirilmiştir. Araştırmanın kapsamını, çevrimiçi perakendecilik uygulamalarının en az bir tanesinde aktif olarak sohbet robotlarını kullanan veya kullanma niyetinde olan katılımcılar oluşturmaktadır.

4.2. Araştırmanın Metodolojisi

Alan araştırması, betimsel bir araştırma olarak tasarlanmış ve birinci elden toplanan verilere dayandırılmıştır. Betimsel araştırma, belirli bir konuda ya da alanda yapılan çalışmaların bağımsız bir şekilde detaylı bir incelemesini ve düzenlenmesini ifade etmektedir (Ültay vd., 2021). Bu yöntem sayesinde konu veya alanla ilgili genel eğilimler belirlenmektedir. Bu çalışmanın betimsel bir araştırma olmasının nedeni, sohbet robotları kullanımının müşteri memnuniyetini nasıl etkilediğini ortaya koymaktır. Veri toplama yöntemi olarak anket tekniği kullanılmıştır.

Araştırmanın ana kütlesini Türkiye’de yerleşik, 18 yaş üstü ve sohbet robotlarını daha önce kullanmış ya da kullanma niyeti olan tüketicilerden oluşturmaktadır. Nicel araştırma kapsamında yer alan evrenin büyüklüğüne göre %95’lik anlamlılık düzeyinde örneklem büyüklüğü saptanmıştır. Bu bağlamda 396 kişiye ulaşılmıştır. Kolayda örneklem yöntemi kullanılan bu çalışmada çevrimiçi anketler Kasım 2023 –Aralık 2023 tarihleri arasında internet ve sosyal medya platformlarında paylaşılarak gerekli sayıda örnekleme ulaşılmıştır. Kolayda örnekleme yöntemi, araştırmacının kolayca ulaşabileceği katılımcılardan veri toplamasını sağlayan, hızlı ve düşük maliyetli bir yöntemdir (Acharya ve diğerleri, 2013). Özellikle de tanımlanan hedef kitledeki bireylerin tamamına

ulaşmanın pratik olmadığı durumlarda hızlı ve etkin bir çözüm sunan (Golzar ve diğerleri, 2022) bir yöntem olması nedeniyle bu çalışmada tercih edilmiştir. Bireylerin ankete katılımı gönüllük esasına göre gerçekleştirilmiştir. Ankette sohbet robotu kullanımı ve müşteri memnuniyetini ölçmeye yönelik ifadeler yer verilmiş olup, 5'li Likert Tipi ölçekten ("1: Kesinlikle Katılmıyorum"; "5: Kesinlikle Katılıyorum") yararlanılmıştır. Araştırmanın kavramsal modelini oluşturmak ve soru formunu hazırlamak için sohbet robotları, müşteri memnuniyeti ve yapay zekâ ile ilgili mevcut literatür geniş çaplı olarak incelenmiştir. Bu incelemeler sonucunda sohbet robotu kullanımından doğan müşteri memnuniyeti üzerinde etkili olan etkileşim değişkeni için Ashfaq vd. (2020) ile Chung vd. (2020) oluşturdukları ölçeklerden; güven ve antropomorfizm değişkeni için Klein ve Martinez'in (2022) ölçeğinden yararlanılmıştır. Müşteri memnuniyeti bağımlı değişkenini ölçmek için ise Ashfaq vd. (2020), Chung vd. (2020), Klein ve Martinez (2022) ile Hsu ve Lin (2023)'in ölçeğinden faydalanılmıştır. Anket üç bölümden oluşmaktadır. İlk bölümde, sohbet robotu kullanımıyla ilgili etkileşim, güven ve antropomorfizm özelliklerine yönelik algıları ölçen ifadeler yer verilmiştir. İkinci bölümde müşteri memnuniyetinin değerlendirildiği ifadeler bulunmakta olup, son bölümde de demografik değişkenlere yönelik sorular yer almaktadır. Elde edilen veriler, SPSS 25.0 paket programı kullanılarak analiz edilmiş ve yorumlanmıştır.

4.3. Araştırmanın Bulguları

Katılımcıların demografik profiliyle ilgili yapılan analize ilişkin Tablo 1'de görüldüğü gibi ankete toplam 396 kişi katılmıştır. Katılımcıların yüzde 48,5'ini erkekler yüzde 51,5'ini de kadınlar oluşturmaktadır. Ankete katılanların yüzde 35,9'u 18-29 yaş aralığında bulunan toplam 142 kişidir. Katılımcıların yüzde 34,1'i ayda 2-5 kez arası sohbet robotu kullanmakta olup, yüzde 52,3'ü lisans mezunudur. Bunu yüzde 21,2'lik bir oranla lise mezunları takip etmektedir. Gelir seviyesi en fazla 24501-31000 TL gelir grubunda toplanmakta olup, bu grup katılımcıların yüzde 21,7'lik kısmını oluşturmaktadır. Katılımcıların meslek grubuna göre dağılımına bakıldığında ise katılımcıların çoğunun (yüzde 17,2) uzmanlık gerektiren meslekler grubunda olduğu görülmektedir.

Tablo 1. Anket Katılımcılarının Demografik Profili

Cinsiyet	Yaş		Yaş		
	N	Geçerli Yüzde	N	Geçerli Yüzde	
Kadın	204	51,5	18-29	142	35,9
Erkek	192	48,5	30-39	123	31,1
Toplam	396	100,0	40-72	131	33,1
			Toplam	396	100,0
Sohbet Robotu Kullanım Seviyesi	Eğitim Düzeyi		Eğitim Düzeyi		
	N	Geçerli Yüzde	N	Geçerli Yüzde	
Ayda 1 veya Daha Az	103	26,0	İlkokul Mezunu	2	0,5
Ayda 2 – 5 Arası	135	34,1	Ortaokul Mezunu	13	3,3
Ayda 6 – 10 Arası	97	24,5	Lise Mezunu	84	21,2
Ayda 11 – 15 Arası	54	13,6	Lisans Mezunu	207	52,3
Ayda 16 ve Üstü	7	1,8	Yüksek Lisans Mezunu	74	18,7
Toplam	396	100,0	Doktora Mezunu	16	4,0
			Toplam	396	100,0
Kişisel Gelir Durumu	Meslek		Meslek		
	N	Geçerli Yüzde	N	Geçerli Yüzde	
0 - 11.500 TL	39	9,8	Özel Sektörde Memur	37	9,3
11.501- 18000 TL	60	15,2	Kamu Sektöründe Memur	51	12,9
18001-24500 TL	54	13,6	Uzmanlık Gerektiren Meslekler	68	17,2
24501-31000 TL	86	21,7	Küçük/Orta Ölçekli Ticaret Serbest Meslek	18	4,5
31001-37500 TL	65	16,4	Büyük Ölçekli Ticaret	12	3,0
37501-44000 TL	59	14,9	Üst Düzey Yönetici	32	8,1
44001 TL ve Üstü	33	8,3	Emekli	24	6,1
Toplam	396	100,0	Öğrenci	56	14,1
			Özel Sektörde İşçi	43	10,9
			Kamu Sektöründe İşçi Benzeri Gelirle Geçinen Kişi	13	3,3
			Ev Kadını	10	2,5
			İşsiz Fakat Gelir Sahibi	12	3,0
			İşsiz	14	3,5
			Sporcu, Sanatçı	4	1,0
			Tarımla Uğraşanlar ve Çiftçilik Yapanlar	2	,5
			Toplam	396	100,0

Kaynak: Yazarlar tarafından oluşturulmuştur.

Araştırma kapsamında toplanan verilerin normal dağılım gösterip göstermediğinin ölçülmesi için normallik testi yapılmıştır. Normallik testi sonuçlarına göre ankette yer alan ifadelerin her biri için yapılmış basıklık ve çarpıklık testlerinde ifadelerin -/+2 oranları arasında olduğu görülmüştür. Ankette yer alan değişkenlerden etkileşim, güven antropomorfizm ve müşteri memnuniyetine yönelik ifadeler temel bileşenler analizi tekniği ile açıklayıcı faktör analizi ile gruplandırılmıştır. Ortak varyansı düşük olan ve güvenilirliği düşüren ifadeler çıkartılmıştır. Tablo 2 ifadelerine yönelik yapılan faktör analizi ve tek örnekli t testi sonuçları ile güvenilirlik katsayısı olan Cronbach Alfa değerlerini göstermektedir.

Tablo 2. Ölçeklere İlişkin Faktör Analiz Sonuçları

İfadeler	Faktör Yükleri	Ort.	t	sd	Anl.	
<i>Sohbet Robotu Etkileşimi</i>						
<i>KMO= 0,877 Bartlett=3181,033, p<0,05, Açıklama Yüzdesi= %74,9, Cronbach α=0,885</i>						
Sohbet robotu müşterilere karşı sürekli olarak nazik davranır	0,864	3,56	8,454	1,314	0,000	
Sohbet robotu müşterilerin isteklerine cevap veremeyecek kadar meşgul değildir	0,843	3,37	5,546	1,314	0,000	
Sohbet robotu müşterilerin sorularını cevaplayacak bilgiye sahiptir	0,774	3,26	3,813	1,344	0,000	
Sohbet robotu müşterilere bireysel ilgi gösterir	0,716	3,16	2,317	1,345	0,021	
Bir müşterinin bir sorunu olduğunda, sohbet robotu bu sorunu çözmek için samimi bir ilgi gösterir	0,832	3,39	6,482	1,202	0,000	
Sohbet robotu iade ve değişim işlemlerini kolayca gerçekleştirir	0,789	3,53	8,983	1,164	0,000	
Sohbet robotu müşteri şikayetlerini doğrudan ve anında ele alabilir	0,767	3,41	6,714	1,220	0,000	
Sohbet robotunun işi yapabilecek yeteneğe sahip olduğuna güveniyorum	0,695	3,39	6,528	1,193	0,000	
<i>Güven</i>						
<i>KMO= 0,871 Bartlett=2073,487, p<0,05, Açıklama Yüzdesi= % 63,1, Cronbach α=0,901</i>						
Bu sohbet robotu sözünü tutuyor	0,813	3,31	5,051	1,234	0,000	
Bu sohbet robotu tüketicinin refahına katkıda bulunabilir	0,812	3,31	5,018	1,212	0,000	
Bu sohbet robotu tüketicinin ihtiyaçlarını önemsiyor	0,745	3,30	4,995	1,207	0,000	
Bu sohbet robotunun güvenilir olabileceğinden hiç şüphem yok	0,656	3,19	3,055	1,250	0,002	
Bu sohbet robotuyla etkileşimde kendimi güvende hissediyorum	0,551	3,31	5,197	1,189	0,000	
Bu sohbet robotuna güvenebileceğimi hissediyorum	0,832	3,25	3,848	1,293	0,000	
Kişisel bilgilerimin üçüncü şahıslara sızdırılmayacağından eminim	0,794	3,12	1,823	1,351	0,069	
Bu sohbet robotunun kişisel bilgilerimi kötüye kullanmayacağına inanıyorum	0,770	3,30	4,571	1,297	0,000	
Kişisel bilgilerin bilinmeyen kişiler ve şirketler tarafından izinsiz olarak elde edilmeyeceğinden eminim	0,545	3,04	0,544	1,292	0,585	
Gizliliğimin bu sohbet robotu tarafından korunduğumu hissediyorum	0,535	3,26	4,234	1,222	0,000	
<i>Antropomorfizm</i>						
<i>KMO= 0,891 Bartlett=2016,026, p<0,05, Açıklama Yüzdesi= % 62,8, Cronbach α=0,915</i>						
Bu sohbet robotunu kullanmak bana sosyallik hissi veriyor	0,835	2,91	-1,343	1,272	0,180	
Bu sohbet robotunu kullanmak bana insan teması hissi veriyor	0,830	2,86	-1,976	1,373	0,049	
Bu sohbet robotunu kullanmak bana insan duyarlılığı hissi veriyor	0,812	2,83	-2,567	1,312	0,011	
Bu sohbet robotunu kullanmak bana birisiyle birlikte olma hissini veriyor	0,807	2,72	4,043	1,355	0,000	
Bu sohbet robotunu kullanmak bana insani bir sıcaklık hissi veriyor	0,802	2,86	-2,097	1,366	0,037	
Bu sohbet robotu insan gibi davranıyor	0,787	3,03	0,432	1,280	0,666	
Bu sohbet robotu insan özelliklerini gösteriyor	0,741	2,96	-0,590	1,277	0,555	
Bu sohbet robotunu kullanmak bana kişisel iletişim hissi veriyor	0,724	2,99	-0,195	1,292	0,846	
<i>Memnuniyet</i>						
<i>KMO= 0,931 Bartlett=4121,264, p<0,05, Açıklama Yüzdesi= % 69,6, Cronbach α₁=0,895, α₂=0,875, α₃=0,891</i>						
<i>Etkileşime Bağlı Memnuniyet</i>	Bilgi sormayı kolaylaştıran bu sohbet robotundan memnunuz.	0,808	3,41	6,368	1,270	0,000
	Sohbet robotu beklediğimi yaptı.	0,761	3,40	6,331	1,262	0,000
	Bana hoş bir deneyim kazandıran bu sohbet robotuyla etkileşimde bulunmaktan memnunuz.	0,696	3,34	5,539	1,234	0,000
	Sohbet robotuyla konuşma deneyimimden memnun kaldım.	0,696	3,39	6,300	1,228	0,000
	Sorunları diyaloga çözen bu sohbet robotundan memnunuz.	0,671	3,39	6,358	1,233	0,000
Başkalarının bu sohbet robotunu kullanmasını tavsiye ederim.	0,515	3,48	7,797	1,238	0,000	
<i>Hizmete Bağlı Memnuniyet</i>	Bu sohbet robotuyla etkileşimde bulunmaktan mutluyum.	0,789	3,23	3,668	1,274	0,000
	Bu sohbet robotu beklediğim şeyi yaptı.	0,746	3,31	5,001	1,246	0,000
	Bu sohbet robotu iyi iş çıkardı.	0,746	3,31	4,922	1,256	0,000
	Bu sohbet robotunu kullanma deneyimimden genel olarak memnunuz.	0,704	3,35	5,696	1,235	0,000
	Sohbet robotunun hizmetinden memnunuz.	0,605	3,38	6,081	1,231	0,000
<i>Olumlu Duygu</i>	Sohbet robotunu kullanmak beni çok tatmin ediyor.	0,793	3,25	3,802	1,308	0,000
	Sohbet robotunu kullanmak bana keyif duygusu veriyor.	0,775	3,24	1,322	3,648	0,000
	Sohbet robotunu kullanmak beni çok memnun ediyor.	0,756	3,29	4,188	1,368	0,000
	Sohbet robotunu kullanmak beni çok mutlu ediyor.	0,704	3,26	3,868	1,325	0,000

Kaynak: Yazarlar tarafından oluşturulmuştur.

Genel olarak ankete katılan katılımcıların sohbet robotları ile gerçekleştirdikleri iletişim neticesinde aldıkları hizmetten, memnun oldukları tespit edilmiştir. Buna ek olarak, ankete katılım gösteren tüketiciler sohbet robotları ile gerçekleştirdikleri etkileşim ile sohbet robotuna karşı güven algısının ortalamasının üzerinde olduğu ancak, bunun hizmet memnuniyeti ve kalitesi açısından geliştirilmesi gereken alanlar olarak değerlendirilmesi gerekliliği büyük önem arz etmektedir. Diğer taraftan, elde edilen verilere göre, sohbet robotlarına yüklenen insani özellikler olarak adlandırılan antropomorfizm özelliğinin tüketicilerde gerçek bir kişiyle iletişim kurma ya da sosyallik hissi yaratma konusunda yetersiz kaldığı ortaya çıkmaktadır. Bu durum, literatürde de belirtildiği üzere, algı ve empati eksikliğinden, sohbet robotlarının performansı hakkındaki belirsizlikten (Nguyen, 2019), gizlilik endişelerinden (Zamora, 2017) ya da etkileşim zorluğundan (Colace vd., 2017) kaynaklanabilmektedir. Ayrıca, gerçek kişilerin genellikle daha iyi

müşteri deneyimi sunduğuna yönelik olası tüketici algıları (Ashfaq vd., 2020) da antropomorfizm algısının düşük çıkmasına neden olabilmektedir.

Araştırma kapsamında belirlenen değişkenlere ilişkin katılımcılara yöneltilen ifadelerin sayısını indirgeyebilmek amacıyla açıklayıcı faktör analizi yapılmıştır. Faktör analizi, çeşitli değişkenleri daha küçük ve yönetilebilir bir boyuta, yani faktöre, ölçeklendirme yeteneğine sahiptir (Pallant, 2001). Bu test, korelasyon modellerini özetleyerek, benzer öğeleri gruplandırmakta ve 'kümeler' oluşturmaktadır. Faktör analizinin kullanılmasının temel amacı, çok sayıda dağınık değişken ifadesini tek tek analiz etmek yerine, benzer durumda olan ifadeleri bir araya getirmektir. Faktör analizi sonuçları, birçok dağınık ifadenin ayrı ayrı analizinden elde edilecek sonuçlara kıyasla daha tutarlı ve gerçeğe daha yakın sonuçlar sağlamaktadır. Güvenilirlik kavramı ise, katılımcıların ölçekteki maddelere verdikleri cevapların birbirleriyle tutarlı olma durumunu ifade etmekte ve ölçümdeki hatalarla ilgilenmektedir. Cronbach Alfa Güvenilirlik testi, katılımcıların verdiği cevaplar temelinde 0 ile 1 arasında bir güvenilirlik katsayısı hesaplanmaktadır. Tablo 2'de de görüldüğü üzere ölçek ifadelerinin güvenilir olduğu söylenebilmektedir (Cevahir, 2020). Bununla birlikte KMO sonuçları veri setinin faktör analizi için uygun olduğunu, Bartlett testi de ifadelerin faktör analizi yapmaya uygun olduğunu göstermektedir (Shrestha, (2021). Faktör analizi bulgularına göre etkileşim, güven ve antropomorfizm değişkenlerinin her biri birer faktöre ayrılmıştır. Memnuniyet değişkeni ise 3 faktöre ayrılarak etkileşime bağlı memnuniyet, hizmete bağlı memnuniyet ve olumlu duygu durumu olarak isimlendirilmiştir.

Araştırma kapsamında tüketicilerin bağımsız değişkenler olan etkileşim, güven ve antropomorfizm algılarının müşteri memnuniyeti üzerindeki etkisini ölçümlemek amacıyla çoklu regresyon analizi gerçekleştirilmiştir. Çoklu regresyon analizi, regresyon modelinde birden fazla bağımsız değişkenle bir bağımlı değişken arasındaki ilişkilerin araştırılması amacıyla yapılmaktadır (Gürbüz ve Şahin, 2015). Regresyon analizi sonuçları Tablo 3'de gösterilmektedir. Tablodaki verilerden elde edilen sonuçlar incelendiğinde, modele ilişkin R² değeri "0,752" ve R değeri "0,867" olarak tespit edilmiştir. Buna göre, güven, antropomorfizm, etkileşim ve sohbet robotu kullanım seviyesi değişkenleri bağımlı değişken olan müşteri memnuniyetinin yüzde 75,2'sini açıklayabilmektedir. Ayrıca "0,867" korelasyon katsayısının pozitif bir değere sahip olması ile var olan etkinin olumlu yönde olduğu söylenebilmektedir. Model kapsamında oluşturulan her değişkenin, bağımlı değişken olan müşteri memnuniyetini açıkladığı görülmektedir. Ayrıca regresyon modelinin anlamlı olduğu (F=196,440, p=0,000) ve istatistik olarak bağımsız değişkenlerin bağımlı değişkeni açıklayacak kadar bir öneme sahip olduğunu söylemek mümkündür.

Tablo 3. Model Değişkenleri Arasındaki Regresyon Analizi

	R	R ²	F	Model (p)	Standardize Edilmemiş Katsayı (B)	Standardize Edilmiş Katsayı (Beta)	t	p
Güven					0,358	0,354	7,413	0,000
Antropomorfizm					0,258	0,283	7,585	0,000
Etkileşim	0,867	0,752	196,440	0,000	0,310	0,307	7,653	0,000
Kullanım seviyesi					0,081	0,090	3,411	0,001

Kaynak: Yazarlar tarafından oluşturulmuştur.

Elde edilen bulgulara göre, etkileşim (t=7,653, p=0,000, B=0,310), güven (t=7,413, p=0,000, B=0,358), antropomorfizm (t=7,585, p=0,000, B= 0,258) ve sohbet robotu kullanım seviyesi (t=3,411, p=0,001, B=0,090) değişkenlerinin müşteri memnuniyetini arttırdığı görülmektedir. Buna göre, sırasıyla, H₁, H₂ H₃ ve H_{4d} hipotezleri desteklenmektedir. Bu bulgular literatürde yer alan ve etkileşimin (Holzwarth vd.,2006; Chung vd., 2018; Cheng ve Jiang, 2022), güvenin (Zehir vd., 2011; Gao ve Waechter, 2017; Mimoun vd., 2017; Jiménez-Barreto vd., 2021; Eren, 2021), antropomorfizmin (Luo vd., 2019; Klein ve Martinez, 2023; Konya-Baumbach vd., 2023) ve kullanım seviyesinin (William vd.,2019; Malodia vd.,2024) müşteri memnuniyetini arttırdığı bulgusuyla paralellik göstermektedir.

Araştırma kapsamında oluşturulan ve yukarıdaki hipotezlerde da ayrıntılı bir şekilde gösterildiği gibi bağımsız değişkenlerin bağımlı değişken üzerindeki etkisinde moderatör değişkenler analiz edilmiştir. Moderatör değişkenlerin analizi kısmi korelasyon yöntemi ile gerçekleştirilmiştir. Kısmi korelasyon yöntemi, sosyal bilimlerde moderatörlük etkisini test etmek amacıyla sıklıkla kullanılan istatistiksel bir tekniktir (Baron ve Kenny, 1986; Hayes, 2013). Moderatörlük etkisi, bir bağımsız değişken ile bir bağımlı değişken arasındaki ilişkinin, üçüncü bir değişkenin (moderator) etkisi altında nasıl değiştiğini incelemektedir (Aiken ve West, 1991). Kısmi korelasyon, iki değişken arasındaki korelasyonu, bir veya daha fazla üçüncü değişkenin etkisi kontrol edildikten sonra hesaplanmaktadır (Baron ve Kenny, 1986; Hayes, 2013; MacKinnon, 2008). Kısmi korelasyonda moderatörlük etkisinde ilk olarak, bağımsız değişken (X) ile bağımlı değişken (Y) arasındaki temel korelasyon hesaplanmakta, daha sonra da moderatör değişkenin (M) etkisi kontrol edilerek, X ve Y arasındaki kısmi korelasyon hesaplanmaktadır. Kısmi korelasyon değeri istatistiksel olarak test edilerek, M'nin etkisinin anlamlı olup olmadığı belirlenmektedir. Kısmi korelasyon, M'nin etkisi çıkarıldıktan sonra X ve Y arasındaki ilişkiyi önemli ölçüde değiştiriyorsa, moderatörlük etkisi olduğu sonucuna varılmaktadır (MacKinnon, 2008). Bu kapsamda, etkileşim, güven ve antropomorfizm değişkenleri ile müşteri memnuniyeti arasındaki ilişkileri test etmek amacıyla korelasyon analizi yapılmıştır. Müşteri memnuniyeti bağımlı değişkeni ile etkileşim (r= 0,759, p=0,000), güven (r= 0,808, p= 0,000) ve

antropomorfizm ($r= 0,742, p= 0,000$) arasında kuvvetli bir ilişki (Gürbüz ve Şahin, 2015) bulunmaktadır. Bunlara ek olarak, eğitim değişkeni kontrol edilerek, sohbet robotuyla gerçekleştirilen etkileşim ($r= 0,753, p= 0,000$), sohbet robotuna duyulan güven ($r= 0,805, p= 0,000$), sohbet robotunun antropomorfizm özelliği ($r= 0,740, p= 0,000$) ve müşteri memnuniyeti arasında kısmi moderatörlük etkisi yarattığı görülmektedir. Bundan dolayı $H_{6a,6b,6c}$ hipotezleri desteklenmiştir. Yaş değişkeninin moderatörlük etkisi incelendiğinde yaş değişkeni kontrol edilip, etkileşim ($r= 0,756, p= 0,000$), güven ($r= 0,805, p= 0,000$) ve antropomorfizm ($r= 0,736, p= 0,000$) ile müşteri memnuniyeti arasında kısmi korelasyon etkisinin bulunduğu tespit edilmiştir. Bu nedenle $H_{5a,5b,5c}$ hipotezleri de desteklenmiştir. Sohbet robotu kullanım seviyesi de etkileşim ($r= 0,758, p= 0,000$), güven ($r= 0,800, p= 0,000$) ve antropomorfizm ($r= 0,726, p= 0,000$) değişkenleri ile müşteri memnuniyeti arasında kısmi moderatör etkisi yaratmaktadır. Bu bulgulardan hareketle $H_{4a,4b,4c}$ desteklenmiştir. Kısmi moderatörlük, moderatör değişken ile bağımsız değişken arasında anlamlı bir etkileşim ve moderatörün kendisi ile bağımsız değişken, bağımlı değişken veya hem bağımsız hem de bağımlı değişken arasında bir korelasyon olduğu durumunda geçerli olmaktadır (Sharma vd., 1981).

Araştırmaya katılan tüketicilerin etkileşim, güven ve antropomorfizm algısının sohbet robotu kullanım seviyesine (düşük-orta-yüksek) göre farklılık gösterip göstermediği tek yönlü varyans analizi (ANOVA) ile test edilmiştir. Buna göre, farklı düzeylerde sohbet robotu kullananlar arasında etkileşim ($F(2/393)=5,490, p<0.05$), güven ($F(3/393)=10,466, p<0.05$) ve antropomorfizm ($F(3/393)=15,143, p<0.05$) algıları arasında anlamlı bir farklılık bulunmaktadır. Diğer bir ifadeyle, sohbet robotunu daha yüksek düzeyde kullanan kişilerin, sohbet robotunu orta ve düşük kullananlara göre etkileşim, güven ve antropomorfizm algıları daha yüksek olmaktadır. Ayrıca kullanım düzeyine göre tüketicilerin sohbet robotundan memnuniyet düzeyleri de farklılık göstermektedir ($F(2/293)=20,760, p<0.05$). Buna göre yüksek düzeyde sohbet robotu kullananların, orta ve düşük düzeyde kullananlara göre memnuniyet düzeyleri daha fazladır. Bu durum Wiliam vd. (2019) ve Malodia vd. (2024) bulguları ile paralellik göstermektedir.

Araştırma kapsamında oluşturulan hipotezlerin analizler neticesinde değerlendirme sonuçları Tablo 4'te gösterilmektedir. Buna göre tüm araştırma hipotezleri desteklenmiştir.

Tablo 4: Hipotez Sonuç Tablosu

Hipotezler	Sonuç
H1	Desteklenmiştir
H2	Desteklenmiştir
H3	Desteklenmiştir
H4 _a	Desteklenmiştir
H4 _b	Desteklenmiştir
H4 _c	Desteklenmiştir
H4 _d	Desteklenmiştir
H5 _a	Desteklenmiştir
H5 _b	Desteklenmiştir
H5 _c	Desteklenmiştir
H6 _a	Desteklenmiştir
H6 _b	Desteklenmiştir
H6 _c	Desteklenmiştir

Kaynak: Yazarlar tarafından oluşturulmuştur.

Sonuçlar ve Tartışma

Bu çalışma, sohbet robotlarının etkileşim, güven, antropomorfizm özellikleri ile kullanım seviyesinin müşteri memnuniyetini arttırdığını ortaya koymak amacıyla, sohbet robotlarının birden fazla özelliğini dikkate alarak bu teknolojilerin çevrimiçi perakendecilikteki rolünü ön plana çıkarmayı hedeflemiştir. Araştırma kapsamında elde edilen bulgulara göre, tüketicilerin sohbet robotları ile gerçekleştirdikleri etkileşim hissi ile sohbet robotuna karşı duydukları güven seviyesinin ortalamasının üzerinde olduğu tespit edilmiştir. Diğer bir ifadeyle, tüketiciler, sohbet robotlarından bilgi alma, sorun çözme, bireysel ilgi ile şikayetlere anında geri dönüş sağlayabilme gibi konularda sohbet robotlarının etkileşim sağlayabildiğini, verilen sözlerin tutulması ve kişisel veriler konusunda da güven hissi yaratabildiğini ifade etmişlerdir. Ancak etkin bir müşteri deneyimi için etkileşim ve güven hissiyatının çok daha kuvvetli olması gerekmektedir. Ayrıca çalışmada, sohbet robotlarına yüklenen insani özellikler olarak adlandırılan antropomorfizm özelliğinin ise tüketicilerde gerçek bir kişiyle iletişim kurma, sosyallik, sıcaklık ya da insan teması hissi yaratma konusunda sohbet robotlarının yetersiz kaldığı tespit edilmiştir. Sözü edilen mevcut durum, algı ve empati eksikliğinden, sohbet robotlarının performansı hakkındaki belirsizlikten (Nguyen, 2019), gizlilik endişelerinden (Zamora, 2017), etkileşim zorluğundan (Colace vd., 2017) ya da iletişim kurmak için gerçek kişi arayışından (Ashfaq vd., 2020) kaynaklanabilmektedir. Sohbet robotlarının sözü edilen özellikleri istenilen düzeyde bir algı yaratmamış olsa da genel olarak ankete katılan katılımcıların sohbet robotları ile gerçekleştirdikleri iletişim neticesinde aldıkları hizmetten ortalamasının üzerinde memnuniyet yaşadıkları saptanmıştır.

Araştırma kapsamı doğrultusunda tüketicilerin memnuniyet düzeylerini etkileyen en önemli değişkenin sırasıyla güven, etkileşim, antropomorfizm ve kullanım düzeyi olduğu görülmektedir. Sohbet robotlarının sağladığı doğru bilgiler, yarattığı güvenlik hissi,

zamanında, yeterli ve eksiksiz yapılan bilgilendirmeler tüketicilerin memnuniyetini arttırmaktadır (Zehir vd., 201; Eren, 2021; Cheng ve Jiang, 2022; Barry ve Crant, 2000). Bu çalışmada da tüketicilerin çevrimiçi perakendecilikte güven düzeyleri arttıkça memnuniyet düzeyleri de artmaktadır. Benzer şekilde tüketicilerin yaptıkları aramalarda ilgili ve hızlı sıralanmış bilgilerin sunulması, zaman ve mekan kısıtı olmadan sohbet robotlarına erişim sağlayabilme ya da sohbet robotlarının problem çözme yetkinliği gibi özellikleri ifade eden etkileşim hissi arttıkça müşteri memnuniyet düzeyi de artmaktadır. Bu bulgular literatürdeki benzer bulgularla da paralellik göstermektedir (Holzwarth vd., 2006; Chung vd., 2018; Cheng ve Jiang, 2022). Diğer önemli bir özellik olan antropomorfizm özelliğinin pek çok çalışmada müşteri memnuniyetini arttırdığına yönelik bulgular olsa da (Luo vd., 2019; Klein ve Martinez, 2023; Konya-Baumbach vd., 2023), bu teknolojilerin çoğu zaman gerçek müşteri temsilcisi gibi hizmet veremediğine dair tüketici algıları bulunmaktadır (Ashfaq vd., 2020). Bu çalışmada da sohbet robotlarının antropomorfizm algısı düşük düzeyde olmasına rağmen, müşteri memnuniyetini etkilediği görülmektedir. Locke (1967, 1969) tarafından formüle edilen ve müşteri memnuniyeti davranışının altında yatan nedenleri açıklamaya çalışan Değer Algı Farklılık Teorisi kapsamında da belirtildiği gibi bir ürün ya da hizmete yönelik algılar tüketicinin sahip olduğu değer standartları ile karşılaştırılarak elde edilmektedir (Westbrook ve Reilly, 1983). Bu kapsamda bu çalışmada da katılımcıların sohbet robotlarından aldıkları hizmet deneyimlerine göre algıladıkları hizmet ile sahip oldukları doğruluk, dürüstlük, güven, saygı gibi insani değerler çerçevesinde değerlendirme yapıp memnuniyet düzeylerini ona göre belirledikleri görülmektedir. Etkileşim, güven ve insansı özellikler sergileyen sohbet robotları, hizmet özelliklerini müşteri değerleri ile uyumlu hale getirerek müşteri memnuniyetini önemli ölçüde etkileyebilmektedir.

Çalışmada elde edilen diğer önemli bir bulgu da Zeithaml ve Bitner (1996) ile Harvey (1998)'in bulgularının aksine, özellikle sohbet robotu kullanımı konusunda daha deneyimli olan tüketicilerde, sohbet robotlarının etkileşim, güven ve antropomorfizm özelliklerinin verdiği hissiyat daha yüksek düzeyde olmakta, buna paralel olarak müşteri memnuniyetleri de daha yüksek düzeyde seyretmektedir. Benzer şekilde yaşça büyük, eğitim düzeyi yüksek ve sohbet robotunu daha fazla kullanan kişilerde etkileşim, güven ve antropomorfizm özelliklerinin müşteri memnuniyetine olan etkisinin kısmi olarak daha fazla olduğu da araştırmada ortaya çıkan diğer önemli bir bulgudur. Bu bulgulardan hareketle işletmelerin müşterilerde etkileşimi artırıcı ve güveni kuvvetlendirici yeni stratejiler geliştirmeleri büyük bir önem arz etmektedir. Sürekli gelişen yapay zekâ teknolojisi ile birlikte gelecekte antropomorfik özelliklerin tüketiciler tarafından daha çok algılanacağı düşünülmektedir.

Sonuç olarak, bu çalışma, sohbet robotlarının müşteri memnuniyetine olumlu bir katkı sağlayabileceğini ve bu katkının güven, antropomorfizm, etkileşim ve kullanım düzeyi gibi faktörlere bağlı olduğunu ortaya koymaktadır. Hızla geliştirilen sohbet robotlarının gelecekte de özellikle işletmelerin gerek pazarlama süreçlerinde gerekse müşteri deneyimlerini iyileştirme çalışmalarında daha çok kullanacağı beklentisi nedeniyle bu çalışmada elde edilen bulguların, bu konudaki farkındalıklarını arttırmaları anlamında pazarlama profesyonellerine ve iş süreçlerini iyileştirmeleri konusunda da pazarlama yöneticilerine katkı sağlayacağı beklenmektedir. Ayrıca çalışmanın güven, antropomorfizm, etkileşim ve kullanım düzeyi gibi faktörlerin bir bütün olarak ele alınmasının da bu konuda sınırlı çalışmaların olduğu dijital pazarlama literatürüne de önemli bir katkısı olacağı düşünülmektedir.

Teorik ve Pratik Katkıları

Her ne kadar son yıllarda sohbet robotları üzerinde kapsamlı araştırmalar yapılmış olsa da müşterilerin memnuniyetini ve sohbet robotlarına yönelik algıyı etkileyen temel faktörleri değerlendiren sınırlı sayıda çalışma mevcuttur. Bu araştırma, sohbet robotları tarafından sunulan etkileşim, güven ve antropomorfizm özelliklerinin tüketiciler tarafından nasıl algılandığını ve bunun müşteri memnuniyetini arttırmaya yönelik geliştirilecek stratejilere ışık tutacağı düşünülmektedir.

Sohbet robotları yeni bir hizmet modeli sunduğundan, bu hizmetin oluşturduğu memnuniyet seviyesinin ve tüketici algılarının ölçülmesine yönelik daha fazla çalışma yapılması son derece önemlidir. Çalışmanın bulguları, gelecekteki araştırmacılara, endüstri profesyonellerine ve tasarımcılara, daha iyi ve eşsiz bir müşteri deneyimi sağlamalarına yardımcı olma konusunda önemli bilgiler sağlamaktadır. Ayrıca çevrimiçi perakendeciler, sohbet robotu teknolojisinin pazarlama stratejilerine entegre edilmesi gerekliliği konusunda bu çalışmadan önemli iç görüler elde edebilmektedir.

Çalışma bulgularının aynı zamanda akademik literatüre, tüketici davranışı, e-ticaret ve dijital pazarlama alanlarına önemli katkılarda bulunmaktadır. Özellikle literatürden farklı olarak, sohbet robotlarının çoklu özelliklerinin bir arada ele alınması bu çalışmanın en önemli akademik katkısı olarak değerlendirilmelidir. Bu teorik ve pratik katkıların hem akademik hem de profesyonel hayata kullanım, tasarım ve strateji geliştirme açısından değerli bir temel oluşturacağı düşünülmektedir.

Öneriler ve Sınırlar

Gelecek çalışmalarda sohbet robotlarına olan güven ve memnuniyet üzerindeki etkileri anlamak için kültürel ve bağlamsal faktörlerin daha fazla göz önüne alınması önemlidir. Bu bağlamda, farklı kültürlerdeki kullanıcı davranışları ve algıları üzerindeki etkileri anlamak için daha geniş bir kültürel çeşitlilik içeren çalışmalar yararlı olacaktır. Çalışmada incelenen değişkenlerin yanı sıra, gelecek çalışmalarda teknoloji kabulü, duygusal etkileşim ve kullanıcı deneyimi gibi faktörlerin de eklenerek, daha kapsamlı bir

modelin oluşturulması da faydalı olacaktır. Pazarlama profesyonelleri açısından da bu çalışmadan elde edilen bulgular ışığında sipariş, teslimat, ödeme ve müşteri şikayetleri gibi iş süreçlerinde sohbet robotları deneyimini tasarlarlarken antropomorfik özelliklerin daha çok kullanılması, güven ile etkileşimin artırılması ve gerçek kişi hissiyatının daha çok verilmesine yönelik stratejilerin geliştirilmesi rekabet avantajı elde etmek açısından son derece yararlı olacaktır.

Bu çalışmada katılımcıların duygusal tepkileri, davranışları ve etkileşimleri doğrudan gözlemlenemediği için objektif veri eksikliği önemli bir kısıt olarak değerlendirilmektedir. Antropomorfizm düzeyleri, güven ve memnuniyet gibi konular genellikle öznel algılara dayanmaktadır. Bu durum, katılımcıların kendi değerlendirmelerine dayalı olarak bilgilerin toplandığı bir araştırma olduğundan ötürü subjektif değerlendirmelerin olması diğer önemli bir kısıttır. Ayrıca çalışmada ele alınan katılımcı sayısı ve profili, genellemeler yapma konusunda sınırlı olmakta, farklı demografik gruplar, yaş aralıkları ve eğitim seviyelerini içeren daha geniş bir katılımcı kitlesi kullanmak, sonuçların genellenebilirliğini arttıracaktır.



This research article has been licensed with Creative Commons Attribution - Non-Commercial 4.0 International License. Bu araştırma makalesi, Creative Commons Atıf - Gayri Ticari 4.0 Uluslararası Lisansı ile lisanslanmıştır.

Yazar Katkıları

Yazarlar çalışmaya katkı oranlarının eşit olduğunu beyan etmişlerdir.

Teşekkür Beyanı

Yazarlar teşekkür beyanında bulunmamışlardır.

Destek Beyanı

Yazarlar destek beyanında bulunmamışlardır.

Çıkar Çatışması

Yazarlar herhangi bir çıkar çatışması beyan etmemişlerdir.

Etik Beyanı

Yazarlar çalışma için Ege Üniversitesi'nden 29.11.2023 tarih ve 2203 sayılı Etik Kurul Onayı alındığını beyan etmişlerdir.

Sorumlu Özel Sayı Editörleri

Doç. Dr. Beyza Mina Ordu-Akkaya, Ankara Sosyal Bilimler Üniversitesi

Doç. Dr. Görkem Ataman, Yaşar Üniversitesi

Arş. Gör. Yunus Yıldırım, Afyon Kocatepe Üniversitesi

Kaynakça/References

- Acharya, A. S., Prakash, A., Saxena, P., & Nigam, A. (2013). Sampling: Why and how of it. *Indian Journal of Medical Specialties*, 4(2), 330-333.
- Aggarwal, P., & McGill, A. L. (2012). When brands seem human, do humans act like brands? Automatic behavioral priming effects of brand anthropomorphism. *Journal of Consumer Research*, 39(2), 307-323.
- Aiken, L. S., & West, S. G. (1991). *Multiple regression: Testing and interpreting interactions*. Newbury Park, CA: Sage.
- Akintan, I., Dabiri, M., & Ojenike, J. (2020). An appraisal of after sales service on consumer satisfaction: A study of LG Electronics in Lagos, Nigeria. *International Journal of Information, Business and Management*, 12(1), 92-112.
- Antons, D., & Breidbach, C. F. (2018). Big data, big insights? Advancing service innovation and design with machine learning. *Journal of Service Research*, 21(1), 17-39.
- Appel, G., Grewal, L., Hadi, R., & Stephen, A. T. (2020). The future of social media in marketing. *Journal of the Academy of Marketing Science*, 48(1), 79-95.
- Araujo, T. (2018). Living up to the chatbot hype: The influence of anthropomorphic design cues and communicative agency framing on conversational agent and company perceptions. *Computers in Human Behavior*, 85, 183-189.
- Ashfaq, M., Yun, J., Yu, S., & Loureiro, S. M. C. (2020). I, chatbot: Modeling the determinants of users' satisfaction and continuance intention of AI-powered service agents. *Telematics and Informatics*, 54, 101473.
- Bag, S., Gupta, S., Kumar, A., & Sivarajah, U. (2021). An integrated artificial intelligence framework for knowledge creation and B2B marketing rational decision making for improving firm performance. *Industrial Marketing Management*, 92, 178-189.
- Balakrishnan, J., & Dwivedi, Y. K. (2021). Conversational commerce: Entering the next stage of AI-powered digital assistants. *Annals of Operations Research*, 1-35.
- Barış, A. (2020). A new business marketing tool: Chatbot. *GSI Journals Serie B: Advancements in Business and Economics*, 3(1), 31-46.
- Baron, R. M., & Kenny, D. A. (1986). The moderator–mediator variable distinction in social psychological research: Conceptual, strategic, and statistical considerations. *Journal of Personality and Social Psychology*, 51(6), 1173-1182.
- Barry, B., & Crant, J. M. (2000). Dyadic communication relationships in organizations: An attribution/expectancy approach. *Organization Science*, 11(6), 648-664.
- Berger, J., Humphreys, A., Ludwig, S., Moe, W. W., Netzer, O., & Schweidel, D. A. (2020). Uniting the tribes: Using text for marketing insight. *Journal of Marketing*, 84(1), 1-25.
- Brennan, K. (2006). The managed teacher: Emotional labour, education, and technology. *Educational Insights*, 10(2), 55-65.
- Brill, T. M., Munoz, L., & Miller, R. J. (2022). Siri, Alexa, and other digital assistants: A study of customer satisfaction with artificial intelligence applications. In *The Role of Smart Technologies in Decision Making* (pp. 35-70). Routledge.
- Brynjolfsson, E., & McAfee, A. (2014). *The second machine age: Work, progress, and prosperity in a time of brilliant technologies*. WW Norton & Company.
- Cevahir, E. (2020). *SPSS ile nicel veri analizi rehberi*. Kibele Yayınları.
- Chatterjee, S., Ghosh, S. K., Chaudhuri, R., & Nguyen, B. (2019). Are CRM systems ready for AI integration? A conceptual framework of organizational readiness for effective AI-CRM integration. *The Bottom Line*, 32(2), 144-157.
- Chen, H., Chan-Olmsted, S., Kim, J., & Sanabria, I. M. (2022). Consumers' perception on artificial intelligence applications in marketing communication. *Qualitative Market Research: An International Journal*, 25(1), 125-142.
- Cheng, Y., & Jiang, H. (2022). Customer–brand relationship in the era of artificial intelligence: Understanding the role of chatbot marketing efforts. *Journal of Product & Brand Management*, 31(2), 252-264.
- Chintagunta, P., Hanssens, D. M., & Hauser, J. R. (2016). Marketing science and big data. *Marketing Science*, 35(3), 341-342.
- Chung, M., Ko, E., Joung, H., & Kim, S. J. (2020). Chatbot e-service and customer satisfaction regarding luxury brands. *Journal of Business Research*, 117, 587-595.
- Chung, N., & Kwon, S. J. (2009). Effect of trust level on mobile banking satisfaction: A multi-group analysis of information system success instruments. *Behaviour & Information Technology*, 28(6), 549-562.
- Chung, T. S., Wedel, M., & Rust, R. T. (2016). Adaptive personalization using social networks. *Journal of the Academy of Marketing Science*, 44, 66-87.
- Ciechanowski, L., Przegalinska, A., Magnuski, M., & Gloor, P. (2019). In the shades of the uncanny valley: An experimental study of human–chatbot interaction. *Future Generation Computer Systems*, 92, 539-548.

- Colace, F., De Santo, M., Pascale, F., Lemma, S., & Lombardi, M. (2017). BotWheels: a Petri Net based chatbot for recommending tires. *DATA*, 17, 350-358.
- Colgate, J. E., Wannasuphoprasit, W., & Peshkin, M. A. (1996). Cobots: Robots for collaboration with human operators. In *ASME International Mechanical Engineering Congress and Exposition* (Vol. 15281, pp. 433-439). American Society of Mechanical Engineers.
- Crolic, C., Thomaz, F., Hadi, R., & Stephen, A. T. (2022). Blame the bot: Anthropomorphism and anger in customer–chatbot interactions. *Journal of Marketing*, 86(1), 132-148.
- Cyr, D., Hassanein, K., Head, M., & Ivanov, A. (2007). The role of social presence in establishing loyalty in e-service environments. *Interacting with Computers*, 19(1), 43-56.
- Davenport, T., Guha, A., Grewal, D., & Bressgott, T. (2020). How artificial intelligence will change the future of marketing. *Journal of the Academy of Marketing Science*, 48, 24-42.
- de Cosmo, L. M., Piper, L., & Di Vittorio, A. (2021). The role of attitude toward chatbots and privacy concern on the relationship between attitude toward mobile advertising and behavioral intent to use chatbots. *Italian Journal of Marketing*, 2021(1), 83-102.
- Dekimpe, M. G. (2020). Retailing and retailing research in the age of big data analytics. *International Journal of Research in Marketing*, 37(1), 3-14.
- Deloitte. (2022). E-ticaretin öne çıkan başarısı, tüketici davranışlarında değişim ve dijitalleşme. TÜSİAD. <https://tusiad.org/tr/yayinlar/raporlar/item/10915-e-ticaretin-one-cikan-basarisi-tuketici-davranislarinda-degisim-ve-dijitallesme-deloitte-digital>
- de Oliveira Santini, F., Ladeira, W. J., Sampaio, C. H., & Perin, M. G. (2018). Online banking services: A meta-analytic review and assessment of the impact of antecedents and consequents on satisfaction. *Journal of Financial Services Marketing*, 23, 168-178.
- Deshpande, I. (2019). What is artificial intelligence and machine learning in marketing?. <https://www.spiceworks.com/marketing/ai-in-marketing/articles/what-is-artificial-intelligence-machine-learning-in-marketing/>
- Dzyabura, D., & Hauser, J. R. (2019). Recommending products when consumers learn their preference weights. *Marketing Science*, 38(3), 417-441.
- Edwards, C., Edwards, A., Spence, P. R., & Shelton, A. K. (2014). Is that a bot running the social media feed? Testing the differences in perceptions of communication quality for a human agent and a bot agent on Twitter. *Computers in Human Behavior*, 33, 372-376.
- Eren, B. A. (2021). Determinants of customer satisfaction in chatbot use: Evidence from a banking application in Turkey. *International Journal of Bank Marketing*, 39(2), 294-311.
- Feine, J., Gnewuch, U., Morana, S., & Maedche, A. (2019). A taxonomy of social cues for conversational agents. *International Journal of Human-Computer Studies*, 132, 138-161.
- Følstad, A., Nordheim, C. B., & Bjørkli, C. A. (2018). What makes users trust a chatbot for customer service? An exploratory interview study. In *Internet Science: 5th International Conference, INSCI 2018, St. Petersburg, Russia, October 24–26, 2018, Proceedings 5* (pp. 194-208). Springer International Publishing.
- Forbes. (2019). AI stats news: Chatbots increase sales by 67% but 87% of consumers prefer humans. <https://www.forbes.com/sites/gilpress/2019/11/25/ai-stats-news-chatbots-increase-sales-by-67-but-87-of-consumers-prefer-humans/?sh=30c6f2fe48a3>
- Gabel, S., Guhl, D., & Klapper, D. (2019). P2V-MAP: Mapping market structures for large retail assortments. *Journal of Marketing Research*, 56(4), 557-580.
- Gao, L., & Waechter, K. A. (2017). Examining the role of initial trust in user adoption of mobile payment services: An empirical investigation. *Information Systems Frontiers*, 19, 525-548.
- Gao, L., Waechter, K. A., & Bai, X. (2015). Understanding consumers' continuance intention towards mobile purchase: A theoretical framework and empirical study—A case of China. *Computers in Human Behavior*, 53, 249-262.
- Giese, J. L., & Cote, J. A. (2000). Defining consumer satisfaction. *Academy of Marketing Science Review*, 1(1), 1-22.
- Glavas, C., & Letheren, K. (2017). Embracing the bots: How direct to consumer advertising is about to change forever. *The Conversation*.
- Gnewuch, U., Morana, S., & Maedche, A. (2017). Towards designing cooperative and social conversational agents for customer service. *ICIS*, 1-13.

