



Batman Üniversitesi
Yaşam Bilimleri Dergisi

Batman University
Journal of Life Sciences

Cilt 14/ Sayı 1

Volume 14/ Number 1



BATMAN ÜNİVERSİTESİ YAŞAM BİLİMLERİ DERGİSİ
BATMAN UNIVERSITY JOURNAL OF LIFE SCIENCES
e-ISSN: 2459-0614

İmtiyaz Sahibi/Publication Owner

Batman Üniversitesi Adına
Prof. Dr. İdris Demir (Rektör)

Yönetici Editörler/Editors in Cheif

Musa Yılmaz

Editör Kurulu/ Editorial Board

- Abdullah Manap**, Batman Üniversitesi, Türkiye
Adem Yılmaz, Batman Üniversitesi, Türkiye
Ali Serkan Avcı, Batman Üniversitesi, Türkiye
Behnam Khaki, University of California Los Angeles, ABD
Behnam Mohammadi-Ivatloo, University of Tabriz, İran
Cafer Budak, Dicle Üniversitesi, Türkiye
Cenap Özel, King Abdulaziz University, Suudi Arabistan
Cihat Özaydın, Batman Üniversitesi, Türkiye
Deniz Barış Cebe, Batman Üniversitesi, Türkiye
Duygu Kızıldemir, Batman Üniversitesi, Türkiye
Emrullah Acar, Batman Üniversitesi, Türkiye
Fırat Çakır, Batman Üniversitesi, Türkiye
Hamidreza Nazaripouya, Oklahoma State University, ABD
Hafzullah İş, Batman Üniversitesi, Türkiye
Haydar Balseçen, Batman Üniversitesi, Türkiye
Heybet Kılıç, Dicle Üniversitesi, Türkiye
İdris Candan, Kocaeli Üniversitesi, Türkiye
Kazım Kılınç, Batman Üniversitesi, Türkiye
Kenan Bozkurt, Batman Üniversitesi, Türkiye
Mahmut Aydın, Batman Üniversitesi, Türkiye
Masoud Taghavi, Technical and Vocational University, İran
Mehmet Ali Özçelik, Gaziantep Üniversitesi, Türkiye
Mehmet Emin Asker, Dicle Üniversitesi, Türkiye
Meral Süer, Batman Üniversitesi, Türkiye
Mousa Marzband, Northumbria University, Birleşik Krallık
Muhammed İnal, Batman Üniversitesi, Türkiye
Musa Kılıç, Batman Üniversitesi, Türkiye
Nevfel Boz, Ankara Sosyal Bilimler Üniversitesi, Türkiye
Okan Özgönel, Ondokuz Mayıs Üniversitesi, Türkiye
Osman Pakma, Batman Üniversitesi, Türkiye
Osman Karlangıç, Batman Üniversitesi, Türkiye
Özgül Kahraman, Batman Üniversitesi, Türkiye
Rajeev Kumar Chauhan, Dayalbagh Educational Institute, Hindistan
Ramazan Tekin, Batman Üniversitesi, Türkiye
Reşat Çelikel, Fırat Üniversitesi, Türkiye

Sabit Ekin, Oklahoma State University, ABD
Sait Kurşunođlu, Batman Üniversitesi, Türkiye
Serhat Berat Efe, Bandırma Onyedı Eylöl Üniversitesi, Türkiye
Sevgi Işık Erol, Batman Üniversitesi, Türkiye
Tahir Çetin Akıncı, İstanbul Teknik Üniversitesi, Türkiye
Tekin İdem, Batman Üniversitesi, Türkiye
Ümit Kemalettin Terzi, Marmara Üniversitesi, Türkiye
Veysel Ertilla, Batman Üniversitesi, Türkiye

Sorumlu Yazı İşleri Müdürü

Musa Yılmaz

Sekreteryaya

Ali Serkan Avcı

Suat Gök

Mizanpaj

Suat GÖK

Web Teknik Hizmet

Suat Gök



BATMAN ÜNİVERSİTESİ YAŞAM BİLİMLERİ DERGİSİ

HAKKINDA

Batman Üniversitesi Yaşam Bilimleri Dergisi 2012 yılı Ocak ayından beri düzenli olarak yayınlanan uluslararası hakemli bir dergidir.

Dergimiz yılda iki sayı, her sayı da Fen Bilimleri ve Sosyal Bilimler olmak üzere iki cilt halinde yayınlanmaktadır. Dergi gerekli durumlarda herhangi bir konu kapsamında özel sayı halinde yayın yapabilir.

Dergimiz elektronik olarak yayınlanmaktadır.

Dergiye gönderilen çalışmalar başka bir yerde yayınlanmamış veya yayınlanmak üzere gönderilmemiş olmalıdır.

Makalelerin yazım dili Türkçe, İngilizce, Almanca veya Fransızca olabilir. Tüm makalelerde Türkçe ve yabancı dilde özet yazılması zorunludur.

Gönderilen makalenin kabul edilip edilmemesine, en az iki uzman hakem tarafından makalenin değerlendirilmesiyle karar verilir. Kabul edilen makalelerin tam metinleri, ilgili sayıda PDF versiyonları ile birlikte online olarak araştırmacıların hizmetine sunulmaktadır.

Batman Üniversitesi Yaşam Bilimleri Dergisi "**Akademik Dizin**", "**Free Journals Act**", "**Google Scholar**", ve "**SOBİAD**" indekslerinde taranmaktadır.

Adres: Batman Üniversitesi Yaşam Bilimleri Dergisi, 72060 Batman, Türkiye.

Tel: 444 9 072

E-posta: journal@batman.edu.tr



İÇİNDEKİLER / CONTENTS

Araştırma Makalesi

Otobüs Yangınları ve Nedenleri Üzerine Bir Araştırma

A Study on Bus Fires and Their Causes

Serkan AYCİL (ss.01-12)

Gastronomi ve Mutfak Sanatları Bölümü Öğrencilerinin Yeme Davranışı Eğilimleri: Karabük Üniversitesi Örneği

Eating Behavior Tendencies of Gastronomy and Culinary Arts Department Students: Karabük University Example

Özlem ÖZER ALTINDAĞ, Sena ATİK (ss.13-30)

Fındık Fiyatlarının Yapay Sinir Ağları ile Tahminlenmesi: Türkiye Örneği

Forecasting Hazelnut Prices with Artificial Neural Networks: The Case of Türkiye

Mehmet Akif KARA (ss.31-42)

A Comparative Analysis of Learning Techniques in the Context of Turkish Spam

Türkçe Spam Tespiti Bağlamında Öğrenme Tekniklerinin Karşılaştırmalı Analizi

Öznur ŞENGEL (ss.43-56)

Decision Tree-Based Direction Detection Using IMU Data in Autonomous

Otonom Robotlarda IMU Verilerini Kullanan Karar Ağacı Tabanlı Yön Tespiti

İrfan KILIÇ, Nafiye Nur APAYDIN, Muhammet APAYDIN, Orhan YAMAN (ss.57-68)

Dominant Color Detection For Online Fashion Retrievals

Çevrimiçi Moda Aramaları İçin Baskın Renk Tespiti

Sultan ZEYBEK, Merve ÇELİK (ss.69-80)

Derin Öğrenme ve Transfer Öğrenme Yöntemleri Kullanarak Değişen Yıldızlarda Sınıflandırma

Classification Of Variable Stars Using Deep Learning and Transfer Learning Methods

Emrullah KUŞTAŞI, Mete YAĞANOĞLU (ss.81-97)

Derleme Makalesi

Systematic Analysis of Special Education Projects in eTwinning

Sipan GÜLER (ss.98-113)



Otobüs Yangınları ve Nedenleri Üzerine Bir Araştırma

Serkan AYCİL*

İstanbul PTT Başmüdürlüğü, TÜRKİYE

Doi: 10.55024/buyasambid.1484897

MAKALE BİLGİSİ

Makale Türü: Araştırma Makalesi

Makale Geçmişi:

İlk gönderim tarihi: 15.05.2024

Düzeltilme tarihi: 22.06.2024

Kabul tarihi: 30.06.2024

Yayın tarihi: 07.07.2024

Anahatar Kelimeler:

Otobüs Yangını, Alternatif Yakıt,
Yetkisiz Tadilat.

*Serkan AYCİL

E-mail address:

sserkan.aycil@gmail.com

Orcid: 0000-0002-3540-5548

ÖZET

Çalışmanın amacı otobüs yangınlarına dikkat çekerek olası nedenlerini açıklamak ve çözüm önerilerinde bulunmaya çalışmaktır. Yerli ve yabancı literatürün taranmasıyla oluşturulan bu çalışma nitel araştırma içerisindeki veri toplama araçlarından biri olan doküman taramasıyla erişilen veriler üzerinden oluşturulmuştur. Öncelikle otobüslerde çıkan yangınlar araçtan kaynaklı, çevresel kaynaklı ve insandan kaynaklı yangınlar olmak üzere üç başlıkta toplanmıştır. Sonrasında araçtan kaynaklı faktörlere bağlı çıkan yangınlar: Motor bölmesinde çıkan yangınlar, elektrik tesisatından kaynaklı yangınlar, yolcu bölmesinde çıkan yangınlar, emisyon temizleme sistemleri ve alternatif yakıtlardan kaynaklı yangınlar, titreşimlerden ve tekerlek yuvasından kaynaklanan yangınlar biçiminde sıralanarak beş alt başlık altında detaylı bir biçimde incelenmiştir. Buna göre karmaşık bir yapıya sahip olan otobüslerde oluşan yangınların imalat hatası, bakımsızlık, yetkili olmayan servislerde yapılan tadilatlar ve alternatif yakıt kullanımı gibi faktörlerden kaynaklandığı anlaşılmıştır. Bu bağlamda otobüslerde yangına neden olan risklerin ekonomik gerekçelere ve maliyetlerdeki artışa bağlı olarak ortaya çıktığı görülmüştür. Ayrıca şahıs ve firmaları korumaya yönelik önlemlerin alınması durumunda otobüslerdeki yangın riskinin asgari seviyeye ineceği sonucuna ulaşılmıştır.

2024 Batman Üniversitesi. Her hakkı saklıdır.

Forecasting Hazelnut Prices with Artificial Neural Networks: The Case of Türkiye

Serkan AYCİL*

İstanbul PTT General Directorate, TURKEY

Doi: 10.55024/buyasambid.1484897

ARTICLE INFO

Article Type: Research Article

Article history:

Received: 15.05.2024

Received in revised form:
22.06.2024

Accepted: 30.06.2024

Available online: 07.07.2024

ABSTRACT

The aim of the study is to draw attention to bus fires, explain their possible causes and try to find solutions. This study, which was created by reviewing domestic and foreign literature, was based on the data accessed through document review, which is one of the data collection tools in qualitative research. First of all, fires in buses

Keywords:
Bus Fire, Alternative Fuel,
Unauthorized Modification.

*Serkan AYCİL
E-mail address:
sserkan.aycil@gmail.com
Orcid: 0000-0002-3540-5548

were categorized under three headings: vehicle-related, environmental-related and human-related fires. Afterwards, fires caused by factors originating from the vehicle: Fires in the engine room, fires caused by electrical installations, fires in the passenger compartment, fires caused by emission cleaning systems and alternative fuels, fires caused by vibrations and wheel wells. Accordingly, it is understood that fires in buses, which have a complex structure, are caused by factors such as manufacturing defects, lack of maintenance, modifications made by unauthorized services and alternative fuel use. In this context, it is seen that the risks that cause fire in buses arise due to economic reasons and the increase in costs. In addition, it has been concluded that if measures are taken to protect individuals and companies, the risk of fire in buses will be minimized.

2024 Batman University. All rights reserved

1. GİRİŞ

Motorlu taşıt teknolojileri insan yaşamı için artık gereklilik olarak görülmektedir. Günlük yaşamın içerisinde yer alan motorlu taşıtlar sadece insanların değil aynı zamanda yük ve eşyaların da bir yerden başka bir yere taşınmasına olanak tanımaktadır. Her ne kadar trafikte elektrikli bisiklet, scooter, motosiklet ve otomobil gibi konforlu araçlar kullanılıyor olsa da bunların hiçbiri kitleleri transfer etmeye yetecek kapasiteye ve hıza sahip değildir. Bu nedenle daha çok insanı transfer etmek için toplu taşıma faaliyetlerine ihtiyaç duyulmaktadır. Toplu taşıma faaliyetleri ise genel olarak deniz yolu, hava yolu, demiryolu ve karayolu ile sağlanmaktadır. Bunun dışında bir de boru hattıyla taşımacılık yapılmadığı bilinmektedir. Boru hattı taşımacılığı insan transferinde kullanılmadığı için konu kapsamı dışında tutulmuştur. Denizyolu taşımacılığı deniz bağlantısı olan yerleşim birimleri arasında ulaşım kolaylığı sağlarken havayolu taşımacılığı helikopter pisti, havaalanı ya da havalimanı bulunan ve birbirine belirli bir uzaklık mesafesi bulunan yerleşim birimleri arasında ulaşım kolaylığı sağlamaktadır. Karayolunda olduğu gibi arazi üzerinde gerçekleşen demiryolu taşımacılığı da birçok açıdan maliyet avantajı sağlıyor olsa da demiryolu ağı bulunmayan yerleşim birimlerine bu taşıma yöntemiyle hizmet götürme olanağı bulunmamaktadır. Türkiye’de demiryolu taşımacılığı da birçok noktada aktif olarak kullanılmaktadır. Ancak yapılması planlanan transfer akışının sağlanabilmesi için yine de transferin bir aşamasında karayoluna ihtiyaç duyulmaktadır. Ulaşım ağları içerisinde görece yaygın ve daha fonksiyonel olan karayolu taşımacılığı ise stabilize veya karayolu bulunan yerleşim birimleri arasında etkin ve kolay bir biçimde ulaşım kolaylığı sağlamaktadır. Buna göre karayolu taşımacılığının bir bölümünde toplu taşımaya ihtiyaç duyulmaktadır. Özellikle insanların bir yerden başka bir yere transfer edilebilmesi ve trafikteki insan transferi kaynaklı araç sayısının azaltılabilmesi için otobüslere ihtiyaç duyulmaktadır.

Seyahat süresince ihtiyaç ve konfor açısından hemen hemen her detayın düşünülerek tasarlandığı otobüsler mobil ve karmaşık bir yapıya sahiptir. Karayolu taşımacılığında rekabeti arttıran bu tür gereksinimler kaliteli seyahat edebilmek için gerekli olarak görülmektedir. Giderek daha dinamik bir yapıya bürünen otobüslerin yoğun enerji barındıran değişik tahrik çeşitlerinin (CNG, dizel, elektrikli, hibrid, hidrojen vb.) bulunduğu bilinmektedir. Bu bağlamda otobüslerde kullanılan alternatif yakıtlar ve araç üzerinde yapılan yetkisiz tadilatlar riskli bölgenin genişlemesine neden olmaktadır. Buna göre yangına dayanıksız malzemeler ile donatılan otobüslerde yangının çıktığı bölgeyi tespit etmek güçleşmektedir. Öte yandan çıkan yangın sonucunda bir otobüs ortalama 5-6 dakika gibi kısa bir süre içerisinde tamamen yanabilmektedir (Karadeniz, 2019: 41; Kılıç, 2019: 21).

Otobüslerde risk oluşturan bölgeler başta motor bölmesi olmak üzere sigorta kutusu, elektrik tesisatı, akü çevresi, yakıt deposu, lastikler, su ısıtıcıları, fren ve farlar biçiminde sıralanmaktadır. Buna göre otobüslerde çıkan yangınların %56’sının motor bölmesinde, %18’inin elektrik aksamında,

%5'inin yakıt deposunda, %3'ünün lastik, fren ve farlarda, %18'inin ise diğ-er riskli bölgelerde meydana geldiđi bilinmektedir (Karadeniz, 2019: 41). Dünya genelindeki otobüslerin yaklaşık %1'i çıkan yangınlarla birlikte kullanılamaz hâle gelmektedir. Türkiye'deki yanan otobüsler için net bir istatistiki verileri bulunmamasına rağmen bu oranının yaklaşık %2 civarında olduđu tahmin edilmektedir (Karadeniz, 2019: 41; Yıldız ve Köse, 2020: 120).

Çalışmanın amacı otobüs yangınlarına dikkat çekerek olası nedenlerini açıklamak ve çözüm önerilerinde bulunmaya çalışmaktır. Literatürde yer alan çalışmalarda genellikle yangın kayıtları, yangın sırasında yolcu tahliyesi, otobüs kaza ve yangın haberleri, otobüs yangınlarında can ve mal kayıpları, yolcu güvenliđi, sigorta mevzuatı, yakıt püskürtme ve emisyon sistemleri ya da itfaiye teşkilatı bağlamında motorlu araç yangınları konularında araştırmalarda bulunulmuştur. Yerli ve yabancı literatürün taranmasıyla oluşturulan bu çalışmada diğ-erlerinden farklı olarak otobüs yangınları konusu doğrudan ve kapsamlı bir biçimde ele alınmıştır. Açık erişimli olan ve otobüs yangınları konusuna karşı farkındalık oluşturacağı düşünölen bu çalışmanın yapılması planlanan diğ-er çalışmalara referans olacağı düşünölmektedir.

2. LİTERATÜR TARAMASI

Smyth ve Dillon (2012), yaptıkları çalışmada ağır iş döngüsü içerisinde çalışan otobüslerde satış işlemlerinden sonraki süreçte yangın riskini arttıran elektrik tesisatından kaynaklı birtakım problemler saptamıştır. Buradaki amaç gelecekte yaşanması muhtemel olan otobüs yangınlarını önlemek için geçmişte hangi faktörlerin otobüs yangınlarına sebep olduğunu belirleyip önceden önlem almaya çalışmaktır. Buna göre yapılan araştırmada otobüs yangınları üç farklı kategoriye ayrılarak analiz edilmiştir. Bunlar; elektrik sisteminden kaynaklı yangınlar, tekerlek seviyesindeki sürtünmeden kaynaklı yangınlar ve motor arızasından kaynaklanan yangınlar olarak belirlenmiştir. Sonuç olarak yangına neden olan bir takım risklerin araç bakımı ve rutin kontrollerle önlenebileceđi görölmüştür.

Hoffman, Dülsen ve Klipper (2013), 2008'de Almanya'nın Hannover şehri yakınlarında yaşanan ve 20 kişinin ölümlüyle sonuçlanan otobüs yangınından hareketle bir çalışma hazırlamıştır. Buna göre yan camlar ile tavan camını kırarak kaçmayı başaran gençlerin yangından sağ kurtuldukları görölmürken tavandan atlamak durumunda kalanların ise ciddi olarak yaralandıkları görölmüştür. Bu bağlamda ani ve hızlı bir biçimde ilerleyen yangının seyrini anlamak için otobüslerden ve tedarikçilerden malzemeler alınmış ve dayanıklılık testleri gerçekleştirilmiştir. Alınan numune örnekleri demiryolu taşımacılığında kullanılan (tramvay ve tren) araçlardaki malzeme örnekleriyle karşılaştırılmıştır. Bu testlerde özellikle yeni otobüs koltuklarında kullanılan malzemenin son derece dayanıksız olduđu anlaşılmıştır. Yapılan testler 1995'ten önce imal edilen otobüs koltuklarının daha yüksek dayanım sağladığını göstermiştir. Dolayısıyla son dönemlerde daha ucuz ve hafif plastiklere yönelimin arttığı bunun da otobüslerdeki yangın riskini arttırdığı sonucuna ulaşılmıştır.

Feng ve Li (2016), çalışmalarında Çin'deki kaza tutanaklarını Delphi yaklaşımıyla analiz ederek otobüs yangınına neden olan risk faktörlerini toplam 17 başlıkta toplamıştır. Buna göre olası risk faktörleri insan kaynaklı, çevreden kaynaklı ve araçtan kaynaklı faktörler olmak üzere üç aşamada değerlendirilerek analiz edilmiştir. Bu bağlamda son dönemlerde yaşanan otobüs yangınlarının iki önemli risk faktöründen kaynaklı olarak ortaya çıktığı sonucuna ulaşılmıştır. Bu risk faktörlerinden biri güvenlik eğitimi eksikliğiyle ilişkilendirilmişken diğ-eri yasal düzenlemelerde görölen yetersizliklerle ilişkilendirilmiştir. Dolayısıyla yapılan analizin sadece otobüs yangınlarıyla sınırlı tutulmaması, trafikte yaşanan kazalar ve demiryolu kazaları gibi kaza türleriyle karşılaştırılarak kapsamının genişletilmesi önerisinde bulunulmuştur.

Kılıç (2019), çalışmasında otobüs yangınlarını; motor bölümünden kaynaklı yangınlar, elektrik tesisatı kaynaklı yangınlar, tekerlek yuvası kaynaklı yangınlar, yolcu bölmesinde çıkan yangınlar ve alternatif yakıtlardan kaynaklanan yangınlar biçiminde sıralamışken alınması gereken önlemleri ise zamanında yapılan bakım, yangın algılama sistemleri ve yangın söndürücüler biçiminde sıralamıştır. Sonuç olarak sefere çıkan her otobüsün motor bölmesi ile diğ-er kısımlarındaki parçalarının fiziksel

olarak kontrol edilmesi ve yapılan risk değerlendirmesi sonucunun tutanak altına alınmasının gerekliliği ve önemi belirtilmiştir.

Karadeniz (2019), çalışmasında son yıllarda sıkça karşılaşılan otobüs yangınlarının oluşma nedenlerini tespit etmeye yönelik bir araştırmada bulunmuş ve kamuoyunun merak ettiği sorulara cevap aramıştır. Buna göre; oluşan yangınların genellikle trafik kazası, imalat hatası, bakımsızlık, yorgunluk, ihtimal, eğitimsizlik ve dikkatsizlik gibi faktörlerden kaynaklandığı üzerinde durulmuştur. Sonuç olarak aracın orijinal donanımını bozan ve araç üzerindeki yangın riskini arttıran değişiklikleri engellemeye yönelik çalışmaların yapılması ve araç denetimlerinin arttırılması önerisinde bulunulmuştur.

Yıldır ve Nazlier (2019), yaptıkları çalışmada yangınla sonuçlanan kazalarda otobüs firmalarının “Karayolu Yolcu Taşımacılığı Zorunlu Koltuk Ferdi Kaza Sigortası” kapsamındaki sorumluluk ve yükümlülüklerinin neler olduğunu belirlemeye çalışmıştır. Buna göre otobüs firmalarının yolcu taşımacılığı faaliyetinde bulunurken öncelikle yolcu taşıma yetki belgesine sahip olmaları, sefere çıkan aracın muayenesini yaptırılmaları ve her bir yolcuya “zorunlu koltuk ferdi kaza sigortası” yaptırılmaları gerektiği üzerinde durulmuştur.

Yıldız ve Köse (2020), yaptıkları çalışmada motorlu araç yangınlarının çarpma olmadan ya da çarpışmadan kaynaklı olduğunu belirterek çarpışmadan kaynaklı araç yangınlarını dört başlık altında incelemiştir. Bunlar; Araç motoru bölümünde çıkan yangınlar, yakıtın dökülmesiyle birlikte başlayan yangınlar, yolcu bölümünde çıkan yangınlar ve diğer bilinmeyen bölümlerde çıkan yangınlar biçiminde sıralanmıştır. Sonuç olarak yangın sayısını en aza indirmek için yalıtımdan periyodik bakıma kadar bir dizi önlemin alınması, motor bölmesinin ise otomatik yangın söndürme sistemi ile korunması önerisinde bulunulmuştur.

Li, Xu ve Bian (2022), yaptıkları çalışmada otobüs yangını sırasında yolcu davranışlarının temel özelliklerini ele alarak genel bir tahliye modeli geliştirmiştir. Bunun için olası bir yangın durumunda dar olan alanlardan yolcuların kolaylıkla tahliye edilmesini sağlayacak uygulamalar geliştirilmiş ve bu sayede yaralanma ve ölüm riski en az seviyeye indirilmeye çalışılmıştır. Yanıcı maddeler ile dolu olan otobüslerin potansiyel olarak tehlike arz ediyor olması ise bu hususta çalışma yapılması ihtiyacını ortaya çıkarmıştır. Sonuç olarak tahliye seçeneklerinin iyi anlaşılması ve tahliyenin hızlı bir biçimde gerçekleştirilmesi için uygun politika ve düzenlemelere ihtiyaç duyulduğu anlaşılmıştır.

Doğan, Güven, Şahinöz ve Nas (2023), çalışmalarında 2007-2019 yılları arasında Türkiye’de meydana gelen ve haber ajanslarında yayımlanan otobüs kaza-yangın haberlerini analiz etmeye çalışmıştır. Buna göre ilgili haber sitelerinden toplam 297 otobüs kazası ve yangın haberi alınmış ve alınan veriler içerik çözümleme yöntemiyle analiz edilmiştir. Sonuç olarak kazalardaki periyodik dağılıma bakıldığında en fazla kazanın mayıs ve haziran aylarında meydana geldiği görülürken otobüs yangınlarındaki artışın ise sıcaklık değerlerinin maksimum seviyelere ulaştığı ağustos ayında olduğu görülmüştür.

3. YÖNTEM

Araştırmanın bu aşamasında araştırma verileri ve verilerin analizi ile ilgili konularda bilgilendirmede bulunulmuştur.

3.1. Araştırmanın Verileri

Literatür taraması ve internet araştırması sonucunda erişilen veriler üzerinden derlenerek oluşturulan bu çalışmanın yazımında basılı ve elektronik ortamda yayınlanan tez, kitap, rapor, bildiri metni, kurumsal yayın, haber sitesi ve dergi gibi kaynaklardan faydalanılmıştır.

3.2. Verilerin Analizi

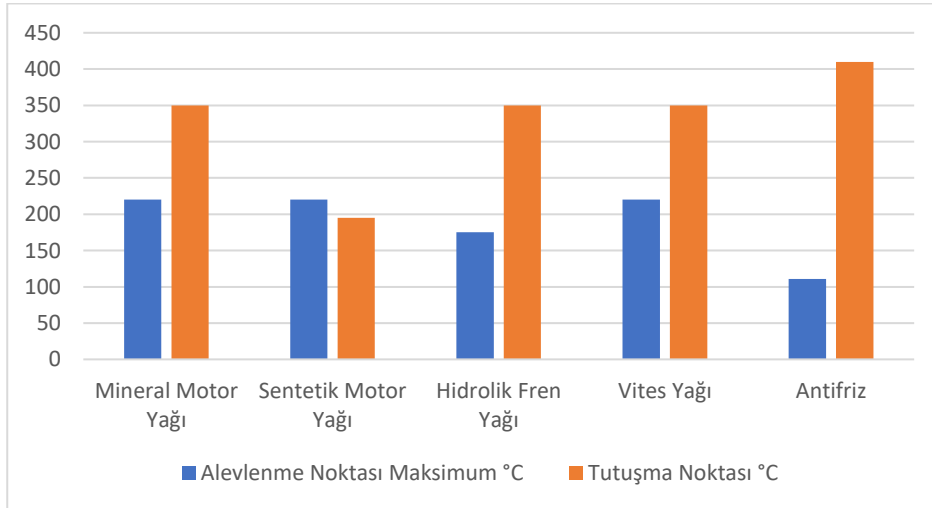
Nitel araştırma içerisindeki veri toplama araçlarından biri olan doküman taramasıyla erişilen veriler çalışmanın esas kısmını oluşturmaktadır. Doküman taraması; güvenilirlik ve temsil edilebilirliği kontrol edilen ve bilimsel çalışmalarda referans gösterilen yayınlar üzerinden oluşturulmuştur. Elde edilen veriler hem yerli hem de yabancı literatürle karşılaştırılmış ve araştırmacı tarafından yorumlanmıştır.

4. BULGULAR

Otobüslerde çıkan yangınların genel olarak araçtan kaynaklı, çevresel kaynaklı ve insandan kaynaklı faktörlere bağlı olarak ortaya çıktığı bilinmektedir. Bu bağlamda sıcak iklim koşulları, sürücü hatası, alternatif yakıt kullanımı, aracın yaşı, söndürme ekipmanlarının yetersizliği, aksatılan bakımlar, sürekli seferler, sigara kullanımı, korumasız malzeme ve yetkisiz tadilatlar gibi faktörlerin yangın riskini arttırdığı anlaşılmaktadır. Çalışmanın bu kısmında “araçtan kaynaklı” faktörlere değinilerek otobüslerin muhtelif bölümlerinde çıkan yangınlara ilişkin bilgilendirmelerde bulunulmuştur. Buna göre üretim hatası, sabotaj, doğal afetler, kundaklama ve kaza dışında meydana gelen yangınlar ise “çevresel faktörlerden kaynaklı yangınlar” ve “insan kaynaklı faktörler” alt başlığı altında incelenmiştir.

4.1. Motor Bölmesinde Çıkan Yangınlar

Araçlarda tespiti ve söndürülmesi oldukça zor olan yangınlar genellikle aracın motor bölümünde ortaya çıkmaktadır. Yaklaşık 95°C civarında olan motor gövdesi 70-90°C aralığındaki hava sıcaklığıyla birlikte sürekli bir biçimde ısı üretmekte ve özellikle egzoz boruları üzerinde 600°C'ye kadar varan sıcaklıklara neden olmaktadır. Bunun yanı sıra motor bölümünde yer alan katı sıvı ve gaz hâlindeki yanıcı maddeler ise olası bir deformasyon ya da sızıntı durumunda yangın riskini arttırmaktadır. Bu bağlamda motor bölümündeki açıklıklar ve fanlarla oluşturulan havalandırma sistemi bir yandan motorun soğutulmasına yardımcı olurken diğer yandan yangın anında alev yoğunluğunun artmasına neden olabilmektedir. Motor sıcaklığı, yanıcı sıvıların sıcaklığından fazla olduğu için yangının başlaması ve yayılması bu bölmede daha kolay gerçekleşmektedir (Kılıç, 2019: 18; Yıldır ve Nazlıer, 2019: 33). Çünkü motor içerisinde yaklaşık 35-45 litre motor yağı, 15-20 litre hidrolik yağı ve 50 litre civarında soğutucu akışkan bulunmaktadır (Yıldız ve Köse 2020: 122). Buna göre sıcak yüzeyle temas eden yanıcı sıvı temas ettiği sıcak yüzeyden ısı almakta ve diğer kısımlara temas etmektedir. Dolayısıyla sızıntı ya da soğutucu sistemlerde yaşanan arıza durumunda yangın riski ortaya çıkmaktadır.



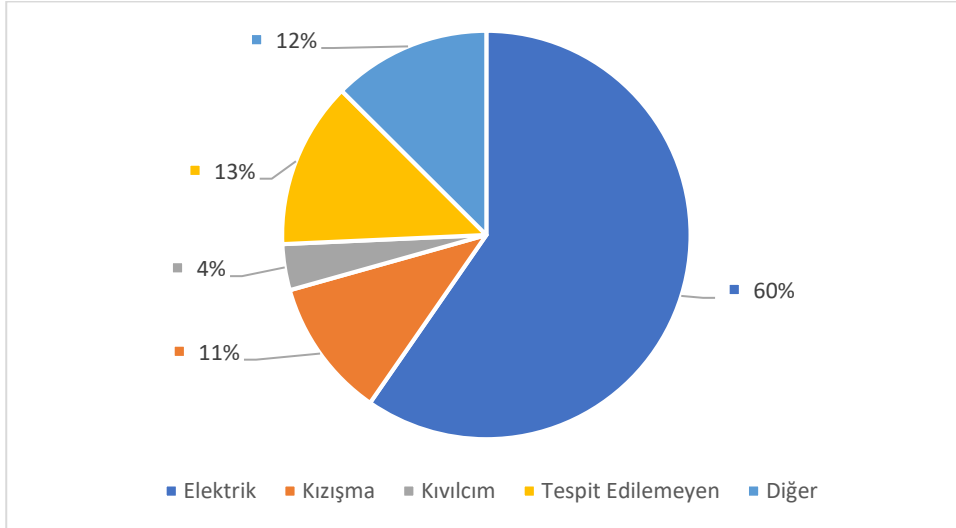
Şekil 1. Motor içerisindeki sıvı ve yağların alevlenme ve tutuşma noktaları °C (Hammarström ve ark. Aktaran Yıldız ve Köse, 2020: 122)

Şekil 1’de motor içerisindeki sıvı ve yağların alevlenme ve tutuşma dereceleri görülmektedir. Buna göre harici bir tutuşturma kaynağı verildiğinde madde buharının tutuşacağı en düşük sıcaklığa parlama noktası (Alevlenme noktası), harici bir tutuşturma kaynağı olmadan madde buharı ile hava

karışımının ateşlendiği en düşük sıcaklığa ise tutuşma noktası denilmektedir (Yamık, 2011: 8). Bu bağlamda mineral motor yağı 170-220°C aralığında alevlenirken 350°C'de tutuşmaktadır. Sentetik motor yağı 220 °C'de alevlenirken 170-220°C aralığında tutuşmaktadır. 175°C'de alevlenen Hidrolik fren yağı 350°C'de tutuşmaktadır. Vites yağı 220°C'de alevlenmekte olup 350°C'de tutuşmaktadır. Antifriz ise 111°C'de alevlenirken 410°C'de tutuşmaktadır.

4.2. Elektrik Tesisatından Kaynaklı Yangınlar

İmalattan kaynaklı hatalar, yetkili olmayan servislerde yapılan tadilatlar, yasal olmayan değişiklikler, sonradan yapılan ekler (buzdolabı, internet, kahve makinesi, TV, priz ve USB bağlantıları) ile standart dışı elektrikli su ısıtıcısı kullanımı elektrik tesisatı üzerindeki yükü arttırmaktadır. Teknoloji kullanımıyla birlikte otobüslerde kullanılan kablo sayısı ve uzunluğu da artmıştır. Bu nedenle gerek ağırlık gerekse maliyetleri azaltmak için daha küçük kesitli kablolar kullanılmaya başlanmıştır. Uzun kablolarla yapılan besleme, gerilimin düşmesine ve elektrik kablolarında aşırı akım çekilmesine yol açarken kablo kesitindeki küçülme ise aşırı yüklemeye ve kabloların ısınmasına yol açmaktadır. Bunun yanı sıra seyahat esnasında oluşan titreşimler elektrik tesisatında yalıtım oluşturan tabakanın aşınmasına ve bunun sonucunda kısa devre oluşmasına neden olmaktadır (Kılıç, 2019: 17; Polat, 2019).




Şekil 2. 2020 yılı itibarıyla İstanbul ilindeki araç yangınlarının çıkış nedenleri (Arslan, 2022: 51)

Şekil 2'de İstanbul il sınırları içerisindeki araç yangınlarının çıkış nedenleri görülmektedir. İstanbul İtfaiye Dairesi Başkanlığı'nın 2020 yılı verilerine göre İstanbul il sınırları içerisinde meydana gelen araç yangın sayısı 1.509 olup çıkan yangınların %59,6'ı elektrik tesisatı, %11'i kızışma, %3,6'sı kıvılcım sıçraması, %13,1'i tespit edilemeyen, %12,7'si ise diğer nedenlerden kaynaklı olarak çıkmıştır.

4.3. Yolcu Bölmesinde Çıkan Yangınlar

Araç tasarımında kapı, pencere, perde, koltuk, koltuk örtüsü, koltuk içi sünger, kaplama ve döşeme elemanlarında kullanılan malzemelerin genel olarak yangına karşı düşük direnç gösterdiği bilinmektedir. Bu bağlamda yapılan araştırmalar yolcu bölgesinde oluşan yangınların genellikle motor bölgesinden yayıldığını ya da elektriksel bir arıza ile tetiklenerek ortaya çıktığını göstermektedir. Ancak bunun dışında gerek bagaja konulan eşyaların gerekse yolcuların yanlarında bulundurduğu el bagajlarının belirli riskler taşıdığı bilinmektedir. Otobüs terminallerinin birçoğunda vücut tarama sistemleri (el dedektörü ve geçiş tipi X-ray cihazı) haricinde posta ve kargoların içerisini kontrol etmeye yarayan X-ray cihazları bulunmamaktadır. Yolcu güvenliği açısından zafiyet oluşturan bu uygulama nedeniyle yanıcı, patlayıcı ya da parlayıcı niteliği taşıyan sıvılar kolaylıkla otobüslerde

taşınabilmektedir. Özellikle seyahat esnasında oluşacak olası bir tehlike karşısında yolcu bagajları kolaylıkla tutuşabilmekte ve yangına karşı düşük direnç gösteren kabin içi malzemeler kolaylıkla yanabilmektedir (Karadeniz, 2019: 45; Polat, 2019). Şekil 3'te yolcu otobüsü tasarımında yaygın olarak kullanılan malzemeler ve bu malzemelerin tutuşma noktaları °C gösterilmiştir.



Şekil 3. Yolcu bölümünde kullanılan malzemelerin tutuşma noktaları °C (Yıldız ve Köse, 2020: 123)

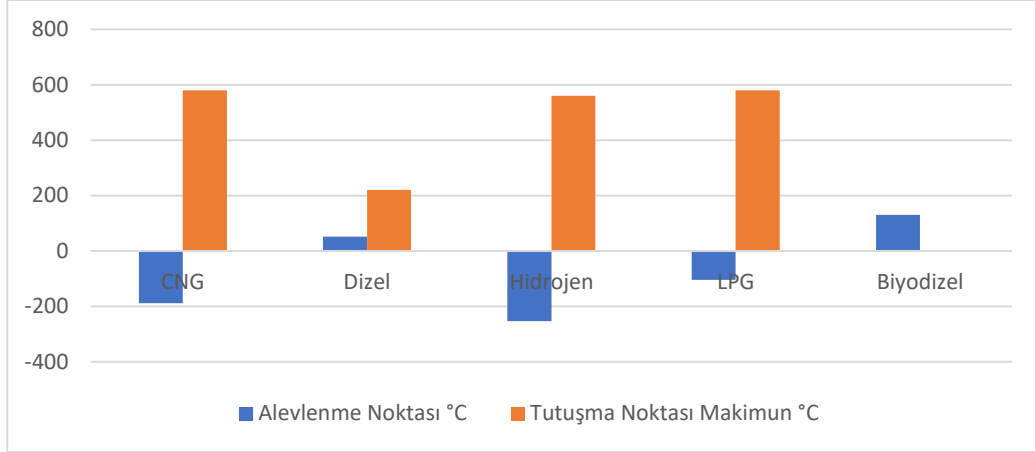
Şekil 3'te otobüslerin yolcu bölümünde kullanılan malzemelerin tutuşma dereceleri görülmektedir. Buna göre PA6 (PolyAmide 6) 65°C'de tutuşuyorken PC (PolyCarbonate) 115°C'de tutuşmaktadır. PVC'nin (PolyVinyl Chloride) tutuşma noktası 50°C iken PP (PolyPropylene) 80-115°C aralığında tutuşmaktadır.

4.4. Emisyon Temizleme Sistemleri ve Alternatif Yakıtlardan Kaynaklı Yangınlar

Zararlı egzoz emisyonlarının ve partikül taneciklerinin atmosfere atılmadan önce süzülmesini sağlamak için DOC (Dizel oksidasyon katalizörü), DPF (Dizel partikül filtresi) ve SCR (Seçici katalitik indirgeme) benzeri sistemlere ihtiyaç duyulmaktadır. Filtreli olan bu donanımlar enjektör, yakıt püskürtme sistemi ve sistemi yöneten yazılım ile birlikte uyumlu çalışmak üzere dizayn edilmiştir. Ancak günümüzde sürücüler tekrar eden ikaz ışığı uyarısı karşısında SCR sistemlerini AdBlue emülatör cihazı olarak adlandırılan aparatlarla ya da aracın orijinal yazılımına müdahale ederek devre dışı bırakılmaktadır. Filtrelerin durumunu önceden haber veren sistemin iptaliyle birlikte egzoz gazı çıkışındaki aşırı ısınma artık fark edilememektedir. Bunun sonucunda dışarı çıkmakta zorlanan egzoz gazları nedeniyle DOC, DPF ve SCR kombinasyonu aşırı ısınmakta ve 600°C civarında seyreden sıcaklık 800-1000°C sınırına ulaşarak tutuşabilir duruma gelmektedir (Dizdar, 2019: 37-38; Lök, 2019: 28-29).

Benzin ve motorin fiyatlarının yüksekliliği, akaryakıttan alınan vergi oranındaki değişkenlik ve indirimli bilet satışı gibi nedenlerden kaynaklı olarak şahıs ve firmalar motorine ikame olarak alternatif yakıt tüketimine yönelmektedir. Bu bağlamda özellikle fosil kaynaklı olmayan biyodizel ve 10 numara yağların alternatif yakıt olarak kullanıldığı görülmektedir (Kaya, 2006: 3). Yağlar genel itibarıyla mineral ve sentetik olmak üzere ikiye ayrılmaktadır. Petrolden elde edilenler, mineral yağlar olarak isimlendirilirken kimyasal yollarla elde edilenler sentetik yağlar olarak isimlendirilmektedir. Kamyonlarda ve şehirlerarası otobüslerde yaygın olarak kullanılan 10 numara yağlar genellikle solvent, baz yağ, atık bitkisel yağ ve atık madeni yağlarla karıştırılarak kullanıldığı için alevlenme ve tutuşma noktaları değişmektedir. Buna göre yapılan ölçümlerde mineral yağ olarak değerlendirilen 10 numara yağın viskozitesi dizel yakıtın yaklaşık 12 katı, biyodizel yakıtın ise yaklaşık 10 katı olduğu görülmüştür (Uyaroğlu, Yücesu ve Çıtak, 2010: 114-115). Açıkta satılan 10 numara yağlar, enjektörlerde ve yakıt pompasında aşınmalar ve düzensizlikler oluşturarak piston kafaları ve yanma odasında soğutmayı engelleyecek boyutta kurum birikimine neden olmaktadır. Kurum ise motor ısısını arttırarak hararete ve motorun etrafındaki PVC kaplı kabloların tutuşmasına sebebiyet vermektedir. Ayrıca dizel motorlarda yakıt pompasının motora göndermiş olduğu yakıtın bir kısmı silindirlere

püskürtülürken geri kalan kısmı yakıt geri dönüş hattı üzerinden yakıt deposuna geri gönderilir. Silindire püskürtülen yakıt enerjisinin yaklaşık %30'u mekanik güce dönüşürken geri kalan %70'lik enerji sürtünme, ısı transferi vb. mekanizmalar ile ısı enerjisi şeklinde motordan atılır. Buna göre yakıt yerine 10 numara yağ kullanıldığında bloklarda mazot yerine yağ dolaştığı için motor yeterince soğutulamamaktadır (Dizdar, 2019: 38).



Şekil 4. Motor içerisindeki yanıcı sıvıların alevlenme ve tutuşma noktaları °C (Biyodizel Endüstri Raporu 1, 2019: 24; Hammarström ve ark. aktaran Yıldız ve Köse, 2020: 122)


Şekil 4'te motor içerisindeki yanıcı sıvıların alevlenme ve tutuşma dereceleri görülmektedir. Buna göre CNG -188°C'de alevlenirken 580°C'de tutuşmaktadır. Dizel 52°C'de alevlenmekte ve 220°C'de tutuşmaktadır. -253°C'de alevlenen Hidrojen 560°C'de tutuşmaktadır. LPG ise -104°C'de alevlenmekte olup 430-580°C aralığında tutuşmaktadır. Setan sayısı dizel yakıtına göre daha fazla olan biyodizelin tutuşma gecikmesi daha yüksek olup 130°C'nin üzerine çıktığında alevlenmektedir.

4.5. Titreşimlerden ve Tekerlek Yuvasından Kaynaklanan Yangınlar

Gerek motor gerekse yola temas eden lastikler araçta titreşimler oluşturmaktadır. Buna göre araçta oluşan sarsıntılar aracı oluşturan bileşenler üzerinde yorulma, bağlantılarda gevşeme, kırılma ve kısa devre meydana getirerek ömürlü parçaların bozulma süreçlerini hızlandırmaktadır. Titreşim kaynaklı frekanslı hareketler hortum ve benzeri parçalar üzerinde çatlaklar oluşturarak yanıcı sıvıların sızmasına yol açmakta ve yangın riskini arttırmaktadır. Bunun yanı sıra tekerlek yuvası bölgesindeki bazı kaplamalardan kaynaklanan yangınlara da rastlanmaktadır. Araç lastiğini oluşturan bileşenlerin tutuşma sıcaklığı düşük olmakla birlikte 170-250°C arasında yanma özelliği göstermektedir. Bu bağlamda ilk aşama testlerinden başarılı bir biçimde geçen bazı kaplamaların zaman içerisinde meydana gelen bozulmalarla birlikte yangına karşı dirençsiz hâle geldiği görülmektedir. Buna göre ısı ya da kıvılcımların etkisiyle oluşan yayılmanın tekerlek yuvası bölgesinden yolcu bölümüne geçmesiyle birlikte yangın riski ortaya çıkmaktadır (Kılıç, 2019: 17-18; Yıldız ve Nazlıer, 2019: 31-32; Yıldız ve Köse, 2020: 123).

5. ÇEVRESEL FAKTÖRLERDEN KAYNAKLI YANGINLAR

İklim ve yol durumuna bağlı olarak ortaya çıkan otobüs yangınları “çevresel faktörlerden kaynaklanan yangınlar” kategorisinde değerlendirilmektedir. Buna göre sıcak hava, nem, kar, dolu, yağmur, sis, sel ve yıldırım düşmesi gibi hava olaylarına bağlı olarak çıkan yangınlar iklimsel koşullarla ilişkilendirilirken yüksek kasis, kaygan zemin, mıcırly yol, çukur ya da başka bir aracın karıştığı kazaya bağlı olarak çıkan yangınlar yol durumuyla ilişkilendirilmektedir (Feng vd., 2016: 9-10; Tunca, 2019: 18-19).

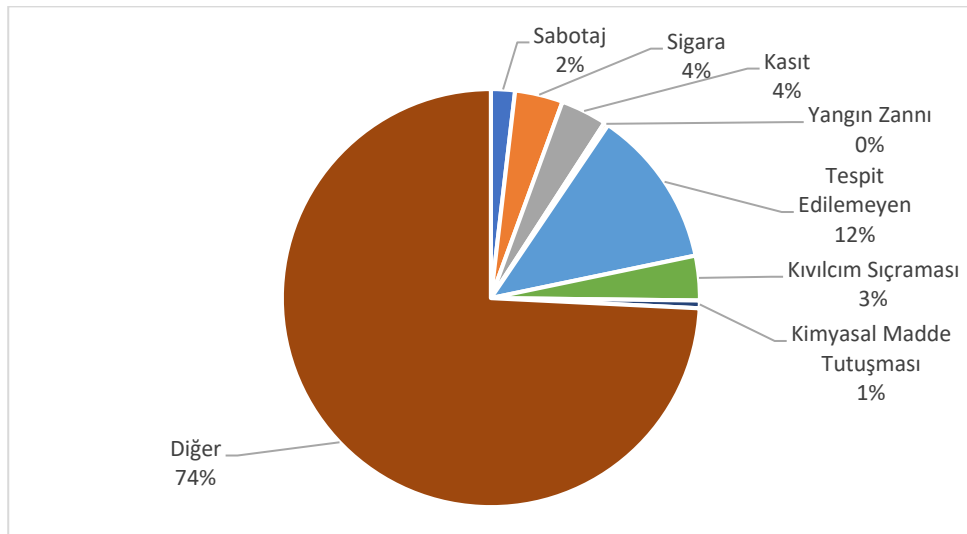


Şekil 5. 2020 yılı itibarıyla İstanbul ilindeki araç yangınlarının mevsimsel dağılımı (Arslan, 2022: 51)

Şekil 5'te İstanbul il sınırları içerisindeki araç yangınlarının mevsimsel dağılımı görülmektedir. İstanbul İtfaiye Dairesi Başkanlığı'nın 2020 yılı verilerine göre İstanbul il sınırları içerisindeki mevsimler bazında meydana gelen araç yangın sayısının 1.509 olduğu görülmektedir. Buna göre çıkan yangınların %26,40'ı aralık, ocak, şubat aylarında, %19,7'si mart, nisan, mayıs aylarında, %27,7'si haziran, temmuz, ağustos aylarında, %26,1'si ise eylül, ekim ve kasım aylarında yaşanmıştır.

6. İNSAN KAYNAKLI FAKTÖRLER

Otobüs yangınlarındaki en aktif rolü insan kaynaklı faktörler oluşturmaktadır. Bu bağlamda ortaya çıkan riskler, sürücüler ve yolculardan kaynaklanan riskler olarak kategorize edilmektedir. Genel olarak riskli sürüş, yorgunluk, alkollü araç kullanma, görevli personelin eğitimsizliği ve aksatılan bakımlar sürücüden kaynaklanan riskler olarak kabul edilirken kundaklama, seyahat esnasında sigara kullanma, yolcu koltuğundaki elektronik sistemlere zarar verme, şüpheli bir durumu yetkililere bildirmede geç davranılması, yanıcı ya da patlayıcı madde bulundurma gibi olgular yolculardan kaynaklanan riskler olarak kabul edilmektedir (Feng vd., 2016: 7-10; Mississippi İtfaiye Akademisi Yangın Müfettişi, t.y.).



Şekil 6. 2020 yılı itibarıyla İstanbul ilindeki insan kaynaklı faktörlere bağlı oluşan araç yangınları (Arslan, 2022: 53-54)

Şekil 6'da İstanbul İtfaiye Dairesi Başkanlığı'nın 2020 yılı verilerine göre İstanbul il sınırları içerisindeki meydana gelen araç yangın sayısının 1.509 olduğu görülmektedir. Buna göre çıkan yangınların 204'ü doğrudan insan kaynaklı faktörlere bağlı, 185'i tespit edilemeyen, 1120'si ise diğer nedenlerden kaynaklı olarak ortaya çıkmıştır.

7. TARTIŞMA VE SONUÇ

Avrupa ve Amerika'daki veriler, otobüs yangınlarının yüzde 70-74'ünün motor bölmesinden kaynaklı olduğunu gösterirken Türkiye'deki veriler oluşan yangınların motor bölmesinin yanı sıra araç içindeki elektrik tesisatından kaynaklandığını göstermektedir (Elektrik Mühendisleri Odası İzmir Şubesi, 2019: 335). Otobüste oluşan ısının önemli bir kısmı motor bölmesinde kalan diğer kısmı ise iklimlendirme ve egzoz sistemi boyunca açığa çıkmaktadır. Bu bağlamda ısının asıl kaynağı olarak görülen motor bölmesinde ortalama 95°C civarında kesintisiz bir biçimde ısı üretilmektedir. Bunun yanı sıra motorun sağlıklı bir biçimde çalışabilmesi için de motor bölmesinde katı sıvı ya da gaz hâlde bulunan maddelere ihtiyaç duyulmaktadır. Özellikle motor bölmesindeki sıvı maddelerin birçoğu düşük yanma direncine sahip olup olası bir sızıntı durumunda yangına neden olabilmektedir. Normal koşullarda motorun ideal ısıda kalmasını sağlayan soğutucu ve fanlar, olası bir alev durumunda yanma sürecinin hızlanmasına neden olabilmektedir.

Yapılan araştırmalar otobüs yangınlarının yaklaşık 1/5'inin elektrik tesisatından kaynaklı problemlerden çıktığını göstermektedir. Otobüsler diğer kara taşıtlarına göre daha karmaşık yapıya sahiptir. Bu nedenle üretici desteği olmadan imalattan kaynaklı herhangi bir hatanın anlaşılması güçleşmektedir. Bunun yanı sıra seyahat süresinin uzunluğuna bağlı olarak ortaya çıkan konfor, sıcak iklimlere yönelme ve ek priz bağlantıları gibi ihtiyaçlar, uzun ve karmaşık olan elektrik sistemleri üzerinde ekstra yük oluşturmakta ve zaman içerisinde dayanımı azalan kablolarla kalıcı zararlar vermektedir. Bu bağlamda artan maliyetleri gerekçe gösteren işletmeciler teknik destek almak yerine ya anlık çözüm arayışına yönelmekte ya da aracın bakımını yetkili olmayan servislerde yapmaya çalışmaktadır. Dolayısıyla mevcut değişkenlerin bir ya da birkaçı dâhi henüz sefere çıkmamış park hâlindeki bir otobüste kısa devre oluşmasına neden olmaktadır.

Her ne kadar otobüs tasarımında yanmaya karşı dirençli malzemeler kullanılsa da ömürlü olan ve zaman içerisinde dayanımı azalan koltuk, perde, kolçak, kaplama ve döşeme gibi elemanlar bir süre sonra potansiyel olarak risk oluşturmaya başlamaktadır. Buna göre yolcu bölmesi ve bagajda taşınan kişisel eşya ve kargolar da seyahat güvenliği açısından çoğunlukla büyük riskler içermektedir. Çünkü otobüs işletmelerinin birçoğu kapalı ya da izole edilmiş kargoların içeriğini kontrol etmeden taşımayı kabul etmektedir. Seyahat güvenliği açısından zafiyet oluşturan bu uygulama nedeniyle kolaylıkla tutuşma ihtimali bulunan herhangi bir yanıcı madde otobüs içerisine girebilmektedir.

Ekonomik koşullardaki istikrarsızlık karşısında alternatifler üretmeye çalışan otobüs firmaları standart dışı AdBlue ve 10 numara yağ kullanarak maliyetlerini azaltma yoluna gitmektedir. Günümüzdeki araçların önemli bir kısmında tekrar eden ikaz ışığı uyarısı karşısında sürücüler SCR sistemlerini AdBlue emülatör cihazı olarak adlandırılan aparatlarla devre dışı bırakılmaktadır. Bu bağlamda gerek sürücüler gerekse araç servisleri tekrarlayan ikaz ışığı uyarısını şehir içi trafikten kaynaklı kronik bir problem olarak yorumlamaktadır. Günlük kullanımda ya da araç satışı sırasında psikolojik olarak rahatsızlık hissi oluşturan bu olgu karşısında yetkili olmayan servisler, ikaz uyarı ışığını pasif duruma getirmek için genellikle motor kontrol ünitesine (ECU) yazılımla müdahale etmektedir. Bunun yanı sıra partikül filtresi (DPF) ve SCR katalizörü araçtan çıkarılmakta, sensörler değiştirilmekte, uyarı ışığının elektrik bağlantısı kesilmekte ya da gösterge panelinde bulunan ikaz ışığının üzerine siyah bant çekilmektedir. Bu bağlamda son yıllarda yaşanan otobüs yangınlarının önemli bir kısmının ise AdBlue emülatör cihazı olarak adlandırılan aparatların kullanımından kaynaklandığı düşünülmektedir (Dizdar, 2019: 37; Tele1, 2019; Venedik, 2019). Yakıt yerine 10 numara yağ kullanımı, yangın riski başta olmak üzere çevre kirliliği, dolaylı vergilerde kayıp ve

akaryakıt satışında düşme gibi birtakım olumsuzluklar içermesine rağmen günümüzde hâlâ şahıs ve firmalar tarafından tercih edilmektedir. Özellikle son yıllarda 10 numara yağ kullanımını engellemeye yönelik birçok yasal düzenleme yapıldığı bilinmektedir. Adli ve idari yaptırımların yanı sıra kaçakçılıkla mücadele kanunu kapsamında da engelleyici girişimlerde bulunulmasına rağmen 10 numara yağ satışı ve kullanımı tam olarak engellenememiştir.

Karmaşık ve büyük boyutlu olan otobüsler çok sayıda parçanın bir araya gelmesinden oluşmaktadır. Buna göre hem otobüslerin hareket etmesini sağlayan motor aksamı hem de seyruferde oluşan sarsıntılar araç üzerinde frekanslı titreşimler oluşturarak aracı oluşturan bileşenlerde gevşeme, yorulma ve kırılmalara neden olmaktadır. Ömürlü parçaların bozulma süreçlerini hızlandıran ritmik hareketlerle birlikte genellikle hortum ve keçe aralarında kaçaklar oluşmaktadır. Oluşan sızıntılar ise olası yangın riskini arttırmaktadır.

Trafik kazalarının önemli bir kısmını maddi hasarlı kazalar oluşturmaktadır. Yaşanan kaza sonucunda ekstrem bir durum oluşmadığı müddetçe yangın ihtimali oluşmamaktadır. Bu bağlamda oluşan kazaların ise genellikle insan faktörü, iklim ve yol durumuna bağlı olarak oluştuğu görülmektedir. Özellikle ağır tonajlı araçların ya da otobüslerin karıştığı kazalarda yangın riskinin diğer kara taşıtlarına göre daha yüksek olduğu gözlenmektedir. Buna göre ağır tonajlı araçlara göre daha karmaşık olan ve bu karmaşıklığın yanında bir de insan transferinde kullanılan otobüslerde diğer risklerin yanı sıra bir de insan kaynaklı risk faktörlerine karşı önlem almak gerekmektedir. Buna göre otobüslerdeki yangın riskini asgari seviyeye indirmek için alınması gereken önlemler maddeler hâlinde sıralanmıştır. Bunlar:

- Daha kapsamlı ve caydırıcı yasal düzenlemeler yapılabilir.
- Şehirlerarası otobüs terminallerine denetimli akaryakıt istasyonları ve yetkili servisler açılabilir. Sunulan hizmetlerden faydalanan firmalara teşvik verilebilir.
- Otobüslere belirli aralıklarla ücretsiz kapsamlı muayene zorunluluğu getirilebilir.
- Şehirlerarası otobüs terminallerine detaylı çanta ve üst araması zorunluluğu getirilebilir.
- Otobüste görevli personellere belirli aralıklarla eğitimler verilebilir. Bunun için özerk enstitülerin açılması fayda sağlayabilir.
- Otobüs firmalarına her yakıt alımında vergi indirim uygulanabilir.
- Alınan yakıt fişlerini yıllık bazda kilometre bilgisi ile karşılaştıracak bir sistemin geliştirilmesi vergilendirme açısından fayda sağlayabilir.
- Yapılan tadilatlar için izin zorunluluğu getirilebilir. Yetkisiz tadilatlar için caydırıcı nitelikte yaptırımlar uygulanabilir.

Otobüslerde yangına neden olan risklerin önemli bir kısmının ekonomik gerekçelere ve maliyetlerdeki artışa bağlı olarak ortaya çıktığı görülmektedir. Buna göre şahıs ve firmaları koruyacak önlemlerin alınması durumunda otobüslerdeki yangın riskinin asgari seviyeye ineceği anlaşılmıştır. Ayrıca yangın riskine karşı alınacak önlemlerin konforlu seyahat avantajı sağlayacak uygulamalar içerdiği görülmüştür.

8. KAYNAKÇA

- Arslan, E. (2022). *T.C. İstanbul Büyükşehir Belediyesi İtfaiye Daire Başkanlığının 2020 yılı araç yangını kayıtlarının değerlendirilmesi*. (Yayınlanmamış yüksek lisans tezi). Bezmialem Vakıf Üniversitesi, İstanbul.
- Biyodizel Endüstri Raporu 1. (2019). *Sürdürülebilir bir gelecek için yerli yeşil yakıt biyodizel*. İzmir: Biyodizel Sanayi Derneği. [www.http://efaidnbmnnnibpcajpcgclefindmkaj/https://biyoyakit.org.tr/asset/pdf/biyodizel.pdf](http://efaidnbmnnnibpcajpcgclefindmkaj/https://biyoyakit.org.tr/asset/pdf/biyodizel.pdf) Erişim Tarihi: 05.05.2024.
- Dizdar, F. T. (2019). Otobüs yangınlarında yakıt püskürtme ve emisyon sistemlerinin rolü. *Mühendis ve Makine Güncel Dergisi*, (30), 36-39.

- Doğan, A., Güven, T., Şahinöz, S., ve Nas, M. (2023). 2007-2019 yılları arasında meydana gelen otobüs kaza ve yangın haberlerinin nicel analizi: Anadolu ve İhlas Haber Ajansı örneği. *Gümüşhane Üniversitesi Sağlık Bilimleri Dergisi*, 12 (4), 1674-1684.
- Elektrik Mühendisleri Odası İzmir Şubesi. (2019). *Denetim, denetim, denetim... otobüs yangınlarına karşı önlem çağrısı*. İzmir: 32. Dönem Çalışma Raporu.
- Feng ve Li (2016). Analysis of bus fires using interpretative structural modeling. *Journal of Public Transportation*, 9(3), 1-18. doi: 10.5038/2375-0901.19.3.1
- Hoffman, A., Dülsen, S. ve Klipper, A. (2013, 28-30, Ocak). Problems in bus fire safety-recent developments and possible solutions. *Fire and Materials Conference*. San Francisco, USA. <https://www.firescienceshow.com/029-busses-flammability-and-an-unknown-force-holding-good-solutions-back-with-anja-hofmann-bollinghaus/>
- Karadeniz, R. (2019). Şehirlerarası otobüs yangınlarında can ve mal kayıpları önlenmeli. *Mühendis ve Makine Güncel Dergisi*, (30), 40-45.
- Kaya, C. (2006). *Bitkisel yağlardan biyodizel üretimi*. (Yayınlanmamış yüksek lisans tezi). Dicle Üniversitesi, Diyarbakır.
- Kılıç, A. (2019). Otobüs yangınları: sebepler ve önlemler. *Mühendis ve Makine Güncel Dergisi*, (30), 15-22.
- Li, Z. Xu, C., ve Bian, Z. (2022). A force-driven model for passenger evacuation in bus fires. *Physica A: Statistical Mechanics and its Applications*, 589, 126591 doi.org/10.1016/j.physa.2021.126591.
- Lök, A. (2019). Otobüs Yangınları Nasıl Önlenir. *Mühendis ve Makine Güncel Dergisi*, (30), 27-29.
- Mississippi İtfaiye Akademisi Yangın Müfettişi. (t.y.). *Araç yangınları*. <https://firemedic.tr.gg/ara%E7-yang%26%23305%3Bnlar%26%23305%3B-ve-kriminolojisi.htm> Erişim Tarihi: 06.05.2024.
- Polat, S. (2019). *Otobüs Yangınlarının sebepleri ve önleme yöntemleri*. <http://omd.org.tr/teknik-yazilar/otobus-yanginlarinin-sebepleri-ve-onleme-yontemleri/> Erişim Tarihi: 05.05.2024.
- Smyth, S. A. ve Dillon, S. (2012). Common causes of bus fires. *SAE Technical Paper Series*, 1-10. doi: 10.4271/2012-01-0989
- Tele1 (2019). *On beş günde 5 otobüs yangını: Yolcu otobüslerinin yanma sayıları neden arttı?* https://tele1.com.tr/on-bes-gunde-5-otobus-yangini-yolcu-otobuslerinin-yanma-sayilari-neden-artti-76199/#google_vignette Erişim Tarihi: 16.06.2024.
- Tunca, K. (2019). *Otomotiv sanayi için bir yangın güvenliği modeli*. (Yayınlanmamış yüksek lisans tezi). Sakarya Üniversitesi, Sakarya.
- Uyaroğlu, A., Yücesu, H. S., ve Çıtak, R. (2010). Piston arızalarının analizi. *Selçuk-Teknik Dergisi*, 9(2), 110-130.
- Venedik, Y. (2019). *Otobüs yangınları araçlardaki adblue yazılımına müdahale, felakete davetiye çıkarıyor*. <https://onedio.com/haber/otobus-yanginlari-araclardaki-yazilima-mudahale-felakete-davetiye-cikariyor-884203> Erişim Tarihi: 16.06.2024.
- Yamık, H. (2011). *Dizel motor enjektörlerinin uç kısımlarında yakıt kaynaklı oluşan hasarın analizi*. T.C. Şeyh Edebalı Üniversitesi Bilimsel Araştırma Projesi Sonuç Raporu. (Proje No: 2011-02-Bil.03-02). <https://acikkaynak.bilecik.edu.tr/xmlui/bitstream/handle/11552/2219/2011-02.B%C4%B0L.03-02.pdf?sequence=1&isAllowed=y> Erişim Tarihi: 16.06.2024.
- Yıldır ve Nazlier (2019, Haziran). On beş günde altı otobüs yangını ve ilgili sigorta mevzuatı. *Mühendis ve Makine Güncel Dergisi*, (30), 30-35.
- Yıldız, Z. ve Köse, E. (2020). Motorlu araç yangınları üzerine bir inceleme. *Avrupa Bilim ve Teknoloji Dergisi*, (19), 119-126.



Gastronomi ve Mutfak Sanatları Bölümü Öğrencilerinin Yeme Davranışı Eğilimleri: Karabük Üniversitesi Örneği

Özlem ÖZER ALTUNDAĞ^{1*}, Sena ATİK²

*¹Karabük Üniversitesi, TÜRKİYE

²Karabük Üniversitesi, TÜRKİYE

Doi: 10.55024/buyasambid.1448104

MAKALE BİLGİSİ

Makale Türü: Araştırma Makalesi

Makale Geçmişi:

İlk gönderim tarihi: 06.03.2024

Düzeltilme tarihi: 04.04.2024

Kabul tarihi: 15.04.2024

Yayın tarihi: 07.07.2024

Anahatar Kelimeler:

Gastronomi, Beslenme, BKİ, Yeme Davranış Bozuklukları.

*¹ Özlem ÖZER ALTUNDAĞ

E-mail address:

ozlemezeraltundag@karabuk.edu.tr

Orcid: 0000-0001-7117-6335

² Sena ATİK

E-mail address:

senaa.atik23@gmail.com

Orcid: 0000-0002-5384-1757

ÖZET

Bu çalışmada Gastronomi bölümü öğrencilerinin yeme davranış bozukluklarına olan eğiliminin incelenmesi hedeflenmiştir. Bu amaç doğrultusunda Karabük Üniversitesi'nde öğrenim gören Gastronomi ve Mutfak Sanatları öğrencileri evreni oluşturmuştur. Veri toplamada nicel araştırma yöntemlerinden anket tekniği kullanılmış ve 200 öğrenciye ulaşılmıştır. Elde edilen veriler SPSS v.20 programında analiz edilmiştir. Araştırmaya katılan öğrencilerin %59,5'inin Beden Kitle İndeksi(BKİ) değerlerinin normal referans değerinde olduğu ve çoğunluğun cinsiyetinin kız olduğu (%61) belirlenmiştir. Öğrencilerin yeme bozukluklarına eğilimleri ile cinsiyet, öğün atlama durumu, yaş ve sınıf düzeyleri arasında herhangi bir anlamlılık tespit edilemezken ($p>0,05$) vücut ağırlığını korumaya olan eğilimleri, barındıkları yer, spor/egzersiz yapma durumları, sigara/alkol tüketim durumları ve vücut ağırlığı memnuniyeti ile yeme davranışları arasında anlamlılık tespit edilmiştir ($p<0,05$). Bu araştırma Karabük Üniversitesi Gastronomi ve Mutfak Sanatları bölümü öğrencileri ile sınırlı kalmaktadır. Dünyada giderek artan yeme davranış bozukluklarının önlenmesi amacıyla besinlerle iç içe olan ve yeni popülaritesi yükselmiş olan gastronomi bölümü öğrencilerinin ve mezunlarının bu durumdan nasıl etkilendiklerinin araştırılması sağlıklı toplum oluşturmaya katkı sağlayacaktır. İleriki çalışmalarda farklı üniversitelerin gastronomi bölümleri öğrencilerine ya da mezunlarına ulaşılarak daha kapsamlı araştırmalar gerçekleştirilebilir ve bu araştırma ile karşılaştırılabilir.

2024 Batman Üniversitesi. Her hakkı saklıdır.

Eating Behavior Tendencies of Gastronomy and Culinary Arts Department Students: Karabük University Example

Özlem ÖZER ALTUNDAĞ^{1*}, Sena ATİK²

*¹Karabük University, TURKEY

²Karabük University, TURKEY

Doi: 10.55024/buyasambid.1448104

Article Type: Research Article

Article history:

Received: 06.03.2024

Received in revised form:
04.04.2024

Accepted: 15.04.2024

Available online: 07.07.2024

Keywords:

Gastronomy, Nutrition, BMI,
Eating Behavior Disorders.

*¹Özlem ÖZER ALTINDAĞ

E-mail address:

ozlemozeraltundag@karabuk.edu.tr

Orcid: 0000-0001-7117-6335

²Sena ATİK

E-mail address:

senaa.atik23@gmail.com

Orcid: 0000-0002-5384-1757

This research aims to examine the tendency towards eating behavior disorders among students of the Gastronomy and Culinary Arts Department. For this purpose, the universe consisted of students enrolled at Karabük University. Quantitative research methods were employed for data collection, utilizing the survey technique, and reaching 200 students. The obtained data were analyzed using the SPSS v.20 program. It was determined that 59,5% of the participating students had Body Mass Index (BMI) values within the normal reference range, with the majority being female (61%). While no significant correlation was found between students' tendencies towards eating disorders and gender, meal skipping habits, age, and class levels ($p > 0,05$), a significant relationship was identified between their tendencies ,o maintain body weight, place of residence, engagement in sports/exercise, smoking/alcohol consumption habits, satisfaction with body weight, and eating behaviors ($p < 0,05$). This study is limited to students of the Gastronomy and Culinary Arts Department at Karabük University. Investigating how gastronomy department students and graduates are affected by the increasingly prevalent eating behavior disorders, with their close association with food and their rising popularity, will contribute to the formation of a healthy society aimed at preventing such disorders. Future research could conduct more comprehensive studies by reaching out to students or graduates of gastronomy departments in different universities and comparing them with the findings of this study.

2024 Batman University. All rights reserved

1. GİRİŞ

Günümüzde, toplumun estetik beklentileri, medyanın etkisi ve bireyler arasında yaygınlaşan mükemmeliyetçilik anlayışı yeme bozukluklarının artışına etki etmektedir. Yeme bozuklukları, bireyin beslenme alışkanlıklarında ortaya çıkan anormal değişikliklerle karakterizedir ve genellikle fiziksel görünüşle ilgili derinlemesine duygusal ve zihinsel bir mücadeleyi yansıtır. Yeme bozukluğu, yüksek düzeyde yaygınlığı ve olası ciddi fiziksel ve ruhsal sonuçlarından dolayı özellikle ergen ve genç yetişkinlerde görülen önemli bir toplum sağlığı sorunudur (Tavolacci vd., 2015).

Beslenme toplumun her kesimi için önemli olsa da üniversite öğrencileri için farklı bir öneme sahiptir. Genellikle üniversite eğitimi sürecinde öğrenciler, ailelerinden uzakta yaşama deneyimiyle karşılaşır. Üniversiteye geçişle birlikte yaşam tarzları değişebilir ve bu da beslenme alışkanlıklarını etkileyebilir (Korkmaz, 2010). Bu dönemde aileden bağımsız yemek yeme alışkanlığına yönelme ile yiyecek tercihleri değişir ve beslenme ile ilgili riskli davranışlar görülebilir. Özellikle yağ ve enerji bakımından zengin, fast-food beslenme sıklığındaki artış ve fiziksel aktivitedeki azalma, obezite ve yeme bozuklukları oranlarının artmasına neden olabilmektedir (Kadioğlu, 2015). Bu yaşam dönemi ayrıca birçok zihinsel ve yeme bozukluğunun başlangıç zirvesiyle de örtüşmektedir, bu nedenle yaşam tarzı alışkanlıklarını iyileştirmek ve sağlıklı yeme alışkanlıkları geliştirmek için uygun bir hedef aşama olabilir (Harrer vd., 2020). Yeme bozukluklarının önlenmesi ve tedavisi için bütüncül bir yaklaşım ile

belirli risk faktörlerinin bilinmesi, gerektiğinde kullanılabilir olan bilgilerin geliştirilmesi oldukça önemlidir çünkü bir yeme bozukluğunun gelişimi için risk oluşturan kötü yeme alışkanlıklarının erken tespiti, bozuklukların yayılmasını azaltmada en önemli başlangıçtır (Le Grange & Loeb, 2007).

Özellikle Gastronomi ve Mutfak Sanatları gibi bireylerin gıda ile iç içe olduğu alanlarda yeme bozukluğuna olan eğilimlerin önemli olduğu söylenebilir. Aşırı olması veya yetersiz olması herhangi bir yeme bozukluğuna sebep olabileceği gibi bireyin yaşamını da oldukça etkileyecektir. Bu bağlamda bu araştırmada Gastronomi ve Mutfak Sanatları bölümü öğrencilerinin bazı yeme bozukluğu davranışları (hedonik-sınırlayıcı-duygusal) ile sosyo-demografik özellikleri ve beden kütle indeksi (BKİ) arasındaki ilişkinin incelenmesi hedeflenmiştir.

1.1. KURAMASL ÇERÇEVE

1.1.1. Yeme Bozuklukları

Yeme bozukluğu tanıları, Amerikan Psikiyatri Birliği (2013) Mental Bozuklukların Tanısal ve İstatistiksel El Kitabı tanımlamasına göre Anoreksiya Nervoza, Bulimia Nervoza, Aşırı Yeme Bozukluğu ve Kaçınan/Kısıtlayıcı Besin Alımı Bozukluğu olarak dört tanıda belirlenmiştir.

Anoreksiya Nervoza (AN), genellikle genç adölesanlarda, gençlerin veya genç yetişkinlerin, incelik konusunda acımasız ve başarılı bir takibe girdiği, ciddi kilo kaybına yol açan bir bozukluktur. AN, artan fiziksel aktivite; depresyon, yeme üzerine obsesif düşkünlük; kalp atış hızında, kan basıncında ve metabolik hızda azalma; artan kortizol üretimi ve östrojen (erkeklerde testosteron) üretiminde derin bir azalma dahil olmak üzere belirgin davranışsal, psikolojik ve fizyolojik bozukluklarla karakterizedir (Walsh, 1998). Anoreksiya Nervoza genellikle ergenlik döneminde aşırı ve katı bir diyet kısıtlamasıyla başlar ve yoğun bir kilo kaybına neden olur. Bazı ergenlerde bu bozukluk kısa süreli olup tedavi olmadan veya kısa bir müdahale ile düzelebilir ancak diğerlerinde devam etme eğilimindedir ve uzun, karmaşık, uzmanlık gerektiren tedavilere ihtiyaç duyar (Grave, 2011). Bulimia nervosa (BN) ise, 3 temel tanısal öge ile karakterize edilen bir yeme bozukluğudur (Wade, 2018);

- Aşırı yeme nöbetleri (2 saatlik bir süre içinde büyük miktarda yiyecek tüketme),
- Bu aşırı yeme ile baş etme çabaları (ya kusturarak, zorlu egzersiz yaparak veya uzun süren açlığa vücudu tabii tutmak),
- Kilo veya vücut tipinin öneminin birey için aşırı değerlendirilmesi ile gerçekleşir.

Düzensiz-Aşırı Yeme Bozukluğunun belirgin özelliği, tekrarlayan aşırı yeme nöbetleridir. Bu, belirli bir zaman içinde diğer insanların benzer koşullar altında tüketeceğinden açıkça daha fazla miktarda yiyecek tüketimi ile karakterizedir ve yeme üzerinde kontrol kaybı hissiyle ilişkilidir. Bulimia Nervosa'daki aşırı yeme ile kıyaslandığında, aşırı yeme, kilo alımını önlemeye yönelik düzenli olarak yapılan uygun olmayan telafi davranışları olmaksızın ortaya çıkar; örneğin kendi kendine kusturma, açlık veya müshil yanlış kullanımı gibi. Aşırı yeme, hızlı bir şekilde yeme veya rahatsız edici derecede tok hissedilinceye kadar yeme gibi davranışsal anormalliklere sahiptir ve belirgin bir sıkıntıya neden olur (Hilbert, 2019).

Kaçıncı yeme bozukluğuna sahip olan kişiler arasında ise uzun süreli yetersiz veya seçici beslenme geçmişine sahip olanlar ve muhtemelen çocuklukları boyunca veya birkaç yıl boyunca normal beslenmeyi engelleyen genel anksiyete veya gastrointestinal sorunlara sahip olan bireylerden oluştuğu söylenebilir (Zimmerman, 2017). Bu durum, yemeğe veya yiyeceklerle açık bir ilginin olmamasıyla karakterize edilen yiyecekten kaçınma duygusal bozukluğu ve infantil anoreksi (yetersiz beslenme sonucu oluşan anoreksiya) gibi tanılardan oluşmaktadır. Ayrıca, seçici yeme, yemek fobisi ve neofobi gibi durumlar da bulunmaktadır. Bu durumlar, yeni yiyecekleri denemekten kaçınma eğilimini içerir, yani yiyeceğin duygusal özelliklerine dayalı bir kaçınma barındırır (Kurz vd., 2015).

Tablo 1. Yeme bozukluklarındaki yaygın belirtiler

Davranışlar	Kendini Gösterme			
Kısıtlayıcı Davranış	Yenilen yiyecek miktarını ve çeşidini azaltma	Yemek ile ilgili katı kurallar oluşturmak	Uzun süreli açlık	Yiyecek çeşidinde azalma (örneğin aşırı vegan diyetler, yağdan kaçınma vb.)
Aşırı Yeme	Rahatsız edici derecede tok hissedinceye kadar yeme	Aç olmadığı halde büyük miktarlarda yeme	Yeme nedeniyle iğrenme, depresyon ya da yoğun suçluluk hissi	Aç olmadığı halde büyük miktarlarda yeme
Temizleyici Davranış	Kendi kendine kusma, kusturma, tükürme		Laksatif, diüretik diyet hapları vb. kötüye kullanma	
Aşırı Egzersiz	Zorlayıcı ve yoğun bir şekilde gerçekleştirilen egzersiz		Egzersiz yapma isteği	
Vücut Kontrolü	Ayna karşısında uzun süre durmak ve diğer insanların vücutlarıyla kendini karşılaştırma	Belirli kıyafetlerin uygunluğunu kontrol etme	Sürekli tartılma	Vücut parçalarının sıkça ölçülmesi (örneğin bel, bilek çevresi)
Bedensel İmaj Bozukluğu	Ağırlık ve şekil endişeleri	Kendi değerliliğinin belirlenmesinde şekil ve ağırlığın aşırı değer kazanması	Zayıf olunmasına rağmen ağırlık kazanma korkusu	Semptom şiddetinin küçümsemesi veya inkâr edilmesi
Fiziksel Belirtiler	Soğuğa karşı duyarlılık.	Zayıflık, yorgunluk vb	Kadınlarda adet döngüsünün kesintiye uğraması	
Bedenden Kaçınma	Yukarıdaki davranışlardan kaçınma (örneğin, tartılmayı reddetme, aynalardan kaçınma, kalın giysiler giyme)			

Kaynak: (Treasure, Claudino, & Zucker, 2010)

1.1.2. Yeme Bozukluklarını Etkileyen Faktörler

Yeme bozuklukları belirli birçok faktör çerçevesinde bireyi etkileyerek kendini gösterebilir (Tablo 2). Yeme bozuklukları, genellikle kontrol kaybı, düşük benlik saygısı, mükemmeliyetçilik gibi psikolojik faktörlerle ilişkilendirilir. Yeme bozukluklarına ilişkin etmenler bireyin öncelikle ince ideale maruz kalması; idealin içselleştirilmesi ve nihayetinde, benliği ve ideali arasında bir uyumsuzluk deneyimi yaşayarak bunun sonucunda vücut memnuniyetsizliği, diyet kısıtlaması ve sınırlamalara yol açması ile devam eder (Swinbourne & Touyz, 2007). Yeme bozukluklarının yaygınlığı kadınlarda ve Batı ülkelerinde daha yüksekken, Güney Kore dışındaki Asya ülkelerinde ise daha düşük olduğu tespit edilmiştir. Yeme bozukluklarının yaygınlığı zaman içinde artma eğiliminde olmuştur ancak bu durum aynı zamanda tanı kriterlerindeki değişikliklerden de kaynaklanabilir (Qian, 2021). Genellikle medya sıklıkla artan yeme bozukluğu vakalarından sorumlu tutulur, medyanın idealize edilmiş zayıf ve ince vücut görüntüleri nedeniyle insanları zayıflığa teşvik ettiği düşünülür çünkü medyada portre edilen bireylerin çoğunluğu vücut ağırlığının normal dağılımının uç noktalarında olduğu görülmektedir (Polivy & Herman, 2002).

Tablo 2. Yeme bozukluklarını etkileyen faktörler

Bireysel Risk Faktörleri **Aile Faktörleri** **Sosyo-Kültürel Etmenler**

Biyolojik <ul style="list-style-type: none">• Erken maturasyon• Şişmanlık	Ebeveynler <ul style="list-style-type: none">• Şişmanlık• Aşırı koruyuculuk• Dışlanma	Çevresel Ağırlık kaygısı <ul style="list-style-type: none">• Alay konusu olma• Grup içinde zayıf olma idealistiği
Kişilik <ul style="list-style-type: none">• Düşük benlik algısı• Tepkisizlik• Mükemmeliyetçilik• Olaylarla baş etmede yetersizlik• Beden memnuniyetsizliği	Ailesel Yapı <ul style="list-style-type: none">• Aile içi çatışma• Beden şekli üzerinde kaygı• Yeme bozukluğu olan kişilerle akrabalık	Toplumsal <ul style="list-style-type: none">• Medya baskısı• Başarı için fiziksel görünümün önemi• Baskın kültürün güzellik, zayıflık ideali
Davranış <ul style="list-style-type: none">• Diyetsel kısıtlama• Ağırlık kaygısı		

Kaynak: (Demirer B. & H., 2020);akt (Tümen, 2023).

Yetişkinlerde aşırı kilolu ve obeziteyi sınıflandırmak için yaygın olarak kullanılan basit bir boy-kilo indeksi olan BKİ, bir bireyin kilogram cinsinden ağırlığını metre cinsinden boyunun karesine bölerek hesaplanır (kg/m²) (WHO, 2024). BKİ, her iki cinsiyetin ve tüm yaş gruplarının yetişkinlerinde aynı olduğu için, aşırı kilolu ve obezitenin popülasyon düzeyinde dağılımını belirlemek için en kullanışlı ölçüttür.

Dünya Sağlık Örgütü'nün belirlediği BKİ kategorileri aşağıdaki gibi sınıflandırılmaktadır;

- 18,5'in altı: Zayıf
- 18,5 ile 24,9 arası: Normal kilolu
- 25,0 ile 29,9 arası: Pre-obezite (Kilolu)
- 30,0 ile 34,9 arası: Obezite Sınıfı I (WHO, 2024)

1.2. İlgili Çalışmalar

Üniversite yılları, genç yetişkinlik olarak tanımlanan kritik bir gelişimsel döneme denk gelir. Bu yaşta, önceki araştırmalar ergenlik döneminde yeme bozukluklarının insidansının zirve yaptığını göstermiştir. Genç yetişkinlerin %2-4'ünün yeme bozukluklarından muzdarip olduğu tahmin edilmektedir (Hudson vd., 2007).

18-25 yaş arası genç yetişkinlik dönemi, yeme ve kilo ile ilgili durumları, sağlık alışkanlıklarını ve inançları keşfetmek ve kurmak için önemli bir gelişim dönemi olarak tanımlanmıştır. Birçok vücut ve kilo ile ilgili durum ve davranış, ergenlik döneminde kurulduğu için ömür boyu sürer. Dolayısıyla, ergenlik ve genç yetişkinlik dönemi, yeme patolojisi için öngörücülerin ve risk faktörlerinin değerlendirilmesi için güçlü gelişim penceleri sunar. Bu tür davranışlar, ilerleyen yaşlarda metabolik riskler olarak olumsuz sonuçları olduğundan dolayı ele alınmalıdır. Bu tür araştırmalar üniversite düzeyinde özellikle gerekli hale gelir, çünkü öğrenciler genellikle nispeten iyi sağlıkta olduğu düşünülebilecek homojen bir nüfusu oluşturmaktadır (Tavolacci vd., 2015)

Risk altındaki bireyler arasında, gıda ile ilgili alanda öğrenim gören öğrencilerin de bulunduğu yapılan araştırmalar ile kanıtlanmıştır. Purkiewicz vd. (2021) tarafından yapılan araştırmada beslenme ve diyetetik bölümü ile gastronomi öğrencilerinin yeme bozuklukları üzerine erkekler ve kadınlar arasındaki yiyecek seçimleri ve yeme davranışlarındaki farklarının incelenmesi hedeflenerek yapılan araştırmada katılımcıların neredeyse %67'sinde yeme bozuklukları geliştirme riski tespit edilmiştir. Sonuçlara göre yeme bozukluklarının kadınlarda daha yaygın olduğu ve vücut ağırlığının bireylerin kendilerini nasıl hissettiklerini etkilediği yönündedir. Kadınlar daha sağlıksız yeme alışkanlıkları sergilemiş, bunun sonucunda diyet kısıtlamaları ve duygusal aşırı yeme davranışları yaşamıştır. Erkeklerde et ve alkol tüketiminin sıklığının daha yüksek olduğu, kadınlarda ise baklagil tüketiminin daha az olduğu belirlenmiştir.

Gastronomi öğrencileri üzerine yapılan diğer bir araştırmada Deveci, Deveci, & Avcıkurt (2017) tarafından gastronomi ve mutfak sanatları bölümü öğrencileri ve turizm öğrencilerinin cinsiyetle genel yeme davranışı ve kontrolsüz yeme davranışı arasında anlamlı bir fark bulunamadığı belirtilirken, duygusal yeme ve bilişsel kısıtlama boyutlarında erkek ve kadınlar arasında anlamlı farklar tespit edildiği ifade edilmektedir. Duygusal yeme davranışındaki farklılık, kadınların depresyon ve kaygı bozukluğuna daha yatkın olmalarıyla ilişkilendirilirken, bilişsel kısıtlama boyutundaki farklılık ise diyet ve kilo kontrolü konusundaki düşüncelerdeki cinsiyet farklılıklarına bağlanmaktadır. Kontrolsüz yeme konusunda ise erkekler ve kadınlar arasında benzer düşünce kalıplarının olduğu belirtilmiştir.

Telatar, (2021) tarafından yapılan araştırmada, tıp fakültesi öğrencileri üzerinde beslenme ve yeme bozukluğu riski değerlendirilmiş, öğrencilerin %50,1'inin beslenme ve yeme bozukluğu riskine sahip olduğu tespit edilmiştir. Araştırmada kadın olmanın ve güne kahvaltı yapmadan başlamanın yeme bozukluğu riskini artırdığı, öğrencilerin öğrenim gördükleri dönemin ilerlemesiyle yeme bozukluğu riskinin azaldığı tespit edilmiştir.

Akdevelioğlu & Yörüsün (2019) tarafından yapılan araştırmada, 339 üniversite öğrencisi üzerinde yeme davranışı bozukluğu riskinin değerlendirilmiş, 18-19 yaş grubundaki bireylerde yeme davranışı bozukluğu riskinin %35,7 daha fazla olduğu, diyet yapma geçmişine sahip bireylerde yeme tutum testi, duygusal ve kısıtlı yeme davranışı skorlarının diyet yapma geçmişine sahip olmayan bireylerden daha yüksek olduğu ve beden kütle indeksi (BKİ) ile kısıtlı ve duygusal yeme skorları arasında pozitif yönlü anlamlı bir korelasyon olduğu tespit edilmiştir.

Özvrmaz, Mandıracioğlu & Lüleci (2018) tarafından yapılan araştırmada 431 üniversite öğrencisi üzerinde yeme tutumu değerlendirilmiş, Yeme Tutum Testi skorları ile cinsiyeti kız, annesi çalışan, çekirdek aile tipine sahip, babası üniversite mezunu olan ve alkol tüketen öğrenciler arasında anlamlı bir ilişki tespit edilmiştir. Ulaş, Uncu, & Üner (2013) tarafından yapılan araştırmada, sağlık meslek yüksekokulu öğrencileri arasında kadın olmanın, benlik saygısının düşük olmasının ve diyet yapma eğiliminin olası yeme bozukluğu riskini artırdığı belirlenmiştir.