- Go, E., & Sundar, S. S. (2019). Humanizing chatbots: The effects of visual, identity and conversational cues on humanness perceptions. *Computers in Human Behavior, 97*, 304-316.
- Golzar, J., Noor, S., & Tajik, O. (2022). Convenience sampling. *International Journal of Education & Language Studies, 1*(2), 72-77.
- Gürbüz, S., & Şahin, F. (2014). *Sosyal bilimlerde araştırma yöntemleri*. Ankara: Seçkin Yayıncılık.
- Gürsoy, D., Chi, O. H., Lu, L., & Nunkoo, R. (2019). Consumers acceptance of artificially intelligent (AI) device use in service delivery. *International Journal of Information Management, 49*, 157-169.
- Haugeland, I. K. F., Fornell, C., Følstad, A., Taylor, C., & Bjørkli, C. A. (2022). Understanding the user experience of customer service chatbots: An experimental study of chatbot interaction design. *International Journal of Human-Computer Studies, 161*.
- Hayes, A. F. (2013). *Introduction to mediation, moderation, and conditional process analysis: A regression-based approach*. New York: Guilford Press.
- Hill, J., Ford, W. R., & Farreras, I. G. (2015). Real conversations with artificial intelligence: A comparison between human-human online conversations and human-chatbot conversations. *Computers in Human Behavior, 49*, 245-250.
- Holzwarth, M., Janiszewski, C., & Neumann, M. M. (2006). The influence of avatars on online consumer shopping behavior. *Journal of Marketing, 70*(4), 19-36.
- Hong, N. O., Govindarajan, U. H., Chien, Y. J. C., & Trappey, J. A. (2019). Comprehensive technology function product matrix for intelligent chatbot patent mining. In *2019 IEEE International Conference on Systems, Man and Cybernetics (SMC)* (pp. 1344-1348).
- Hsiao, K. L., & Chen, C. C. (2022). What drives continuance intention to use a food-ordering chatbot? An examination of trust and satisfaction. *Library Hi Tech, 40*(4), 929-946.
- Huang, J., Zhou, M., & Yang, D. (2007). Extracting chatbot knowledge from online discussion forums. *IJCAI, 7*, 423-428.
- Huang, M. H., & Rust, R. T. (2020). Engaged to a robot? The role of AI in service. *Journal of Service Research, 109467052090226*.
- Huang, M. H., & Rust, R. T. (2021). A strategic framework for artificial intelligence in marketing. *Journal of the Academy of Marketing Science, 49*, 30-50.
- Humphreys, A., & Wang, R. J. H. (2018). Automated text analysis for consumer research. *Journal of Consumer Research, 44*(6), 1274-1306.
- Illescas-Manzano, M. D., López, N. V., González, N. A., & Cristofol Rodríguez, C. (2021). Implementation of chatbot in online commerce, and open innovation. *Journal of Open Innovation: Technology, Market, and Complexity, 7*(2), 125.
- Jarek, K., & Mazurek, G. (2019). Marketing and artificial intelligence. *Central European Business Review, 8*(2).
- Jarrahi, M. H. (2018). Artificial intelligence and the future of work: Human-AI symbiosis in organizational decision making. *Business Horizons, 61*(4), 577-586.
- Jiménez-Barreto, J., Rubio, N., & Molinillo, S. (2021). "Find a flight for me, Oscar!" Motivational customer experiences with chatbots. *International Journal of Contemporary Hospitality Management, 33*(11), 3860-3882.
- Kallel, A., Ben Dahmane Mouelhi, N., Chaouali, W., & Danks, N. P. (2023). Hey chatbot, why do you treat me like other people? The role of uniqueness neglect in human-chatbot interactions. *Journal of Strategic Marketing, 1*-17.
- Klaus, P., & Zaichkowsky, J. (2020). AI voice bots: A services marketing research agenda. *Journal of Services Marketing, 34*(3), 389-398.
- Klein, K., & Martinez, L. F. (2023). The impact of anthropomorphism on customer satisfaction in chatbot commerce: An experimental study in the food sector. *Electronic Commerce Research, 23*, 2789-2825. <https://doi.org/10.1007/s10660-022-09562-8>
- Konya-Baumbach, E., Biller, M., & von Janda, S. (2023). Someone out there? A study on the social presence of anthropomorphized chatbots. *Computers in Human Behavior, 139*.
- Kumar, V., Rajan, B., Venkatesan, R., & Lecinski, J. (2019). Understanding the role of artificial intelligence in personalized engagement marketing. *California Management Review, 61*(4), 135-155.
- Lalicic, L., & Weismayer, C. (2021). Consumers' reasons and perceived value co-creation of using artificial intelligence-enabled travel service agents. *Journal of Business Research, 129*, 891-901.
- Lee, D., Hosanagar, K., & Nair, H. S. (2018). Advertising content and consumer engagement on social media: Evidence from Facebook. *Management Science, 64*(11), 5105-5131.
- Lee, S. A., & Oh, H. (2021). Anthropomorphism and its implications for advertising hotel brands. *Journal of Business Research, 129*, 455-464.

- Lei, S. I., Shen, H., & Ye, S. (2021). A comparison between chatbot and human service: Customer perception and reuse intention. *International Journal of Contemporary Hospitality Management*, 33(11), 3977-3995.
- Letheren, K., Russell-Bennett, R., & Whittaker, L. (2020). Black, white or grey magic? Our future with artificial intelligence. *Journal of Marketing Management*, 36(3-4), 216-232.
- Lin, X., Shao, B., & Wang, X. (2022). Employees' perceptions of chatbots in B2B marketing: Affordances vs. disaffordances. *Industrial Marketing Management*, 101, 45-56.
- Liu, X., Singh, P. V., & Srinivasan, K. (2016). A structured analysis of unstructured big data by leveraging cloud computing. *Marketing Science*, 35(3), 363-388.
- Locke, E. A. (1967). Relationship of success and expectation to affect on goal-seeking tasks. *Journal of Personality and Social Psychology*, 7, 125-130.
- Locke, E. A. (1969). What is job satisfaction? *Organizational Behavior and Human Performance*, 4(4), 309-336.
- Lu, L., Cai, R., & Gursoy, D. (2019). Developing and validating a service robot integration willingness scale. *International Journal of Hospitality Management*, 80, 36-51.
- Luo, X., Tong, S., Fang, Z., & Qu, Z. (2019). Frontiers: Machines vs. humans: The impact of artificial intelligence chatbot disclosure on customer purchases. *Marketing Science*, 38(6), 937-947.
- MacKinnon, D. P. (2008). *Introduction to statistical mediation analysis*. New York: Lawrence Erlbaum Associates.
- Malodia, S., Islam, N., Kaur, P., & Dhir, A. (2024). Why do people use artificial intelligence (AI)-enabled voice assistants? *IEEE Transactions on Engineering Management*, 71, 491-505. <https://doi.org/10.1109/TEM.2021.3117884>
- Marinova, D., Singh, S. K., & Singh, J. (2018). Frontline problem-solving effectiveness: A dynamic analysis of verbal and nonverbal cues. *Journal of Marketing Research*, 55(2), 178-192.
- Mende, M., Scott, M. L., van Doorn, J., Grewal, D., & Shanks, I. (2019). Service robots rising: How humanoid robots influence service experiences and elicit compensatory consumer responses. *Journal of Marketing Research*, 56(4), 535-556.
- Michaud, L. N. (2018). Observations of a new chatbot: Drawing conclusions from early interactions with users. *IT Professional*, 20(5), 40-47.
- Mimoun, M. S. B., Poncin, I., & Garnier, M. (2017). Animated conversational agents and e-consumer productivity: The roles of agents and individual characteristics. *Information & Management*, 54(5), 545-559.
- Moffett, J. W., Folse, J. A. G., & Palmatier, R. W. (2021). A theory of multiformat communication: Mechanisms, dynamics, and strategies. *Journal of the Academy of Marketing Science*, 49, 441-461.
- Mozafari, N., Weiger, W. H., & Hammerschmidt, M. (2022). Trust me, I'm a bot—repercussions of chatbot disclosure in different service frontline settings. *Journal of Service Management*, 33(2), 221-245.
- Murtarelli, G., Gregory, A., & Romenti, S. (2021). A conversation-based perspective for shaping ethical human-machine interactions: The particular challenge of chatbots. *Journal of Business Research*, 129, 927-935.
- Netzer, O., Lemaire, A., & Herzenstein, M. (2019). When words sweat: Identifying signals for loan default in the text of loan applications. *Journal of Marketing Research*, 56(6), 960-980.
- Nguyen, T. (2019). Potential effects of chatbot technology on customer support: A case study.
- Sharma, S., Durand, R. M., & Gur-Arie, O. (1981). Identification and analysis of moderator variables. *Journal of Marketing Research*, 18(3), 291-300.
- Nordheim, C. B., Følstad, A., & Bjørkli, C. A. (2019). An initial model of trust in chatbots for customer service—findings from a questionnaire study. *Interacting with Computers*, 31(3), 317-335.
- Overgoor, G., Chica, M., Rand, W., & Weishampel, A. (2019). Letting the computers take over: Using AI to solve marketing problems. *California Management Review*, 61(4), 156-185.
- Pallant, J. (2001). *SPSS survival manual: A step by step guide to data analysis using SPSS*. Open University Press.
- Pantano, E., & Pizzi, G. (2020). Forecasting artificial intelligence on online customer assistance: Evidence from chatbot patents analysis. *Journal of Retailing and Consumer Services*, 55, 1-9.
- Parker, C., & Mathews, B. P. (2001). Customer satisfaction: Contrasting academic and consumers' interpretations. *Marketing Intelligence & Planning*, 19(1), 38-44.
- Paschen, J., Kietzmann, J., & Kietzmann, T. C. (2019). Artificial intelligence (AI) and its implications for market knowledge in B2B marketing. *Journal of Business & Industrial Marketing*, 34(7), 1410-1419.

- Pitt, C. S., Bal, A. S., & Plangger, K. (2020). New approaches to psychographic consumer segmentation: Exploring fine art collectors using artificial intelligence, automated text analysis and correspondence analysis. *European Journal of Marketing*, 54(2), 305-326.
- Prakash, A. V., Joshi, A., Nim, S., & Das, S. (2023). Determinants and consequences of trust in AI-based customer service chatbots. *The Service Industries Journal*, 1-34.
- Przegalinska, A., Ciechanowski, L., Stroz, A., Gloor, P., & Mazurek, G. (2019). In bot we trust: A new methodology of chatbot performance measures. *Business Horizons*, 62(6), 785-797.
- Roller, S., Dinan, E., Goyal, N., Ju, D., Williamson, M., Liu, Y., & Boureau, Y. L. (2020). Recipes for building an open-domain chatbot. *arXiv preprint. arXiv:2004.13637*.
- Roy, R., & Naidoo, V. (2021). Enhancing chatbot effectiveness: The role of anthropomorphic conversational styles and time orientation. *Journal of Business Research*, 126, 23-34.
- Russell, S. J., & Norvig, P. (2016). *Artificial intelligence: A modern approach*. Pearson Education Limited.
- Schuetzler, R. M., Grimes, G. M., & Giboney, J. S. (2020). The impact of chatbot conversational skill on engagement and perceived humanness. *Journal of Management Information Systems*, 37(3), 875-900.
- Seranmadevi, R., & Kumar, A. (2019). Experiencing the AI emergence in Indian retail—Early adopters approach. *Management Science Letters*, 9(1), 33-42.
- Sha, S. N., & Rajeswari, M. (2019). Creating a brand value and consumer satisfaction in E-commerce business using artificial intelligence with the help of VOSAG technology. *International Journal of Innovative Technology and Exploring Engineering*, 8(8), 1510-1515.
- Shawar, B. A., & Atwell, E. S. (2005). Using corpora in machine-learning chatbot systems. *International Journal of Corpus Linguistics*, 10(4), 489-516.
- Sheehan, B., Jin, H. S., & Gottlieb, U. (2020). Customer service chatbots: Anthropomorphism and adoption. *Journal of Business Research*, 115, 14-24.
- Shokouhyar, S., Shokoohyar, S., & Safari, S. (2020). Research on the influence of after-sales service quality factors on customer satisfaction. *Journal of Retailing and Consumer Services*, 56, 102139.
- Shrestha, N. (2021). Factor analysis as a tool for survey analysis. *American Journal of Applied Mathematics and Statistics*, 9(1), 4-11.
- Siau, K. L., & Yang, Y. (2017). Impact of artificial intelligence, robotics, and machine learning on sales and marketing. *MWAIS 2017 Proceedings*, 48.
- Singh, R., Paste, M., Shinde, N., Patel, H., & Mishra, N. (2018). Chatbot using TensorFlow for small businesses. In *2018 Second International Conference on Inventive Communication and Computational Technologies (ICICCT)* (pp. 1614-1619).
- Sivaramakrishnan, S., Wan, F., & Tang, Z. (2007). Giving an “e-human touch” to e-tailing: The moderating roles of static information quantity and consumption motive in the effectiveness of an anthropomorphic information agent. *Journal of Interactive Marketing*, 21(1), 60-75.
- Sowa, K., Przegalinska, A., & Ciechanowski, L. (2021). Cobots in knowledge work: Human–AI collaboration in managerial professions. *Journal of Business Research*, 125, 135-142.
- Söderlund, M., & Oikarinen, E. L. (2021). Service encounters with virtual agents: An examination of perceived humanness as a source of customer satisfaction. *European Journal of Marketing*, 55(13), 94-121.
- Stephen, A., & Ahmad, Y. (2017). Recreating intimacy with connected consumers. *NIM Marketing Intelligence Review*, 9(2), 48-53.
- Teo, T. S., Srivastava, S. C., & Jiang, L. I. (2008). Trust and electronic government success: An empirical study. *Journal of Management Information Systems*, 25(3), 99-132.
- Trappey, A. J. C., Trappey, C., Govindarajan, U. H., Sharma, A., & Yeh, L. C. (2018). Conversational service bot specifications for advanced manufacturing applications. In *2018 IEEE International Conference on Advanced Manufacturing (ICAM 2018)*.
- Tripathi, S., & Verma, S. (2018). Social media, an emerging platform for relationship building: A study of engagement with non-government organizations in India. *International Journal of Nonprofit and Voluntary Sector Marketing*, 23(1), e1589.
- Valls, A., Gibert, K., Orellana, A., & Antón-Clavé, S. (2018). Using ontology-based clustering to understand the push and pull factors for British tourists visiting a Mediterranean coastal destination. *Information & Management*, 55(2), 145-159.
- Verma, S., Sharma, R., Deb, S., & Maitra, D. (2021). Artificial intelligence in marketing: Systematic review and future research direction. *International Journal of Information Management Data Insights*, 1(1), 100002.
- Wamba, S. F., Bawack, R. E., Guthrie, C., Queiroz, M. M., & Carillo, K. D. A. (2021). Are we preparing for a good AI society? A
- Ventura ve Karabaşak (2024).

- bibliometric review and research agenda. *Technological Forecasting and Social Change*, 164, 120482.
- Wang, L. C., Baker, J., Wagner, J. A., & Wakefield, K. (2007). Can a retail web site be social? *Journal of Marketing*, 71(3), 143-157.
- Wedel, M., & Kannan, P. K. (2016). Marketing analytics for data-rich environments. *Journal of Marketing*, 80(6), 97-121.
- Westbrook, R. A., & Reilly, M. D. (1983). Value-percept disparity: An alternative to the disconfirmation of expectations theory of consumer satisfaction. *Advances in Consumer Research*, 10(1).
- Whang, J. B., Song, J. H., Lee, J. H., & Choi, B. (2022). Interacting with chatbots: Message type and consumers' control. *Journal of Business Research*, 153, 309-318.
- Wiliam, A., Sasmoko, H., Prabowo, M., Hamsal, E., & Princes, Y. (2019). Analysis of e-service chatbot and satisfaction of banking customers in Indonesia. *Asia Proceedings of Social Sciences*, 4(3), 72-75.
- Wilson-Nash, C., Goode, A., & Currie, A. (2020). Introducing the socialbot: A novel touchpoint along the young adult customer journey. *European Journal of Marketing*, 54(10), 2621-2643.
- Wirtz, J., Patterson, P. G., Kunz, W. H., Gruber, T., Lu, V. N., Paluch, S., & Martins, A. (2018). Brave new world: Service robots in the frontline. *Journal of Service Management*, 29(5), 907-931.
- Xu, Y., Niu, N., & Zhao, Z. (2023). Dissecting the mixed effects of human-customer service chatbot interaction on customer satisfaction: An explanation from temporal and conversational cues. *Journal of Retailing and Consumer Services*, 74, 103417.
- Yagoda, R. E., & Gillan, D. J. (2012). You want me to trust a ROBOT? The development of a human-robot interaction trust scale. *International Journal of Social Robotics*, 4, 235-248.
- Yao, M. (2017). 100 best bots for brands and business. www.topbots.com/100-best-bots-brands-businesses/
- Yun, J., & Park, J. (2022). The effects of chatbot service recovery with emotion words on customer satisfaction, repurchase intention, and positive word-of-mouth. *Frontiers in Psychology*, 13, 922503.
- Zamora, J. (2017). I'm sorry, Dave, I'm afraid I can't do that: Chatbot perception and expectations. In *Proceedings of the 5th International Conference on Human Agent Interaction* (pp. 253-260).
- Zarouali, B., Van den Broeck, E., Walrave, M., & Poels, K. (2018). Predicting consumer responses to a chatbot on Facebook. *Cyberpsychology, Behavior, and Social Networking*, 21(8), 491-497.
- Zehir, C., Şahin, A., Kitapçı, H., & Özşahin, M. (2011). The effects of brand communication and service quality in building brand loyalty through brand trust: The empirical research on global brands. *Procedia-Social and Behavioral Sciences*, 24, 1218-1231.

Research Article (Special Issue) | Araştırma Makalesi (Özel Sayı)

An example of the application of artificial intelligence models in human resources processes

Selim Sürücü

Berk Küçük

Mustafa Kemal Aydın

Res. Assist., Çankırı Karatekin University, selimsurucu@karatekin.edu.tr, [0000-0002-8754-3846](https://orcid.org/0000-0002-8754-3846)Student, Çankırı Karatekin University, dev.berkkucukk@gmail.com, [0009-0005-3500-4540](https://orcid.org/0009-0005-3500-4540)Student, Çankırı Karatekin University, dev.mkaydin@gmail.com, [0009-0000-0306-9730](https://orcid.org/0009-0000-0306-9730)Corresponding author/Sorumlu yazar: Selim Sürücü ✉ selimsurucu@karatekin.edu.tr

Abstract

Creating job postings and selecting suitable candidates among these job postings is a challenging process. This process increases the workload of human resources and causes the process to proceed slowly. It is of great importance for human resources departments to utilize information processing technologies to create job postings effectively and to evaluate the CVs of applicants to these postings. This study introduces and analyzes two different technologies that can help human resources. In the process of preparing job advertisements in the field of IT, in the first stage, the word cloud method is used to decide which keywords should be emphasized in the advertisement texts. In the second stage, the resumes of the applicants are analyzed using three different deep learning models such as CNN (Convolutional Neural Network), GRU (Gated Recurrent Unit), and LSTM (Long Short-Term Memory) for classification purposes. While the performance of these models is evaluated using metrics such as accuracy, MCC, F_1 score, and MSE, the decision-making processes of the models with explainable artificial intelligence are also analyzed. In this context, the GRU model, which achieved an accuracy of 99%, provided the most superior result in this study and the literature. This research shows that deep learning models provide high accuracy rates and efficiency in human resources resume classification and candidate matching processes. It also explains that using the word cloud method, the most appropriate keywords can be identified, and advertisements can be created.

Keywords: Resume Classification, AI-Powered Human Resources Automation, Natural Language, Text Classification, Explainable Artificial Intelligence

JEL Codes: O15, M12, M15

İnsan kaynakları süreçlerinde yapay zekâ modellerinin uygulanmasına bir örnek

Öz

İş ilanı oluşturmak ve bu iş ilanları arasından uygun adayları seçmek zorlu bir süreçtir. Bu süreç insan kaynaklarının iş yükünü arttırmakta, sürecin yavaş ilerlemesine neden olmaktadır. İnsan kaynakları departmanlarının etkin bir şekilde iş ilanı oluşturabilmesi ve bu ilanlara yapılan başvuruların özgeçmişlerinin değerlendirilmesi süreçlerinde bilgi işlem teknolojilerinden yararlanılması büyük bir öneme sahiptir. Bu çalışma, insan kaynaklarına yardımcı olabilecek, iki farklı teknolojinin tanıtımını ve analizini yapmaktadır. Bilgi işlem teknolojileri alanında iş ilanlarının hazırlanması sürecinde, ilk aşamada kelime bulutu yöntemi kullanılarak ilan metinlerinde hangi anahtar kelimelerin vurgulanması gerektiğine karar verilir. İkinci aşamada, başvuran adayların özgeçmişleri, sınıflandırma amacıyla CNN (Convolutional Neural Network), GRU (Gated Recurrent Unit) ve LSTM (Long Short-Term Memory) gibi üç farklı derin öğrenme modeli kullanılarak analiz edilmiştir. Bu modellerin performansları, doğruluk, MCC, F_1 score ve MSE gibi metrikler kullanılarak değerlendirilirken, açıklanabilir yapay zekâ ile modellerin karar verme süreçleri de incelenmiştir. Bu çerçevede, %99'luk bir doğruluk başarısı sergileyen GRU modeli, bu çalışma kapsamında ve literatürde elde edilen en üstün sonucu sağlamıştır. Bu araştırma, derin öğrenme modellerinin, insan kaynakları alanında özgeçmiş sınıflandırma ve aday eşleştirme süreçlerinde yüksek doğruluk oranları ve verimlilik sağladığını göstermektedir. Ayrıca, kelime bulutu yöntemi kullanılarak uygun anahtar kelimelerin belirlenerek ilanların oluşturulabileceğini de anlatmaktadır.

Anahtar Kelimeler: Özgeçmiş Sınıflandırma, Yapay Zekâ Destekli İnsan Kaynakları Otomasyonu, Doğal Dil İşleme, Metin Sınıflandırması, Açıklanabilir Yapay Zekâ

JEL Kodları: O15, M12, M15

Introduction

As one of the cornerstones of the modern business world, Human Resources (HR) plays a critical role in achieving an organization's strategic goals. Work in this field covers a wide range of areas, from employee recruitment, training and development,

How to cite this article / Bu makaleye atıf vermek için:

Sürücü, S., Küçük, B., & Aydın, M. K. (2024). An example of the application of artificial intelligence models in human resources processes. *KOCATEPEİİBFD*, 26(Özel Sayı), 101-116. <https://doi.org/10.33707/akuibfd.1443940>

performance management, compensation, and benefits management (Mezhoudi et al., 2023). The main purpose of human resources is to effectively manage and develop human capital, the most valuable asset of an organization. It is a strategic investment to help employees achieve their career goals and increase the organization's overall productivity and competitiveness. Today, with technological advances and globalization, HR practices are constantly evolving, and organizations are faced with new challenges such as diversity, flexible working patterns, and increasing employee engagement. In this context, Human Resource management has become an indispensable strategic partner for successfully managing and future-proofing organizations.

Recruitment is one of human resources management's most critical and strategic activities. This process aims to bring the right talent to the company and involves identifying, assessing, and selecting candidates (Smith, 2021). A successful recruitment process starts with a detailed analysis of the positions needed, followed by preparing an effective job advertisement and selecting suitable candidates from among the applications. This process aims to find the most suitable person to meet the candidate's and organization's needs and expectations. Recruitment is not only about finding qualified individuals but also about selecting people who will fit into the company culture and contribute in the long term. Therefore, an effective recruitment process plays a vital role in the organization's success.

Today, with the digitalization of companies and the pandemic, the vast majority of recruitment processes (such as personnel advertisements and collection of resumes) take place online. In order to carry out the processes in a healthy, fast, and accurate manner, the human resources department needs to use technology more effectively (Poulose et al., 2024). For example, processes such as analyzing the personnel correctly in the recruitment advertisement, giving the right keywords, or examining and analyzing the collected resumes correctly must be carried out quickly and accurately. Effective use of technology can help human resources carry out these processes quickly and efficiently and make the right decisions.

With the increasing use of information technologies in companies, human resources processes have also adapted. With the developments in recent years, the use of Artificial Intelligence (AI) in automation systems is increasing. AI can be defined as the development of computer systems or algorithms that mimic human-like thinking, learning, decision-making, and problem-solving abilities. AI can be used for many different purposes in human resources processes. AI automates CV screening, candidate matching, and pre-assessment processes in recruitment, helping to identify the most suitable candidates quickly and objectively. By analyzing the experience, skills, and competencies of candidates, AI-supported tools select the most suitable candidates for open positions and accelerate the recruitment process. Another human resources process where AI is used is performance evaluation. Continuous monitoring and evaluation of employee performance can increase objectivity and precision in processes. In order to reduce the workload of human resources, chatbots, and virtual assistants can be utilized to improve the employee experience and increase employee engagement. When used in in-house training processes, it can offer personalized training programs in line with employees' individual learning styles and needs. Examining employees' performance data and learning progress, AI recommends the most appropriate training materials and modules. While traditional HR methods can be inefficient and subjective at times, AI-based solutions are reshaping the field by automating processes and making data-driven decisions. AI-supported human resources systems make human resources processes very fast while ensuring that the decisions made in the process are made with high accuracy. Companies with these systems have come to the forefront in their sectors.

The use of AI in the recruitment and selection stages of the human resources process has the potential to ensure efficiency and objectivity for both employers and candidates. AI technologies can quickly and accurately assess candidates' skills, experience, and suitability, thus improving and optimizing recruitment. By scanning candidates' resumes and application forms, AI can automatically identify the candidates who best match the job description and requirements. These systems can rank candidates based on criteria such as specific keywords, skills, education levels, and work experience and highlight the most suitable candidates. In addition, AI-supported human resources or resume analysis systems allow students to closely examine the pulse of the sectors and provide students with information about the features, such as technology and language, that they need to know according to the fields in which they want to work. While enabling students to plan their education accordingly, it also allows educational institutions to keep their curricula up-to-date.

This study was conducted to improve two human resources processes in information technology companies by using natural language processing methods, one of the AI fields. The first of these processes is to identify the keywords that can be used in the job advertisement to be created for the personnel need, and a solution is proposed with a word cloud. In addition, this word cloud method provides preliminary information about what those who plan to work in information technologies should know according to the field. In the second process, the resumes of the personnel sought in the job advertisement are quickly analyzed and classified with natural language processing models to ensure automatic and accurate analysis of the initial evaluations of the resumes.

The contribution of this study to the literature is as follows:

Word cloud, which is one of the natural language processing techniques, is used to determine the right keywords that can be used in recruitment advertisements.

It is a recent example of using natural language processing techniques in human resources, a fairly new field of study.

In addition to natural language processing techniques, Gated Recurrent Unit (GRU), Long Short-Term Memory (LSTM) models, this is the first study to use the Convolutional Neural Network (CNN) model, which is a deep learning model for the correct classification of CVs.

It is one of the rare studies on resume classification that shows how a model works on a resume with explainable and interpretable AI.

The next section of this paper presents the literature on resume classification. The third section presents the methodology of this study. The methodology section describes the dataset, models, and metrics used in the study. In the third section, the results obtained in this study are presented, and the results are explained in detail. In the last section, a comparison is made with the literature, and information about its future use is given.

1. Literature Review

In recent years, with the advances in artificial intelligence technologies, information technology systems have started to play a critical role in the automation of human resources processes in areas ranging from assessing higher education students to analyzing professional experience. This literature review will detail the diversity and effectiveness of methods developed for different applications, such as classification of student and job applications, curriculum vitae enhancement and error detection, knowledge extraction, and matching. The literature review presents studies on these three different applications.

Before moving on to the studies in the literature, it is necessary to mention the accuracy metric, the most frequently used metric in the studies, to make comparisons within the scope of this study. The accuracy metric refers to the number of correctly performed classification results divided by the total amount of data. The closer the accuracy value is to 100%, the better the result is considered to be.

1.1. Resume Classification and Assessment

Haddad and Mercier-Laurent (2021) conducted a study to automate the pre-selection and assessment of higher education students for use in recruitment processes. The evaluation system used classification algorithms using machine learning according to 4 main categories: personal information, academic background, professional experience, and social and technical skills. They used Naive Bayes Classifies, Support Vector Machine (SVM), and Random Forest machine learning models. The accuracy results of these models are 64%, 69%, and 78%, respectively. Pal et al. (2022) tried to classify resumes with machine learning methods. Within the scope of this study, they collected data from 3 different websites (kaggle.com, glassdoor.com and indeed.com). They used 70% of the collected data as training and 30% as testing. They used SVM, Naive Bayes, and Random Forest machine learning methods and achieved 60%, 45%, and 70% accuracy, respectively. Another study used machine learning models SVM, Naive Bayes, K-Nearest Neighbor, Logistic regression, and Term-Frequency-Inverse-Document-Frequency (TF-IDF) to classify job applications with resumes with available vacancies. For this Resume Classification System (RCS), it was observed that the SVM model used with the One-Vs-Rest-Classification strategy achieved a validation value of around 96% (Ali et al., 2022). In another study, a resume recommendation system was developed to classify and match candidate resumes with advertisements. In this study, 4 machine learning methods (Random Forest, Multinomial Naive Bayes, Logistic Regression, Linear Support Vector Machine Classifier) were used for classification. At the same time, cosine similarity and k-NN were preferred for matching. They obtained an accuracy of approximately 78% with the Linear Support Vector Machine Classifier method in resume classification (Roy et al., 2020, p. 2318).

1.2. Resume Enhancement and Error Elimination

In another study, Bert Regression, Linear Regression, Decision Tree, Support Vector Regression (SVR), and Random Forest were used to develop a Natural Language Processing (NLP) and rule-based content scoring system to eliminate errors in the resumes prepared by undergraduate students and recent graduates and to improve the resumes. Mean Absolute Error (MEE) was used to measure success, and 4 sections of the resume (Profile, Education, Projects, and Technical Skills) were analyzed. The Bert Regression model gave the best result, and the values of 0.0667 for Profile, 0.7333 for Education, 0.5333 for Project, and 1.2667 for Technical Skills were obtained (Weerasinghe et al., 2023, p.1). Bharadwaj et al. (2022, p. 238) tried to categorize CVs according to the skills they contain according to various job options using NLP and LSTM. In this study, model success was not measured with any metric. It is seen that it is provided to be analyzed with a simple interface so that every user can use it.

1.3. Information Extraction and Matching

In another study, a structure consisting of 3 parts was developed in order to extract important information from resumes and sort them according to company requirements. In the second part, they extracted meaningful data from unstructured data. In the last stage, they made an evaluation with a decision tree. Approximately 80%- 85% accuracy was obtained with the decision tree (Reza & Zaman,2022). Another study, developed for employers, ranked resumes using the word2vec algorithm, taking into account skills, experience, education, and location. Also, in this study, after ranking, resumes and employers were matched using the Gale-Shapley algorithm (Pudasaini vd.,2022). In another similar study, an application that can be updated according to the needs of an organization was developed to analyze the resumes received for a job advertisement with headings such as educational qualifications, skill sets, and technical subjects by machine learning. An application was proposed for this, but the successful results of the machine learning used were not given (Harsha et al., 2022, p. 1772).

Machine learning and natural language processing techniques were used to predict personality traits in a study conducted to analyze personal information in a CV by adding a quiz alongside the CV. The methods used were KNN, Linear Regression, Logistic Regression, SVM, and Random Forest. The best accuracy result in this study was obtained with Random Forest with 80.2% (Anusha et al., 2023, p. 1179). In another study on software engineering candidates, a character positioning technique matched words and phrases to extract candidate information. From the extracted information, a resume summary was created, and a scoring system was created based on skills. In the testing process, the results were around 33% for five random software engineering positions (Pant et al., 2022, p. 44). In another study, they used natural language processing and text mining to identify technical knowledge in software engineering positions using resumes and unstructured texts from the syllabus. They achieved an accuracy of about 98% and presented this study as a web application (Valdez-Almada et al.,2017, p.97).

2. Methodology

2.1. Dataset

The Resume-Dataset dataset published on Kaggle and created specifically for the IT sector was used (Mzali, 2023). This dataset was created by compiling job applicants' resumes from various sources, including websites like Kaggle, Glassdoor, and Indeed. This dataset consists of a CSV file. This dataset has two columns, and one contains the resume's text version. The other column contains fields related to information technologies. This dataset, which consists of more than 29000 data, consists of 6 IT-related occupational classes. These classes are database, administrator, system administrator, project manager, software developer, network administrator, and security analyst. In addition, the data set was randomly selected from the data set with the train test split method, and 80% were split for training and 20% for testing.

Before proceeding with the model training, various operations were performed on the CV dataset. These operations are as follows:

Reading the Data Set: All CVs are contained in a CSV file. As a first step, the file with CSV extension was read.

Blank Data Check: The data set was checked for empty data, and no empty data was found.

Removal of Punctuation and Special Characters: For natural language processing models to work more effectively, punctuation marks and special characters in the texts in the resume dataset were removed, leaving only letters and numbers.

Stopwords Removal Process: Removing unnecessary words (stopwords) was performed on the resume texts. Since the CVs were in English, stopwords accepted in English were removed. Examples of English stopwords; "i", 'me', 'our', 'your', 'he', 'him', 'it', 'them', 'they', 'what', 'which', 'who', 'am', 'is', 'are', 'be', 'been', 'being', 'have', 'has', "had", 'a', 'an', 'until', 'of', 'about', 'with', 'or', 'and', 'to', 'from', 'up', 'all', 'any', 'both', 'too', 'can', 'very', 'should' etc.

Converting Tags Into Numeric Values (Encoding): As a final step, the resume tags are converted so that each category tag corresponds to a numeric value. This process is called "encode".

This was done in order to process the dataset more efficiently with natural language processing models.

2.2. Models

In this study, Convolutional Neural Networks (CNN), Long Short-Term Memory (LSTM), and Gated Recurrent Unit (GRU) models were preferred. CNN was chosen because it is a classical deep learning model, while LSTM was chosen because it is one of the most widely used models in natural language processing applications. The GRU model is included in this study because it is an improved version of the LSTM model.

This study was performed on Google Colab Pro and developed using the Nvidia Tesla T4 GPU. The specifications of the Nvidia T4 GPU are as follows:

TFLOPS: 8.1

CUDA Cores: 2560

Memory: 16 GB GDDR6

Thanks to this powerful GPU, the training and testing of deep learning models could be done faster and more efficiently. This GPU met the project's requirements, improving the model's performance and accuracy.

2.2.1. Convolutional Neural Networks(CNN)

CNN, one of the deep learning methods, stands for "Convolutional Neural Networks". This artificial intelligence model, which is used in many fields, such as image processing, video analysis, and natural language processing, has the ability to extract features from data automatically. CNNs are particularly successful in image recognition and classification tasks. The CNN architecture consists of successive layers. These layers are;

Convolutional Layer: Performs convolutional processing on the input image to extract local features. Each convolutional operation scans different parts of the image using small filters. It then creates feature maps.

Pooling Layer: Used to reduce image size and preserve the most important information in feature maps. There are two most common pooling techniques. The first is max pooling, and the other is average pooling.

Fully Connected Layer: The features obtained after convolution and pooling are fed to one or more fully connected layers for classification. This layer learns the relationships between features and classifies objects.

Activation Function: This layer helps the model to learn non-linear features. Usually ReLU (Corrected Linear Unit) is used, but there are other activation functions such as Sigmoid, tanh, etc.

The hyperparameters of the CNN model used in this study are given in Table 1.

Table 1. Hyperparameters used in the CNN model

Hyperparameter Name	Value
vocab_size	1000
embedding_dim	50
num_filters	100
filter_sizes	[2, 3, 4]
dropout_prob	0.7
hidden_dim	64
output_size	7
lr (learning Rate)	0.001
dropout	0.5
batch_size	16
num_epochs	100

Source: Authors.

2.2.2. Long Short-Term Memory (LSTM)

LSTM, a type of Recurrent Neural Network (RNN), stands for long short-term memory. Proposed in 1997 by Sepp Hochreiter and Jürgen Schmidhuber, LSTMs are specifically designed for use in sequential data processing tasks such as time series, NLP, and speech recognition. Unlike basic RNN structures, LSTM has the ability to learn long-term dependencies, making it much more suitable for complex sequential tasks.

The main feature of the LSTM is that it has a special structure that can store information for long periods of time and forget redundant information. LSTM contains 4 gates. These gates are;

Input Gate: Selects which information from the current input is important and which inputs should be added to the cell state.

Forget Gate: Decides which information to delete from the cell state. It decides the information to be deleted according to the past state and current input.

Cell State: It is seen as the heart of the LSTM. It stores long-term information. The forget gate and the enter gate can update it.

Output Gate: This gate determines the output information to be passed to the next layer or unit.

LSTM models can precisely control the flow of information through these gates. Through this control, it allows the model to learn both short-term and long-term dependencies.

The hyperparameters of the LSTM model used in this study are given in Table 2.

Table 2. Hyperparameters used in the LSTM model

Hyperparameter Name	Value
vocab_size	1000
embedding_dim	50
hidden_dim	64
output_size	7
bidirectional	True
lr (learning rate)	0.001
dropout	0.5
batch_size	16
num_epochs	100

Source: Authors.

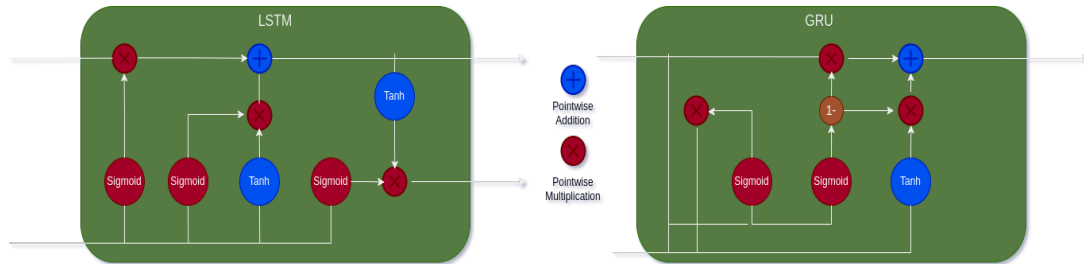
2.2.3. Gated Recurrent Unit (GRU)

Proposed in 2014 by Cho et al. GRU is a member of recurrent neural networks (RNN). Developed to overcome the difficulties of RNNs in learning long-term dependencies, GRU achieves high success in natural language processing and time series data.

Working in a similar way to the LSTM model, the main goal of GRU is to provide a structure that can remember information for long periods of time and forget redundant information. However, accomplishing this task offers a simpler structure than LSTM. Unlike the LSTM, it has 2 gates. One of the gates is the Reset Gate. This gate decides how much of the past information will be used in the creation of the future state and how this information will be combined. The other gate is known as the Update Gate, which determines which information to keep or discard. It sets the degree of importance between past information and new inputs and decides which information to pass on to the next state.

GRU works faster and more efficiently than LSTM. The biggest reason for this is that it has fewer parameters than LSTM. It is preferred when learning resources are limited (Figure 1).

Figure 1. Diagram of LSTM and GRU models



Source: Authors.

The hyperparameters of the GRU model used in this study are given in Table 3.

Table 3. Hyperparameters used in the GRU model

Hyperparameter Name	Value
vocab_size	1000
embedding_dim	50
hidden_dim	64
output_size	7
lr (learning rate)	0.001
batch_size	16
num_epochs	100

Source: Authors.

2.2.4. Local Interpretable Model-agnostic Explanations (LIME)

LIME is a method for making the decisions of complex machine learning models more understandable. LIME is considered a tool for both explainable AI and interpretable AI. explainable AI is a technique that provides transparency and ease of understanding in the decisions made by AI models. Interpretive AI is another technique for making the internal logic and decision-making process of an AI model understandable. The main features of LIME are;

Model independent. It can be applied to every model and can show the working logic of each model.

Understandability: It helps to understand the predictions of complex models.

Local Approach: LIME examines a small region around a single forecast.

The LIME approach works in 3 basic steps.

Firstly, it creates many synthetic data points in the data space around the original data points.

The complex model then predicts the synthetic data points.

Based on the predictions of the complex model, LIME creates a local description with a simple and straightforward model.

In this study, the models we used to classify resumes with LIME are used in the prediction process to see how a resume is analyzed.

The class-specific weights of the words in the resume are also included.

2.3. Metrics

In this study, the success of the models in resume classification is measured by 4 metrics. The first of these metrics is the accuracy metric. The accuracy metric is one of the most commonly used performance measures in machine learning and statistics, particularly for classification problems. It measures how well a model's predictions match the true values. Accuracy is calculated as the total number of correctly predicted examples (both positive and negative) divided by the total number of examples. The accuracy metric can be misleading in the presence of unbalanced classes. Summarizes the performance of a model in a simple way (Hossin et al., 2015, p. 1). The closer the accuracy value is to 100, the better the result.

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \quad (1)$$

In this equation,

True Positive = Refers to the situation where the forecast and actual value is YES.

True Negative = Refers to the situation where the forecast and actual value is NO.

False Positive = It refers to the situation where the model prediction is YES, but the actual output is NO.

False Negative = It refers to the situation where the model prediction is NO, but the actual output is YES.

Another metric, Mean Squared Error (MSE), is an important metric used in statistics and machine learning to evaluate model performance. It measures the amount of error by averaging the square of the difference between the predicted values and the true values. Low MSE values indicate that the model makes predictions close to the true values, while high MSE values indicate poor model performance (Wallach & Goffinet, 1989, p. 299). The ideal value for this metric is 0. The closer it is to 0, the more perfect the classification. However, the ideal value of the MSE metric may vary depending on the classification problem. For example, in a house price prediction application, a margin of error of 1000 Turkish liras among houses worth millions of Turkish liras can be considered ideal. Therefore, the ideal value for MSE is related to the problem itself.

$$MSE = \frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 \quad (2)$$

In this equation,

n is the number of samples,

Y_i actual values,

\hat{Y}_i represents the values predicted by the model.

MCC (Matthews Correlation Coefficient) is a metric commonly used to evaluate the performance of a model in classification problems. MCC expresses the performance of a classification model with a value between -1 and 1, taking into account imbalances between all classes of a classification model. The expected value of a model making completely random predictions is 0, while it takes the value 1 or -1 for perfect classification. -1 denotes a complete misclassification (Baldi et al., 2000, p.413). The main advantage of the MCC metric is that it accurately measures model performance even with imbalanced datasets. The best value for MCC is close to +1. A value of +1 indicates correct classification. A value of 0 indicates that the model produces a random result. A value of -1 indicates that the model completely misclassifies.

$$MCC = \frac{(TP \times TN) - (FP \times FN)}{\sqrt{(TP+FP) \times (TP+FN) \times (TN+FP) \times (TN+FN)}} \quad (3)$$

Another metric used in modeling imbalanced datasets is the F_1 Score, a metric used to evaluate the performance of the model in classification tasks. The F_1 Score is calculated as the harmonic mean of precision and recall and takes a value between 0 and 1. Precision is the probability that the instances that the model predicts as positive are actually positive. At the same time, recall indicates how many of the instances that are actually positive are correctly predicted as positive (Goutte & Gaussier, 2005, p. 345). The ideal value for precision, recall, and F_1 Score is 1. Precision 1 means no false positives, while recall 1 means no false negatives.