Oğur, Aksoy, & Selen (2016) tarafından Bitlis Eren Üniversitesi'nde gerçekleştirilen bir araştırmada Yeme Tutumu Testi (YTT-40) puanlarına göre, zayıf öğrencilerin %7,8'i normal öğrencilerin %13,6'sı ve şişmanlık öncesi (pre-obez) öğrencilerin %15,5'inin yeme davranışı bozukluğuna yatkın olduğu tespit edilmiştir. Öğrencilerin yaş aralıklarına göre, 17-23 yaş aralığındaki öğrencilerden %13,8'i ve 24-29 yaş aralığındaki öğrencilerden ise %4,3'ü yeme davranışı bozukluğuna yatkın olduğu belirlenmiştir. Ancak, öğrencilerin cinsiyetleri, BKİ değerleri ve yaş aralıkları ile YTT-40 puanları arasında anlamlı bir fark bulunmamıştır.

Çelik, Yoldaşcan, Azim, & Özenli (2016) tarafından Çukurova Üniversitesi'nde 688 öğrenci üzerinde yapılan araştırmaya göre üniversite öğrencilerinde yeme bozukluğu sık görülmektedir, özellikle depresif belirtileri olan ve BKİ'si yüksek öğrencilerin bu risk altında olabilecekleri tespit edilmiştir. Kalabalık ailelerde yeme bozukluğu daha düşük bulunmuşken, yeme bozukluğu bulunan öğrencilerde bildirilen mevcut hastalık varlığı BKİ ve BDÖ puanları açısından anlamlı derecede yüksek olduğu belirlenmiştir.

Işık (2009) tarafından Uludağ Üniversitesinde 1250 öğrenci arasında gerçekleştirilen araştırmada, kız ve erkek öğrenciler arasında sigara içme, alkol kullanımı, egzersiz alışkanlığı, yemek seçimleri, Beden Kitle İndeksi (BKİ) ortalamaları ve obezite sıklığı açısından belirgin farklılıklar tespit edilirken ebeveynlerden herhangi birisinin ya da her ikisinin kilolu olduğunda öğrencilerin kilolu olma eğilimi olduğu gelir düzeyleri arttıkça, öğrencilerin fast food tüketim eğilimleri ile televizyon ve bilgisayar başında geçirdikleri sürelerin arttığı ve özellikle kız öğrenciler arasında, yeme bozukluğu riskinin, literatür verilerine göre daha yüksek olduğu belirlendiği belirtilmiştir.

Yaşar vd., (2010) tarafından 136 tıp öğrencisi üzerinde yapılan araştırmada öğrencilerin %55,9'unda yeme bozukluğu tespit edilmiştir. Ayrıca, kadın öğrencilerde yeme bozukluğu sıklığının erkek öğrencilere göre daha yüksek olduğu, ailelerinin aylık gelir düzeyi 1000 TL üzerinde olan öğrencilerde daha fazla yeme bozukluğu olduğu ve kilo vermeye çalışan öğrencilerde yeme bozukluğu sıklığının daha yüksek olduğu belirlenmiştir.

Literatürdeki yapılan çalışmalar incelendiğinde üniversite öğrencilerinde yeme bozukluklarının belirlenmesine yönelik çalışmaların olduğu görülmektedir fakat besinlerle iç içe olan gastronomi ve mutfak sanatları bölümünde ya da aşçılık programında okuyan öğrencilerin yeme bozukluklarını irdeleyen çalışmalar mevcut değildir. Bu araştırma literatüre bu konuda ışık tutacaktır.

2. YÖNTEM

Bu araştırmada, Karabük Üniversitesi Gastronomi ve Mutfak Sanatları bölümü öğrencilerinin yeme bozukluğuna ilişkin tutumlarını incelemeyi amaçlamaktadır. Bu amaçla, nicel araştırma yöntemi kullanılarak veriler anket tekniği ile toplanmış ve veriler SPSS v.20 programı kullanılarak analiz edilmiştir.

2.1. Evren ve Örneklem

Araştırma evrenini, Karabük Üniversitesi'nde öğrenim gören Gastronomi ve Mutfak Sanatları öğrencileri oluşturmaktadır. Araştırmada örnekleme yöntemine gidilmeyerek evrenin tamamına

ulaşılmaya çalışılmıştır. Yükseköğretim Kurulu'nun 2022-2023 Akademik yılı verilerine göre, Karabük Üniversitesi Gastronomi ve Mutfak Sanatları Bölümü'nde toplam 304 kayıtlı öğrenci bulunmaktadır (YÖK, 2023). Anket formları, Aralık 2023 ile Ocak 2024 tarihleri arasında çevrimiçi olarak gönderilerek aktif olarak öğrenim gören öğrencilere gönüllülük esasına dayalı olarak uygulanmıştır. Evrenin tamamına ulaşmak hedeflenmiştir fakat çalışmaya katılmak gönüllük esasına dayalı olması sebebiyle 200 öğrenciye ulaşılmıştır.

2.2. Veri Toplama Aracı

Bu araştırmada nicel araştırma yöntemlerinden veri toplamak amacıyla anket tekniği kullanılmıştır. İlk bölümde katılımcıların demografik özellikleri belirlenmiş, ikinci bölümde ise Yeme Davranışı Bozukluğu Ölçeği (YDBÖ) kullanılmıştır.

Demografik Bilgi Formu: Cinsiyet, yaş, sınıf düzeyi, kronik hastalık sahip olma durumu, öğün atlama durumu, spor/egzersiz yapma durumu, sigara/alkol tüketimi, vücut ağırlığı memnuniyeti, barınma türü ve vücut ağırlığını korumaya çalışma durumu gibi demografik sorulara yer verilmiştir.

Yeme Davranışı Bozukluğu Ölçeği: Yaşam kalitesini olumsuz etkileyen yeme davranış sorunlarını değerlendirmek ve belirlemek amacıyla Şahin (2022) tarafından geliştirilmiştir. Ölçek toplam 25 sorudan ve 1-Kesinlikle Katılmıyorum, 5-Kesinlikle Katılıyorum arasında değişen beşli likert tipinde hazırlanmıştır. Şahin (2022) tarafından geliştirilen ölçek sonucunda “kognitif sınırlayıcı yeme”, “duygusal yeme” ve “hedonik yeme” olarak üç boyut elde edilmiştir. Ölçeğin iç tutarlılık katsayısı ,944 olarak belirlenmiştir. Cronbach alfa güvenirlik katsayısı yapılan bu araştırma içinse ,930 olarak hesaplanmıştır.

2.3. Etik Kurul

Araştırma kapsamında Karabük Üniversitesi Sosyal ve Beşeri Bilimler Araştırmaları Etik Kurulu'ndan 2023/08 toplantı nolu 289757 sayılı karar ile etik kurul izni alınmıştır.

2.4. Hipotezler

H1: Gastronomi öğrencilerinin cinsiyetleri ile yeme davranışları arasında anlamlı farklılıklar bulunmaktadır.

H2: Gastronomi öğrencilerinin vücut ağırlığını korumaya çalışmaları ile yeme davranışları arasında anlamlı farklılıklar bulunmaktadır.

H3: Gastronomi öğrencilerinin kronik hastalık mevcudiyetleri ile yeme davranışları arasında anlamlı farklılıklar bulunmaktadır.

H4: Gastronomi öğrencilerinin barınma türleri ile yeme davranışları arasında anlamlı farklılıklar bulunmaktadır.

H5: Gastronomi öğrencilerinin spor/egzersiz yapma durumu ile yeme davranışları arasında anlamlı farklılıklar bulunmaktadır.

H6: Gastronomi öğrencilerinin sigara/alkol tüketim durumu ile yeme davranışları arasında anlamlı farklılıklar bulunmaktadır.

H7: Gastronomi öğrencilerinin vücut ağırlığı memnuniyeti ile yeme davranışları arasında anlamlı farklılıklar bulunmaktadır.

2.5. İstatistiksel Analizler

Elde edilen veriler, SPSS v.20 programı ile analiz edilmiştir. Veri analizinde; demografik özellikler için frekans analizi ve çapraz tablo, alt boyutlar için açıklayıcı faktör analizi (AFA) kullanılmıştır. Likert tipi bir ölçek kullanıldığından normal dağılım için çarpıklık ve basıklık katsayıları dikkate alınmıştır. Verilerin normal dağıldığı belirlenmiştir. Parametrik fark testleri için Bağımsız T-testi ve One Way ANOVA testleri kullanılmıştır.

3. BULGULAR

Araştırma verileri değerlendirilmeden önce güvenilirlik analizi gerçekleştirilmiştir. Güvenilirlik analizi sonucunda Cronbach'ın alfa değeri ,935 olarak bulunmuş ve verilerin geçerli ve güvenilir olduğu, iç tutarlılığın yüksek olduğu sonucuna varılmıştır.

Tablo 3. Katılımcıların demografik özellikleri

Araştırmaya katılan bireylerin %61'i kadın, %39'u erkektir. Sınıf dağılımı incelendiğinde;

Değişkenler		S	%
Cinsiyet	Kadın	122	61
	Erkek	78	39
Sınıf	1.	51	25,5
	2.	40	20
	3.	41	20,5
	4.	45	22,5
	Lisansüstü	23	11,5
Yaş (yıl)	18-20	83	41,5
	21-23	86	43
	24-26	22	11
	27-29	4	2
	30+	5	2,5
BKİ (kg/m ²)	18.5 ve aşağı (zayıf)	23	11,5
	18.5-24.9 (normal)	119	59,5
	25-29.9 (kilolu)	42	21
	30-39.9 (obez)	16	8
Barınma Türü	Aile evi	24	12
	Arkadaş evi	30	15
	Yurt vb.	118	59
	Tek başına evde	28	14
Sigara/Alkol Tüketimi	Çoğunlukla	39	19,5
	Bazen	47	23,5
	Hiçbir zaman	114	57
Kronik Hastalık Sahibi	Evet	20	10
	Hayır	180	90
Öğün Atlama Durumu	Çoğunlukla	56	28
	Bazen	128	64
	Hiçbir zaman	16	8
Spor/Egzersiz Yapma Durumu	Çoğunlukla	36	18
	Bazen	114	57
	Hiçbir zaman	50	25
Vücut Ağırlığı Memnuniyeti	Memnunum	114	57
	Memnun değilim	77	38,5
	Hiç memnun değilim	9	4,5
Vücut Ağırlığını Korumaya Çalışırım	Evet	132	66
	Hayır	68	34
Toplam		200	100

%25,5 birinci sınıf, %20 ikinci sınıf, %20,5 üçüncü sınıf, %22,5 dördüncü sınıf ve %11,5 lisansüstü öğrencisi olduğu görülmektedir. Katılımcıların çoğunluğu (%43) 21-23 yaş aralığındadır. Beden Kütle İndeksi (BKİ) dağılımına bakıldığında, katılımcıların %59,5'inin normal aralıkta olduğu görülmektedir. Barınma türü olarak çoğunluğun (%59) yurt veya benzeri bir yerde yaşadığı görülmektedir. Sigara/alkol tüketimi değerlendirildiğinde çoğunluğunun (%57) hiç tüketmediği görülmektedir. Kronik hastalık sahibi olanların oranı ise %10'dur. Öğün atlama durumları incelendiğinde ise en fazla oranla %64'nün bazen atladığı ve bunu %28 oranıyla çoğunlukla cevabını veren bireylerin takip ettiği görülmektedir. Katılımcıların çoğunluğu (%57) bazen spor/egzersiz yaptığını bildirmektedir. Vücut ağırlığı memnuniyeti değerlendirildiğinde; %57'si memnun olduğunu, %38,5 ise memnun olmadığını belirtmiştir. Son olarak katılımcıların çoğunluğu (%66) vücut ağırlığını korumaya çalıştığını ifade etmiştir (Tablo 3).

Tablo 4. Katılımcıların demografik özelliklerine göre BKİ dağılımı

BKİ	Zayıf	Normal	Kilolu	Obez	Toplam
-----	-------	--------	--------	------	--------

		S	%	S	%	S	%	S	%	S
Cinsiyet	Kadın	13	0,6	70	57,3	28	22,9	11	9	122
	Erkek	10	12,3	49	60,4	14	17,2	5	6,1	78
Sınıf	1.	9	17,6	27	52,9	12	23,5	3	5,8	3
	2.	6	14	25	62,5	7	17,5	2	5	40
	3.	3	7,3	21	51,22	12	29,27	5	12,2	41
	4.	2	4,4	30	66,6	9	20	4	8,8	45
	Lisansüstü	3	13	13	56,5	2	8,7	2	8,7	23
Yaş	18-20	11	13,2	44	53	20	24,1	8	9,6	83
	21-23	8	9,3	54	62,7	18	20,9	6	6,9	86
	24-26	2	9	15	68,1	3	13,6	2	9,9	22
	27-29	0	0	3	75	1	25	0	0	4
	30+	2	40	3	60	0	0	0	0	5
Barınma Türü	Aile evi	5	20,8	15	6,2	2	8,3	2	8,3	24
	Arkadaş evi	1	3,3	17	56,6	9	30	3	10	30
	Yurt vb.	11	9,3	68	57,6	29	24,5	11	9,3	118
	Tek başına evde	6	21,4	19	67,8	3	10,7	0	0	28
Sigara/Alkol Tüketimi	Çoğunlukla	2	5,13	27	69,2	7	17,9	3	7,6	39
	Bazen	7	14,8	24	51	12	25,5	4	8,5	47
	Hiçbir zaman	14	12,2	68	59,6	23	20,1	9	7,8	114
Kronik Hastalık Sahibi	Evet	3	15	13	65	4	20	0	0	20
	Hayır	20	11,1	106	58,8	38	21,1	16	8,9	180
Öğün Atlama Durumu	Çoğunlukla	7	12,5	29	51,7	14	25	6	10,7	56
	Bazen	13	10,1	79	61,7	27	21	9	7	128
	Hiçbir zaman	3	18,7	11	68,7	1	6,25	1	6,25	16
Spor/Egzersiziz Yapma Durumu	Çoğunlukla	4	10,5	25	65,7	5	13,1	4	10,5	38
	Bazen	12	10,4	71	61,7	25	21,7	7	6	115
	Hiçbir zaman	7	14	25	56	13	26	5	10	50
Vücut Ağırlığı Memnuniyeti	Memnunum	14	12,2	70	61,4	23	20,1	7	6,1	114
	Memnun değilim	9	11,6	44	57,1	16	20,7	8	10,3	77
	Hiç memnun değilim	0	0	5	55,5	3	33,3	1	11,1	9
Vücut Ağırlığını Korumaya Çalışırım	Evet	15	11,3	79	59,8	26	19,7	12	9	132
	Hayır	8	11,7	40	58,8	16	23,5	4	5,8	68

Katılımcıların demografik özelliklerine göre BKİ dağılımı incelendiğinde; kadınların (%57,3) ve erkeklerin (%60,4) çoğunluğunun normal BKİ aralığında olduğu bulunmuştur. Sınıf seviyesine ve yaşa göre BKİ dağılımında belirgin bir eğilim görülmemektedir. Katılımcıların çoğunluğu yurt veya benzeri konaklama yerlerinde kalmaktadır ve bu grup içindeki bireylerin (%57,6) normal BKİ değer sıklığı daha yüksektir. Evde tek başına yaşayanların içinde zayıf olanlar (%2,4) göze çarpmaktadır. Sigara içmeme ve alkol tüketmeme oranının hiçbir zaman yanıtında yüksek olduğu ve bu kategoride normal BKİ oranının (%59,6) daha yüksek olduğu görülmektedir. Spor/egzersiz yapma durumu ve öğün atlamaya eğilim gösterenler arasında olanların çoğunluğu normal BKİ değerinde olan (%57,7) katılımcılardan olup en fazla bazen yanıtı verilmiştir. Vücut ağırlığı memnuniyeti dağılımında normal BKİ değerinde olan katılımcılardan (%57,1) memnun değilimi yanıtı da oldukça yüksek bir dağılım göstermektedir. Ayrıca vücut ağırlığını korumaya çalışanların normal BKİ oranı (%59,8) diğer gruplara göre daha yüksektir (Tablo 4). Ek olarak değişkenler ve BKİ arasında korelasyon analizi yapılmış fakat herhangi bir anlamlılık tespit edilememiştir ($p>0,01$).

Tablo 5. Katılımcıların yeme davranışı bozukluğu tutumlarının açıklayıcı faktör analizi

Yeme Davranışı Bozukluğu Kognitif Sınırlayıcı Yeme	Faktör Yüğü	Varyans
--	-------------	---------

Yemek yemek beni suçlu hissettirir.	,793	
Yediğim her şeyin kalorisini hesaplarım.	,512	
Yiyeceğim yemeğin kalorisinin sandığımdan fazla olduğunu öğrenirsem yemeyi bırakırım.	,672	
Neyi ne kadar yiyeceğim konusunda endişelenirim.	,890	
Bir yiyeceğin/öğünün bana ne kadar kilo aldıracağı konusunda endişelenirim.	,917	39,436
Daha düşük kalorili seçenekleri seçmem gerektiğini düşünürüm.	,891	
Sık sık diyet yaparım.	,776	
Daha zayıf olmayı hayal ederim.	,838	
Haftada birkaç kez tartılırım.	,632	
Aldığım fazla kaloriyi telafi etmek için aşırı egzersiz yaparım.	,619	
Açık büfelerde bol miktarda yiyecek bulunduğundan dolayı gergin hissedirim.	,706	
Duygusal Yeme		
Bir reklamda veya vitrinde yiyecek gördüğüm zaman canım çeker.	,805	
Bir yiyecek ikram edildiği zaman reddedemem.	,732	
Başkalarını yemek yerken görürsem, ben de yemek isterim.	,808	
Yemek hakkında konuşulurken acıktığımı hissedirim.	,803	
Sosyal medyada yiyeceklerle ilgili gördüğüm paylaşımlar bende yeme isteği uyandırır.	,821	18,460
Biri bana çok güzel bir yemeği tarif ettiğinde, yeme isteği duyarım.	,790	
Sık yemek yiyen birinin yanında, ben de yemeye yönelirim.	,745	
Hedonik Yeme		
Doyduğumu fark etmeden yemeye devam ederim.	,557	
Olumsuz ruh halinden bir şeyler yiyerek uzaklaşmaya çalışırım.	,662	
Yiyecekler duygularımla baş etmede bana yardım eder.	,854	
Yapacak bir şey bulamadığımda kendimi yemek yerken bulurum.	,804	7,510
Kendimi daha iyi hissetmek için yerim.	,906	
Yalnızken aç olmasam bile yemeye yönelirim.	,841	
Yemek yemek beni sakinleştirir.	,831	
Cronbach Alpha: 0,930 Toplam Varyans: 65,406. Rotasyon Yöntemi: Kaiser Normalleştirme ve Oblimin Çıkarım Yöntemi: Temel Bileşen Analizi KMO Geçerlilik Analizi: 0,913 Sferisite Barlett Testi x2: 3883,714 p: 0,000 Ölçek Türü: 5 noktalı Likert ölçeği (kesinlikle katılmıyorum, kararsızım, katılıyorum, kesinlikle katılıyorum).		

Araştırmanın açıklayıcı faktör analizinin sonucunda elde edilen Cronbach Alpha değeri yüksektir (0,930), bu da çalışmanın iç tutarlılığının yüksek olduğunu göstermektedir. Kaiser-Meyer-Olkin Geçerlilik Analizi'nin (0,913) yüksek olması, Sferisite Barlett Testi'nde p değeri 0,000 olması veri setinin faktör analizi için uygun olduğu yönündedir. Yapılan AFA'ya göre maddelerin üç farklı faktör altında toplandığı görülmektedir. Bunlar: Kognitif Sınırlayıcı Yeme, Duygusal Yeme ve Hedonik Yemedir. Her bir faktör altında yer alan maddeler ve faktör yükleri belirtilmiştir. Kaiser Normalizasyonu için birden büyük özdeğerlere sahip faktörler dikkate alınmıştır. Ortaya çıkan üç faktörün toplam açıklama varyansı %65,406'dır. Scherer, Luther ve Wiebe'e (1988) göre, bu değer %50'den yüksek olduğundan, doğru bir analizi işaret etmektedir. Ayrıca, faktör analizinde tüm öğe değerlerinin 0,40'tan az olmaması gerekmektedir (Field, 2009:466). Faktör analizinde, tüm madde değerlerinin 0,40'tan yüksek olduğu görülmüştür.

Keşfedici faktör analizinin ardından, her bir faktör için normalite testleri gerçekleştirilmiştir. Kullanılan ölçek tipinin 5'li Likert olduğu göz önüne alındığında, çarpıklık ve basıklık katsayıları dikkate alınmıştır. Tabachnick & Fidell (2013)'e göre +1,5 ile -1,5 aralığı idealdir. Bu değerler referans alındığında veri dağılımı normallik göstermektedir. Bu nedenle parametrik testlerin kullanılabileceği anlamına gelmektedir.

Tablo 6. Cinsiyet, vücut ağırlığını koruma ve kronik hastalık sahibi olma durumuna göre öğrencilerin yeme davranışı bozuklukları arasındaki ilişki

Boyutlar	Cinsiyet	n	\bar{X}	SS	T testi	
					t	P
Kognitif Sınırlayıcı Yeme	Kadın	122	3,69	,916	1,158	0,248
	Erkek	78	3,52	1,20		
Duygusal Yeme	Kadın	122	2,66	1,05	-,723	0,370
	Erkek	78	2,77	1,04		
Hedonik Yeme	Kadın	122	2,86	1,13	-1,510	0,133
	Erkek	78	3,11	1,16		
Boyutlar	Vücut Ağırlığını Korumaya Çalışırım	n	\bar{X}	SS	T testi	
					t	P
Kognitif Sınırlayıcı Yeme	Evet	132	3,51	,988	-2,155	0,032
	Hayır	68	3,84	1,10		
Duygusal Yeme	Evet	132	2,70	1,02	-0,36	0,971
	Hayır	68	2,70	1,08		
Hedonik Yeme	Evet	132	2,96	1,09	-0,19	0,985
	Hayır	68	2,96	1,25		
Boyutlar	Kronik Hastalık Sahibi	n	\bar{X}	SS	T testi	
					t	P
Kognitif Sınırlayıcı Yeme	Evet	20	4,04	,854	1,901	0,059
	Hayır	180	3,58	1,05		
Duygusal Yeme	Evet	20	3,05	1,02	1,569	0,118
	Hayır	180	2,66	1,04		
Hedonik Yeme	Evet	20	3,17	,951	,849	0,397
	Hayır	180	2,94	1,16		

Tablo 6 değerlendirildiğinde; katılımcıların yeme davranışı bozuklukları ile cinsiyetleri arasında anlamlı bir farklılık olup olmadığı t testi ile incelenmiş fakat herhangi bir anlamlılık görülmemiştir ($p>0,05$). Buna göre H1 hipotezi reddedilmiştir. Katılımcıların vücut ağırlığını korumaya olan eğilimleri ile yeme davranışları arasında Kognitif Sınırlayıcı Yeme boyutunda anlamlılık tespit edilmiştir ($p<0,05$). Buna göre vücut ağırlığını koruma eğiliminde olmayan katılımcılar kendini yemekten sınırlamayan katılımcılardır. Yemek konusunda kendilerine herhangi bir sınırlılık koymamaları ağırlıklarından endişe etmemeleri ile anlaşılabilir. Diğer boyutlar içinse herhangi bir anlamlılık tespit edilememiştir ($p>0,05$). Buna göre H2 hipotezi desteklenebilir.

Katılımcıların kronik hastalık sahip olma durumları yeme davranışları arasında Kognitif Sınırlayıcı Yeme boyutunda anlamlılık tespit edilmiştir ($p<0,05$). Buna göre kronik hastalık sahibi katılımcılar kendini yemekten sınırlayan katılımcılardır. Kronik hastalıkları nedeniyle yememeleri gereken herhangi bir gıda ürününün varlığı kendilerine sınırlayıcı yeme davranışı atfetmeleri ile anlaşılabilir. Diğer boyutlar içinse herhangi bir anlamlılık tespit edilememiştir ($p>0,05$). Buna göre H3 hipotezi desteklenebilir.

Tablo 7. Barınma türüne göre öğrencilerin yeme davranışı bozuklukları arasındaki farklılıklar için tek yönlü anova testi tablosu

Boyut	Barınma Türü	n	\bar{X}	SS	F	P	Farklar
Kognitif Sınırlayıcı Yeme	Aile evi (a)	24	3,66	1,090	,203	0,894	$p>0,05$
	Tek başına evde (b)	28	3,52	1,111			
	Yurt vb. (c)	118	3,66	1,004			
	Arkadaşları ile evde (d)	30	3,55	1,114			
	Toplam	200	3,62	1,040			
Boyut	Barınma Türü	n	\bar{X}	SS	F	P	Farklar

Boyut	Barınma Türü	n	\bar{X}	SS	F	P	Farklar
Duygusal Yeme	Aile evi (a)	24	2,44	1,211	3,469	0,017	b>c
	Tek başına evde (b)	28	3,12	1,046			
	Yurt vb. (c)	118	2,58	0,956			
	Arkadaşları ile evde (d)	30	2,99	1,076			
	Toplam	200	2,70	1,042			
Hedonik Yeme	Aile evi (a)	24	2,94	1,343	,412	0,745	P>0,05
	Tek başına evde (b)	28	3,12	1,034			
	Yurt vb. (c)	118	2,89	1,146			
	Arkadaşları ile evde (d)	30	3,08	1,124			
	Toplam	200	2,96	1,148			

Katılımcıların öğrenci olması nedeniyle barındıkları yer oldukça önemlidir. Araştırmada çoğunluğun yurt vb. türde yerlerde barındığı tespit edilmiştir. Yeme davranışları ile barınma türleri arasında anlamlılık Duygusal Yeme Boyutunda tespit edilmiştir ($p<0,05$). Buna göre tek başına evde yaşayanlar aile evinde ve yurt vb. yerde yaşayan katılımcılara göre daha fazla duygusal yeme bozukluğuna sahiptir. Yalnız kalan bireyler, sosyal izolasyon ve yalnızlık hissi ile daha fazla karşı karşıya olabilirler. Bu durum, duygusal boşluk hissini doldurmak için yemek yeme eğilimini artırabilir. Bu durumda yiyecekleri bir tür rahatlama veya teselli kaynağı olarak kullanabilirler. Diğer boyutlar içinse herhangi bir anlamlılık tespit edilememiştir ($p>0,05$). Buna göre H4 hipotezi desteklenebilir (Tablo 7).

Tablo 8. Spor/Egzersiz yapma ve sigara/alkol tüketimine göre öğrencilerin yeme davranışı bozuklukları arasındaki farklılıklar için tek yönlü anova testi

Boyut	Spor/Egzersiz Yaparım	n	\bar{X}	SS	F	P	Farklar
Kognitif Sınırlayıcı Yeme	Çoğunlukla (a)	36	3,39	,979	2,710	0,069	p>0,05
	Bazen (b)	114	3,58	1,013			
	Hiçbir zaman (c)	50	3,89	1,106			
	Toplam	200	3,62	1,040			
Duygusal Yeme	Çoğunlukla (a)	36	3,11	0,899	3,482	0,033	a>b
	Bazen (b)	114	2,63	1,000			
	Hiçbir zaman (c)	50	2,57	1,168			
	Toplam	200	2,70	1,042			
Hedonik Yeme	Çoğunlukla (a)	36	3,45	1,149	4,157	0,017	a>b
	Bazen (b)	114	2,85	1,044			
	Hiçbir zaman (c)	50	2,84	1,296			
	Toplam	200	2,96	1,148			
Kognitif Sınırlayıcı Yeme	Çoğunlukla (a)	39	3,64	1,259	2,873	0,059	c>a
	Bazen (b)	47	3,32	1,143			
	Hiçbir zaman (c)	114	3,74	,8873			
	Toplam	200	3,62	1,040			

Boyut	Sigara/Alkol Tüketimi	n	\bar{X}	SS	F	P	Farklar
Duygusal Yeme	Çoğunlukla (a)	39	2,38	1,198	2,273	0,106	p>0,05
	Bazen (b)	47	2,80	1,178			
	Hiçbir zaman (c)	114	2,77	,907			
	Toplam	200	2,70	1,042			
Boyut	Sigara/Alkol Tüketimi	n	\bar{X}	SS	F	P	Farklar
Hedonik Yeme	Çoğunlukla (a)	39	2,53	1,301	3,614	0,029	b>a c>a
	Bazen (b)	47	3,12	1,284			
	Hiçbir zaman (c)	114	3,04	1,000			
	Toplam	200	2,96	1,148			

Tablo 8 değerlendirildiğinde; katılımcıların spor/egzersiz yapma durumları eğilimleri ile yeme davranışları arasında Duygusal ve Hedonik yeme boyutlarında anlamlılık tespit edilmiştir ($p<0,05$). Buna göre çoğunlukla spor yapan katılımcılar, bazen veya hiçbir zaman spor yapmayan katılımcılara göre daha fazla hedonik ve duygusal yeme bozukluğuna sahiptir. Kognitif yeme boyutunda herhangi bir anlamlılık tespit edilememiştir ($p>0,05$). Buna göre H5 hipotezi desteklenebilir. Katılımcıların sigara/alkol tüketim durumları ile yeme davranışları arasında Hedonik Yeme ve Kognitif Yeme boyutunda anlamlılık tespit edilmiştir ($p<0,05$). Buna göre bazen veya hiçbir zaman sigara/alkol tüketmediğini belirten katılımcılar çoğunlukla tüketen gruba göre hedonik yeme bozukluğuna sahiptir. Ayrıca hiçbir zaman sigara/alkol tüketmediğini belirten katılımcılar çoğunlukla tüketen gruba göre daha anlamlı kognitif sınırlayıcı yeme bozukluğuna sahiptir. Duygusal yeme boyutu içinse herhangi bir anlamlılık tespit edilememiştir ($p>0,05$). Buna göre H6 hipotezi desteklenebilir.

Tablo 9. Vücut ağırlığı memnuniyet durumu ve öğün atlama durumuna göre öğrencilerin yeme davranışı bozuklukları arasındaki farklılıklar için tek yönlü anova testi

Boyut	Vücut Ağırlığı Memnuniyeti	n	\bar{X}	SS	F	P	Farklar
Kognitif Sınırlayıcı Yeme	Hiç memnun değilim (a)	9	3,11	1,139	2,016	0,124	p>0,05
	Memnunum (b)	114	3,73	1,031			
	Memnun değilim (c)	77	3,52	1,028			
	Toplam	200	3,62	1,040			
Boyut	Vücut Ağırlığı Memnuniyeti	n	\bar{X}	SS	F	P	Farklar
Duygusal Yeme	Hiç memnun değilim (a)	9	2,26	,861	1,481	0,230	p>0,05
	Memnunum (b)	114	2,79	1,067			
	Memnun değilim (c)	77	2,61	1,016			
	Toplam	200	2,70	1,042			
Boyut	Vücut Ağırlığı Memnuniyeti	n	\bar{X}	SS	F	P	Farklar
Hedonik Yeme	Hiç memnun değilim (a)	9	2,23	1,133	3,426	0,034	b>a
	Memnunum (b)	114	3,11	1,127			
	Memnun değilim (c)	77	2,82	1,145			
	Toplam	200	2,96	1,148			

Boyut	Öğün Atlama	n	\bar{X}	SS	F	P	Farklar
Kognitif Sınırlayıcı Yeme	Çoğunlukla (a)	56	3,75	,955	,545	0,581	p>0,05
	Bazen (b)	128	3,58	1,042			
	Hiçbir zaman (c)	16	3,53	1,316			
	Toplam	200	3,62	1,040			
Boyut	Öğün Atlama	n	\bar{X}	SS	F	P	Farklar
Duygusal Yeme	Çoğunlukla (a)	56	2,69	1,062	2,742	0,67	p>0,05
	Bazen (b)	128	2,63	1,020			
	Hiçbir zaman (c)	16	3,27	1,038			
	Toplam	200	2,70	1,042			
Boyut	Öğün Atlama	n	\bar{X}	SS	F	P	Farklar
Hedonik Yeme	Çoğunlukla (a)	56	2,86	1,217	,328	0,721	p>0,05
	Bazen (b)	128	2,99	1,116			
	Hiçbir zaman (c)	16	3,06	1,205			
	Toplam	200	2,96	1,148			

Katılımcıların vücut ağırlığı memnuniyeti ile yeme davranışları arasında Hedonik Yeme boyutunda anlamlılık tespit edilmiştir ($p<0,05$). Buna göre vücut ağırlığından memnun olan katılımcılar hiç memnun olmayanlara göre daha fazla hedonik yeme eğilimi göstermektedir ($p = 0,034$). Diğer boyutlar içinse herhangi bir anlamlılık tespit edilememiştir ($p>0,05$). Buna göre H7 hipotezi desteklenebilir.

4. TARTIŞMA VE SONUÇ

Yapılan araştırmada, Karabük Üniversitesi'nde Gastronomi ve Mutfak Sanatları bölümünde okuyan öğrencilerin bazı yeme davranışı bozukluklarına olan eğilimleri incelenmiştir. Araştırmada, katılımcıların vücut ağırlığını koruma durumu, kronik hastalık sahipliği, barınma türü, spor/egzersiz yapma durumu, sigara/alkol tüketim durumu, vücut ağırlığı memnuniyet durumu, öğün atlama durumu, cinsiyet, sınıf düzeyi ve yaş grubuna göre yeme davranışı bozuklukları arasındaki farklılıklar incelenmiştir. Araştırmada barınma türü ile duygusal yeme boyutu arasında anlamlılık tespit edilmiştir (Tablo 7). Tek başına evde yaşayanların aile evinde veya yurt vb. yerlerde yaşayanlara göre daha fazla duygusal yeme bozukluğuna sahip oldukları tespit edilmiştir. Bu durum sosyal izolasyonun ve yalnızlığın duygusal yeme eğilimini artırabileceğini gösterebilir. Yapılan bir çalışmada da yeme davranışının bilişsel alt boyutu ve duygusal yeme alt boyutunda cinsiyete göre anlamlı farklılıklar görüldüğü bildirilmiştir (Deveci vd., 2017). Yapılan bir başka çalışmada da kadınların (%16,2), erkeklere (%11,4) kıyasla yeme bozukluğu riskinin daha yüksek olduğu belirtilmiştir ($p<0,05$) (Gezer Yalvaç, 2018).

Kronik hastalık sahiplerinin kendilerini yemekten sınırlamaları ve belirli gıdaları tüketmemeleri, kognitif sınırlayıcı yeme boyutu ile ilişkilendirilmiştir (Tablo 6). Bu durum, sağlık durumlarına dikkat etme eğilimlerinin yeme alışkanlıklarını etkilediğini gösterebilir.

Katılımcıların spor/egzersiz yapma durumları ile yeme davranışları arasında Duygusal ve Hedonik yeme boyutlarında anlamlılık tespit edilmiştir (Tablo 8). Buna göre çoğunlukla spor yapan katılımcıların, bazen veya hiçbir zaman spor yapmayan katılımcılara göre daha fazla hedonik ve duygusal yeme bozukluğuna sahip olduğu tespit edilmiştir. Hedonik yeme boyutunda spor yapan bireylerin yemeği ödül olarak kullanabileceği, duygusal yeme boyutundaki anlamlılığın ise spor yapmanın daha fazla enerji tüketimine neden olabileceği ve bu durumun açlık hissini artırmasından kaynaklı olabileceği düşünülebilir. Franzki ve arkadaşlarının (2013) yaptığı bir çalışmada erkek spor bölümünde okuyan öğrencilerin, diğer bölümlerde okuyan erkek öğrencilere kıyasla bulimi ölçeğinde

belirgin şekilde daha yüksek puan görüldüğü bildirilmiştir. Bu durum yapılan bu çalışma ile benzerlik göstermektedir (Franzki vd., 2013). Yapılan bir çalışmada da egzersiz eğitimi ile stres yiyicileri olarak kendini tanımlayan kadınlarda aşırı yeme ve içsel ipuçlarına yanıt olarak yeme olasılığını azaltıldığı bildirilmektedir. Bu durum egzersiz eğitimi ile strese bağlı yeme eğiliminin kontrol altına alınabileceğini belirtmektedir (Unick vd., 2021). Yapılan bir başka çalışmada ise düşük karbonhidratlı beslenme ve egzersiz kombinasyonu ile aşırı kilolu genç kadınlarda vücut ağırlığında ek azalmalara etki etmediği, ancak egzersizin kardiyometabolik sağlığı iyileştirmek ve anksiyete düzeylerini azaltmak için düşük karbonhidratlı beslenme ile birlikte yararlı bir ek tedavi olabileceği bildirilmektedir (Hu vd., 2022).

Sigara/alkol tüketmeyen bireylerin, tüketenlere göre daha fazla hedonik ve kognitif yeme bozukluğuna sahip oldukları tespit edilmiştir (Tablo 8). Sigara ve alkol tüketmeyen bireylerin stresle başa çıkmak için yiyecekleri tercih etme eğiliminde olmaları bu durumu destekleyebilir. Sigara ve alkol tüketmeyen bireyler, stresle başa çıkmak için alkol veya sigara yerine yiyecekleri tercih edebilirler. Sigara ve alkol tüketmeyen bireyler genellikle sağlık ve refahlarına daha fazla odaklanırlar. Bu nedenle, sağlıklı beslenme alışkanlıklarını korumak ve kontrol etmek için daha fazla çaba harcayabilirler. Ayrıca kognitif sınırlayıcı yeme bozukluğu, beslenme ve sağlık konularına aşırı odaklanmayı içerir ve bireyler kendilerini bununla karakterize edebilir. Bu sonuçlar Işık (2009) tarafından yapılan araştırmanın bulguları ile benzerlik göstermektedir. Yapılan bir başka çalışmada da yeme davranışı bozukluğu alt faktörlerinin cinsiyet, sigara ve alkol tüketme, vücut imajından memnuniyetsizlik, ve yüksek algılanan stres ile ilişkili olduğu bildirilmiştir (Matos vd., 2021).

Vücut ağırlığından memnun olan bireylerin, memnun olmayanlara göre daha fazla hedonik yeme eğiliminde olmaları dikkat çekicidir (Tablo 9). Bu durum, duygusal durumun yiyeceklerle olan ilişkisini ve özgüvenin yeme alışkanlıklarını nasıl etkileyebileceğini gösterebilir. Vücut ağırlığından memnun olan bireyler genellikle daha pozitif bir duygusal duruma sahip olabilirler. Daha iyi bir duygusal durum, yiyeceklerle olan olumlu ilişkilerini artırabilir ve bu da hedonik yeme eğilimini destekleyebilir. Ayrıca vücudundan memnun olan bireyler genellikle kendilerine güvenirlere ve özsaygıları daha yüksektir. Bu, yiyecekleri sınırlama konusunda daha az kaygılı olabilecekleri anlamına gelebilir. Bu nedenle, kendine güvenen bireyler, yiyeceklerle olan ilişkilerini daha özgürce yaşayabilirler ve hedonik yeme eğilimleri daha yüksek olabilir. Hiç memnun olmayan katılımcıların ise bu konuda kendilerini sınırladığı söylenebilir. Yapılan bir çalışmada ise zayıf bireylerin normal ve kilolu bireylere göre vücut ağırlıklarından daha az memnun oldukları bildirilmiştir. Bu çalışma genç kadınların düşük kilolu olma eğiliminin ve zayıf olma isteğinin vücut memnuniyetsizliği gibi yeme bozukluğu belirtilerinin gelişimini etkilediğini bildirmektedir (Ko vd., 2015). Akdevelioğlu & Yörüsün (2019) tarafından yapılan çalışmada duygusal yeme ve BKİ arasında pozitif korelasyon tespit edilirken yapılan bu çalışmada herhangi bir anlamlılık gözlemlenmemiştir.

Yapılan bu çalışmada katılımcı öğrencilerin BKİ değerlerinin normal aralıklarda olması ve kız öğrencilerin erkek öğrencilere göre daha fazla katılım sağlaması araştırmanın homojenliğini etkilemiş olabilir. Bu sonuçlar, beslenme alışkanlıklarını ve yeme davranışlarını etkileyen çeşitli faktörlerin karmaşıklığını vurgulamaktadır. Bu araştırma Gastronomi ve Mutfak Sanatları öğrencilerinin yeme davranışı bozukluklarına olan eğilimlerini anlamak için önemli bir adım olarak kabul edilebilir. Çünkü öğrencilerin beslenme ve yeme alışkanlıkları, gelecekteki profesyonel hayatlarında besin hazırlama ve sunma konusundaki yeteneklerini etkileyebilir. Araştırmanın sonuçları, bu öğrenci grubunun genel yeme davranışlarını değerlendirmeye yardımcı olabilir ve gerekli müdahalelerin yapılmasına katkı sağlayabilir.

5. KAYNAKÇA

Akdevelioğlu, Y., & Yörüsün, T. (2019). Üniversite Öğrencilerinin Yeme Tutum Ve Davranışlarına İlişkin Bazı Faktörlerin İncelenmesi. *Gazi Sağlık Bilimleri Dergisi*, 4(1), 19-28.

- Association, A. P. (2013). *Diagnostic And Statistical Manual Of Mental Disorders* (Cilt 5th Ed. Arlington). Va: American Psychiatric Publishing.
- Çelik, S., Yoldaşcan, E. B., Azim, R., & Özenli, Y. (2016). Kadın Üniversite Öğrencilerinde Yeme Bozukluğunun Yaygınlığı Ve Etkileyen Etkenler. *Anadolu Psikiyatri Dergisi*, 17(1), 42-50.
- Demirer B., & H., Y. (2020). Güncel Dsm-5 Kılavuzuna Göre Yeme Bozukluklarının İncelenmesi. *Sağlık Biliminde Multidisipliner Araştırmalar* (S. 275-300). İçinde Efe Akademi Yayınevi.
- Deveci, B., Deveci, B., & Avcıkurt, C. (2017). Yeme Davranışı: Gastronomi Ve Mutfak Sanatları Öğrencileri Üzerine Bir Araştırma. *Journal Of Tourism & Gastronomy Studies*, 5(3), 118-134.
- Franzki, R., Braun, H., Schänzer, W., & Köhler, K. (2013). Eating disorders in sports: comparison of sport students and non-sport students using the Eating Disorder Inventory-2. *Aktuelle Ernährungsmedizin*, 38(4), 283-289.
- Field, A. (2009). *Discovering Statistics Using Spss*. London: Sage.
- Gezer, C., & Yalvac, M. (2018). The relation between eating behaviours and obsession among university students. *Progress in Nutrition*, 20, 429-437.
- Grave, R. D. (2011). Eating Disorders: Progress And Challenges. *European Journal Of Internal Medicine*, 22(2), 153-160.
- Harrer, M., Adam, S., Messner, E., Baumeister, H., Cuijpers, P., Bruffaerts, R., . . . Taylor, C. (2020). Prevention Of Eating Disorders At Universities: A Systematic Review And Meta-Analysis. . *Int. J. Eat. Disord*, 813-833.
- Hay, P. (2020). Current Approach To Eating Disorders: A Clinical Update. *Internal Medicine Journal*, 50(1), 24-29. Doi:Doi:10.1111/İmj.14691
- Hilbert, A. (2019). Binge-Eating Disorder. *Psychiatric Clinics*, 42(1), 33-43.
- Hu, M., Shi, Q., Sun, S., Hong, H. I., Zhang, H., Qi, F., ... & Nie, J. (2022). Effect of a low-carbohydrate diet with or without exercise on anxiety and eating behavior and associated changes in cardiometabolic health in overweight young women. *Frontiers in Nutrition*, 9, 894916.
- Hudson, J., Hiripi, E., Pope, H., & Kessler, R. (2007). The Prevalence And Correlates Of Eating Disorders İn The National Comorbidity Survey Replication. *Biol. Psychiatry*, 61, 348-358.
- Işık, B. (2009). Uludağ Üniversitesi Öğrencilerinde Yeme Bozukluklarının Araştırılması . *Doctoral Dissertation, Bursa Uludag University (Turkey)*.
- Kadıoğlu, M. &. (2015). Üniversite Öğrencilerinin Yeme Tutumu, Öz-Etkililikve Etkileyen Faktörler. *Journal Of Marmara University Institute Of Health Sciences*, 5(2), 96-104. Doi:10.5455/Musbed.20150309011008
- Ko, N., Tam, D. M., Viet, N. K., Scheib, P., Wirsching, M., & Zeeck, A. (2015). Disordered eating behaviors in university students in Hanoi, Vietnam. *Journal of eating disorders*, 3, 1-7.
- Korkmaz, N. H. (2010). Uludağ Üniversitesi Öğrencilerinin Spor Yapma Ve Beslenme Alışkanlıklarının İncelenmesi. . *Uludağ Üniversitesi Eğitim Fakültesi Dergisi*, 23(2), 399-413.
- Kurz S, V. D. (2015). Early-Onset Restrictive Eating Disturbances İn Primary School Boys And Girls. *European Child & Adolescent Psychiatry*, 24, 779-85.
- Le Grange, D., & Loeb, K. (2007). Early Identification And Treatment Of Eating Disorders: Prodrome To Syndrome. *Early Interv. Psychiatry*, 1, 27-39.
- Oğur, S., Aksoy, A., & Selen, H. (2016). Üniversite Öğrencilerinin Yeme Davranışı Bozukluğuna Yatkınlıkları: Bitlis Eren Üniversitesi Örneği. *Beü Fen Bilimleri Dergisi*, 5(1), 14-26.
- Matos, A. P., Rodrigues, P. R. M., Fonseca, L. B., Ferreira, M. G., & Muraro, A. P. (2021). Prevalence of disordered eating behaviors and associated factors in Brazilian university students. *Nutrition and Health*, 27(2), 231-241.
- Polivy, J., & Herman, C. P. (2002). Causes Of Eating Disorders. *Annual Review Of Psychology*, 53(1), 187-213. Doi:Doi:10.1146/Annurev.Psych.53.1009

- Purkiewicz, A., Kamelska-Sadowska, A. M., Ciborska, J., Mikulska, J., & Pietrzak-Fiecko, R. (2021). Risk Factors For Eating Disorders And Perception Of Body In Young Adults Associated With Sex. *Nutrients*, 3, 2819.
- Qian, J. W. (2021). An Update On The Prevalence Of Eating Disorders In The General Population: A Systematic Review And Meta-Analysis. *Eating And Weight Disorders - Studies On Anorexia, Bulimia And Obesity*. Doi:10.1007/S40519-021-01162-Z
- S, Ö., A, M., & E., L. (2018). Üniversite Öğrencilerinde Yeme Tutumu Ve Yeme Tutumuna Etki Eden Faktörler. *Adyü Sağlık Bilimleri Derg.*, 4(2), 841-849.
- Scherer, R. F., Luther, D. C., Wiebe, F. A., & Adams, J. S. (1988). Dimensionality Of Coping: Factor Stability Using The Ways Of Coping Questionnaire. *62(3)*, 763-770.
- Swinbourne, J. M., & Touyz, S. W. (2007). The Co-Morbidity Of Eating Disorders And Anxiety Disorders: A Review. *European Eating Disorders Review*, 15(4), 253-274. Doi:10.1002/Erv.784
- Şahin, İ. N. (2022). Besin Bilgisi Ve Yeme Tutumuna Yönelik Ölçek Geliştirme: Geçerlilik Ve Güvenilirlik Çalışması . *Yüksek Lisans Tezi*. Üsküdar Üniversitesi.
- Tabachnick, B. G., & Fidell, L. S. (2013). *Fidell Using Multivariate Statistics*. L.S. (Sixth Ed.):)Pearson, Boston.
- Tabachnick, B. G., & Fidell, L. S. (2013). *Fidell Using Multivariate Statistics*. L.S. (Cilt Sixth Ed.). Boston: Pearson.
- Tavolacci, Mp. S, G., L, R., G, M., P, D., & J., L. (2015). Eating Disorders And Associated Health Risks Among University Students. *J Nutr Educ Behav*, 47, 412-420.
- Telatar, T. G. (2021). Bir Üniversitenin Tıp Fakültesinde Öğrenim Gören Öğrencilerin Beslenme Ve Yeme Bozukluğu Sıklığının Ve İlişkili Faktörlerin Belirlenmesi. *Fırat Tıp Dergisi*, 26(2), 68-73.
- Treasure, J., Claudino, A. M., & Zucker, N. (2010). Eating Disorders. *The Lancet*, 375(9714), 583-593. Doi: 10.1016/S0140-6736(09)61748-7
- Tümen, Z. Ç. (2023). Yeme Bozukluklarına Genel Bir Bakış. *Çukurova Tıp Öğrenci Derg.*, 3(2), 40-45.
- Ulaş, B., Uncu, F., & Üner, S. (2013). Sağlık Yüksekokulu Öğrencilerinde Olası Yeme Bozukluğu Sıklığı Ve Etkileyen Faktörler. *Annals Of Health Sciences Research*, 2(2), 1-8.
- Unick, J. L., Dunsiger, S. I., Leblond, T., Hahn, K., Thomas, J. G., Abrantes, A. M., ... & Wing, R. R. (2021). Randomized trial examining the effect of a 12-wk exercise program on hedonic eating. *Medicine and science in sports and exercise*, 53(8), 1638.
- Wade, T. D. (2018). Recent Research On Bulimia Nervosa. *Psychiatric Clinics Of North America*. Doi:10.1016/J.Psc.2018.10.002
- Walsh, B. T. (1998). Eating Disorders: Progress And Problems. *Science*, 280(5368), 1387-1390.
- Who. (2024, Ocak 30). <https://www.who.int/europe/news-room/fact-sheets/item/a-healthy-lifestyle---who-recommendations> Adresinden Alındı
- Yaşar, K., Emel, L. N., Şimal, Ç., Nurcan, E., Mürvet, D., Bige, D., . . . Osman, H. (2010). Maltepe Üniversitesi Tıp Fakültesi Öğrencilerinde Olası Yeme Bozukluğu Sıklığı. *Maltepe Tıp Derg*, 2(2), 18-25.
- Yök. (2023, 06 01). <https://yokatlas.yok.gov.tr/lisans.php?Y=106190067> Adresinden Alındı
- Zimmerman, J. &. (2017). Avoidant/Restrictive Food Intake Disorder (Arfid). *Current Problems In Pediatric And Adolescent Health Care*, 47(4), 95-103. Doi:10.1016/J.Cppeds.2017.02.005



Fındık Fiyatlarının Yapay Sinir Ağları ile Tahminlenmesi: Türkiye Örneği

Mehmet Akif KARA^{1*}

Giresun Üniversitesi, TÜRKİYE

Doi: 10.55024/buyasambid.1394033

MAKALE BİLGİSİ

Makale Türü: Araştırma Makalesi

Makale Geçmişi:

İlk gönderim tarihi: 21.11.2023

Düzeltilme tarihi: 11.01.2024

Kabul tarihi: 11.01.2024

Yayın tarihi: 07.07.2024

Anahatar Kelimeler:

Yapay Sinir Ağları, Öngörü,
Fındık, Fiyat Tahmini.

*¹Mehmet Akif KARA

E-mail address:

akifkara28@gmail.com

Orcid: 0000-0003-4308-9933

ÖZET

Fındık hiç kuşkusuz Türkiye için önemli bir tarım ürünüdür. Fındık fiyatlarının tahminlenmesi fiyatın belirlenmesi, ürünün pazarlanması vs. açıdan çok önemlidir. Fiyat tahminlemede birçok yöntem kullanılmaktadır. Bu yöntemlerden birisi de yapay zekânın bir alt türü olan yapay sinir ağlarıdır. Bu çalışmada yapay sinir ağları ile fındık fiyatının tahminlenmesi yapılmıştır. Çalışmanın amacı fiyat tahminlenmesinde yapay sinir ağları kullanılarak bir model ortaya konulması ve uygulamasının gerçekleştirilmesidir. Alan yazındaki çalışmalardan farkı da bu yöntem ile fındık fiyatı tahminlenmesi üzerine uygulanmasıdır. Çalışmada, Giresun Ticaret Borsası'ndan elde edilen 2000-2023 yıllarına ait aylık fındık fiyatlarından oluşan 214 veriden oluşan zaman serisi kullanılmıştır. Çalışmanın analizi için MATLAB Neural Network Toolbox aracı kullanılmıştır. Çalışmada kullanılan veri seti tek değişkenli zaman serisi olduğu için Nonlinear Autoregressive (NAR) ile analiz gerçekleştirilmiştir. Çalışma neticesinde fındık fiyatlarının tahminine ilişki yapay sinir ağı modeli kurulmuş ve 0.33 derecelik ortalama hata ile tahminleme yapılmıştır.

2024 Batman Üniversitesi. Her hakkı saklıdır.

Forecasting Hazelnut Prices with Artificial Neural Networks: The Case of Türkiye

Mehmet Akif KARA^{1*}

Giresun University, TURKEY

Doi: 10.55024/buyasambid.1394033

ARTICLE INFO

Article Type: Research Article

Article history:

Received: 11.01.2024

Received in revised form

Accepted: 11.01.2024

Available online: 07.07.2024

ABSTRACT

Hazelnut is undoubtedly an important agricultural product for Turkey. Forecasting hazelnut prices is very important in terms of price determination, marketing of the product, etc. Many methods are used in price forecasting. One of these methods is artificial

Keywords:
Artificial Neural Networks,
Forecasting, Hazelnut, Price
Forecasting.

*¹Mehmet Akif KARA
E-mail address:
akifkara28@gmail.com
Orcid: 0000-0003-4308-9933

neural networks, which is a subtype of artificial intelligence. In this study, hazelnut price forecasting is done with artificial neural networks. The aim of the study is to present a model using artificial neural networks in price forecasting and to realize its application. The difference from the studies in the literature is that it is applied on hazelnut price forecasting with this method. In the study, a time series of 214 data consisting of monthly hazelnut prices for the years 2000-2023 obtained from Giresun Commodity Exchange was used. MATLAB Neural Network Toolbox tool package was used for the analysis of the study. Since the data set used in the study is a univariate time series, the analysis was performed with Nonlinear Autoregressive (NAR). As a result of the study, an artificial neural network model was established for the prediction of hazelnut prices and prediction was made with an error margin of 0.33.

2024 Batman University. All rights reserved

1. GİRİŞ

Türkiye tarımında en önemli ürünlerden birisi hiç kuşkusuz fındıktır. Fındık, üretim yoğunluğunun çoğunluğunu Karadeniz bölgesinde bulundurmaktadır. Bu bölgede yaşayan hemen herkesin fındık üretimi ile doğrudan ilişkisi bulunmakta ve bölgenin en önemli geçim kaynağı olarak karşımıza çıkmaktadır. Bölge halkı için önemli ve birincil geçim kaynağı olan fındık üretim alanları iki standart gruba ayrılmıştır. İlk standart grupta; Giresun, Ordu, Trabzon, Rize ve Artvin yer almaktadır. İkinci standart grupta ise; Samsun, Sinop, Kastamonu, Bolu, Düzce, Sakarya, Zonguldak ve Kocaeli illeri yer almaktadır (Hazneci, Naycı ve Çelikkan, 2022). Türkiye’de fındık üretimi/tarımı genel itibarıyla aile işletmeciliği şeklinde yapılmaktadır (Karaman, 2022:23).

Fındık ürünü çok farklı alanlarda kullanılmaktadır. Bu nedenle Dünya ekonomisinde de önemli bir tarım ürünü olarak karşımıza çıkmaktadır. Kuruyemiş, tatlı, helva, çikolata, fırıncılık vs. gibi sektörlerde hammadde olarak kullanılmaktadır. Dolayısı ile sıradan bir tarım ürünü olmasının ötesinde önemli bir sanayi hammaddesidir (Kırhasanoğlu, 2022: 166). Bu bağlamda değerlendirildiğinde fındık fiyatlarının tahmin edilmesi stratejik politikaların gerçekleştirilebilmesi için elzemdir. Hem Türkiye’nin diğer üretici ülkelerle rekabeti hem de fındık fiyatının belirlenmesi sürecine müdahil olabilmesi için stratejik politikaların belirlenmesi gerekmektedir.

24 Ocak 1980 yılı itibarıyla uygulanmaya konulan neoliberal ekonomi politikaları birçok alan gibi tarım alanını da doğrudan etkilemiştir (Öztürk, Nas, İçöz, 2008). Tarım alanında liberalizasyon politikalarının giderek yoğunlaşması ve pazar odaklı politikaların uygulanması, tarımsal ürünlerde fiyat oynaklığı (volatilité) konusunda bir çok tartışmayı beraberinde getirmiştir. Koşullara bağlı olarak oluşan ürün fiyatlarındaki oynaklığın varlığı da tarım üreticisi için verimlilik, yatırım ve birçok konuda karar alma sürecinde önemli bir unsur haline gelmiştir (Yang, Haigh ve Leathem, 2001: 593). Fındık fiyatına etki eden birçok faktör söz konusudur. Yapılan araştırmalar neticesinde fındık üretim miktarı (Hüsnoğlu, 2018), fındık ihracat miktarı (Kırhasanoğlu, 2022), Pazar yoğunlaşması ve Pazar gücü (Spaulding, Tulum, Sahgaian ve Özertan, 2009), gibi değişkenler fındık fiyatları üzerinde etkili olmaktadır.

Özellikle, dünyada en yaygın olarak yetiştiriciliği yapılan sert kabuklu meyve grubunda bademden sonra fındık yer almaktadır. Fındık ürünü bu özelliğinin yanı sıra Türkiye açısından tarım sektörünün önemli ürünlerinden birisidir. Fındık ihracatından ülkeye önemli oranda döviz geliri sağlanmaktadır. Aynı zamanda, Türkiye, dünya fındık üretiminde lider ülke konumunda bulunmaktadır (Bozoğlu ve Kabaoğlu, 2023). Tablo 1’de ülkelerin fındık üretim miktarları gösterilmektedir.

Tablo 1. Dünya fındık üretimi (2021)

Ülke	Üretim (Ton)	Kişi Başına Üretim (Kg)	Yüzölçümü (Hektar)	Verim (Kg/Hektar)
Türkiye	515.000	6,373	728.381	707
İtalya	132.699	2,196	78.593	1.688,4
Azerbaycan	52.067	5,26	39.021	1.334,3
ABD	46.270	0,141	17.806	2.598,6
Çin Halk C.	24.790	0,018	11.775	2.105,3
Gürcistan	17.000	4,558	9.484	1.792,5
İran	15.839	0,194	17.957	882
Fransa	14.988	0,223	6.644	2.255,9
Şili	9.019	0,513	13.104	688,3
İspanya	8.033	0,172	13.505	594,8
Polonya	6.642	0,173	3.716	1.787,4
Sırbistan	5.428	0,775	4.363	1.244,1
Kırgızistan	4.346	0,689	6.824	636,9
Özbekistan	3.711	0,114	3.219	1.152,8
Hırvatistan	1.753	0,418	4.810	364,4
Beyaz Rusya	1.275	0,135	2.057	619,8
Romanya	1.036	0,053	715	1.449
Tacikistan	997	0,112	802	1.242,7
Yunanistan	810	0,075	420	1.928,6
Bulgaristan	393	0,056	799	491,9
Ermenistan	342	0,115	192	1.781,3
Moğolistan	326	0,101	358	910,3
Moldova	267	0,075	515	519,4
Portekiz	240	0,023	348	689,7
Slovenya	223	0,108	119	1.873,9
Kamerun	167	0,007	149	1.117,1
Macaristan	134	0,014	348	385,1
Tunus	46	0,004	50	918,1
Kıbrıs	23	0,027	17	1.352,9
Ukrayna	20	0	100	200

Kaynak: FAO (2021) akt. Kara, 2022).

Fındık endüstrisi bu bağlamda üreticisinden tüketicisine ve aracısına kadar birçok sektörle doğrudan ilişki kurmaktadır (Kara, 2022: 105). Fındık fiyatlarının belirlenmesi süreci de bu paydaşların faaliyetlerini doğrudan etkilemektedir. Hem üretici açısından hem de satıcı/işletmeci açısından fiyatların makul seviyelerde olması gerekmektedir. Aynı zamanda tarımsal ürünlerin fiyatlarını tahmin etmek, hem ilgili paydaşlar hem de politika yapıcılar açısından her zaman önemli bir yerdedir (Wang, Wang, Li ve Zhou (2022).

Fındık fiyatlarının tahminlenmesine ilişkin alan yazında az sayıda çalışma vardır. Fındık üzerine olan çalışmalar daha çok üretim miktarının tahmini ya da fındık fiyatı ile farklı değişkenler arasındaki ilişkinin ekonometrik olarak belirlenmesine dayalıdır. Buna karşı farklı tarım ürünlerinin fiyatlarının tahminine ilişkin farklı yöntemlerle yapılmış çalışmalar vardır. Özer ve Yavuz (2014) çalışmalarında literatürde sıklıkla kullanılan Box Jenkins modeli yardımıyla fındık fiyatlarının tahminlenmesini gerçekleştirmiştir. Khamis ve Abdullah (2014) yılında yaptıkları çalışmada, geri yayımlı sinir ağı ve NARX modellerini kullanılarak gelecekteki buğday fiyatının tahmin edilmesi amaçlanmıştır. Can ve Gerşil (2018) yaptıkları çalışmada Manisa ilinde pamuk fiyatlarını zaman serisi analizi ve yapay sinir ağı teknikleri ile tahminlemiştir. Şeyranlıoğlu (2022) fındık fiyatları ile döviz kuru arasındaki ilişkiyi incelemiştir. Bayyurt ve Deveci Kocakoç (2023) yapay sinir ağları NARX ile fındık üretim miktarını tahminlemiştir. Wang (2023) çalışmasında Çin'de son 10 yılda domuz eti satış fiyatını ve yenilenebilir sarımsak talebini etkileyen faktörleri geliştirilmiş RBF sinir ağı modeli ile tahmin etmektedir. Xu ve Zhang (2023), Çin'de mısır fiyatlarını 1 Ocak 2010-10 Ocak 2020 döneminde haftalık toptan fiyat endeksi için tahmin etmiştir. Sonuç modeli doğru ve istikrarlı sonuçlara yol açmış ve eğitim, geçerlilik ve test için sırasıyla %1.05, %1.08 ve %1.03'lük göreceli kök ortalama kare hataları üretmektedir. Yapay sinir ağları ise tahmin problemlerinde son yıllarda sıklıkla kullanılmaktadır. Alhendi, Al-Sumaiti,

Marzband, Kumar ve Diab (2023), geliştirilmiş Markov zinciri ile yapay sinir ağı kullanarak kısa vadeli yük ve fiyat tahminini hesaplamıştır. Çalışma sonucunda geliştirilmiş YSA-MC modelinin daha etkili ve doğru tahmin yaptığı bulunmuştur. Kurani, Doshi, Vakharia ve Shah (2023) yaptıkları araştırmada hisse senedi tahmininde yapay sinir ağlarını kullanmıştır. Çalışmada geri yayılım algoritması ve çok katmanlı ileri besleme ağının bir kombinasyonu olan hibrit YSA modelleri uygulanmıştır. Kumari, Goswami ve Pundir (2023) yılında Hindistan'da muz fiyatlarının tahmini için YSA kullanmış ve sonuçları diğer yöntemlerle karşılaştırmıştır. Tekrarlayan sinir ağı (RNN) bu çalışmada çeşitli istatistiksel ve makine öğrenimi teknikleriyle karşılaştırıldığında doğru fiyatları tahmin etmede diğer modellerden daha iyi performans göstermektedir. ARIMA, SARIMA, ARCH GARCH ve ANN gibi diğer metodolojilerin doğruluğu beklentilerin altında kalmaktadır. Saplıoğlu ve Çimen (2010) ise çalışmalarında yapay sinir ağlarını kullanarak günlük yağış miktarını tahmin etmiştir. Çalışma verileri ABD Portland bölgesinde bulunan yağış gözlem istasyonlarından elde edilen, günlük yağış verileridir. Çalışma sonucunda, YSA modeli en küçük hata değerlerini vermiş ve standart hesap yöntemlerine göre daha üstün olduğu ortaya konulmuştur. Akkan, Mutlu ve Baş (2022), 2010-2020 yılları arasında Rize istasyonundan elde edilen aylık ortalama deniz suyu sıcaklığına ait zaman serisinin tahminini ileri beslemeli yapay sinir ağı ile gerçekleştirmiştir. Çalışma sonunda ileri beslemeli yapay sinir ağları en uygun öngörü performansına sahip yöntem olmuştur. Szoplik ve Muchel (2023) doğal gaz bileşimlerinin tahmini için yapay sinir ağları metodunu kullanmıştır. Tahminde 8760 gerçek veri üzerinden model eğitimi gerçekleştirilmiştir. Şenol ve Denizhan (2023) yaptıkları çalışmada kripto para değerinin tahmininde yapay sinir ağları ve regresyon analizini kullanmıştır. Çalışma sonrasında tahmini değer ile gerçek değerler arasındaki karşılaştırmada yapay sinir ağları ile yapılan tahminin daha başarılı sonuç verdiği ortaya konulmuştur.

Bu çalışmada da MATLAB programı Neural Network Toolbox aracı kullanılarak fiyat tahmininde bulunulacaktır. Çalışmanın amacı fiyat tahmininde yapay sinir ağları kullanılarak bir model ortaya konulması ve uygulamasının gerçekleştirilmesidir. Alan yazındaki çalışmalardan farkı da bu yöntem ile fındık fiyatı tahmini üzerine uygulanmasıdır. Oluşturulan model ile birlikte hem politika yapıcılar, hem işletmeler hem de fındık piyasasında faaliyet gösteren paydaşlar açısından geleceğe ilişkin bir projeksiyonun ortaya konulması da çalışmanın ikincil amaçları arasında yer almakta ve literatüre katkı sunacağı düşünülmektedir.

2. YÖNTEM

2.1. Yapay Sinir Ağları


Yapay Sinir Ağları (YSA) yapay zekâ yöntemlerinden birisidir. Yapay sinir ağı, insan beynindeki biyolojik nöronların mimarisinden esinlenmiştir. İlk yapay sinir ağı modellemesi 1943 yılında bir nörobilimci olan Warren McCulloch ve bir matematikçi olan Walter Pitts tarafından gerçekleştirilmiştir. Basit biyolojik sinir sistemlerin çalışma şekillerinin taklit edilerek oluşturulan matematiksel modellemelerdir (Eğrioğlu, Yolcu ve Baş, 2019:1).

YSA yönteminde örnekler kullanılarak öğrenme işlemi gerçekleştirilir. Bilinen hesaplama tekniklerinden farklılaşan bir yöntem önermektedir. Bu yöntemi öne çıkaran çeşitli özellikleri söz konusudur. Bu özellikler; bulunduğu ortama uyum sağlayabilmesi, adapte olabilmesi, eksik veri ile çalışabilmesi, belirsizlik durumunda karar verebilmesi ve hata toleransının bulunmasıdır (Eğrioğlu, Yolcu ve Baş, 2019). Bu bağlamda ele alındığında yaşanan her alanında başarılı bir şekilde uygulanması mümkündür. Keza, son yıllarda, özellikle sınıflandırma, sinyal filtreleme, örüntü tanımlama, veri sıkıştırma ve optimizasyon konularında YSA güçlü sonuçlar üreten teknikler arasında yer almaktadır (Eğrioğlu, Aladağ, Yolcu ve Baş, 2015; Cansu, Kölemen, Karahasan, Baş ve Eğrioğlu, 2023).

YSA için kullanılan veri seti eğitim, geçerlilik ve test verisi olarak parçalanır. Eğitim verisi, YSA'nın optimal ağırlıklarını belirlemek için kullanılırken; geçerlilik kümesi ise eğitimi erken durdurmak için aşırı belirleme probleminde çözüm bulmak amacıyla kullanılmaktadır. Test verisi ise

mimarinin nihai performansının diğer mimari yapı veya diğer yöntemler ile karşılaştırılmasında kullanılabilir. YSA girdi, gizli ve çıktı olmak üzere üç ana tabakadan oluşmaktadır. Her bir tabaka ise nöronlardan oluşmaktadır. Nöronların birbirleri ile bağlantıları ağı oluşturmaktadır. Şekil 1'de üç ana katmandan oluşan yapay sinir ağı bağlantıları verilmiştir.

Şekil 1. Yapay sinir ağı bağlantıları



Kaynak: www.akanesen.com

Yapay sinir ağları için çeşitli programlama dillerinde birçok kütüphane ve araç geliştirilmiştir. Bunlar arasında öne çıkanlar Stuttgart Neural Network Simulator (SNNS), Fast Artificial Neural Network Library (FANN), Java Object Oriented Neural Engine (JOONE) ve MATLAB Neural Network Toolbox gibi araçlardır (Arı ve Berberler, 2017).

Çalışmada yapay sinir ağları ile uygulama yapmakta kullanılan araçlar arasında yer alan MATLAB Neural Network Toolbox aracı kullanılmıştır. Bu araç paketi içerisinde bulunan zaman serilerinin YSA ile çözümlenmesinde Neural Time Series aracı kullanılmıştır. Çalışmada kullanılan veri seti tek değişkenli zaman serisi olduğu için Nonlinear Autoregressive (NAR) kısmı kullanılmıştır. NAR; $y(t)$ zaman serisi, kendi gecikmeli değişkenleri yardımıyla çözümlenmektedir. Elde edilen model doğrusal olmayan bir otoregressif model olacaktır. Literatürde sıkça kullanılmaktadır (Eğrioğlu, Yolcu ve Baş, 2019; Çakır Sönmez, 2019). Neural Fitting Tool gizli katmanda sigmoid aktivasyon fonksiyonu, çıktıda ise doğrusal aktivasyon fonksiyonunu kullanan birçok katmanlı algılayıcı mimarisi ile çözüm yapmaktadır. Eğitim algoritması olarak ise LM (Levenberg-Marquardt) algoritması tercih edilmiştir. Bu yöntem ikinci derecede eğitim algoritmasıdır. Geri yayılım algoritmasından farklı olarak ağırlıklar bir devirde bir kez değiştirilmektedir (Khosravi, Barghinia ve Ansarimehr, 2006).

Bu çalışmada veri seti eğitim, geçerlilik ve test kümesi olarak parçalanmıştır. Bunun nedeni ise eğitim ve geçerlilik kümeleri optimum ağırlıklarının belirlemektir. Aynı zamanda geçerlilik kümesini kullanarak, eğitim sürecinin ağırlıkların ezberlemesini engelleyecek şekilde durdurulması sağlanmaktadır.

3. BULGULAR

Verilerin çözümlenmesi sürecinde ilgili araç kullanılırken karar verilmesi gereken önemli bir parametre gizli tabaka birim sayısı olmaktadır. Her farklı gizli tabaka sayısı için YSA şekil olarak farklı bir doğrusal olmayan model ile çalışılmasına imkân vermektedir. Bu nedenle uygun gizli tabakadaki birim sayısının belirlenmesi kritik olmaktadır. Farklı girdi ve katman sayılarına göre hata oranı düşük model belirlenmektedir. En iyi test kümesi performansı üreten model bizim için tercih edilmesi gereken model olmaktadır (Eğrioğlu, Yolcu ve Baş, 2019).

Çalışmada 2000-2023 yılları arasında Giresun Ticaret Borsası'ndan elde edilen fındık satış fiyatlarını içeren 214 veri kullanılmıştır. Çalışmadaki MSE değerleri Tablo 2'de verilmiştir. MSE

değerleri birim başına hatanın karesini gösteren ve YSA’larda kullanılan temel hata ölçütlerinden birisidir (Eğrioğlu, Yolcu ve Baş, 2019). MSE değerlerinin küçük olması ağın eğitiminin başarılı olduğunu göstermektedir (Yaman Selçi, 2021: 26).


Eğitim, geçerlilik ve test kümesi oranları sırasıyla %70, %15 ve %15 olarak alınmıştır. Literatürde olan genel kabul eğitim kümesinin geçerlilik ve test kümelerine göre daha büyük alınması gerektirir (Eğrioğlu, Yolcu ve Baş, 2019: 96).

Tablo 2. Aylık fındık fiyatları verilerinde gizli tabaka birimleri için sonuçlar

HKO (MSE) Değerleri			
Gizli tabaka birim sayısı	Eğitim	Geçerlilik	Test
1	0.12	0.19	0.66
2	0.12	0.57	0.11
3	0.97	0.12	0.27
4	0.68	0.17	0.17
5	0.55	0.64	0.13
6	0.62	0.11	0.30
7	0.79	0.27	0.82
8	0.83	0.14	0.23
9	0.53	0.95	0.59
10	0.77	0.56	0.36
11	0.92	0.27	0.30
12	0.77	0.74	0.19

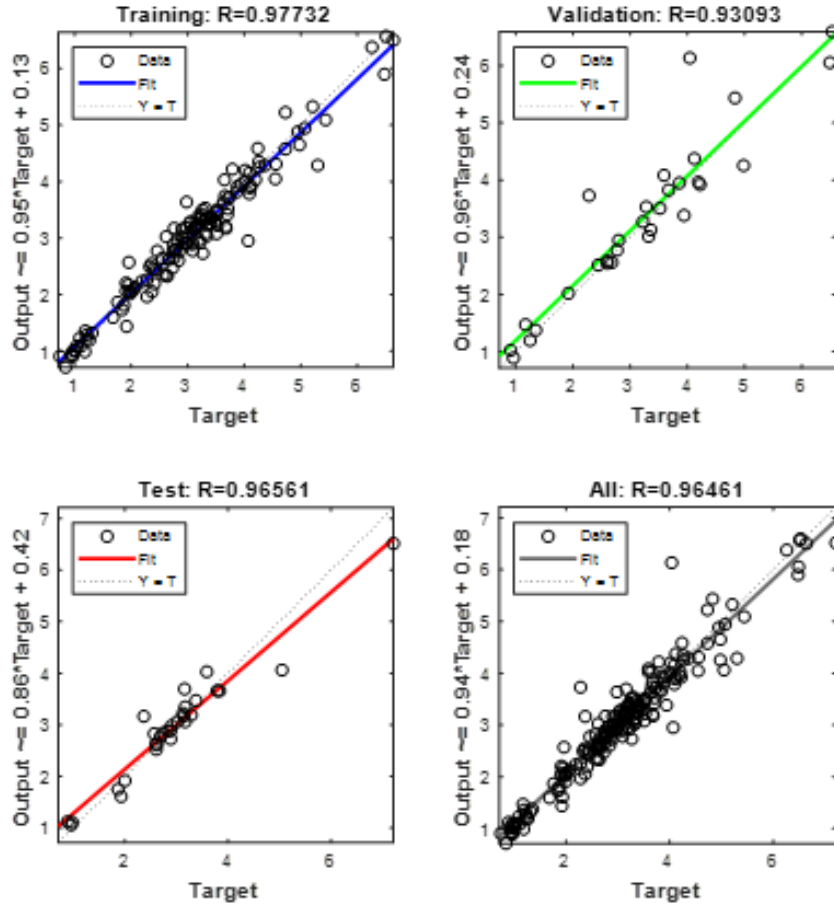
Sonuçlar incelendiğinde en iyi test sonucunun gizli tabaka birim sayısı 2 olduğunda elde edildiği görülmektedir. Bu mimari eğitim ve geçerlilik sonuçlarının da kötü olmadığı dikkate alınarak zaman serisinin modellenmesinde seçilebilir. Eğitim süreci için grafik Şekil 2’de gösterilmiştir. On altıncı iterasyondan itibaren geçerlilik kümesi için MSE değerleri iyileşme sağlayamadığından eğitim süreci on yedinci iterasyon itibariyle durdurulmuştur ve 11. İterasyondaki optimal ağırlık ve yan değerlerinde karar kılınmıştır.

Şekil 2. Gizli tabaka birim sayısı 2 olduğunda eğitim süreci grafiği



Şekil 3’de eğitim, geçerlilik ve test için ayrılan verilerin regresyon değerleri verilmiştir. Grafik incelendiğinde r square değerlerinin yüksek olduğu görülmektedir. Bu sonuçlar, ağıın öğrenme işlemini başarıyla tamamladığını göstermektedir. Yapay sinir ağları için r square değerlerinin 0.80’in üzerinde olması beklenmektedir (Eğrioğlu, Yolcu ve Baş, 2019). Bu değerin yüksek olması model uyumunun iyi olduğunu göstermektedir (Yaman Selçi, 2021:26). Şekil 3’de gösterilen kesikli çizgi, çıktı ve hedeflerin birbirine eşit olması mükemmel uyum çizgisidir. Daireler veri noktalarıdır ve renkli çizgi çıktılar ile hedefler arasındaki en iyi uyumu temsil etmektedir (Caner, Kesik ve Keçebaş, 2011).

Şekil 3. Regresyon grafiği



Gizli tabaka ile çıktı tabakası arasındaki ağırlıklar (LW) -0.20 ve 1.87 olarak elde edilmiştir. Çıktı tabakası için optimal yan değeri (b) -0.1332 ve gizli tabaka birimleri için optimal yan değerleri ise sırasıyla 0.8397 ve 0.1230 olarak elde edilmiştir. Diğer optimal ağırlıklar (IW) ise Tablo 3’de gösterilmektedir. Optimal ağırlık yapay sinir ağının eğitim verisi ile eğitilmesi sonucunda elde edilen optimum ağırlık ve yan değerlerini göstermektedir (Eğrioğlu, Yolcu ve Baş, 2019). Bu ağırlıkları kullanarak gelecek yıllarda modelden tekrar öngörülerin elde edilmesi mümkün olabileceği için makalede yer verilmektedir.

Tablo 3. Girdi tabakası ile gizli tabaka arasındaki optimal ağırlıklar


Gizli Tabaka	Girdi Tabakası											
	1	2	3	4	5	6	7	8	9	10	11	12
1	0.96	0.19	0.64	-0.19	-0.12	-0.05	0.12	-1.17	-0.39	-0.15	-0.11	0.16
2	0.65	-0.08	0.11	-0.01	-0.07	0.02	-0.03	0.01	-0.25	0.07	0.12	-0.05

Çalışmada ele alınan fındık fiyatları aylık verileri için çok katmanlı algılayıcı model oluşturulmuştur. Çok katmanlı algılayıcı model bir tür ileri beslemeli yapay sinir ağıdır. Modelin tahminlerinin gerçek değerler ile birlikte grafiği Şekil 4’de gösterilmektedir. Modelin yorumlanmasında test kümesi için MSE değeri 0.11 olduğundan karekökü alınarak sonraki bir ay için fiyat tahminimizi 0.33 derecelik bir ortalama hata ile tahmin etmemiz mümkündür. Modelin gelecek değerleri de bu ortalama hata ile tahmin edilmesi beklenmektedir.

Tablo 4. Aylık fındık fiyatları ve YSA tahmin fiyatlarının seçili tablosu


Gözlem	Gerçek Değerler	YSA Tahmin değerleri	Gözlem	Gerçek Değerler	YSA Tahmin Değerleri
1	1.56	1.56	8	1.27	1.21
2	1,56	1.56	9	1.68	1.55
3	1,66	1.30	10	1.73	1.49
4	1,7	1.52	11	1.53	1.55
5	1,7	1.46	12	0.99	1.08
6	1,65	1.46	13	0.94	0.83
7	1,37	1.42	14	1.18	1.12

Şekil 4. Aylık fındık fiyatları ile YSA tahminlerinin birlikte grafiği



Şekil 4’te aylık fındık fiyatları ile yapay sinir ağı tahminlerinin birlikte grafiği yer almaktadır. Çalışmada kullanılan aylık fındık fiyatları <https://www.giresuntb.org.tr/Istatistikler> adresinde yer almaktadır.

Şekil 5. Çalışmanın yapay sinir ağı mimari grafiği



Şekil 5’de görüldüğü üzere modelin yapay sinir ağı mimari grafiği tek katmanlı algılayıcı girdi, 2 gizli tabaka birimi ve 1 çıktıdan oluşmaktadır.

4. TARTIŞMA VE SONUÇ

Fındık ürünü Türkiye için önemli bir gelir kaynağıdır (Çamoğlu, Akıncı ve Bozkurt, 2015:28). Çok sayıda paydaşı doğrudan ilgilendiren, birçok sektörle ilişki içerisinde bulunan önemli bir tarım ürünüdür. Fındık endüstrisinin gelişimi aynı zamanda Türkiye’nin diğer fındık üreticisi ülkelerle rekabetini de güçlendirecektir. Bu açıdan fındık fiyatlarının sadece rekabet edirlilik düzeyi açısından değil bu üründen geçinen yüzbinlerce üreticinin de refahı için yüksek olması beklenmektedir. Ürünün ana geçim kaynağı haline getirilmesi aynı zamanda üretimde kullanılacak muhtemel teknolojik yeniliklerinde yaygınlaşmasını beraberinde getireceği aşikârdır.

Bu çalışmada 2000-2023 yıllarına ait aylık fındık fiyatı verileri kullanılarak fındık fiyatının tahminine ilişkin bir model ortaya konulmaktadır. Çalışmada uygulama kolaylığı nedeniyle MATLAB Neural Network Toolbox aracı kullanılmıştır. Yapılan analiz sonucunda yapay sinir ağları yöntemi ile birlikte tahminlemenin iyi bir sonuç verdiği ifade edilebilir. 0.33 ortalama hata payı ile tahmin değerinin gerçek değere yakın olduğu görülmektedir. Yapay sinir ağlarının özellikle zaman serisi ve tahminleme problemlerinde kullanımının diğer yöntemlere göre daha gerçeğe yakın sonuç verdiği ifade edilebilir.

Konuya ilişkin yapılan benzer çalışmalarda elde edilen sonuca göre yapay sinir ağlarının reel olana daha yakın sonuçlar ürettiği görülmektedir (Şenol ve Denizhan, 2023; Kotan ve Erener, 2023).

Yapay sinir ağlarının tasarımlarının kolay olması, herhangi bir probleme kolayca adapte edilebilmesi ve veri setinin az olmasına karşı başarılı sonuçlar üretebilmesi nedeniyle birçok alanda uygulandığı gibi tarım ekonomisi alanında da uygulanması muhtemel araştırmacılara önerilmektedir.

5. KAYNAKÇA

- Akan Esen, B. (2023).Yapay sinir ağının ana öğeleri, www.akanesen.com, Erişim tarihi: 18.12.2023.
- Akkan, T., Mutlu, T. ve Baş, E. (2022). Forecasting sea surface temperature with feed-forward artificial networks in combating the global climate change: The sample of Rize, Türkiye. *Ege Journal of Fisheries and Aquatic Sciences*, 39 (4), 311-315.
- Alhendi, A., Al-Sumaiti, A.S., Marzband, M., Kumar, R., ve Diab, A.A.Z. (2023). Short-term load and price forecasting using artificial neural network with enhanced markov chain for ISO New England, *Energy Reports*, 9, 4799-4815.
- Arı, A. ve Berberler, M.E. (2017). Yapay sinir ağları ile tahmin ve sınıflandırma problemlerinin çözümü için arayüz tasarımı. *ACTA INFOLICA*, 2(1), 55-73.
- Bayyurt, D. ve Deveci Kocakoç, İ. (2023). Yapay sinir ağları NARX ile Türkiye fındık üretim miktarı tahmini, *Giresun Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 9(1), 15-35.

- Bozođlu, M. ve Kabaođlu, S. (2023). Türkiye'deki fındık kırma ve işleme sanayinin yapısı. *Tarım Ekonomisi Araştırmaları Dergisi (TEAD)*, 9(1), 68-80.
- Can, Ş., ve Gerşil, M. (2018). Manisa pamuk fiyatlarının zaman serisi analizi ve yapay sinir ađı teknikleri ile tahminlenmesi ve tahmin performanslarının karşılaştırılması. *Yönetim ve Ekonomi Dergisi*, 25(3), 1017-1031.
- Caner, M., Gedik, E., & Keçebaş, A. (2011). Investigation on thermal performance calculation of two type solar air collectors using artificial neural network. *Expert Systems with Applications*, 38(3), 1668-1674.
- Cansu, T., Kolemen, E., Karahasan, Ö., Bas, E., ve Egrioglu, E. (2023). A new training algorithm for long short-term memory artificial neural network based on particle swarm optimization. *Granular Computing*, 1-14.
- Çakır Sönmez, F. (2019). *Yapay sinir ađları matlab kodları ve matlab toolbox çözümleri*, Ankara: Nobel.
- Çamođlu, S., Akıncı, M. ve Bozkurt, A. (2015). Fındık sektörü, ekonomik ve yapısal problemleri: Ordu ili değerlendirmesi, *Uluslararası İktisadi ve İdari İncelemeler Dergisi*, 6, 27-48.
- Eđriođlu, E., Aladađ, C.H., Yolcu, U. ve Baş, E. (2015). Recurrent multiplicative neuron model artificial neural network for non-linear time series forecasting. *Neural Processing Letters*, 41(2), 249-258.
- Eđriođlu, E., Yolcu, U. ve Baş, E. (2019). *Yapay sinir ađları öngörü ve tahmin uygulamaları*. Ankara: Nobel.
- Giresun Ticaret Borsası (2023). <https://www.giresuntb.org.tr/Istatistikler>. Erişim Tarihi: 09.08.2023.
- Hazneci, E., Naycı, E. ve Çelikkan, G. (2022). Fındık üretiminde maliyet ve karlılık analizi: Giresun ili örneđi, *Ege Üniversitesi Ziraat Fakültesi Dergisi*, 59(3), 499-511.
- Hüsnüođlu, N. (2018). Türkiye'de fındık üretim miktarı ve fiyat ilişkisi: ARDL sınır testi yaklaşımı. *Sosyal Bilimler Araştırma Dergisi*, 7(4), 24-41.
- Kara, M.A. (2022). *Fındık ekonomisi*. K.Y.Genç, Y.Mamur Işıkçı & M.Özdemir (Edt.) Fındık ekonomisinde kooperatiflerin yeri: dünden bugüne Fiskobirlik, (ss.105-120). Bursa: Ekin.
- Karaman, G. (2022). *Fındık ekonomisi*, K.Y.Genç, Y.Mamur Işıkçı & M.Özdemir(Edt.), İnsan Kaynakları yönetimi perspektifinde Türkiye'de fındık ekonomisi, (s.22-37). Bursa: Ekin.
- Khamis, A., ve Abdullah, S. N. S. B. (2014). forecasting wheat price using back propagation and NARX neural network. *The International Journal Of Engineering And Science*, 3(11), 19-26.
- Khosravi, Z.M.H., Barghinia, S., Ansarimehr, P. (2006). New momentum adjustment technique for Levenberg-Marquardt neural network used in short term load forecasting, in Proc. of 21st International Power System Conference (PSC 2006), Tehran, Iran.