If the F_1 Score is 1, it means that there is perfect agreement between precision and recall.

$$Precision = \frac{TP}{TP+FP} \quad (4)$$

$$Recall = \frac{TP}{TP+FN} \quad (5)$$

$$F_1 \text{ Score} = 2 \times \frac{Precision \times Recall}{Precision+Recall} \quad (6)$$

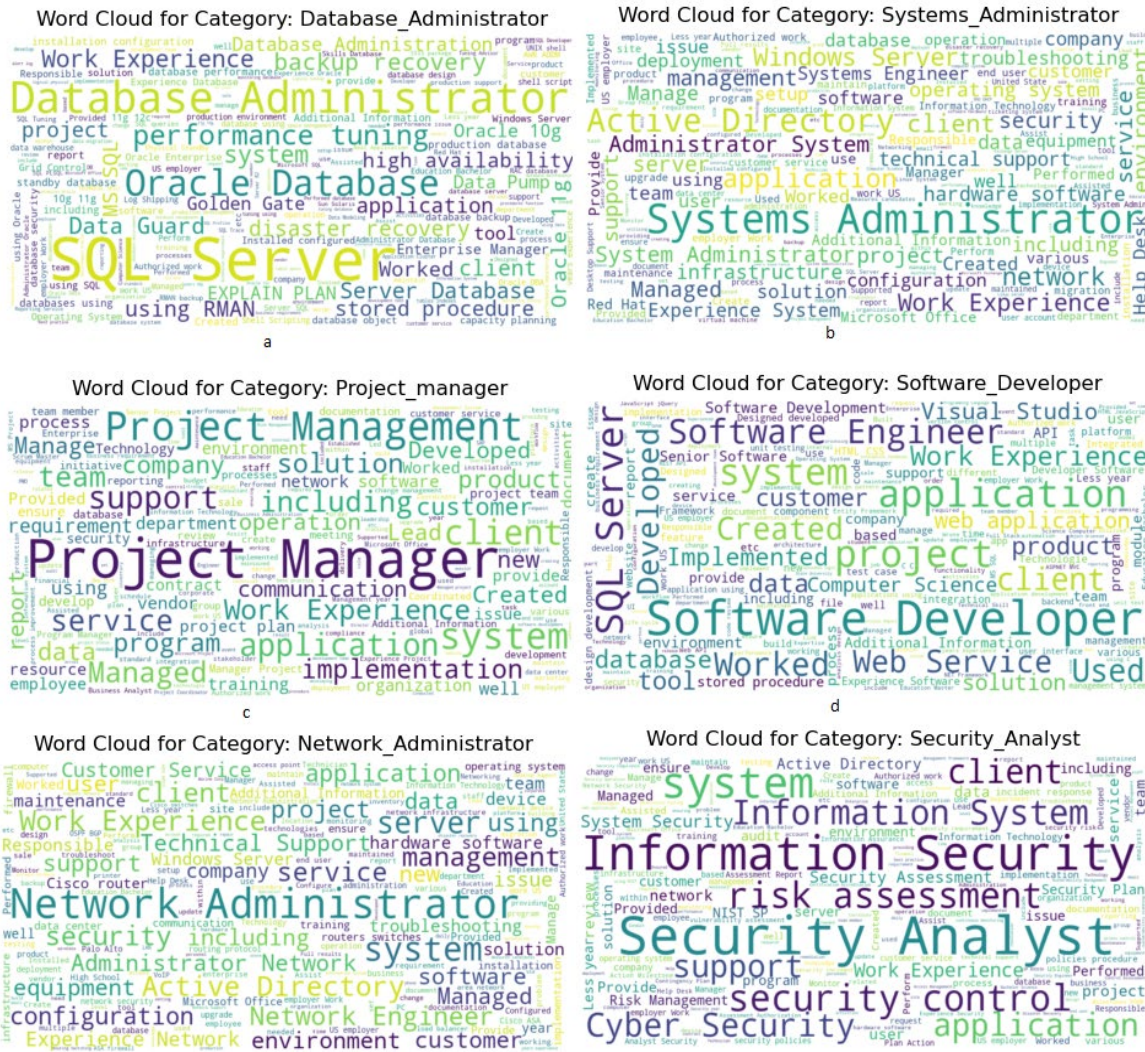
3. Results

In the first phase of this study, we used the word cloud method, a Natural Language Processing (NLP) method, to identify required qualifications for a field from resumes in the field of computer technology. A word cloud is a visual representation of the words in a collection of text or documents. Frequent words in the text are shown in larger and/or bolder fonts, while less frequent words are shown in smaller fonts. With this method, general information about a document can be obtained. In this study, the word cloud method was used to obtain information about the fields of information technologies by analyzing resumes in information technologies. The common words in the documents belonging to the same class (information technology fields) have been identified, keywords that can be used in new job postings have been identified, and it provides preliminary information about what those who want to work in that class should know.

Figure 1 shows the word clouds created for 6 information technologies. In the word cloud created for the Database administrator role in Figure 1, it is seen that concepts such as Oracle Database, SQL, high availability, Server, and backup recovery are prominent. However, for the same role, it is seen that concepts such as 10g, customer service, and education are mentioned very little. When analyzed for the System Administrator role, it is seen that concepts such as system administrator, active directory, security, and windows server are mentioned very often, while concepts such as employee, multiple, group policy, and virtual machine are mentioned less frequently. For another role, project manager, concepts such as work us, financial, and assisted are used less frequently, while concepts such as support, project management, work experience, report, managed, application, client, and lead are mentioned quite frequently. When the software developer role is analyzed, concepts such as implemented, software engineer, visual studio, SQL server, data, and web service come to the fore. For the same role, application use, enterprise, standard, group, organization, and issue are mentioned less frequently. For network administrators, which is a sub-role of information technologies, concepts such as active directory, customer service, configuration, network engineering, and technical support are frequently mentioned, while concepts such as deployment, installed, supported, maintain are rarely mentioned. When Security analyst, which is the last role in this study, is examined, it is seen that security-oriented concepts such as information security, risk assessment, system, client, active directory, security control, and cyber security stand out. In contrast, concepts such as help desk, hardware, and configuration are rarely used.

When the word clouds given in Figure 2 are analyzed, it is seen that some concepts belonging to some roles are common, while some concepts are specific to that role. For example, while the concept of risk assessment and cyber security is specific to the security analyst, the concept of active directory is a common concept with the system administrator. Likewise, concepts such as Oracle Database and backup recovery are specific to the database administrator, while SQL server is common with the software developer role. The concept of application is common to the professions of project manager and software developer, while the concept of web service is specific to the software engineer profession. The results of the models used in this study are given in Table 4. When Table 4 is analyzed, it is seen that the best result in all metrics is obtained in the GRU model. An accuracy rate of just over 99% is a very good result. In addition, the GRU model obtained 0.9883 in the MCC metric, 0.9865 in F_1 score and 0.1119 in MSE. The best value for accuracy, MCC and F_1 score metrics is 1, while the best value for MSE is 0. The GRU model was closest to 0 in MSE and closest to 1 in other metrics. The closest accuracy value to the GRU model was CNN with 97.95%. CNN model gave values of 0.9743 in MCC metric, 0.9794 in F_1 score metric and 0.1278 in MSE metric. The worst result was the LSTM model with an accuracy of 92.35%. LSTM gave values of 0.4628 in MSE metric, 0.9042 in MCC and 0.9168 in F_1 score. Loss values are also given in Table 4. When all metrics are analyzed, it is seen that the GRU model gives the best result with a value of 0.03 in terms of loss values. With this value, it is clearly seen that the GRU model shows a success parallel to its success in all metrics in the loss value. Loss values of other models are 0.2819 for the LSTM model and 0.0754 for CNN.

Figure 2. Extracting Qualifications According to Their Fields from the Resumes of Candidates in the Field of Information Technologies by Word Cloud Method



Source: Authors.

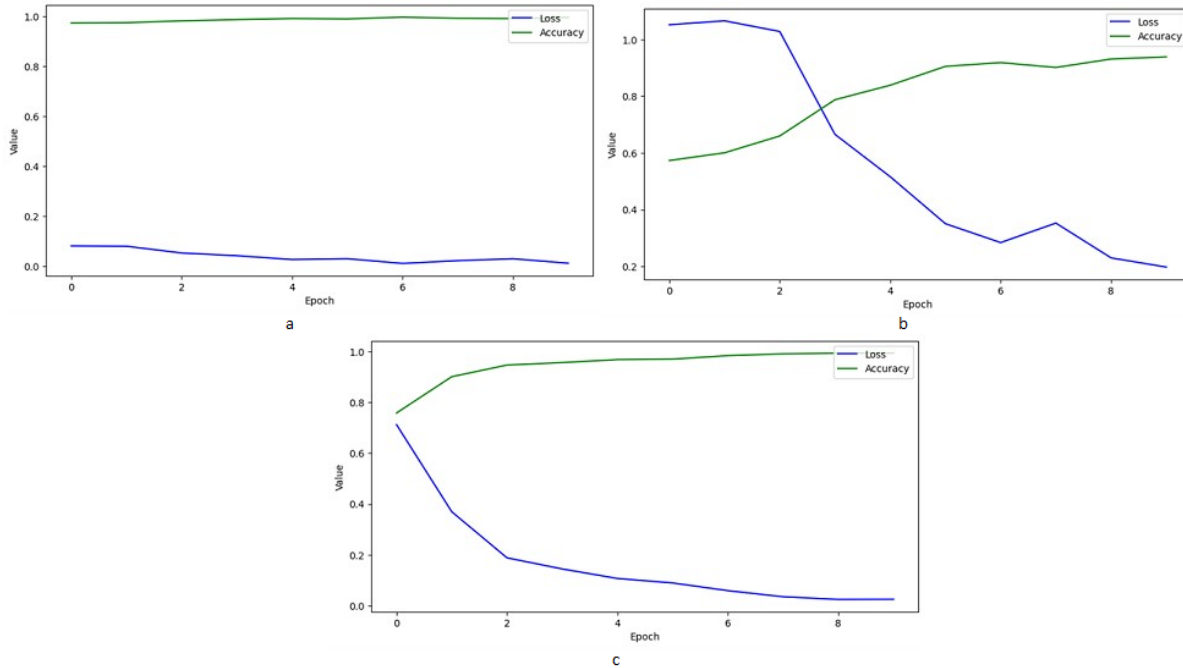
In addition, Figure 3, attached to Table 4, shows the changes in the accuracy and loss metrics of the models during the training process. At the end of the training process, the loss value is expected to be low, and the accuracy value is expected to be high. During the training process, the loss value gradually decreases, and the accuracy value increases, indicating that the training is healthy. It is seen that there is no significant change in the accuracy and loss values of the CNN model during the training process. In other words, the CNN model has been quite stable throughout the training process. When the graph of the LSTM model is analyzed, it is seen that while the values were very bad at the beginning, they improved as the training process progressed. The GRU model, which gave the best result, started with worse values than the CNN model initially but improved as the training process progressed. During the training process, LSTM was the most improved model, while CNN was the least improved model.

Table 4. Results of Models

Metrics					
Models	Accuracy (%)	MCC	F ₁ Score	MSE	Loss
CNN	97.95	0.9743	0.9794	0.1278	0.0754
LSTM	92.35	0.9042	0.9168	0.4628	0.2819
GRU	99.07	0.9883	0.9865	0.1119	0.03

Source: Authors.

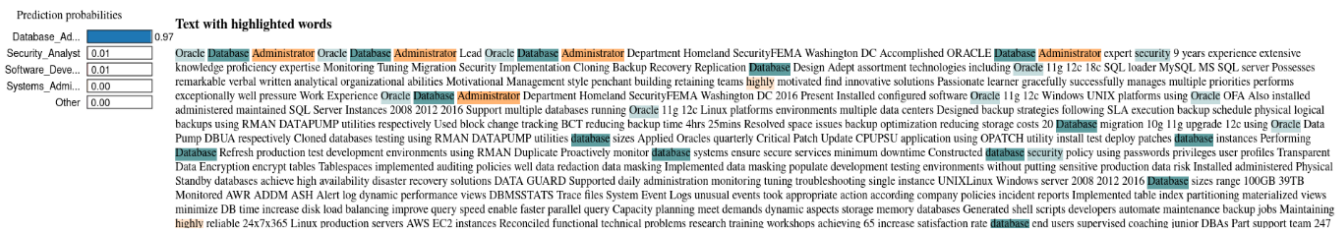
Figure 3. Plot of Accuracy and Loss Results For 9 Epochs (a: CNN, b: LSTM, c: GRU)



Source: Authors.

LIME was used to analyze a resume of the Database_Administrator class of the GRU model. The result of this analysis is shown in Figure 4. Figure 4 should be analyzed in two stages. First, the right side of Figure 4 shows the text information of the resume. When this text information is examined, some words on the text are highlighted in color. These highlights show which words the model finds important and which words are taken into account in the prediction process and are effective in predictions. For example; the word “Database” is highlighted in green and repeated quite frequently in the text. In addition, the word “Administrator” is highlighted with orange color in the text. The word “oracle” and “security” are highlighted with a similar color tone, showing that the model is equally effective in the decision-making process. It is concluded that these 4 words (“Database”, “Administrator”, “oracle”, “security”) are effective in the decision making process. When the left side of Figure 4 is analyzed, it can be concluded to which classes the given resume can belong. 97% of the time “Database_Administrator” makes the decision, 1% value is calculated for “Security_Analyst” and “Software_Developer” class, while the value of the other classes is 0.

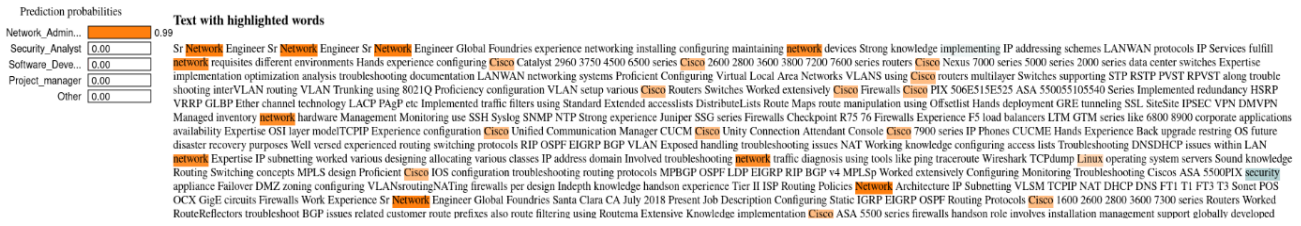
Figure 4. The Main Application of LIME and the GRU Model on the Decision-Making Process of a Resume Belonging to the Database_Administrator Class



Source: Authors.

LIME was used to analyze a resume of the Network_Administrator class of the GRU model. The result of this analysis is shown in Figure 5. Figure 5 should be analyzed in two stages. First, the right side of Figure 5 shows the text information of the resume. When this text information is examined, some words in the text are highlighted in color. These highlights show which words the model finds important and which words are taken into account in the prediction process and are effective in predictions. For example, the most effective word is “network”, which is highlighted in orange. The word “Cisco” highlighted in light orange and the word “security” highlighted in blue are also effective in the classification decision process. When the left side of Figure 5 is analyzed, it is seen that the model made the decision of “Network_Administrator” with 99% accuracy. When the other classes are analyzed, it is seen that the rate is 1% and lower.

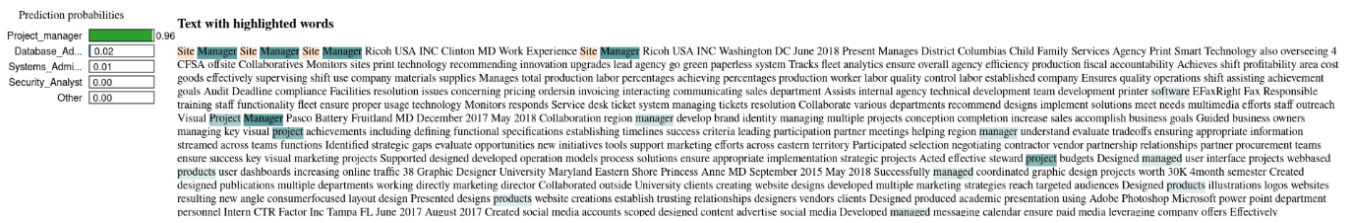
Figure 5. The Main Application of LIME and the GRU Model on the Decision-Making Process of a Resume Belonging to the Network_Administrator Class



Source: Authors.

LIME was used to analyze a resume of the “Project_manager” class of the GRU model. The result of this analysis is shown in Figure 6. Figure 6 should be analyzed in two stages. Firstly, the right side of Figure 6 shows the text information of the resume. When this text information is examined, some words in the text are highlighted in color. These highlights show which words the model finds important and which words are taken into account in the prediction process. For example, it is seen that the words “manager” and “project” highlighted in green are the most effective words in the decision making process. The words “products”, “managed”, “manager” and “site” highlighted in light green are also effective in the decision-making process. As a result of the analysis of these words, the GRU model predicted the “Project_manager” class 96% of the time, while it predicted the “Database_Administrator” class 2% of the time. The GRU model calculated that the other classes have 1% and less.


Figure 6. The Main Application of LIME and the GRU Model on the Decision-Making Process of a Resume Belonging to the Project_manager class



Source: Authors.

LIME was used to analyze a resume of the Security_analyst class of the GRU model. The result of this analysis is shown in Figure 7. Figure 7 should be analyzed in two stages. First, the right side of Figure 7 shows the text information of the resume. When this text information is examined, some words in the text are highlighted in color. These highlights show which words the model finds important and which words are taken into account in the prediction process. For example, the word “Security” is highlighted in green and it is seen that it is the most effective word. When we look at the other words, it is seen that the words “network” and “July” are also effective. When the left side of the Figure is analyzed, it is seen that the GRU model decided that 98% of the CV belongs to the “Security_analyst” class. In addition, the GRU model calculated the probability of belonging to the “System_Administrator”, “Project_manager” and “Database_Administrator” classes as 1%, while the value for the other classes was 0.


Figure 7. The Main Application of LIME and the GRU Model on the Decision-Making Process of a Resume Belonging to the Security_Analyst class



Source: Authors.

LIME was used to analyze a CV of the Software_Developer class of the GRU model. The result of this analysis is shown in Figure 8. Figure 8 should be analyzed in two stages. First, the right side of Figure 8 shows the text information of the resume. When the CV is examined, it is seen that the words “Software_Developer”, “Developed”, “Java” and “development” highlighted in green are the most effective words. The words “curriculum” and “implemented” highlighted in orange are effective for this class but may be effective for other classes. The GRU model has determined with 100% certainty that this resume belongs to the “Software_Developer” class.


Figure 8. The Main Application of LIME and the GRU Model on the Decision-Making Process of a Resume Belonging to the Software_Developer class.



Source: Authors.

LIME was used to analyze a resume of the System_Administrator class of the GRU model. The result of this analysis is shown in Figure 9. Figure 9 should be analyzed in two stages. First, the right side of Figure 9 shows the textual information of the resume. When the CV is examined, it is seen that only one word is expressed in orange color and this word may be effective for other classes. The word shown in orange is “network”. In this case, it is not possible to talk about the effect of one word clearly, but it is seen that there are very few effective words. These words are words like “manager”, “administrator”, “sales”. GRU concluded that this resume belongs to the System_Administrator class with a slightly lower value (79%), but with 11% it belongs to the Software_Developer class. Regarding the other classes, the results show that 5% belong to “Security_Analyst”, 4% to “Project Manager” and 2% to other classes.

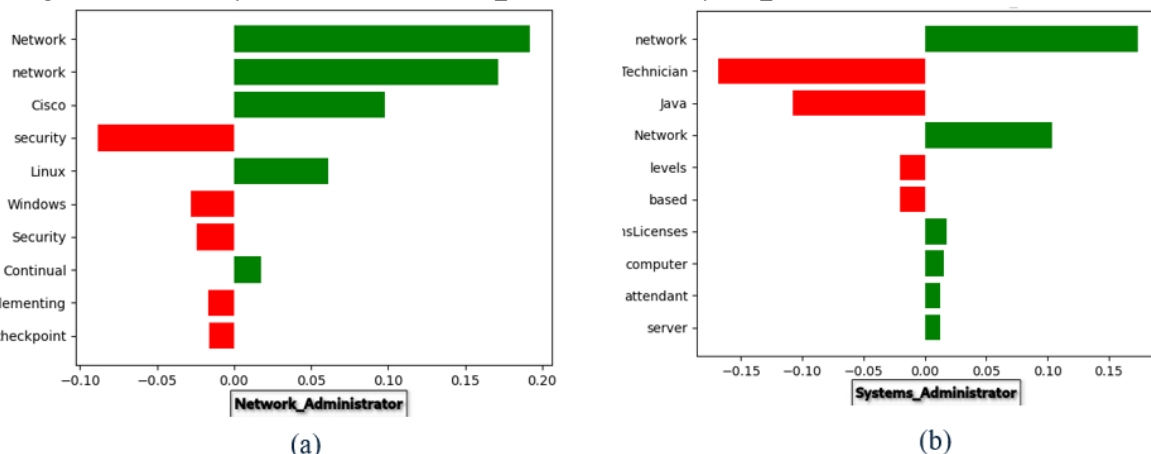
Figure 9. The Main Application of LIME and the GRU Model on the Decision-Making Process of a Resume Belonging to the System_Administrator class.



Source: Authors.

Figure 10 shows the words used by the GRU model in the classification process for Network_Administrator and System_Administrator classes with LIME. When examining the bar graphs in Figure 10, it should be noted that green colors indicate that the words belonging to those classes are important words, while red colored words have a negative impact for the class. In Figure 10 (a), it can be seen that the words “Network”, “network”, “Cisco”, “Linux” and “Continual” belonging to the Network_Administrator class are effective in the decision making process. However, the words “security”, “Windows”, “Security”, “Security”, “implementing” and “checkpoint” belonging to a different class may have an effect on the conclusion, while it is negative for the Network_Administrator class. In Figure 10 (b), the important words for the Systems_Administrator class are “network”, “Network”, “Licenses”, “computer”, “attendant” and “server”. The negative words belonging to this class are “Technician”, “Java”, “levels” and “based”. Among the important words in these two classes, the words “network” and “network” are common. In addition to these common words, the GRU model also looks at other important words to determine which class they belong to. So, if the word “Linux” or “Cisco” appears next to the word “Network” in the resume, the GRU model decides that this resume belongs to the Network_Administrator class. On the other hand, if the words “computer” or “server” appear next to “network” or “Network”, the GRU model decides that this resume belongs to the System_Administrator class.

Figure 10. Word Analysis with LIME for Network_Administrator and System_Administrator Classes of GRU model



Source: Authors.

Conclusion

The word cloud techniques used in this study have been shown to reveal the qualities that candidates who will work in computer technology should know and have according to the roles they want. This will help the candidate develop himself/herself according to the role beforehand and give the chance to organize his/her training according to these characteristics. In addition, word clouds can be used as an auxiliary application that can be used by the human resources department in the recruitment process, from the job advertisement to the end of the pre-assessment process, providing preliminary information about which qualifications they should have according to the role. The effective use of the word cloud method can provide significant contributions both for human resources and candidates.

In this study, the GRU model used in the resume classification step achieved an accuracy of just over 99%. In other words, the GRU model performs a very accurate classification. In addition, when Table 4 is examined, the closest study to the GRU model in the classification of general resumes is the study by Haddad and Mercier-Laurent (2021), where they obtained 85% accuracy with the Decision Tree model. On IT resumes, the closest result to this study is the study by Valdez-Almada et al. (2017, p.97), where they obtained a 98% accuracy value with the text mining method. There may be two major reasons why our study yielded the best results. The first reason may be that we only worked with resumes related to information technologies. The second reason is that we used current and newly developed models. We believe that our results are better than those of other studies because we work with current models, such as GRU, among natural language processing models.

The research results show that these deep learning models provide high accuracy rates and efficiency in human resources' resume classification and candidate matching processes. Furthermore, the paper shows that applying the models can significantly help human resource professionals in candidate selection by improving the speed and quality of recruitment processes. These models can be integrated into applications such as CRM, making human resources modules AI-enabled.

Table 4. Comparison with the Literature

Literature	Model	Accuracy (%)	Dataset Feature
Haddad and Mercier-Laurent (2021)	Random Forest	78	General
Reza and Zaman(2022)	Decision Tree	85	General
Anusha et al. (2023, p. 1179)	Random Forest	80.2	General
Roy et al. (2020, p. 2318)	Linear Support Vector Machine Classifier	78	General
Pant et al. (2022, p. 44)	Extract Information	33	IT
Valdez-Almada et al. (2017, p. 97)	Text Mining	98	IT
Pal et al. (2022)	Random Forest	70	General
Our Proposal	GRU	99	IT

Source: Authors.

Finally, this study has shown that the word cloud method can be used to select the best keywords for advertisements in information technology. This method helps candidates to make decisions during the application process and shows what students studying IT should know according to the field they want to work in. In addition, the curricula of departments such as computer engineering and software engineering can be reorganized according to these keywords, and the personnel needed by the sector can be trained.

There are some limitations in this study. The data set used in this study includes only CVs in information technologies. There are limitations regarding data set diversity and number of data. The GRU model, which gives the best results as a model, gave good results on IT resumes. However, how it will perform in general resume classification or in different data sets remains to be seen. In addition, the study did not test integration and compatibility with the tools used in human resources processes.

The study can be repeated in future studies with more extensive and diverse datasets, including different sectors and job roles. In addition, the universality of the study can be extended by training with resumes in different languages, not only English resumes. In addition to data set studies, modifications can be made to the models, or improvements can be made to new models. This AI-based study and similar studies can be integrated with human resource management systems (HRMS) and customer relationship management systems (CRM) to test the models in real environments. In addition, model results can be verified by a human resources expert. The accuracy can be increased by repeating the training process with user feedback.



This research article has been licensed with Creative Commons Attribution - Non-Commercial 4.0 International License. Bu araştırma makalesi, Creative Commons Atıf - Gayri Ticari 4.0 Uluslararası Lisansı ile lisanslanmıştır.

Author Contributions

The authors have declared contributions to research as follows: Selim Sürücü: 50%, Berk Küçük: 25%, Mustafa Kemal Aydın: 25%

Acknowledgments

The authors reported no acknowledgment.

Funding and Support

The authors reported no funding and support.

Conflict of Interests

The authors reported no conflict of interest.

Ethics Statement

The authors have reported no need for ethical committee approval.

Corresponding Editors

Assoc. Prof. Dr. Beyza Mina Ordu-Akkaya, Ankara University of Social Sciences

Assoc. Prof. Dr. Görkem Ataman, Yaşar University

Res. Asst. Yunus Yıldırım, Afyon Kocatepe University

References

- Ali, I., Mughal, N., Khand, Z. K., Ahmed, J., & Mujtaba, G. (2022). Resume classification system using natural language processing and machine learning techniques. *Mehran University Research Journal Of Engineering & Technology*, 41(1), 65-79.
- Anusha, K. O. V., Dhar, A., Dixit, S., Saraf, A., & Lonial, I. A. N. (2023). Automated personality-based candidate shortlisting using machine learning and natural language processing. *2023 Second International Conference on Augmented Intelligence and Sustainable Systems (ICAISS)*, Trichy, India, 2023, pp. 1179-1184. <https://doi.org/10.1109/ICAISS58487.2023.10250633>
- Baldi, P., Brunak, S., Chauvin, Y., Andersen, C. A. F., & Nielsen, H. (2000). Assessing the accuracy of prediction algorithms for classification: An overview. *Bioinformatics*, 16(5), 412-424.
- Bharadwaj, S., Varun, R., Aditya, P. S., Nikhil, M., & Babu, G. C. (2022). Resume screening using NLP and LSTM. *2022 International Conference on Inventive Computation Technologies (ICICT)*, Nepal, 2022, pp. 238-241. <https://doi.org/10.1109/ICICT54344.2022.9850889>
- Cho, K., Merriënboer, B. V., Gulcehre, C., Bahdanau, D., Bougares, F., Schwenk, H., & Bengio, Y. (2014). Learning phrase representations using RNN encoder-decoder for statistical machine translation. *Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP)*, pp. 1724-1734. <https://doi.org/10.3115/v1/D14-1179>
- Haddad, R., & Mercier-Laurent, E. (2021). Curriculum vitae (CVs) evaluation using machine learning approach. In E. Mercier-Laurent, M. Ö. Kayalica, & M. L. Owoc (Eds.), *Artificial intelligence for knowledge management* (Vol. 614). Springer, Cham. https://doi.org/10.1007/978-3-030-80847-1_4
- Harsha, T. M., Moukthika, G. S., Sai, D. S., Pravallika, M. N. R., Anamalamudi, S., & Enduri, M. (2022). Automated resume screener using natural language processing (NLP). *2022 6th International Conference on Trends in Electronics and Informatics (ICOEI)*, Tirunelveli, India, 2022, pp. 1772-1777. <https://doi.org/10.1109/ICOEI53556.2022.9777194>
- Hossin, H., & M. N., S. (2015). A review on evaluation metrics for data classification evaluations. *International Journal of Data Mining & Knowledge Management Process*, 5, 01–11. <https://doi.org/10.5121/ijdkp.2015.5201>
- Goutte, C., & Gaussier, E. (2005). A probabilistic interpretation of precision, recall, and F-score, with implication for evaluation. *Advances in Information Retrieval*, pp. 345-359.
- Mezhoudi, N., Aşghamdi, R., Aljunaid, R., Krichna, G., & Düşteğör, D. (2021). Employability prediction: A survey of current approaches, research challenges and applications. *Journal of Ambient Intelligence and Humanized Computing*, 14, 1489-1505. <https://doi.org/10.1007/s12652-021-03276-9>
- Mzali, W. (2023, February 27). Resume dataset. Retrieved on 18 December 2023 from <https://www.kaggle.com/datasets/wahib04/multilabel-resume-dataset>
- Pal, R., Shaikh, S., Satpute, S., & Bhagwat, S. (2022). Resume classification using various machine learning algorithms. *In ITM Web Conf*. <https://doi.org/10.1051/itmconf/20224403011>
- Pant, D., Pokhrel, D., & Poudyal, R. (2022). Automatic software engineering position resume screening using natural language processing, word matching, character positioning, and regex. *2022 5th International Conference on Advanced Systems and Emergent Technologies (ICASET)*, Hammamet, Tunisia, 2022, pp. 44-48. https://doi.org/10.1109/IC_ASET53395.2022.9765916
- Pudasaini, S., Shakya, S., Lamichhane, S., Adhikari, S., Tamang, A., & Adhikari, S. (2022). Scoring of resume and job description using Word2vec and matching them using Gale–Shapley algorithm. In I. Jeena Jacob, F. M. Gonzalez-Longatt, S. Kolandapalayam Shanmugam, & I. Izonin (Eds.), *Expert clouds and applications* (Vol. 209). Springer, Singapore. https://doi.org/10.1007/978-981-16-2126-0_55
- Reza, Md. T., & Zaman, Md. S. (2022). Analyzing CV/resume using natural language processing and machine learning.
- Roy, P. K., Chowdhary, S. S., & Bhatia, R. (2020). A machine learning approach for automation of resume recommendation system. *Procedia Computer Science*, 167, 2318-2327. <https://doi.org/10.1016/j.procs.2020.03.284>
- Smith, J. D. (2021). Recruitment strategy. In A. B. Johnson & C. D. Lee (Eds.), *The Oxford Handbook of Human Resource Management* (pp. 123-145). Oxford University Press. <https://doi.org/10.1093/oxfordhb/9780198833783.001.0001>
- Poulose, S., Bhattacharjee, B., & Chakravorty, A. (2024). Determinants and drivers of change for digital transformation and digitalization in human resource management: A systematic literature review and conceptual framework building. *Management Review Quarterly*. <https://doi.org/10.1007/s11301-024-00423-2>
- Valdez-Almada, R., Rodriguez-Elias, O. M., Rose-Gomez, C. E., Velazquez-Mendoza, M. D. J., & Gonzalez-Lopez, S. (2017). Natural language processing and text mining to identify knowledge profiles for software engineering positions: Generating knowledge profiles from resumes. *2017 5th International Conference in Software Engineering Research and Innovation (CONISOFT)*, Merida, Mexico, 2017, pp. 97-106. <https://doi.org/10.1109/CONISOFT.2017.00019>

Wallach, D., & Goffinet, B. (1989). Mean squared error of prediction as a criterion for evaluating and comparing system models. *Ecological Modelling*, 44(3-4), 299-306. [https://doi.org/10.1016/0304-3800\(89\)90035-5](https://doi.org/10.1016/0304-3800(89)90035-5)

Weerasinghe, R. L., Perera, N. N., Warusawithana, S. P., Hindakaraldeniya, T. M., & Ganegoda, G. U. (2023). 2023 8th International Conference on Information Technology Research (ICITR). *2023 8th International Conference on Information Technology Research (ICITR)*, Colombo, Sri Lanka, 2023, pp. 1-6. <https://doi.org/10.1109/ICITR61062.2023.10382755>

Research Article (Special Issue) | Araştırma Makalesi (Özel Sayı)

Kişilik özelliklerinin yapay zekâ tutumuna etkisinde statü kaygısının ılımlaştırıcı rolü: Muhasebe meslek mensupları üzerine ampirik bir çalışma

Fatih Bıyıklı

Tunga Bozdoğan

Ömer Orbay Çetin

Dr. Öğr. Üyesi, Afyon Kocatepe Üniversitesi, fbiyikli@aku.edu.tr, [0000-0002-1652-7910](https://orcid.org/0000-0002-1652-7910)Doç. Dr., Eskişehir Osmangazi Üniversitesi, tunga.bozdogan26@gmail.com, [0000-0002-1651-9865](https://orcid.org/0000-0002-1651-9865)Arş. Gör., Afyon Kocatepe Üniversitesi, omerocetin@aku.edu.tr, [0000-0002-6909-7248](https://orcid.org/0000-0002-6909-7248)Corresponding author/Sorumlu yazar: Ömer Orbay Çetin ✉ omerocetin@aku.edu.tr

Öz

Muhasebe alanındaki kullanımı her geçen gün artan yapay zekâ teknolojisi, muhasebe meslek mensuplarının geleceğini doğrudan etkilemekte ve muhasebe çalışanlarını yeni beceriler kazanmaya itmektedir. Buna bağlı olarak muhasebe meslek mensuplarının kişilik özellikleri temelinde yapay zekâyâ tutumunu ve buna bağlı olarak yaşadıkları statü kaygısını ölçmek önem taşımaktadır. Bu çalışmada, Eskişehir ilindeki muhasebe meslek mensuplarına üç ayrı ölçek içeren bir anket uygulanmış ve anket yanıtları Smart-PLS 3.0 YEM (Yapısal Eşitlik Modeli) aracılığıyla analiz edilmiştir. Analizde öncelikli olarak PLS-YEM analiz kısıtları belirtilmiş, ardından faktör analizi ve güvenilirlik ve geçerlilik testleri yapılmıştır. Bu aşamalardan sonra HTMT ve Fornell Larcker Kriteri test sonuçlarına yer verilmiş, son aşamalar olarak da varyans artırıcı faktör (VIF) değeri ve model uyum endeksleri değerlendirilerek analiz tamamlanmıştır. Elde edilen bulgulara göre muhasebe meslek mensuplarının dışa dönüklükleri arttıkça yaşadıkları statü kaygısında bir düşüş ve yapay zekâyâ tutumunda olumlu bir algı tespit edilmiştir. Ayrıca muhasebe meslek mensuplarının statü kaygısı arttıkça negatif yapay zekâ tutum algısında artış görülürken, öz denetimlilik kişilik özelliği arttıkça statü kaygısında ve negatif yapay zekâyâ tutum algısında da düşüş görülmüştür. Çalışmanın son kısmında ise elde edilen bulgulardan hareketle muhasebe meslek mensupları ve muhasebe alanı için çeşitli önerilerde bulunulmuştur.

Anahtar Kelimeler: Yapay Zekâ, Dijitalleşme, Muhasebe Meslek Mensupları, Statü Kaygısı **JEL Kodları:** M40, M41, M42, M49

The mediating role of status anxiety in the effect of personality traits on artificial intelligence attitude: An empirical study on accounting professionals

Abstract

Artificial intelligence technology, whose use in the field of accounting is increasing day by day, directly affects the future of accounting professionals and pushes accounting professionals to acquire new skills. Accordingly, it is important to measure the attitude of accounting professionals towards artificial intelligence on the basis of their personality traits and the status anxiety they experience accordingly. In this study, a questionnaire containing three different scales was applied to accounting professionals in Eskişehir province, and the survey responses were analyzed using Smart-PLS 3.0 SEM (Structural Equation Modeling). In the analysis, firstly, PLS-SEM analysis constraints were specified, followed by factor analysis and reliability and validity tests. After these stages, HTMT and Fornell Larcker Criterion test results were included, and the analysis was completed by evaluating the variance inflation factor (VIF) value and model fit indices as the last stages. According to the findings, as the extroversion of accounting professionals increases, there is a decrease in their status anxiety and a positive perception in their attitude toward artificial intelligence. In addition, as the status anxiety of accounting professionals increased, there was an increase in the perception of negative artificial intelligence attitude, while as the self-control personality trait increased, there was a decrease in status anxiety and a decrease in the perception of negative artificial intelligence attitude. In the last part of the study, various suggestions were made for accounting professionals and the field of accounting based on the findings obtained.

Keywords: Artificial Intelligence, Digitalization, Accounting Professionals, Status Anxiety **JEL Codes:** M40, M41, M42, M49

Extended Summary

The Big Five personality concept has combined many definitions of the difficult-to-define personality concept, making it more general and valid. In most personality studies, the Big Five personality concept is used, and personality traits are grouped into five factors. These factors are extraversion, agreeableness, self-control, neuroticism, and openness to experience.

How to cite this article / Bu makaleye atıf vermek için:

Bıyıklı, F., Bozdoğan, T., & Çetin, Ö. O. (2024). Kişilik özelliklerinin yapay zekâ tutumuna etkisinde statü kaygısının ılımlaştırıcı rolü: Muhasebe meslek mensupları üzerine ampirik bir çalışma. *KOCATEPEİİBFD*, 26(Özel Sayı), 117-132. <https://doi.org/10.33707/akuuibfd.1462678>

In mainstream economics, individuals are considered isolated from society and pursuing profit-benefit maximization. However, individuals often want to know their situation in society and attach great importance to this. In some cases, individuals' importance to their place in society even precedes the desire for profit-benefit maximization. In other words, status anxiety is a factor that shapes and affects many of the decisions individuals make.

It is also possible to describe status anxiety as a state of constant worry about individual socioeconomic status and success. Individuals' inability to achieve a level of success in society, being stuck in the same social position, or worrying about losing their current status means that they experience status anxiety. If individuals cannot achieve these, they experience reactions such as stress, fear, and panic.

Studies on the use of artificial intelligence technology in the field of accounting date back approximately 35 years. In the last ten years, there has been an increase in studies on the subject and the artificial intelligence applications used in accounting. With each passing day, the use of artificial intelligence applications in accounting is becoming more widespread, and its necessity is almost inevitable.

In a study conducted by Manpower Group in 2016, it was stated that accounting and finance are among the areas most affected by artificial intelligence technology. Considering the features such as permanence, shareability, developability, consistency, and registration that distinguish artificial intelligence from human intelligence, it is possible to think that the fields of accounting and finance will be negatively affected in terms of employment. Many of the applications offered by artificial intelligence technology can perform operations with human power.

This research examined the effects of the personality traits of professional accountants in Eskişehir on their attitudes towards artificial intelligence and the role of status anxiety in the relationship between these two factors. In this context, personality traits were measured through the Big Five personality traits scale consisting of 10 items, status anxiety was measured with the status anxiety scale consisting of 5 items, and artificial intelligence attitude was measured through the 20-item general artificial intelligence attitude scale.

Considering the increase in the use of artificial intelligence applications in the accounting sector and the many innovations it brings with it, while the attitude of professional accountants to this technology is critical, it is also possible to evaluate this attitude with their personality traits and associate it with whether they will be able to maintain their current status. In line with this information, a survey including artificial intelligence attitude, status anxiety, and Big Five personality scales was applied to professional accountants practicing their profession in Eskişehir within the scope of the study, and the answers obtained were analyzed with the Smart-PLS 3.0 SEM method. The research model created for the analysis includes the big five personality traits, negative and positive perceptions of artificial intelligence, and status anxiety, which has a moderating role between both factors. Following the creation of the research model, PLS-SEM analysis constraints, PLS-SEM factor analysis, reliability and validity tests, VIF value, model fit indices, and path analysis stages were applied, and then the findings regarding the data set were evaluated.

It has been determined that as professional accountants' extroversion increases, their status anxiety decreases. In order to evaluate this situation more accurately, it is necessary to look at the relationship between extroversion and artificial intelligence attitude. The relationship between professional accountants' perceptions of extraversion and attitude towards artificial intelligence was seen as positive due to the analysis. Accordingly, it is possible to say that as the extroversion levels of professional accountants increase, a positive increase is observed in their perception of artificial intelligence, and therefore, they experience a decrease in status anxiety. It has been observed that the status anxiety of professional accountants who do not improve themselves with artificial intelligence technology and do not include it in their business models increases. With this, the perception of negative artificial intelligence attitudes also increases. Professional accountants who want to maintain their current position and status in the future must improve themselves and add new skills to the ones they already have. As professional accountants improve themselves in artificial intelligence-based applications, increase their awareness of this issue, and see that they have to work in harmony with this technology, their self-control will improve and, accordingly, their status anxiety will decrease.

When all the findings obtained from the study are evaluated together, there should be a positive increase in the personality traits of extroversion and self-control, especially for professional accountants who do not experience artificial intelligence-based status anxiety. It would be right to emphasize that it is essential for professional accountants to focus on the opportunities that this technology will offer them instead of experiencing fear and panic about artificial intelligence technology so that they can continue their profession successfully in the future.

Giriş

Yapay zekâ teknolojisi, kavramsal olarak ilk kez 1955 yılında John McCarthy tarafından yapılan bir çalışmada ortaya çıkmış ve 1960'lı yıllarda daha sık kullanılmaya başlanmıştır. Özellikle son 10 yıldır, yapay zekâ teknolojisiyle ilgili muhasebe, finans, sağlık,

perakende, yazılım vb. birçok sektör üzerinde ne derecede etkili olacağına dair çalışmalar ve değerlendirmeler yapılmıştır. Günümüzde yapay zekânın en çok etkilediği ve gelecekte de etkilemeye devam edeceği sektörlerin başında da muhasebe gelmektedir. Başta denetim alanı olmak üzere muhasebe sektörüne ilişkin pek çok alanda yapay zekâ uygulamaları kullanılmakta ve kullanım sıklığı her geçen gün artmaktadır. Muhasebe sektörünün yapay zekâyla oldukça güçlü bir ilişkide olması da muhasebe meslek mensuplarını doğrudan etkileyen bir durumdur. Dolayısıyla muhasebe meslek mensuplarının yapay zekâ hakkındaki düşünceleri, becerileri ve yaşadığı kaygılar da önemli bir çalışma alanı olarak öne çıkmaktadır.

Yapay zekâ teknolojisi, muhasebe sektörüne iş yükünde azalma, bilgiye erişimde kolaylık ve zamandan tasarruf gibi çeşitli fırsatlar sunmakla birlikte insan gücüne olan ihtiyacın azalması, muhasebe çalışanlarının yaptığı birden fazla işlemin aynı anda yapılması nedeniyle muhasebe çalışanlarının önemini yitirmesi ve işsizlikle karşı karşıya kalma gibi tehditleri de beraberinde getirmektedir. Muhasebe meslek mensuplarının yapay zekâ hakkındaki düşüncelerinin tespiti ve yaşadıkları kaygının nedenlerinin ve boyutlarının kişilik özellikleriyle bağdaştırılarak araştırılması, muhasebe meslek mensuplarının mevcut durumlarının analiz edilmesi ve gelecekte mesleki olarak ne yönde konumlanacağı yorumlanması açısından oldukça önemlidir. Bu doğrultuda çalışmanın konusu, muhasebe meslek mensuplarının kişilik özellikleri temelinde yapay zekâyı tutumlarının ve yaşadıkları statü kaygısının araştırılmasıdır. Eskişehir ilinde yaşayan muhasebe meslek mensuplarına anket uygulanan çalışmada, muhasebe meslek mensuplarının yapay zekâyı yönelik tutumlarının kişilik özellikleriyle ilişkilendirilerek yaşadıkları statü kaygısının analiz edilmesi ve elde edilen bulgulara göre önerilerde bulunulması amaçlanmıştır.

Çalışmanın sonuç kısmında ise elde edilen bulgular değerlendirilmiş ve muhasebe meslek mensuplarına yönelik çeşitli önerilerde bulunulmuştur. Bulgulardan hareketle muhasebe meslek mensuplarının yapay zekâyı tutumu ne kadar olumlu olursa, statü kaygısının da o kadar düşük olacağını ön görmek mümkündür. Muhasebe meslek mensuplarının yapay zekâ teknolojisinin sunduğu uygulamaları kullanmak için sahip olduğu becerilere yenilerini eklemesi veya mevcut becerilerini güncellemesi kaçınılmazdır. Muhasebe meslek mensupları ve yapay zekâ arasındaki ilişkinin sağlıklı şekilde gelişmesi için ise muhasebe meslek mensuplarının bireysel çabası kadar Türkiye Serbest Muhasebeci Mali Müşavirler ve Yeminli Mali Müşavirler Odaları Birliği (TÜRMOB), Temel Eğitim ve Staj Merkezi (TESMER), Kamu Gözetimi, Muhasebe ve Denetim Standartları Kurumu (KGK) ve TÜRMOB Sürekli Mesleki Geliştirme Eğitimi Merkezi (SÜRGEN) gibi yetkili muhasebe kurumlarının da rol alması gerektiği önerilmektedir.

1. Kavramsal Çerçeve

Çalışmanın genel çerçevesini muhasebe özelinde yapay zekâ, statü kaygısı ve beş faktörlü kişilik kavramları oluşturmaktadır. Bu başlık altında ilk olarak statü kaygısı ve beş faktörlü kişilik kavramlarına ilişkin genel açıklamalar yer almaktadır. Ardından çalışmanın temelini oluşturan yapay zekâ kavramı tanımlanmış ve değerlendirmelerde bulunulmuştur. Bu bölüme ait son alt başlıkta ise yapay zekâ teknolojisinin muhasebe alanındaki kullanımına ve uygulamalarına ilişkin değerlendirmelere yer verilmiştir.

1.1. Statü Kaygısı Kavramı

Ana akım iktisatta bireyler, toplumdaki soyutlanan ve kâr-fayda maksimizasyonu peşinde olan varlıklar olarak değerlendirilir. Fakat bireyler, çoğu zaman toplum içerisindeki durumlarının ne olduğunu bilmek istemekte ve buna oldukça önem vermektedirler. Bazı durumlarda ise bireylerin toplum içerisindeki yerinin ne olduğuna verdiği önem, kâr-fayda maksimizasyonu arzusundan bile öne geçmektedir. Diğer bir ifadeyle statü kaygısı, bireylerin verdiği kararların pek çoğunda bu kararları şekillendiren ve etkileyen bir faktördür (Birdal vd., 2019, s. 15). Bireylerin sahip olduğu tüketim alışkanlıklarında değişikliğe yol açabilecek bir kavram olan statü kaygısı, bireylerin tüketim seviyelerini artıran bir itici güç olarak da değerlendirilebilir (Pybus vd., 2022, s.1-2).

Statü kaygısı için bireysel sosyoekonomik durum ve başarıya ilişkin sürekli endişeli olma hali demek de mümkündür. Bireylerin toplum içerisindeki başarı düzeyini yakalayamaması, sosyal açıdan aynı konumda sıkışması ya da mevcut statüsünü kaybetme konusundaki yaşadığı endişe, statü kaygısı yaşandığı anlamına gelmektedir. Bireyler, bunları başaramaması durumunda ise stres, korku ve panik gibi tepkiler yaşamaktadırlar (Sürücü vd., 2022, s. 227). Bireydeki statü arayışı arttıkça, bu arayış hem stres hem de kaygı konusundaki artışı tetiklemektedir. Ayrıca bireylerin sosyal konumlarında yaşadığı belirsizlerdeki artış da doğrudan statü kaygısı yaşama oranlarının artmasına neden olmaktadır (Blake ve Brooks, 2019, s.2).

1.2. Beş Faktörlü Kişilik Kavramı

Konuya ilişkin bir diğer kavram olan beş faktörlü kişiliği tanımlamadan önce kişilik kavramı üzerinde durmakta fayda vardır. Kişilik, ortaya çıktığından beri yapısının karmaşıklığından ötürü tanımlaması oldukça zor bir kavramdır. Karmaşık bir yapıda olması ve tanım yapılması güç bir kavram olmasından dolayı da her zaman araştırmacıların ilgi duyduğu bir konu olmuştur. Genel bir tanımlamayla kişilik kavramı, bireylerin duygusal, zihinsel ve fiziksel özelliklerinin bir bütün olarak yaşam şekli, davranış ve tutumlarla etkileşim ve döngü içerisinde olmasıdır (Çiçek ve Aslan, 2020, s. 138).

Beş faktörlü kişilik kavramı, tanımlaması güç olan kişilik kavramına ait birçok tanımla birleştirilmiş ve hem daha genel hem de daha geçerli bir hale getirmiştir. Kişilik üzerinde yapılan çalışmaların pek çoğunda beş faktörlü kişilik kavramı kullanılmakta ve kişilik

özellikleri beş faktörde toplanmaktadır. Bu faktörler ise dışa dönüklük, yumuşak başlılık, öz denetimlilik, nörotiklik ve deneyime açıklık olarak öne çıkmaktadır (Bercanlı vd., 2019, s. 262). Her faktör, bireylerde çeşitli özelliklerle bağdaşmakta ve ele alınmaktadır (Shafer, 2001, s. 193) Örnek olarak yüksek dışa dönüklüğün liderlikle ilişkilendirildiğini ve yüksek deneyime açıklığın yaratıcılıkla birlikte değerlendirilebileceğini söylemek mümkündür (Malouff vd., 2010, s.124).

1.3. Yapay Zekâ Kavramı

Endüstri 4.0'ın temel bileşenlerinden biri olan yapay zekâ kavramı, daha çok 1960'lı yıllardan itibaren karşımıza çıkan ve bilgisayarların akıllı davranmasına ya da karışık yapıda olan sorunların çözülmesine ilişkin yöntemler içeren bir teknolojidir. Tanım olarak bakıldığında ise yapay zekâ ilk kez 1955 yılında akıllı makineler üretmenin bilimi ve mühendisliği olarak tanımlanmıştır. Yine ilk kez 1955 yılında John McCarthy, bu konu üzerine yapmış olduğu bir çalışmada yapay zekâ kavramını kullanarak bu kavramın kurucusu olarak kabul edilmektedir. (Gacar, 2019, s. 390).

Dijital teknolojiler arasında yapay zekâ, en hızlı gelişim gösteren teknolojilerden biri olmakla birlikte kullanım alanları da her geçen gün artmaktadır. Dünyada bilinirliği yüksek araştırma ve danışmanlık şirketlerinden birisi olan Gartner Anonim Şirketi tarafından 2019 yılında uygulanan CIO Anketi (Bilişim Teknolojileri Yöneticileri Yapay Zekânın Önemine Uyandı) anketine göre yapay zekâ teknolojisini kullanan şirket sayısında son dört yılda %270'lik bir artış görülmesi de bunu desteklemektedir. Her geçen gün kullanım oranı artış gösterirken, yapay zekâ teknolojisine yapılan harcamalar da buna bağlı olarak artış içerisindedir (Zemankova, 2019, s. 148).

Yapay zekânın insan zekâsından ayrılan temel özellikleri ise şunlardır (Yardımcıoğlu ve Şitak, 2020, ss. 344-345; İTÜ, 2020):

Yapay Zekâ ve Kalıcılık: Bireylerde herhangi bir konu veya olayın hafızada kalıcı olma süresi, o konu veya olaya verilen önemle doğru orantılıdır. Fakat bilgisayarlar için bu durum geçerli değildir. Bilgisayar belleğine kaydedilmiş herhangi bir veri, kasıtlı olarak silinmedikçe bellekte kayıtlı olmaya devam edecektir. Bireylerdeki unutma yeteneği, bilgisayarlar için geçerli değildir ve yapay zekâ, süresiz kalıcılık sunmaktadır.

Yapay Zekâ ve Paylaşılabilirlik: Bireyler için insan zekâsı ile edinilmiş tecrübe ve birikimlerin paylaşımı ancak usta-çırak ilişkisiyle mümkündür ve oldukça zaman alıcı bir süreçtir. Süreç sonunda başarılı bir paylaşım olup olmayacağı da belirsizdir. Fakat bilgisayarlar için bu durum farklıdır. Yapay zekâ teknolojisinin sunduğu kopyalama yöntemi sayesinde hem bilgi ve birikimlerin başarılı bir şekilde paylaşımı mümkündür hem de bu paylaşım saniyelere indirgenebilecek kadar hızlı gerçekleşebilmektedir.

Yapay Zekâ ve Geliştirilebilirlik: Bireylerin zekâ seviyesinin yükseltilmesi maliyet yüksekliliği, ihtiyaç duyulan süre ve başarı garantisi gibi konularda pek çok belirsizliğe sahipken, bilgisayarlar için yapay zekânın geliştirilmesi çok daha kolay, hızlı ve düşük maliyetlidir.

Yapay Zekâ ve Tutarlılık: Bireylerin çeşitli olaylar karşısında verdiği tepkiler farklılaşabilmektedir. Öyle ki bazı durumlarda aynı bireyin benzer olaylara verdiği tepki de bile farklılıklar gözlenebilir. Bunlara sebep olarak bireyler arasında var olan zekâ seviyesindeki ayrımlar, düşünce şekillerindeki farklılıklar ve duygusallık gibi birçok farklı faktör sayılabilir. Fakat yapay zekâ temelli bilgi teknolojilerinde bu gibi farklılıklar minimize edilmiş ve çoğu zaman sıfıra indirilmiştir. Buna bağlı olarak yapay zekânın son derece tutarlı tepkiler göstereceğini söylemek mümkündür.

Yapay Zekâ ve Kayıtlılık: İnsandan farklı olarak yapay zekâ, daha önce gerçekleşen olaylara verilen tepkileri kusursuz şekilde kayıt altına alabilmektedir. Bu sayede geçmişte yaşanan bir olayın benzeriyle karşılaşıldığında ani şekilde karar vermek veya tepki göstermek yerine, daha önce alınan kararlar ve verilen tepkiler süratle tek tek değerlendirilerek en doğru karar veya tepkiye ulaşılır.

1.4. Yapay Zekâ Teknolojisi ve Muhasebe Alanındaki Uygulamaları

Yapay zekâ teknolojisinin muhasebe alanındaki kullanımına yönelik yapılan çalışmalar, yaklaşık 35 yıl öncesine dayanmaktadır. Son 10 yıldır hem konuya ilişkin yapılan çalışmalarda hem de muhasebe alanında kullanılan yapay zekâ uygulamalarında artış görülmektedir. Her geçen gün yapay zekâ uygulamalarının muhasebe alanındaki kullanımı yaygınlaşmakta ve kullanım gerekliliği neredeyse kaçınılmaz bir hale gelmektedir.

Manpower Group'un 2016 yılında yaptığı çalışmada yapay zekâ teknolojisini en fazla etkileyeceği alanların başında muhasebe ve finans alanlarının olduğu belirtilmiştir. Yapay zekâyı insan zekâsından ayıran kalıcılık, paylaşılabilirlik, geliştirilebilirlik, tutarlılık ve kayıtlılık gibi özellikler göz önünde bulundurulduğunda, istihdam açısından muhasebe ve finans alanlarının olumsuz etkileneceğini düşünmek mümkündür. Yapay zekâ teknolojisini sunduğu uygulamaların pek çoğu, insan gücünün gerçekleştirdiği işlemleri yürütebilecektir (Gacar, 2019, p. 391).

Muhasebe alanı açısından bakıldığında, yapay zekâ teknolojisiyle birlikte yaşanan bu hızlı dönüşümün en önemli muhataplarından birisi de muhasebe meslek mensuplarıdır. İşletmelerin ve kamu kurumlarının finansal bilgilerini doğru sunması, vergi sisteminin verimli şekilde işlemesi ve yatırımcıların güveninin sağlanması gibi birçok önemli konuda muhasebe meslek mensupları aktif şekilde

rol almaktadır. İlk bakışta yapay zekânın, muhasebe alanındaki insan gücüne olan ihtiyacı azaltacağı, muhasebe meslek mensuplarının yaptığı işlemlerin yapay zekâ tarafından yapılacağı ve muhasebe sektöründe istihdam edilen çalışanların işsizlikle yüzleşeceği gibi hususlarda oldukça büyük bir tehdit olduğu düşünülse de daha genel bir bakış açısıyla bakıldığında yapay zekânın muhasebe çalışanları için sunduğu fırsatları da göz ardı etmemesi gerekmektedir. Bu sebeple muhasebe meslek mensuplarının gelecekte de mesleklerinde başarılı olabilmesi için yapay zekâ konusundaki farkındalıklarını artırması, bu teknolojiye ilişkin teknik becerilerini geliştirmesi ve sürdürdüğü işlemlere yapay zekâ uygulamalarını entegre etmesi gerekmektedir.

Zaman içerisinde yapay zekânın muhasebenin temel fonksiyonlarından özellikle kaydetme, sınıflandırma, özetleme, raporlama ve analiz etme fonksiyonlarını yürütebileceği düşünülmeyle birlikte muhasebe meslek mensuplarının yorumlama fonksiyonu üzerinde kendilerini geliştirmeleri doğru olacaktır. Diğer yandan muhasebe meslek mensuplarının, zaman kaybına ve yüksek maliyete neden olan süreçler için yapay zekâyı süreçlere dahil etmesi yerinde olacakken muhasebe bilgi sisteminden elde edilen tüm bulguları yorumlamak için ise kendi deneyim ve kabiliyetlerini öne çıkarması uygun olacaktır.

Günümüzde yine muhasebe mesleğinin bir parçası olan ve gün geçtikçe daha da önem kazanan bir diğer muhasebe alanı ise denetimdir. Yapay zekâ teknolojisinin denetim alanını da önemli ölçüde etkileyeceği beklenmektedir. Denetim süreci sonunda ortaya çıkan denetim raporundaki finansal bilgilerin ve tabloların doğruluğu, rapor içerisinde yer alan bilgilerin analizi, süreç içerisinde toplanan kanıtların güvenilirliğinin ölçülmesi ve olası risklerin tespiti konularında yapay zekânın kullanılabileceği düşünülmektedir. Süreç yönetimi, zamandan tasarruf, iş yükünün azalması gibi faktörlerde yapay zekânın etkin bir şekilde kullanımı faydalı olacağından pek çok denetim firması, yapay zekâ uygulamalarını süreçlerine entegre etmeye çalışmakta ve yapay zekâ kullanımına olumlu bakmaktadır (Omotoso, 2012, pp. 8490 – 8491).

Bu doğrultuda özellikle dünya genelinde dört büyük denetim firması olarak kabul edilen PwC, Ernst&Young, KPMG ve Deloitte, yapay zekâ uygulamalarına son derece yüksek yatırımlar yapmakta ve bu teknolojiye uyum sağlama noktasında çalışmalar yürütmektedirler (Yücel ve Adiloğlu, 2019, p. 54). Bu çalışmalara ilişkin örnekler ise aşağıdaki gibidir (Yaninen, 2008: 10; Gacar, 2019, p. 391):

PwC Firması: Dünya genelinde gerçekleştirilen yapay zekâ çalışması sonucunda 2030 yılı itibariyle elde edilen gelirin yaklaşık yarısının yapay zekâ uygulamalarıyla birlikte elde edileceği belirtilmiştir.

Ernst&Young Firması: Farklı alanlardan pek çok uzmanın bir araya getirilmesiyle birlikte Hindistan'da kendisine ait yapay zekâ tesisini kurmuştur.

KPMG Firması: 2015 yılından beri yapay zekâ uygulamalarını denetim süreçlerinde aktif şekilde kullanan firma, IBM firmasının ürettiği bilişsel bilgisayarları kullanmaktadır.

Deloitte Firması: Yapay zekânın denetim süreçlerinde kullanımını yaygınlaştırmak ve firma tarafından yürütülen işlerin güvenliğini sağlamak amacıyla Kira Systems isimli bir yapay zekâ uygulaması kullanmaktadır.

Muhasebe mesleğinin geçmişte çok eski dönemlere uzanmakla birlikte yaşanan teknolojik gelişmeler doğrultusunda pek çok kez değişim içerisine girmiş fakat mesleki olarak bu gelişmelere uyumlu şekilde dönüşerek önemli bir meslek olmaya devam etmiştir. Teknolojik olarak yaşanan gelişmeler doğrultusunda muhasebe mesleğinin de işleyiş şekli değişim göstermiştir. Günümüzde de yapay zekâyı bağlı olarak muhasebe mesleği, yeni bir dönüşüm içerisindedir. Bu yeni dönüşümde muhasebe meslek mensupları için en önemli olan nokta, yapay zekâ teknolojisini er ya da geç benimsemek zorunda kalacaklarını görmeleri gerektiğidir (Sarıççek, 2019, p. 1096).

Yapay zekâ teknolojisine sadece olumsuz bir bakış açısıyla yaklaşmak ve beraberinde getirdiği muhtemel tehditlere odaklanmak yerine, olumlu bir bakış açısına sahip olarak sunacağı fırsatları da görmek daha doğru olacaktır. Örneğin yapay zekânın muhasebe süreçlerindeki insan kaynaklı hataları sıfıra indireceğini düşünerek kaygı yaşamak yerine, yapay zekâ algoritmalarının da insanlar tarafından yazıldığı farkında olarak insan kaynaklı hataların minimum düzeye indirilebileceğine ve buna bağlı olarak hem zamandan hem de iş yükünden tasarruf sağlanabileceğine odaklanılabilir (Yardımcıoğlu ve Şitak, 2020, p. 347).

Yapay zekâ uygulamalarının muhasebe alanındaki kullanım oranlarının artmasıyla birlikte muhasebe meslek mensuplarının dönüşüm içerisinde olan mesleklerine uyum sağlaması için atması gereken adımları şu şekilde sıralamak mümkündür (Beder, 2021, p. 166):

Uluslararası muhasebe standartları ve uluslararası finansal raporlama standartları ile uyumlu olacak şekilde yapay zekâ ve dijital teknolojilere yönelik eğitimleri verilmesiyle ortak bir muhasebe dilinin oluşturulması,

Dijital teknolojilerin daha sağlıklı takip edilmesi ve sektöre ilişkin güncel gelişmelerden daha hızlı haberdar olunması için yabancı dil öğreniminin zorunluluk haline getirilmesi,

Teknolojik gelişmelere daha kolay uyum sağlanması için Serbest Muhasebeci Mali Müşavirlik ve Yeminli Mali Müşavirlik sınavlarında bu konulara ilişkin sorulara da yer verilmesi,

Bilgi yönetimi ve müşterilere değer yaratacak hizmetlere yönelik farkındalık oluşturulması,

Sürekli eğitim ve danışmanlık konusuna önem verilerek sürekli şekilde buna ilişkin meslek mensuplarına yönelik bilgilendirmeler yapılması gerekmektedir.

2. Literatür İncelemesi

Yapay zekânın muhasebe alanındaki etkilerine, statü kaygısı kavramına ve beş faktörlü kişilik kavramına ilişkin yapılan çalışmalar Tablo 1’de özet olarak sunulmuştur.

Tablo 1. Çalışmaya İlişkin Literatür Özeti

Yazar/lar	Yıl	Araştırma Yöntemi	Çalışma Özeti
Yapay Zekânın Muhasebe Alanındaki Etkilerine Yönelik Yapılan Çalışmalar			
Gacar	2019	-	Çalışmada yapay zekâ teknolojisinin muhasebe alanında ve muhasebe meslek mensuplarına olan etkileri ele alınmış, Türkiye’de yaratacağı muhtemel fırsat ve tehdit alanları değerlendirilerek önerilerde bulunulmuştur.
Ukpong	2019	Anket	Muhasebe ve denetim alanlarında yapay zekâ teknolojilerinin uygulanabilirliği incelenmiştir. Ayrıca bankaların gelecekte bu çerçevede alacağı roller de ayrıca değerlendirilmiştir.
Zemankova	2019	-	Çalışmada 4 büyük denetim firmasında muhasebe ve denetim alanında kullanılan yapay zekâ teknolojisi esaslı uygulamalar değerlendirilmiştir. Yapılan inceleme sonucunda en yaygın kullanılan uygulamaların bulanık sistemler, sinir ağları ve hibrit sistemler vb. olduğu görülmüştür.
Yardımcıoğlu ve Şitak	2020	Literatür Taraması	Çalışmada, literatür incelenerek muhasebe alanı üzerinde yapay zekânın ne şekilde etkili olduğu ele alınmıştır. Çalışmanın sonucunda Türkiye’nin yapay zekâ teknolojisi konusunda istenilen seviyede olmadığı fakat bu konuda yapılan çalışmaların giderek arttığı görülmüştür. Buna ek olarak pandemi gibi tüm dünyayı etkilemesi muhtemel sorunlar karşısında yapay zekânın muhasebe alanında nasıl kullanılabilceği tartışılarak literatüre katkı sunmaya çalışılmıştır.
Banta vd.	2022	Anket	Yapay zekâ teknolojisinin muhasebe alanında kullanımındaki faydaların ve zorlukların değerlendirildiği çalışmada, Romanya’daki muhasebe uygulayıcılarına yönelik bir anket uygulanmıştır. Elde edilen bulgulara göre de muhasebe uygulayıcılarının konuya ilişkin faydaların ve zorlukların farkında olduğu, gerekli becerilerin bu doğrultuda geliştirilmesi gerektiğini kabullendiği ve gerekli olan bu değişime istekli olduğu sonucuna varılmıştır.
Günaydın ve Uzunoğlu	2022	-	Çalışma kapsamında Endüstri 4.0 temelinde kullanıma sunulan dijital teknolojilerin muhasebe alanındaki uygulamaları ve bu uygulamaların muhasebe mesleğinde ve muhasebe eğitiminde yarattığı etkiler ele alınmıştır. Yapılan incelemeler sonrasında muhasebe müfredatlarının bu yeniliklere karşı güncellenmesi, derslerin dijital teknolojilerle daha uyumlu hale getirilmesi ve birtakım yasal düzenlemelerin de bu doğrultuda geliştirilmesi gerektiği sonuçlarına ulaşılmıştır.
Mert	2022	Literatür Taraması	Bu çalışmada modern teknolojilerin muhasebe eğitimindeki kullanımı incelenmiş ve muhasebe eğitimi müfredatında hangi materyallerin kullanılabilceği gözlemlenmiştir. Çalışmanın devamında ise üç ayrı araştırma sorusu cevaplanmaya çalışılmış ve modern teknolojilerin tam anlamıyla olmasa da kısmen muhasebe eğitimi müfredatına uyarlandığı sonucuna varılmıştır.
Varol	2023	-	Çalışmada dijitalleşmenin ve yapay zekâ uygulamalarının muhasebe ve denetim mesleklerini ne şekilde etkilediği incelenmiş ve bu mesleklerin serbest meslek statüsünden çıkarak mali müşavir ve bilişim personeline doğru evrileceği sonucuna ulaşılmıştır. Buna bağlı olarak muhasebe ve denetim alanlarındaki eğitim müfredatlarının da yeniden şekillenmek durumunda olduğu belirtilmiştir.
Ağdeniz	2024	Betimsel Analiz	Güvenilir bir yapay zekâ denetiminin varlığını ve buna ilişkin iç denetimin sunacağı katkıları değerlendirmenin amaçlandığı çalışmada, iç denetçilerin yapay zekâyı uygulamalarına yönelik oluşturulan iç kontrol denetiminde ve buna ilişkin risk değerlendirmede katkı sunabileceği sonucuna varılmıştır.
Özbek	2024	Anket	Yapay zekâyı ilişkin meydana gelen kaygıların muhasebe meslek mensupları üzerindeki etkisini ortaya koymayı amaçlayan çalışmada, gelecekte muhasebe meslek mensuplarının istihdam edilebilirliği ve yapay zekâ kaygısı arasında anlamlı bir etki olduğuna ulaşılmıştır.

Tablo 1. Devam.

Statü Kaygısı ve Beş Faktörlü Kişilik Kavramlarına Yönelik Yapılan Çalışmalar			
Bacanlı vd.	2009	Direct Oblimin	Beş Faktör kuramından hareketle bunlara uygun sıfat çiftlerinin kullanımıyla bir ölçek geliştirmenin amaçlandığı çalışmada, ortaya çıkarılan ölçeğin üniversite öğrencilerine ilişkin kullanılabilir bir araç olduğu sonucuna ulaşılmıştır. Çalışmada 3848 katılımcının yer aldığı ve 19 örneklem içeren bir meta-analiz kullanılmıştır. Bireyin kişilik özellikleri ve bireyin yakın partneriyle ilişki memnuniyetinin Beş Faktör Modeli esasında incelendiği çalışmada, erkekler ve kadınlar ya da evli bireyler ve evli olmayan bireyler arasında önemli bir farklılık olmadığı sonucuna ulaşılmıştır.
Malouff vd.	2010	Meta Analiz	Çalışmada statü kaygısının rolü, tüketici davranışları özelinde incelenmiştir. Elde edilen bulgulara göre, fiziksel çekicilik, fiziksel yetenek, çocuğun eğitimi ve bazı tüketim kararlarında statü kaygısının diğerlerine göre çok daha baskın olduğu ve ayrıca yaş, eğitim ve gelir düzeyi ile statü kaygısı arasında güçlü bir ilişki olduğu sonucuna varılmıştır.
Birdal vd.	2019	Anket	Çalışmada statü kaygısının daha eşitsiz bağlamlarda daha yüksek tüketim seviyelerinin önemli bir itici gücü olabileceği belirtilmiş ve toplanan kanıtlarla iklim değişikliği ve sürdürülebilirlik üzerindeki etkileri araştırılmıştır. Statü kaygısı kaynaklı tüketimin hane halkı borcu, mekânsal eşitsizlikler, sürdürülemez tüketim döngüleri ve daha uzun işe gidip gelme süreleri ile ilişkili olduğu ve buna bağlı olarak daha yüksek karbon emisyonlarına katkıda bulunduğu tespit edilmiştir.
Pybus vd.	2022	Keşifsel İnceleme	Literatürde statü kaygısını ölçmeye ilişkin tek madde esaslı ve oldukça genel bir ölçeğin kullanılması sebebiyle bu ölçüm aracının güvenilirlik ve geçerlik testlerini yaparak sağlamlaştırmanın amaçlandığı çalışmada, Kuzey Kıbrıs Türk Cumhuriyeti'nde çalışan 323 akademisyenden elde edilen verilere göre statü kaygısı ölçeğinin geçerli ve güvenilir bir ölçüm aracı olduğu sonucuna ulaşılmıştır.
Sürücü vd.	2022	Anket	

Yapılan literatür incelemesinde yapay zekânın muhasebeye olan etkilerine ilişkin yapılmış 10 çalışmaya ve buna ek olarak statü kaygısı ve beş faktörlü kişilik kavramlarına ilişkin yapılmış 5 çalışmaya yer verilmiştir. Tablo 1'de konuya ilişkin özet olarak sunulan çalışmalar kronolojik olarak sıralanırken, aynı zamanda çalışmalarda kullanılan yöntem ve yazar bilgisine de ayrıca yer verilmiştir.

3. Araştırma Metodolojisi


Bu araştırmada muhasebe meslek mensuplarının kişilik özelliklerinin yapay zekâ tutumlarına etkileri ve statü kaygısının bu iki faktör arasındaki ilişkideki rolü incelenmiştir. Bu doğrultuda Eskişehir ilinde yaşayan muhasebe meslek mensuplarına yapay zekâyâ tutum, beş faktörlü kişilik özellikleri ve statü kaygısına yönelik üç ayrı ölçeği içeren bir anket uygulanmıştır. Uygulamada ölçek olarak yer alan kavramlardan kişilik özellikleri Rammstedt ve John (2007) tarafından geliştirilen ve Horzum vd., (2017) tarafından Türk kültürüne uyarlanan 10 maddeden oluşan beş temel kişilik özellikleri ölçeği aracılığıyla ölçülmüştür. Statü kaygısı ise Day ve Fiske (2016) tarafından geliştirilen ve Sürücü vd., (2022) tarafından Türk kültürüne uyarlanan 5 maddeden oluşan statü kaygısı ölçeğiyle ölçülmüştür. Yapay zekâ tutumu ise Schepman ve Rodway (2020, 2022) tarafından geliştirilen ve Kaya vd., (2024) tarafından Türk kültürüne uyarlanan 20 maddelik genel yapay zekâ tutum ölçeği aracılığıyla ölçülmüştür.

Kolayda örnekleme yöntemi kullanılarak uygulanan anket sonucunda toplam 163 adet kullanılabilir anket elde edilmiştir. Elde edilen anketler Smart-PLS 3.0 YEM (Yapısal Eşitlik Modeli) yöntemi kullanılarak analiz edilmiştir. Analiz kapsamında sağlıklı ve güvenilir bulgular elde etmek için birtakım aşamalar uygulanmıştır. Öncelikle PLS-YEM analiz kısıtları belirtilmiş ve devamında faktör analizi ve güvenilirlik ve geçerlilik testleri yapılmıştır. Uygulanan son aşamalarda ise HTMT ve Fornell Larcker Kriteri test sonuçları verilmiş ve ardından varyans artırıcı faktör (VIF) değeri ve model uyum endeksleri tablolaştırılarak analiz tamamlanmıştır.

3.1. Araştırmanın Metodu

Analiz metodu olarak Smart-PLS 3.0 YEM (Yapısal Eşitlik Modeli) kullanılmıştır. Bu modelin kullanılma sebebi ise karmaşık modellerle analiz yapılabilme imkânı sunmasıdır. Özellikle diğer yapısal eşitlik modellerinde olmayan alt faktörler arasındaki formatif ve reflektif ilişkiler ağını mükemmel bir şekilde çözümlenebilmektedir (Hair vd., 2017). Bu kapsamda bu çalışmada yer alan araştırma modeli Şekil 1'de görülebilir.

Şekil 1. Araştırma Modeli



Şekil 1'e bakıldığında beş temel kişilik özelliklerinin yapay zekâ tutumuna etkisinde statü kaygısının ılımlayıcı rolünün olup olmadığı ve beş temel kişilik faktörünün muhasebe meslek mensuplarının yapay zekâ tutumlarına etkileri araştırılmıştır. Bu modelde genel yapay zekâ tutum ölçeği de pozitif ve negatif yapay zekâ tutum ölçekleri olarak iki alt faktöre ayrılmıştır. Kurgulanan bu modelde pek çok sayıda hipotez oluşturulacağı için tüm hipotezleri tek tek yazmak yerine hangi faktörler arasındaki ilişkinin olduğu yapısal eşitlik modeli çerçevesinde raporlanmıştır.

3.2. Araştırmanın Evreni, Örnekleme ve Veri Toplama

Bu araştırma Eskişehir ilinde görev yapan 1.089 muhasebe meslek mensubu üzerine yapılmıştır. Verilerin bir kısmı yüz yüze kalan diğer kısmı ise online anket yöntemiyle toplanmıştır. Anketler kolayda örnekleme yöntemi kullanılarak toplanmıştır. Anket sonucunda toplam 163 adet kullanılabilir anket elde edilmiştir. Bu sayı 0.05 ve 0.10 örnekleme hata payına göre toplanması gereken minimum veri sayısının üzerinde gerçekleşmiştir (Büyüköztürk vd., 2014, p. 95; Lorcu, 2015, p. 18). Dolayısıyla örnekleminiz anakütleyi temsil edebilecek düzeyde gerçekleşmiştir.

3.3. Verilerin Analizi

Bu kısımda ise çalışma kapsamında elde edilen verilerin analizi yer almaktadır. Analiz sürecinde hangi aşamalardan geçildiği ve her aşamadan elde edilen veriler değerlendirilmiştir.

PLS-YEM Analizi Kısıtları

PLS-YEM diğer yapısal eşitlik modellerinden farklı olarak normallik dağılımı ve minimum veri sayısı gibi koşullar aramamaktadır. Bunun yanında PLS-YEM'in varyans temelli bir model olması da kendisini diğer modellerden ayırmaktadır (Hair vd., 2017). Bununla birlikte diğer yapısal eşitlik modellerinde olduğu gibi model kurgulanmadan önce bazı ön koşulların raporlanması gerekmektedir. Bunlar faktör yük tablosu, güvenilirlik test sonuçları, birleşme ve ayrışma geçerliliği test sonuçları, VIF değerleri ve model uyum endeks sonuçları olarak sıralanabilir. Dolayısıyla yapısal model sunulmadan önce bu ön koşulların sağlanıp sağlanmadığına ilişkin raporlamaların yapılması gerekmektedir.

PLS-YEM Faktör Analizi

Faktör analizi PLS-YEM modelinin ilk analiz birimidir. Bu noktada faktör yükleri her bir ölçeğin alt faktörlerinin ölçeği ne kadar açıkladığını gösterir. Alanyazın incelendiğinde her bir alt faktörün faktör yükünün en az 0,60 olması gerektiği ifade edilmektedir (Hair vd., 2017). Eğer ki 0,60'ın altında bir faktör yükü mevcutsa bu faktörün modelden çıkarılarak analizin tekrardan gerçekleştirilmesi gerekmektedir. Bu çalışmada yer alan ölçeklere ilişkin faktör yükleri Tablo 2'de gösterilmiştir.

Tablo 2. Faktör Yükleri

	Deneyime Açıklık	Dışa Dönüklük	Negatif Yapay Zekâ Algısı	Nörotiklik	Pozitif Yapay Zekâ Algısı	Statü Kaygısı	Yumuşak başlılık	Öz Denetimlilik
Kisilik1		0.984						
Kisilik2		0.750						
Kisilik3							0.736	
Kisilik4							0.789	
Kisilik5								0.997
Kisilik6								0.782
Kisilik7				0.722				
Kisilik8				0.944				
Kisilik9	1.000							
Kisilik10	0.710							
StatuKaygisi1						0.765		
StatuKaygisi2						0.871		
StatuKaygisi3						0.869		
StatuKaygisi4						0.912		
StatuKaygisi5						0.850		
YapayZeka1					0.706			
YapayZeka2					0.729			
YapayZeka3					0.774			
YapayZeka4					0.765			
YapayZeka5					0.805			
YapayZeka6					0.795			
YapayZeka7					0.732			
YapayZeka8					0.780			
YapayZeka9					0.724			
YapayZeka10					0.784			
YapayZeka11					0.771			
YapayZeka12					0.728			
YapayZeka13			0.784					
YapayZeka14			0.752					
YapayZeka15			0.838					
YapayZeka16			0.824					
YapayZeka17			0.829					
YapayZeka18			0.734					
YapayZeka19			0.784					
YapayZeka20			0.773					

Tablo 2 incelendiğinde 0,60'ın altında herhangi bir faktör yükünün olmadığı görülmektedir. Dolayısıyla model üzerinde herhangi bir çıkarma işlemi yapmaya gerek yoktur.

Güvenilirlik ve Geçerlilik Testleri

Faktör analizinden sonra raporlanması gereken bir diğer durum modelin güvenilirlik ve geçerliliğinin test edilmesidir. Bu kapsamda Tablo 3'te modele ilişkin güvenilirlik test sonuçları yer almaktadır.

Tablo 3. Güvenilirlik Test Sonuçları

	Cronbach's alpha	Rho_a	Rho_c	Average variance extracted (ave)
Deneyime açıklık	0.734	0.765	0.795	0.500
Dışa dönüklük	0.707	0.727	0.738	0.610
Negatif yapay zekâ algısı	0.867	0.890	0.894	0.517
Nörotiklik	0.716	0.725	0.715	0.598
Pozitif yapay zekâ algısı	0.910	0.912	0.921	0.594
Statü kaygısı	0.907	0.909	0.931	0.731
Yumuşak başlılık	0.775	0.776	0.710	0.540
Öz denetimlilik	0.794	0.743	0.788	0.514

Tablo 3 incelendiğinde 4 farklı güvenilirlik test sonucu görülmektedir. Cronbach Alpha, rho_A ve rho_C güvenilirlik test sonuçlarının minimum 0,70, AVE değerinin ise minimum 0,50 olması beklenmektedir (Ringle vd., 2023). Tablo tekrar incelendiğinde her bir değişkenin güvenilirlik skorlarının beklenen aralıklarda olduğu görülmektedir. Bir başka ifadeyle ölçeklerin güvenilirlik açısından bir probleminin olmadığı söylenebilir.

PLS-YEM de güvenilirlik testinden sonra raporlanması gereken bir başka test de geçerlilik testidir. Model geçerliliğinin sağlanması için birleşme ve ayrışma geçerlilik tablolarının da raporlanması gerekmektedir. Birleşme geçerliliği için HTMT (Heterotrait-monotrait) tablosu ayrışma geçerliliği için ise Fornell Larcker kriteri rasyosu raporlanmalıdır. Bu çerçevede HTMT rasyosuna ilişkin değerler Tablo 4'te verilmiştir.

Tablo 4. HTMT Test Sonuçları

	Deneyime Açıklık	Dışa Dönüklük	Negatif Yapay Zekâ Algısı	Nörotiklik	Pozitif Yapay Zekâ Algısı	Statü Kaygısı	Yumuşak başlılık	Öz Denetimlilik
Deneyime Açıklık	0.103							
Dışa Dönüklük	0.846	0.360						
Negatif Yapay Zekâ Algısı	0.546	0.866	0.364					
Nörotiklik	0.359	0.165	0.220	0.938				
Pozitif Yapay Zekâ Algısı	0.661	0.497	0.608	0.973	0.207			
Statü Kaygısı	0.440	0.094	0.405	0.609	0.479	0.426		
Yumuşak başlılık	0.506	0.488	0.616	0.344	0.319	0.782	0.154	
Öz Denetimlilik								

Tablo 4'te yer alan değerler HTMT değerleridir. Birleşme geçerliliğinin varlığından söz edebilmek için bu değerlerin 0.90'ın altında olması beklenmektedir (Ringle vd., 2023). Tablo tekrar incelendiğinde 0.90'ın üstünde herhangi bir değer olmadığı görülmektedir. Bir diğer ifadeyle modelin birleşme geçerliliğini sağladığı söylenebilir.

Bir diğer geçerlilik değeri ise Fornell Larcker kriteri değeridir. Tablo 5'te ilgili test kriteri sonuçları verilmiştir.

Tablo 5. Fornell Larcker Kriteri Test Sonuçları

	Deneyime Açıklık	Dışa Dönüklük	Negatif Yapay Zekâ Algısı	Nörotiklik	Pozitif Yapay Zekâ Algısı	Statü Kaygısı	Yumuşak başlılık	Öz Denetimlilik
Deneyime Açıklık	0.707							
Dışa Dönüklük	0.108	0.781						
Negatif Yapay Zekâ Algısı	0.073	0.281	0.719					
Nörotiklik	0.255	0.203	0.104	0.705				
Pozitif Yapay Zekâ Algısı	0.118	0.014	0.203	0.195	0.703			
Statü Kaygısı	0.122	0.440	0.574	0.247	0.212	0.855		
Yumuşak başlılık	0.216	0.243	0.130	0.341	0.012	0.214	0.663	
Öz Denetimlilik	0.212	0.444	0.287	0.192	0.022	0.434	0.123	0.717

Ayrışma geçerliliğini test eden Fornell Larcker kriteri test sonuçları Tablo 5'te görülmektedir. Tabloya göre ayrışma geçerliliğinin sağlanabilmesi için her bir değişkenin kendisine ait çapraz değerlerinin (sütun ve satır) en yüksek olması gerekir. (Richter vd., 2022). Tablo incelendiğinde her bir değişkene ait çapraz değerlerin kendi satır ve sütunlarında en yüksek değere sahip olduğu görülmektedir. Bu sonuç modelin ayrışma geçerliliğini sağlandığını ifade etmektedir.

VIF (Variance Increasing Factor) Değeri

Modele ilişkin geçerlilik ve güvenilirlik testleri yapıldıktan sonra göz önüne alınması gereken bir diğer durum da değişkenlerin birbirleriyle çoklu doğrusallık ilişkisinin olup olmadığıdır. Çoklu doğrusallık PLS-YEM de varyans artırıcı faktör tablosuyla (VIF) anlaşılmaktadır. VIF değerlerinin en fazla kaç olması gerektiğine yönelik birçok farklı görüş olsa da maksimum 5 olması ideal olarak da 3 ve altında olması gerektiği belirtilmektedir (Hair vd., 2017, p. 143). VIF değerleri Tablo 6'da görülmektedir.

Tablo 6. VIF Değerleri Tablosu

	VIF		VIF		VIF
Kisilik1	1.130	YapayZeka1	2.208	YapayZeka16	1.950
Kisilik2	1.130	YapayZeka2	2.350	YapayZeka17	2.487
Kisilik3	1.015	YapayZeka3	2.130	YapayZeka18	1.903
Kisilik4	1.015	YapayZeka4	1.889	YapayZeka19	1.556
Kisilik5	1.012	YapayZeka5	2.423	YapayZeka20	1.887
Kisilik6	1.012	YapayZeka6	2.306		
Kisilik7	1.000	YapayZeka7	2.345		
Kisilik8	1.000	YapayZeka8	1.841		
Kisilik9	1.000	YapayZeka9	1.826		
Kisilik10	1.000	YapayZeka10	2.195		
StatuKaygisi1	1.837	YapayZeka11	2.281		
StatuKaygisi2	2.976	YapayZeka12	1.549		
StatuKaygisi3	3.152	YapayZeka13	1.682		
StatuKaygisi4	3.073	YapayZeka14	1.620		
StatuKaygisi5	2.633	YapayZeka15	2.002		

Tablo 6 incelendiğinde VIF değerlerinin hepsinin 3 ve altında olduğu görülmektedir. Bu durum değişkenlerin birbirleriyle çoklu doğrusallık problem olmadığını göstermektedir.

Model Uyum Endeksleri

Yapısal eşitlik modeli raporlanması yapılmadan önceki son ön koşul model uyum endekslerinin raporlanmasıdır. Model uyumuna ilişkin literatürde çok fazla değer olduğu görülmektedir. PLS-YEM de ise en çok dikkat edilmesi gereken iki test sonucu SRMR ve NFI değerleridir. Literatür incelendiğinde model uyum endeksinin sağlanabilmesi için SRMR'nin ideal olarak 0.09'un altında olması (Hu ve Bentler, 1998) NFI değerinin ise 0.90'dan büyük olması gerekmektedir (Henseler vd., 2016). Bunun yanında d-ULS ve d_G değerleri skorlarının tahmin edilmiş model sonuçlarının doymuş model sonuçlarının çıkarılmasından sonra elde edilecek sonuçların 0.05'ten küçük olması gerekmektedir (Henseler vd., 2014). Tablo 7'de model uyum endeksleri raporlanmıştır.

Tablo 7. Model Uyum Endeksleri

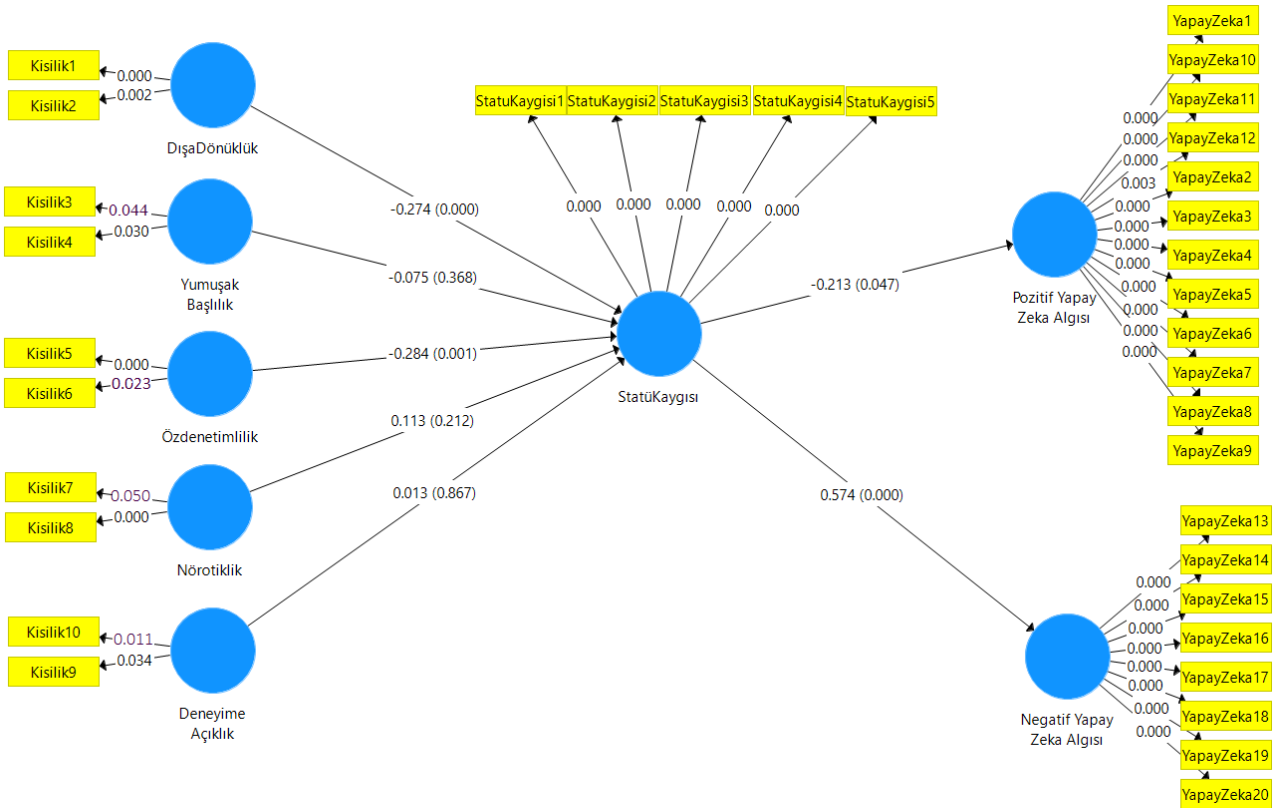
	Saturated Model	Estimated Model
SRMR	0.079	0.076
d_ULS	7.536	7.553
d_G	1.673	1.708
Chi-Square	1.350.722	1.372.967
NFI	0.989	0.982

Tablo incelendiğinde tüm değerlerin ifade edilen sınırlar arasında kaldığı görülmektedir. Bir başka ifadeyle kurgulanan modelin uyum endeksleri açısından uygun olduğu söylenebilir.

Yol Analizi

Tüm ön koşullar yerine getirildikten sonra artık yapısal eşitlik modelinin kurgulanması ve raporlanmasının önünde herhangi bir kısıt kalmamıştır. Şekil 2 de kurgulanan PLS-YEM yapısal eşitlik modeli görülmektedir.

Şekil 2. PLS-YEM Yapısal Eşitlik Modeli



Şekil 2'ye bakıldığında kurgulanan modelde beş temel kişilik özelleri, statü kaygısı ve pozitif ve negatif yapay zekâ tutum algılarının birbirleriyle ilişkisinin incelendiği görülmektedir. Şekil de parantez içerisinde verilen değerler p değerlerini parantez dışında kalan değerler de yol katsayısını ifade etmektedir. Yol katsayıları ilişkinin yönü ve derecesini ifade ederken p değerli ilişkinin anlamlı olup olmadığını göstermektedir. Bununla birlikte Şekil 2'de yalnızca doğrusal ilişkiler yer almakta olup dolaylı ilişkiler ve statü kaygısının ılımlaştırıcı rolüne yönelik analizler Tablo 8 ve Tablo 9'da yer almaktadır. Doğrudan ve dolaylı ilişkilerin raporlandığı istatistikler Tablo 8'de şu şekilde raporlanmıştır:

Tablo 8. Doğrudan ve Dolaylı İlişkiler Tablosu

	Original Sample (O)	Sample Mean (M)	Standard Deviation (STDEV)	T Statistics (O/STDEV)	P Values
Deneyime Açıklık -> Statü Kaygısı	0.013	-0.003	0.078	0.168	0.867
Dışa Dönüklük -> Statü Kaygısı	-0.274	-0.294	0.075	3.643	0.000
Nörotiklik -> Statü Kaygısı	0.113	0.109	0.091	1.248	0.212
Statü Kaygısı -> Negatif Yapay Zekâ Algısı	0.574	0.582	0.051	11.304	0.000
Statü Kaygısı -> Pozitif Yapay Zekâ Algısı	-0.213	-0.241	0.107	1.991	0.047
Yumuşak_Başlılık -> Statü Kaygısı	-0.075	-0.082	0.083	0.900	0.368
Öz Denetimlilik -> Statü Kaygısı	-0.284	-0.271	0.088	3.244	0.001
Dışa Dönüklük -> Negatif Yapay Zekâ Algısı	-0.157	-0.171	0.047	3.352	0.001
Öz Denetimlilik -> Negatif Yapay Zekâ Algısı	-0.163	-0.158	0.054	3.026	0.003

Tablo 8 irdelendiğinde dışa dönüklülüğün statü kaygısı ve negatif yapay zekâ algısıyla, statü kaygısının hem pozitif hem de negatif yapay zekâ tutum algısıyla, öz denetimliliğin ise hem statü kaygısı hem de negatif yapay zekâ tutum algısıyla anlamlı bir ilişkinin olduğu görülmektedir. Tablo 9'da ise statü kaygısının ılımlaştırıcı rolü irdelenmiştir.

Tablo 9. Statü Kaygısının İlimlaştırıcı Rolü

	Original Sample (O)	Sample Mean (M)	Standard Deviation (STDEV)	T Statistics (O/STDEV)	P Values
Deneyime Açıklık -> Statü Kaygısı -> Negatif Yapay Zekâ Algısı	0.008	-0.002	0.045	0.166	0.868
Dışa Dönüklük -> Statü Kaygısı -> Negatif Yapay Zekâ Algısı	-0.157	-0.171	0.047	3.352	0.001
Nörotiklik -> Statü Kaygısı -> Negatif Yapay Zekâ Algısı	0.065	0.063	0.053	1.228	0.220
Yumuşak_Başlılık -> Statü Kaygısı -> Negatif Yapay Zekâ Algısı	-0.043	-0.049	0.050	0.867	0.386
Öz Denetimlilik -> Statü Kaygısı -> Negatif Yapay Zekâ Algısı	-0.163	-0.158	0.054	3.026	0.003
Deneyime Açıklık -> Statü Kaygısı -> Pozitif Yapay Zekâ Algısı	-0.003	0.001	0.020	0.136	0.892
Dışa Dönüklük -> Statü Kaygısı -> Pozitif Yapay Zekâ Algısı	0.058	0.070	0.037	1.590	0.113
Nörotiklik -> Statü Kaygısı -> Pozitif Yapay Zekâ Algısı	-0.024	-0.024	0.026	0.914	0.361
Yumuşak_Başlılık -> Statü Kaygısı -> Pozitif Yapay Zekâ Algısı	0.016	0.021	0.024	0.664	0.507
Öz Denetimlilik -> Statü Kaygısı -> Pozitif Yapay Zekâ Algısı	0.060	0.066	0.037	1.619	0.106

Tablo 9 incelendiğinde de dışa dönüklülüğünün negatif yapay zekâ tutum algısını tahmin etmede statü kaygısının ılımlaştırıcı rol oynadığı ve benzer şekilde öz denetimliliğin negatif yapay zekâ tutum algısını tahmin etmede statü kaygısının ılımlaştırıcı rol oynadığı görülmektedir. Bu ilişkilerin yönü ve derecesi ise bulgular kısmında tartışılmıştır.

3.4. Araştırmanın Bulguları

Analiz sonucunda dışa dönüklük ve statü kaygısı arasında anlamlı bir ilişki olduğu görülürken bu ilişkinin yönünü anlayabilmek için yol katsayı değerine bakılmalıdır. Bu ilişkide yol katsayı değerinin -0.274 olduğu görülmektedir. Bu sonuç iki değişken arasında negatif ilişki olduğunu göstermektedir. Bir diğer ifadeyle muhasebe meslek mensuplarının dışa dönüklük düzeyleri arttıkça yaşadıkları statü kaygısının azaldığı ya da tam tersi olarak dışa dönüklük düzeyleri azaldıkça statü kaygılarının arttığı sonucuna ulaşılmıştır.