- Kırsahanoğlu, Ş. (2022). *Fındık ekonomisi*. K.Y.Genç, Y.Mamur Işıkçı & M.Özdemir (Edt.), fındık fiyatını etkileyen faktörlerin VAR modeliyle analizi, (s.165-182). Bursa: Ekin.
- Kotan, B. ve Erener, A. (2023). PM10, SO2 hava kirleticilerinin çoklu doğrusal regresyon ve yapay sinir ağları ile sezonsal tahmini, *Geomatik*, 8(2), 163-179.
- Kumari, P., Goswami, V., N, H., ve Pundir, R. S. (2023). Recurrent neural network architecture for forecasting banana prices in Gujarat, India. *Plos one*, 18(6), e0275702.
- Kurani, A., Doshi, P., Vakharia, A., ve Shah, M. (2023). A comprehensive comparative study of artificial neural network (ANN) and support vector machines (SVM) on stock forecasting. *Annals of Data Science*, 10(1), 183-208.
- Öztürk, Ş. , Nas, F. ve İçöz, E. (2008). 24 Ocak kararları, neo-liberal politikalar ve Türkiye tarımı. *Pamukkale Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, (2) , 15-32.
- Saplıoğlu, K. ve Çimen, M. (2010). Yapay sinir ağlarını kullanarak günlük yağış miktarının tahmini. *Mühendislik Bilimleri ve Tasarım Dergisi*, 1(1), 14-21.
- Spaulding, A.D., Tulum, O., Saghaian, S. ve Özertan, G. (2009). Impact of a new price support policy on the Turkish hazelnut industry. *Acta Horti*, 845, 795-800.
- Szoplik, J., ve Muchel, P. (2023). Using an artificial neural network model for natural gas compositions forecasting. *Energy*, 263, 126001.
- Şenol, D. ve Denizhan, B. (2023). Kripto para değerinin yapay sinir ağları ile tahmini, *Endüstri Mühendisliği*, 34(1), 42-69.
- Şeyranlıoğlu, O. (2022). *Fındık ekonomisi*. K.Y.Genç, Y.Mamur Işıkçı & M.Özdemir (Edt.), Fındık fiyatları ile döviz kuru arasındaki saklı ilişkinin analizi, (s.261-278). Bursa: Ekin.
- Özer, O. O., ve Yavuz, G. G. (2014). Box-Jenkins Modeli Yardımıyla Fındık Fiyatının Tahmini. XI. Ulusal Tarım Ekonomisi Kongresi, 3(5).
- Wang, J., Wang, Z., Li, X., ve Zhou, H. (2022). Artificial bee colony-based combination approach to forecasting agricultural commodity prices. *International Journal of Forecasting*, 38, 21–34.
- Wang, Y. (2023) Agricultural Products price prediction based on improved RBF neural network model, *Applied Artificial Intelligence*, 37:1, DOI: 10.1080/08839514.2023.2204600.
- Xu, X., ve Zhang, Y. (2023). Yellow corn wholesale price forecasts via the neural network. *EconomiA*. 24 (1), 44-67. <https://doi.org/10.1108/ECON-05-2022-0026>.
- Yang, J., Haigh, M. S., ve Leatham, D. J. (2001). Agricultural liberalization policy and commodity price volatility: a GARCH application. *Applied Economics Letters*, 8(9), 593-598.
- Yaman Selçi, B. (2021). Türkiye'nin konut satışı değerlerinin yapay sinir ağları ile öngörülmesi. *EKOIST Journal of Econometrics and Statistics*, (35), 19-32.



A Comparative Analysis of Learning Techniques in the Context of Turkish Spam*

Öznur ŞENGEL^{1*}

¹Istanbul Kültür University, TURKEY

Doi: 10.55024/buyasambid.1501609

ARTICLE INFO

Article Type: Research Article

Article history:

Received: 15.06.2024

Received in revised form:

Accepted: 25.06.2024

Available online: 07.07.2024

Keywords:

Turkish SMS Datasets, Spam SMS Detection, SMS Classification, Machine Learning, Deep Learning.

*¹Öznur ŞENGEL

E-mail address:

ozsengelnur@gmail.com

Orcid: 0000-0002-2186-927X

ABSTRACT

Short Message Service (SMS) is a mobile messaging tool used by billions of people to communicate via a mobile phone. However, due to the lack of proper message filtering techniques, this form of communication is vulnerable to unwanted and junk messages. This paper compared SMS spam detection approaches based on machine learning methods such as Adaptive Boosting (AdaBoost), Extreme Gradient Boosting (XGBoost), K-Nearest Neighbors (KNN), Decision Tree (DT), Random Forest (RF), Multinomial Naïve Bayes (MNB), Logistic Regression (LR), and Support Vector Machines (SVM) and deep learning methods such as Convolutional Neural Networks (CNNs), Artificial Neural Networks (ANNs), and Long Short Term Memory (LSTM) in terms of f-score, accuracy, recall, precision, and a confusion matrix constructed for each strategy. The study tested two different preprocessing methods on two different Turkish SMS datasets to evaluate the approaches. The aim of this study is to contribute to the issue of spam filtering in Turkey. The results indicate that the highest accuracy values were achieved with Support Vector Machine (99.03%) using the first preprocessing method and Logistic Regression and Random Forest (98.07%) using the second preprocessing method on the BigTurkishSMS dataset, a combination of the two datasets used. As is the case with the majority of machine learning algorithms, the second preprocessing of the data set yielded superior results in deep learning models. The ANN model achieved the highest accuracy, with a score of 97.41%. The study employed a comparison of machine learning and deep learning techniques on Turkish SMS datasets, which will provide valuable insights for researchers working in this field.

2024 Batman University. All rights reserved.

* "This article is derived from the paper titled 'A Comparative Analysis of Learning Techniques in the Context of Turkish Spam' presented at the International Information Congress 2024 (IIC2024) held at Batman University between May 2-4, 2024."

Türkçe Spam Tespiti Bağlamında Öğrenme Tekniklerinin Karşılaştırmalı Analizi

Öznur ŞENGEL^{1*}

¹İstanbul Kültür Üniversitesi, TÜRKİYE

Doi: 10.55024/buyasambid.1501609

MAKALE BİLGİSİ

ÖZET

Makale Türü: Araştırma Makalesi

Makale Geçmişi:

İlk gönderim tarihi: 15.06.2024

Düzeltilme tarihi:

Kabul tarihi: 25.06.2024

Yayın tarihi: 07.07.2024

Anahatar Kelimeler:

Türkçe SMS Veri Kümeleri, İstenmeyen SMS Tespiti, SMS Sınıflandırma, Makine Öğrenmesi, Derin Öğrenme.

*¹Öznur ŞENGEL

E-mail address:

ozsengelnur@gmail.com

Orcid: 0000-0002-2186-927X

Kısa Mesaj Servisi (SMS), milyarlarca insan tarafından cep telefonu aracılığıyla iletişim kurmak için kullanılan bir mobil mesajlaşma aracıdır. Ancak, uygun mesaj filtreleme tekniklerinin eksikliği nedeniyle, bu iletişim biçimi istenmeyen ve önemsiz mesajlara karşı savunmasızdır. Bu makalede, Adaptif Boosting (AdaBoost), Extreme Gradient Boosting (XGBoost), K-En Yakın Komşular (KNN), Karar Ağacı (DT), Rastgele Orman (RF), Multinominal Naïve Bayes (MNB), Lojistik Regresyon (LR) ve Destek Vektör Makineleri (DVM) gibi makine öğrenimi yöntemleri ile Evrişimli Sinir Ağları (CNN), Yapay Sinir Ağları (YSA) ve Uzun Kısa Süreli Bellek (LSTM) gibi derin öğrenme yöntemlerine dayalı SMS spam tespit yaklaşımları f-skor, doğruluk, duyarlılık, kesinlik ve her bir strateji için oluşturulan karışıklık matrisi açısından karşılaştırılmıştır. Çalışma, yöntemleri değerlendirmek için iki farklı ön işleme yöntemini iki farklı Türkçe SMS veri kümesi üzerinde test etmiştir. Bu çalışmanın amacı, Türkiye'deki spam filtreleme konusuna katkıda bulunmaktır. Sonuçlar, kullanılan iki veri kümesinin bir kombinasyonu olan BigTurkishSMS veri kümesi üzerinde en yüksek doğruluk değerlerinin birinci ön işleme yöntemi kullanılarak Destek Vektör Makinesi (%99,03) ve ikinci ön işleme yöntemi kullanılarak Lojistik Regresyon ve Rastgele Orman (%98,07) ile elde edildiğini göstermektedir. Makine öğrenimi algoritmalarının çoğunda olduğu gibi, veri setinin ikinci ön işleme derin öğrenme modellerinde üstün sonuçlar vermiştir. YSA modeli %97,41'lik bir skorla en yüksek doğruluğu elde etmiştir. Bu çalışma, Türkçe SMS veri kümeleri üzerinde makine öğrenimi ve derin öğrenme tekniklerinin bir karşılaştırmasını yaparak bu alanda çalışan araştırmacılar için değerli bilgiler sağlamaktadır.

2024 Batman Üniversitesi. Her hakkı saklıdır.

1. INTRODUCTION

The United Nations World Population Prospects report (2022) states that the current global population is 8.08 billion, having increased by 74 million people since last year, representing a year-on-year growth of 0.9%. According to the latest data from GSMA Intelligence (Matthew, 2023), 69.4% of the world's population now uses a mobile device, with the global total increasing by 138 million (+2.5%) since the beginning of 2023. At the beginning of 2024, the number of mobile phone users was 5.61 billion (Kemp, 2024). By 2022, over 75% of Turkey's population will own a smartphone, with 68.7 million mobile internet users. At the Cyber Security Weekend - META event, Kaspersky reported a 120% increase in mobile threats in Turkey. The number of smartphone users in Turkey is expected to increase to approximately 88 million by 2028 (Dierks, 2023). It is predicted that the number of mobile phone users will lead to an increase in potential threats via mobile phones.

Short message service (SMS) is a mobile messaging tool that enables the exchange of 160-character text messages among mobile devices. Supported by almost all mobile devices, SMS provides

a quick and easy way to send messages to individuals or organizations for business and personal communication. Many companies that use Short Message Service, one of the main sources of communication, send SMS messages programmatically using Short Message Service Application Programming Interface (SMS API) software systems and send information messages to their customers. The SMS API, which has many advantages such as automation, integration, scalability, personalization, and real-time communication, is being abused by some users. During the day, mobile phone users are unintentionally exposed to unnecessary messages sent in this way.

Short Message Service (SMS) has security weaknesses, including phishing spam messages from cybercriminals. Cybercriminals are continuously enhancing their social engineering techniques to execute more effective phishing attacks. The topics of phishing attacks include traffic fines, bank transfer confirmations, overdue payments, money transfers, online orders, e-tickets, and similar items. Additionally, there are fraudulent messages that appear to originate from government offices, online shops, airlines, and booking services. It is important to remain vigilant and cautious when receiving messages from unknown sources. Criminals may also exploit holidays and major events. While there have been several studies on filtering and classifying spam messages in English (Salman et al., 2024), limited research has been conducted on spam detection in Turkish like Bengali (Al Maruf et al., 2023), and Indonesia (Theodorus et al., 2021). This study aims to fill this gap by classifying Turkish SMS messages as either spam or normal messages.

In this study, only two datasets containing spam messages in Turkish are used. The two datasets were pre-processed in two different ways. Finally, the two Turkish SMS datasets were combined to create a new, comprehensive dataset. In the new dataset, machine learning and deep learning techniques were evaluated for two different preprocessing methods. To compare the results, a confusion matrix was constructed for each technique and evaluated f-score, recall, precision, and accuracy metrics. The main contributions of this study are as follows:

- The performance of machine learning and deep learning techniques used in the literature is compared and evaluated using commonly used metrics.
- The techniques are tested on real Turkish SMS datasets.
- A new Turkish SMS dataset is obtained from two real datasets.
- Two different preprocessing methods are compared on real Turkish SMS datasets.
- Two real Turkish SMS datasets are used to filter spam messages.

In the remainder of this paper, Section 1.1 presents a review of past work in this area. Section 2 provides information about the datasets used, the data preprocessing steps applied, and details of the machine and deep learning techniques discussed in this paper. The test results of the techniques used in the datasets are presented in Section 3. Finally, the paper is discussed and concluded in Section 4.

1.1. Spam SMS Detection

Mobile devices are susceptible to a range of threats, which have increased over time and pose a significant risk to users. SMS attacks are a serious concern. The conventional BOTNET attack causes significant financial losses by surreptitiously sending SMS messages at regular intervals to toll lines that charge higher rates than regular phone lines (Masum and Samet, 2018). The transmission of unsolicited messages, commonly referred to as spam, can result in several adverse consequences. These include the dissemination of unwanted advertisements (Chen et al., 2022), the theft of personal data, the exposure to fraudulent schemes and commercial practices, and the installation of adware and hacking software.

Spam on SMS, WhatsApp, and other messaging services is a common danger that compromises phone security by spreading adware on phone devices. A phone device that sends spam may also be the result of a security breach. Mobile SMS spam is a nuisance to mobile device users and can harm the infrastructure of modern portable electronic devices, like email spam (Özdemir et al., 2013; Ergin and Isik, 2014a; Ergin and Isik, 2014b; Karamollaoglu et al., 2018; Eryılmaz et al., 2020).

The fact that the incoming message comes from a known and trusted source, that it contains information that the user expects and trusts from a previously agreed user, that he/she has received similar messages from the same person or organization before, and that he/she thinks it does not involve any risk, seems to be sufficient for the user to trust incoming messages and open them. If one or more of these criteria are met, the user opens the message and begins to analyze its content. In the meantime, he/she decides, based on experience, whether it is unnecessary or not and whether it is harmful or not. However, this experience can be costly. By generating unnecessary traffic on the mobile phone while the message arrives, it wastes the user's time and leaves them vulnerable to risks that may arise later. It is absolutely necessary to use a filter against such negative situations that may occur. The initial step in addressing the issue of unwanted messages is to implement a filtering system that intercepts messages as they enter and leave the phone. At this stage, the reliability of the previous sender's information, the quarantine list, the control of international spam lists, and the inclusion of some filters created with learning algorithms can be realized. Researchers have employed various learning techniques to filter out unwanted messages. With the richness of the dataset and powerful hardware, spam filtering has been developed using both deep learning models (Karasoy and Ballı, 2022) and machine learning methods (Srinivasarao and Sharaff, 2023).

Theodorus et al. (2021) developed a model that was trained with 4,125 messages and tested with 1,260 messages using a 10-fold cross-validation procedure to categorize spam, raw, and promotional messages in Indonesian dispatches. The results indicate that Multinomial Logistic Regression (MLR) (93.57%), XGBoost (93.52%), SVM (93.38%), and RF (93.62%) were effective classifiers. Arulprakash and Jansi (2021) divided the structure of SMS transmission into two layers and applied SMS spam detection filters and techniques to either the Access Layer or the Service Provider Layer. The accuracy values for grouping raw and spam messages using the NB, SVM, KNN, and DT algorithms were 95.2%, 88%, 85%, and 83%, respectively.

Message filtering is based on natural language processing, and the preprocessing steps used to create the training data set affect the success achieved. There are studies that create training datasets with various preprocessing steps and test them on application platforms such as Weka. Using the Orange 3 application, Özlem (2019) determined that the Neural Networks algorithm (98.4%) is highly accurate for the Turkish SMS dataset, while the NB algorithm (98.4%) is highly accurate for the UCI SMS Spam dataset. Suleiman et al. (2020) proposed a new message detection classifier supported by the H2O platform and employed three classifiers (RF, DL, and NB) and two validation models (3-fold and 10-fold cross-validation). The results indicate that the RF classifier has an accuracy rate of 0.977, making it the most effective. While NB has the lowest accuracy, it performed the best in terms of running time, with a value of 0.6 seconds.

Ertuğrul and Kaya (2016) proposed a new statistical approach that is superior to statistical methods that collect the frequency of occurrence of letters and words, called one-dimensional ternary models (1DTP), for analyzing text messages. The proposed method involves converting the text to UTF8 and comparing each letter with its adjacent letter. Two different feature sets were extracted from the results of these comparisons, and several machine learning techniques were tested on three different datasets. The accuracy rates obtained, 94.10%, 93.318%, and 87.15%, demonstrated the successful applicability of the proposed approach for message filtering feature extraction. The study conducted by Sajedi et al. (2016) aimed to test 15 different algorithms on the most common SMS datasets from 5 different countries available on the internet, and the Dendritic Cell Algorithm (DCA) achieved the highest accuracy rate of 99.95%.

Previous studies in the field of SMS spam detection have utilized a limited set of features, such as word frequency (Almeida et al., 2011; Mathew and Issac, 2011) and TF-IDF (Roy et al., 2020), as well as models like multiple model stack structures (Gupta et al., 2018) and various word embedding techniques (Jain et al., 2019). In this work, we use a Bag of Words (BoW) approach for word embedding, which is a feature extraction method that represents and describes the occurrence of words in a document.

2. METHODOLOGY

2.1. Datasets

The number of publicly available SMS datasets in the literature is limited, particularly for the Turkish language. Therefore, this study utilizes a pre-existing collection of SMS messages in Turkish, which is one of the most widely used suffixed languages worldwide. The first Turkish SMS dataset (Uysal et al., 2013) in the academic literature, named TurkishSMS, consists of 430 normal and 420 spam messages collected from different people. As seen in Figure 1, 50.6% of the messages are normal, and 49.4% are spam messages in the dataset. This dataset is the fundamental Turkish dataset used in articles written about SMS spam classification.




Figure 1. The number of spam and normal data in all used datasets

The TurkishSMSCollection (Karasoy and Ballı, 2022) dataset comprises messages collected from 76 individuals of varying age groups and residing in different cities across Turkey, including Muğla, İstanbul, and Ankara. The age groups represented were 18–24 (26 individuals), 25–39 (37 individuals), and over 40 (13 individuals). As seen in Figure 1, 46.6% of the messages are normal, and 53.4% are spam messages in the dataset.

As the TurkishSMS and TurkishSMSCollection datasets are both balanced, the experimental results obtained from these datasets can be compared fairly. The BigTurkishSMS dataset, which was created by combining the TurkishSMS and TurkishSMSCollection datasets, shows that 47.2% of the messages are normal and 52.8% are spam.

2.2. Data Preprocessing

Electronic messages are textual data and belong to the category of unstructured data. Although electronic messages can be read and viewed by computers, they need to be transformed into structured data sets by going through various processes in order to run machine learning algorithms on them. These procedures are necessary to convert the text from human language to a machine-readable format. The most important of these steps is preprocessing.

In our study, two preprocessing steps are applied. The steps applied in the first preprocessing step are as follows: (1) All letters in the message are converted to lowercase. (2) Abbreviations such as http, www, com, and tr in the text are deleted. (3) Emails in the text are deleted. (4) Numbers and spaces in the text are deleted. (5) Punctuation marks in the text are deleted.

The steps applied in the second preprocessing stage are as follows: (1) All special characters and punctuation marks in the message are deleted. (2) All letters in the message are converted to lowercase. (3) Stop words are deleted. (4) The bag of words was used to identify the 50 most frequently occurring words in the dataset.

2.3. Machine and Deep Learning

Machine learning (ML) is the ability to use the most appropriate algorithm to transform a dataset into a model. Which ML method (supervised, unsupervised, etc.) works best is determined by the type of data being analyzed, the resources available, the nature of the data, and the intended outcome at the conclusion of the process. Deep learning is a sub-branch of machine learning that aims to learn phenomena through a nested hierarchy of concepts, mimicking the neurons of the human brain. In this study, Multinomial Naive Bayes (MNB), Support Vector Machine (SVM), Random Forest (RF), Logistic Regression (LR), K-Nearest Neighbors (KNN), Decision Tree (DT), Adaptive Boosting (AdaBoost), Extreme Gradient Boosting (XGBoost), Convolutional Neural Networks (CNNs), Artificial Neural Networks (ANNs), and Long Short-Term Memory (LSTM) algorithms are applied.

3. EXPERIMENTAL ANALYZES

3.1. Metrics

Nowadays, the accuracy results of many data science models used for classification processes are shared. However, it is not known to what extent the accuracy results reflect reality. Therefore, some techniques have been developed. In order to evaluate the performance of classification models used in machine learning, the confusion matrix, which compares the predictions and actual values of the target attribute, is frequently used.

Table 1. The confusion matrix

		Actual	
		True	False
Predicted	True	TP	FP
	False	FN	TN

The values represented on the confusion matrix (Table 1) are as follows:

- True Positive (TP) refers to cases that indicate a positive state and are predicted as such by the classifier.
- True Negative (TN) samples reflect a negative state and are predicted as such by the classifier.
- False Positives (FP) are samples that indicate a negative condition but are projected as positive by the classifier.
- False Negative (FN) refers to cases that exhibit a positive condition but are predicted as negative by the classifier.

Some values calculated using confusion matrix are used to evaluate classifier performance.

- Accuracy is the ratio of the number of correct predictions made by the classifier to the number of data in the whole data set. Accuracy, which is calculated as shown in Equation (1), measures how often the classifier makes a correct prediction.

$$TP + TN / TP + FN + FP + FN \quad (1)$$

- Precision is obtained by dividing the correct positive predictions made in all classes by the total positive predictions. Precision measures how accurately a prediction is made. Precision is also referred to as a positive predictive value and is calculated as shown in Equation (2).

$$\text{Precision} = TP / (TP + FP) \quad (2)$$

- Recall is determined as the number of accurate positive predictions divided by the total of the number of correct positive and negative predictions by using Equation (3).

$$\text{Recall} = TP / (TP + FN) \quad (3)$$

- The f-score is the harmonic mean of precision and recall, which is the ratio of true positive values. The f-score is a measure of how well a classifier performs. It is frequently used in literature to compare the performance of classifiers and is calculated as shown in Equation (4).

$$\text{F-score} = 2 \times ((\text{Precision} \times \text{Recall}) / (\text{Precision} + \text{Recall})) \quad (4)$$

3.2. Performance Analysis

Table 2 presents the recall, precision, accuracy, and f-score results obtained from training the TurkishSMS dataset with machine learning algorithms after the first and second preprocessing. The highest accuracy value of 95% was achieved by the AdaBoost and SVM algorithms, while KNN had the lowest performance with a value of 74% after first preprocessing. The RF and MNB performed well with the second preprocessing, achieving an accuracy value of 95%. However, DT had the lowest performance, with a value of 87%.

Table 2. The results of the TurkishSMS dataset

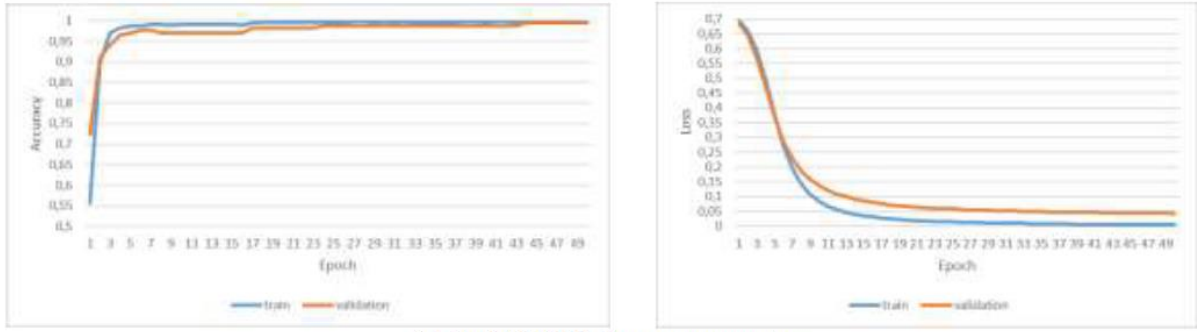
Preprocessing		First				Second			
ML Models	Accuracy	Precision	Recall	F-Score	Accuracy	Precision	Recall	F-Score	
AdaBoost	0.9471	0.9487	0.9471	0.9471	0.9352	0.9353	0.9352	0.9353	
DT	0.8588	0.8762	0.8588	0.8576	0.8705	0.8813	0.8705	0.8699	
KNN	0.7353	0.7385	0.7353	0.7338	0.8941	0.8999	0.8941	0.8938	
LR	0.9412	0.9422	0.9412	0.9412	0.9294	0.9304	0.9294	0.9294	
MNB	0.9412	0.9472	0.9412	0.9409	0.9470	0.9475	0.9470	0.9470	
RF	0.9412	0.9422	0.9412	0.9412	0.9470	0.9475	0.9470	0.9470	
SVM	0.9471	0.9477	0.9471	0.9471	0.9411	0.9413	0.9411	0.9411	
XGBoost	0.9235	0.9266	0.9235	0.9235	0.9352	0.9358	0.9352	0.9353	

Table 3 presents the recall, precision, accuracy, and f-score results obtained from training the TurkishSMSCollection dataset with machine learning algorithms after the first and second preprocessings. After the first preprocessing, the SVM algorithm achieved the highest accuracy rate of 98%, while KNN had the lowest performance with an accuracy rate of 66%. After the second preprocessing, the AdaBoost algorithm achieved the highest accuracy rate of 98%, while MNB had the lowest performance with an accuracy rate of 66%.

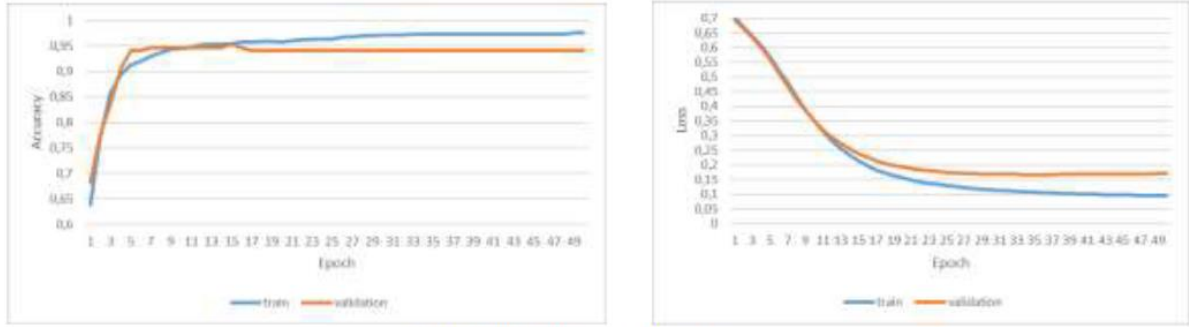
Table 3. The results of the TurkishSMSCollection dataset

Preprocessing		First				Second			
ML Models	Accuracy	Precision	Recall	F-Score	Accuracy	Precision	Recall	F-Score	
AdaBoost	0.9663	0.9664	0.9663	0.9663	0.9842	0.9842	0.9842	0.9842	
DT	0.9158	0.9196	0.9158	0.9161	0.9463	0.9495	0.9463	0.9465	
KNN	0.6635	0.7474	0.6635	0.6101	0.9652	0.9667	0.9652	0.9653	
LR	0.9747	0.9757	0.9747	0.9748	0.9737	0.9740	0.9737	0.9737	
MNB	0.9747	0.9756	0.9747	0.9746	0.6624	0.7640	0.6624	0.6039	
RF	0.9284	0.9322	0.9284	0.9278	0.9821	0.9821	0.9821	0.9821	
SVM	0.9831	0.9837	0.9831	0.9832	0.9821	0.9821	0.9821	0.9821	
XGBoost	0.9674	0.9678	0.9674	0.9674	0.9779	0.9779	0.9779	0.9779	


The accuracy and loss rates of the ANN with the rectified linear unit (ReLU) activation function and the adaptive moment estimation (Adam) optimizer, CNNs with the ReLU activation function and the Adam optimizer, and LSTM networks with the sigmoid activation function and the Adam optimizer are illustrated in Figures 2, 3, and 4, respectively, for both the TurkishSMS and TurkishSMSCollection datasets. All deep learning models are evaluated in a batch size of 32 and 50 epochs.




(a) TurkishSMS, first preprocessing



(b) TurkishSMS, second preprocessing




(c) TurkishSMSCollection, first preprocessing

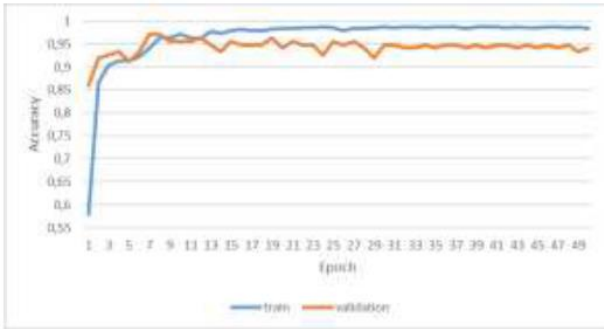


(d) TurkishSMSCollection, second preprocessing


Figure 2. The accuracy and loss rate of ANN



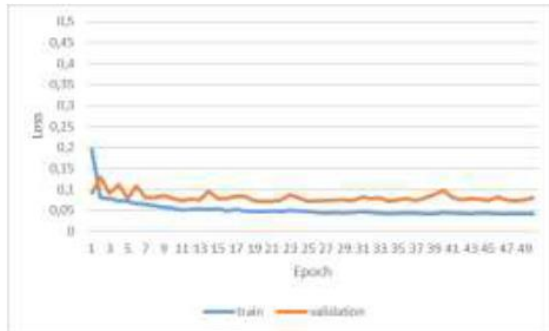

(a) TurkishSMS, first preprocessing



(b) TurkishSMS, second preprocessing




(c) TurkishSMSCollection, first preprocessing





(d) TurkishSMSCollection, second preprocessing



Figure 3. The accuracy and loss rate of CNN




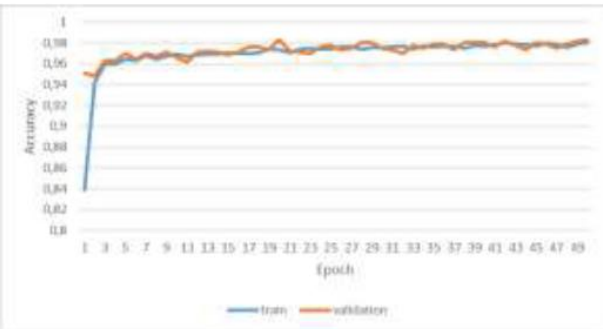
(a) TurkishSMS, first preprocessing



(b) TurkishSMS, second preprocessing



(c) TurkishSMSCollection, first preprocessing



(d) TurkishSMSCollection, second preprocessing

Figure 4. The accuracy and loss rate of LSTM

Cross-validation is a statistical resampling technique used to measure the efficiency of a machine learning model objectively and accurately on unseen data. It provides a more accurate idea of how the model will perform with real-world data. This study employed the non-parametric K-fold crossvalidation method. By dividing the dataset into 'k' equal parts, validation data is created and processed for each part individually. This ensures that each data point is used as validation data at least once, resulting in a more accurate evaluation of the overall performance of the model. In this study, k values of 3, 5, and 10 were tested on the TurkishSMS dataset, and the accuracy values are presented in Table 4.

Table 4. The K-fold cross validation result of algorithms on the TurkishSMS dataset

Algorithm	K = 3	K = 5	K = 10
AdaBoost	0.9561	0.9589	0.9545
KNN	0.5888	0.6426	0.6981
LR	0.9656	0.9716	0.9722
DT	0.9156	0.9147	0.9172
MNB	0.9548	0.9545	0.9676
RF	0.9672	0.9603	0.9726
SVM	0.9661	0.9710	0.9770
XGBoost	0.9406	0.9445	0.9483

As the best results were consistently achieved with a value of 10 for k, this value was selected for all algorithms. Table 5 displays the accuracy values for all algorithms resulting from two different preprocessing methods applied to the TurkishSMS, TurkishSMSCollection, and the BigTurkishSMS datasets, when k was set to 10. The TurkishSMS dataset yielded the highest value of 99.41% with ANN after the first preprocessing. The second preprocessing resulted in the highest value of 96.60% with SVM. Similarly, the SVM algorithm produced the highest score of 99.24% for the TurkishSMSCollection dataset after the first preprocessing, while the second preprocessing resulted in the highest value of 98.85% with RF.

Table 5. The accuracy results of the algorithms with 10-fold cross-validation

Dataset	TurkishSMS		TurkishSMSCollection		BigTurkishSMS	
	First	Second	First	Second	First	Second
AdaBoost	95.45%	94.64%	97.87%	98.48%	97.85%	97.88%
DT	91.72%	91.27%	95.73%	97.79%	94.77%	96.20%
KNN	69.81%	94.36%	64.59%	97.90%	69.42%	97.67%
LR	97.22%	96.06%	98.92%	98.78%	98.88%	98.07%
MNB	96.76%	94.72%	98.74%	65.01%	97.86%	65.06%
RF	97.26%	95.37%	89.77%	98.85%	89.72%	98.07%
SVM	97.70%	96.60%	99.24%	98.63%	99.03%	97.44%
XGBoost	94.83%	95.21%	98.02%	98.68%	97.60%	98.01%
ANN	99.41%	94.12%	96.32%	98.53%	95.63%	97.41%
CNN	95.88%	94.12%	95.79%	98.32%	95.72%	97.15%
LSTM	90.00%	92.94%	97.69%	97.79%	59.87%	96.34%

The accuracy values for all algorithms resulting from two different preprocessing methods applied to the BigTurkishSMS datasets, as seen in Table 5, with 10-fold cross-validation. The BigTurkishSMS dataset resulted in the highest accuracy of 99.03% using SVM after the first preprocessing and the highest accuracy of 98.07% using LR and RF after the second preprocessing.

The study analyzed the SMS datasets and found that the second preprocessing method resulted in eight learning models with better results for the TurkishSMSCollection and BigTurkishSMS datasets. Similarly, for the TurkishSMS dataset, the first preprocessing method resulted in eight learning models with better results. The study also observed that the second preprocessing method had better accuracy in detecting spam messages as the dataset size increased. In fact, the BigTurkishSMS dataset showed improved performance for RF, DT, AdaBoost, ANN, and CNN learning models, which did not perform well on the TurkishSMS dataset with the second preprocessing. The accuracy of spam message detection was improved by 1.0% to 3.5% with the second preprocessing.

The evaluation of the learning algorithms resulted in the following outcomes:

- In the TurkishSMS dataset, the second preprocessing outperformed the KNN, XGBoost, and LSTM models by 24.5%, 0.38%, and 2.94%, respectively. Meanwhile, the first preprocessing outperformed RF, LR, MNB, SVM, DT, AdaBoost, ANN, and CNN by 1.89%, 1.16%, 2.04%, 1.10%, 0.45%, 0.81%, 5.29%, and 1.76%, respectively.
- The second preprocessing method yielded better results in the TurkishSMSCollection dataset, with increases of 33.31%, 9.08%, 2.06%, 0.61%, 0.66%, 2.21%, 2.53%, and 0.10% in KNN, RF, DT, AdaBoost, XGBoost, ANN, CNN, and LSTM models, respectively. Conversely, the first preprocessing method resulted in better performance in LR, MNB, and SVM models, with increases of 0.14%, 33.73%, and 0.61%, respectively.
- The BigTurkishSMS dataset showed that the second preprocessing method resulted in better performance for KNN, RF, DT, AdaBoost, XGBoost, ANN, CNN, and LSTM models with increases of 28.25%, 8.35%, 1.43%, 0.03%, 0.41%, 1.78%, 1.43%, and 36.47%, respectively. On the other hand, the first preprocessing method resulted in better performance for LR, MNB, and SVM models with increases of 0.81%, 32.80%, and 1.59%, respectively.
- In the second preprocessing, KNN and LSTM outperformed their performance in the first preprocessing. Conversely, MNB performed better in the first preprocess than in the second preprocessing.

4. DISCUSSION AND CONCLUSIONS

Short message service (SMS) is a widely used form of communication with mobile devices. However, it is also a common target for social engineering scams, particularly in promotional messages from banks, betting companies, vacation providers, and similar businesses. Phishing attacks, which aim to obtain passwords, credentials, or similar data by sending fake messages to the target person, such as gifts, discounts, or similar tempting messages, are increasing day by day. To protect against such attacks, it is important to ignore messages containing unusual and untrusted URLs, requests for verification of critical personal information such as card details or passwords, errors in the language used in the message, and misspellings. Education and awareness, as well as the development of spam filtering structures, are crucial in preventing phishing attacks.

Currently, numerous studies have been conducted on spam mail and comment filtering using various learning models. Although there have been many studies on spam filtering, particularly with English real datasets, there have been fewer studies conducted with Turkish real datasets. This study utilized two significant datasets, TurkishSMS and TurkishSMSCollection, which exclusively contain Turkish spam messages. The study aimed to contribute to the field of Turkish spam filtering. By merging both datasets, a new dataset is created, named BigTurkishSMS. The datasets undergo preprocessing based on specific criteria before being used to detect spam messages. Two different preprocessing steps were used in this study. The resulting datasets were trained and tested using eight machine learning and three deep learning models. The f-score, recall, precision, and accuracy values were calculated to compare the results obtained from each model. The study aimed to provide preliminary information for future new detection models on Turkish spam. In this study, we compared the performance of eleven algorithms on three datasets using two preprocessing methods. We tested the accuracy rates of these models using 10-fold cross-validation. The highest accuracy rate of 99.41% was achieved with ANN when the first preprocessing method was used, while the highest accuracy rate of 98.85% was achieved with RF when the second preprocessing method was used. When the dataset resulting from the second preprocessing was trained with deep learning models, it increased for all datasets. Additionally, the second preprocessing resulted in an average increase in the accuracy rate of between 1.0% and 3.5% for all datasets.

According to a report by The International Business Machines Corporation (IBM), our country ranks 6th in terms of exposure to cyber-attacks. The report indicates that, following the pandemic, there was a 217 percent increase in phishing attacks and a 220 percent increase in spam attacks. This

study aimed to create more effective Turkish spam filtering models to combat phishing attacks using simple SMS. The study highlighted the importance of message filtering with learning algorithms in combating SMS phishing attacks and aimed to raise awareness on this issue. To strengthen the models used in this study, it is suggested that more recent examples of spam messages be included. Future studies could focus on developing deep learning models using new Turkish datasets.

5. REFERENCES

- Al Maruf, A., Al Numan, A., Haque, M. M., Jidney, T. T., & Aung, Z. (2023, April). Ensemble approach to classify spam SMS from Bengali text. In *International Conference on Advances in Computing and Data Sciences* (pp. 440-453). Cham: Springer Nature Switzerland.
- Almeida, T. A., Hidalgo, J. M. G., & Yamakami, A. (2011, September). Contributions to the study of SMS spam filtering: new collection and results. In *Proceedings of the 11th ACM symposium on Document engineering* (pp. 259-262).
- Arulprakash, M. (2021). Eshort message service spam detection and filtering using machine learning approach. *Turkish Journal of Computer and Mathematics Education (TURCOMAT)*, 12(9), 721- 727.
- Chen, Y. H., Huang, L., Wang, C. D., Fu, M., Huang, S. Q., Huang, J., Tan & Yan, C. (2022). Adversarial Spam Detector with Character Similarity Network. *IEEE Transactions on Industrial Informatics*, 19(3), 2541-2551. doi: 10.1109/TII.2022.3177726
- Dierks, Z., (2023). Forecast of the smartphone user penetration rate in Turkey 2018-2024. Tech. rep., Statista.
- Ergin, S., & Isik, S. (2014a, June). The assessment of feature selection methods on agglutinative language for spam email detection: A special case for Turkish. In *2014 IEEE International Symposium on Innovations in Intelligent Systems and Applications (INISTA) Proceedings* (pp. 122-125). IEEE.
- Ergin, S., & Isik, S. (2014b, June). The investigation on the effect of feature vector dimension for spam email detection with a new framework. In *2014 9th Iberian Conference on Information Systems and Technologies (CISTI)* (pp. 1-4). IEEE.
- Eryılmaz, E. E., Şahin, D. Ö., & Kılıç, E. (2020, June). Filtering Turkish spam using LSTM from deep learning techniques. In *2020 8th International Symposium on Digital Forensics and Security (ISDFS)* (pp. 1-6). IEEE.
- Gupta, M., Bakliwal, A., Agarwal, S., & Mehndiratta, P. (2018, August). A comparative study of spam SMS detection using machine learning classifiers. In *2018 eleventh international conference on contemporary computing (IC3)* (pp. 1-7). IEEE.
- Jain, G., Sharma, M., & Agarwal, B. (2019). Optimizing semantic LSTM for spam detection. *International Journal of Information Technology*, 11, 239-250. doi: 10.1007/s41870-018-0157-5
- Karamollaoglu, H., Dogru, İ. A., & Dorterler, M. (2018, October). Detection of Spam E-mails with Machine Learning Methods. In *2018 Innovations in Intelligent Systems and Applications Conference (ASYU)* (pp. 1-5). IEEE.
- Karasoy, O., & Ballı, S. (2022). Spam SMS detection for Turkish language with deep text analysis and deep learning methods. *Arabian Journal for Science and Engineering*, 47(8), 9361-9377. doi: 10.1007/s13369-021-06187-1
- Kaya, Y., & Ertuğrul, Ö. F. (2016). A novel feature extraction approach in SMS spam filtering for mobile communication: one-dimensional ternary patterns. *Security and communication networks*, 9(17), 4680-4690. doi: 10.1002/sec.1660
- Kemp, S., (2024). Digital 2024 global overview report. Tech. rep., Meltwater and We Are Social.
- Masum, E., & Samet, R. (2018). Mobil BOTNET ile DDOS Saldırısı. *Bilişim Teknolojileri Dergisi*, 11(2), 111-121. doi: 10.17671/gazibtd.306612

- Mathew, K., & Issac, B. (2011, December). Intelligent spam classification for mobile text message. In Proceedings of 2011 International Conference on Computer Science and Network Technology (Vol. 1, pp. 101-105). IEEE.
- Matthew Shanahan, K.B., (2023). The state of mobile internet connectivity report. Tech. rep., GSMA Intelligence.
- Örnek, Ö. (2019). Orange 3 ile Türkçe ve İngilizce SMS Mesajlarında Spam Tespiti. Eskişehir Türk Dünyası Uygulama ve Araştırma Merkezi Bilişim Dergisi, 1(1), 1-4.
- Özdemir, C., Ataş, M., & Özer, A. B. (2013, April). Classification of Turkish spam e-mails with artificial immune system. In 2013 21st Signal Processing and Communications Applications Conference (SIU) (pp. 1-4). IEEE.
- Roy, P. K., Singh, J. P., & Banerjee, S. (2020). Deep learning to filter SMS Spam. Future Generation Computer Systems, 102, 524-533. doi: 10.1016/j.future.2019.09.001
- Sajedi, H., Parast, G. Z., & Akbari, F. (2016). SMS spam filtering using machine learning techniques: A survey. Machine Learning Research, 1(1), 1-14. doi: 10.11648/j.ml.20160101.11
- Salman, M., Ikram, M., & Kaafar, M. A. (2024). Investigating Evasive Techniques in SMS Spam Filtering: A Comparative Analysis of Machine Learning Models. IEEE Access, 12, 24306–24324. doi: 10.1109/ACCESS.2024.3364671
- Suleiman, D., Al-Naymat, G., & Itriq, M. (2020). Deep SMS Spam Detection using H2O Platform. International Journal of Advanced Trends in Computer Science and Engineering, 9(5), 9179–9188. doi: 10.30534/ijatcse/2020/326952020
- Theodorus, A., Prasetyo, T. K., Hartono, R., & Suhartono, D. (2021, April). Short message service (SMS) spam filtering using machine learning in Bahasa Indonesia. In 2021 3rd East Indonesia Conference on Computer and Information Technology (EIconCIT) (pp. 199-203). IEEE.
- United Nations Department of Economic and Social Affairs, Population Division (2022). World Population Prospects 2022: Summary of Results. UN DESA/POP/2022/TR/NO. 3.
- Uysal, A. K., Gunal, S., Ergin, S., & Gunal, E. S. (2013). The impact of feature extraction and selection on SMS spam filtering. Elektronika ir Elektrotechnika, 19(5), 67-72. doi: 10.5755/j01.eee.19.5.1829



Decision Tree-Based Direction Detection Using IMU Data in Autonomous*

İrfan KILIÇ^{1*}, Nafiye Nur APAYDIN², Muhammet APAYDIN³, Orhan YAMAN⁴

¹Firat University, TURKEY

²Firat University, TURKEY

³Firat University, TURKEY

⁴Firat University, TURKEY

Doi: 10.55024/buyasambid.1501521

ARTICLE INFO

Article Type: Research Article

Article history:

Received: 15.06.2024

Received in revised form:

Accepted: 26.06.2024

Available online: 07.07.2024

Keywords:

Direction Detection, Decision Tree Algorithm, Inertial Measurement Unit (IMU), GPS Data.

*İrfan KILIÇ

E-mail address:

irfankilic@firat.edu.tr

Orcid: 0000-0001-5079-2825

²Nafiye Nur APAYDIN

E-mail address:

200509008@firat.edu.tr

Orcid: 0009-0006-3438-7401

³Muhammet APAYDIN

E-mail address:

200503003@firat.edu.tr

Orcid: 0009-0002-6880-8113

⁴Orhan YAMAN

E-mail address:

orhanyaman@firat.edu.tr

Orcid: 0000-0001-9623-2284

ABSTRACT

Location detection plays a crucial role in various applications. In this study, a machine learning (ML) method using inertial measurement unit (IMU) data was developed to determine direction with the Global Positioning System (GPS). In this study, an electronic board was designed using an Arduino Mega, Altimu-10 IMU sensor, GPS module, and SD card module. This electronic board was placed on a car to create a new dataset. This dataset consists of 1952x11 data. The dataset was obtained using accelerometer (x, y, z), gyroscope (x, y, z), compass (x, y, z), and GPS sensor data. The Decision Tree Algorithm was proposed for direction determination in this study. The angles between each position and the previous position were calculated using the latitude and longitude values obtained from the collected data. Then, the data were divided into 4 classes: North, East, South, and West, based on specific angle ranges. Finally, a direction detection model was developed using IMU data in the proposed method, achieving an accuracy of approximately 82.11%.