Dışa dönüklükle anlamlı bir ilişki olan bir diğer değişken ise negatif yapay zekâ algısıdır. Bu iki değişken arasındaki yol katsayısı da -0.157 olarak ölçülmüştür. Bu değere bakarak kişilerin dışa dönüklük düzeylerinin arttıkça negatif yapay zekâ tutum algılarının azaldığı ya da tam tersi olarak dışa dönüklük düzeyleri azaldıkça negatif yapay zekâ tutum algılarının azaldığı sonucunu varılmıştır.

Bulgular tekrar incelendiğinde statü kaygısı ile hem pozitif yapay zekâ tutum algısı hem de negatif yapay zekâ tutum algısı arasında anlamlı bir ilişki olduğu görülmektedir. İlişkilerin yönlerini incelemek içinse yine yol katsayılarına bakmak gerekmektedir. Statü kaygısıyla pozitif yapay zekâ tutum algısı arasındaki yol katsayısının -0.213 olduğu görülmektedir. Bu durum muhasebe meslek mensuplarının statü kaygıları arttıkça pozitif yapay zekâ tutum algılarının azaldığını göstermektedir ya da tam tersi olarak statü

kaygıları azaldıkça yapay zekâ tutum algılarının arttığını ifade etmektedir. Statü kaygısıyla negatif yapay zekâ algısı arasındaki ilişkinin yönü incelendiğinde ise yol katsayısının 0.574 gibi çok yüksek bir pozitif ilişki olduğu görülmektedir. Bu durum muhasebe meslek mensuplarının statü kaygılarının artmasının negatif yapay zekâ tutum algısını da arttırdığını veya statü kaygısının azalmasının negatif yapay zekâ tutum algısını da azalttığı sonucunu ifade etmektedir.

Kişilik özelliklerinden bir diğeri olan öz denetimlilik ile hem statü kaygısı hem de negatif yapay zekâ tutum algısı arasında da anlamlı bir ilişki olduğu Tablo 8’de görülmektedir. Öz denetimlilik ile statü kaygısı arasındaki ilişkinin katsayısı -0.284 olarak bulunmuştur. Bu sonuç muhasebe meslek mensuplarının öz denetimlilik düzeylerinin artmasıyla statü kaygısı arasında negatif bir ilişki olduğunu göstermektedir. Bir diğere ifadeyle öz denetimlilik düzeyi arttıkça statü kaygısının azaldığı ya da öz denetimlilik azaldıkça da statü kaygısının arttığı sonucuna ulaşılmıştır. Yine aynı tabloda öz denetimlilik ile negatif yapay zekâ tutum algısı arasındaki yol katsayısının -0.163 olduğu görülmektedir. Bu durum muhasebe meslek mensuplarının öz denetimlilik düzeylerinin arttıkça negatif yapay zekâ tutumlarının algılarının azaldığı ya da tam tersi olarak özdenetim düzeylerinin azaldıkça negatif yapay zekâ tutum algılarının arttığı sonucunu vermektedir.

Doğrudan ilişkilerin raporlandığı Tablo 8’den sonra ılımlaştırıcı etkilerin ölçüldüğü tablo 9’daki anlamlı olan ilişkilerin raporlanma sürecine geçilebilir. Tablo 9 incelendiğinde iki farklı anlamlı ılımlaştırıcı etki olduğu görülmektedir. İlk olarak dışa dönüklüğün negatif yapay zekâ tutum algısını tahmin etmede statü kaygısının ılımlaştırıcı rol oynadığı görülmektedir. Bu ilişkideki yol katsayısının -0.157 olduğu görülmektedir. Diğere ılımlaştırıcı etkiye bakıldığında öz denetimliliğin negatif yapay zekâ algısını tahmin etmede statü kaygısının ılımlaştırıcı rol oynadığı görülmektedir. Bu ilişkideki yol katsayısı ise -0.163 olarak görülmüştür.

Sonuç

İlk kez 1955 yılında kavramsal olarak kullanılan ve 1960’lı yıllardan itibaren sıklıkla karşımıza çıkan ve günümüzde ise pek çok alanda olduğu gibi muhasebe alanında da kullanım oranı artmış olan yapay zekâ teknolojisi, en hızlı değişim gösteren teknolojilerden biri olmakla birlikte muhasebe alanındaki uygulamaları da sürekli artış göstermektedir. Yapay zekâ teknolojisi, muhasebe meslek mensuplarını doğrudan etkileyen ve etkilemeye devam edecek bir teknoloji olarak kabul edilirken muhasebe meslek mensuplarının sahip olduğu yeteneklerde de yenilik ve dönüşüm gerektiren bir teknolojidir. Özellikle kalıcılık, paylaşılabilirlik, geliştirilebilirlik, tutarlılık ve kayıtlılık gibi temel özelliklerde insan zekâsından ayrılan yapay zekâ, muhasebe meslek mensupları tarafından iş süreçlerine doğru entegre edilmesi ve olumlu yönde algılanması halinde iş yükü, zaman, maliyet, yorum yapabilme yeteneği gibi faktörler üzerinde iyileştirici bir etkiye sahip olacaktır.

Yapay zekânın muhasebe sektöründeki uygulamalarının kullanımındaki artış ve beraberinde getirdiği pek çok yenilik birlikte düşünüldüğünde, muhasebe meslek mensuplarının bu teknolojiye olan tutumu son derece önemliken bu tutumun kişilik özellikleriyle değerlendirilmesi ve mevcut statülerini koruyup koruyamayacak olmalarıyla ilişkilendirilmesi de mümkündür. Bu bilgiler doğrultusunda çalışma kapsamında Eskişehir ilinde mesleğini icra eden muhasebe meslek mensuplarına yapay zekâ tutumu, statü kaygısı ve beş faktörlü kişilik ölççeklerini bir arada içeren bir anket uygulanmış ve elde edilen yanıtlar Smart-PLS 3.0 YEM yöntemiyle analiz edilmiştir. Analize ilişkin oluşturulan araştırma modelinde beş temel kişilik özelliği, negatif ve pozitif olmak üzere yapay zekâ algısı ve her iki faktör arasında ılımlaştırıcı bir role sahip olmak üzere statü kaygısı yer almaktadır. Araştırma modelinin oluşturulmasını takiben PLS-YEM analizi kısıtları, PLS-YEM faktör analizi, güvenilirlik ve geçerlilik testleri, VIF değeri, model uyum endeksleri ve yol analizi aşamaları uygulanmış, arından veri setine ilişkin elde edilen bulgular değerlendirilmiştir.

Muhasebe meslek mensuplarının dışa dönüklükleri arttıkça, yaşadıkları statü kaygısında azalma tespit edilmiştir. Bu durumun daha doğru değerlendirilmesi için dışa dönüklük ve yapay zekâ tutumu arasındaki ilişkiye de bakmak gerekir. Muhasebe meslek mensuplarının dışa dönüklük ve yapay zekâyâ tutum algıları arasındaki ilişki, yapılan analiz sonucunda pozitif olarak görülmüştür. Buna göre muhasebe meslek mensuplarının dışa dönüklük düzeyleri arttıkça yapay zekâyâ ilgi tutumunda da olumlu bir artış gözlemlendiği ve dolayısıyla statü kaygısı gütmeye de düşüş yaşadıklarını söylemek mümkündür. Yapay zekâ teknolojisi konusunda kendini geliştirmeyen ve bu teknolojiyi iş modellerine dahil etmeyen muhasebe meslek mensuplarının statü kaygısının arttığı ve bununla birlikte negatif yapay zekâ tutum algısının da arttığı görülmüştür. Gelecekte mevcut pozisyonunu ve statüsünü korumak isteyen muhasebe meslek mensuplarının, mutlaka kendilerini geliştirmesi ve sahip olduğu yeteneklere yeni yetenekler eklemesi gerekmektedir. Muhasebe meslek mensupları, yapay zekâ temelli uygulamalarda kendisini geliştirdikçe, bu konuda farkındalıklarını arttırdıkça ve bu teknolojiyle uyumlu bir şekilde çalışmak zorunda olduklarını gördükçe öz denetimlilikleri açısından da daha iyiye gidecek ve buna bağlı olarak yaşadıkları statü kaygısında da düşüş olacaktır (Özbek, 2024).

Çalışmanın sonucunda elde edilen tüm bulgular birlikte değerlendirildiğinde, muhasebe meslek mensuplarının yapay zekâ esaslı statü kaygısı yaşamaması için özellikle dışa dönüklük ve öz denetimlilik kişilik özelliklerinde, olumlu anlamda bir artış içerisinde olması gerekmektedir. Muhasebe meslek mensupları için yapay zekâ teknolojisine yönelik korku ve panik yaşamayı yerine, bu teknolojinin kendilerine sunacağı fırsatlara odaklanmasının gelecekte de mesleklerini başarıyla sürdürebilmeleri için önemli olduğunu vurgulamak doğru olacaktır. Buna ek olarak Günaydın ve Uzunoğlu (2022) ve Mert (2022) yapmış

oldukları çalışmada yapay zekâ teknolojisinin muhasebe eğitimindeki yerini incelemiş ve muhasebe eğitimindeki müfredatların kısmen güncel olsa da yetersiz kaldığını vurgulamışlardır. Geleceğin muhasebe meslek mensuplarını, denetçilerini ve finansal danışmanlarını yetiştiren ön lisans, lisans ve lisansüstü programlarına sahip olan üniversitelerin, özellikle muhasebe sektöründe aktif olarak çalışan ve mesleğe ilişkin dijital uygulamalar konusunda yetkin olan kişilerden görüşler alarak dersleri ve müfredatı güncellemesi gerekmektedir.

Konuya ilişkin yapılan diğer çalışmalarda özellikle denetim alanına ilişkin yapay zekâ uygulamalarının sıklıkla kullanıldığı görülürken, bireysel olarak muhasebe meslek mensuplarının da kendilerini yetiştirebilmesi ve yeni beceriler kazanabilmesi için başta kendi illerindeki muhasebe odaları olmak üzere Türkiye Serbest Muhasebeci Mali Müşavirler ve Yeminli Mali Müşavirler Odaları Birliği (TÜRMOB), Temel Eğitim ve Staj Merkezi (TESMER), Kamu Gözetimi, Muhasebe ve Denetim Standartları Kurumu (KGK) ve TÜRMOB Sürekli Mesleki Geliştirme Eğitimi Merkezi (SÜRGEN) gibi kurum ve kuruluşlarda sıklıkla yapay zekâ kullanımı ve gelişimiyle ilgili eğitimler düzenlenmelidir (Ukpong, 2019; Zemankova, 2019; Varol, 2023). Yapay zekâ uygulamaları başta olmak üzere bilgi teknolojileri konusunda muhasebe meslek mensuplarının mutlaka aksiyon alması ve hem bireysel hem de meslek odaları aracılığıyla kendilerini yenilemesi gerekmektedir. Muhasebenin temel fonksiyonları yapay zekâ tarafından kolaylıkla gerçekleştirilebileceğinden, meslek mensuplarının daha çok yorumlama ve müşavirlik yapabilmeye odaklanması yerinde olacaktır. Tekbaş (2019) tarafından yapılan çalışmada ortaya çıkarılan Mali Mühendislik kavramı pek çok boyutuyla ele alınmalı ve buna yönelik yeni iş modelleri kurulmalıdır. Muhasebe meslek mensuplarının geleceği yakalaması, mevcut statüsünü kaybetme kaygısı yaşamaması, mesleğini ilerleyen dönemlerde de başarıyla sürdürmesi için yapay zekâ teknolojisine olan bakış açılarını olumlu yönde değiştirmesi ve hızlı bir şekilde donanımlarını iyileştirmek için adım atması önerilmektedir.



This research article has been licensed with Creative Commons Attribution - Non-Commercial 4.0 International License. Bu araştırma makalesi, Creative Commons Atıf - Gayri Ticari 4.0 Uluslararası Lisansı ile lisanslanmıştır.

Yazar Katkıları

Yazarlar çalışmaya katkı oranlarını bu şekilde beyan etmişlerdir: Fatih Bıyıklı: %34, Tunga Bozdoğan: %33, Ömer Orbay Çetin: %33

Teşekkür Beyanı

Yazarlar teşekkür beyanında bulunmamışlardır.

Destek Beyanı

Yazarlar destek beyanında bulunmamışlardır.

Çıkar Çatışması

Yazarlar herhangi bir çıkar çatışması beyan etmemişlerdir.

Etik Beyanı

Yazarlar çalışma için Afyon Kocatepe Üniversitesi'nden 20.03.2024 tarih ve 259306 sayılı Etik Kurul Onayı alındığını beyan etmişlerdir.

Sorumlu Özel Sayı Editörleri

Doç. Dr. Beyza Mina Ordu-Akkaya, Ankara Sosyal Bilimler Üniversitesi

Doç. Dr. Görkem Ataman, Yaşar Üniversitesi

Arş. Gör. Yunus Yıldırım, Afyon Kocatepe Üniversitesi

Kaynakça/References

- ACCA. (2017). An introduction to professional insights. <https://www.accaglobal.com/gb/en/professional-insights/intro-pi.html>
- Ağdeniz, Ş. (2024). Güvenilir yapay zekâ ve iç denetim. *Denetisim*, (29), 112-126. <https://doi.org/10.58348/denetisim.1384391>
- Bacanlı, H., İlhan, T., & Aslan, S. (2009). Beş faktör kuramına dayalı bir kişilik ölçeğinin geliştirilmesi: Sıfatlara dayalı kişilik testi (Sdkt). *Türk Eğitim Bilimleri Dergisi*, 7(2), 261-279.
- Banta, V. C., Rîndasu, S. M., Tanasie, A., & Cojocaru, D. (2022). Artificial intelligence in the accounting of international businesses: A perception-based approach. *Sustainability*, 14, 6632. <https://doi.org/10.3390/su14116632>
- Beder, N. (2021). Muhasebe meslek mensuplarının yeni dünya ile imtihanı. *Anadolu Üniversitesi Sosyal Bilimler Dergisi*, 21(1), 163-184. <https://doi.org/10.18037/ausbd.902591>
- Birdal, M., Acun, S., & Onuk, P. (2011). Tüketici davranışlarında statü kaygısı ve sosyoekonomik belirleyenleri. *Doğuş Üniversitesi Dergisi*, 12(1), 17-31.
- Blake, K. R., & Brooks, R. C. (2019). Status anxiety mediates the positive relationship between income inequality and sexualization. *Proceedings of the National Academy of Sciences*, 201909806. <https://doi.org/10.1073/pnas.1909806116>
- Büyüköztürk, Ş., Çakmak, E. K., Akgün, Ö., Karadeniz, Ş., & Demirel, F. (2014). *Bilimsel araştırma yöntemleri*. Pegem Akademi.
- Çiçek, İ., & Aslan, A. E. (2020). Kişilik ve beş faktör kişilik özellikleri: Kuramsal bir çerçeve. *Batman Üniversitesi Yaşam Bilimleri Dergisi*, 10(1), 137-147.
- Day, M., & Fiske, S. (2016). What is status anxiety? Exploring a mechanism of the consequences of income inequality. Presentation at the International Society for Justice Research (ISJR), 16th Biennial Conference, University of Kent, Canterbury, UK.
- Demirkol, A., & Aslan, S. (2021). Holland'ın tipolojisi, bağlanma ve beş faktör kişilik kuramı üzerine bir derleme çalışması. *Uluslararası Anadolu Sosyal Bilimler Dergisi*, 5(3), 1127-1150. <https://doi.org/10.47525/ulasbid.932449>
- Digman, J. M. (1990). Personality structure: Emergence of the five-factor model. *Annual Review of Psychology*, 41(1), 417-440. <https://doi.org/10.1146/annurev.ps.41.020190.002221>
- Efe, A., & Tunçbilek, M. (2023). Yapay zekâ algoritmaları ile dönüşen denetim araçları üzerine bir değerlendirme. *Denetisim*, (27), 72-102. <https://doi.org/10.58348/denetisim.1195294>
- Gacar, A. (2019). Yapay zekâ ve yapay zekânın muhasebe mesleğine olan etkileri: Türkiye'ye yönelik fırsat ve tehditler. *Balkan Sosyal Bilimler Dergisi*, 8, 389-394.
- Günaydın, A., & Uzunoğlu, H. (2022). Teknolojik yenilikler ışığında muhasebe eğitimi ve muhasebe mesleğine ilişkin yazınsal bakış. *Denetim Ve Güvence Hizmetleri Dergisi*, 2(2), 92-102.
- Hair, J. F., Hult, G. T. M., Ringle, C. M., & Sarstedt, M. (2017). *A primer on partial least squares structural equation modeling (PLS-SEM)*. (2. Baskı). Sage.
- Henseler, J., Dijkstra, T. K., Sarstedt, M., Ringle, C. M., Diamantopoulos, A., Straub, D. W., & Calantone, R. J. (2014). Common beliefs and reality about PLS: Comments on Rönkkö and Evermann. *Organizational Research Methods*, 17(2), 182-200. <https://doi.org/10.1177/1094428114526928>
- Henseler, J., Hubona, G., & Ray, P. (2016). Using PLS path modeling in new technology research: Updated guidelines. *Industrial Management & Data Systems*, 116(2), 2-20. <https://doi.org/10.1108/IMDS-09-2015-0382>
- Horzum, M. B., Ayas, T., & Padır, M. A. (2017). Adaptation of big five personality traits scale to Turkish culture. *Sakarya University Journal of Education*, 7(2), 398-408. <https://doi.org/10.19126/suje.298430>
- Hu, L. T., & Bentler, P. M. (1998). Fit indices in covariance structure modeling: Sensitivity to underparameterized model misspecification. *Psychological Methods*, 3(4), 424-453.
- İskenderoğlu, N. (2020). Yapay zekâ teknolojilerinin muhasebeye entegrasyonu. <https://finansmuhendisi.net/yapay-zeka-ve-muhasebe/>
- İstanbul Teknik Üniversitesi (İTÜ). (2017). *İnsanlaşan makinalar ve yapay zekâ*. İTÜ Vakfı Yayınları.
- Kaya, F., Aydın, F., Schepman, A., Rodway, P., Yetişensoy, O., & Demir-Kaya, M. (2024). The roles of personality traits, AI anxiety, and demographic factors in attitudes toward artificial intelligence. *International Journal of Human-Computer Interaction*, 40(2), 497-514. <https://doi.org/10.1080/10447318.2022.2151730>
- Lorcu, F. (2015). *Örneklerle veri analizi SPSS uygulamalı*. Detay Yayıncılık.
- Malouff, J. M., Thorsteinsson, E. B., Schutte, N. S., Bhullar, N., & Rooke, S. E. (2010). The five-factor model of personality and relationship satisfaction of intimate partners: A meta-analysis. *Journal of Research in Personality*, 44(1), 124-127. <https://doi.org/10.1016/j.jrp.2009.09.004>

- Melita, D., Willis, G. B., & Rodríguez-Bailón, R. (2021). Economic inequality increases status anxiety through perceived contextual competitiveness. *Frontiers in Psychology, 12*, 637365. <https://doi.org/10.3389/fpsyg.2021.637365>
- Mert, İ. (2023). Muhasebe eğitimi ve araştırmasında çok disiplinli yaklaşım: Dijitalleşme ve modern yöntemler. *Muhasebe ve Denetim Bakış Dergisi, 68*, 249-262. <https://doi.org/10.55322/mbbakis.1131174>
- Omoteso, K. (2012). The application of artificial intelligence in auditing: Looking back to the future. *Expert Systems with Applications, 39*(9), 8490-8495.
- Özbek, A. (2024). Muhasebe meslek mensuplarının yapay zekâ kaygılarının gelecekte istihdam edilebilirlik algıları üzerine bir çalışma. *Alanya Akademik Bakış, 8*(1), 254-267. <https://doi.org/10.29023/alanyaakademik.1329511>
- Paskov, M., Gerxhani, K., & Van De Werfhorst, H. G. (2013). Income inequality and status anxiety. Growing Inequalities' Impacts.
- Pybus, K., Power, M., Pickett, K., & Wilkinson, R. (2022). Income inequality, status consumption and status anxiety: An exploratory review of implications for sustainability and directions for future research. *Social Sciences & Humanities Open, 100353*. <https://doi.org/10.1016/j.ssaho.2022.100353>
- Rammstedt, B., & John, O. P. (2007). Measuring personality in one minute or less: A 10-item short version of the Big Five Inventory in English and German. *Journal of Research in Personality, 41*(1), 203-212. <https://doi.org/10.1016/j.jrp.2006.02.001>
- Richter, N. F., Hauff, S., Ringle, C. M., & Gudergan, S. P. (2022). The use of partial least squares structural equation modeling and complementary methods in international management research. *Management International Review, 62*, 449-470.
- Ringle, C. M., Sarstedt, M., Sinkovics, N., & Sinkovics, R. R. (2023). A perspective on using partial least squares structural equation modelling in data articles. *Data in Brief, 48*, 109074.
- Sarıççek, R. (2019). Muhasebe alanındaki dönüşüm ve yapay zekâ. 2. *Uluslararası İnsan ve Toplum Bilimleri Araştırmaları Kongresi Bildiri Kitabı*, 1092-1099.
- Schepman, A., & Rodway, P. (2020). Initial validation of the general attitudes towards artificial intelligence scale. *Computers in Human Behavior Reports, 1*, 100014. <https://doi.org/10.1016/j.chbr.2020.100014>
- Schepman, A., & Rodway, P. (2022). The general attitudes towards artificial intelligence scale (GAAIS): Confirmatory validation and associations with personality, corporate distrust, and general trust. *International Journal of Human-Computer Interaction, 1-18*. <https://doi.org/10.1080/10447318.2022.2085400>
- Shafer, A. B. (2001). Relation of the big five to the EASI scales and the Thurstone temperament schedule. *Personality and Individual Differences, 31*(2), 193-204. [https://doi.org/10.1016/S0191-8869\(00\)00128-8](https://doi.org/10.1016/S0191-8869(00)00128-8)
- Sürücü, L., Maslakçı, A., & Ertan, Ş. S. (2022). Statü kaygısı ölçeğinin Türkçeye uyarlanması: Geçerlik ve güvenilirlik çalışması. *Selçuk Üniversitesi Sosyal Bilimler Meslek Yüksekokulu Dergisi, 25*(1), 226-235. <https://doi.org/10.29249/selcuksbmyd.1076257>
- Tekbaş, İ. (2019). *Muhasebenin dijital dönüşümü ve mali mühendislik*. Hümanist Kitap Yayıncılık.
- Ukpong, E. G., Udoh, I. I., & Essien, I. T. (2019). Artificial intelligence: Opportunities, issues and applications in accounting and auditing in Nigeria. *Journal of Accounting & Marketing, 7*, 309. <https://doi.org/10.4172/2168-9601.1000309>
- Varol, N. (2023). Dijital dönüşüm ve yapay zekâ: Muhasebenin ve denetimin geleceği. *Denetim Ve Güvence Hizmetleri Dergisi, 3*(2), 162-184.
- Wasny, G. (2019). How artificial intelligence will change the way accountants work. <https://www.accountingtoday.com/author/garrett-wasny-ma-cmccitp-fibp-at374>
- Yaninen, D. (2018). Artificial intelligence and the accounting profession in 2030. https://cpapng.org/pg/data/documents/CPA-Presentation-Artificial-Intelligence-and-the-Accounting-Profession-in-2030_1.pdf
- Yardımcıoğlu, M., & Şitak, B. (2020). Yapay zekâ teknolojisinin muhasebe alanına yansımaları: Literatür incelemesi. *Bilecik Şeyh Edebali Üniversitesi Sosyal Bilimler Dergisi, 5*(2), 342-353. <https://doi.org/10.33905/bseusbed.809795>
- Yi, Z., Cao, X., Chen, Z., & Li, S. (2023). Artificial intelligence in accounting and finance: Challenges and opportunities. *IEEE Access, 11*, 129100-129123. <https://doi.org/10.1109/ACCESS.2023.3333389>
- Zemankova, A. (2019). Artificial intelligence in audit and accounting: Development, current trends, opportunities and threats - literature review. *2019 International Conference on Control, Artificial Intelligence, Robotics & Optimization (ICCAIRO)*, Athens, Greece, 148-154. <https://doi.org/10.1109/ICCAIRO47923.2019.00031>
- Zhang, Y., Xiong, F., Xie, Y., Fan, X., & Gu, H. (2020). The impact of artificial intelligence and blockchain on the accounting profession. *IEEE Access, 8*, 110461-110477. <https://doi.org/10.1109/ACCESS.2020.3000505>

Research Article (Special Issue) | Araştırma Makalesi (Özel Sayı)

Kamu Denetçiliği Kurumu'nun kamu personel rejimi konusunda almış olduğu tavsiye kararlarını ChatGPT değerlendirebilir mi?

Elvettin Akman

Doç. Dr., Süleyman Demirel Üniversitesi, elvettinakman@sdu.edu.tr, [0000-0003-2303-840X](https://orcid.org/0000-0003-2303-840X)

Duygu Aksu

Dr., Bağımsız Araştırmacı, duygaksu@gmail.com, [0000-0002-8603-9074](https://orcid.org/0000-0002-8603-9074)

Yağmur Can

Dr., Bağımsız Araştırmacı, yagmurracan327@gmail.com, [0000-0001-9679-8819](https://orcid.org/0000-0001-9679-8819)Corresponding author/Sorumlu yazar: Duygu Aksu ✉ duygaksu@gmail.com

Öz

Kamu Denetçiliği Kurumu, daha yaygın bilinen adıyla Ombudsmanlık, toplumda şeffaflık ve adalet ilkesinin korunması adına denetim mekanizmasında önemli rol üstlenen bir kurum olarak değerlendirilmektedir. Bu kurum, vatandaşların kamu hizmetlerinden adil bir şekilde yararlanmasını sağlamak için önemli bir denetim aracı olarak işlev görmektedir. Özellikle, kamu personel rejimi konusunda aldığı tavsiye kararlarıyla dikkat çekmektedir. Bu kararlar, kamu kurumlarının personel politikalarını denetleyerek adaletin sağlanmasına katkıda bulunmaktadır. Kurumun yeni nesil teknolojilerden faydalanması, karar alma süreçlerinin etkinliğini artırabileceği sorusu akla gelmektedir. Örneğin, yapay zekâ teknolojisi, büyük veri setlerini hızlı ve objektif bir şekilde analiz ederek karar alma süreçlerine katkı sağlayabilir. Yapay zekâ tabanlı uygulamalar arasında yer alan ChatGPT de bu tavsiye kararlarının değerlendirilmesinde önemli bir araç olabilir. Bu teknolojilerin kullanımı, kurumun kararlarını daha kapsamlı ve etkili bir şekilde değerlendirmesine olanak tanıyabilir. Kamu Denetçiliği Kurumu tarafından alınan tavsiye kararlarının değerlendirilmesinde, ChatGPT gibi yapay zekâ tabanlı geliştirilen uygulamaların kullanımının kurum tarafından alınan tavsiye kararlarının etkinliğini ve verimliliğini artırabilir. Bu çalışma da yapay zekâ teknolojilerinden biri olan ChatGPT'nin Kamu Denetçiliği Kurumunun kararlarının değerlendirilmesindeki potansiyelini incelemeyi ve bu teknolojinin potansiyelini tartışmayı amaçlamaktadır.

Anahtar Kelimeler: Ombudsmanlık, Yapay Zekâ, ChatGPT, Prompt **JEL Kodları:** H83, O3, O38

Can ChatGPT evaluate the recommendations of the Ombudsman's office on public personnel regime?

Abstract

The Ombudsman Institution, more commonly known as the Ombudsman, is considered an institution that plays an important role in the audit mechanism in order to protect the principle of transparency and justice in society. This institution functions as an important control tool to ensure that citizens benefit from public services fairly. It draws attention especially with the advisory decisions it takes regarding the public personnel regime. These decisions contribute to ensuring justice by supervising the personnel policies of public institutions. In this context, the institution's use of new-generation technologies can increase the effectiveness of decision-making processes. For example, artificial intelligence technology can contribute to decision-making processes by analyzing large data sets quickly and objectively. ChatGPT, one of the artificial intelligence-based applications, can be an important tool in evaluating these recommendations. These technologies allow the organization to evaluate its decisions more comprehensively and effectively. The use of artificial intelligence-based applications such as ChatGPT in the evaluation of advisory decisions taken by the Ombudsman's Office can help to evaluate the decisions more comprehensively and fairly. In this context, using artificial intelligence technologies can increase the effectiveness and efficiency of the Ombudsman's advisory decisions. This study will examine the potential of ChatGPT, one of the artificial intelligence technologies, in evaluating Ombudsman decisions and emphasize the importance of this technology.

Keywords: Ombudsman, Artificial Intelligence, ChatGPT, Prompt **JEL Codes:** H83, O3, O38

Extended Summary

The Ombudsman Institution is commonly known as the Ombudsman. This institution plays an essential role in the audit mechanism by protecting the principles of transparency and justice in society. It is a vital audit tool to ensure that citizens benefit from public

How to cite this article / Bu makaleye atıf vermek için:

Akman, E., Aksu, D., & Can, Y. (2024). Kamu Denetçiliği Kurumu'nun kamu personel rejimi konusunda almış olduğu tavsiye kararlarını ChatGPT değerlendirebilir mi? *KOCATEPEİİBFD*, 26(Özel Sayı), 133-149. <https://doi.org/10.33707/akuuibfd.1463116>

services fairly. This is particularly notable for its advisory decisions regarding the public personnel regime. These decisions contribute to ensuring justice by supervising public institutions' personnel policies.

In this context, the Ombudsman's Office's utilization of new-generation technologies can increase the effectiveness of its decision-making processes. For example, artificial intelligence technology can contribute to decision-making by quickly and objectively analyzing large datasets. ChatGPT, an artificial intelligence-based application, can be essential in evaluating these advisory decisions. These technologies may allow institutions to evaluate their decisions more comprehensively and effectively.

We believe that the use of artificial intelligence-based applications, such as ChatGPT, in the evaluation of the recommendations made by the Ombudsman's Office can increase the effectiveness and efficiency of the recommendations made by the institution. ChatGPT is an artificial intelligence model capable of understanding and analyzing extensive text data. This model can quickly review advisory decisions, highlight key points, and evaluate their effectiveness. In particular, ChatGPT's ability to process large datasets can help an organization evaluate its decisions from a broader perspective.

Moreover, integrating artificial intelligence technologies such as ChatGPT into the Ombudsman's Office could improve decision-making processes. By automating the initial analysis of advisory decisions, ChatGPT can free human resources for more nuanced and complex tasks, ultimately increasing the efficiency of the institution. However, it is crucial to consider the ethical implications of such an integration, including issues related to privacy, bias, and accountability. Future studies should explore these aspects in more detail to ensure that the use of AI technologies aligns with the principles of fairness and transparency upheld by the Ombudsman's Office.

This study aims to examine the potential of ChatGPT, an artificial intelligence technology, to evaluate the decisions of the Ombudsman's Office and discuss the potential of this technology. Future research should address in more detail how AI technology can be integrated into the functioning of the Ombudsman's office and how this integration can increase the effectiveness of the institution. The ethical and security aspects of this technology should be considered. Measures should be taken to ensure that artificial intelligence applications produce accurate and fair results.

Furthermore, exploring the practical implementation of AI in the Ombudsman's Office could shed light on the potential challenges and benefits of such integration. This study seeks to provide a foundation for future research by outlining the key considerations and implications of incorporating AI into the decision-making processes of the Ombudsman's Office. By examining how AI can enhance the effectiveness and efficiency of an institution, this study aims to contribute to a broader understanding of the role of technology in public service delivery and governance.

This extended abstract includes the purpose of the study, why it is needed, its contribution to the literature, its original value, the methodology and data used, the main findings, policy recommendations, limitations of the study, and suggestions for future research. How artificial intelligence technology can be integrated into the functioning of the Ombudsman's Office and how this integration can increase the effectiveness of the institution are seen as important areas for future research.

Additionally, this study aims to address the ethical and security implications of AI integration in the Ombudsman's Office. Ensuring the responsible use of AI technologies is paramount, and this research explores how to mitigate potential risks, such as bias in decision-making and the protection of sensitive data. By identifying the best practices and guidelines for AI implementation, this study sought to provide a comprehensive framework for AI's ethical and secure utilization in public institutions.

Moreover, by examining the practical implications of AI integration in the Ombudsman's Office, this research can inform policymakers and practitioners about the potential benefits and challenges of adopting AI technologies in similar contexts. Through a thorough analysis of current literature and case studies, this study aims to provide valuable insights into how AI can transform public service delivery and governance, paving the way for more efficient, transparent, and accountable government operations.

Giriş

Değişen bir dünyada yaşadığımızı söylemek gerçektir. Özellikle de son yıllarda hiçbir şeyin uzun süre aynı kalmadığı bir dünyadan bahsetmemiz gerekmektedir. Dünya genelinde yaygın kullanımı ile Ombudsman olarak adlandırdığımız Kamu Denetçiliği Kurumunun çalışmalarını da bu değişimden ayrı görmek imkânsızdır. Kamu Denetçiliği Kurumunun Türkiye'de kurulduğu yıl olan 2012 yılının üzerinden geçen on iki yıllık süreçte içerisinde bulunduğumuz dünyada vatandaş, özel sektör, kamu kurumları ve kamuda hizmet sunma yöntemleri oldukça farklılaşmıştır.

Haksızlığa uğrayan bireylerin zararını gidermeye çalışan, kamu hizmetlerini iyileştirmek ve hataların tekrarlanmasını önlemek için çaba sarf eden ombudsmanlık kurumlarının dünya çapında göstermiş oldukları başarılı faaliyetler kurumun küresel yaygınlaşmasına da yansımıştır. Ombudsmanlık kurumlarının yaygınlaşmasının temelinde yatan iki husus bulunmaktadır. İlki,

vatandaşlarda hak arama kültürünün yaygınlaşmaya başlaması, ikincisi ise gelişen teknoloji ile kuruma hızlı ve masrafsız biçimde başvuru yapılmasıdır. Ayrıca ombudsmanlık kurumlarının yargı organlarına görece hızlı yanıt vermesi de kuruma başvuruları cazip hale getirmektedir. Türkiye’de kurum altı aylık bir sürede başvuruyu karar bağlayacağını ifade etmekte ve çoğu zamanda buna uymaktadır.

Kurumun hızlı yanıt vermesi, kararlarına uyma düzeyinin gün geçtikçe artması ve gelişen teknoloji ile beraber insanların daha fazla etkileşimde bulunma isteği zaman içerisinde kurumun karar alma süreçlerini gözden geçirmesini gerektirebilecektir. Özellikle şikâyetçiler, hayatlarının diğer alanlarında olduğu gibi, sıklıkla kullandıkları sosyal medya platformları aracılığı ile kurum ile daha fazla etkileşimde bulunmak daha hızlı yanıt almak ve yaşanabilecek herhangi bir gecikmede ya da şikâyetlerinin dikkate alınmaması durumlarında memnuniyetsizliklerini hızlı bir şekilde dile getireceklerdir. Zaman içerisinde daha hızlı sonuçlara duyulan ihtiyaç, teknolojinin hayatının tamamını daha fazla kapsamı ve en önemlisi de Z kuşağı ve hemen ardından Alfa Kuşağı olarak adlandırılan kuşakların kurumun hizmetlerinden yararlanıcı olacakları düşünüldüğünde ombudsmanlık kurumunun karar verme süreçlerinde yapay zekâ teknolojilerinden yararlanması kaçınılmaz gibi görünmektedir.

Dijital çağın kamu hizmet sunumuna bir yansıması da yapay zekâ kullanılarak algoritmik karar alma süreçlerinin entegre edilmesi ile kamu yönetiminde önemli bir dönüşüm yaşanmaktadır. Yapay zekâ teknolojisi de son dönemlerde dikkatleri üzerine çeken yeni nesil teknolojiler arasında yer almaktadır (Okcu vd., 2020, s. 43). Türkiye’de bazı kurum ve kuruluşlar karar alma süreçlerine yardımcı olarak yapay zekâ teknolojilerinden faydalanma konusunda çeşitli hazırlıklar yapmakta ve adımlar atmaktadır. Örneğin; Adalet Bakanlığı hâkim ve savcılarının karar alma süreçlerine yardımcı olacak bir yapay zekâ sistemi üzerinde çalışmalarını yürütmektedirler. Yargıda kullanılması konusunda adım atılan yapay zekâ teknolojisinin yargının yükünü hafifleten bir kurum olan Kamu Denetçiliği Kurumunun karar alma süreçlerinde de kullanımı düşünülebilir. Yapay zekâ teknolojisine sahip sistemler, büyük veri setlerini analiz ederek hızlı ve hassas kararlar alabilme yeteneğine sahiptirler. Bu durum, Kamu Denetçiliği Kurumu’nun etkinlik ve verimliliğini artırabilir ve karar alma süreçlerini daha adil ve şeffaf hale getirebilir. Ayrıca, yapay zekâ destekli sistemler, süreçlerdeki insan hatalarını azaltabilir ve kaynakların daha etkin kullanılmasını sağlayabilir. Dolayısıyla, Kamu Denetçiliği Kurumu’nun bu teknolojiden faydalanması, kamu hizmetlerinin kalitesini ve vatandaş memnuniyetini artırabilir.

Bugün Avrupa Ombudsmanının Avrupa Ombudsman Ağındaki meslektaşlarıyla birlikte, yapay zekânın kamu idareleri üzerindeki etkilerini değerlendirdiği bir ortamda yapay zekâdan yararlanılabileceği öngörülmektedir. Türkiye’de Adalet Bakanlığının hâkim ve savcılarının karar alma süreçlerine yardımcı olacak bir yapay zekâ sistemi üzerinde çalıştığı bir ortamda yapay zekânın karar alma süreçlerinde kullanımının kaçınılmaz olduğunu işaret etmektedir. Ancak burada bazı temel sorunların ortaya çıkıp çıkmayacağı tartışılmaktadır. Yapay zekâ kullanımının bir sonucu ortaya çıkacak adaletsizliğin nasıl giderileceği, bir bireyin özel koşullarının dikkate alınması açısından takdir yetkisinin kullanılması gerekliliği gibi hususlar tartışılmaktadır. Ayrıca karar verici pozisyonda yer alan hâkime nasıl bir karara vardığını sormak kolay olsa da yapay zekâ için bu her zaman geçerli olmayacaktır. Tüm bunların ışığında bu çalışma da Kamu Denetçiliği Kurumunun kamu personel rejimi konusunda aldığı kararlar OpenAI tarafından geliştirilen ve geniş bir kullanım alanına sahip yapay zekâ uygulaması olan ChatGPT kullanılarak yeniden değerlendirmeye tabi tutulmuştur. Yapılan değerlendirmeler neticesinde, ChatGPT tarafından Kamu Denetçiliği Kurumuna benzer yönde kararlar aldığı görülmektedir. Ancak daha sağlıklı bir değerlendirme yapabilmek için başvuru dosyasının tamamının ChatGPT vb. yapay zekâ destekli bir uygulama tarafından değerlendirilmeye tabi tutulmasını görmek gerekmektedir.

1. Kavramsal Çerçeve

Her ülkede farklı isimle anılan ombudsmanlık kurumu Türkçede dilimize “kamu denetçisi” olarak yerleşmiştir (Özer, 2017, s. 67). Günümüzde, kamu denetçiliği kurumları, vatandaşların haklarını koruma ve hükümet faaliyetlerini denetleme noktasında önemli bir rol oynamaktadır. Bu kurumlar, çeşitli konularda tavsiye kararları alarak kamu yönetimini iyileştirmeye katkı sunmaktadır (Karaca ve Azimli Çilingir, 2022, s. 227). Kamu Denetçiliği Kurumu, Türkiye’de ombudsmanlık işlevini yerine getiren, kamu personel rejimi gibi önemli konularda tavsiye kararları veren ve uygulamaları değerlendiren bir kurumdur.

Türkiye’de kamu denetçiliğine dair ilk yasal düzenleme 14 Haziran 2012 tarihinde 6328 sayılı “Kamu Denetçiliği Kurumu Kanunu”nun çıkarılması ile gerçekleştirilmiştir. Bu kanunun 29 Mart 2013 tarihinde yürürlüğe girmesiyle, Türkiye Cumhuriyeti tarihinin ilk kamu denetçisi göreve başlamıştır. Bu kurumun oluşturulmasından önce Türk kamu yönetiminde, iyi yönetim ilkelerinin uygulanması ve geliştirilmesi, toplum haklarını arama kültürünün güçlendirilmesi amacıyla yıllar içinde birçok düzenleme yapılmıştır (Erdoğan, 2020, ss. 228-229). Bu kapsamda yapılan düzenlemeler kamu denetçiliği kurumunun oluşturulmasında atılan adımlar olarak değerlendirilmektedir. Bu adımlar örnekler ile somutlaştırılacak olursa;

1982 Anayasası’nın “Temel Hak ve Özgürlükler” başlıklı 40. Maddesi, temel hak ve özgürlüklerin korunması ve güvence altına alınması noktasında önemli bir referans teşkil etmektedir.

2002 yılında İçişleri Bakanlığı tarafından yayımlanan 12/467 sayılı genelge, “iyi yönetimin geliştirilmesi” konusunu ele alarak, kamu

hizmetlerinde şeffaflığı, hesap verebilirliği ve etkinliği artırmayı amaçlamıştır. Bu genelge, vatandaşların hizmetlere erişimini kolaylaştırmak ve sorunlarına daha hızlı çözüm bulabilmek için uygun politikaları ve uygulamaları benimsemeleri yönünde rehberlik etmektedir.

2003 yılında çıkarılan kamu kurumlarının faaliyetlerine ilişkin bilgi edinme hakkını düzenleyen ve kamu yönetiminde şeffaflığı artırmayı hedefleyen 4982 sayılı “Bilgi Edinme Hakkı Kanunu” da bir referans teşkil etmektedir. Bu kanun, vatandaşların kamu hizmetlerine ilişkin bilgiye erişimini kolaylaştırmak suretiyle katılımcı demokrasiyi güçlendirmeyi ve toplumun kamu faaliyetlerine daha etkin şekilde katılmasını amaçlamaktadır. Bu düzenlemeler, Türk kamu yönetiminde iyi yönetim ilkelerinin teşvik edilmesi ve uygulanmasına yönelik önemli adımlar olarak değerlendirilmektedir.

2004 yılında, Adalet Bakanlığı tarafından hazırlanan “Türkiye Halk Denetçiliği Kurumu Kanunu Tasarı Taslağı” konu ile ilgili önemli bir somut belge niteliğindedir. Kamu Denetçiliği Kurumu’nun Türkiye’de faaliyete geçirilmesi noktasında atılan adımlardan biri olarak gösterilen bu belgenin Cumhurbaşkanı tarafından meclise geri gönderilmesi ve tekrar meclis gündemine gelmemesinden dolayı kadük olmuştur (Kayar, 2015, ss. 26-30). Bu durum uzun yıllar boyunca kamu denetçiliği kurumunun oluşturulması konusundaki çabaların karşısında duran önemli bir engel olmuştur.

Kamu denetçiliği kurumunun oluşturulması adına devam eden girişimler bahsedilen bu sebep ve anayasal düzenlemelere uygun olmadığı gerekçesiyle sık sık tartışmalı bir gündem maddesi olmaktan öteye gidememiştir. Bu durum, Türkiye’de kamu denetçiliği kurumunun kurulması sürecinde yaşanan karmaşıklık ve zorlukları tarihe geçirmiştir. Kamu denetçiliği kurumunun henüz faaliyete geçmediği dönemlerde, çeşitli denetim mekanizmalarının bu görevi üstlenmeye çalıştığı ancak başarısız olduğu görülmüştür. Bu düzenlemeler, kamu hizmetlerinin etkin denetimini sağlamak için yapılan çabaların bir yansıması olarak değerlendirilebilir. Ancak, bu alternatif denetim girişimlerinin istenen sonucu vermediği açıktır.

12 Eylül 2010 yılında 2982 sayılı “Türkiye Cumhuriyeti Anayasasının Bazı Maddelerinde Değişiklik Yapılması Hakkında Kanun” ile yapılan referandumda kabul edilen anayasa değişikliğinin “Siyasi Haklar ve Ödevler” bölümünde bulunan 74. maddesinde yapılan değişiklik neticesinde kamu denetçiliği kurumunun kurulmasına ilişkin alt yapı oluşturulmuştur. Bu düzenleme, kamu denetçiliği kurumunun oluşturulmasıyla ilgili anayasal tartışmaları sonlandıran belge olarak da nitelendirilebilir.

2000’li yılların başından 2010 yılına kadar, kamu denetçiliği kurumuna yönelik birçok girişim ve düzenleme yapılmış olmasına rağmen, somut bir sonuç elde edilememiştir. 2010 yılında yaşanan gelişmelerin ardından 2013 yılında yayımlanan 6328 sayılı “Kamu Denetçiliği Kurumu Kanunu” ile birlikte “Kamu Denetçiliği Kurumu” resmi olarak kurulmuştur. “Türkiye Büyük Millet Meclisi Başkanlığına bağlı, kamu tüzel kişiliğini haiz, özel bütçeli ve merkezi Ankara”da bulunan ibaresi ile kurulan kurum Başkanlık ve genel sekreterlik birimlerinden oluşmaktadır. Bu kanunla birlikte, kamu denetçiliği alanında yapılan çalışmaların somut bir kurumsal yapıya kavuştuğu ve etkinlik kazandığı görülmektedir.

Kurum, kamu hizmetlerinde hesap verebilirlik, şeffaflık ve adaletin sağlanması amacıyla kurulmuş, bağımsız ve tarafsız bir mekanizma olarak kamu yönetimi sistemine eklenmiştir. Kamu Denetçiliği Kurumunda görev yapan kamu denetçileri genellikle devlet kurumlarının faaliyetlerini denetlemek, vatandaşların haklarını korumak ve çıkarlarını savunmak için görev yapmaktadır (Efe ve Demirci, 2013, s. 50). Ayrıca bu kuruma hiçbir yetkili makam veya kişi tarafından yönlendirme, emir veya telkinde bulunulamaz.

Türkiye’deki kamu denetçiliği kurumunun işleyişi ve karar alma süreci şikâyetlerin alınmasıyla başlamaktadır. Vatandaşlar veya kurumlar tarafından şekli şartlara uygun olarak yapılan şikâyetler detaylı bir şekilde uzmanlar tarafından incelenmekte ve konu ile ilgili gerekli araştırmalar yapılmaktadır. Bu süreçte ilgili belgeler gözden geçirilmekte, gerekli görülürse şahitlerin ifadelerine başvurulabilmekte hatta bilirkişi atanabilmektedir. Devam eden süreçte de ilgili kurumlarla iletişime geçilmektedir. Kamu kurumlarından konu ile ilgili 30 gün içerisinde cevap almak üzere, bilgi ve belge talep edilmektedir. Ardından, kurum şikâyetle ilgili bir karar vermekte, bu kararda şikâyetin haklı veya haksız olduğuna dair bir değerlendirme yer almaktadır. Karar verilirken genellikle ilgili kurumlara tavsiye kararları ile önerilerde bulunmaktadır. Bu tavsiyeler adaletin sağlanması veya benzer hataların tekrarlanmasının önlenmesini amaçlamaktadır. Kararların tavsiye ve öneri olarak belirtilmesinin nedeni ise bir bağlayıcılığının ve yaptırımının olmamasından kaynaklanmaktadır (TBMM KDK, t.y.). Yasama, Yargı ve Türk Silahlı Kuvvetlerinin sırf askerî nitelikteki etkinlikleri kurumun faaliyet alanı dışında bırakılmıştır. Bu konularla ilgili bir denetleme ve öneri de bulunma yetkisi yoktur.

Kamu denetçiliği kurumu, devletin vatandaşlarına daha iyi hizmet sunmasına ve kamu kurumlarına olan güvenin arttırmasına yardımcı olabilecek nitelikte bir kurumdur. Bunun yanı sıra, demokratik değerlerin korunmasına ve insan haklarının güvence altına alınmasına da katkı sağlamaktadır. Bağımsızlık ve tarafsızlık ilkelerine dayanan kamu denetçileri, toplumun her kesiminden gelen şikâyetleri adil bir şekilde ele almak ve çözüme kavuşturmakla sorumludurlar. Bu şekilde, kamu denetçiliği kurumu, demokratik bir toplumun işleyişinde önemli bir rol oynar ve devlet ile vatandaşlar arasındaki güven bağına güçlendirir.

Yapay zekâ ise, insan benzeri zekâyâ sahip olması amaçlanan bilgisayar sistemlerinin bilim ve mühendislik alanı olarak tanımlanmadır (Mohamed Saleh, 2019, s. 3; Pirim, 2006, s. 84). TDK’ya göre yapay zekâ “bir bilgisayarın, bilgisayar kontrolündeki

bir robotun veya programlanabilir bir aygıtın insana benzer biçimde algılama, öğrenme, fikir yürütme, karar verme, sorun çözme, iletişim kurma vb. işlevleri sergileyebilme yeteneği” olarak tanımlanmaktadır. Yapay zekâ, makinelerin zeki birer varlık haline gelmesini sağlama amacı taşıyan bir girişim olarak da ifade edilmektedir (Nilsson, 2010, s. 13; Okcu ve Akman, 2020, s. 71). Bilgi işleme, öğrenme, algılama ve karar verme gibi insan zekâsının birçok yönü taklit edilerek oluşturulan yapay zekâ sistemi son yıllarda önemli bir hızla gelişen ve birçok alanda uygulama potansiyeli bulunan bir teknolojidir.

Çalışmada Kamu Denetçiliği Kurumu’nun aldığı kararlar kullanıcıdan gelen soru ve yanıtlara göre bir sonraki metni tahmin etme yeteneği bulunan yapay zekâ uygulaması olan ChatGPT kullanılarak yeniden değerlendirmeye tabi tutulmuştur. OpenAI isimli yapay zekâ araştırmaları kuruluşu tarafından geliştirilen ChatGPT, başta özel sektörde olmak ticaret, spor, turizm, sağlık ve eğitim gibi pek çok sektörde kullanılmaya başlamıştır (Altman, 2023).

Bu yapay zekâ sohbet robotu ilk kez 2018’de tanıtılan “Generative Pre-trained Transformer (GPT)” dil modelini temel alarak geliştirilmiştir. Bu model doğal dil anlama ve üretme becerilerine sahip derin öğrenme tabanlı bir sisteme sahiptir (Radford vd. 2018, s. 8). Doğal bir iletişim kurabilen bilgisayar programı olarak bilinen ChatGPT, şu anda dört farklı versiyona sahiptir. İlk sürümü, temel metinler oluşturabilen bir modelken ikinci sürümü olan GPT-2 versiyonuyla birlikte bu metinler daha karmaşık ve insan benzeri hale gelmiştir. Bu versiyonlar, zaman içerisinde sürekli geliştirilerek günümüzde kullanılan ChatGPT-3.5 ve ChatGPT-4 uygulamalarına dönüşmüştür (OpenAI, 2023).

ChatGPT, 30 Kasım 2022’de yapılan ilk tanıtımından sadece beş gün sonra, hızlı bir şekilde popülerlik kazanarak 1 milyon kullanıcıya ulaşmıştır. Bu yapay zekâ modelinin başarılı bulunan ücretli ve ücretsiz versiyonları, popülerliğini ücretsiz olan GPT-3.5 versiyonundan almaktadır. ChatGPT’nin bu hızlı başlangıcın ardından, sadece iki ay sonra 100 milyon aktif kullanıcı sayısına ulaşarak tarihin en hızlı büyüyen tüketici uygulamalarından biri haline gelmiştir. Ek olarak 2024 Mart ayı güncel verilerine göre 180,5 milyondan fazla aylık kullanıcıya sahiptir (Shewale, 2024). Bu muazzam büyüme, ChatGPT’nin insanlar arasında ne kadar çabuk kabul gördüğünün ve hayatın birçok yönünde nasıl kullanıldığının bir göstergesi olarak değerlendirilebilir. Bu teknolojiyi benimsemenin yanı sıra etkin kullanabilmek adına da doğru prompt girişinin sağlanması önemlidir.

“Prompt girişi” olarak adlandırılan teknik kavram ise yapay zekâ modelleri ile etkileşim sırasında kullanıcılar için kilit bir araç olarak kabul edilmektedir. Bu teknik, özellikle ChatGPT gibi yapay zekâ modelleriyle etkileşimde bulunurken kullanıcıların iletişimini önemli ölçüde iyileştirmektedir (ChatGPT 4 ve Ekin, 2023, s. 3). Kullanıcılar, ChatGPT’ye belirli bir konuda bir giriş cümlesi veya talimat vererek, yapay zekânın o konuda daha spesifik, odaklı, akıcı ve doğru cevaplar üretmesini sağlayabilmektedir. Bu sayede, kullanıcıların istedikleri bilgiye daha hızlı ve daha doğru bir şekilde erişmeleri mümkün olmaktadır. Aynı zamanda, prompt girişi yaparak ChatGPT’nin cevapları daha iyi yönlendirilir ve iletişim süreci daha etkili bir hale getirilebilir. Dolayısıyla, prompt girişi kullanıcıların yapay zekâ modelleriyle etkileşimini kolaylaştıran ve daha verimli hale getiren önemli bir strateji olarak ifade edilebilir.

Kamu Denetçiliği Kurumu’nun kamu personel rejimi konusunda almış olduğu tavsiye kararlarının ChatGPT tarafından değerlendirilmesi, yapay zekâ teknolojisinin kamu yönetiminde denetim alanındaki potansiyelini ortaya koymaktadır. Bu çalışma, Kamu Denetçiliği Kurumu’nun önerilerinin, yapay zekâ aracılığıyla incelenerek analiz edilmesini ve belirli kamu personel rejimi konularında yapay zekâ tabanlı önerilerin sunulmasını içermektedir. Bu yaklaşım ile yeni nesil teknolojik araçların kamu yönetimi alanında kullanılması etkinlik ve verimlilik düzeyini artıran bir potansiyel yaratabilir.

2. Literatür Taraması

Yakın zamanda Avrupa Ombudsmanlık Kurumu, yapay zekânın kullanımı ve karar alma süreçleriyle ilgili olarak Avrupa Komisyonu’na bir mektup yönlendirmiştir. Bu mektupta yapay zekâ gelişmelerinin iş kalitesini ve verimliliğini artırmada sunabileceği çeşitli faydaları kabul eden Ombudsman, doğruluk, potansiyel önyargılar ve insan gözetiminin gerekliliği ile ilgili sorunlar da dâhil olmak üzere bunların ortaya çıkarabileceği zorlukların altını çizmiştir (European Ombudsman, 2024). Kamuoyu geri bildirimlerinin analizi, AB rekabet düzenlemelerinin olası ihlallerinin tespiti ve şikâyetlerin ele alınması gibi konuların net bir şekilde ifade edildiği mektup yapay zekâyı kullanma konusunda pozitif yaklaşım sergilemektedir ancak konu ile ilgili net olmayan noktalardan dolayı sorularına yanıt talep etmektedir.

Perlman (2022) “ChatGPT’nin Yasal Hizmetler ve Toplum Açısından Etkileri” başlıklı çalışmada konuyu spesifik olarak ele almıştır. Bu çalışmada, ChatGPT uygulamasının potansiyel faydaları ve avantajları kabul edilmektedir. Ancak uygulama tarafından oluşturulan yanıtların zaman zaman kusurlu ve hatalı olmasından ve bundan kaynaklı bir dizi yasal düzenleyici ve etik sorunun gündeme geleceği de ifade edilmiştir. Bu sorunların üstesinden gelmek adına da konuyla ilgili gerekli düzenlemelerin yapılması ve mevcut duruma uygun bir şekilde kullanılması adına yeniden tasarlanmasını önermektedir.

Şentürk (2023) ise, tarafından yapılan çalışmada, iç denetim alanında yapay zekânın kullanımı üzerine odaklanılmıştır. Bu çalışma, ChatGPT gibi yapay zekâ uygulamalarının iç denetim süreçlerine destek sağlayabileceği ve zamanla önemli bir rol oynayabileceği

öngörüsünü ortaya koymuştur. Ancak, bu uygulamaların potansiyel riskleri ve bunların nasıl yönetilebileceği konularına da dikkat çekilmiştir.

Derdiyok ve diğerleri (2023) de, şirketlerin mali durumlarının tespitinde ChatGPT'nin yeteneklerine odaklanan bir çalışma gerçekleştirmişlerdir. Bu çalışma, ChatGPT'nin borsada halka açık olan şirketlerin finansal durum skorlarını ne kadar başarılı bir şekilde değerlendirdiği konusuna odaklanmıştır. Araştırma, ChatGPT'nin finansal verileri analiz etme ve şirketlerin mali durumlarını öngörme konusundaki potansiyelini incelemiştir.

Günek (2023) tarafından yapılan çalışmada, yapay zekâ ile birlikte bilginin dönüşüm süreci üzerine odaklanılmıştır. Araştırmada, yapay zekâ uygulamalarının yeni bir bilgi formu olarak kabul edilmesi ve bu yeni bilgi formunun -yapay zekânın- iktidar ilişkilerini yeniden şekillendirdiği iddia edilmiştir. Bu çalışma, yapay zekâ teknolojisinin bilgi üretimindeki etkisini ve bu etkinin iktidar ilişkileri üzerindeki yansımalarını ele almıştır. Araştırma, yapay zekâ kullanımının toplumsal ve politik bağlamlardaki değişimleri nasıl etkilediğini anlamak için önemli bir perspektif sunmaktadır.

Özparlak ve Çetin (2023) de, ChatGPT gibi üretken yapay zekâ modellerinin güvenlik ve mahremiyet üzerindeki etkilerini hukuki açıdan değerlendirmiştir. Bu çalışmada yapay zekâ modellerinin kullanımının potansiyel güvenlik risklerini ve mahremiyet ihlallerini nasıl etkileyebileceği de ele alınan temel konulardan biri olmuştur.

Benzer şekilde, Balaban ve Kulular İbrahim (2023) de hukuki açıdan bir çalışma yürütmüş ve özellikle hukuki ayrılıkların önlenmesi üzerine odaklanmışlardır. Bu çalışmada, yapay zekâ uygulamalarının hukuki çerçeve içinde nasıl yönetilebileceği ve olası anlaşmazlıkların nasıl önlenebileceği konusunda değerlendirmeler yapılmıştır. Bu iki çalışma da yapay zekâ teknolojisinin hukuki boyutlarını anlamak ve uygun yönetim politikalarının oluşturulmasına katkı sağlamak amacıyla önemli bir katkı sunmaktadır.

Kurt (2023), muhasebe ve denetim mesleklerinin dijital çağda nasıl geliştiğini ve ChatGPT'nin sonuçlarına odaklanarak bu mesleklerin evrimini araştırmıştır. Araştırması, hızla değişen dijital ortamda muhasebe ve denetim profesyonellerinin güncel ve rekabetçi kalabilmek adına teknolojik gelişmelere sürekli olarak adapte olmalarının gerekliliği vurgulanan bir konu olmuştur. Sürekli öğrenme ve yeni teknolojileri benimseme ihtiyacının önemine dikkat çekilmiştir.

Özer vd., (2023) ve Gürsoy ile Kılıç (2023), ChatGPT uygulamasının finansal düzeydeki kullanımını inceleyen çalışmalar gerçekleştirmişlerdir. Bu çalışmalar, yapay zekâ teknolojisinin finansal analiz ve karar verme süreçlerinde nasıl kullanılabileceği konusunda önemli bir anlayış sunmaktadır.

Salah ve diğerlerinin (2023), çalışması ise net bir ifade ile kamu yönetimi ve ChatGPT konusunu ele almıştır. Bu çalışma, özellikle sokak düzeyindeki bürokraside ChatGPT ve Bard gibi üretken yapay zekâ araçlarının benimsenmesini eleştirel bir şekilde incelemiştir. Araştırma, bu yapay zekâ araçlarının kamu yönetimi araştırmalarında nasıl kullanılabileceğini ve bürokratik davranışlar ile karar alma süreçlerine olan etkilerini üzerine değerlendirmelerde bulunmuştur. Bu çalışma, yapay zekâ teknolojisinin kamu yönetimi alanındaki potansiyelini ve bu teknolojinin günlük bürokratik işleyiş üzerindeki etkilerini anlamak için yardımcı bir nitelik taşımaktadır.

Bu çalışmaya benzer şekilde, Cantens (2024) kamu idarelerinde üretken yapay zekâyı çevreleyen zorlukları ve bu teknolojinin kamu yönetimi içindeki insan-makine etkileşimleri üzerindeki etkisini araştırmıştır. Yapılan araştırmada, bu dönüşümün daha fazla değerlendirme gerektirdiği ve kamu yönetimi süreçlerinde önemli bir değişimin öngörüldüğü vurgulanmıştır.

Huang ve Huang'ın (2024), "Devlette ChatGPT" çalışması ChatGPT ve Web 3'ün devlet hizmetleri alanındaki dönüştürücü potansiyeli üzerine odaklanmıştır. Vatandaş katılımının artırılabilirliği, kurumlar arası iş birliğini teşvik, idari süreçlerin kolaylaşması gibi konularda ayrıntılı bir genel bakış sunulmaya çalışılmıştır.

Literatürde yer alan çalışmalar incelendiğinde derinlemesine analizi ve tartışması için literatür özeti tablosunun oluşturulmuştur. Konunun geliştirilmesi ve daha kapsamlı bir şekilde ele alınması ve adına tabloda araştırmacılara, araştırmanın başlığına ve araştırmanın bulgusuna yer verilmiştir.

Tablo 1. Literatür Taraması Tablosu

Araştırmacı/Araştırmacılar	Araştırmanın Başlığı	Araştırmanın Bulgusu
Avrupa Ombudsmanlık Kurumu (2024)	"Avrupa Komisyonu'na Yapay Zekâ Kullanımıyla İlgili Mektup"	Yapay zekânın iş kalitesi ve verimliliğini artırabileceği belirtilmiş ancak doğruluk, önyargılar ve insan gözetimi gerekliliği üzerinde durulmuştur.
Perlman (2022)	"ChatGPT'nin Yasal Hizmetler ve Toplum Açısından Etkileri"	ChatGPT'nin potansiyel faydaları kabul edilmiş, ancak yasal düzenleyici ve etik sorunlar için düzenlemeler önerilmiştir.
Şentürk (2023)	"İç Denetim Faaliyetlerinde Yapay Zekâdan Beklentiler: Chatgpt Uygulaması Örneği"	Yapay zekâ uygulamalarının iç denetim süreçlerine katkı sağlayabileceği, potansiyel risklerin yönetimi için dikkat çekilmiştir.

Tablo 1. Devam.

Derdiyok vd. (2023)	“Chatgpt’nin Şirketlerin Mali Durumunu Tespit Yeteneği”	ChatGPT’nin finansal durum değerlendirmesi ve analiz yeteneklerine odaklanılmış, yapay zekânın analitik potansiyeli incelenmiştir.
Günek (2023)	“Dijital Çağda Bilginin Dönüşümü ve Yapay Zekâ: Üretim ve İktidar İlişkileri Açısından Bir Değerlendirme”	Yapay zekâ teknolojisinin bilgi üretimi ve iktidar ilişkileri üzerindeki etkisi ele alınmıştır.
Özparlak ve Çetin (2023)	“ChatGPT ve Üretici Yapay Zekâ Modellerinde Mahremiyet ve Güvenliğin Hukuki Boyutu”	Yapay zekâ kullanımının güvenlik ve mahremiyet üzerindeki potansiyel etkileri ve hukuki düzenlemelerin gerekliliği vurgulanmıştır.
Balaban ve Kulular İbrahim (2023)	“ChatGPT Gibi Sohbet Yazılımlarının (Sohbet Botları/ Chatbots) Neden Olduğu Hukuka Aykırılıkların Önlenmesi”	Mevcut yasaların sohbet yazılımlarından kaynaklanan hukuki sorunları yeterince ele alamadığını ve bu konuda özel düzenlemelerin gerekliliğini tartışmaktadır.
Kurt (2023)	“Digital Transformation in Accounting and Auditing: Insights from The ChatGPT Example”	Dijital çağda muhasebe ve denetim mesleklerinin evrimi, ChatGPT’nin kullanımıyla yapılan etkileşimler üzerinden incelenmiş ve muhasebecilerin teknolojik becerilerini geliştirmelerinin gerekliliği vurgulanmıştır.
Özer vd. (2023)	“ChatGPT Hisse Senedi Değerlemede Kullanılabilir Mi? Borsa İstanbul Üzerine Bir Araştırma”	ChatGPT’nin şirketlerin finansal tablolarını analiz ederek hisse senedi değerlemesi yapma başarısını değerlendiren bu çalışma bulguların istatistiksel anlamlılık derecesinin düşük olduğunu ortaya koymuştur.
Gürsoy ve Kılıç (2023)	“The Comparison of Google Bard and Chatgpt Use in Financial Markets”	ChatGPT ve Google Bard gibi yapay zekâ sistemlerinin finansal piyasalarda kullanım avantajları ve sınırlılıklarını karşılaştırmalı olarak analiz eden çalışma bu sistemlerin performansının zaman içinde daha iyi anlaşılacağını öne sürmektedir.
Salah vd. (2023)	“Generative Artificial Intelligence (ChatGPT & Bard) in Public Administration Research: A Double-Edged Sword for Street-Level Bureaucracy Studies”	Kamu yönetimi araştırmalarında özellikle sokak düzeyi bürokraside ChatGPT ve Bard gibi üretken yapay zekâ araçlarının etik zorluklarını ve benimsenme süreçlerini ele alan bu çalışma veri doğrulama ve etik standartlara bağlı kalma gerekliliğine vurgu yapmaktadır.
Cantens (2024)	“How will the state think with ChatGPT? The challenges of generative artificial intelligence for public administrations”	Kamu yönetimde üretken yapay zekânın kullanımının etkilerini ve bu teknolojinin insan-makine etkileşimleri üzerindeki zorluklarını ele alan bu çalışma özellikle üretken yapay zekânın sınırlı açıklanabilirliğinden kaynaklanan güven sorunlarına ve kamu sektöründeki uygulamalarına odaklanmaktadır.
Huang ve Huang (2024)	“ChatGPT in Government”	ChatGPT ve Web 3 teknolojilerinin kamu hizmetlerine nasıl katkıda bulunabileceğini inceleyen bu çalışma vatandaş etkileşimini güçlendirme, idari işlemleri kolaylaştırma ve politika geliştirmede bu teknolojilerin rolünü ve aynı zamanda yapay zekâ kullanımının getirdiği etik sorunları ele almaktadır.
Casey (2024)	“ChatGPT in public policy teaching and assessment: An examination of opportunities and challenges”	Öğrencilerin ChatGPT kullanarak bir Avustralya Hükümeti bakanına politika özeti taslağı hazırlamalarını gerektiren yenilikçi bir değerlendirme görevini sunmakta ve öğrencilerin ChatGPT’nin kamu politikası ile öğretim ve değerlendirme süreçlerindeki rolünü nasıl algıladıklarını incelemektedir.
Aleksander vd. (2024)	“Artificial Intelligence in Public Administration: A Bibliometric Review in Comparative Perspective”	Kamu yönetimi ve iş sektöründe yapay zekâ (AI) araştırmalarını karşılaştıran bu çalışma Scopus veri tabanında 2022’ye kadar yayımlanan 1758 kamu yönetimi ve 2163 özel sektör dokümanı üzerinde yapılan bibliyometrik analizin sonuçlarını sunmaktadır. Bu minvalde de kamu yönetimindeki araştırmaların iş sektörüne göre daha hızlı büyüdüğünü ortaya koymaktadır.
National Audit Office (NAO) (2024)	“Government’s Use of Artificial Intelligence Report”	Raporda yapay zekânın kamu hizmetlerini dönüştürme potansiyeli vurgulanmış, etkili bir strateji ve kapsamlı iş süreci değişiklikleri gerektiğine işaret edilmiştir.

Kaynak: Yazarlar tarafından oluşturulmuştur.

Literatür özetinden de anlaşılacağı üzere gerek kamu yönetiminde yapay zekâ kullanımı gerekse de ombudsmanlık kurumunda yapay zekâ kullanımı konusunda akademik literatür oldukça yenidir. Zaman içerisinde ve hatta hızlı bir biçimde bu alandaki literatür boşluğunun dolacağı düşünülmektedir. Özellikle farklı coğrafyalarda yapılan literatür taramaları, hükümetlerin bu konuya büyük önem verdiğini ortaya koymaktadır. Bu yeni ve gelişmekte olan alanın, hızla daha da genişleyeceği öngörülmektedir. Çalışmada, Kamu Denetçiliği Kurumu (Ombudsmanlık) örneğinde ChatGPT’nin nasıl kullanıldığına ve bu kullanımın sonuçlarına dair örnek olay çalışmaları sunulmuştur. Bu bilgiler yapay zekânın kamu hizmetleri üzerindeki etkisinin hem pratik hem de etik boyutları açısından daha iyi anlaşılmasına katkı sağlamaktadır. Bu tür çalışmalar, yapay zekâ araçlarının kamu yönetiminde nasıl etkili bir şekilde kullanılabileceğini ve bu sürecin yönetilmesi gereken zorlukları ortaya koyarak, politika yapıcılar için önemli bir kaynak teşkil etmektedir. Çalışmanın bir sonraki başlığında da örnek olay çalışma deseni yöntemi çerçevesinde Kamu Denetçiliği Kurumunun kararlarında yapay zekâ uygulaması olan ChatGPT kullanımının nasıl sonuçlar ortaya koyduğuna yer verilmiştir.

3. Araştırmanın Metodolojisi

3.1. Araştırmanın Yöntemi

Bu çalışmada nitel analiz yöntemlerinden örnek olay çalışması deseni kullanılmıştır. Nitel araştırma, bir kavram veya olgu hakkındaki deneyimleri, davranışları ve inançları keşfetmek için sistematik ve tekrarlanabilir yöntemleri içermektedir (O'Brien, 2016). Nicel araştırmalarda yaygın olarak yapıldığı gibi hipotezleri ve teorileri test etmek ve doğrulamak yerine bunları üretmeye odaklanılmaktadır (Ponterotto, 2002). Öte yandan örnek olay çalışması tasarımı, genellikle temellendirilmiş teori ile birbirinin yerine kullanılır ancak yaklaşımı bakımından farklıdır (Ridder, 2012). Genel olarak, nitel araştırma ve örnek olay çalışması tasarımı, bağımsız yöntemler, karma yöntem yaklaşımlarının bir parçası olabilen çok yönlü araçlardır (Bristowe vd., 2015). Veri toplamak ve analiz etmek için titiz bir çerçeve sunarak çeşitli disiplinlerdeki karmaşık olgulara ilişkin değerli içgörüler sağlamaktadır. Sağlanan katkıların çeşitliliği açısından da bu çalışmada nitel analiz yöntemlerinden örnek olay çalışma deseni tercih edilmiştir.

Kamu Denetçiliği Kurumu'nun kamu personel rejimi konusundaki tavsiye kararlarının değerlendirilmesinde ChatGPT gibi yapay zekâ tabanlı uygulamaların potansiyelini incelemek amacıyla yapılmıştır. Çalışmada kullanılan yöntem, örnek olay çalışması ve incelemesi şeklindedir. Aşağıda bu yöntemin detayları sunulmuştur.

Örnek Olay Seçimi: Çalışma kapsamında, Kamu Denetçiliği Kurumu'nun kamu personel rejimi konusundaki tavsiye kararları arasından belirli sayıda karar örnek olay olarak seçilmiştir. Bu seçimde, çeşitli personel sorunlarını ve çözümlerini temsil eden kararlar dikkate alınmıştır.

Veri Toplama: Seçilen kararlar, Kamu Denetçiliği Kurumu'nun resmî web sitesinden ve ilgili raporlardan toplanmıştır. Her bir kararın metni detaylı bir şekilde incelenmiş ve kararların içeriği, dayandığı hukuki ve idari gerekçeler, alınan kararların sonuçları ve önerileri kaydedilmiştir.

Yapay Zekâ Değerlendirmesi: Toplanan karar metinleri, ChatGPT'ye sunulmuş ve bu kararların analiz edilmesi istenmiştir. ChatGPT'nin kararları nasıl değerlendirdiği, hangi unsurları vurguladığı ve hangi sonuçlara ulaştığı incelenmiştir.

Karşılaştırmalı Analiz: ChatGPT tarafından yapılan değerlendirmeler, Kamu Denetçiliği Kurumu'nun orijinal kararları ile karşılaştırılmıştır. Bu karşılaştırmada, yapay zekanın kararları nasıl yorumladığı ve orijinal kararlarla ne ölçüde örtüştüğü analiz edilmiştir.

Sonuçların Değerlendirilmesi: Yapay zekanın karar alma sürecine katkı sağlayabileceği alanlar belirlenmiştir. ChatGPT'nin sağladığı içgörüler, Kamu Denetçiliği Kurumu'nun kararlarının daha kapsamlı ve objektif bir şekilde değerlendirilmesine nasıl yardımcı olabileceği üzerine odaklanılmıştır.

Politika Önerileri: Elde edilen bulgulara dayanarak, Kamu Denetçiliği Kurumu'nun yapay zekâ tabanlı teknolojileri nasıl daha etkin bir şekilde kullanabileceği konusunda politika önerileri geliştirilmiştir. Bu öneriler, kurumun karar alma süreçlerini iyileştirmeyi ve vatandaşların sorunlarına daha hızlı ve etkili çözümler sunmayı hedeflemektedir.

Bu yöntem, Kamu Denetçiliği Kurumu'nun kamu personel rejimi konusundaki tavsiye kararlarının değerlendirilmesinde yapay zekâ teknolojilerinin potansiyelini anlamak için sistematik ve yapılandırılmış bir yaklaşım sunmaktadır. Elde edilen bulgular, yapay zekanın kurumun verimliliğini ve etkinliğini artırma potansiyelini ortaya koymayı amaçlamaktadır.

3.2. Araştırmanın Amacı ve Sorusu

Bu araştırmanın amacı, ChatGPT aracılığı ile Kamu Denetçiliği Kurumu'nun (Ombudsmanlık) kamu personel rejimi konusunda tavsiye niteliğinde aldığı kararları değerlendirmektir. Ayrıca, ChatGPT tarafından yapılan tavsiyelerin kamu personel rejimindeki iyileştirmeler üzerindeki potansiyel etkileri analiz etmek hedeflenmiştir. Bu çalışma, yapay zekâ tabanlı uygulamaların kamu kurumlarındaki karar alma süreçlerinde uygulanabilirliğini test etmek, yapay zekâ tabanlı uygulamaların karar alma süreçlerine olan katkısını anlamak ve kamu personel rejimindeki yönetim pratiğini geliştirmek amacıyla yapılmıştır.

Araştırma "ChatGPT aracılığıyla Kamu Denetçiliği Kurumu'nun (Ombudsmanlık) kamu personel rejimi konusunda tavsiye niteliğinde aldığı kararlar nasıl değerlendirilebilir ve bu tavsiyelerin uygulanmasındaki potansiyel zorluklar nelerdir?" sorusu özelinde şekillenmiştir.

3.3. Araştırmanın Evren ve Örneklemi

Nitel araştırmada, bir örnek olay çalışması tasarlamak, evren ve örneklem seçiminin dikkatli bir şekilde değerlendirilmesini gerektirir. Nitel çalışmaların amacı genelleme yapmak değil, belirli örnek olayların derinlemesine analizi yoluyla insan deneyimlerinin zengin bir şekilde anlaşılmasını sağlamaktır (Polit ve Beck, 2010). Amaçlı örnekleme, nitel araştırmalarda yaygın bir tekniktir ve bilgi açısından zengin vakaların seçilmesine olanak tanır (Karafil ve Oğuz, 2019).

Nitel arařtırmada örnekleme, arařtırma sonuçlarının kalitesini etkileyen kritik bir unsurdur. Nicel arařtırmalar genellenebilirlik için temsil edilebilirliđi vurgularken, nitel arařtırmalar tipik olarak analiz edilen örneklerin sayısının az olması nedeniyle örneklerin dikkatli bir şekilde seçilmesine odaklanır (Weis ve Willems, 2016). Teorik doygunluk, nitel arařtırma tasarımında yol gösterici bir ilkedir ve veri doygunluđunun küçük örnekleme boyutlarında bile gerçekteşebileceđini öne sürer (Boddy, 2016). Ayrıca, amaçlı örnekleme teknikleri, arařtırma çalıřması için en bilgilendirici vakaların belirlenmesine ve seçilmesine yardımcı olur (Tafur-Arciniegas ve Purzer, 2015). Örnek olay çalıřmalarında nitel arařtırma tasarımı, evren ve örnekleme seçiminde nüanslı bir yaklaşım gerektirir ve genellenebilirlikten ziyade anlayışın derinliđini vurgular.

Bu çalıřmanın evrenini, 2023 yılında Kamu Denetçiliđi Kurumu'nun (Ombudsmanlık) kamu personel rejimi konusunda almış olduđu tavsiye kararları oluřturmaktadır. Bu kararlar, Ombudsmanlık tarafından alınmış ve kamu personel rejimi ile ilgili tavsiye niteliğindeki kararları içermektedir. Örneklemin belirlenmesi için ařađıdaki adımlar izlenmiştir:

Adım: Ombudsmanlık Kararlar Bilgi Bankasına girilmiştir,

Adım: Filtre seçenekleri ayarlanmıştır. Başvuru konusu olarak "kamu personel rejimi" seçilmiş ve karar türü olarak "tavsiye karar" seçilmiştir,

Adım: Başvuru tarih aralıđı belirlenmiştir. 2023 yılı için ocak ayından aralık ayına kadar olan tarih aralıđı seçilmiştir.

Adım: Bu filtrelerle yapılan sorgulama sonucunda elde edilen tavsiye kararları, çalıřmanın örneklemini oluřturmuştur. Örnekleme her ay için bir tavsiye kararı seçilerek oluřturulması planlanmıştır. Fakat 2023 yılında ilk tavsiye kararın mart ayında çıkması ve aralık ayında yapılan başvuruların karar tarama işleminin tamamlanmamış olması sebebi ile her ay için bir tavsiye karar seçilememiştir. Bu durum çalıřmanın kısıtını oluřturmuş ve ocak, şubat ve aralık ayları örneklemin dışında tutulmuştur. Bu durumda, 2023 yılında kamu personel rejimi konusunda toplam 9 tavsiye karar örnekleme dâhil edilmiştir.

Tablo 2. Arařtırmanın Örneklemini Oluřturan Tavsiye Niteliğindeki Kararlar

Örnekleme Kodu	Karar Tarihi	Başvuru Konu Daire	Başvuru No
O1	30/03/2023	Millî Eđitim Bakanlığı	2023/439
O2	10/04/2023	Çalıřma ve Sosyal Güvenlik Bakanlığı, İçiřleri Bakanlığı, Millî Savunma Bakanlığı	2023/439
O3	22/05/2023	Konya Büyükşehir Belediye Başkanlıđı	2023/3125
O4	06/06/2023	Gençlik ve Spor Bakanlığı	2023/2326
O5	17/07/2023	Kahramanmaraş Valiliđi	2023/1503
O6	22/08/2023	Afet ve Acil Durum Yönetimi Başkanlıđı	2023/3113
O7	19/09/2023	Yozgat İl Sađlık Müdürlüđü	2023/3750
O8	27/10/2023	İçiřleri Bakanlığı	2023/7962
O9	22/11/2023	Türkiye Radyo-Televizyon Kurumu Genel Müdürlüđü	2023/8908

3.4. Arařtırmanın Kapsamı ve Veri Toplama Aracı

Bu arařtırma, Kamu Denetçiliđi Kurumu'nun (Ombudsmanlık) 2023 yılında kamu personel rejimi konusunda almış olduđu 9 adet tavsiye kararların ChatGPT aracılıđı ile incelenmesini kapsamaktadır. Diđer konu başlıkları altında alınan kararlar arařtırmaya dâhil edilmemiştir. Arařtırma kapsam olarak Ombudsmanlık tarafından kamu personel rejimi konusunda alınan tavsiye niteliğindeki kararları ele almış ve bu kararların ChatGPT aracılıđıyla deđerlendirilmesinin mümkün olup olmadıđını arařtırmıştır.

Arařtırmada veri toplama aracı olarak ikincil verilerden yararlanılmıştır. Ombudsmanlık kararları, Ombudsmanlık Web Sitesinden (<https://www.ombudsman.gov.tr/>) filtreleme işlemi yapılarak çekilmiş ve analiz edilmiştir. Filtreleme işlemi, başvuru konusu olarak "kamu personel rejimi" ve karar türü olarak "tavsiye karar" seçilerek yapılmıştır. Bu şekilde elde edilen veriler, ChatGPT aracılıđıyla analiz edilerek kararların etkinliđi ve uygulanabilirliđi üzerine deđerlendirmeler bir sonraki başlıkta yapılmıştır.

3.5. Verilerin Analizi

Bu çalıřmada, ChatGPT 3.5 sürümü, Ombudsmanlık tarafından alınan tavsiye kararlarını analiz etmek ve bu kararların uygulanabilirliđi üzerine deđerlendirmeler yapmak için kullanılmıştır. Verilerin analizi için veriler O1-O9 arasında kodlanmıştır. İlk olarak Ombudsmanlıđa başvuranın iddia ve talepleri yazılmış, buna iliřkin olarak alınan tavsiye karar yazılmış ve sonrasında başvuranın iddia ve talepleri ile kararın ChatGPT tarafından deđerlendirilmesine iliřkin yanıtına yer verilmiştir. Analiz bulguların deđerlendirilmesi noktasında her kod alt başlık halinde deđerlendirilmiştir. Ombudsmanlık Kararlar Bilgi Bankasından elde edilen örneklemler 5 (beş) kategoride toplanmıştır. Bu kategoriler Başvuru Konu Daire, Başvuru No, Başvuranın İddia ve Talepleri ile karardan oluřmaktadır. Elde edilen veriler ChatGPT'ye prompt (istem) girilerek analiz edilmiştir.

ChatGPT kullanımı bağlamında, bir prompt (istem), yanıt üretimini yönlendirmek için yapay zekâ modeline verilen bir talimat veya ipucu anlamına gelmektedir. Yönlendirmeler karmařıklık, özgünlük ve içerik açısından farklılık gösterebilir ve üretilen yanıtların kalitesini ve uygunluđunu etkileyebilir (Hartley vd., 1990). Etkili promptlar yapay zekâ modeline, çıktısını aşırı derecede kısıtlamadan, özgünlük ve genellik arasında bir denge kurarak açık bir rehberlik sađlamalıdır (Cooper vd., 2016). Arařtırmalar, iyi hazırlanmış promptların ChatGPT gibi yapay zekâ modellerinin klinik dokümantasyon yardımı (Baker, 2023), dil öğrenme (Kim vd.,

2023) ve değerlendirme süreçleri (Ferretti, 2023) gibi çeşitli görevlerdeki performansını artırabileceğini göstermiştir.

Çalışmada ChatGPT değerlendirmesi için girilen prompt “Kamu Denetçiliği Kurumda çalışan bir Kamu Denetçisisin. Kamu Personel Rejimi konusunda yapılan başvurular için tavsiye niteliğinde karar veriyorsun. Başvuranın iddia ve talebi “...” bu şekildedir ve Kamu Denetçiliği Kurumu karar olarak “...” bu kararı vermiştir. Sen Kamu Denetçisi olsan bu başvuru iddia ve talebine nasıl bir tavsiye kararı verirdin? Verilmiş olan bu kararı nasıl değerlendiriyorsun? şeklindedir. Her örneklem için aynı prompt tekrarlanmıştır. Prompt için “..” şeklinde gösterilen yerlere iddia ve talep ile tavsiye niteliğindeki karar yazılarak ChatGPT’nin değerlendirilmesi için kullanılmıştır.

4. Bulguların Değerlendirilmesi

O1-O9 kodlu verilerin analizi için girilen promptlar ve sonucunda elde edilen ChatGPT değerlendirilmesi aşağıda yer alan maddelerde sıralanmıştır.

4.1. O1 Kodlu Verinin Değerlendirilmesi

Başvuru Konu Daire: Millî Eğitim Bakanlığı

Başvuru No: 2023/439

Karar Tarihi: 30/03/2023

Başvuranın İddia ve Talepleri: “Millî Eğitim Bakanlığında Bişkek Eğitim Müşaviri, daire başkanlığı ve şube müdürlüğü görevlerinde bulunduğunu, mevzuat gereği Bakanlık Müfettişi veya Kurum Uzmanı olarak atanması gerekirken, araştırmacı unvanı ile atandığını iddia ve şikâyet ederek, mevzuat kapsamında ve emsal atamalar dikkate alınarak hak ettiği Milli Eğitim Uzmanı veya Bakanlık Müfettişliği kadrolarından birine atanması için Kurumumuza başvuruda bulunmuştur.”

Karar: “Açıklanan gerekçeler ve dosya kapsamına göre; başvurunun kabulüne, açıklanan gerekçelerle, başvuranın durumuna uygun bir kadroya (Millî Eğitim Uzmanı veya Bakanlık Müfettişliği) atanması yönünde Millî Eğitim Bakanlığına tavsiyede bulunulmasına, kararın başvurana, gereği için millî eğitim bakanlığına tebliğine;”

ChatGPT Değerlendirmesi: Başvuranın iddia ve talebine yönelik olarak, mevzuat gereği belirli kadrolara atanması gerektiği iddiası dikkate alındığında, başvurunun kabul edilmesi ve başvurana uygun bir kadroya atanması yönünde bir tavsiye kararı verilebilir. Ancak, bu tavsiye kararının tam olarak hangi kadroya atanması gerektiği konusunda daha detaylı bir inceleme gerektirebilir. Verilen kararın başvurana tebliği ve gereği için Millî Eğitim Bakanlığı’na iletilmesi önemlidir.

Analiz Sonucunun Özeti: Bu kararı değerlendirirken, Kamu Denetçiliği Kurumu’nun başvuruyu detaylı bir şekilde incelediği ve başvuranın durumuna uygun bir kadroya atanması yönünde bir tavsiye kararı verdiği görülmektedir. Bu kararın, başvuranın haklarının korunması ve adaletin sağlanması açısından olumlu bir adım olduğu söylenebilir.

4.2. O2 Kodlu Verinin Değerlendirilmesi

Başvuru Konu Daire: Çalışma ve Sosyal Güvenlik Bakanlığı, İçişleri Bakanlığı, Millî Savunma Bakanlığı

Başvuru No: 2023/3704

Karar Tarihi: 10/04/2023

Başvuranın İddia ve Talepleri: “Kurumumuza yaptığı başvuruda başvuran, sözleşmeli er/erbaş olarak görev yapıp 7 hizmet yılını tamamladığını, 6191 sayılı Kanun’un Ek-1’inci maddesi kapsamında kamu kurum ve kuruluşlarının boş kadro ve pozisyonlarına atanmak istediğini, ancak anılan düzenlemede belirtilen Yönetmeliğin hazırlanıp yürürlüğe konulmaması nedeniyle atanmadığını belirtmektedir. Başvuran, Kurumumuzdan Yönetmeliğin yürürlüğe konulmasını talep etmektedir.”

Karar: “Açıklanan gerekçelerle Başvurunun Kabulüne; 6191 sayılı Kanun’un Ek-1 inci maddesinde belirtilen Yönetmelik taslağına ilişkin görüşlerin ivedilikle Millî Savunma Bakanlığına iletilmesi ve sonrasında taslağın hazırlanmasına ilişkin Millî Savunma Bakanlığınca talep edilebilecek işlemlerin de gecikmeksizin tamamlanması hususunda İçişleri Bakanlığınca Ve Çalışma ve Sosyal Güvenlik Bakanlığınca Tavsiyede Bulunulmasına, 6191 sayılı Kanun’un Ek-1 inci maddesinde belirtilen Yönetmelik taslağına ilişkin görüşlerin hızla değerlendirilmesi ve Yönetmeliğin imzaya sunulması işlemlerinin ivedilikle tamamlanması hususunda Millî Savunma Bakanlığınca Tavsiyede Bulunulmasına;”

ChatGPT Değerlendirmesi: Başvuranın iddiası ve talebi, 6191 sayılı Kanun’un Ek-1’inci maddesi kapsamında kamu kurum ve kuruluşlarının boş kadro ve pozisyonlarına atanmak istemesi, ancak ilgili Yönetmeliğin hazırlanıp yürürlüğe konulmaması nedeniyle atanmaması şeklinde özetlenebilir. Kamu Denetçiliği Kurumu ise başvuruyu inceledikten sonra, 6191 sayılı Kanun’un Ek-1 inci maddesinde belirtilen Yönetmelik taslağına ilişkin görüşlerin hızla değerlendirilmesi ve Yönetmeliğin imzaya sunulması işlemlerinin

ivedilikle tamamlanması hususunda Millî Savunma Bakanlığı'na tavsiyede bulunmuştur.

Analiz Sonucunun Özeti: Bu başvuruya yönelik bir tavsiye kararı verirken, başvuranın haklı talebini dikkate alarak, 6191 sayılı Kanun'un Ek-1 inci maddesinde belirtilen Yönetmelik taslağına ilişkin işlemlerin hızla tamamlanması yönünde bir tavsiye kararı verilebilir. Bu şekilde, başvuranın talebinin yerine getirilmesi için gerekli adımların atılması sağlanmış olur. Verilen kararı değerlendirirken, Kamu Denetçiliği Kurumu'nun başvuruyu detaylı bir şekilde incelediği ve başvuranın haklı talebini dikkate alarak ilgili kurumlara tavsiyede bulunduğu görülmektedir. Bu kararın, başvuranın haklarının korunması ve adaletin sağlanması açısından olumlu bir adım olduğu söylenebilir.

4.3. O3 Kodlu Verinin Değerlendirilmesi

Başvuru Konu Daire: Konya Büyükşehir Belediye Başkanlığı

Başvuru No: 2023/3125

Karar Tarihi: 22/05/2023

Başvuranın İddia ve Talepler: "Kurumumuza yaptığı başvuruda başvuran, 11/11/2022 tarihinde yayımlanan Konya Büyükşehir Belediyesi Başkanlığına istihdam ilanına başvurduğu, alınacak 144 adayın 5 katı kadar adayın sözlü sınav çağırıldığını, ancak 58 kişinin alındığını belirtmektedir. Başvuran, sözlü sınavı çağırılıp sonrasında istihdam edilmeyenlere herhangi bir gerekçe sunulmadığını, bölümler arasında en yüksek KPSS puanı alanların mimarlar olmasına karşın hiç mimar istihdam edilmediğini açıklamaktadır. Başvuran, Kurumumuzdan mimar alımının detaylı bir şekilde incelenmesini ve mimarların atamasının yapılmasını talep etmektedir."

Karar: "Açıklanan gerekçelerle Başvurunun Kabulüne; Başvuruya konu gelir uzman yardımcılığı sınavının başvuran açısından iptal edilerek hukuka, hakkaniyete ve iyi yönetim ilkelerine uygun olacak şekilde yeni bir sözlü sınav düzenlenmesi; bundan sonra düzenlenecek sözlü sınavların iyi yönetim ilkelerinden olan "nesnellik", "tarafsızlık", "şeffaflık", "hesap verilebilirlik" ve "kararların gerekçeli olması" ilkelerine uygun yapılmasını teminen, adaylara verilen puanların gerekçelerini ortaya koyacak tedbirlerin ve sınavların ses ve görüntü ile kayıt altına alınması hususunda Konya Büyükşehir Belediye Başkanlığına Tavsiyede Bulunulmasına;"

ChatGPT Değerlendirmesi: Başvuranın iddiası ve talebi, Konya Büyükşehir Belediyesi Başkanlığı tarafından yapılan istihdam ilanına başvurduktan sonra, sözlü sınavda başarılı olmasına rağmen istihdam edilmediğini ve bu süreçte şeffaflık ve adil bir şekilde işlem yapılmadığını belirtmektedir. Kamu Denetçiliği Kurumu ise başvuruyu inceledikten sonra, sözlü sınavın başvuran açısından iptal edilerek yeni bir sözlü sınav düzenlenmesi, bu süreçte adaylara verilen puanların gerekçelerini ortaya koyacak tedbirler alınması ve sınavların ses ve görüntü ile kayıt altına alınması yönünde Konya Büyükşehir Belediye Başkanlığı'na tavsiyede bulunmuştur.

Analiz Sonucunun Özeti: Bu başvuruya yönelik bir tavsiye kararı verirken, başvuranın şeffaf ve adil bir şekilde değerlendirilmesi gerektiği, sözlü sınavda başarılı olmasına rağmen atama sürecinin şeffaflık ilkesine uygun olmadığı göz önünde bulundurulmalıdır. Bu nedenle, sözlü sınavın iptal edilerek yeni bir sınav düzenlenmesi, adaylara verilen puanların gerekçelerini ortaya koyacak tedbirler alınması ve sınavların ses ve görüntü ile kayıt altına alınması, adil bir sürecin sağlanması açısından önemli adımlar olabilir. Verilen kararı değerlendirirken, Kamu Denetçiliği Kurumu'nun başvuruyu detaylı bir şekilde incelediği ve adil bir sürecin sağlanması için gerekli tavsiyelerde bulunduğu görülmektedir. Bu kararın, başvuranın haklarının korunması ve adil bir şekilde işlem yapılması açısından olumlu bir adım olduğu söylenebilir.

4.4. O4 Kodlu Verinin Değerlendirilmesi

Başvuru Konu Daire: Gençlik ve Spor Bakanlığı

Başvuru No: 2023/2326

Karar Tarihi: 06/06/2023

Başvuranın İddia ve Talepleri: "Başvuran, Samsun Gençlik ve Spor İl Müdürlüğünde Sözleşmeli Yurt Yönetim Personeli olarak görev yaptığını, Havza Yurt Müdürlüğünde görevlendirildiğini, Turgut Özal Öğrenci Yurdunda 1 kişilik boş kadro olduğu bilgisine ulaştığını belirterek İl merkezine görevli olduğu yer arasında 81 km mesafe olması nedeni ile merkeze naklini talep etmektedir."

Karar: "Başvuranın talebinin kamu yararı ve hizmet gerekleri göz önünde bulundurularak yeniden değerlendirilmesi hususunda Gençlik ve Spor Bakanlığına Tavsiyede Bulunulmasına,"

ChatGPT Değerlendirmesi: Başvuranın iddiası ve talebi, Samsun Gençlik ve Spor İl Müdürlüğünde görevli olduğu halde Havza Yurt Müdürlüğünde görevlendirildiğini ve bu görevlendirmenin neden olduğu 81 km mesafe nedeniyle merkeze naklini talep ettiğini belirtmektedir. Kamu Denetçiliği Kurumu ise başvuruyu inceledikten sonra, başvuranın talebinin kamu yararı ve hizmet gerekleri

göz önünde bulundurularak yeniden değerlendirilmesi hususunda Gençlik ve Spor Bakanlığı'na tavsiyede bulunmuştur.