2024 Batman University. All rights reserved.

* "This article is derived from the paper titled 'Decision Tree-Based Direction Detection Using IMU Data in Autonomous,' presented at the International Information Congress 2024 (IIC2024) held at Batman University between May 2-4, 2024."

Otonom Robotlarda IMU Verilerini Kullanan Karar Ağacı Tabanlı Yön Tespiti

İrfan KILIÇ^{1*}, Nafiye Nur APAYDIN², Muhammet APAYDIN³, Orhan YAMAN⁴

¹Fırat Üniversitesi, TÜRKİYE

²Fırat Üniversitesi, TÜRKİYE

³Fırat Üniversitesi, TÜRKİYE

⁴Fırat Üniversitesi, TÜRKİYE

Doi: 10.55024/buyasambid.1501521

MAKALE BİLGİSİ

ÖZET

Makale Türü: Araştırma Makalesi

Makale Geçmişi:

İlk gönderim tarihi: 15.06.2024

Düzeltilme tarihi:

Kabul tarihi: 26.06.2024

Yayın tarihi: 07.07.2024

Anahatar Kelimeler:

Yön Tespiti, Karar Ağacı Algoritması, IMU, GPS Verileri.

¹İrfan KILIÇ

E-mail address:

irfankilic@firat.edu.tr

Orcid: 0000-0001-5079-2825

²Nafiye Nur APAYDIN

E-mail address:

200509008@firat.edu.tr

Orcid: 0009-0006-3438-7401

³Muhammet APAYDIN

E-mail address:

200503003@firat.edu.tr

Orcid: 0009-0002-6880-8113

⁴Orhan YAMAN

E-mail address:

orhanyaman@firat.edu.tr

Orcid: 0000-0001-9623-2284

Konum tespiti, birçok uygulama alanında önemli bir role sahiptir. Bu çalışmada, yerel konumlandırma sistemi (GPS) ile yön tespiti yapmak için atalet ölçü birimi (IMU) verilerinin kullanıldığı bir makine öğrenmesi (ML) yöntemi geliştirilmiştir. Bu çalışma kapsamında, Arduino Mega, Altimu-10 IMU sensör, GPS modülü ve SD kart modülü kullanılarak bir elektronik kart tasarlanmıştır. Bu elektronik kart, bir otomobil üzerine yerleştirilerek yeni bir veri seti oluşturulmuştur. Bu veri seti 1952x11 veriden oluşmaktadır. Bu veri seti ivmeölçer (x, y, z), jiroskop (x, y, z), pusula (x, y, z) ve GPS sensöründen alınan veriler yardımıyla elde edilmiştir. Bu çalışmada yön tespiti için Karar Ağacı Algoritması önerilmiştir. Elde edilen verilerden Enlem ve Boylam değerleriyle her konumun bir önceki konum ile açısı hesaplanmıştır. Daha sonra belirli bir açı aralığına göre Kuzey, Doğu, Güney ve Batı olmak üzere veriler 4 sınıfa ayrılmıştır. En sonunda da IMU verileri önerilen yöntemde kullanılarak yön tespit modeli geliştirilmiş ve yaklaşık %82,11 doğruluk(accuracy) elde edilmiştir.

2024 Batman Üniversitesi. Her hakkı saklıdır.

1. INTRODUCTION

Location information has always had an important place for people. Because it makes people's daily lives easier and allows them to interact with their environment. Location determination studies start with maps and today extend to GPS systems. With the development of technology and the increasing importance of location information, studies in this field are increasing day by day. Nowadays, the importance of location information has increased with elements such as smart systems, vehicles, and robots that act instead of people, in order to make people's lives easier and reduce risks. Therefore, in unmanned systems, the starting position must be known to move from one place to another. GPS (Global Positioning System) has been a major advancement in being able to share location information. However, location determination should be possible without GPS technology. Because GPS signals may be weak in some places or may not be usable in cases of international disputes since GPS is a satellite-based radio navigation system managed by the US Space Force. This situation poses a significant problem. In order to prevent these problems, methods such as IMU (Inertial Measurement Unit), ZigBee, Bluetooth, Beacon, Wi-Fi, LIDAR, and RFID (Radio frequency identification) have been developed to solve location information problems in robots (Girgensohn, Patel, and Biehl 2024; Khanh et al. 2020; Regus, Talar, and Labudzki 2019). These methods have advantages and disadvantages. ZigBee, Bluetooth, Beacon, Wi-Fi, LIDAR, and RFID systems work

depending on the environment (Kaya 2018). These systems, which can detect location depending on the environment, do not work compatible with different environments. At the same time, it is difficult to achieve high performance since ZigBee, Bluetooth, Beacon, Wi-Fi, and RFID systems use wireless technologies.

In the literature, studies are carried out to obtain location information with many technologies without using GPS data. In particular, location information acquisition studies are carried out using methods such as ZigBee, Bluetooth, Beacon, Wi-Fi, LIDAR, and RFID. Literature studies that are similar to the subject of our study are summarized in Table 1.

Table 1. Literature studies that are similar to the subject of the study

References	Year	Purpose of Study
Kaya et al. (Kaya 2018)	2018	In this thesis study; An indoor positioning system is proposed using the received signal strength and acceleration measurements.
Lopez et al. (Álvarez López, de Cos Gómez, and Las-Heras Andrés 2017)	2017	In this study; Two antennas were used and RSSI values were collected by placing RFID tags. Internal location determination was made using the collected data.
Oguntala et al. (Oguntala et al. 2018)	2018	In this study; Real-time location detection technologies for IoT applications are described.
Karabey (Karabey 2015)	2015	In this thesis study; Indoor positioning methods have been proposed using the Wi-Fi-based fingerprint method. In addition to wireless-based indoor positioning methods, multi-sensor-based methods based on inertial data have also been developed.
Xing et al. (Xing et al. 2021)	2021	In this study; A multi-sensor fusion self-positioning system of a miniature underwater robot in structured and GPS-blocked environments is proposed.
Kepper ve diğ. (Iv, Claus, and Kinsey 2019)	2019	In this study; An IMU and acoustic range measurement-based navigation method has been proposed for underwater vehicles.
Poulose et al. (Poulose, Eyobu, and Han 2019)	2019	In this study; Indoor location estimation algorithms have been developed using IMU data obtained from a smartphone.
Farooq et al. (Farooq and Kamal 2019)	2019	In this study, sensor data on smartphones was used for indoor location detection and tracking. The data collected from the sensors was recorded in the database. Its location on the map was determined using the three-axis data and elevation data obtained from the acceleration sensor.
Sanchez et al. (Hernández Sánchez, Fernández Pozo, and Hernández Gómez 2019)	2019	In this study; A deep neural network model is proposed for driver identification using accelerometer signals from smartphones.
Du et al. (Du et al. 2020)	2020	In this study, real-time onboard 3D attitude estimation of unmanned aerial vehicles in multi-environments using multi-sensor data fusion was developed.
Shu et al. (Shu, Chen, and Zhang 2022)	2022	In this study; Efficient image-based indoor positioning was performed with the help of MEMS on the mobile device.
Y. Li et al. (Li et al. 2022)	2022	In this study; A spatiotemporal calibration algorithm has been developed for the IMU-LiDAR navigation system based on the similarity of motion trajectories.
Mahdi et al. (Mahdi et al. 2022)	2022	In this study; A machine learning approach is presented for an advanced inertial navigation system solution.
R. Sun et al. (R. Sun et al. 2022)	2022	In this study; Pseudo-orange error estimation has been made for adaptive tightly coupled GNSS/IMU navigation in urban areas.
Y. Sun et al. (Y. Sun et al. 2022)	2022	In this study; A motion model supported GNSS/MEMS-IMU integrated navigation system has been developed for the land vehicle.
Greff et al. (Greff et al. 2017)	2017	In this study; an LSTM-based odometry design was implemented.
Chen et al. (Chen et al. 2018)	2018	In this study; an LSTM-based odometry design was implemented.

2018)		
Wagstaff et al. (Wagstaff and Kelly 2018)	2018	In this study; A zero-speed EKF model is proposed that updates measurements using EKF at a specific time when the LSTM model detects a zero-speed condition.
S. Wang et al. (Wang et al. 2017)	2017	In this study; the LSTM model was developed to extract distinctive features from images to learn the motion between two consecutive frames.

Within the scope of this study, it is aimed to develop a machine-learning method that uses inertial data for location determination in autonomous vehicles. The main focus of our work is; The aim is to produce an electronic system that can be used for location detection, to collect the data set by fixing this system to the car, and to develop and verify the machine learning method. This study contributes to direction determination. In Table 2 below, the tools used in some studies for location determination in the literature are given.

Table 2. Tools used in IMU-Based studies for Location Detection in the literature

Reference, Year	Jiroskop	Accelerometer	Compass
Kaya et al. (Kaya 2018), 2018	-	+	-
Xing et al. (Xing et al. 2021), 2021	-	+	-
(Hernández Sánchez et al. 2019), 2019	-	+	-
Shu et al. (Shu et al. 2022), 2022	+	+	+
Kopar et al.(Kopar 2020), 2020	+	+	-
Y. S. Li et al. (Li and Ning 2018), 2018	+	+	-
Orhan YAMAN et al. (Yaman, Tasar, and Yakut 2022), 2022	+	+	+
D. Wang et al. (Wang et al. 2019), 2019	+	+	+
Poulose et al. (Poulose and Han 2019), 2019	+	+	+
Prikhodko et al. (Prikhodko et al. 2018), 2018	+	-	+
Şahin et al. (Şahin and Ulaş 2023), 2022	+	+	-
Okudan et al. (Okudan 2019),	+	+	+
Gögüş et al. (Gögüş 2022), 2022	-	+	-
Ata et al. (Ata 2022), 2022	-	+	-
Our Study, 2024	+	+	+

In Table 2, the tools (gyroscope, accelerometer, and compass) used in some studies for position determination in the literature are given. As seen in the table, in some studies only the gyroscope sensor was used, in some studies the accelerometer sensor or some compass sensors were used. In our study, an electronic card system was created using all of these tools, and IMU and GPS data were obtained. The main purpose of the study is to develop a machine learning classification method that can produce real-time direction data (North, East, South, West) as output by using the IMU and GPS sensor data obtained for direction determination. Thanks to this machine learning method, it can be determined in advance which direction to go depending on the location.

2. MATERIALS AND METHODS

In this study, a system that uses inertial measurement units to determine the location of autonomous vehicles has been developed. In this embedded system, an Altumu-10 sensor was used to collect data such as GPS, Gyro, Accelerometer, and Compass (Magnetometer). Arduino Mega development card was used to read the data from these sensors and log them to the memory card. The architecture of the embedded system developed in this study to collect IMU and GPS data is shown in Figure 1 (Yaman et al. 2022).




Figure 1. The architecture of the embedded system developed for collecting IMU and GPS data in this study

Data such as location, altitude, Gyro, accelerometer, and compass were collected from the sensors given in Figure 1. Sample data collected with the developed embedded system is shown in Figure 2.




Figure 2. Sample data collected with the developed embedded system

The embedded system developed in this study is fixed on the automobile. The car traveled approximately 50 km/h between 20 km/h and 100 km/h. During the data set collection phase, the movement of the car is shown on the map in Figure 3.

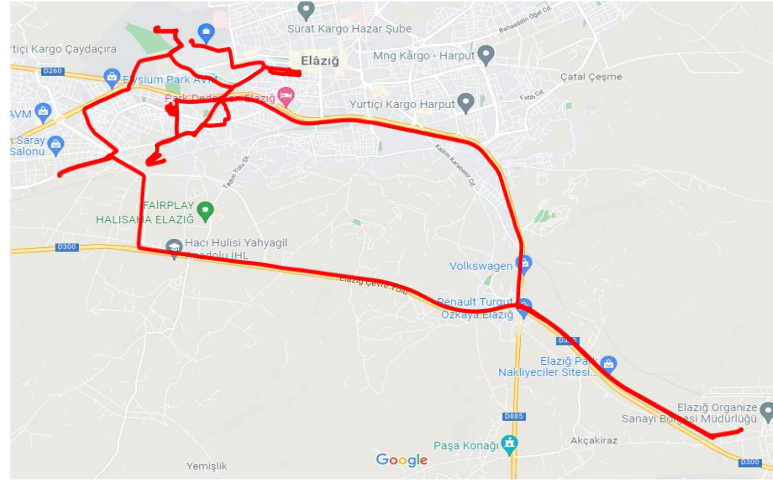


Figure 3. Movement of the car for data set collection

Figure 3 shows the car's route on the map. 1952 samples were collected during the car's journey. Each sample contains accelerometer (x,y,z), gyro (x,y,z), compass (x,y,z), latitude and longitude data. The size of the collected data set is 1952x11.

2.1. Method

The decision Tree Classification Method was applied to this data set. Thanks to the developed methods, it was determined in which position and in which direction the autonomous system was directed by looking at the IMU data. The flow chart of the proposed method is given in Figure 4.

As can be seen in Figure 4, the proposed method consists of six basic steps. First of all, accelerometer (x,y,z), gyro (x,y,z), compass (x,y,z), latitude and longitude data were collected on the developed embedded system. The collected data was parsed and converted into a usable form for classification. For this transformation, Latitude and Longitude values and angle values for each location with the previous location were obtained. Then, the angle values obtained were divided into 4 classes: North, East, South, and West, according to the ranges given in Table 3. Additionally, since the first position is considered the starting position, it does not have an angle value. For this reason, it was not used for the classification process and the number of data decreased to 1951.

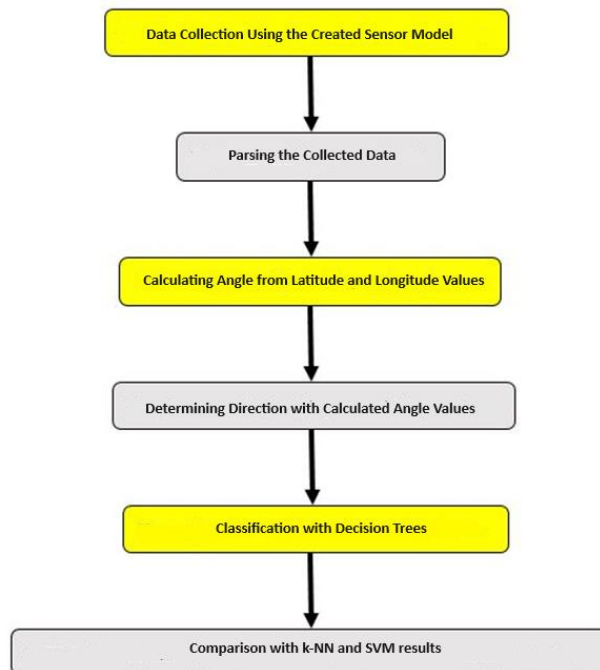


Figure 4. Flow chart of the proposed method

Table 3. Direction determination according to angle range

Class No	Direction	Angle Range
1	North	direction_angle >= 315 < 45 direction_angle
2	East	direction_angle >= 45 && direction_angle < 135
3	South	direction_angle >= 135 && direction_angle < 225
4	West	direction_angle >= 225 && direction_angle < 315

After the classes were determined, the results were compared using the Decision Tree Classification Method, KNN, and SVM methods to predict the direction classes using accelerometer (x,y,z), gyro (x,y,z), compass (x,y,z) values.

The k-Nearest Neighbor (KNN) algorithm is a supervised machine learning algorithm. In this method, the assumption that similar things are close to each other is valid. It is used for classification and regression (Deng et al. 2016; Naviani 2018; Ulgen 2024).

Steps of k-NN algorithm:

- First, the k parameter is determined. This parameter is the number of nearest neighbors to a given point. For example: let k = 2. In this case, classification will be made according to the 2 closest neighbors.
- The distance of the new data to be added to the data set, relative to the existing data, is calculated one by one with the help of relevant distance functions.
- The k nearest neighbors from the relevant distances are considered. It is assigned to k neighbors or classes of neighbors according to their attribute values.
- The selected class is considered as the class of the observation value expected to be predicted. So the new data is labeled.
- Support Vector Machine (SVM) is a machine learning algorithm used in classification and regression problems. The main goal of SVM is to find a hyperplane that best separates samples belonging to different classes (Baygin, Baygin, and Karakose 2019).

Steps of SVM Algorithm:

- Data collection and preprocessing: Before starting the training of the SVM, the data set to be classified must be collected and preprocessing steps must be carried out. In this step, the data set is examined, missing data is filled in if necessary, outliers are identified, and features are normalized.
- Feature selection: In order for SVM to work on the data set, appropriate features must be selected. In this step, features that are important and improve classification performance are identified.
- Creating feature vectors: Each data sample should be represented as a vector of features. Feature vectors are created for each example of the data set to be classified.
- Determination of training data and labels: For training the SVM, it is necessary to determine the input data and the labels showing which class this data belongs to. The training dataset consists of feature vectors and corresponding class labels.
- Training of the SVM model: The SVM model is trained using the training data and labels. SVM is optimized to find a hyperplane that separates different classes in the data set. In this step, the parameters of the SVM are determined and the training algorithm is run.
- Validation of the model: Validation data is used to evaluate the performance of the trained SVM model. The accuracy of the model is evaluated using the error matrix or other performance metrics.
- Tuning and optimization of the model: Parameters and hyperparameters of the SVM can be tuned to improve the performance of the model. In this step, different parameter values are tested and the model is optimized.

• **Classification of new examples:** The trained SVM model can be used to predict classes of new, unclassified examples. In this step, feature vectors of new samples are created and classification is made using the SVM model.

SVM is an effective algorithm used in classification problems, and the above steps generally reflect the application process of SVM.

A decision tree uses features (independent variables) in the dataset to predict a target variable (Rajesh, Sai Vardhan, and Sujihelen 2020).

Steps of the Decision Trees Method:

• Before starting the decision tree analysis, it is necessary to determine the first node, the root node. The root node is the first point from which the target variable will be predicted.

• The decision tree makes a split on one feature at each node. A partition divides the data set into subsets and these subsets are aimed to be homogeneous. The best split is the one that provides the greatest information gain.

• Once the best split is selected, the data set is divided into subsets based on this split. Each subset creates a child node.

• Once the child nodes are created, the same steps are repeated for each subset. On each subset, a split is selected, the split is applied, and new child nodes are created.

• A stopping condition should be set to control the size and depth of the decision tree. When the stopping condition is met, the tree-creation process ends.

• When the above steps are repeated, the decision tree is completed and a hierarchical structure is created. This tree is used to predict the target variable based on the values of features in the dataset.

• Once the tree is created, pruning can be applied to remove unnecessary branches or simplify the tree. Pruning helps prevent the tree from overfitting and increases its generalization ability.

3. EXPERIMENT RESULTS AND DISCUSSION

In this study, MATLAB Classification Learner Toolbox was used to obtain classification results. KNN, SVM, and Decision Tree methods were preferred for classification. 10-fold cross-validation was used for validation in each method. The confusion matrix results obtained for the methods used are presented in Figure 5.

		Predicted Class						Predicted Class						Predicted Class			
		0	1	2	3			0	1	2	3			0	1	2	3
True Class	0	265	43	36	29	True Class	0	256	24	52	41	True Class	0	281	24	40	28
	1	27	479	32	5		1	23	478	36	6		1	28	465	42	8
	2	52	33	414	43		2	47	39	418	38		2	62	39	411	30
	3	21	6	43	423		3	16	5	46	426		3	27	6	58	402
		a)						b)						c)			

Figure 5. Confusion matrix a) Decision Trees b) k-NN c) SVM

When the results calculated for the three methods are examined in Fig. 5, it can be seen that the best direction prediction results are generally calculated in the Decision Tree Algorithm. Class-based accuracy rates of the proposed method are given in Figure 6.




Figure 6. Class-based accuracy rates

The proposed method was run for 1000 iterations and Accuracy, Precision, Recall, Geometric Mean, and F1-Score results was calculated. The calculated results are shown in Table 4.

Table 4. 1000 iteration performance values of the proposed method

		Accuracy (%)	Precision (%)	Recall (%)	Geometric Mean (%)	F1-Score (%)
Decision Trees	Max	82.11	81.47	81.33	81.04	81.40
	Min	79.80	79.12	79.16	78.90	79.14
	Mean	81.06	80.50	80.38	80.13	80.44
	Std	0.31	0.32	0.31	0.32	0.31
k-NN	Max	81.65	81.15	80.90	80.56	81.02
	Min	79.49	78.79	78.60	78.10	78.74
	Mean	80.52	79.97	79.69	79.31	79.83
	Std	0.33	0.36	0.35	0.37	0.35
SVM	Max	80.88	80.48	80.49	80.37	80.48
	Min	78.88	78.42	78.36	78.18	78.39
	Mean	79.98	79.62	79.56	79.44	79.59
	Std	0.43	0.44	0.46	0.47	0.45

Table 4 shows that the best result was obtained with the Decision Trees Algorithm.

4.CONCLUSION

With today's technology, we can remotely control autonomous vehicles and monitor their movements in real-time. Using GPS modules, the location information of autonomous vehicles can be connected to more than one satellite, and location determination can be made with high accuracy. But sometimes problems occur due to reasons such as GPS signals not being received. That's why we're looking for new methods. In this study, an embedded system was developed and data was collected in the external environment by fixing it on the automobile. GPS data showing the location of the car was also recorded during the data collected. From the collected data, latitude and longitude data were calculated and the angle between each location and the previous location was calculated and labeled in four classes North, East, South, and West. Then, an attempt was made to develop a direction prediction model using IMU data.

K-Nearest Neighbor, Support Vector Machine, and Decision Tree classification Algorithms were applied to these data. 82.11% Accuracy was calculated with the proposed method Decision Tree Algorithm. The decision Tree Algorithm was compared with other classification methods and it was seen that the proposed method was successful.

Acknowledgment

This study was supported by the TÜBİTAK 2209/A project numbered “1919B012310014”

5. REFERENCES

- Álvarez López, Yuri, María Elena de Cos Gómez, and Fernando Las-Heras Andrés. 2017. “A Received Signal Strength RFID-Based Indoor Location System.” *Sensors and Actuators, A: Physical*. doi: 10.1016/j.sna.2017.01.007.
- Ata, Emre Han. 2022. “Inertial-Navigation-System Aiding by Combining Data Link and Seeker Measurements.” Middle East Technical University.
- Baygin, Nursena, Mehmet Baygin, and Mehmet Karakose. 2019. “A SVM-PSO Classifier for Robot Motion in Environment with Obstacles.” in *2019 International Conference on Artificial Intelligence and Data Processing Symposium, IDAP 2019*.
- Chen, Changhao, Xiaoxuan Lu, Andrew Markham, and Niki Trigoni. 2018. “IoNet: Learning to Cure the Curse of Drift in Inertial Odometry.” in *32nd AAAI Conference on Artificial Intelligence, AAAI 2018*.
- Deng, Zhenyun, Xiaoshu Zhu, Debo Cheng, Ming Zong, and Shichao Zhang. 2016. “Efficient KNN Classification Algorithm for Big Data.” *Neurocomputing*. doi: 10.1016/j.neucom.2015.08.112.
- Du, Hao, Wei Wang, Chaowen Xu, Ran Xiao, and Changyin Sun. 2020. “Real-Time Onboard 3D State Estimation of an Unmanned Aerial Vehicle in Multi-Environments Using Multi-Sensor Data Fusion.” *Sensors (Switzerland)*. doi: 10.3390/s20030919.
- Farooq, Asad, and Shaharyar Kamal. 2019. “Indoor Positioning and Tracking Using Sensors of a Smart Device.” in *2019 International Conference on Applied and Engineering Mathematics, ICAEM 2019 - Proceedings*.
- Girgensohn, Andreas, Mitesh Patel, and Jacob T. Biehl. 2024. “Radio-Frequency-Based Indoor-Localization Techniques for Enhancing Internet-of-Things Applications.” *Personal and Ubiquitous Computing*. doi: 10.1007/s00779-020-01446-8.
- Göğüş, Bekir. 2022. “Ataletsel Navigasyon Sistemlerinde Kestirim İçin Farklı Yöntemlerin Performanslarının Karşılaştırılması.” Başkent Üniversitesi.
- Greff, Klaus, Rupesh K. Srivastava, Jan Koutnik, Bas R. Steunebrink, and Jürgen Schmidhuber. 2017. “LSTM: A Search Space Odyssey.” *IEEE Transactions on Neural Networks and Learning Systems*. doi: 10.1109/TNNLS.2016.2582924.
- Hernández Sánchez, Sara, Rubén Fernández Pozo, and Luis Alfonso Hernández Gómez. 2019. “Deep Neural Networks for Driver Identification Using Accelerometer Signals from Smartphones.” in *Lecture Notes in Business Information Processing*.
- Iv, James H. Keppe., Brian C. Claus, and James C. Kinsey. 2019. “A Navigation Solution Using a MEMS IMU, Model-Based Dead-Reckoning, and One-Way-Travel-Time Acoustic Range Measurements for Autonomous Underwater Vehicles.” *IEEE Journal of Oceanic Engineering*. doi: 10.1109/JOE.2018.2832878.
- Karabey, Işıl. 2015. “Wi-Fi Tabanlı Parmak İzi Yöntemi Kullanarak İç Ortam Konumlandırma.” Atatürk Üniversitesi.
- Kaya, Sertaç Buğra. 2018. “Çoklu Veri Füzyonu Tabanlı İç Ortam Konumlandırma ve Takip Sistemi Tasarımı.” Hacettepe Üniversitesi.
- Khanh, Tran Trong, Van Dung Nguyen, Xuan Qui Pham, and Eui Nam Huh. 2020. “Wi-Fi Indoor Positioning and Navigation: A Cloudlet-Based Cloud Computing Approach.” *Human-Centric Computing and Information Sciences*. doi: 10.1186/s13673-020-00236-8.
- Kopar, Ahmet Serdar. 2020. “İnsansız Hava Araçlarının (İHA) Konumlandırılmasında Kullanılan Sensör Verilerinin Filtre Teknikleri Kullanılarak İyileştirilmesi.” Erzurum Teknik Üniversitesi.
- Li, Yi Shan, and Fang Shii Ning. 2018. “Low-Cost Indoor Positioning Application Based on Map Assistance and Mobile Phone Sensors.” *Sensors (Switzerland)*. doi: 10.3390/s18124285.

- Li, Yunhui, Shize Yang, Xianchao Xiu, and Zhonghua Miao. 2022. "A Spatiotemporal Calibration Algorithm for IMU–LiDAR Navigation System Based on Similarity of Motion Trajectories." *Sensors*. doi: 10.3390/s22197637.
- Mahdi, Ahmed E., Ahmed Azouz, Ahmed E. Abdalla, and Ashraf Abosekeen. 2022. "A Machine Learning Approach for an Improved Inertial Navigation System Solution." *Sensors*. doi: 10.3390/s22041687.
- Naviani, Avinash. 2018. "KNN Classification Tutorial Using Scikit-Learn." *Datacamp*.
- Oguntala, George, Raed Abd-Alhameed, Stephen Jones, James Noras, Mohammad Patwary, and Jonathan Rodriguez. 2018. "Indoor Location Identification Technologies for Real-Time IoT-Based Applications: An Inclusive Survey." *Computer Science Review*.
- Okudan, Mehmet Emin. 2019. "Navigasyon Hassasiyetini Arttırmak İçin Ataletsel Ölçüm Birimine Tamamlayıcı Filtre Uygulanması." İstanbul Teknik Üniversitesi.
- Poulose, Alwin, Odongo Steven Eyobu, and Dong Seog Han. 2019. "An Indoor Position-Estimation Algorithm Using Smartphone IMU Sensor Data." *IEEE Access*. doi: 10.1109/ACCESS.2019.2891942.
- Poulose, Alwin, and Dong Seog Han. 2019. "Hybrid Indoor Localization Using IMU Sensors and Smartphone Camera." *Sensors (Switzerland)*. doi: 10.3390/s19235084.
- Prikhodko, Igor P., Brock Bearss, Carey Merritt, Joe Bergeron, and Charles Blackmer. 2018. "Towards Self-Navigating Cars Using MEMS IMU: Challenges and Opportunities." in *5th IEEE International Symposium on Inertial Sensors and Systems, INERTIAL 2018 - Proceedings*.
- Rajesh, B., M. Vishnu Sai Vardhan, and L. Sujihelen. 2020. "Leaf Disease Detection and Classification by Decision Tree." in *Proceedings of the 4th International Conference on Trends in Electronics and Informatics, ICOEI 2020*.
- Regus, M., R. Talar, and R. Labudzki. 2019. "Indoor Positioning and Navigation System for Autonomous Vehicles Based on RFID Technology." in *IOP Conference Series: Materials Science and Engineering*.
- Şahin, Fatih, and Faruk Ulaş. 2023. "Makine Öğrenmesi İle Ataletsel Navigasyon Sistemlerinde Doğruluğun Geliştirilmesi TT - Improving Accuracy in Inertial Navigation Systems with Machine Learning." *International Journal of Engineering Research and Development* 15(1):286–96. doi: 10.29137/umagd.1129097.
- Shu, Mingcong, Guoliang Chen, and Zhenghua Zhang. 2022. "Efficient Image-Based Indoor Localization with MEMS Aid on the Mobile Device." *ISPRS Journal of Photogrammetry and Remote Sensing*. doi: 10.1016/j.isprsjprs.2022.01.010.
- Sun, Rui, Zixuan Zhang, Qi Cheng, and Washington Yotto Ochieng. 2022. "Pseudorange Error Prediction for Adaptive Tightly Coupled GNSS/IMU Navigation in Urban Areas." *GPS Solutions*. doi: 10.1007/s10291-021-01213-z.
- Sun, Yaowen, Zengke Li, Zehua Yang, Kefan Shao, and Wangqi Chen. 2022. "Motion Model-Assisted GNSS/MEMS-IMU Integrated Navigation System for Land Vehicle." *GPS Solutions*. doi: 10.1007/s10291-022-01318-z.
- Ulgen, E. Kaan. 2024. "Makine Öğrenimi Bölüm-2 (k-En Yakın Komşuluk)." Retrieved March 1, 2024 (<https://medium.com/@k.ulgen90/makine-ogrenimi-bolum-2-6d6d120a18e1>).
- Wagstaff, Brandon, and Jonathan Kelly. 2018. "LSTM-Based Zero-Velocity Detection for Robust Inertial Navigation." in *IPIN 2018 - 9th International Conference on Indoor Positioning and Indoor Navigation*.
- Wang, Dongsheng, Yongjie Lu, Lei Zhang, and Guoping Jiang. 2019. "Intelligent Positioning for a Commercial Mobile Platform in Seamless Indoor/Outdoor Scenes Based on Multi-Sensor Fusion." *Sensors (Switzerland)*. doi: 10.3390/s19071696.

- Wang, Sen, Ronald Clark, Hongkai Wen, and Niki Trigoni. 2017. "DeepVO: Towards End-to-End Visual Odometry with Deep Recurrent Convolutional Neural Networks." in *Proceedings - IEEE International Conference on Robotics and Automation*.
- Xing, Huiming, Yu Liu, Shuxiang Guo, Liwei Shi, Xihuan Hou, Wenzhi Liu, and Yan Zhao. 2021. "A Multi-Sensor Fusion Self-Localization System of a Miniature Underwater Robot in Structured and GPS-Denied Environments." *IEEE Sensors Journal*. doi: 10.1109/JSEN.2021.3120663.
- Yaman, Orhan, Beyda Tasar, and Oguz Yakut. 2022. "Regression-Based Position Detection for Navigation Using IMU." in *2022 International Conference on Decision Aid Sciences and Applications, DASA 2022*.



Dominant Color Detection For Online Fashion Retrievals*

Sultan ZEYBEK^{1*}, Merve ÇELİK²

^{1*} Fatih Sultan Mehmet Vakif University, TURKEY

² Fatih Sultan Mehmet Vakif University, TURKEY

Doi: 10.55024/buyasambid.1501329

ARTICLE INFO

Article Type: Research Article

Article history:

Received: 14.06.2024

Received in revised form:
26.06.2024

Accepted: 27.06.2024

Available online: 07.07.2024

Keywords:

Dominant Color Extraction,
Fashion Image Analysis, K-means
Clustering, Image Segmentation.

^{1*}Sultan ZEYBEK

E-mail address:

szeybek@fsm.edu.tr

Orcid: 0000-0002-1298-9499

²Merve ÇELİK

E-mail address:

mervelilith1@gmail.com

Orcid: 0009-0009-0085-4237

ABSTRACT

This paper introduces a novel approach aimed at efficiently extracting dominant colors from online fashion images. The method addresses challenges related to detecting overlapping objects and computationally expensive methods by combining K-means clustering and graph-cut techniques into a framework. This framework incorporates an adaptive weighting strategy to enhance color extraction accuracy. Additionally, it introduces a two-phase fashion apparel detection method called YOLOv4, which utilizes U-Net architecture for clothing segmentation to precisely separate clothing items from the background or other elements. Experimental results show that K-means with YOLOv4 outperforms K-means with the U-Net model. These findings suggest that the U-Net architecture and YOLOv4 models can be effective methods for complex image segmentation tasks in online fashion retrieval and image processing, particularly in the rapidly evolving e-commerce environment.

2024 Batman University. All rights reserved.

Çevrimiçi Moda Aramaları İçin Baskın Renk Tespiti

Sultan ZEYBEK^{1*}, Merve ÇELİK²

^{1*} Fatih Sultan Mehmet Vakif Üniversitesi, TÜRKİYE

² Fatih Sultan Mehmet Vakif Üniversitesi, TÜRKİYE

Doi: 10.55024/buyasambid.1501329

MAKALE BİLGİSİ

Makale Türü: Araştırma Makalesi

Makale Geçmişi:

İlk gönderim tarihi: 14.06.2024

Düzeltilme tarihi: 26.06.2024

Kabul tarihi: 27.06.2024

Yayın tarihi: 07.07.2024

ÖZET

Bu makale, çevrimiçi moda görüntülerinden baskın renklerin verimli bir şekilde çıkarılmasını amaçlayan yeni bir yaklaşımı tanıtmaktadır. Bu yöntem, üst üste binen nesnelerin tespit edilmesi sırasında ortaya çıkan zorluklara ve hesaplama maliyeti yüksek yöntemlere çözüm sunarak, K-means kümeleme ve graf-kesim tekniklerini birleştiren

* "This article is derived from the paper titled 'Dominant Color Detection for Online Fashion Retrievals,' presented at the International Information Congress 2024 (IIC2024) held at Batman University between May 2-4, 2024."

Anahatar Kelimeler:

Moda Görüntü Analizi, Baskın Renk Tespiti, K-means Kümeleme, Görüntü Bölütleme.

*¹Sultan ZEYBEK

E-mail address:

szeybek@fsm.edu.tr

Orcid: 0000-0002-1298-9499

²Merve ÇELİK

E-mail address:

mervelilith1@gmail.com

Orcid: 0009-0009-0085-4237

ve adaptif bir ağırlıklandırma stratejisi kullanılarak renk çıkarımının doğruluğu artırmayı amaçlayan bir çerçeve üzerine kurulmuştur. Giysi segmentasyonu için U-Net mimarisini ile giysi öğelerini arka plandan veya diğer unsurlardan hassas bir şekilde ayırmayı sağlayarak giysi öznitelik tahmini ve ayrıştırma görevi için YOLOv4 adlı iki aşamalı bir moda giyim tespit yöntemini tanıtmaktadır ile karşılaştırılmıştır. Deneysel sonuçlar, K-means ile YOLOv4'ün, K-means ile U-Net modeline kıyasla daha üstün performans sergilediğini göstermektedir. Bu bulgular, özellikle hızla gelişen e-ticaret ortamında çevrimiçi moda arama ve görüntü işleme alanlarında ilerlemeye katkı sağlamak amacıyla U-Net mimarisinin ve YOLOv4 mimarilerinin karmaşık görüntü segmentasyon görevlerini için etkin metotlar olarak kullanılabileceğini göstermiştir.

2024 Batman Üniversitesi. Her hakkı saklıdır.

1. INTRODUCTION

Detection of dominant colors in online design pictures is vital due to its profound impact on people's purchasing behaviour. A basic component of vision-based frameworks is color image segmentation since color pictures contain more data than grayscale pictures (Karthick et al., 2023). Image analytics, clothing recognition and parsing are crucial steps and play a pivotal role in online detection and decision systems (Lu, 2023; Gunduz, 2021; Liang,2016). By extracting features from recognized fashion landmarks, we can improve the analysis of clothing images, making it easier to predict attributes and retrieve specific clothing items (Bu et al., 2020).

Recently, there has been an increasing interest among researchers in detection algorithms, spanning traditional and deep learning methods, incorporating image feature extraction for explainable detection (Liu et al., 2023). The study proposed dominant color representations as a way to decrease the size of color descriptors, shifting away from histogram-based methods with numerous bins, such as the reduction to eight colors in MP7DCD (Talib et al., 2013). An approach has been proposed for treating an image as a graph with user inputs as strict constraints (Shih et al., 2016) and similarly (Ngoc et al., 2023) focuses on solving the graph-cut problem to find the minimum cut optimizing an energy function, balancing region and boundary information. To address these challenges, a proposed technique efficiently extracts the dominant color component (DCC) for optimal thresholding (Agrawal et al., 2022), which also proposed a multi-view clustering framework using K-means and graphs. The graph-cut-based multi-view clustering involves calculating similarity matrices, obtaining eigenvectors, and applying K-means to segregate objects into specified clusters. A spatial K-clustering algorithm, outlined in (Chang et al., 2015), which strives to minimize errors in assigning data points to clusters by assessing local texture complexity worked on the selection of optimal features to ensure spatial homogeneity. Furthermore, as discussed in (Tomasi and Manduchi, 1998) filters operating on the three bands of a color image, particularly bilateral filters, play a crucial role in enforcing perceptual metrics in the CIE-Lab color space. These filters are adeptly smooth colors and preserve edges in alignment with human perception.

In the domain of fashion retrieval, as highlighted in (Tomasi and Manduchi, 1998), learning methods have demonstrated success. The inclusion of massive attributes contributes to an improved partitioning of the clothing feature space, facilitating the recognition and retrieval of cross-domain clothing images (Liao et al., 2018). The paper proposes a method where each pixel color in an image is replaced by the color in a common palette that is most similar (Liu et al., 2016). This process classifies all pixels into k-clusters, termed the CHKM feature. An approach outlined in (Lin et al., 2009), involves the extraction of object proposal descriptors. These descriptors are then used to train joint textual and image embeddings. In the context of Fashion Image Retrieval (FIR) (Rubio et al.,

2017), the goal is to retrieve relevant fashion images similar to a query image. Features obtained from FIR are utilized in an unsupervised histogram clustering-based segmentation algorithm (Park et al., 2019), to identify regions of uniform texture. The research community's interest in color–texture-based segmentation (Khotanzad et al., 2003), is motivated by the perceptual description of imaged objects and diverse applications. Motion vectors from P-frames are employed for foreground/background segmentation (Mezaris and Kompatsiaris, 2004) and a consensus matrix is generated from multiple views for K-means clustering (Kalantidis et al., 2013).

Deep learning models such as convolutional neural networks have been used to directly classify or segment original color images. Even though they work well, advanced classifiers like convolutional neural networks are computationally expensive and need large sets of precisely annotated training images (Liu, 2021; Lu, 2022). A clustering method, which interprets an image as a dataset with multiple dimensions and divides it into distinct parts, can offer improved segmentation results. Conversely, the edge detection method remains a prevalent strategy for addressing image segmentation challenges. This technique revolves around identifying points where significant shifts in grey levels occur (Wang et al., 2012). This study aims to detect the dominant colors for online fashion retrievals even when multiple objects overlap. The objective is to identify common and popular color combinations associated with a specific object. A k-means clustering algorithm has been developed combining quantizing pixels within the corresponding image segment to achieve this.

The rest of the paper is structured as follows. Section 2 reviews related work for the study. Section 3 describes the proposed models for extracting dominant colors from images and Section 4 presents the hyperparameters of the model and the experimental results. Section 5 concludes the paper.

2. BACKGROUND

Visual aspects play an important role within the dynamic landscape of online fashion retail and offer potential applications in clothing recognition, retrieval, and e-commerce. As the number of digital images continues to rise, it has become essential to efficiently organize and sort fashion items to offer users a personalized and improved shopping experience (Yamaguchi et al., 2012)

Recently, there have been numerous investigations centred around the segmentation and parsing of images focusing on dominant color extraction methods and content-based image retrieval techniques. Various computational techniques, including clustering algorithms (Gunduz et al., 2021), machine learning (Wang et al., 2012), and image processing, are explored for color extraction and trend analysis. Existing approaches often rely on clothing models trained with tagged samples or complex And-Or graph representations, which have limitations in handling diverse clothing styles and poses.

Joint image segmentation and labelling methods have been proposed by Liang et al. as an integrated system to parse a set of clothing images into semantic configurations using machine learning techniques (Liang et al., 2016). The image co-segmentation phase of the system extracts consistent regions from images using the exemplar-SVM (ESVM) technique, and the region co-labelling phase constructs a multi-image graphical model using segmented regions as vertices. Graph Cuts algorithm has been used for joint label assignment. The authors evaluate their framework on both the Fashionista dataset and a newly constructed dataset called CCP.

The study (Hu et al., 2008) proposed method introduces an approach for segmentation using the graph cuts technique that partitions image pixels based on foreground and background seeds. In this method, the algorithm is guided by detected faces, and foreground and background seeds where Foreground seeds are approximated based on the identification of the main color using torso detection, and background seeds are determined using constrained Delaunay triangulation (CDT). Wang introduced a similar semantic segmentation model designed to identify compatible color combinations in everyday photos which utilizes Deeplab V2, trained on the ModaNet dataset (Wang, 2019).

Traditional color detection methods are mainly based on human inferences and manual analysis makes this process time-consuming. In addition to the conventional methods, the garment image

retrieval method is proposed based on grab-cut auto segmentation and the dominant color method for handling both simple and complex backgrounds. A color feature extraction using the color coherence vector (CCV) and dominant color method tries to achieve rapid and effective garment image retrieval in the context of the growing demand for online shopping platforms. Experimental results have been done using a database of 300 images that reached up to 60% precision rate (Liu et al., 2023).

Machine learning and deep learning algorithms have also been widely used for color detection tasks as the traditional segmentation methods face limitations. With the data-driven approaches, the fashion industry started to use social media images to automatically analyze fashion images, particularly runway images, for trend prediction. The study (Lai and Westland, 2020) focuses on machine learning techniques to automatically generate color palettes for fashion with a set of ground-truth data. Color palette generation combined with the k-means clustering algorithm has been compared with people detection and foreground/background segmentation before clustering. Experimental results showed that the image segmentation method outperformed the colors of the garments displayed.

The paper introduced a method for semantic segmentation that utilizes deep learning techniques along with color quantization and K-means clustering to extract dominant colors from salient objects (Gunduz et al., 2021). This approach employs a modified Inception-ResNet architecture for semantic segmentation and integrates SALGAN for salient object detection. Furthermore, K-means clustering is utilized to quantize the pixels within the segment and extract the dominant colors. Another study proposed a method for color image segmentation using Support Vector Machine (SVM) and Fuzzy C-Means (FCM) (Wnag et al., 2012) based on a local spatial similarity measure model and Steerable filter. These features are fed into an SVM classifier trained using FCM.

Some studies focused on metaheuristics, fuzzy set theory and graph cut techniques to improve the proposed models' performance. The study (Agrawal et al., 2022) proposes the use of the Adaptive Whale Optimization Algorithm (AWOA) to determine optimal threshold values introducing a new segmentation score for evaluation. While existing methods employ parametric and non-parametric strategies with entropic and non-entropic objective functions for threshold determination, this study proposed a DCC-based method for thresholding color images compared to the Gravitational Search Algorithm (GSA), Differential Evolution (DE), and Whale Optimization Algorithm (WOA). Karthick et al. proposed the S-fuzzy normalized graph cut (S-FNGC) method based on the common S-membership function to improve the image segmentation process (Karthick et al., 2023) To this end, each pixel in the color image has a functioned into a fuzzy region as a fuzzy weighted graph to represent the relationships between pixels. The proposed model has been compared with existing approaches such as mask thresholding, Gabor filter, Genetic algorithm (GA), and K-means clustering algorithm using the Barkey Segmentation dataset. The s-FNGC method outperforms other techniques, offering better segmentation accuracy and lower error rates. By integrating fuzzy set theory and graph cut techniques, it effectively addresses the challenges associated with segmenting complex color images. The findings of the study highlight the potential of the S-FNGC method for various computer vision applications requiring accurate and efficient image segmentation.

3. METHODS

In this section, the proposed model has been given that leverages a uniform framework based on K-means clustering and graph-cut techniques, designed for both single-view and multi-view datasets. To this end, firstly object detection and Graph-Cut Algorithm have been defined and then, the YOLOv4 and U-Net model have been outlined which comprises two distinct phases: data preparation and model training.

3.1. Object Detection and Graph Cut Algorithm

The initial module of the proposed model contains object detection and graph-cut stages. Object Detection algorithm effectively identifies all fashion items within the image which encompasses both classification and localization processes. Within this model, there exist three distinct classes: top, bottom, and middle. The algorithm proceeds with localization to determine the precise position of the identified class after the detection of one or more of these classes within the input image. This step is crucial for subsequent steps of segmentation with the Graph Cut algorithm (Lu et al., 2023). Within the Graph Cut algorithm, the image is represented as a graph and the segmentation problem is framed as finding the optimal cut in this graph. It is especially useful for tasks where the background of the image is complex or where there are other objects in the image that are similar to the foreground object. This algorithm requires precise localization data to effectively segment the image. The sample output of the Object Detection phase and Graph Cut Algorithm is represented in Figure 3.1.



Figure 3.1 Object Detection and Graph Cut Algorithm

3.2. Extraction of Color Candidates from Segmented Images

The k-means clustering method has been employed to extract candidate colors from segmented images. K-means clustering is a widely recognized technique utilized for low-level image segmentation tasks. As an unsupervised clustering algorithm, K-Means effectively groups data points into k clusters, where each cluster represents a distinct colour after removing dominant colours. Initially, a multitude of candidate colors is extracted and subsequently refined based on their respective features.

Before operating the K-Means algorithm, we preprocess images using the Binary Filter. This filter diminishes noise by replacing the intensity of each pixel with a weighted average derived from neighbouring pixels. Additionally, during the application of K-Means, only pixels selected by the Graph Cut Algorithm are considered. Following the extraction of candidate colors, we derive various features such as contrast, saturation, and the area covered by each candidate color. The CIELAB color space is chosen due to its perceptually uniform nature, where equal changes in L^* , a^* , and b^* correspond to equal perceived changes in color. In the CIELAB color space, color is defined in a way that corresponds closely to human perception, with three components: L^* (Lightness), a^* (Green-Red axis), and b^* (Blue-Yellow axis). L^* indicates the perceived lightness of a color, ranging from 0 (black) to 100 (white), with higher values indicating lighter colors and lower values indicating darker ones. The a^* axis represents the spectrum from green ($-a^*$) to red ($+a^*$), while the b^* axis spans from blue ($-b^*$) to yellow ($+b^*$) (Chang and Mukai., 2022). Positive values on both axes indicate the

presence of the respective color, while negative values indicate its absence. These components are essential for tasks such as measuring contrast and saturation in image processing, as they provide a precise way to compare colors based on human perception. Contrast represents the brightness of a color, while saturation denotes its richness. These attributes play a pivotal role in ranking candidate colors. Equations 1 and 2 below represent the computation of contrast and saturation. These metrics contribute significantly to the refinement and selection of optimal candidate colors for our research purposes.

$$C = \frac{(L_{max}-L_{min})}{L_{min}} \quad (1)$$

where $L_{min} = \text{Min}(L_{values})$ and $L_{max} = \text{Max}(L_{values})$.

$$S = \sqrt{a^2 + b^2} \quad (2)$$

Equation 1 defines the contrast, denoted as C, computed from all L values within the Lab color space. This formula yields the contrast value, reflecting the dispersion of L values across the image. Specifically, high-contrast images exhibit a broad spectrum of L values, whereas low-contrast images feature a narrower range of L values. Equation 2 computes the saturation, represented as S, as the square root of the sum of the squares of the a^* and b^* values divided by the L^* value. Saturation serves as an indicator of the distance of the a^* and b^* values from zero relative to the L^* value. Images with high saturation boast significant a^* and b^* values, whereas those with low saturation present smaller a^* and b^* values. Consequently, Equation 1 assesses the disparity between the lightness of each pixel and the average lightness of the image, while Equation 2 gauges the deviation of pixel colors from neutral tones ($a=0, b=0$). Together, these equations facilitate the calculation of contrast and saturation within the CIELAB color space. Additionally, we quantify the area occupied by the color candidate under scrutiny. This metric, termed Area, corresponds to the number of pixels attributed to the candidate color. Such calculations provide valuable insights into the spatial distribution and prominence of color candidates within the image context.

3.3. Sorting Final Colors

In the final stage of our analysis, we aim to refine our candidate colors by eliminating similar hues. This process entails pairwise comparisons of colors, necessitating a metric that amalgamates the three CIELAB components into a singular indicator representing the comprehensive color disparity between two samples. To this end, we employ CIEDE2000, also referred to as ΔE_{2000} , a color difference formula and metric endorsed by the International Commission on Illumination (CIE) for quantifying and evaluating the perceived color disparity between two entities. ΔE_{2000} yields higher values to signify greater disparities in perceived color. Thus, it inherently serves as a threshold, functioning as a hyper-parameter within our methodology. We use ΔE_{2000} to set a standard for recognizing colors with noticeable differences, making our color selection more precise. In fashion, we focus on different aspects, with the size of color areas being especially important. This tells us how much space each color takes up and how prominent it is in the product. Contrast is also key because it affects how textures and patterns look and how well colors go together. Saturation, while less critical than area and contrast, still plays a role in how vibrant the colors appear. Our study highlights the importance of area, contrast, and saturation in selecting colors for fashion products, though their significance may vary depending on the product type. Through careful testing, we've determined the varying importance of these factors across different fashion categories, improving how we choose colors for products.

Figure 3.2 represents the flowchart of the proposed method. Utilizing the K-Means algorithm, the color features are organized into a defined number of clusters, facilitating the identification of dominant colors within the image. The cluster centres derived from the K-Means algorithm accurately represent the dominant colors present in the visual content to prepare ground truth. Then object segmentation detection has been done using YOLOv4 and U-Net algorithms. YOLOv4 is known for quickly detecting objects in one go, while U-Net is skilled at precise object detection in high-

resolution images. The study compares how these models perform in various contexts and applications. The next section presents the procedure for images which are converted, normalized, and scaled to fit both models' input and output formats. The dataset includes diverse object classes for thorough evaluation. Customized setups are created for both YOLOv4 and U-Net.

3.5. YOLOv4 and U-Net Architectures

The dual-phase application of YOLOv4 presents a streamlined and efficient solution, seamlessly integrating processes encompassing dominant color identification, object detection, and color analysis.

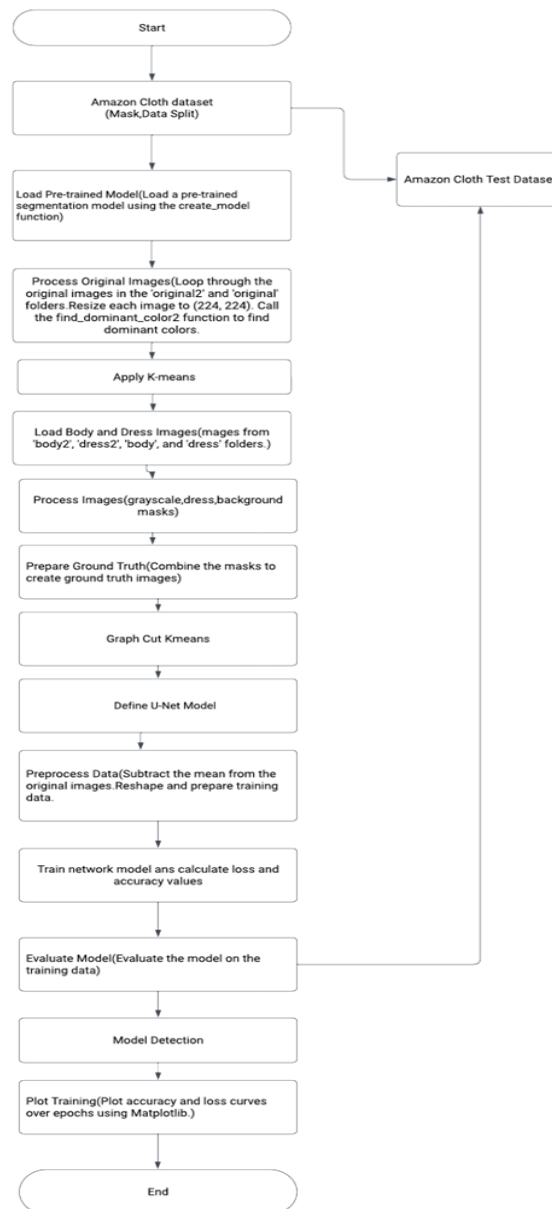


Figure 3.2 Flowchart of the proposed model

This approach not only enhances the effectiveness of color-centric tasks but also offers a swift and reliable methodology for diverse visual analysis requirements. YOLO is trained on the COCO dataset with optimizations for fast detection. U-Net, originally for medical images, is adapted for high-resolution object detection. Training has been done separately for each model, focusing on comparing training times and performance metrics, considering YOLO's quick trainability and U-Net's deep learning requirements. The implementation of a dual-phase methodology entails the breakdown of a

given task into more specialized subtasks, thereby enabling a comprehensive analysis of the target domain. In the context of the YOLOv4 application for the identification of dominant colors, the dual-phase approach comprises a systematic progression from general object detection to more focused color analysis. During the initial phase, the YOLOv4 algorithm has been employed to detect and classify objects within the image. Subsequently, in the first phase, the detected objects undergo regional segmentation, wherein each segment encapsulates the color features pertinent to the identified object. These features, including color histograms or RGB values, serve as the basis for subsequent analysis.

4. EXPERIMENTS

This section reports on the experimental setting and comparable performance results of the proposed models.

4.1. Experimental Setup, Dataset, and Preprocessing Steps

In this study, outdoor images of people and semantic segmentation masks of their clothing dataset have been used. This dataset has 1000 images and matching segmentation masks, showing different clothes people wear. It covers 59 types of objects, all in a standard size of 825 by 550 pixels and saved as PNG files. The masks outline areas like shirts, hair, pants, and more, with one class for the background. There's also a CSV file detailing these classes. The dataset contains both JPEG and PNG files, with PNG preferred for its higher quality. It's useful for research in computer vision and fashion analysis, aiding in tasks like person detection and clothing recognition in outdoor scenes.

This dataset has broad applications, from fashion industry progress to improved surveillance and understanding of human behavior. It's a valuable resource for studying attire recognition outdoors and reflects the growing connection between technology and fashion analysis. In the data preprocessing phase, several essential steps are undertaken to prepare the dataset for subsequent analysis and model training. Firstly, images are loaded from the dataset using standard libraries like OpenCV. Next, the images are resized to a uniform size and standardized to ensure consistency across the dataset. Pixel values are then normalized to a standardized scale, typically ranging from 0 to 1, to facilitate model convergence and stability during training. Following this, images are converted to a suitable color space, such as RGB, HSV, or LAB, to enable effective dominant color extraction, considering specific application requirements and computational efficiency. Labelling and preprocessing of training data sets have been done for the stage of effective model training. The model is trained using transfer learning principles, with a primary focus on detecting apparel features based on contour and appearance, irrespective of color variations. Table 1 reports the hyperparameters of the U-Net and Yolov4 models.

Table 1. Hyperparameter setup for U-Net and Yolov4 models

Hyperparameters	Value
Epoch number	120
Activation Function	ReLU
Learning Rate for Adam	0.001
Hidden Layers	18

5. RESULTS AND DISCUSSION

The performance of both models has been evaluated using accuracy and loss metrics with a primary focus on accuracy. Figure 4.1 represents visual representations of accuracy metrics, offering valuable insights into the comparative performance of YOLOv4 and U-Net across evaluation scenarios. Table 2 reports the results for the training set over 120 epochs.




Figure 4.1. Training Accuracy and loss results for the Yolov4 model (top), U-Net model (middle), and training and validation results comparison for Yolov4 (left) and U-Net models over 10 epochs

Table 2. Experimental results over 120 epochs

	K-means with Yolov4	K-means with U-Net	Gaussian Mixture with U-Net
Accuracy	0.8714	0.70	0.5077
Loss	0.2176	0.30	0.3446

The experimental results demonstrate varying performance metrics across different methods for object segmentation detection. When utilizing K-means with YOLOv4, the accuracy achieved is notably high at 0.8714, accompanied by a relatively low loss value of 0.2176. Conversely, employing K-means with U-Net yields a slightly lower accuracy of 0.70, with a corresponding loss of 0.30. Gaussian Mixture with U-Net shows the lowest accuracy among the methods at 0.5077, accompanied

by a loss value of 0.3446. These results suggest that K-means with YOLOv4 outperforms the other methods in terms of both accuracy and loss, indicating its effectiveness in object segmentation detection tasks. The performance of the K-means algorithm has also been compared with Gaussian Mixture Model (GMM) over the precision metric for the selection of dominant colors. The precision metric serves as a pivotal indicator of the algorithm's capability to accurately identify dominant color components within the image dataset under scrutiny.

6. CONCLUSION

This study introduces a novel and adaptable approach to dominant color extraction in the context of online fashion retrieval. By combining K-means clustering with segmentation techniques, our proposed framework demonstrates versatility across images. According to the experimental results, in the U-Net model, the dense layer structure leads to slower training, while YOLOv4 exhibits faster training with higher accuracy rates. The YOLOv4 model represents a promising solution to the longstanding challenges of object detection within the fashion domain, thereby contributing to advancements in computer vision applications geared towards apparel recognition and recommendation systems.

7. REFERENCES

- Agrawal, S., Panda, R., Choudhury, P., & Abraham, A. (2022). Dominant color component and adaptive whale optimization algorithm for multilevel thresholding of color images. *Knowledge-Based Systems*, 240, 108172. <https://doi.org/10.1016/j.knosys.2021.108172>.
- Agrawal, S., Panda, R., Choudhury, P., & Abraham, A. (2022). Dominant color component and adaptive whale optimization algorithm for multilevel thresholding of color images. *Knowledge-Based Systems*, 240, 108172.
- Bu, Q., Zeng, K., Wang, R., & Feng, J. (2020). Multi-depth dilated network for fashion landmark detection with batch-level online hard keypoint mining. *Image and Vision Computing*, 99, 103930. <https://doi.org/10.1016/j.imavis.2019.103930>
- Chang, Y., & Mukai, N. (2022). Color feature based dominant color extraction. *IEEE Access*, 10, 93055-93061. <https://doi.org/10.1109/ACCESS.2022.3202632>.
- Chang, Y., Iida, T., and Mukai, N. (2015). Dominant color extraction method from natural images. *Proceedings of the International Conference on Image Processing*, 44, 637-643.
- Gunduz, A. B., Taskin, B., Yavuz, A. G., & Karsligil, M. E. (2021). A better way of extracting dominant colors using salient objects with semantic segmentation. *Engineering Applications of Artificial Intelligence*, 100, 104204. <https://doi.org/10.1016/j.engappai.2021.104204>.
- Gunduz, A. B., Taskin, B., Yavuz, A. G., & Karsligil, M. E. (2021). A better way of extracting dominant colors using salient objects with semantic segmentation. *Engineering Applications of Artificial Intelligence*, 100, 104204.
- Hu, Z., Yan, H., & Lin, X. (2008). Clothing segmentation using foreground and background estimation based on the constrained Delaunay triangulation. *Pattern Recognition*, 41(5), (pp. 1581-1592)
- Ilea, D. E., & Whelan, P. F. (2011). Image segmentation based on the integration of colour–texture descriptors—A review. *Pattern Recognition*, 44(10–11), 2479-2501. <https://doi.org/10.1016/j.patcog.2011.03.011>
- Ilea, D., & Whelan, P. (2006). Color image segmentation using a spatial k-means clustering algorithm. *Proceedings of the 10th International Machine Vision and Image Processing Conference*, 30-1.
- Kalantidis, Y., Kennedy, L., & Li, L.-J. (2013). Getting the look: Clothing recognition and segmentation for automatic product suggestions in everyday photos. *In Proceedings of the 3rd ACM Conference on International Conference on Multimedia Retrieval, ICMR*, (pp. 105–112) Association for Computing Machinery, New York, NY, USA.

- Karthick, P., Mohiuddine, S. A., Tamilvanan, K., Narayanamoorthy, S., & Maheswari, S. (2023). Investigations of color image segmentation based on connectivity measure, shape priority and normalized fuzzy graph cut. *Applied Soft Computing*, 139, 110239.
- Khotanzad, A., & Hernandez, O. J. (2003). Color image retrieval using multispectral random field texture model and color content features. *Pattern Recognition*, 36(8), 1679-1694. [https://doi.org/10.1016/S0031-3203\(02\)00320-4](https://doi.org/10.1016/S0031-3203(02)00320-4)
- Khotanzad, A., & Hernandez, O. J. (2003). Color image retrieval using multispectral random field texture model and color content features. *Pattern Recognition*, 36(8), 1679-1694.
- Lai, P., & Westland, S. (2020). Machine learning for colour palette extraction from fashion runway images. *International Journal of Fashion Design, Technology and Education*, 13(3), 334-340.
- Lee, C. H., & Lin, C. W. (2021). A two-phase fashion apparel detection method based on YOLOv4. *Applied Sciences*, 11(9), 3782.
- Lee, C.-H., & Lin, C.-W. (2021). A two-phase fashion apparel detection method based on YOLOv4. *Applied Sciences*, 11(9), 3782. <https://doi.org/10.3390/app11093782>
- Liang, X., Lin, L., Yang, W., Luo, P., Huang, J., & Yan, S. (2016). Clothes Co-Parsing Via Joint Image Segmentation and Labeling With Application to Clothing Retrieval. *IEEE Transactions on Multimedia*, 18(6), <https://doi.org/10.1109/TMM.2016.2553482>
- Liao, L., He, X., Zhao, B., Ngo, C.-W., & Chua, T.-S. (2018). Interpretable Multimodal Retrieval for Fashion Products. In *Proceedings of the 26th ACM International Conference on Multimedia (MM '18)* (pp. 1571–1579). Association for Computing Machinery
- Lin, C.-H., Chen, R.-T., & Chan, Y., K. (2009). A smart content-based image retrieval system based on color and texture features. *Image and Vision Computing*, 27(6), 658-665. <https://doi.org/10.1016/j.imavis.2008.07.002>
- Liu, Y., Wan, Z., Yin, X., Yue, G., Tan, A., & Zheng, Z. (2023). Detection of GAN generated image using color gradient representation. *Journal of Visual Communication and Image Representation*, 95, 103876. <https://doi.org/10.1016/j.jvcir.2022.103876>.
- Liu, Z., Luo, P., Qiu, S., Wang, X., & Tang, X. (2016). DeepFashion: Powering Robust Clothes Recognition and Retrieval with Rich Annotations. *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 1096-1104.
- Liu, Z.-y., Ding, F., Xu, Y., & Han, X. (2021). Background dominant colors extraction method based on color image quick fuzzy c-means clustering algorithm. *Defence Technology*, 17*(5), (pp1782–1790. <https://doi.org/10.1016/j.dt.2021.03.020>.
- Liu,H.,Wang,Y.,Chen,D.,Lv,J. & Alshalabi,R.(2023).Garment Image Retrieval based on Grab Cut Auto Segmentation and Dominate Color Method. *Applied Mathematics and Nonlinear Sciences*,8(1) 573-584. <https://doi.org/10.2478/amns.2022.2.0042>
- Lu, B., Zhou, J., Wang, Q., Zou, G., & Yang, J. (2023). Fusion-based color and depth image segmentation method for rocks on conveyor belt. *Minerals Engineering*, 199, 108107. <https://doi.org/10.1016/j.mineng.2023.108107>.
- Lu, H., Gao, Q., Zhang, X., & Xia, W. (2022). A multi-view clustering framework via integrating K-means and graph-cut. *Neurocomputing*, 501, 609-617. <https://doi.org/10.1016/j.neucom.2022.02.082>.
- Lu, Y., Young, S., Wang, H., & Wijewardane, N. (2022). Robust plant segmentation of color images based on image contrast optimization. *Computers and Electronics in Agriculture*, 193, 106711. <https://doi.org/10.1016/j.compag.2022.106711>.
- Mezaris, V., & Kompatsiaris, I. (2004). Real-Time Compressed-Domain Spatiotemporal Segmentation and Ontologies for Video Indexing and Retrieval. *IEEE Transactions on Circuit and Systems for Video Technology*, 14(5). <https://doi.org/10.1109/TCSVT.2004.828272>

- Ngoc, M. Ô. V., Carlinet, E., Fabrizio, J., & Géraud, T. (2023). The Dahu graph cut for interactive segmentation on 2D/3D images. *Pattern Recognition*, 136, 109207. <https://doi.org/10.1016/j.patcog.2021.109207>.
- P Karthick, P., Mohiuddine, S. A., Tamilvanan, K., Narayanamoorthy, S., & Maheswari, S. (2023). Investigations of color image segmentation based on connectivity measure, shape priority and normalized fuzzy graph cut. *Applied Soft Computing*, 139, 110239. <https://doi.org/10.1016/j.asoc.2023.110239>.
- Park, S., Shin, M., Ham, S., Choe, S., & Kang, Y. (2019). Study on fashion image retrieval methods for efficient fashion visual search. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops*, Long Beach, CA, USA, (pp. 316-319), doi: 10.1109/CVPRW.2019.00042.
- S. Park, M. Shin, S. Ham, S. Choe & Y. Kang, (2019). Study on fashion image retrieval methods for efficient fashion visual search. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops*, (pp. 316-319), Long Beach, CA, USA.
- Saranya, M. S., & Geetha, P. (2023). Cross-domain fashion cloth retrieval via novel attention-guided cascade neural network and clothing parsing. *Computer Vision and Image Understanding*, 235, 103777. <https://doi.org/10.1016/j.cviu.2021.104204>
- Shih, H.-C., & Liu, E.-R. (2016). New quartile-based region merging algorithm for unsupervised image segmentation using color-alone feature. *Information Sciences*, 342, 24–36. <https://doi.org/10.1016/j.ins.2016.01.029>.
- Talib, A., Mahmuddin, M., Husni, H., & George, L. E. (2013). A weighted dominant color descriptor for content-based image retrieval. *Journal of Visual Communication and Image Representation*, 24(3), 345–360. <https://doi.org/10.1016/j.jvcir.2012.12.008>.
- Tomasi, C., & Manduchi, R. (1998). Bilateral filtering for gray and color images. In *Sixth International Conference on Computer Vision*, pp. 839–846. IEEE.
- Wang, X. (2019). Towards color compatibility in fashion using machine learning.
- Wang, X. Y., Zhang, X. J., Yang, H. Y., & Bu, J. (2012). A pixel-based color image segmentation using support vector machine and fuzzy C-means. *Neural Networks*, 33, 148-159.
- Wang, X.-Y., Zhang, X.-J., Yang, H.-Y., & Bu, J. (2012). A pixel-based color image segmentation using support vector machine and fuzzy C-means. *Neural Networks*, 33, 148–159. <https://doi.org/10.1016/j.neunet.2012.03.018>.
- Yamaguchi, K., Kiapour, M. H., Ortiz, L. E., & Berg, T. L. (2012). Parsing clothing in fashion photographs. In *CVPR*.
- Yamaguchi, K., Kiapour, M. H., Ortiz, L. E., & Berg, T. L. (2012). Parsing clothing in fashion photographs. In *2012 IEEE Conference on Computer vision and pattern recognition* (pp. 3570-3577). IEEE.
- Yu, L. L., Simo-Serra, E., Moreno-Noguer, F., & Rubio, A. (2017). Multi-modal Embedding for Main Product Detection in Fashion. In *Proceedings - 2017 IEEE International Conference on Computer Vision Workshops, ICCVW 2017* (pp. 2236-2242). Institute of Electrical and Electronics Engineers Inc. <https://doi.org/10.1109/ICCVW.2017.261>



Derin Öğrenme ve Transfer Öğrenme Yöntemleri Kullanarak Değişen Yıldızlarda Sınıflandırma*

Emrullah KUŞTAŞI^{1*}, Mete YAĞANOĞLU²

¹Atatürk Üniversitesi, TÜRKİYE

²Atatürk Üniversitesi, TÜRKİYE

Doi: 10.55024/buyasambid.1501877

MAKALE BİLGİSİ

Makale Türü: Araştırma Makalesi

Makale Geçmişi:

İlk gönderim tarihi: 15.06.2024

Düzeltilme tarihi: 01.07.2024

Kabul tarihi: 02.07.2024

Yayın tarihi: 07.07.2024

Anahatar Kelimeler:

Yapay Zekâ, Makine Öğrenmesi,

Derin Öğrenme, Transfer

Öğrenme, Astrofizik,

Astroenformatik

*¹ Emrullah KUŞTAŞI

E-mail address:

emrullahkustasi@gmail.com

Orcid: 0009-0008-4962-9623

² Mete YAĞANOĞLU

E-mail address:

yaganoglu@atauni.edu.tr

Orcid: 0000-0003-3045-169X

ÖZET

Değişen yıldızların sınıflandırılması, geleneksel yöntemlerle bazen zorlu bir süreç olabilir. Gökbilimcilerin, genellikle yıldızların parlaklık eğrilerini ve diğer fiziksel özelliklerini analiz ederek sınıflandırma yaptıkları süreç, zaman alıcı ve zahmetli olabilir. Transfer öğrenimi yaklaşımı, bu noktada önemli bir rol oynayabilir. Bu çalışma ile gökbilimcilerin yıldız sınıflandırması yaparken daha az sayıda veri etiketlemesi yaparak, çalışmalarını yapmalarını sağlayıp, zaman alıcı ve zahmetli bir sürecin kısaltılması amaçlanmıştır. Transfer öğrenme için bir derin sinir ağı eğitilmiş ve bu modelin performansı diğer makine öğrenmesi yöntemleriyle de karşılaştırılmıştır. Model eğitiminde kullanılan veri setleri, CoRoT hedefleri için yapılan çalışmalardan elde edilmiş veri setleridir. Bu veri setleri CoRoT hedeflerinin ışık eğrileriyle yapılan hesaplamalarından oluşur. Transfer öğrenme için eğitilen temel model metrikleri incelendiğinde doğruluk, duyarlılık, hassasiyet ve f1-skor değerlerinin %94 olduğu bulunmuştur. Değişen yıldızların sınıflandırılmasında transfer öğrenimi yaklaşımı kullanıldığında, daha önce sınıflandırılmış yıldızların bilgileri ve özellikleri yeni yıldızların sınıflandırılmasında kullanılabilir. Çalışmadan elde edilen temel modelin astronomi alanında farklı problemler ve farklı veri setleri için yeniden kullanılabilir olması ve bu alanda çalışan araştırmacılara katkı sağlaması beklenmektedir.

2024 Batman Üniversitesi. Her hakkı saklıdır.

*Bu makale 2-4 Mayıs 2024 tarihleri arasında Batman Üniversitesi'nde düzenlenen Uluslararası Bilişim Kongresi'nde 2024 (IIC2024) sunulan 'Derin Öğrenme ve Transfer Öğrenme Yöntemleri Kullanarak Değişen Yıldızlarda Sınıflandırma' isimli bildiriden türetilmiştir

Classification Of Variable Stars Using Deep Learning and Transfer Learning Methods

Emrullah KUŞTAŞI^{1*}, Mete YAĞANOĞLU²

¹Atatürk University, TURKEY

²Atatürk University, TURKEY

Doi: 10.55024/buyasambid.1501877

ARTICLE INFO

Article Type: Research Article

Article history:

Received: 15.06.2024

Received in revised form:
01.07.2024

Accepted: 02.07.2024

Available online: 07.07.2024

Keywords:

Artificial Intelligence, Machine Learning, Deep Learning, Transfer Learning, Astrophysics, Astroinformatics.

*¹ Emrullah KUŞTAŞI

E-mail address:

emrullahkustasi@gmail.com

Orcid: 0009-0008-4962-9623

² Mete YAĞANOĞLU

E-mail address:

yaganoglu@atauni.edu.tr

Orcid: 0000-0003-3045-169X

ABSTRACT

Classifying variable stars can sometimes be a challenging process using traditional methods. The process by which astronomers classify stars, often by analyzing their brightness curves and other physical properties, can be time-consuming and laborious. The transfer learning approach can play an important role at this point. This study aims to shorten a time-consuming and laborious process by enabling astronomers to do their work by labeling fewer data while classifying stars. A deep neural network was trained for transfer learning and the performance of this model was compared with other machine learning methods. The data sets used in model training are data sets obtained from studies conducted for CoRoT targets. These data sets consist of calculations made with the light curves of CoRoT targets. When the basic model metrics trained for transfer learning were examined, it was found that the accuracy, precision, recall and f1-score values were 94%. When transfer learning approach is used to classify variable stars, the information and properties of previously classified stars can be used to classify new stars. It is expected that the basic model obtained from the study will be reusable for different problems and different data sets in the field of astronomy and will contribute to researchers working in this field.

2024 Batman University. All rights reserved

1. GİRİŞ


Astronomi alanında gözlem yeteneklerimizin gelişmesi, beraberinde büyük boyutlarda verinin ortaya çıkmasına sebep olmuştur. Bu büyük boyutlu verilerin işlenmesi, bilgiye dönüştürülmesi bilgisayar algoritmalarının kullanımını zorunlu kılmıştır. Toplanan veri miktarının artmasıyla birlikte bu alandaki veri madenciliği, büyük veri uygulamaları, makine öğrenmesi ve yapay zekâ uygulamalarının sayısı her geçen gün artmaktadır (Özkan ve Kayhan, 2021).

Değişen yıldızların sınıflandırılması, geleneksel yöntemlerle bazen zorlu bir süreç olabilir. Gökbilimciler, genellikle yıldızların parlaklık eğrilerini ve diğer fiziksel özelliklerini analiz ederek sınıflandırma yaparlar. Ancak, bu süreç zaman alıcı ve zahmetli olabilir. Bu aşamada gökbilimciler çeşitli makine öğrenmesi algoritmalarından da faydalanabilirler.

Özkan ve Kayhan (2021) çalışmalarında astronomi alanında makine öğrenmesi kullanılarak son beş yılda içerisinde 3000'e yakın çalışmanın yapıldığını, çalışmaların hakemli ve hakemsiz dergilerde yayınlanarak toplamda 17000'e yakın atıf aldığını belirtmişlerdir. Azari vd. (2020) çalışmalarına göre astronomide makine öğrenmesi içerikli yayınların yüzdelik dağılımları Şekil 1'de gösterilmiştir. Şekilde NASA (National Aeronautics and Space Administration) SMD (Bilim Misyonu Direktörlüğü) konuları genelinde makine öğreniminin yıllık dağılımları görülürken 2018'de Güneş fiziğine ait yayınların yer bilimlerine ait yayınlardan daha fazla olduğu görülmektedir. Bu durum astronomi alanında makine öğrenmesi algoritmaları kullanımının giderek ne kadar yaygınlaşacağına bir göstergesidir.

Makine öğrenmesi ve sinir ağları algoritmalarının sıklıkla kullanıldığı bu alanda, kullanılan modellerin eğitimi de bu algoritmaların önemli bir aşamasını oluşturmaktadır. Eğitim sürecinde veri setleri, parametre seçimleri, veri ön işleme gibi işlemler modellerin genel performansını doğrudan etkilediğinden, eğitim aşamasının önemi bir kat daha artmaktadır.

Eğitim için yeterli sayıda etiketli veri toplamak, özellikle yeni bir araştırmada ilk aşamalarda zordur (Kim vd., 2021). Bu çalışma ile gökbilimcilerin yıldız sınıflandırması yaparken modellerin eğitiminde karşılaştıkları problemlerin en aza indirgenmesi, daha az sayıda veri etiketlemesi yaparak, zaman alıcı ve zahmetli bir sürecin kısaltılması amaçlanmıştır.



Şekil 1. Astronomide makine öğrenmesi konulu yayınlar (Azari vd.,2020)

Jin-Meng vd. (2021) yıldızların yüzey sıcaklıklarını tespit için rastgele orman algoritması kullanmışlardır. APOGEE (Apache Point Observatory Galactic Evolution Experiment) ve LAMOST (Large Sky Area Multi-Object Fiber Spectroscopic Telescope) veri setlerini kullanarak modellerini eğitmiş, APOGEE’de yaklaşık %94 LAMOST’ta yaklaşık %90 başarı elde etmişlerdir.

Brenton vd. (2019) NASA misyonu Kepler tarafından gözlemlenen güneş benzeri yıldızların yüzey dönüş sürelerini ölçmekle ilgilenmiş, yıldız yaşının yüzey dönüş periyodundan bulmaya çalışmışlardır. Çalışmalarının iki farklı adımında döndürücü sınıflandırması için %89, döndürme periyodunun bulunmasında %97 gibi doğruluk değeri bulmuşlardır. Rastgele orman sınıflandırıcılarının, yıldız dönme özelliklerini incelemek için mükemmel bir araç olduklarını ve büyük veri kümeleriyle başa çıkmalarına olanak sağladıklarını belirtmişlerdir.

Saux vd. (2019) NASA’nın Kepler uydusu K2’nin ikinci görevinde elde ettiği verilerle yıldızları sınıflandırmaya çalışmışlardır. Bu çalışmada, rastgele orman makine öğrenimi tekniği ile titreşen K2 yıldızlarını otomatik olarak sınıflandırmak için bir yöntem sunmuşlardır. Yöntem yıldızları dört sınıfa ayırmaktadır: kırmızı dev (RG), ana dizi Güneş benzeri yıldızlar (SL), klasik pulsatörler (PULS) ve diğerleri. Yıldızların %80’inden fazlası için doğru sınıflandırma yapmışlardır.

Kim vd. (2021) çalışmalarında OGLE (Optical Gravitational Lensing Experiment) (Udalski vd., 1997) ve EROS-2 (Expérience pour la Recherche d’Objets Sombres) (Tisserand vd., 2007) olmak üzere iki farklı araştırmadan elde edilen değişken kaynakların tek bantlı ışık eğrilerinden oluşan veri setleri kullanarak bir yapay sinir ağı eğitmişlerdir. Modeli transfer aktarım yöntemiyle farklı veri setleri üzerinde başarılı bir şekilde çalıştırabildiklerini ifade etmişlerdir.

Sarro vd. (2013) çalışmalarında yüksek çözünürlüklü spektrumlardan türetilen temel parametreleri kullanarak otomatik yıldız değişkenliği sınıflandırması için geliştirilmiş bir yöntem sunmuşlardır. Teff ve logg değerlerini, 6832 CoRoT hedefi için Giraffe spektrumlarından elde etmişlerdir.


Rimoldini vd. (2012) periyodik, periyodik olmayan ve düzensiz ışık değişimleri sergileyen yıldızların otomatik sınıflandırması için HIPPARCOS verisini kullanmışlardır. Rastgele orman ve Bayesian ağları yöntemlerini kullanarak genel yanlış sınıflandırma oranlarının %12’nin altında

gerçekleştiğini ve literatürde belirsiz veya eksik türlere sahip 6051 HIPPARCOS değişkeni için tür tahmininde uygulandığını belirtmişlerdir.

Hon vd. (2017) katlanmış titreşim spektrumlarının görüntülerinden bu görsel özellikleri otomatik olarak öğrenmek için denetimli öğrenme ile 1D evrişimli sinir ağı eğitmişlerdir. Kepler kırmızı devlerinde eğitim ve test yaparak, helyum yanma işlemi gören kırmızı devleri, kırmızı dev koldan yükselenlerden %99'a varan bir doğrulukla ayırmayı başarmışlardır.

2.YÖNTEM

Bu çalışmada astronomi araştırmaları neticesinde açılan verilerden yapılmış çalışmalardan elde edilen veri setleri kullanılmıştır. Şekil 2'de görüldüğü gibi veri seti makine öğrenmesine uygun bir hale getirilmesi için ön işlemlerden geçirilmiş ve DNN (Derin sinir ağları) dahil olmak üzere çeşitli makine öğrenmesi yöntemleri ile modeller eğitilerek performansları değerlendirilmiştir.



Şekil 1. Çalışmanın akış diyagramı

2.1. Veri Seti

CoRoT (Convection, Rotation and planetary Transits), Avrupa Uzay Ajansı (ESA) tarafından geliştirilen bir uzay teleskopu projesidir. CoRoT, yıldızların iç yapılarını, dönüş hızlarını ve gezegen geçişlerini incelemek amacıyla 2006 yılında fırlatılmıştır. CoRoT, uzaydan yıldızları sürekli olarak gözlemleyerek, yıldızların ışık eğrisindeki değişimleri ve gezegenlerin yıldız önünden geçişlerini tespit eder. Bu bilgiler, yıldızların iç yapısını, dönme hızlarını, yerleşik manyetik alanlarını ve gezegenlerin boyutlarını ve yörüngelerini belirlemek için kullanılır.

Bu çalışmada test edilen makine öğrenmesi yöntemleri ve yapay sinir ağları eğitiminde, Corot hedefleri için elde edilen ışık eğrilerinden çıkarılan verilerle oluşturulmuş, Sarro vd. (2013) çalışmalarından elde edilen veri seti kullanılmıştır. Yine transfer öğrenimi testi için Dubath vd. (2011) HIPPARCOS veri seti için yaptıkları çalışma ile üretilen veri seti kullanılmıştır. Bu çalışmada kullanılan veri setleri CDS tarafından sunulan lisans altında kullanılmıştır. Bu lisans, veri setinin ticari olmayan kullanımına kaynak ve lisans bilgilerinin uygun şekilde belirtilmesi şartı ile izin vermektedir.

Veri seti VLT'deki Giraffe spektrografı ile gözlemlenen CoRoT hedeflerini sınıflandırmada kullanılan hem fotometrik zaman serisinden türetilen hem de spektrumlardan türetilen fiziksel parametreleri içerir. Veri setinde yaklaşık 10100 kayıt bulunmaktadır. Ön deneylerde veri setindeki bazı sınıflara ait örnek sayıları çok düşük olduğu için, modeli aşırı uyum problemine götürdüğü görülmüştür. Bu sebeple bu sınıflar veri setinden atılmıştır.

2.2. Veri Ön işleme

Veri ön işleme süreci, sınıflandırma algoritmalarından daha doğru sonuçlar alınması ve daha iyi performans göstermesi amacıyla veri setindeki uygunsuzlukları gidermek için gerekli bir çalışmadır.

Bu aşamada eksik veriler giderilir, hatalı veriler düzeltilir, tekrarlanan kayıtlar silinebilir, sınıflandırmada anlamsız alanlar atılabilir. Bu çalışmadaki veri setindeki en büyük problem veri setinin dengesizliğidir. Bu problemin çözümü için sentetik kayıtlar oluşturularak dengesizliğin giderilebileceği düşünülmüştür.

Dengesiz sınıf dağılımı, yüksek doğruluk değerlerine ulaşmayı engelleyen önemli bir sorundur. Bu soruna çözüm olarak Chawla (2002) tarafından tanıtılan SMOTE (Synthetic Minority Over-sampling Technique) kullanılmıştır. İstatistiksel bir yöntem olan SMOTE azınlık sınıfının örnek sayısını artırarak sınıf dengesini sağlamayı amaçlamaktadır.

2.3. Öznitelikler

Vmag: Yıldızın görünür parlaklığıdır. Görünür büyüklük ölçümüne fotometri denir. Fotometri ise fotometrik sistemlere ait çeşitli filtrelerle birlikte yapılır. Görünür parlaklık değeri kendi ışınma gücüyle ve dünyaya olan uzaklığıyla alakalıdır.

Nu1, Nu2: Yıldızların dönme periyotlarıdır. Yıldızların dönme periyotları, çeşitli faktörlere bağlı olarak değişebilir. Özellikle, yıldızın kütlesi, boyutu ve yaşına bağlı olarak değişen dönme hızları gözlemlenir. Genç yıldızlar genellikle hızlı dönerken, yaşlı yıldızlar daha yavaş dönebilirler. Bu dönme hızları, yıldızın manyetik alanını, yüzey aktivitelerini ve yıldız lekelerini de etkiler.

A11, A21: Yıldız periyotlarının fourrier serisindeki ilk terimin genliğidir. Fourier serisi dönüşümü, bir periyodik fonksiyonun bir dizi sinüs ve kosinüs fonksiyonu toplamına dönüştürülmesi işlemidir. Bu dönüşüm, bir fonksiyonun periyodik bir şekilde genişletilmesi ve daha sonra bu genişletilmiş fonksiyonun sinüs ve kosinüs terimlerine ayrılmasıyla gerçekleştirilir.

Teff1, Teff2: Yıldızın etkin sıcaklığıdır. Yıldızların iç bölgelerindeki termonükleer reaksiyonlar sonucu oluşan enerji, yıldızın yüzeyine ulaşırken kayıp yaşar, bu nedenle yüzey sıcaklığı ile etkin sıcaklık arasında farklar olur. Etkin sıcaklık, bir yıldızın elektromanyetik radyasyonunun hangi dalga boylarında yoğunlaştığını belirlemek için kullanılır. Bir yıldızın etkin sıcaklığı, spektral sınıfını belirlemede ve yıldızın evrimini anlamada önemli bir gösterge olarak kabul edilir.

2.4. Makine Öğrenmesi Yöntemleri

Makine öğrenimi, bilgisayarların geçmiş örneklerden öğrenmesine ve büyük, gürültülü veya karmaşık veri kümelerinden ayırt edilmesi zor kalıpları algılamasına olanak tanıyan çeşitli istatistiksel, olasılıksal ve optimizasyon tekniklerini kullanan bir yapay zekâ dalıdır (Cruz ve Wishart, 2006). Bu çalışmada sadece transfer aktarımı için yalnızca bir DNN eğitilmemiş aynı zamanda bu DNN modelin çeşitli makine öğrenmesi yöntemleriyle de performansları karşılaştırılmıştır.

Makine öğrenmesi modellerinde hiperparametreler, modelin yapılandırılmasını ve eğitimini yönlendiren ayarlamalardır. Bağımlı ve bağımsız değişkenler arasındaki ilişkiyi temsil eden matematiksel fonksiyonlara bağlıdır. Bir regresyon formülündeki bir sabit değer, KNN (K-en yakın komşular) algoritmasındaki komşuluk sayısı, SVM (Destek vektör makinesi) yöntemindeki düzgünleştirme katsayısı gibi değerler uygulanan yöntem için birer hiperparametredir. Her bir problem için bu değerler değişebilir. Hiperparametre ayarı, bir yöntem için modelin performansını olumlu veya olumsuz yönde değiştirir. Makine öğrenmesi çalışmalarında her zaman modelin performansını üst düzeye çıkaracak olan parametreler tespit edilmeye çalışılır. Bu çalışmada hiperparametreler her bir modelde de en iyi metrikleri vermesi için tespit edilmiştir.

Karar Ağaçları

Temel yaklaşım, örneklerden aşamalı olmayan öğrenmedir. Sistemler, bir sınıflandırma göreviyle ilgili bir dizi durumla sunulur ve örneklerin verildiği belirli sıraya göre değil, örneklerdeki frekans bilgilerine göre yukarıdan aşağıya bir karar ağacı geliştirir (Quinlan, 1986). Bu ağaçlar, veri setindeki bilgileri en iyi şekilde bölecek ve genelleme yeteneği yüksek modeller oluşturacak şekilde eğitilirler.