Analiz Sonucunun Özeti: Bu başvuruya yönelik bir tavsiye kararı verirken, başvuranın talebinin haklılığı ve kamu yararı açısından değerlendirilmesi önemlidir. Başvuranın görev yerinin merkeze olan uzaklığı nedeniyle yaşadığı zorluklar dikkate alındığında, başvurunun kabul edilerek merkeze naklinin yapılması veya alternatif çözüm önerilerinin değerlendirilmesi gerekebilir. Verilen kararı değerlendirirken, Kamu Denetçiliği Kurumu'nun başvuruyu detaylı bir şekilde incelediği ve başvuranın talebinin kamu yararı ve hizmet gerekleri doğrultusunda yeniden değerlendirilmesi gerektiği yönünde Gençlik ve Spor Bakanlığı'na tavsiyede bulunduğu görülmektedir. Bu kararın, başvuranın haklarının korunması ve adaletin sağlanması açısından olumlu bir adım olduğu söylenebilir.

4.5. 05 Kodlu Verinin Değerlendirilmesi

Başvuru Konulu Daire: Kahramanmaraş Valiliği

Başvuru No: 2023/1503

Karar Tarihi: 17/07/2023

Başvuranın İddia ve Talepleri: "Kurumumuza yapılan başvuruda başvuran; Kahramanmaraş Mesleki Ve Teknik Anadolu Lisesinde çalıştığını, doğum yaptıktan sonra idareye gerekli doğum evraklarını teslim ettiğini doğum olayının gerçekleştiği tarihi takip eden aybaşından itibaren çocuk yardımı ödeneğine hak kazanmasına rağmen e-bordrosunu kontrol ettiği 06.06.2022 tarihine kadar çocuk yardımı ödeneğini almadığını fark ettiğini, İdarenin tarafına en fazla geriye dönük üç ay için çocuk yardımı ödediğini (Nisan-Mayıs-Haziran 2022) belirterek, doğum yaptığı 21.10.2020 tarihinden itibaren geriye dönük çocuk yardımının tamamının tarafına ödenmesini talep etmektedir."

Karar: "Açıklanan gerekçelerle Başvurunun Kabulüne; Başvuranın talep ettiği aile yardımı (Çocuk) ödeneğinin, ödenmemiş olan kısmının, geriye dönük olarak ödenmesi yönünde Kahramanmaraş Valiliğine Tavsiyede Bulunulmasına,"

ChatGPT Değerlendirmesi: Başvuranın iddiası ve talebi, doğum yaptıktan sonra çocuk yardımı ödeneğine hak kazanmasına rağmen ödemelerin eksik yapıldığı ve geriye dönük olarak tamamlanmasını talep ettiği şeklindedir. Kamu Denetçiliği Kurumu ise başvuruyu inceledikten sonra, başvuranın talep ettiği çocuk yardımı ödeneğinin ödenmemiş olan kısmının geriye dönük olarak ödenmesi yönünde Kahramanmaraş Valiliği'ne tavsiyede bulunmuştur.

Analiz Sonucunun Özeti: Bu başvuruya yönelik bir tavsiye kararı verirken, başvuranın talebinin haklılığı ve kanuni haklarının korunması önemlidir. Başvuranın doğum olayını takip eden aybaşından itibaren çocuk yardımı ödeneğine hak kazandığı ve bu ödemelerin eksik yapıldığı belirtilmektedir. Bu nedenle, başvuranın talep ettiği çocuk yardımı ödeneğinin geriye dönük olarak tamamlanması ve eksik ödemelerin yapılması gerekebilir. Verilen kararı değerlendirirken, Kamu Denetçiliği Kurumu'nun başvuruyu detaylı bir şekilde incelediği ve başvuranın talebinin haklılığı doğrultusunda Kahramanmaraş Valiliği'ne tavsiyede bulunduğu görülmektedir. Bu kararın, başvuranın haklarının korunması ve adaletin sağlanması açısından olumlu bir adım olduğunu söylenebilir.

4.6. 06 Kodlu Verinin Değerlendirilmesi

Başvuru Konulu Daire: Afet ve Acil Durum Yönetimi Başkanlığı

Başvuru No: 2023/3113

Başvuru Tarihi: 22/08/2023

Başvuru İddia ve Talepleri: "Başvuran, başvurusunda özetle; Afet ve Acil Durum Yönetimi Başkanlığının sınav, eğitim ve afet görevlendirilmelerinde kurbağa adam ve dalgıç unvanıyla tarafına görev verildiğini, bu kapsamda ilgili mevzuat gereğince tarafına dalgıçlık tazminatı ödenmesi gerektiğini belirterek, 3160 sayılı Kanun'un 6 ıncı maddesi ve Afet ve Acil Durum Yönetimi Başkanlığı Su Altı Arama Kurtarma Ekibi ve Kurbağa Adam Personel Yönergesinin 3 üncü maddesi gereği sınavı kazandığı tarih itibarıyla yapılan görevlendirmeler için tarafına ödenmeyen dalış tazminatının yasal faizi birlikte ödenmesini talep etmektedir."

Karar: "Açıklanan gerekçelerle Başvurunun Kabulüne; Başvurana dalış tazminatının hak ediş tarihinden itibaren işletilecek yasal faiziyle birlikte ödenmesi hususunda Afet ve Acil Durum Yönetimi Başkanlığına Tavsiyede Bulunulmasına,"

ChatGPT Değerlendirmesi: Başvuranın iddiası ve talebi, Afet ve Acil Durum Yönetimi Başkanlığı'nda görevlendirilen kurbağa adam ve dalgıç unvanıyla çalışmasına rağmen dalış tazminatının ödenmemesi üzerine yasal faiziyle birlikte ödenmesini talep etmektedir. Kamu Denetçiliği Kurumu ise başvuruyu inceledikten sonra, başvuranın talep ettiği dalış tazminatının hak ediş tarihinden itibaren işletilecek yasal faiziyle birlikte ödenmesi yönünde Afet ve Acil Durum Yönetimi Başkanlığı'na tavsiyede bulunmuştur.

Analiz Sonucunun Özeti: Bu başvuruya yönelik bir tavsiye kararı verirken, başvuranın haklı talebini dikkate alarak, dalış tazminatının hak ediş tarihinden itibaren işletilecek yasal faiziyle birlikte ödenmesi yönünde bir karar verilebilir. Başvuranın

belirttiği mevzuat hükümleri ve görevlendirmeleri dikkate alındığında, bu tazminatın ödenmesi gerektiği açıktır. Verilen kararı değerlendirirken, Kamu Denetçiliği Kurumu'nun başvuruyu detaylı bir şekilde incelediği ve başvuranın haklı talebini dikkate alarak Afet ve Acil Durum Yönetimi Başkanlığı'na tavsiyede bulunduğu görülmektedir. Bu kararın, başvuranın haklarının korunması ve adaletin sağlanması açısından olumlu bir adım olduğunu söylenebilir.

4.7. 07 Kodlu Verilerin Değerlendirilmesi

Başvuru Konulu Daire: Yozgat İl Sağlık Müdürlüğü

Başvuru No: 2023/3750

Karar Tarihi: 19/09/2023

Başvuru İddia ve Talepleri: "Kurumumuza yapılan başvuruda başvuran özetle, İlçesi No.lu Aile Hekimliği Biriminde aile sağlığı elemanı olarak göreve yapmakta olduğunu, yıllık izin ve rapor kullandığı dönemlere ilişkin olarak ücret kesintileri yapıldığını ifade ederek yapılan kesintilerin kesinti tarihinden itibaren yasal faizi ile birlikte tarafına ödenmesini talep etmektedir."

Karar: "Yukarıda açıklanan gerekçe ve dosya kapsamına göre Başvurunun Kabulüne, Başvuranın kullandığı izinler nedeniyle ücretinden yapılan kesintilerin yasal faiz uygulanarak tarafına ödenmesi ve başvuranın mağduriyetinin giderilmesi hususunda Yozgat İl Sağlık Müdürlüğüne Tavsiyede Bulunulmasına,"

ChatGPT Değerlendirmesi: Başvuranın iddiası ve talebi, İlçesi No.lu Aile Hekimliği Biriminde aile sağlığı elemanı olarak görev yaparken yıllık izin ve rapor kullandığı dönemlerde ücretinden yapılan kesintilerin yasal faizi ile birlikte tarafına ödenmesini talep etmektedir. Kamu Denetçiliği Kurumu ise başvuruyu inceledikten sonra, başvuranın kullandığı izinler nedeniyle ücretinden yapılan kesintilerin yasal faiz uygulanarak tarafına ödenmesi ve başvuranın mağduriyetinin giderilmesi yönünde Yozgat İl Sağlık Müdürlüğü'ne tavsiyede bulunmuştur.

Analiz Sonucunun Özeti: Bu başvuruya yönelik bir tavsiye kararı verirken, başvuranın talebinin haklılığı ve mağduriyetinin giderilmesi önemlidir. Başvuranın kullandığı izinler nedeniyle yapılan kesintilerin yasal faiz uygulanarak tarafına ödenmesi talebi, izinlerin yasal haklarını kullanırken mağdur edilmemesi gerektiği açısından önemlidir. Verilen kararı değerlendirirken, Kamu Denetçiliği Kurumu'nun başvuruyu detaylı bir şekilde incelediği ve başvuranın mağduriyetinin giderilmesi için Yozgat İl Sağlık Müdürlüğü'ne tavsiyede bulunduğu görülmektedir. Bu kararın, başvuranın haklarının korunması ve adaletin sağlanması açısından olumlu bir adım olduğu söylenebilir.

4.8. 08 Kodlu Verilerin Değerlendirilmesi

Başvuru Konulu Daire: İçişleri Bakanlığı

Başvuru No: 2023/7962

Karar Tarihi: 27/10/2023

Başvuru İddia ve Talepleri: "Başvuran, 375 sayılı KHK'nın geçici 35 inci maddesi gereğince İçişleri Bakanlığının 27.07.2022 tarih ve / sayılı onayı ile kamu görevinden çıkarıldığını, Mersin 2. İdare Mahkemesine açmış olduğu dava neticesinde göreve iadesine, yasal özlük ve parasal haklarının faizi ile ödenmesine karar verildiğini, idare tarafından karara yapılan itiraz neticesinde Adana Bölge İdare Mahkemesince yürütmenin durdurulması talebinin reddedildiğini, mahkeme kararlarına rağmen göreve başlatılmadığını, yasal ve özlük haklarına dair iadelerin yapılmadığını belirterek; mahkeme kararlarının yerine getirilerek, göreve başlatılmayı, özlük ve parasal haklarının yasal faizi ile iadesini talep etmektedir."

Karar: "Yukarıda açıklanan gerekçe ve dosya kapsamına göre, Başvurunun Kabulü ile; Mersin 2. İdare Mahkemesinin 22.11.2022 tarih ve E: / K: / sayılı kararı gereğince başvuranın yoksun kaldığı özlük haklarının iadesi ve mali haklarının yasal faizleri ile birlikte ödenmesi yönünde İçişleri Bakanlığına Tavsiyede Bulunulmasına,"

ChatGPT Değerlendirmesi: Başvuranın iddiası ve talebi, 375 sayılı KHK'nın geçici 35. maddesi gereğince İçişleri Bakanlığı tarafından kamu görevinden çıkarıldıktan sonra açtığı davada göreve iadesine ve özlük parasal haklarının faiziyle ödenmesine karar verilmesine rağmen, mahkeme kararlarının yerine getirilmediğini ve yasal haklarının iadesinin yapılmadığını belirtmektedir. Kamu Denetçiliği Kurumu ise başvuruyu inceledikten sonra, başvuranın yoksun kaldığı özlük haklarının iadesi ve mali haklarının yasal faizleriyle birlikte ödenmesi yönünde İçişleri Bakanlığı'na tavsiyede bulunmuştur.

Analiz Sonucunun Özeti: Bu başvuruya yönelik bir tavsiye kararı verirken, başvuranın mahkeme kararlarına rağmen yasal haklarının iadesi ve mali haklarının ödenmemesi durumu dikkate alınmalıdır. Başvuranın talebi, yasal süreçler sonucunda hak ettiği özlük ve parasal haklarının yerine getirilmesi gerektiği şeklinde yorumlanabilir. Verilen kararı değerlendirirken, Kamu Denetçiliği Kurumu'nun başvuruyu detaylı bir şekilde incelediği ve başvuranın yasal haklarının yerine getirilmesi için İçişleri Bakanlığı'na

tavsiyede bulunduğu görülmektedir. Bu kararın, başvuranın mağduriyetinin giderilmesi ve adaletin sağlanması açısından olumlu bir adım olduğu söylenebilir.

4.9. O9 Kodlu Verilerin Değerlendirilmesi

Başvuru Konulu Daire: Türkiye Radyo-Televizyon Kurumu Genel Müdürlüğü

Başvuru No: 2023/8908

Karar Tarihi: 22/11/2023

Başvuru İddia ve Talepleri: “Kurumumuza yapılan başvuruda başvuran; 2014 yılından itibaren Türkiye Radyo Televizyon Kurumu Genel Müdürlüğü İstanbul Televizyonunda kadrolu mühendis olarak çalıştığını, Ankara ilinde yalnız ikamet eden ve yaşlarına bağlı olarak çok ciddi sağlık sorunları olan anne ve babasının bakım ve tedavileriyle ilgilenmek için Ankara ilinde uygun bir göreve atanmasının yapılması talebiyle 27.06.2022 ve 07.11.2022 tarihlerinde dilekçe ile Kurumuna müracaatta bulunduğunu; ancak talebinin bugüne kadar kabul edilmediği gibi net olmayan cevaplar ile belirsiz bırakıldığını, son olarak 01.03.2023 tarihinde talebini yenilemesine rağmen tarafına cevap verilmediğini belirterek ailesinin sağlık durumunun göz önünde bulundurularak Ankara iline tayininin yapılmasını talep etmektedir.”

Karar: “Yukarıda açıklanan gerekçe ve dosya kapsamına göre Başvurunun Kabulüne; Başvuranın anne ve babasının sağlık durumu gözetilerek tayin talebinin yeniden değerlendirilmesi hususunda Türkiye Radyo-Televizyon Kurumu Genel Müdürlüğüne Tavsiyede Bulunulmasına,”

ChatGPT Değerlendirmesi: Başvuranın iddiası ve talebi, Türkiye Radyo Televizyon Kurumu’nda mühendis olarak çalışırken, ailesinin sağlık durumlarına bakmak için Ankara’ya atanma talebi olduğunu belirtmektedir. Ancak talebinin bugüne kadar kabul edilmediğini ve net olmayan cevaplarla belirsiz bırakıldığını ifade etmektedir. Kamu Denetçiliği Kurumu ise başvuruyu inceledikten sonra, başvuranın anne ve babasının sağlık durumu göz önünde bulundurularak Ankara’ya atanma talebinin yeniden değerlendirilmesi hususunda Türkiye Radyo Televizyon Kurumu’na tavsiyede bulunmuştur.

Analiz Sonucunun Özeti: Bu başvuruya yönelik bir tavsiye kararı verirken, başvuranın ailesinin sağlık durumunu göz önünde bulundurularak insanî ve ahlaki açıdan haklı talebini değerlendirmek önemlidir. Başvuranın ailesine destek olmak için yapmış olduğu bu talebin, insani bir ihtiyaç olduğu ve makul bir talep olduğu düşünülmektedir. Verilen kararı değerlendirirken, Kamu Denetçiliği Kurumu’nun başvuruyu detaylı bir şekilde incelediği ve başvuranın talebinin ahlaki ve insani gereklilikler doğrultusunda değerlendirilmesi gerektiğini belirttiği görülmektedir. Bu kararın, başvuranın ailesine olan sorumluluklarını yerine getirebilmesi için adil ve insani bir yaklaşım olduğu söylenebilir.

Çalışmanın analiz aşamasında, Kamu Denetçiliği Kurumu’nun kamu personel rejimi konusundaki tavsiye kararları ile ChatGPT’nin değerlendirmeleri karşılaştırılmıştır. İlk olarak, seçilen kararların metinleri detaylı bir şekilde incelenmiş ve her bir kararın içeriği, hukuki dayanakları ve sonuçları belirlenmiştir. ChatGPT’nin bu kararları analiz etmesi sağlanmış ve yapay zekanın hangi unsurları vurguladığı, hangi gerekçelerle sonuçlara ulaştığı değerlendirilmiştir. Bu süreçte, ChatGPT’nin kararları oldukça objektif bir şekilde yorumladığı ve genellikle insan karar vericilerle benzer sonuçlara ulaştığı gözlemlenmiştir.

Yapay zekâ tabanlı ChatGPT’nin sağladığı analizler, Kamu Denetçiliği Kurumu’nun tavsiye kararlarının kapsamlı bir değerlendirmesini sunmuştur. ChatGPT, kararların dayandığı hukuki ve idari gerekçeleri detaylı bir şekilde ele almış ve her bir kararın sonuçlarını açıklıkla ifade etmiştir. Bu analizler, orijinal kararlarla büyük ölçüde örtüşmüş ve yapay zekanın karar alma sürecine katkı sağlayabileceğini göstermiştir. Özellikle, ChatGPT’nin büyük veri setlerini hızlı bir şekilde analiz edebilme yeteneği, kararların daha geniş bir perspektiften değerlendirilmesine olanak tanımıştır.

ChatGPT’nin sağladığı içgörüler, Kamu Denetçiliği Kurumu’nun karar alma süreçlerini destekleyebilecek önemli bir potansiyele sahiptir. Yapay zekâ, kararların objektif bir şekilde analiz edilmesine ve çeşitli açılardan değerlendirilmesine yardımcı olabilir. Bu da kurumun verimliliğini artırabilir ve vatandaşların sorunlarına daha hızlı ve etkili çözümler sunulmasına katkı sağlayabilir. Bu bulgular, yapay zekâ tabanlı teknolojilerin Kamu Denetçiliği Kurumu gibi denetim mekanizmalarında nasıl daha etkin bir şekilde kullanılabileceği konusunda önemli ipuçları sunmaktadır.

Değerlendirme ve Sonuç

İnsanoğlu geçmişten günümüze değin bazı temel hak ve özgürlüklerin korunması ve belirli kurallara bağlanarak bunun temininin sağlanması amacıyla çalışmıştır. Bu çalışmaların bir neticesi olarak dünya genelinde pek çok ülkede idarenin işlem ve eylemleri karşısında vatandaşların korunması, insan haklarına ve hukukun üstünlüğüne dayalı bir anlayışın ortaya çıkarak gelişmesi adına yargısal denetim ve diğer denetim yolları kullanılmaktadır. Hesap verebilir ve şeffaf yönetim anlayışının da bir yansıması olan denetim mekanizmaları bir yandan vatandaşları korurken öte yandan da toplumda uzlaşma kültürünü yerleştirmek ve temel hak

ve özgürlükleri güvence altına almak gibi bir misyon üstlenmiştir. Toplumun zaman içerisinde elde ettiği temel hak ve özgürlükler ile hak arama kültürünün yaygınlaşması alternatif denetim mekanizmalarının da ortaya çıkmasına sebep olmuştur. Bu mekanizmalardan en önemlisi olan dünyada Ombudsman olarak varlık gösteren ve yaygınlaşan Kamu Denetçiliği Kurumudur. Farklı ülkelerde farklı kullanım şekli olsa da temelde vatandaşların haklarını korumayı amaçlayan bu kurum, idare ile birey arasında hak arama, uzlaşma ve müzakereye dayalı çağdaş yönetim anlayışının oluşmasına fırsat vermektedir.

Dünyada 1980 sonrasında yaşanan hızlı değişim ve dönüşüm süreci ile birlikte ombudsmanlık kurumları da değişime ayak uydurarak vatandaşların ihtiyaçlarını dikkate almıştır. Genel ombudsmanlık kurumlarının yanı sıra kadın, çocuk, tüketici, üniversite, yerel yönetimler, engelli gibi pek çok özel ombudsmanlık türlerine ilişkin kurumsal yapılar oluşmuştur. Yukarıda da belirtildiği üzere dünyada hızlı bir değişim yaşanmakta ve hala da hız kesmeden devam etmektedir. Bu değişimin fitilini ateşleyen unsur internetin vatandaşlar tarafından kullanılması ve kamu kurumlarının hizmetlerini elektronik ortamda sunar hale gelmesi olmuştur.

Yaklaşık son on yıldır dünyanın neresinde olursa olsun pek çok insan giderek artan bir şekilde dijital teknolojilerin muhatabı olmaktadır. İnternetin hız ve yaygınlığının artması, bunun aksine internet ve diğer dijital teknolojileri kullanacak cihazların donanımsal ebatlarının küçülmesi ve başta sosyal medya mikro blog siteleri olmak üzere pek çok dijital uygulamanın ortaya çıkması hayatın artık kesinlikle eskisi gibi olmayacağı duygusunu güçlendirmektedir. Günlük yaşantımıza “en son teknoloji” başlığı altında giren bu yenilikler asla gelip geçici, dönemsel bir teknolojik moda olarak görülmemelidir. Aksine tam merkezinde yapay zekânın yer aldığı bu teknolojik değişimler toplumlara baştan ayağa değiştirerek 21. yüzyılı bir Dijital Çağ hâline getirmiştir. Elbette, içinde yer alma sürecinin hızlıca devam ettiği yeni dijital çağ kamu sektöründe sunulan hizmetleri, bu hizmetlerin sunuluş şeklini, kamusal örgütlerin yapısını ve yönetsel süreçlerini de etkileyip dönüştürmektedir. Kurumlar elektronik ortamda sundukları hizmetler neticesinde geleneksel kamu yönetiminin aksine dosya ortamında değil sanal ortamda kullanılabilecek ham veriye sahip hale gelmişlerdir. Kamu Denetçiliği Kurumu da âdeta bir büyük veri madeninin üzerinde oturmaktadır.

Yapay zekâ algoritmalarının bu büyük veriyi işleme ve değerlendirme kapasitesinden faydalanılabilir. Yapay zekâ algoritmalarıyla büyük verinin toplanarak işlenmesinin kamu kurumlarının iş ve işlemlerini kolaylaştırmak, sunulan hizmetin kalitesini artırmak, karar almayı geliştirmek ve daha fazla vatandaşa ulaşmayı sağlamak gibi büyük fırsatlar sunmaktadır. Tüm bu fırsatlardan Kamu Denetçiliği Kurumu da elbette yararlanabilir. Bu çalışma kapsamında da bir yapay zekâ uygulaması olan ChatGPT’ye Kamu Denetçiliği Kurumunun kamu personel rejimi konusunda aldığı kararlar tekrar değerlendirilmiştir. Çeşitli kısıtlar olmasına rağmen ChatGPT tarafından benzer tavsiye niteliğinde kararlar çıktığı görülmüştür. Tabi ki bu tam anlamıyla ChatGPT aracılığı ile kararlar verilsin anlamı taşımamaktadır. Ancak karar alma süreçlerine Adalet Bakanlığının hazırlıklarını yaptığı yapay zekâ uygulaması gibi kurumunda böyle uygulamalar konusunda çalışmalar başlatması gerekliliği yakın zamanda ortaya çıkabilir. Bunun yanı sıra Kamu Denetçiliği Kurumuna vatandaşlar her yöntem ile başvuru gerçekleştirebilmektedirler. 2023 yılı istatistikleri göz önüne alındığında en fazla başvurunun %82,94 ile elektronik başvuru ile gerçekleştiği (KDK 2023 Yıllık Raporu, 2024, s. 59) görülmektedir. Kurum değişime ayak uydurarak kendisine ulaşan vatandaşları yönlendirmek amacıyla ChatGPT vb. uygulamaları yeni bir başvuru yöntemi olarak devreye sokabilir.



This research article has been licensed with Creative Commons Attribution - Non-Commercial 4.0 International License. Bu araştırma makalesi, Creative Commons Atıf - Gayri Ticari 4.0 Uluslararası Lisansı ile lisanslanmıştır.

Yazar Katkıları

Yazarlar çalışmaya katkı oranlarının eşit olduğunu beyan etmişlerdir.

Teşekkür Beyanı

Yazarlar teşekkür beyanında bulunmamışlardır.

Destek Beyanı

Yazarlar destek beyanında bulunmamışlardır.

Çıkar Çatışması

Yazarlar herhangi bir çıkar çatışması beyan etmemişlerdir.

Etik Beyanı

Yazarlar çalışma için Etik Kurul Onayı alınmasına gerek olmadığını beyan etmişlerdir.

Sorumlu Özel Sayı Editörleri

Doç. Dr. Beyza Mina Ordu-Akkaya, Ankara Sosyal Bilimler Üniversitesi

Doç. Dr. Görkem Ataman, Yaşar Üniversitesi

Arş. Gör. Yunus Yıldırım, Afyon Kocatepe Üniversitesi

Kaynakça/References

1982 Türkiye Cumhuriyeti Anayasası.

2982 sayılı "Türkiye Cumhuriyeti Anayasasının Bazı Maddelerinde Değişiklik Yapılması Hakkında Kanun".

6328 sayılı "Kamu Denetçiliği Kurumu Yasası".

Aleksander, A., Lan, U., & Dejan, R. (2024). Artificial intelligence in public administration: A bibliometric review in comparative perspective. *Disruptive Information Technologies for a Smart Society (ICIST 2023)*.

Altman, S. (2023, 24 Şubat). Planning for AGI and beyond. OpenAI. <https://openai.com/blog/planning-for-agi-and-beyond>

Baker, H. (2023). ChatGPT's ability to assist with clinical documentation: A randomized controlled trial. *Journal of the American Academy of Orthopaedic Surgeons*, 32(3), 123-129. <https://doi.org/10.5435/jaaos-d-23-00474>

Balaban, M. F., & Kulular İbrahim, M. A. (2023). ChatGPT gibi sohbet yazılımlarının (sohbet botları/ chatbots) neden olduğu hukuka aykırılıkların önlenmesi. *Ankara Sosyal Bilimler Üniversitesi Hukuk Fakültesi Dergisi*, 5(2), 747-789.

Cantens, T. (2024). How will the state think with ChatGPT? The challenges of generative artificial intelligence for public administrations. *AI & Society*, 1-12.

Casey, D. (2024). ChatGPT in public policy teaching and assessment: An examination of opportunities and challenges. *Australian Journal of Public Administration*, 1-15.

ChatGPT 4, & Ekin, S. (2023). Prompt engineering for ChatGPT: Quick guide to techniques, tips, and best practices. *TechRxiv*, 1-11. <https://doi.org/10.36227/techrxiv.22683919.v2>

Cooper, M., Kouyoumdjian, H., & Underwood, S. (2016). Investigating students' reasoning about acid-base reactions. *Journal of Chemical Education*, 93(10), 1703-1712. <https://doi.org/10.1021/acs.jchemed.6b00417>

Davis, E. (2003). Prompting middle school science students for productive reflection: Generic and directed prompts. *Journal of the Learning Sciences*, 12(1), 91-142. https://doi.org/10.1207/s15327809jls1201_4

Derdiyok, T., Ünal, S., & Dođru, Ç. (2023). ChatGPT'nin şirketlerin mali durumunu tespit yeteneđi. *Ufuk Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 12(23), 6-20.

Efe, H., & Demirci, M. (2013). Ombudsmanlık kavramı ve Türkiye'de Kamu Denetçiliđi Kurumundan beklentiler. *Sayıştay Dergisi*, 9, 49-72.

Erdoğan, O. (2020). Avrupa Doğru İdari Davranış Yasası ve iyi yönetim ilkeleri üzerinden yerel yönetimlerde reform. *Süleyman Demirel Üniversitesi Hukuk Fakültesi Dergisi (SDÜHFD)*, 10(1), 221-242.

European Ombudsman. (2024, March 19). Ombudsman asks European Commission about artificial intelligence use in decision making. <https://www.ombudsman.europa.eu/en/news-document/en/183633>

Ferretti, S. (2023). Hacking by the prompt: Innovative ways to utilize ChatGPT for evaluators. *New Directions for Evaluation*, 2023(178-179), 73-84. <https://doi.org/10.1002/ev.20557>

Günek, A. (2023). Dijital çağda bilginin dönüşümü ve yapay zekâ: Üretim ve iktidar ilişkileri açısından bir değerlendirme. *Communicata*, 25, 1-8.

Gürsoy, M., & Kılıç, S. (2023). The comparison of Google Bard and ChatGPT use in financial markets. *Sosyal Bilimler Akademi Dergisi*, 6(2), 98-106.

Hartley, A., Kieley, J., & Slabach, E. (1990). Age differences and similarities in the effects of cues and prompts. *Journal of Experimental Psychology: Human Perception & Performance*, 16(3), 523-537. <https://doi.org/10.1037/0096-1523.16.3.523>

Huang, J., & Huang, K. (2023). ChatGPT in government. In K. Huang, Y. Wang, F. Zhu, X. Chen, & C. Xing (Eds.), *Beyond AI: ChatGPT, Web3, and the business landscape of tomorrow* (pp. 271-294). Springer.

İçişleri Bakanlığı. (2002). "İyi Yönetimin Geliştirilmesi" konulu yönerge (7 Mayıs 2002, B050ÖKM0000011-12/467).

Karaca, S. O., & Azimli Çilingir, G. (2022). Türkiye'de Kamu Denetçiliđi Kurumu ile hukuk devleti ilkesi arasındaki ilişki. *Sosyal Bilimler Akademi Dergisi*, 5(2), 225-248.

Kayar, N. (2015). *İdari yargı kuruluş ve işleyiş* (3. Baskı). Ekin Yayınları.

KDK. (2024). 2023 Yıllık Raporu. <https://www.ombudsman.gov.tr/Yayinlarimiz/YillikRapor>

Kim, S., Shim, J., & Shim, J. (2023). A study on the utilization of OpenAI ChatGPT as a second language learning tool. *Journal of Multimedia Information System*, 10(1), 79-88. <https://doi.org/10.33851/jmis.2023.10.1.79>

Kurt, Y. (2023). Digital transformation in accounting and auditing: Insights from the ChatGPT example. *İğdır Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 10, 11-22.

- Mohamed Saleh, Z. (2019). Artificial intelligence: Definition, ethics and standards. British University in Egypt, 2-10.
- National Audit Office (NAO). (2024). Use of artificial intelligence in government report. Cabinet Office Department for Science, Innovation & Technology.
- Nilsson, N. J. (2010). *The quest for artificial intelligence*. Cambridge University Press.
- Ogunleye, I. (2022). Al's redress problem. CLTC, University of California, Berkeley.
- Okcu, M., & Akman, E. (2020). Yapay zekâ ve kamu politikası. In M. Yıldız & C. Babaoğlu (Eds.), *Teknoloji ve kamu politikaları* (pp. 67-110). Gazi Kitabevi.
- Okcu, M., Akman, Ç., & Akman, E. (2020). Yapay zekâ ve dijital değişimlerin etkisinde ombudsmanlık: Algoritmik karar alma ve yapay zekâ ombudsmanlığı. In O. Erdoğan (Ed.), *Ombudsmanlık: Dünyada uygulanan özel amaçlı ombudsmanlık türleri ve uygulamaları* (pp. 35-62). Nobel Yayınevi.
- OpenAI. (2023, March 23). GPT-4. <https://openai.com/research/gpt-4>
- Özan Özparlak, B., & Çetin, M. (2023). ChatGPT ve üretici yapay zekâ modellerinde mahremiyet ve güvenliğin hukuki boyutu. *Marmara Üniversitesi Hukuk Fakültesi Hukuk Araştırmaları Dergisi*, 29(2), 1003-1040.
- Özer, A., Çömlekci, İ., & Ünal, S. (2023). ChatGPT hisse senedi değerlemede kullanılabilir mi? Borsa İstanbul üzerine bir araştırma. *Uluslararası Bankacılık, Ekonomi ve Yönetim Araştırmaları Dergisi*, 6(2), 201-227.
- Özer, M. A. (2017). Avrupa Ombudsmanı ve Türkiye Kamu Denetçiliği Kurumu: Mukayeseli bir inceleme. *Türkiye Adalet Akademisi Dergisi*, 8(31), 65-96.
- Pearce, J., & Chiavaroli, N. (2020). Prompting candidates in oral assessment contexts: A taxonomy and guiding principles. *Journal of Medical Education and Curricular Development*, 7, 238212052094888. <https://doi.org/10.1177/2382120520948881>
- Perlman, A. M. (2022). The implications of ChatGPT for legal services and society. *Suffolk University Law School Research*, 22-14.
- Pirim, H. (2006). Yapay zekâ. *Yaşar Üniversitesi E-Dergisi*, 1(1), 81-93.
- Radford, A., Narasimhan, K., Salimans, T., & Sutskever, I. (2018). Improving language understanding by generative pre-training. https://cdn.openai.com/research-covers/language-unsupervised/language_understanding_paper.pdf
- Salah, M., Abdelfattaha, F., & Al Halbusi, H. (2023). Generative artificial intelligence (ChatGPT & Bard) in public administration research: A double-edged sword for street-level bureaucracy studies. *International Journal of Public Administration*, 1-7. <https://doi.org/10.1080/01900692.2023.2274801>
- Shewale, R. (2024, March 19). ChatGPT statistics - users, revenue (March 2024). <https://www.demandsage.com/chatgpt-statistics/#:~:text=ChatGPT%20has%20over%20180.5%20million,are%20from%20the%20United%20States>
- Şentürk, Ö. (2023). İç denetim faaliyetlerinde yapay zekâdan beklentiler: ChatGPT uygulaması örneği. *TIDE Academia Research*, 4(2), 51-82.
- Türk Dil Kurumu (TDK). (n.d.). Yapay zekâ. In *Güncel Türkçe Sözlük*. <https://sozluk.gov.tr/>
- Türkiye Büyük Millet Meclisi Kamu Denetçiliği Kurumu (TBMM KDK). (n.d.). <https://www.ombudsman.gov.tr/AnaSayfa/BizeHangiKonulardaBasvurabilirsiniz>

Research Article (Special Issue) | Araştırma Makalesi (Özel Sayı)

Çalışan yıpranmasını tahmin etmede analitik bir yaklaşım: Topluluk öğrenme yöntemi

Mustafa Yurtsever | Dr. Öğr. Üyesi, İzmir Demokrasi Üniversitesi, mustafa.yurtsever@idu.edu.tr, [0000-0003-2232-0542](https://orcid.org/0000-0003-2232-0542)

Corresponding author/Sorumlu yazar: Mustafa Yurtsever ✉ mustafa.yurtsever@idu.edu.tr

Öz

Şirketler, profesyonel çalışanlarının ayrılmasını engelleyerek işe alım ve eğitim maliyetlerini azaltmak için çeşitli önlemler ararlar. Belirli bir çalışanın ayrılıp ayrılmayacağını önceden tahmin etmek, şirketin bu tür kayıpları minimize etmek için gereken adımları atmasını sağlar. Bu nedenle, çalışanların ayrılma olasılığını önceden tahmin etmek, işverenlere stratejik kararlar almalarında yardımcı olabilir. Çalışan yıpranması bu noktada çalışanların işten ayrılma niyetlerini anlama konusunda belirleyici olabilmektedir. Topluluk öğrenme modelleri, birden fazla algoritmanın çeşitli görüşlerini birleştirerek daha doğru ve güvenilir sonuçlar elde etme potansiyeline sahiptir. Bu çalışmada, 1.470 kayıttan oluşan IBM şirketi Watson Analytics tarafından hazırlanan çalışanların yıpranma durumunu gösteren veri seti kullanılmıştır. Bu amaçla, Rastgele Orman, Destek Vektör Makineleri, Çok Katmanlı Algılayıcı modeli ve iki farklı topluluk öğrenme modeli kullanılarak performansları değerlendirilmiştir. Sınıf dengesizliğini aşmak için adaptif sentetik veri üretimi (ADASYN) yaklaşımı kullanılmıştır. Sonuç olarak, ADASYN kullanılarak oluşturulan dengeli bir veri kümesi ile eğitilen yığın topluluk öğrenme modeli ile 0.96 doğruluk oranı elde etmiştir.

Anahtar Kelimeler: Çalışan Yıpranması, Tahminleme, Topluluk Öğrenmesi Yöntemleri **JEL Kodları:** J21, M51

An analytical approach to predicting employee attrition: Ensemble learning method

Abstract

Companies seek various measures to prevent the departure of professional employees and thereby reduce recruitment and training costs. Predicting whether a specific employee will leave or not enables the company to take the necessary steps to minimize such losses. Therefore, predicting the likelihood of employee attrition in advance can assist employers in making strategic decisions. Employee attrition plays a crucial role in understanding employees' intentions to leave their jobs. Ensemble learning models have the potential to achieve more accurate and reliable results by combining various perspectives of multiple algorithms. In this study, a dataset indicating the attrition status of employees, prepared by IBM Watson Analytics and consisting of 1,470 records, was utilized. For this purpose, the performances were evaluated using Random Forest, Support Vector Machines, Multi-Layer Perceptron model, and two different ensemble learning models. To overcome class imbalance, the adaptive synthetic data generation (ADASYN) approach was used. As a result, a stacked ensemble learning model trained on a balanced dataset created using ADASYN achieved an accuracy rate of 0.96.

Keywords: Employee Attrition, Prediction, Ensemble Learning Methods **JEL Codes:** J21, M51

Extended Summary

Employee attrition can be defined as a gradual decrease in the number of personnel due to increased resignations (typically of competent, high-performing, talented, and team-compatible employees) and the failure to replace them with new hires. To address high turnover rates, organizations should take measures to understand the underlying reasons and implement strategies to mitigate them. These measures may include conducting exit interviews to gather feedback from departing employees, identifying areas for improvement in the workplace environment, offering competitive salaries and benefits packages, providing opportunities for development, and fostering a supportive organizational culture. By addressing the root causes of attrition and prioritizing employee engagement and satisfaction, organizations can work towards reducing turnover rates and promoting long-term stability and success.

How to cite this article / Bu makaleye atıf vermek için:

Yurtsever, M. (2024). Çalışan yıpranmasını tahmin etmede analitik bir yaklaşım: Topluluk öğrenme yöntemi. *KOCATEPEİİBFD*, 26(Özel Sayı), 150-160.

<https://doi.org/10.33707/akuiibfd.1462567>

In recent years, with the advancement of artificial intelligence (AI) technology, it has been observed that businesses have started to implement this technology in various fields. AI is being used in areas such as production management, marketing, procurement, distribution, and human resources management to increase efficiency or improve financial performance.

Traditionally, organizations would react and take steps to mitigate losses after employee attrition incidents occurred. However, with the use of technologies like artificial intelligence (AI) today, it has become possible to predict the likelihood of attrition in advance and take preventive measures. This proactive approach presents a significant opportunity for organizations to enhance their workforce planning and management processes.

In this study, two types of ensemble models were created using Random Forest, Multilayer Perceptron (MLP), and Support Vector Machines (SVM), as well as individual models, to predict employee attrition. The aim is to identify the best classifier for the analyzed problem. To address the limitations of traditional techniques used in predicting employee attrition, a series of ensemble learning methods were employed.

Ensemble learning involves training multiple models simultaneously and combining their outputs to generate predictions. This technique leverages the different features and strengths of each model to yield more accurate and reliable predictions. The approach outlines the classification models used in the initial step and their corresponding training processes. Ensemble learning entails the simultaneous use of multiple classification models. In this approach, various classification models are trained, and their outputs are later combined through a higher-level meta-model to produce the final prediction value. The final prediction is generated by the meta-model through the combination of predictions from the trained models. Particularly, the aggregation process performed using logistic regression at the meta-stage aims to combine the predictions of the base models to achieve higher accuracy. Another prominent ensemble method utilized for making robust predictions is the Voting Classifier. The Voting Classifier is an ensemble learning method that combines predictions from multiple base predictors (machine learning models) and predicts the class label by taking a vote. It can be applied to both classification and regression problems. In hard voting, each base predictor (model) predicts the class label, and the final prediction is determined by a majority vote. The class label with the most votes becomes the final prediction. In soft voting, each base predictor estimates the probability distribution across all classes. The final prediction is determined by taking the average of these probabilities and then selecting the class with the highest average probability.

After analyzing the predictive performance of the models, the ensemble learning model constructed with employee attrition, Random Forest (RO), Support Vector Machine (SVM), and Multilayer Perceptron (MLP) achieved the best performance across all metrics such as accuracy (0.96), F1 score (0.96), precision (0.96), and recall (0.96). The Voting Classifier ensemble model also demonstrated successful performance with an accuracy rate of 0.95. The model with the lowest performance was the Support Vector Machine (SVM) model, with an accuracy rate of 0.91. It is observed that ensemble learning models outperform individual machine learning models.

Giriş

İnsan kaynakları, iş faaliyetlerini yürütmek ve iş hedeflerine ulaşmak için işletmeler için son derece önemlidir. Hızla değişen iş ortamı ve bir organizasyon içinde ortaya çıkan çeşitli insan sorunları nedeniyle, organizasyonlar insan kaynakları yönetimiyle ilgili çok sayıda sorunla karşı karşıyadır (Chung vd., 2023). Bu sorunlardan bir tanesi de işten ayrılmalardır (Douaidi ve Kheddouci, 2022). Ayrılma, bir çalışanın bir kuruluşun gönüllü veya gönülsüz istifa etmesi olarak tanımlanabilir (Srivastava ve Nair, 2018).

Çalışan memnuniyetinin düşük olması bir çalışanın şirketi terk etmesi için başlıca nedenlerden biridir. Çalışma saatlerinin belirsizliği, ücret politikası, çevresel koşullar, iş yükü gibi nedenler çalışan memnuniyetini etkileyen faktörlerdir. Oshagbemi (2003), genel iş memnuniyetinin işin çeşitli yönlerine bağlı olduğunu ve çoğu zaman işin doğasının birincil neden olabileceğini kanıtıyor. Oshagbemi ayrıca, iş tatminini etkileyebilecek iş arkadaşlarının kişi üzerindeki etkisi veya işteki denetim, teklif edilen ücret, çalışma ortamı, organizasyonda izlenen politikalar, prosedürler ve organizasyondaki büyüme fırsatları gibi birçok nedenin iş tatminini etkileyebileceğini ve bunun da bir çalışanın organizasyondan ayrılma kararını etkileyebileceğini açıklıyor.

Bir diğer çalışma işten ayrılmasının başlıca nedenleri olarak yöneticiyle ilişki, daha iyi kariyer beklentileri, tazminat, ödüller, takdir ve iş içeriği gibi insan kaynakları değişkenleriyle ilgili olduğunu ortaya koymaktadır (Barpanda ve Athira, 2022). Sriram vd. (2019) araştırması, örgüt kültürünün ve çalışanlara izin verilmesinin çalışan yıpranmasını etkileyen iki önemli faktör olduğunu ortaya koydu. Tüm bu faktörler çalışanların iş tatmin seviyesini etkilemektedir. İş tatmini düşük olan birinin gelecekte işini bırakma olasılığı, iş tatmini yüksek olan aynı kişiye göre çok daha yüksek olduğu bilinmektedir (Clark, 2001).

Yüksek işten ayrılma oranı, herhangi bir organizasyon için hem finansal hem de insan kaynakları açısından zararlı olabilir (Jain vd., 2020). Yalnızca yeni çalışanları işe almak ve onları eğitmek için değil, aynı zamanda mevcut çalışanların moralini düşürmesi ve geriye kalan çalışanların iş yükünü artırması açısından işletmeleri etkiler (Oruç, 2020). Ayrıca ayrılan çalışanların yerine geçecek

doğru kişiyi bulmakta işletme açısından zorlayıcıdır (Yadav vd., 2018). Bir diğer nokta ise temel teknolojilerin ve teknik bilgilerin sızma riski gibi çeşitli nedenlerden dolayı kuruluşta önemli kayıplara neden olmasıdır (Chung vd., 2023). Müşterilerin hizmet markasına ilişkin imajı üzerinde olumsuz bir etkiye sahip olduğu da bilinmektedir (Subramony ve Holtom, 2012). Projelerden kazanılan değerli bilgi ve deneyimlerin kaybına neden olması da diğer bir etkisidir (Kumar ve Yakhlef, 2016). Özellikle ileri teknoloji firmaları işten ayrılma oranlarını azaltmak ile yakından ilgilenmektedir (Hoffman ve Tadelis, 2021). Bu nedenle, çalışanların işten ayrılmasına katkıda bulunan faktörleri anlamak ve önleyici önlemler almak gerçekten önemlidir.

Çalışan yıpranması, işten ayrılmaların (genellikle yetkin, performansı yüksek, yetenekli ve takım uyumuna sahip çalışanların) artması ve yerlerine yeni çalışanların getirilememesi durumunda personel sayısında kademeli bir azalma olarak tanımlanabilir (Oruç, 2020). Yüksek işten ayrılma oranlarını ele almak için, kuruluşlar altta yatan nedenleri anlamak ve bunları azaltacak stratejiler uygulamak için önlemler almalıdır (El-Rayes vd., 2020). Bu önlemler; ayrılan çalışanlardan geri bildirim almak için çıkış görüşmeleri yapmayı, işyeri ortamında iyileştirme alanlarını belirlemeyi, rekabetçi ücret vermeyi, yan hak paketleri sunmayı, gelişim için fırsatlar sağlamayı ve destekleyici bir kurum kültürünü teşvik etmeyi içerebilir. Kuruluşlar, işten ayrılmanın temel nedenlerini ele alarak çalışan bağlılığı ve memnuniyetine öncelik vererek işten ayrılma oranını azaltmaya ve uzun vadeli istikrar ve başarıyı teşvik etmeye çalışabilir.

Geleneksel olarak, işten ayrılma durumları meydana geldikten sonra kurumlar tepki verir ve kayıpları azaltmaya yönelik adımlar atardı. Ancak, günümüzde YZ gibi teknolojilerin kullanımıyla, işten ayrılma olasılığını önceden tahmin etmek ve bu duruma önlem almak mümkün hale gelmiştir. Bu önleyici yaklaşım, kurumların işgücü planlaması ve yönetimi süreçlerini geliştirmek için önemli bir fırsat sunar.

Son yıllarda yapay zeka (YZ) teknolojisinin gelişmesiyle birlikte, işletmelerin çeşitli alanlarda bu teknolojiyi uygulamaya başladığı gözlemlenmektedir. Üretim yönetimi, pazarlama, satın alma, dağıtım ve insan kaynakları yönetimi gibi alanlarda verimliliği artırmak veya finansal performansı iyileştirmek amacıyla YZ kullanılmaktadır (Buntak vd., 2021; Enholm vd., 2022) İnsan kaynakları yönetimi alanında ise, YZ özellikle işe alım, performans yönetimi (Garg vd., 2022) ve insan kaynakları otomasyonu gibi alanlarda uygulanmaya başlamıştır ve bu kullanım alanı giderek genişlemektedir (Aldulaimi vd., 2021). Özellikle makine öğrenimi gibi veri analizi tekniklerinin çalışan devirlerini önleme yöntemi olarak kullanılması dikkat çekmektedir (Avrahami vd., 2022).

Bu doğrultuda, literatürde çalışan yıpranmasını önceden tahmin edilmesini analiz eden çeşitli çalışmalar bulunmaktadır. Makine öğrenmesi yöntemleri kullanılarak yapılan çalışmalarda Gaussian Naive Bayes (Fallucchi vd., 2020), Ragele Orman (Kaya ve Korkmaz, 2021), K-en Yakın Komşu (Alduayj ve Rajpoot, 2018) gibi makine öğrenmesi yöntemleri kullanılmıştır. Bu çalışmaların tek bir modele bağlı olduğu ve yöntemlerin sonuçlarının karşılaştırılmasına dayandığı görülmektedir.

Bu çalışmanın temel amacı, çalışan yıpranmasını ve bunun sonucunda çalışanların işten ayrılma olasılıklarını daha doğru bir şekilde tahmin etmek için çeşitli makine öğrenimi modellerini karşılaştırmak ve topluluk öğrenme modellerinin bu süreçteki etkisini incelemektir. Bu çalışma, çalışan yıpranmasını tahmin etme alanında birkaç yeniliği barındırmaktadır. İlk olarak, IBM Watson Analytics tarafından sağlanan 1.470 kayıttan oluşan veri seti üzerinde farklı makine öğrenimi algoritmaları test edilmiştir. İkinci olarak, sınıf dengesizliği gibi yaygın bir sorunla başa çıkmak için ADASYN (Adaptif Sentetik Veri Üretimi) yöntemi kullanılmıştır. Bu yöntem, sınıf dengesizliğini azaltarak daha dengeli bir veri kümesi oluşturmakta ve modellerin performansını artırmaktadır. Son olarak, topluluk öğrenme yöntemlerinin uygulanmasıyla elde edilen sonuçlar, bu tür yaklaşımların çalışan yıpranması tahmininde ne kadar etkili olabileceğini göstermektedir.

Çalışmanın katkıları arasında, çalışan yıpranmasını tahmin etmeye yönelik olarak kullanılan farklı makine öğrenimi algoritmalarının performanslarının karşılaştırılması ve topluluk öğrenme yöntemlerinin bu alandaki etkisinin değerlendirilmesi bulunmaktadır. Ayrıca, ADASYN gibi veri işleme tekniklerinin model performansı üzerindeki etkisi de incelenmiştir. Elde edilen bulgular, işverenlere, çalışanların işten ayrılma olasılıklarını daha iyi tahmin edebilecek ve bu kayıpları minimize edebilecek stratejik kararlar almaları için yol gösterici niteliktedir.

Bu çalışmada cevap aranan temel araştırma soruları şunlardır:

- Farklı makine öğrenimi modelleri, çalışan yıpranmasını tahmin etmede ne kadar başarılıdır?
- Topluluk öğrenme yöntemleri, çalışan yıpranması tahmininde doğruluğu artırmak için nasıl kullanılabilir?
- Sınıf dengesizliği gibi sorunlarla başa çıkmak için veri işleme teknikleri etkili sonuçlar verir mi?

Çoğu şirketin personel verisi bulunmakla birlikte, çalışan yıpranmasının çeşitli faktörlere bağlı olması daha sofistike yöntemlerin kullanılmasını gerektirir. Çalışmada kullanılan veri setinin dengesiz olması tahmin yapmayı daha da zorlaştırmaktadır. Bu çalışma, çalışan yıpranması tahminlerinin doğruluğunu artırmak için topluluk öğrenme modellerinin performanslarının karşılaştırılması amaçlanmaktadır. Bu makalenin 1. bölümü, çalışan yıpranması ile ilgili YZ alanındaki literatür incelemesini ele almıştır. 2. bölüm

araştırma yöntemini sunmakta ve 3. bölüm analiz sonuçlarını sunmaktadır. Son olarak, bu çalışmanın sonuçlarını, etkilerini, sınırlılıklarını ve ileriye dönük araştırma konularını sunmuştur.

1. Literatür Taraması

Hızla değişen iş ortamı ve bir şirkette ortaya çıkan çeşitli insani sorunlar nedeniyle kuruluşlar, insan kaynaklarıyla ilgili birçok sorunla karşı karşıya kalmaktadırlar (Rutherford vd., 2003). Çalışanların işten ayrılması veya işten ayrılma oranı, bir işyerindeki çalışanların belirli bir dönem içinde işlerini bırakma veya ayrılma durumunu ifade eder. Bu durum, çalışanların kendi istekleriyle ayrılması, emekli olması, işten çıkarılması veya başka nedenlerle işi terk etmesi gibi çeşitli sebeplerle gerçekleşebilir.

İşverenler için çalışanların işten ayrılması, iş gücü planlaması, maliyetler, verimlilik gibi birçok faktörü etkileyebilir (Yahia vd., 2021; Alsheref vd., 2022). Bu nedenle, işletmeler sıklıkla çalışanların işten ayrılma oranını takip eder ve bu durumu tahmin etmek ister. Ayrıca çalışan yıpranmasının iş birimlerinin performansı üzerinde önemli olumsuz etkileri olduğunu göstermektedir (Subramony ve Holtom, 2012). Yeni bir çalışanın yetiştirilmesi uzun ve maliyetli bir süreçtir ve çalışanların yıpranma oranını kontrol etmek ve azaltmak şirketin çıkarıdır (Fallucchi vd., 2020).

Bu nedenle bir kuruluşun ticari faaliyetlerini sürdürebilmesi ve yüksek rekabet avantajı elde edebilmesi için çalışan kaybının en aza indirilmesi gerekmektedir (Chung vd., 2023) Çalışanların neden ayrıldığına dair bir anlayış edinmek, İnsan Kaynakları departmanlarının gelişmiş planlama ve müdahale yoluyla çalışanlarını elde tutmalarına destek olur (Frye vd., 2018).

Literatürde araştırmacılar bu konuya farklı yöntemler ile yaklaşmışlardır. Alao ve Adeyemo (2013) beş farklı karar ağacı modeli ve iki kural kümesi ürettikleri çalışmalarında yeni çalışan kaybı durumlarını tahmin etmek için bir tahmin modeli geliştirmişlerdir. Khare vd. (2011), tarafından yapılan çalışmada lojistik regresyon yöntemi, ayrılmış ve mevcut çalışanların demografik verilerine dayalı olarak çalışan kaybını tahmin etmek için bir risk denklemi geliştirmek üzere önerilmiştir.

Alduayj ve Rajpoot (2018) Rastgele Orman (RO), k-en yakın komşu ve Destek Vektörü Makineleri (DVM) yöntemlerine kullandıkları çalışmada IBM İK veri setinin kaynak olarak kullanmışlardır. Veri setinin dengesizliğinden dolayı veri kümesini orijinal, sentetik olarak aşırı örneklenmiş ve az örneklenmiş olarak 3 farklı şekilde kullanmışlardır. Sentetik veri setine sahip sistemleri yüksek doğruluk gösterse de orijinal veri setiyle çıkan sonuçların doğruluğu yeterli olmamıştır. Bhatta vd. (2022), farklı makine öğrenmesi yöntemleri ve oylama sınıflandırıcı kullandıkları çalışmada, oylama sınıflandırıcısı yöntemi ile çalışan yıpranmasını 0,89'lük bir AUC (ROC Eğrisi Altındaki Alan) puanına ulaşmışlardır. Bir diğer araştırmada üç makine öğrenme algoritması, Karar Ağacı, Rastgele Orman ve İkili Lojistik Regresyon ile çalışan kaybını tahmin etmek için seçilmiştir. Lojistik Regresyon modeli, test edilen algoritmalar arasında %87,44'lük en yüksek doğruluğu sağlamıştır (Alsubaie ve Aldoukhi, 2024).

Fallucchi vd. (2020), IBM İK verilerini kullanarak Gaussian Naive Bayes, K-En Yakın Komşu, Karar Ağacı, RO, DVM ile modellerini oluşturdu. Tahmin doğruluğu açısından en iyi performansa sahip model doğrusal DVM oldu. Al-Darraji vd. (2021) yılında aynı veri setini derin sinir ağları kullanarak modellemişlerdir. Veri setinin dengesizliğini gidermek için sentetik veri ile genişletmişlerdir. Orijinal veri seti ile tahmin doğruluğu yaklaşık %91 iken sentetik veri seti kullanıldığında yaklaşık %94 doğruluk sonucuna ulaşılar.

Kaya ve Korkmaz (2021), aynı veri seti için dengesizlik problemini gidermek için bootstrap tekniğini kullanmışlardır ve sınıfların örnek sayılarını dengelemişlerdir. Yedi farklı makine öğrenmesi yöntemi kullandıkları çalışmada doğruluk oranı olarak %80 seviyelerine ulaşmışlardır. Celik (2019), ise karar ağacı ve destek vektör makinesi yöntemlerini kullandıkları çalışmalarında DVM ile %91 doğruluk oranı elde etmişlerdir.

2. Metodoloji

2.1. Rasgele Orman

RO algoritması, makine öğrenimi alanında sınıflandırma ve regresyon problemleri için kullanılan bir topluluk öğrenme algoritmasıdır. İlk olarak Breiman (2001) tarafından tanımlanan RO algoritması, daha güçlü bir model oluşturmak için birden fazla karar ağacının kombinasyonundan yararlanan bir topluluk yaklaşımıdır. Her bir karar ağacı rastgele bir alt örnek üzerinde eğitilir ve bireysel tahminler yapar. RO, aşırı uyum eğilimine karşı dirençlidir ve genellikle yüksek boyutlu veri setlerinde ve yüksek boyutlu özellik uzaylarında etkilidir. Oluşturulan tüm karar ağaçları kullanılarak sınıflandırma veya regresyon işlemi gerçekleştirilir. Sınıflandırma durumunda, her ağaç tek bir sınıf tahmini yapar ve ardından en çok oy alan sınıf tahmini sonuç olarak seçilir. Daha fazla optimizasyon elde etmek için, ağaç sayısı, maksimum derinlik ve minimum bölüm boyutu dahil olmak üzere hiperparametreler ayarlanarak RO'ya ince ayar yapılabilir. Sınıflandırma verilerine dayalı RO gerçekleştirirken Gini endeksini kullanmaktadır. Gini endeksinin azalması sınıf homojenliğini artırır. Bölünme işlemlerinde homejen sınıf dağılımına sahip düğümler tercih edilmektedir. Gini endeksinin formülü aşağıdaki gibidir.

$$Gini = 1 - \sum_{i=1}^C (p_i)^2$$

2.2. Destek Vektör Makineleri

DVM'nin temel amacı, veri noktalarını sınıflar arasında bir karar sınırı ile ayırmaktır. Bu karar sınırı, veri noktalarının en iyi şekilde ayrılmasını sağlamak için optimize edilir. DVM, sınıflar arasındaki marjı (mesafe) maksimize etmeye çalışarak, veri noktalarını ayıran en iyi karar sınırını bulur. DVM'nin ana avantajlarından biri, yüksek boyutlu veri kümeleri üzerinde iyi performans göstermesi (Suthaharan ve Suthaharan, 2016) ve ayrık, sürekli veya karmaşık veri türlerini işleyebilmesidir. Model, çekirdek fonksiyonu seçimi ve düşük marjinal hata için tolerans parametresi gibi çeşitli hiperparametreler ayarlanarak optimize edilebilir. İki boyutlu uzayda, optimal hiper-düzlem, uzayı iki parçaya bölen bir çizgi olarak düşünülebilir (Hearst vd., 1998). Uzayın bir kısmı bir sınıfa ait veri noktalarını içerirken, uzayın diğer kısmı diğer sınıfa ait veri noktalarını içerir. Bir sınıflandırıcı olarak hareket eden çizgiler kavramı, yalnızca veri noktaları doğrusal olarak ayrılabilirse geçerlidir. DVM, doğrusal olarak ayrılamayan veri noktalarını sınıflandırmak için kullanılabilir en uygun eğriyi bulmak için de kullanılabilir. Bu sınıflandırmayı yapabilmek için iki sınıfı ayıran bir doğru çizilir. Bu doğrunun arasında kalan bölgeye Margin adı verilir. Margin ne kadar geniş ise sınıflandırma o kadar başarılı olur. Aşağıda buna ilişkin formül verilmiştir.

$$y = \begin{cases} 0 & \text{if } w^T * x + b < 0, \\ 1 & \text{if } w^T * x + b \geq 0 \end{cases}$$


Formülde; w ağırlık vektörü, x girdi vektörü, b ise sapmayı ifade etmektedir.

2.3. Çok Katmanlı Algılayıcı (ÇKA)

Yapay sinir ağlarının bir türü olan ve en azından bir gizli katman içeren bir mimariyi ifade eden model girdi katmanı, en az bir gizli katman ve çıktı katmanından oluşur. Gizli katmanlardaki her bir düğüm, girdi katmanındaki girdilerin birleşik bir ağırlık toplamına dayanarak bir aktivasyon fonksiyonu tarafından işlenmesiyle oluşturulur (Gardner ve Dorling, 1998). ÇKA, özellikle sınıflandırma ve regresyon problemleri için yaygın olarak kullanılan bir modeldir. ÇKA öncelikle geriye yayılma algoritması yoluyla öğrenir ve gizli katman sayısı, nöron sayısı, aktivasyon fonksiyonlarının seçimi ve daha fazlası dahil olmak üzere hiper parametreler ayarlanarak daha da optimize edilebilir (Wilson ve Tufts, 1994).

ÇKA modelinde, her bir gizli katmanın çıktısı, bir önceki katmanın çıktısı girdi olarak kullanılarak elde edilir. Son çıktı katmanı, tahmin sonucunu üretmek için bir aktivasyon fonksiyonu uygular. Regresyon problemleri için genellikle doğrusal aktivasyon fonksiyonları kullanılırken, sınıflandırma problemleri için sigmoid veya softmax gibi uygun aktivasyon fonksiyonları kullanılır. ÇKA mimarisi Şekil-1 de gösterilmektedir. Her katman $y = f(Wx + b)$ olarak temsil edilir. Burada f, aktivasyon fonksiyonudur. W, katmandaki parametre veya ağırlıklar kümesidir, x, aynı zamanda önceki katmanın çıkışı da olabilen giriş vektörüdür ve b, bias vektörüdür. ÇKA'nın katmanları, tamamen bağlı birkaç katmandan oluşur çünkü bir katmandaki her birim, bir önceki katmandaki tüm birimlere bağlıdır.

Şekil 1. ÇKA Mimarisi



Kaynak: Yazarlar.

2.4. Veri Seti

Bu çalışmada kullanılan veri seti, IBM Analytics tarafından oluşturulmuştur. Kaggle'ın yarışmalarında yayınlanan 'IBM HR Analytics Çalışan Yıpranması ve Performans' verileridir (IBM HR Analytics Employee, 2017). 1470 çalışan için 35 özellik içermektedir. "Yıpranma" özelliği, çalışanın şirkette kalma veya ayrılma kararını temsil eder. Tüm özellikler çalışanların çalışma hayatı ve kişisel özellikleri ile ilgilidir. Tablo 1'de veri setinde bulunan özellikler listelenmiştir.

Tablo 1. Veri Seti Özellikleri


Yaş	Çalışan Yıpranması	Seyahat Durumu
Günlük Ücret	Departman	Evden uzaklık
Eğitim	Eğitim Alanı	İşçi Sayısı
Çalışan Numarası	Çevre Memnuniyeti	Cinsiyet Eğitim Süreleri
Saatlik Ücret	İşe Katılım	İş Seviyesi
İş Rolü	İş Tatmini	Medeni Durum
Aylık Gelir	Aylık Ücret	Önceki İşveren Sayısı
18 Yaş Üstü	Fazla Mesai	Yüzde Maaş Artışı
Performans Derecesi	İlişki Memnuniyeti	Standart Saatler
Hisse Senedi Opsiyonu Seviyesi	Toplam Çalışma Yılı	Son sene
İş Yaşam Dengesi	Şirkette Geçirdiği Yıl	Mevcut Görevdeki Yıl
Son Promosyon Zamanı	Mevcut Yönetici ile Kaç Yıl	

Kaynak: Yazarlar.

Veri setinde yapılan basit bir inceleme, çalışan sayısı, 18 yaş üstü ve standart çalışma saatleri gibi bazı özelliklerin tüm çalışanlar için aynı olduğunu ortaya koyuyor, bu nedenle bu özellikler bu aşamada ihmal edilmiştir. Ayrıca, çalışan numarası özelliği de ihmal edilmiştir çünkü değerleri sınıflandırma problemimizle ilgili değildir.

Veri seti incelendiğinde bazı özellikler sayılar yerine kategorik değerlerdir. Makine öğrenmesi yöntemlerinde kullanmak için kategorik veriler sayılara dönüştürülmüştür. Orijinal veri seti, iş seyahati, departman, eğitim alanı, cinsiyet, iş rolü, medeni durumu ve mesai gibi birçok kategorik özelliği içerir. Öncelikle benzersiz değerler ve sayıları belirlenir. Daha sonra her değer için bir tek etiketli ikili vektör atanır. İki kategorili kategorik değişkenlerde, sayılar 0 ve 1'e eşlenmiştir. Üç veya daha fazla kategoriye sahip kategorik değişkenlerde ise, değişken bağımsızlığını korurken kategorik değişkenleri sayısal verilere dönüştürmek için one-hot dönüşümü kullanılmıştır. Makine öğrenmesi modelleri, eğitim sürecindeki özellikler arasındaki göreceli değerlerin büyüklüğüne karşı duyarlıdır. Bir özelliğin diğerlerine üstün gelmesini önlemek için özellik ölçeklendirmesi kullanılmıştır. Bu çalışmada özellik değerleri [0, 1] aralığına yeniden ölçeklendirilmiştir.

Çalışan yıpranması oranları dengesiz olduğundan ADASYN algoritması uygulanarak yeni örnekler oluşturulmuştur. Şekil 2'de bu dengesizliğin grafik üzerinde gösterimi yapılmıştır. ADASYN algoritması yoğunluk dağılımı, her bir azınlık sınıfı örneği için oluşturulması gereken sentetik örneklerin sayısına otomatik olarak karar vermek için kullanılır. Algoritmanın temel işleyişi, her örnek için farklı miktarlarda sentetik veri üretmek amacıyla farklı azınlık sınıfı örneklerine ağırlıklar vermesidir (Gosaion ve Sardana, 2017). ADASYN algoritması kullanımı sonrası veri setinin büyüklüğü 2406 örneğe çıkmıştır. Yeni veri setinde çalışan yıpranması dağılımı (Evet:1173, Hayır:1233) şeklinde dengeli bir şekilde oluşmuştur.

Şekil 2. Çalışan Yıpranması Dağılımı

Kaynak: Yazarlar.

2.5. Model Tasarımı

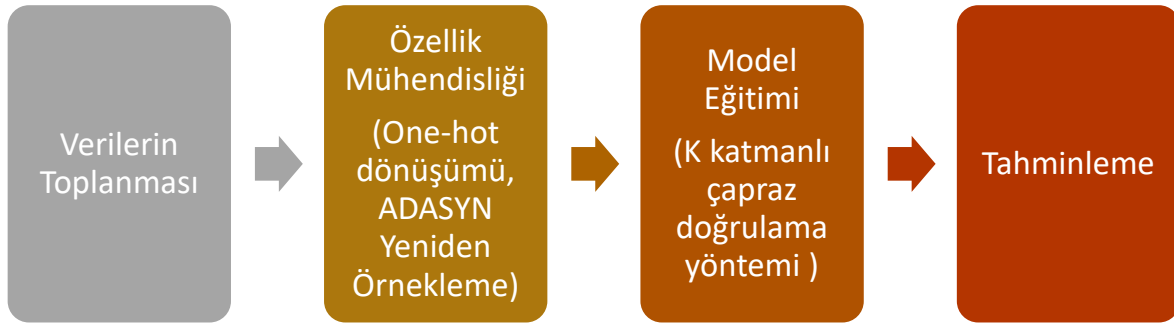
Bu çalışmada RO, ÇKA, DVM, ve bu bireysel modeller kullanılarak oluşturulan 2 tip topluluk modeli, çalışanların yıpranmasını tahmin etmek için oluşturulmuştur. Amaç, analiz edilen problem için en iyi sınıflandırıcıyı belirlemektir. Bu çalışmada, çalışan yıpranması tahmininde kullanılan geleneksel tekniklerin sınırlamalarını gidermek için bir dizi topluluk öğrenmesi yöntemi kullanılmıştır. RO, DVM ve ÇKA gibi algoritmalar, genellikle sınıflandırma problemlerinde güçlü performans gösterirler ve özellik uzayındaki karmaşıklığı iyi yönetirler. Çalışmamızda KNN ve Naif Bayes yöntemlerinin kullanılmamasının sebebi çalışma öncesi bu modellerinin denenip performans sonuçlarının diğer algoritmalara göre düşük olmasıdır.

Yığın topluluğu öğrenimi yaklaşımı, birden fazla modeli aynı anda eğitmeyi ve tahminler oluşturmak için çıktıları birleştirmeyi içerir. Bu teknik, her modelin farklı özelliklerinden ve güçlü yönlerinden yararlanarak daha doğru ve güvenilir tahminlere yol açar. İlk adımda kullanılan sınıflandırma modellerini ve bunlara karşılık gelen eğitim sürecini ortaya koymaktadır. Yığın topluluğu yöntemi birden fazla sınıflandırma modelinin aynı anda kullanılmasını içerir. Bu yaklaşımda çeşitli sınıflandırma modelleri eğitilir. Her modelden elde edilen daha sonra daha üst düzey bir meta model aracılığıyla birleştirilir ve nihai tahmin değeri elde edilir. Nihai tahmin, eğitilen modellerden gelen tahminlerin birleşimi yoluyla meta model tarafından üretilir. Özellikle meta aşamada lojistik regresyon kullanılarak yapılan toplama işlemi, temel modellerin tahminlerini birleştirerek daha yüksek bir doğruluk sağlaması amaçlanmıştır.

Öne çıkan bir diğer topluluk yöntemi, sağlam tahminler yapmak için kullanılan Oylama Sınıflandırıcısıdır. Oylama Sınıflandırıcısı, birden fazla temel tahmincinin (makine öğrenimi modelleri) tahminlerini birleştiren ve oy alarak sınıf etiketini tahmin eden bir topluluk öğrenme yöntemidir. Hem sınıflandırma hem de regresyon problemlerine uygulanabilir. Zorunlu oylamada, her temel tahminci (model) sınıf etiketini tahmin eder ve nihai tahmin çoğunluk oyu ile belirlenir. En çok oyu alan sınıf etiketi son tahmin olur. Yumuşak oylamada her temel tahminci, tüm sınıflar üzerindeki olasılık dağılımını tahmin eder. Nihai tahmin, bu olasılıkların ortalaması alınarak ve ardından en yüksek ortalama olasılığa sahip sınıfın seçilmesiyle belirlenir.

Tahmin modelinin performansını değerlendirmek için veri seti eğitim ve test veri seti olmak üzere iki bölüme ayrılmıştır. Eğitim veri seti %70'lik kısımdan test veri seti %30'luk kısımdan oluşturuldu. Eğitim seti modelin verilerde gizli olan ilişkileri öğrenmesine olanak sağlamak amacıyla ayrıldı. Test verisi ise modeli doğrulamak için kullanıldı. Aşırı uyum sorunlarını önlemek ve modeli basitleştirmek için k katmanlı çapraz doğrulama yöntemi kullanılmıştır. Eğitim seti rastgele beş parçaya bölündükten sonra, biri doğrulama seti olarak, diğer k-1'ler eğitim seti olarak kullanılmıştır. Bu işlem k kere gerçekleştirilmiştir. Her yinelemede farklı bir parça doğrulama seti olarak alınmıştır. Finalde k kerelik uygulamaların doğruluk değerlerinin ortalaması kullanılmıştır. Şekil 3'te tahmin modelinin grafiği gösterilmektedir.

Şekil 3. Önerilen Model



Kaynak: Yazarlar.

3. Analiz Sonuçları

Makalede sunulan modellerin performansı çeşitli ölçümler kullanılarak değerlendirildi. Performans değerlendirmesinde her bir algoritmanın başarısını ölçmek amacıyla doğruluk, kesinlik, duyarlılık ve F1 skorları kullanılmıştır. Doğruluk, modelin doğru tahmin ettiği örneklerin oranıdır. En yüksek değeri 1 olabilir. Kesinlik ise pozitif olarak sınıflandırılan örneklerin ne kadarının gerçekten pozitif olduğunu ölçer. Duyarlılık ise, gerçek pozitif örneklerin ne kadarının pozitif olarak tahmin edildiğini gösterir. F1-skoru ise sınıflandırma modelinin kesinlik ile duyarlılık değerlerinin harmonik ortalamasıdır. Bu metriklerin formülleri aşağıdaki gibidir.

$$\text{Doğruluk} = \frac{(TP+TN)}{TP+FP+TN+FN}$$

$$\text{Kesinlik} = \frac{TP}{TP+FP}$$

$$\text{Duyarlılık} = \frac{TP}{TP+FN}$$

$$\text{F1 Skor} = 2 * \frac{\text{Duyarlılık} * \text{Kesinlik}}{\text{Duyarlılık} + \text{Kesinlik}}$$

Formüllerdeki;

TP (True Positive): doğru pozitif sayısı

TN (True Negative): doğru negatif sayısı

FP (False Positive): yanlış pozitif sayısı

FN (False Negative): yanlış negatif sayısıdır.

Topluluk öğrenme modelleri; RO, DVM ve ÇKA gibi tekli modellerinden daha iyi performans gösterdi. Bu, farklı modellerin birleştirilmesinden elde edilecek sinerjinin, bireysel modellerin performansından daha büyük olabileceğini göstermektedir. Tekli modeller arasında RO ve ÇKA'nın en iyi doğruluğa sahip olduğu görüldü. Çeşitli model kombinasyonlarından oluşan topluluk modeli, tekli modele göre daha iyi performans gösterse de, belirli algoritmaların kombinasyonuna bağlı olarak topluluk modelinin performansı farklılık göstermektedir.

Tablo 2, sentetik veriler ile genişletilen veri setinin test verileri aracılığıyla yapılan yıpranma tahmin değerleri ile ilgili olarak doğruluk, kesinlik, duyarlılık ve F1 skorları sonuçlarını göstermektedir. Tablo 3 ise orijinal veri seti ile eğitilen modelin test verileri aracılığıyla yapılan yıpranma tahmin değerleri ile ilgili olarak doğruluk, kesinlik, duyarlılık ve F1 skorları sonuçlarını göstermektedir. Ayrıca sentetik olarak üretilen veri ile orijinal veri kullanıldığında çıkan sonuç farklılıkları bu iki tablo incelendiğinde net olarak gözükmemektedir. Sentetik olarak üretilen veri ile sınıf dengesizliğinin ortadan kaldırılması sonuçları olumlu yönde etkilemiştir.

Tablo 2. Model Performansları (Sentetik Veri)

Model	Doğruluk	Kesinlik	Duyarlılık	F1 Skor
RO	0.93	0.94	0.93	0.93
DVM	0.91	0.91	0.91	0.91
ÇKA	0.94	0.95	0.94	0.94
Yığın Topluluk Öğrenme Modeli	0.96	0.96	0.96	0.96
Oylama Sınıflandırıcı Topluluk Modeli	0.95	0.95	0.95	0.95

Kaynak: Yazarlar.

Tablo 3. Model Performansları (Orijinal Veri)

Model	Doğruluk	Kesinlik	Duyarlılık	F1 Skor
RO	0.87	0.72	0.55	0.55
DVM	0.89	0.89	0.60	0.64
ÇKA	0.85	0.65	0.62	0.63
Yığın Topluluk Öğrenme Modeli	0.88	0.77	0.61	0.64
Oylama Sınıflandırıcı Topluluk Modeli	0.86	0.68	0.62	0.64

Kaynak: Yazarlar.

Model tahmin performansının analiz edilmesi sonucunda çalışan yıpranması, RO, DVM ve ÇKA ile oluşturulan yığın topluluk öğrenme modeli, doğruluk (0.96), F1 puanı (0.96), kesinlik (0.96) ve duyarlılık (0.96) gibi tüm göstergelerde en iyi performansı göstermiştir. Oylama sınıflandırıcı topluluk modeli de 0.95 doğruluk oranı ile başarılı bir performans sergilemiştir. En düşük performans gösteren model ise 0.91 doğruluk oranı ile DVM modelidir. Topluluk öğrenme modellerinin tek başına makine öğrenmesi modellerine göre daha yüksek performans gösterdiği görülmektedir.

Orijinal veri ile yapılan çalışan yıpranması modellerinin performansı sentetik veri ile genişletilen veri setine göre çok daha düşüktür. Bunun ilk sebebinin sınıflar arasındaki dengesizlikten kaynaklandığı söylenebilir. Orijinal veri modellerinde en iyi sonucu 0.89 doğruluk oranı ile DVM modeli sergilemiştir. Topluluk modellerinden yığın model (0.88) ve oylama sınıflandırıcı model (0.86) doğruluk oranı yakalamıştır.

Tartışma ve Sonuç

Önerilen çalışma insan kaynakları departmanı için bir çalışanın işten ayrılma niyeti hakkında işletmelere önemli bilgiler sunabilir. Çalışan yıpranmasını tahmin eden çalışma, bu amaçla çeşitli makine öğrenmesi yöntemlerini ve bu yöntemler kullanılarak oluşturulan topluluk öğrenme yöntemlerini kullanmıştır. Genel değerlendirme için doğruluk, kesinlik, duyarlılık ve F1 skoru kullanılmıştır. Yığın topluluk öğrenme modeli 0.96 doğruluk oranı ile en iyi sonucu vermiştir. Tek modellerin sınırlamalarının topluluk modelleri ile avantaja dönüştürüldüğü ve sonuçlara yansıdığı görülmektedir.

Aynı veri setini kullanan diğer çalışmalar ile karşılaştırıldığında modelimiz kayda değer bir performans göstermiştir. Tablo 4'te aynı veri setini kullanan diğer çalışmalar listelenmiştir.

Tablo 4. Aynı Veri Setini Kullanan Diğer Çalışmalar

Referans	Model	Doğruluk Oranı
Alduayj ve Rajpoot, 2018	RO	0.91
Celik, 2019	DVM	0.91
Fallucchi vd., 2020	Doğrusal DVM	0.87
Al-Darraji vd., 2021	Derin Sinir Ağları	0.94
Kaya ve Korkmaz, 2021	Radyal Tabanlı Fonksiyon Ağı	0.80
Raza vd., 2022	Ekstra Ağaçlar	0.93
Alshiddy ve Aljaber, 2023	İç İçe Topluluk Öğrenme	0.94
Alsubaie ve Aldoukhi (2024)	Lojistik Regresyon	0.87

Kaynak: Yazarlar.

Tablo 4 aynı veri setinin kullanan diğer çalışmalar arasındaki karşılaştırmayı göstermektedir. Her çalışmada kullanılan özellik mühendisliği yöntemleri, veri ön işleme ve örnekleme yöntemleri farklı olsa da doğruluk oranları karşılaştırıldığında modelin başarılı olduğu söylenebilir. Tablodaki çalışmalara bakıldığında Alshiddy ve Aljaber (2023)'in çalışması dışında diğer çalışmalarda tek bir yöntemin kullanıldığı görülmektedir. Bu çalışmaların performanslarına bakıldığında bu çalışmadaki 0.96'lık doğruluk oranının altında kaldığı görülmektedir. Derin Sinir ağlarında birden fazla gizli katmanın kullanılması öğrenme performansını arttırdığı bilinmektedir (Sze vd., 2017). Bu doğrultuda Al-Darraji vd. (2021) çalışmasının sonucu bunu desteklemektedir. Topluluk öğrenme modellerinin ana amacı bireysel modelleri birleştirerek performans artırmaktır (Sagi ve Rokach, 2018). Çalışmada topluluk öğrenme modelinin bu avantajı kullandığı görülmektedir. Kullandığımız modelin, çalışanların yıpranma riskini doğru bir şekilde tahmin etmede karşılaştırma yaptığımız çalışmalardan daha iyi performans göstermiştir.

Bu çalışmada, çalışanların işten ayrılma olasılığını tahmin etmek amacıyla çeşitli makine öğrenmesi algoritmaları ve topluluk öğrenme modelleri kullanılarak IBM Watson Analytics tarafından sağlanan bir veri seti üzerinde analizler yapılmıştır. Giriş bölümünde belirtildiği üzere, çalışanların ayrılma olasılığını önceden tahmin etmek, şirketlerin işe alım ve eğitim maliyetlerini azaltarak verimliliği artırmalarına yardımcı olabilir. Çalışmanın sonuçları, bu problemin çözümüne önemli katkılar sağlamaktadır.

İlk olarak, kullanılan tahmin modelleri ile çalışanların işten ayrılma olasılıklarının yüksek doğrulukla tahmin edilebildiği gösterilmiştir. RO, DVM, ÇKA ve topluluk öğrenme modelleri ile yapılan değerlendirmeler sonucunda, ADASYN yöntemi ile dengelenmiş veri seti üzerinde eğitilen yığın topluluk öğrenme modelinin %96 doğruluk oranı ile en iyi performansı sergilediği tespit edilmiştir. Bu yüksek doğruluk oranı, insan kaynakları departmanlarının, çalışanların memnuniyet ve bağlılığını artırmak için proaktif ve hedefe yönelik stratejiler geliştirmesine olanak tanır. Dolayısıyla, araştırmamızda kullanılan modeller, çalışan bağlılığını artırmak ve ayrılma oranlarını düşürmek isteyen şirketler için pratik bir çözüm sunmaktadır.

İkinci olarak, çalışmamızda kullanılan tahmin yöntemlerinin güçlü yönleri, özellikle veri dengesizliği gibi yaygın bir problemi ele almadaki etkinliği, çözüm sürecine önemli katkılar sağlamıştır. ADASYN yöntemi, dengesiz veri kümelerinde azınlık sınıfın daha iyi temsil edilmesine yardımcı olmuş ve model performansını artırmıştır. Bu yaklaşım, veri dengesizliği problemini çözmek için yenilikçi bir çözüm sunmakta ve bu alandaki diğer araştırmacılar için de değerli bir örnek teşkil etmektedir. Ayrıca, topluluk öğrenme modellerinin çeşitli algoritmaların avantajlarını birleştirerek elde ettiği yüksek doğruluk oranı, bu modellerin karmaşık iş gücü veri setlerinde kullanımı için güçlü bir argüman sunmaktadır.

Son olarak, bu çalışma, çalışan yıpranması ve işten ayrılma tahminine yönelik literatüre anlamlı katkılar sağlamaktadır. Giriş bölümünde öngörülen hipotezlerin doğrulanmış olması, literatürdeki boşlukların doldurulmasına yardımcı olmuştur. Çalışma, topluluk öğrenme modellerinin ve ADASYN yönteminin bu alandaki uygulamaları konusunda literatüre önemli bir katkı sağlamış ve gelecekteki araştırmalar için yeni bir yol haritası çizmiştir.

Gelecekteki çalışmalar, burada elde edilen bulguları genişleterek farklı veri kümeleri veya endüstrilerde kullanılarak modellerin performansını değerlendirebilir. Ayrıca, farklı veri dengeleme yöntemleri veya yeni makine öğrenmesi algoritmalarının kullanılması, model doğruluğunu ve genelleme yeteneğini daha da artırabilir.



This research article has been licensed with Creative Commons Attribution - Non-Commercial 4.0 International License. Bu araştırma makalesi, Creative Commons Atıf - Gayri Ticari 4.0 Uluslararası Lisansı ile lisanslanmıştır.

Yazar Katkıları

Yazarlar çalışmaya katkı oranlarını bu şekilde beyan etmişlerdir: Yunus Emre Gür %35, Kamil Abdullah Eşidir %35, Şahin Göktuğ Kaldırımcı %30

Teşekkür Beyanı

Yazarlar teşekkür beyanında bulunmamışlardır.

Destek Beyanı

Yazarlar destek beyanında bulunmamışlardır.

Çıkar Çatışması

Yazarlar herhangi bir çıkar çatışması beyan etmemişlerdir.

Etik Beyanı

Yazarlar çalışma için Etik Kurul Onayı alınmasına gerek olmadığını beyan etmişlerdir.

Sorumlu Özel Sayı Editörleri

Doç. Dr. Beyza Mina Ordu-Akkaya, Ankara Sosyal Bilimler Üniversitesi

Doç. Dr. Görkem Ataman, Yaşar Üniversitesi

Arş. Gör. Yunus Yıldırım, Afyon Kocatepe Üniversitesi

Kaynakça/References

- Alao, D. A. B. A., & Adeyemo, A. B. (2013). Analyzing employee attrition using decision tree algorithms. *Computing, Information Systems, Development Informatics and Allied Research Journal*, 4(1), 17–28.
- Al-Darraj, S., Honi, D. G., Fallucchi, F., Abdulsada, A. I., Giuliano, R., & Abdulmalik, H. A. (2021). Employee attrition prediction using deep neural networks. *Computers*, 10(11), 141. <https://doi.org/10.3390/computers10110141>
- Alduayj, S. S., & Rajpoot, K. (2018). Predicting employee attrition using machine learning. In *2018 International Conference on Innovations in Information Technology (IIT)* (pp. 93–98). IEEE. <https://doi.org/10.1109/INNOVATIONS.2018.8605976>
- Aldulaimi, S. H., Abdeldayem, M. M., Mowafak, B. M., & Abdulaziz, M. M. (2021). Experimental perspective of artificial intelligence technology in human resources management. In Hamdan, A., Hassanien, A. E., Khamis, R., Alareeni, B., Razzaque, A., & Awwad, B. (Eds.), *Applications of artificial intelligence in business, education and healthcare* (Vol. 954, pp. 605–619). Springer. https://doi.org/10.1007/978-3-030-72080-3_26
- Alsheref, F. K., Fattoh, I. E., & M. Ead, W. (2022). Automated prediction of employee attrition using ensemble model based on machine learning algorithms. *Computational Intelligence and Neuroscience*, 2022(1), 7728668. <https://doi.org/10.1155/2022/7728668>
- Alshiddy, M. S., & Aljaber, B. N. (2023). Employee attrition prediction using nested ensemble learning techniques. *International Journal of Advanced Computer Science and Applications*, 14(7), 932–938. <https://doi.org/10.14569/IJACSA.2023.01400712>
- Alsubaie, F., & Aldoukhi, M. (2024). Using machine learning algorithms with improved accuracy to analyze and predict employee attrition. *Decision Science Letters*, 13(1), 1–18. <https://doi.org/10.5267/j.dsl.2023.12.006>
- Avrahami, D., Pessach, D., Singer, G., & Chalutz Ben-Gal, H. (2022). A human resources analytics and machine-learning examination of turnover: Implications for theory and practice. *International Journal of Manpower*, 43(6), 1405–1424. <https://doi.org/10.1108/IJM-12-2020-0548>
- Barpanda, S., & Athira, S. (2022). Cause of attrition in an information technology-enabled services company: A triangulation approach. *International Journal of Human Capital and Information Technology Professionals (IJHCITP)*, 13(1), 1–22. <https://doi.org/10.4018/IJHCITP.20220101.0a1>
- Bhatta, S., Zaman, I. U., Raisa, N., Fahim, S. I., & Momen, S. (2022, April). Machine learning approach to predicting attrition among employees at work. In *Computer Science On-line Conference* (pp. 285–294). Springer International Publishing. https://doi.org/10.1007/978-3-030-93515-3_25
- Breiman, L. (2001). Random forests. *Machine Learning*, 45(5), 5–32. <https://doi.org/10.1023/A:1010933404324>
- Buntak, K., Kovačić, M., & Mutavdžija, M. (2021). Application of artificial intelligence in the business. *International Journal for Quality Research*, 15(2), 403. <https://doi.org/10.24874/IJQR15.02-03>
- Çelik, U. (2019). Veri madenciliği yöntemleri ile iş yaşam dengesinde yıpranma durumu tahmini. *Journal of Management and Economics Research*, 17(1), 63–76. <https://doi.org/10.11611/yead.519923>
- Chung, D., Yun, J., Lee, J., & Jeon, Y. (2023). Predictive model of employee attrition based on stacking ensemble learning. *Expert Systems with Applications*, 215, 119364. <https://doi.org/10.1016/j.eswa.2022.119364>
- Clark, A. E. (2001). What really matters in a job? Hedonic measurement using quit data. *Labour Economics*, 8(2), 223–242. [https://doi.org/10.1016/S0927-5371\(00\)00041-9](https://doi.org/10.1016/S0927-5371(00)00041-9)
- Douaidi, L., & Kheddouci, H. (2022, September). A new approach for employee attrition prediction. In *International Conference on Conceptual Structures* (pp. 115–128). Springer International Publishing. https://doi.org/10.1007/978-3-030-76294-0_9
- El-Rayes, N., Fang, M., Smith, M., & Taylor, S. M. (2020). Predicting employee attrition using tree-based models. *International Journal of Organizational Analysis*, 28(6), 1273–1291. <https://doi.org/10.1108/IJOA-10-2019-1903>
- Enholm, I. M., Papagiannidis, E., Mikalef, P., & Krogstie, J. (2022). Artificial intelligence and business value: A literature review. *Information Systems Frontiers*, 24(5), 1709–1734. <https://doi.org/10.1007/s10796-021-10186-w>
- Fallucchi, F., Coladangelo, M., Giuliano, R., & De Luca, E. W. (2020). Predicting employee attrition using machine learning techniques. *Computers*, 9(4), 86. <https://doi.org/10.3390/computers9040086>
- Frye, A., Boomhower, C., Smith, M., Vitovsky, L., & Fabricant, S. (2018). Employee attrition: What makes an employee quit?. *SMU Data Science Review*, 1(1), 9.
- Gardner, M. W., & Dorling, S. R. (1998). Artificial neural networks (the multilayer perceptron)—a review of applications in the atmospheric sciences. *Atmospheric Environment*, 32(14–15), 2627–2636. [https://doi.org/10.1016/S1352-2310\(97\)00447-0](https://doi.org/10.1016/S1352-2310(97)00447-0)

- Garg, S., Sinha, S., Kar, A. K., & Mani, M. (2022). A review of machine learning applications in human resource management. *International Journal of Productivity and Performance Management*, 71(5), 1590–1610. <https://doi.org/10.1108/IJPPM-08-2020-0427>
- Gosain, A., & Sardana, S. (2017). Handling class imbalance problem using oversampling techniques: A review. In *2017 International Conference on Advances in Computing, Communications and Informatics (ICACCI)* (pp. 79–85). IEEE. <https://doi.org/10.1109/ICACCI.2017.8125865>
- Hearst, M. A., Dumais, S. T., Osuna, E., Platt, J., & Scholkopf, B. (1998). Support vector machines. *IEEE Intelligent Systems and Their Applications*, 13(4), 18–28. <https://doi.org/10.1109/5254.708428>
- Hoffman, M., & Tadelis, S. (2021). People management skills, employee attrition, and manager rewards: An empirical analysis. *Journal of Political Economy*, 129(1), 243–285. <https://doi.org/10.1086/712436>
- IBM HR Analytics Employee. (2017). *IBM HR Analytics Employee Dataset*. Kaggle. <https://www.kaggle.com/pavansubhasht/ibm-hr-analytics-attrition-dataset>
- Jain, P. K., Jain, M., & Pamula, R. (2020). Explaining and predicting employees' attrition: A machine learning approach. *SN Applied Sciences*, 2(4), 757. <https://doi.org/10.1007/s42452-020-2519-4>
- Kaya, İ. E., & Korkmaz, O. (2021). Machine learning approach for predicting employee attrition and factors leading to attrition. *Çukurova Üniversitesi Mühendislik Fakültesi Dergisi*, 36(4), 913–928. <https://doi.org/10.21605/cukurovaumfd.1040487>
- Khalid, S. M., Rashid, S., & Ullah, R. (2022). Employee retention prediction using machine learning techniques: A review of the state of the art. *International Journal of Electrical and Computer Engineering*, 12(4), 4498–4506. <https://doi.org/10.11591/ijece.v12i4.9440>
- Khare, R., Kaloya, D., Choudhary, C. K., & Gupta, G. (2011, January). Employee attrition risk assessment using logistic regression analysis. In *Proceedings of the International Conference Advanced Data Analytics Business Analytics Intelligence* (pp. 1–33).
- Kumar, N., & Yakhlef, A. (2016). Managing business-to-business relationships under conditions of employee attrition: A transparency approach. *Industrial Marketing Management*, 56, 143–155. <https://doi.org/10.1016/j.indmarman.2016.01.002>
- Oruç, E. (2020). Örgütsel yıpranma üzerine kuramsal bir inceleme. *Dumlupınar Üniversitesi Sosyal Bilimler Dergisi*, 66, 319–334.
- Oshagbemi, T. (2003). Personal correlates of job satisfaction: Empirical evidence from UK universities. *International Journal of Social Economics*, 30(12), 1210–1232. <https://doi.org/10.1108/03068290310504380>
- Raza, A., Munir, K., Almutairi, M., Younas, F., & Fareed, M. M. S. (2022). Predicting employee attrition using machine learning approaches. *Applied Sciences*, 12(13), 6424. <https://doi.org/10.3390/app12136424>
- Rutherford, M. W., Buller, P. F., & McMullen, P. R. (2003). Human resource management problems over the life cycle of small to medium-sized firms. *Human Resource Management*, 42(4), 321–335. <https://doi.org/10.1002/hrm.10093>
- Sagi, O., & Rokach, L. (2018). Ensemble learning: A survey. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 8(4), e1249. <https://doi.org/10.1002/widm.1249>
- Sriram, K. V., Joseph, J., Mathew, A. O., & Rai, A. S. (2019). Factors affecting high employee attrition in manufacturing firms—A case study. *Calitatea*, 20(169), 23–28.
- Srivastava, D. K., & Nair, P. (2018). Employee attrition analysis using predictive techniques. In *Information and Communication Technology for Intelligent Systems (ICTIS 2017) - Volume 1* (pp. 293–300). Springer International Publishing. https://doi.org/10.1007/978-3-319-98516-7_32
- Subramony, M., & Holtom, B. C. (2012). The long-term influence of service employee attrition on customer outcomes and profits. *Journal of Service Research*, 15(4), 460–473. <https://doi.org/10.1177/1094670512452792>
- Suthaharan, S. (2016). Support vector machine. In *Machine Learning Models and Algorithms for Big Data Classification* (Vol. 36, pp. 393–405). Springer. https://doi.org/10.1007/978-1-4899-7641-3_9
- Sze, V., Chen, Y. H., Yang, T. J., & Emer, J. S. (2017). Efficient processing of deep neural networks: A tutorial and survey. *Proceedings of the IEEE*, 105(12), 2295–2329. <https://doi.org/10.1109/JPROC.2017.2763201>
- Wilson, E., & Tufts, D. W. (1994). Multilayer perceptron design algorithm. In *Proceedings of IEEE Workshop on Neural Networks for Signal Processing* (pp. 61–68). IEEE. <https://doi.org/10.1109/NNSP.1994.336191>
- Yadav, S., Jain, A., & Singh, D. (2018, December). Early prediction of employee attrition using data mining techniques. In *2018 IEEE 8th International Advance Computing Conference (IACC)* (pp. 349–354). IEEE. <https://doi.org/10.1109/IACC.2018.8710222>
- Yahia, N. B., Hlel, J., & Colomo-Palacios, R. (2021). From big data to deep data to support people analytics for employee attrition prediction. *IEEE Access*, 9, 60447–60458. <https://doi.org/10.1109/ACCESS.2021.3074559>

Afyon Kocatepe Üniversitesi
İktisadi ve İdari Bilimler Fakültesi

Ahmet Necdet Sezer Kampüsü. Gazlıgöl Yolu. Eğitim 3 Binası. Afyonkarahisar/Merkez - 03200

+90272 218 20 00

www.dergipark.org.tr/akuiibfd | iibfdergisi@aku.edu.tr