Ağaç yapısı yapraklar ve karar düğümlerinden oluşur. Kökten başlayarak her karar düğümü girdiye bir bölme sınaması uygular ve sonuca göre dallardan biri alınır. Bir yaprağa ulaşıldığında arama durur. Burada örneğin hangi sınıfa ait olduğuna karar verilir.

Karar ağacı kurallardan oluşan bir kural tabanına dönüştürülebilir ve kuralların yorumlanmasını kolaylaştırır. Kara ağacı öğrenmesi parametrik değildir, böylece ağaç ihtiyaç duyulduğunda büyür (Alpaydın, 2019). Bu gibi durumlar karar ağaçlarının avantajları arasında yer alır.

Rastgele Orman

Rastgele ormanlar, birçok karar ağacının bir araya gelerek oluşturduğu bir ensemble (topluluk) yöntemidir. Her bir karar ağacı, farklı bir alt veri kümesi ve özellik kümesiyle eğitilir. Böylece, genellikle daha güçlü, daha kararlı ve daha az aşırı öğrenmeye eğilimli modeller üretilir.

Rastgele orman algoritmasına göre ilk olarak eğitim verisinden örnekler alınarak farklı alt kümeler oluşturulur. Her bir alt küme için bir karar ağacı oluşturulur. Bu süreçte her düğüm için rastgele bir özellik alt kümesi kullanılır. Bu durum aşırı uyum riskini azaltır. Sonraki aşamada tahmin edilen her bir hedef için oylar hesaplanır ve en yüksek oyu alan tahmin seçilir.

Rastgele orman algoritması hem regresyon hem de sınıflandırma problemlerinde kullanılabilir. Bu algoritma aşırı uyum problemini önlemektedir. Ayrıca mevcut özellikler arasından en önemli özelliği tanımlamak için de kullanılabilir (Çebi, 2020). Bu özellikler rastgele orman algoritmasının avantajları olarak gösterilir.

K-En Yakın Komşular (KNN)

Makine öğrenmesinde, sınıflandırma ve regresyon problemlerini çözmek için kullanılan basit ve etkili bir algoritmadır. Temel yaklaşım, bir veri noktasını etiketlemek veya tahmin etmek için, ona en yakın olan k komşusunun etiketlerini veya değerlerini kullanmaktır. En yakın noktalar bulunurken öklit, manhattan ve minkowski uzaklık değerlerine bakılır.

KNN algoritması uygulanması kolay bir algoritmaya sahip olması, sınıflandırma ve regresyon için kullanılabilmesi avantajları olarak görülmektedir. Ancak, bağımsız değişkenlerinin artmasıyla birlikte yavaşlaması, yüksek hafıza ihtiyacı, örnek sayısının artmasına paralel olarak tahmin süresinin artması dezavantajları olarak karşımıza çıkmaktadır (Atıcı 2022).

Destek Vektör Makinesi

Makine kavramsal olarak şu fikri uygular: giriş vektörleri, çok yüksek boyutlu bir özellik uzayına doğrusal olmayan bir şekilde eşlenir. Bu özellik uzayında doğrusal bir karar yüzeyi oluşturulur. Karar yüzeyinin özellikleri, makinenin yüksek genelleme yeteneği kazanmasını sağlar (Cortes, 1995). Destek vektör makinesi, veri noktaları arasındaki en büyük marjı (mesafe) maksimize etmeye çalışarak noktaları birbirinden en iyi şekilde ayıran, bir karar sınırı belirler. Veri doğrusal olarak ayrılabilirse bir hiper düzlem bulur, eğer veri doğrusal ayrılmıyorsa veriyi çok boyutlu özellik uzayına dönüştürerek doğrusal ayrıştırılabilir hale getirir.

Naive Bayes

Naive Bayes sınıflandırıcı, olasılığa dayalı bir makine öğrenimi sınıflandırma algoritmasıdır ve Bayes teoremini esas alır. Sınıflandırıcı bir eleman için her durumun olasılığını hesaplar ve olasılık değeri en yüksek olana göre sınıflandırır (Hatipoğlu 2023). Test kümesindeki bir veri eğitim kümesinde gözlemlenemiyorsa tahmin yapmaz. Bayes sınıflandırıcı, her özneliğin birbirinden koşulsal bağımsız olduğu ve öğrenilmek istenen kavramın tüm bu özneliklere koşulsal bağlı olduğu bir Bayes ağı olarak da düşünülebilir (Anonim, 2023).

2.5. Derin Öğrenme

Yapay sinir ağları biyolojik canlılardaki sinir ağlarından esinlenerek geliştirilmiş matematiksel model ve algoritmalarından oluşan yapay zekanın alt dalıdır. Yapay sinir ağları tahmin modelleri geliştirmek için oluşturulmuş istatistiksel bir yaklaşımdır (Staub vd.,2015). İlk yapay sinir ağı modeli 1943 yılında Warren McCulloch ve Walter Pitts tarafından geliştirilmiştir.

Derin öğrenme, yapay sinir ağları ve benzeri makine öğrenme algoritmalarını içeren bir alanı kapsar, bu algoritmalarda birden fazla gizli katman bulunur. Yani, birbirine bağlı çok katmanlı bir yapay sinir ağı kullanılarak bilgisayarın mevcut verilerden yeni veriler elde etmesini sağlayan bir çalışma alanıdır. Hinton vd. (2006) çalışmalarında, derin öğrenme (Deep Convolutional Neural Network) adı verilen yeni bir yaklaşımı ortaya koymuştur ve çalışmalarıyla yapay sinir ağlarına yeni bir perspektif kazandırmıştır.

Derin öğrenme, gözetimli, yarı gözetimli veya gözetimsiz bir şekilde gerçekleştirilebilir. Ayrıca, pekiştirmeli öğrenme yaklaşımı da derin yapay sinir ağları ile başarılı bir şekilde uygulanabilir (Doğan ve Türkoğlu, 2019).

Temel bir sinir ağı, girdi ve çıktı katmanları arasında bir veya iki gizli katman içerebilirken, derin öğrenme ağları, düzinelerce hatta yüzlerce katmana sahip olabilir. Bu fark, modelin karmaşıklığını ve öğrenme kapasitesini artırma potansiyelini temsil eder. Ancak, daha fazla katman eklemek aynı zamanda daha fazla parametre ve hesaplama kaynağı gerektirir.

Derin öğrenme, sinir ağı katmanları aracılığıyla ham verileri alır ve bu bilgileri sınıflandırır. Örneğin, bir sinir ağı kuş görüntüleriyle eğitildiğinde, kuşları tanımak için kullanılabilir. Daha fazla katman eklemek, örneğin güvercini kartaldan ayırt etmek gibi daha kesin sınıflandırmalar elde etmeye yardımcı olabilir. Ancak, bu ekstra karmaşıklık daha fazla veri ve hesaplama gücü gerektirebilir.

Her bir katman, ağı öğrenme sürecine katkıda bulunur. Girdi katmanı, ham verileri alır; gizli katmanlar, bu verileri daha soyut ve yüksek düzeyli özelliklere dönüştürmekten sorumludur; çıktı katmanı, bu özellikleri belirli bir sınıfa veya değere atar. Daha fazla gizli katman eklemek, ağı daha karmaşık ve özelleştirilmiş özellikler öğrenmesine olanak tanır, ancak aynı zamanda eğitim sürecini zorlaştırabilir.

Derin öğrenme modellerindeki katmanlar, bilgiyi önceki katmanlardan alarak ve ardından bu bilgileri bir sonraki katmana ileterek modelin mimarisini oluşturan temel yapı taşlarıdır.

Giriş katmanı, ham girdi verilerini alır ve önceden tanımlanmış filtrelerle ön işleme yaparak, orijinal görüntüye ek bilgiler ekler ya da orijinal veri matrisini düzleştirerek model girişine uygun hale getirir.

Aktivasyon katmanı çıktıların belirli bir aralığa sınırlanması veya belirli bir formu alması için kullanılan bir matematiksel işlemler setidir. Bu katman, ağı öğrenme kapasitesini artırmak, modelin doğrusallık dışında öğrenmesini sağlamak ve ağı daha karmaşık örüntüleri öğrenmesine yardımcı olmak amacıyla kullanılır. Sık kullanılan bir aktivasyon fonksiyonu, rectified linear unit (ReLU) fonksiyonudur. ReLU, $f(x)=\max(0,x)$ şeklinde ifade edilir ve giriş değeri negatifse sıfır, pozitifse kendisi olarak çıktı üretir. Bu, doğrusallık olmayan bir özellik ekleyerek ve ağı daha karmaşık örüntüleri öğrenmesine yardımcı olarak ağı performansını artırabilir. ReLU'dan farklı olarak sigmoid, tanh ve softmax gibi fonksiyonlar da bulunur.

Dropout, yapay sinir ağlarında kullanılan bir regülerleme tekniğidir ve ağı ezberlenmesini önlemek için tasarlanmıştır. Ezberleme (overfitting), bir modelin eğitim verilerine aşırı derecede uyum sağlaması, ancak yeni ve görülmemiş verilere genellenme yeteneğinin düşük olması durumunu ifade eder. Dropout katmanında, eğitim sırasında rastgele seçilen nöronlar (veya düğümleri) belli bir olasılıkla devre dışı bırakılır. Yani, her eğitim örneğini işlerken, her bir nöronun devre dışı bırakılma olasılığı vardır. Bu devre dışı bırakılan nöronlar, o eğitim adımında modelin öğrenme sürecine katılmazlar.

Tam bağlı katman, bir önceki katmandaki tüm nöronlarla bağlantılıdır, yani her bir çıkış nöronu, giriş katmanındaki tüm nöronlarla ilişkilidir. Aynı zamanda yoğun katman olarak da adlandırılır. Tam

bağlı katmanın temel amacı, önceki katmanlardan gelen özellikleri kullanarak final sınıflandırmayı gerçekleştirmektir ve geriye yayılım algoritması ile eğitilirler.

Bu katmanlar, derin öğrenme modellerinde farklı işlevlere sahiptir ve birlikte çalışarak karmaşık veri setlerinden anlam çıkarılmasını sağlar. Her katmanın özel rolü, modelin genel performansını etkiler.

Hata fonksiyonları, bir modelin tahminlerinin gerçek değerlere olan uzaklığını ölçerek eğitim sırasında optimize edilmesi gereken bir metrik sunar. Bu fonksiyonlar, modelin performansını değerlendirmek ve geliştirmek adına kritik öneme sahiptir (Fortuner, 2023).

Öğrenme oranı (learning rate), bir makine öğrenimi modelinin, eğitim sırasında ağırlıklarını ve bias'larını güncellerken kullanılan bir hiperparametredir. Gradyan inişi (gradient descent) gibi optimizasyon algoritmalarında, her güncelleme adımının boyutunu kontrol etmek için kullanılır. Öğrenme oranı, her eğitim iterasyonunda güncellenen parametre değerlerine çarpan bir ölçekleme faktörüdür. Bu oranın değeri genellikle 0 ile 1 arasındadır. Öğrenme oranının seçimi, modelin hızlı ve etkili bir şekilde öğrenmesini etkileyen önemli bir faktördür.


Yüksek öğrenme oranında modelin hızlı bir şekilde öğrenmesine neden olur. Ancak bu durum geçebileceği minimum noktaları atlmasına ve istikrarlı bir şekilde yaklaşmaktansa uzaklaşmasına sebep olabilir. Bu durumda, modelin ağırlıkları ve bias'ları çok hızlı bir şekilde güncellenir, bu da bir optimizasyon probleminin çözümüne ulaşamamasına neden olabilir (Eğrioğlu vd., 2020).

Düşük öğrenme oranında modelin daha istikrarlı bir şekilde öğrenmesine neden olur. Bu durumda da daha yavaş bir öğrenme hızına sahip olur. Bu durumda, modelin minimuma yaklaşması daha stabil olabilir, ancak bu da eğitim sürecinin daha uzun sürmesine neden olabilir.

Optimal öğrenme oranı, spesifik bir problem ve veri seti için ampirik olarak belirlenir. Genellikle, eğitim sürecinin başlarında farklı öğrenme oranları denemek ve modelin performansını gözlemlemek yararlı olabilir. En iyi öğrenme oranını bulmak, grid search veya random search gibi yöntemlerle gerçekleştirilir.

Optimizasyon algoritmaları derin öğrenme modellerinin öğrenme sürecini yönlendiren stratejilerdir. Bu algoritmalar, modelin parametrelerini ağırlıklar ve bias'larını güncelleyerek, hata fonksiyonunu minimize etmeyi hedefler. Bu süreç, modelin gerçek değerlerle tahminleri arasındaki farkı en aza indirerek, daha doğru ve genelleştirilebilir tahminler elde etmesi için gerçekleştirilir.

Optimizasyon algoritmaları, ağı eğitirken hatayı azaltma amacını taşır ve genellikle gradiyan inişi (gradient descent) veya türevlerini kullanarak hata fonksiyonunun minimum noktasına doğru ilerlemesini sağlar. Bu algoritmalar, belirli bir öğrenme oranını (learning rate) ve diğer hiperparametreleri ayarlayarak, modelin başarıyla öğrenmesini sağlamak için çeşitli stratejiler kullanır. Modelin doğruluğunu ve genelleme yeteneğini artırmak amacıyla kullanılan optimizasyon algoritmaları, makine öğrenimi uygulamalarında temel bir rol oynar (Eğrioğlu vd., 2020). Gradyan inişi, stokastik gradiyan inişi, momentum, Adagrad, RMSprop, Adam ve AdaDelta gibi çeşitli optimizasyon algoritmaları, farklı problem tiplerine ve veri setlerine göre uygun olanı seçme esnekliği sunar.



Şekil 2. DNN Model

Bu çalışmada oluşturulan modelde Şekil 3'deki gibi bir giriş katmanı, üç gizli katman ve bir çıkış katmanı kullanılmıştır. İlk gizli katmanda 64, ikinci katmanda 128 ve üçüncü katmanda 576 nöron kullanılmıştır. Aktivasyon fonksiyonu gizli katmanlarda RELU, son katmanda Softmax seçilmiştir. Optimizasyon algoritması olarak Nadam kullanılmıştır.

2.6. Transfer Öğrenme

Transfer öğrenme makine öğrenmesi yöntemlerinin de aynı bizim gibi bir problemi çözerken elde ettiği bilgiyi saklayıp, başka bir problem ile karşılaştığında o bilgiyi kullanmasıdır. Öğrenme aktarımı ile önceki bilgiler kullanılarak daha az eğitim verisi ile daha yüksek başarı gösteren ve daha hızlı öğrenen modeller elde edilir (Yiğit ve Yeğin, 2023).

Çalışmada önceden eğitilen modele temel model, aktarım yapılacak modele ise transfer model adı verilmiştir.

Problem çözümü için bilgi aktarımı yaparken, kaynak ve hedef veri setlerine bağlı olarak farklı problemler ortaya çıkmaktadır. Çünkü her farklı veri seti kendine özgü bir iz taşır.

Sınıf sayısı ve sınıf türleri ilk problemidir. Temel modelin eğitiminde kullanılan veri setindeki sınıf sayısı ile transfer modelde kullanılacak veri setindeki sınıf sayısı farklı olabilir. Daha da önemlisi sınıf türlerinin farklı olmasıdır.

İkinci büyük problem ise farklı özelliklerdir. Astronomi alanında kendine özgü her bir araştırmada objelerin değerlendirilmesinde kullanılan parametreler farklı olabilir. Örneğin değişen yıldız sınıflandırmasında kullanılan değişim genliği, ışık eğrisi biçimi, tayf türü, yüzey çekim ivmesi gibi parametrelerden bazıları bir çalışmada kullanılırken bir diğer çalışmada kullanılmayabilir. Üstelik filtre dalga boyları, büyüklük aralıkları gibi özelliklerde farklı olabilir. Bu gibi sorunların üstesinden gelmek için katmanları dondurmak ve katmanların ağırlıklarını yeniden optimize etmek gibi çözümler kullanılmalıdır.

Çalışmada önceden eğittiğimiz DNN model burada kullanmıştır. Yeni veri seti model eğitimi için uygun hale getirildikten sonra önceden eğitilmiş modelden bilgi aktarımı için bazı katmanlar yeni modele eklenerek ince ayar yapılmıştır.

Bu çalışmada temel modelden giriş katmanı ve gizli katmanlar alınmış çıkış katmanı alınmamıştır. Bu katmanların önüne transfer modelin veri setine uygun olacak yeni bir giriş katmanı eklenmiş, modelin çıkışına ise bağımlı değişkenin farklı sınıflarına uygun olacak yeni bir softmax çıkış katmanı eklenmiştir. Ayrıca ön deneylerde eğitim-validasyon-doğruluk grafiklerinden transfer modelin aşırı uyum sorununa gittiği görüldüğünden, katmanlar arasına dropout katmanları eklenmiştir.

3. BULGULAR

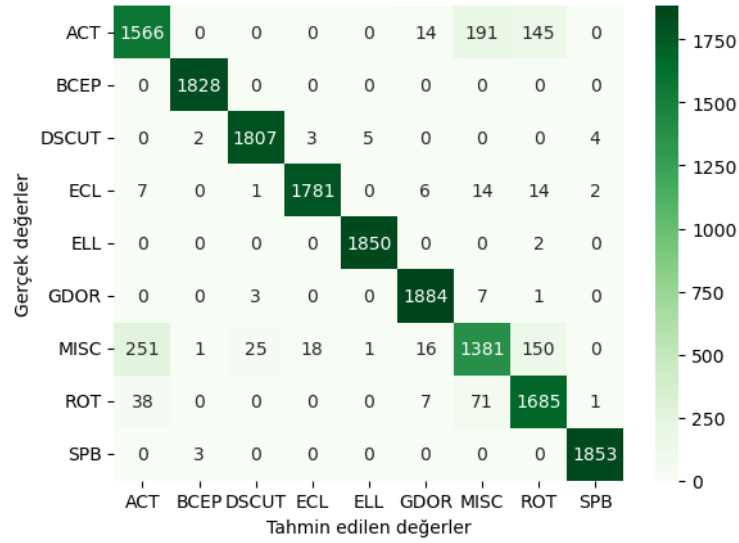
Çalışmada makine öğrenmesi modelleri ve temel model eğitimi için veri setinin %80'i eğitim, %20'si test için kullanılırken, transfer modelde veri setinin %20'si eğitim, %80'i test için kullanılmıştır. Modellerin performansı karmaşıklık matrisi ile elde edilen metriklerle ortaya konmuştur.

Karmaşıklık matrisi sınıflandırma modelinin performansını değerlendirmek için kullanılan bir metriktir. Gerçek ve tahmin edilen sınıflar arasındaki ilişkiyi gösteren bir matristir. Her bir hücre, gerçek sınıf ve tahmin edilen sınıf kombinasyonlarına göre örnek sayılarını içerir. Bu matris, modelin hangi sınıfları ne kadar doğru sınıflandırdığını ve hangi hataların yapıldığını gösterir.

Tablo 1. Temel Model Metrikleri

Sınıf	Hassasiyet	Duyarlılık	F1-Score
ACT	0.84	0.82	0.83
BCEP	1.00	1.00	1.00
DSCUT	0.98	0.99	0.98
ECL	0.99	0.98	0.98
ELL	1.00	1.00	1.00
GDOR	0.98	0.99	0.98
MISC	0.83	0.75	0.79
ROT	0.84	0.94	0.89
SPB	1.00	1.00	1.00

Temel DNN modele ait karmaşıklık matrisi Şekil 4’de gösterilmiştir. Şekle incelendiğinde modelin ACT ve MISC sınıflarında kayda değer sayıda hatalı sonuçlar ürettiği görülmektedir. Yönteme ait doğruluk değeri %94 iken diğer metrikler Tablo 1’de verilmiştir. Tabloya göre modelin, ACT, MISC ve ROT sınıfları haricinde yüksek bir sınıflandırma performansı verdiği görülmektedir.



Şekil 4. Temel model karmaşıklık matrisi

3.1. Performans Metrikleri

Karmaşıklık matrisi kullanılarak hesaplanan metrikler bu kısımda verilmiştir. Tablo 2’de metrikler için formüller verilmiştir.

Doğruluk (Accuracy): Doğru olarak sınıflandırılan örneklerin oranıdır. Modelin doğru olarak sınıflandırdığı örnek sayısının, toplam örnek sayısına oranıdır.

Hassasiyet (Precision): Belirli bir sınıf için doğru tahmin edilen örnek sayısının, doğru veya yanlış bu sınıf cinsinde tahmin edilen örnek sayısına oranıdır. İki sınıflı bir problemde gerçek pozitiflerin toplam gerçek pozitif örnek sayısına oranıdır.

Duyarlılık (Recall): Bir sınıf için doğru tahmin edilen örnek sayısının, sınıfın örnek sayısına oranıdır.


F1-Score: Hassasiyet ve duyarlılığın harmonik ortalamasıdır. Özellikle dengesiz veri setlerini değerlendirmek için önemli bir parametredir.

Özgüllük (Specificity): İki sınıflı bir problem için gerçek negatiflerin, toplam negatif tahminlere oranıdır.


Tablo 2. Metrik formülleri

Metrik	Formül
Doğruluk	$\frac{TP + TN}{TP + FP + TN + FN}$
Hassasiyet	$\frac{TP}{TP + FP}$
Duyarlılık	$\frac{TP}{TP + FN}$
F1- Score	$2 \frac{Hassasiyet * Duyarlılık}{Hassasiyet + Duyarlılık}$
Özgüllük	$\frac{TN}{TN + FP}$

ROC Eğrisi: Modelin TPR ve FPR özellikleri arasındaki ilişkiyi gösterir ve sınıflandırma problemlerinde kullanılan bir performans metriğidir. ROC eğrisi, farklı bir eşik değeri kullanıldığında modelin ürettiği TPR ve FPR değerlerini çizgisel olarak gösterir. Eşik değeri, sınıflandırma problemleri için olasılık değerlerine göre ne şekilde bir sınıflandırma yapılması gerektiğinin bir kriteridir (Anonim, 2024). ROC eğrisi, ideal bir sınıflandırıcı için sol üst köşeden geçer. Bu nokta hem true positive (TP) hem de true negative (TN) oranlarının yüksek olduğu noktadır. Şekil 5'te temel model için One-vs-Rest yöntemi ile çizdirilen ROC eğrisi verilmiştir. Şekilde tüm sınıflar için eğri sol üst köşeye yakındır. Bu durum modelin iyi bir sınıflandırma performansı gösterdiğini ifade eder.




Şekil 3. Temel model ROC eğrisi



Şekil 4. Temel modelin eğitim-validasyon-doğruluk grafiği

Modelin aşırı uyum problemine uğrayıp uğramadığı ve genel performansı hakkında bilgi edinmek için Eğitim-Doğrulama grafiklerine bakılabilir. Şekil 6'da temel modelin eğitim-validasyon-doğruluk grafiği verilmiştir. Grafik incelendiğinde modelin %90'lık başarı seviyesine ulaşması yaklaşık 100 devirde olmuştur ve modelin aşırı uyuma gitmediği de gözlemlenebilir.




Şekil 5. Transfer model karmaşıklık matrisi

Transfer modele ait karmaşıklık matrisi Şekil 7'de verilmiştir. Şekil incelendiğinde modelin DCEPS, BE+GCAS, ELL, SPB türünde çok sayıda hatalı tahminler yaptığı görülmektedir. Yönteme ait doğruluk değeri %84 iken diğer metrikler Tablo 3'de verilmiştir. Tablo incelendiğinde sınıflandırıcının, en yüksek RRAB sınıfında, en düşük EB ve SPB sınıfı yıldızlar için sınıflandırma performansı gösterdiği görülür.

Tablo 3. Transfer model metrikleri

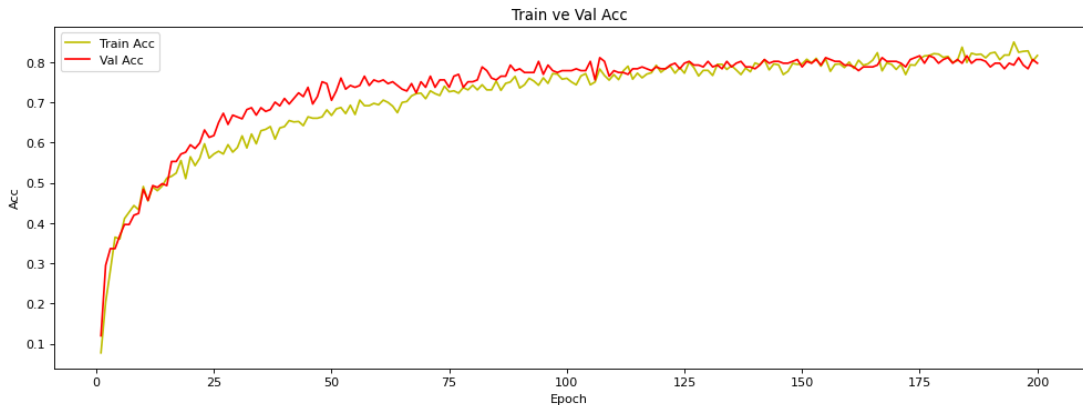
Sınıf	Hassasiyet	Duyarlılık	F1-Score
ACV	0.91	0.74	0.81
ACYG	0.82	0.97	0.89
BCEP	0.91	0.93	0.92
BE+GCAS	0.73	0.75	0.74
CEP (B)	0.86	0.96	0.90

DCEP	0.86	0.77	0.81
DCEPS	0.77	0.86	0.82
DSCT	0.76	0.77	0.77
DSCRC	0.77	0.84	0.80
EA	0.92	0.76	0.83
EB	0.63	0.51	0.56
ELL	0.75	0.71	0.73
EW	0.84	0.87	0.85
GDOR	0.95	0.98	0.96
LPV	0.94	0.96	0.95
RRAB	0.99	0.86	0.92
RRC	0.84	1.00	0.92
RS+BY	0.95	0.91	0.93
SPB	0.72	0.77	0.74



Şekil 6. Transfer model ROC eğrisi

Şekil 8’de transfer model için One-vs-Rest yöntemi ile çizdirilen ROC eğrisi verilmiştir. Şekilde EB sınıfı hariç diğer tüm sınıflar için eğri sol üst köşeye yakındır. Bu durum modelin EB sınıfı için düşük bir sınıflandırma performansı gösterdiğini, diğer sınıflar için iyi bir sınıflandırıcı performansı gösterdiğini ifade eder.



Şekil 7. Transfer model eğitim-validasyon-doğruluk grafiği

Transfer modelin aşırı uyum problemine uğrayıp uğramadığı ve genel performansı hakkında bilgi edinmek için eğitim-validasyon-doğrulama grafiğine bakılır. Şekil 9'da temel modelin eğitim-validasyon-doğruluk grafiği verilmiştir. Grafik incelendiğinde modelin en yüksek başarı seviyesine ulaşması yaklaşık 175 devirde olmuştur ve modelin aşırı uyuma gitmemiştir.

Tablo 4. Çalışmada kullanılan yöntemlere ait metrikler

Sınıflandırıcı	Doğruluk	Hassasiyet	Duyarlılık	F1-Score
Rastgele orman	0.97	0.97	0.97	0.97
Destek vektör makinesi	0.87	0.87	0.87	0.87
Naive Bayes	0.66	0.72	0.72	0.72
KNN	0.95	0.95	0.95	0.95
Karar ağaçları	0.95	0.95	0.95	0.95
Temel DNN model	0.94	0.94	0.94	0.94
Transfer model	0.84	0.84	0.84	0.84

Makine öğrenmesi yöntemleri, temel model ve transfer model dahil olmak üzere çalışmada kullanılan tüm yöntemlere ait metrikler Tablo 4'te verilmiştir. Tablo incelendiğinde, bu alanda daha önceden yapılan diğer çalışmalara paralel sonuçlar elde edildiği, rastgele orman yönteminin, en yüksek değerleri verdiği, Bayes sınıflandırıcısının ise en kötü değerleri verdiği görülür.

4. TARTIŞMA

Bu çalışmada, değişen yıldız sınıflandırmasında transfer öğrenme yönteminin etkinliği değerlendirilirken, aynı zamanda diğer makine öğrenmesi yöntemlerinin bu alandaki performansları da test edilmiştir.

Seçilen veri seti astronomi alanındaki bir araştırmadan elde edilen veri setidir. Bu kaynak araştırma yapılırken temel parametreler araştırmacı tarafından seçildiği için, yeniden öznitelik seçimi yapılmamıştır. Eğitim için kullanılan veri seti doğrudan uzay araştırmalarından değil, bir uzay araştırması için yapılmış çalışmadan elde edilen veri setidir. Bu durum hem öznitelik seçimi yaparken hem de yıldız sınıflandırmasında etkin olmayan özniteliklerin hiç ortaya gelmemesi ile, eğitim aşamasının kısa sürede tamamlanmasına avantaj sağlamıştır.

Makine öğrenmesi yöntemlerinden elden elde edilen sonuçlara göre en iyi performansı %97'lik bir doğruluk değeri ile rastgele orman yöntemi gösterirken, en düşük performansı %65 ile Naive Bayes göstermiştir. Veri seti başta dengesiz olduğu için doğruluk değeri tek değerlendirilen metrik olmamıştır.

ROC eğrileri incelendiğinde bazı sınıfların BCEP, ELL ve SBP gibi sınıflarda modellerin çok yüksek performans gösterdiği görülmektedir. Bunun sebebi diğer sınıf türlerindeki örnek sayısının çok olmasına karşın bu türdeki kayıt sayısı oldukça azdı. SMOTE uygulanırken bu sınıflara ait kayıtlar çoğaltıldığı için eğitim ve test olarak bölünen veride değer olarak birbirine yakın değerli kayıtların bölündüğü tahmin edilebilir. Bu durum doğruluk haricinde diğer metrikleri de üst seviyede tutmaktadır.

Metrikler incelendiğinde tüm modellerin MISC sınıfında performanslarının çok düştüğü görülmüştür. Bu sınıf özünde diğer sınıflara uymayan, belirli bir sınıfa dahil edilemeyen yıldızlar için kullanılan bir sınıftır. Bu sebeple problemin bu çalışmadaki modellere veya farklı çalışmalara özgü olmayıp genel bir problem olduğu ortadadır.

Transfer aktarımı için eğitilen temel model metrikleri incelendiğinde doğruluk değerinin %94 olduğu görülür. Tartışılan problemlerin diğer yöntemlerde olduğu gibi transfer model için de geçerli olduğu görülmektedir.

Çalışmanın odak noktası olan transfer öğrenimi için farklı bir veri setinin model üzerinde denenmesi mümkün olabilir. Bu çalışmada Dubath vd. (2011) çalışmasından alınan veri seti örnek olarak seçilmiştir. Model metriklerine bakıldığında doğruluk oranının %84 olduğu görülür. Farklı veri setleri ile model performansı yeniden değerlendirilebilir.

5. SONUÇ

Astronomi alanında önceki çalışmalarda veri setleri, yöntemler, problemler farklı olmakla birlikte, metrikler yaklaşık olarak %87 ile %95 arasında değişmektedir. Bu çalışma daha önceki yapılan çalışmalar ile kıyaslandığında metrikler Tablo 5’de görüldüğü gibi, diğerlerine benzer sonuçlar üretmiştir.

Ağırlıklı olarak rastgele orman ve çeşitli makine öğrenmesi yöntemlerinin tercih edildiği diğer çalışmalara kıyasla, bu çalışmada bir DNN model kullanılması, model katmanlarını araştırmacıların kendi çalışmalarına dahil etmesini kolaylaştıracaktır. Ancak araştırmacıların katman aktarımı yaparken hedef veri setindeki sınıf sayısı, sınıf türleri, farklı özellikler gibi durumlara dikkat etmesi gerekmektedir. Ayrıca oluşturulacak yeni modelin eğitiminde aşırı uyum problemine gidip gitmediği kontrol edilmeli, gerekirse dropout katmanı ekleme gibi çözüm yollarına başvurulmalıdır.

Tablo 4. Çalışmanın benzer çalışmalarla karşılaştırılması

Çalışma	Yıl	Açıklama	Sonuç
Jin Meng vd.	2021	Yıldızların yüzey sıcaklıkları tespiti için rastgele orman sınıflandırıcısı	0.90-0.94 (ACC)
Brenton vd.	2019	Yıldızların yüzey dönüş sürelerini tespiti için Rasgele Orman sınıflandırıcısı	0.87 (ACC)
Saux vd.	2019	Kepler K2 görevi yıldız sınıflandırma için rastgele orman sınıflandırıcısı	0.80 (ACC)
Kim vd.	2021	Eğitim için OGLE ve EROS-2 veri setleri kullanarak DNN model	0.94 (MCC)
Dubath vd.	2011	HIPPARCOS hedefleri için rastgele orman sınıflandırıcısı	0.90-1.00 (ACC)
Rimoldini vd.	2012	HIPPARCOS verisi ile yıldızların sınıflandırılması için rastgele orman ve Bayesian ağları	0.88 (ACC)
Hon vd.	2017	Zonklayan yıldızların sınıflandırılması için Evrişimli sinir ağı	0.99 (ACC)
Bu çalışma	2023	Değişen yıldızların sınıflandırılması için DNN model	0.94 (ACC)

Gökbilimcilerin, genellikle yıldızların parlaklık eğrilerini ve diğer fiziksel özelliklerini analiz ederek sınıflandırma yaptıkları süreç zaman alıcı ve zahmetli olabilir. Transfer öğrenimi yaklaşımı, bu noktada önemli bir rol oynayarak bu süreçleri kısaltabilir.

Değişen yıldızların sınıflandırılmasında transfer öğrenimi yaklaşımı kullanıldığında, daha önce sınıflandırılmış yıldızların bilgileri ve özellikleri yeni yıldızların sınıflandırılmasında kullanılabilir. Bu, gökbilimcilerin yeni yıldızları sınıflandırmak için daha az bir çaba ile az bir veri etiketlemesini gerektirecek ve süreci hızlandıracaktır.

6. KAYNAKÇA

Alpaydın, E. (2019). Makine öğrenmesi. İstanbul: *Ufuk açan yayınlar*.

Anonim, (2023). Naive Bayes, https://tr.wikipedia.org/wiki/Naive_Bayes_sınıflandırıcısı. Erişim tarihi: 03.09.2023.

- Anonim, (2024). ROC ve AUC eğrileri, <https://devreyakan.com/roc-ve-auc-egri-leri>. Erişim Tarihi:06.02.2024.
- Atıncılı, A. (2022). <https://medium.com/machine-learning-türkiye/knn-k-en-yakın-komşu-7a037f056116>. (28.05.2024)
- Azari, A. R., Biersteker, J. B., Dewey, R. M., Doran, G., Forsberg, E. J., Harris, C. D., ve Himes, M. D. (2020). Integrating Machine Learning for Planetary Science: Perspectives for the Next Decade. *NRC Planetary Science and Astrobiology*. <https://doi.org/10.48550/arXiv.2007.15129>
- Breton, S., Bugnet, L., Santos, A., Saux, A. L., Mathur, S., Palle, P., ve Garcia, R. (2019). Determining surface rotation periods of solar-like stars observed by the kepler mission using machine learning techniques. *Societ'e Francaise d'Astronomie et d'Astrophysique*. <https://doi.org/10.48550/arXiv.1906.09609>
- Chawla, N. V., Bowyer, K. W., Hall, L. O., ve Kegelmeyer, W. P. (2022). SMOTE: Synthetic Minority Over-sampling Technique. *Journal of Artificial Intelligence Research*. <https://doi.org/10.1613/jair.953>
- Cortes, C. V. (1995). Support-vector networks. *Mach Learn*. <http://dx.doi.org/10.1007/BF00994018>
- Cruz, J. A., ve Wishart, D. S. (2006). Applications of machine learning in cancer prediction and prognosis. *Cancer informatics*. <https://doi.org/10.1177/117693510600200030>
- Çebi, C. (2020). <https://medium.com/@cemthecebi/rastgele-orman-algoritması-1600ca4f4784>. 28.05.2024
- Doğan, F., ve Türkoğlu, İ. (2019). Derin Öğrenme Modelleri ve Uygulama Alanlarına İlişkin Bir Derleme. *DÜMF Mühendislik Dergisi*. <https://doi.org/10.24012/dumf.411130>
- Dubath, P., Rimoldini, L., Süveges, M., Blomme, J., López, M., Sarro, L. M., ve Eyer, L. (2011). Random forest automated supervised classification of Hipparcos periodic variable stars. *Monthly Notices of the Royal Astronomical Society*. <https://doi.org/10.1111/j.1365-2966.2011.18575.x>
- Eğrioğlu, E., Yolcu, U., ve Baş, E. (2020) Yapay Sinir Ağları- Öngörü ve Tahmin Uygulamaları. *Nobel Akademik Yayıncılık*.
- Fortuner, B. Loss Functions. https://github.com/bfortuner/ml-glossary/blob/master/docs/loss_functions.rst. Erişim Tarihi: 27.09.2023
- Hatipoğlu, E. (2023) <https://medium.com/@ekrem.hatipoglu/machine-learning-classification-naive-bayes-part-11-4a10cd3452b4>. Erişim tarihi: 29.08.2023
- Hinton, G. E., ve Salakhutdinov, R. R. (2006) Reducing the dimensionality of data with neural networks. *Science*. <https://doi.org/10.1126/science.1127647>
- Hon, M., Stello, D., ve Yu, J. (2017). Deep learning classification in asteroseismology. *Monthly Notices of the Royal Astronomical Society*. <https://doi.org/10.1093/mnras/stx1174>
- Jin-Meng, Y., Xiao-Qing, W., ve min, Z. (2021). The regression of effective temperatures in APOGEE and LAMOST. *New Astronomy*. <https://doi.org/10.1016/j.newast.2020.101568>
- Kim, D.W., Yeo, D., Bailer-Jones, C. A., ve Lee, G. (2021). Deep Transfer Learning for Classification of Variable Sources. *Astronomy & Astrophysics*. <https://doi.org/10.48550/arXiv.2106.00187>
- Ochsenbein F. vd. The VizieR database of astronomical catalogues. <https://doi.org/10.26093/cds/vizieR>
- Quinlan, J. (1986). Induction of decision trees. *Machine Learning*. <https://doi.org/10.1007/BF00116251>
- Özkan, M., & Kayhan, C. (2021) Astronomi Alanında Makine Öğrenmesi Uygulamaları. *Turkish Journal of Astronomy and Astrophysics*.
- Rimoldini, L., Dubath, P., Süveges, M., López, M., Sarro, L. M., Blomme, J., ve Eyer, L. (2012). Automated classification of Hipparcos unsolved variables. *Monthly Notices of the Royal Astronomical Society*. <https://doi.org/10.48550/arXiv.1301.1545>
- Sarro, L. M., Debosscher, J., Neiner, C., Bello-Garcia, A., González-Marcos, A., Prendes-Gero, B., ve Batz, B. D. (2013). Improved variability classification of CoRoT targets with Giraffe spectra. *Astronomy & Astrophysics*. <https://doi.org/10.26093/cds/vizieR.35500120>

- Saux, A. L., Bugnet, L., Mathur, S., Breton, S. N., ve Garcia, R. A. (2019). Automatic classification of k2 pulsating stars using machine learning techniques. *Societe Francaise d'Astronomie et d'Astrophysique*. <https://doi.org/10.48550/arXiv.1906.09611>
- Staub, S., Karaman, E., Kaya, S., Karapınar, H., ve Güven, E. (2015). Artificial Neural Network and Agility. *Procedia - Social and Behavioral Sciences*. <https://doi.org/10.1016/j.sbspro.2015.06.448>
- Tisserand, P., Le Guillou, L., Afonso, C., Albert, J. N., Andersen, J., Ansari, R., ve Vigroux, L. (2007). Limits on the Macho Content of the Galactic Halo from the EROS-2 Survey of the Magellanic Clouds. *Astronomy & Astrophysics*. 469(2), 387-404.
- Udalski, A., M. Kubiak, ve M. Szymanski. (1997). Optical Gravitational Lensing Experiment. OGLE-2--the Second Phase of the OGLE Project. *Acta Astronomica*. 47,319-344.
- Yiğit, G., ve Yeğin, M. N. (2020). Öğrenme Aktarımı/Transfer Learning. <https://medium.com/novaresearchlab/öğrenme-aktarımı-transfer-learning-c0b8126965c4>. Erişim Tarihi: 19.08.2023

TEŞEKKÜR

Bu araştırmada Vizier katalog erişim aracı CDS'den yararlanılmıştır. Strasbourg, Fransa (DOI:10.26093/cds /vizier).

Astronomi alanında desteklerinden dolayı değerli hocamız Dr. Onur ŞATIR ve bilgisinden sıklıkla istifade ettiğimiz astronom Alperen Furkan EKSİLMEZ'e teşekkürlerimizi sunarız.



Systematic Analysis of Special Education Projects in eTwinning

Sipan GÜLER^{1*}

Ministry of National Education, Turkey

Doi: 10.55024/buyasambid.1376133

ARTICLE INFO

ABSTRACT

Article Type: Review Article

Article history:

Received: 19.10.2023

Received in revised form: 11.11.2023

Accepted: 20.01.2024

Available online: 07.07.2024

Keywords:

eTwinning, ESEP, Special Education Projects, Special Education, Erasmus+

*¹Sipan GÜLER

E-mail address:

sipangulerr@gmail.com

Orcid: 0000-0002-5113-8902

In this study, Turkey-partnered special education projects carried out in eTwinning (European School Education Platform) were analyzed using the systematic analysis method. Projects implemented between 2017-2019 were examined and analyzed. Twenty-five projects that met the inclusion criteria were analyzed as part of the research. As a result of the analysis, it was seen that the number of projects increased over time, the majority of the projects were carried out with Turkish partners, and among the program countries, Turkish teachers formed partnerships with Romanian teachers at the highest rate. It has been determined that more awareness activities are carried out in the projects. In addition, it has been observed that the projects generally do not meet the validity standards. It has been determined that the academic, social and technological skills of teachers and students have improved through the projects. As a result of the study, suggestions for other studies and teachers are described.

2024 Batman University. All rights reserved

1. INTRODUCTION

eTwinning is a platform where educators in Erasmus+ countries and partner countries can organize educational activities at a national or international level in order to develop cooperation with their colleagues and produce various projects (Gajek, 2009). For the purpose of putting the inclusive school vision to work, eTwinning serves thousands of education personnel, especially teachers, to reach the latest information and communication technologies and be instantly informed about the newest developments (Gajek, 2007; Camilleri, 2016). At eTwinning events and conferences, the users create networks and form professional collaborations to offer the best possible educational environment for their students (Fät, 2012; Demir and Kayaoğlu, 2022;). eTwinning platform, founded in 2005, operates in 44 countries consisting of 27 European Union countries and others including Jordan and Tunisia (Döger, 2022).

eTwinning section under the European School Education Platform provides teachers with an online social networking environment where they can create projects, share and learn together, in line with project kits, application examples, references and interests of its users (ESEP, 2022). eTwinning

users can network, share and collaborate with other registered users and schools by joining rooms, eTwinning groups and European projects through the offered social networking features (ESEP, 2022). Based on the principle of lifelong learning, the eTwinning community aims to carry out educational activities in cooperation with all participant countries (Crisan, 2013). Thus, it hosts webinars, online collaborative seminars, conferences and professional development opportunities. These activities allow teachers to network, learn together, and feel part of the same community (Crisan, 2013). However, in order to organize all these activities, it is necessary to be an approved user in eTwinning (eTwinning Türkiye, 2023). To become an approved user on School Education Platform, the official site of the eTwinning platform:

First you need to fill out the application form. In order for the teacher who fills out the form to become an approved user, he/she must receive approval from his/her country's National Support Service (NSO) (ESEP, 2022)

The NSO is a national body authorized by the Central Support Service (CSS), the main governance mechanism of eTwinning (eTwinning Türkiye, 2023). This board operates under the Ministry of National Education in Turkey and uses the Ministry's personnel database to approve users. Therefore, the NSO requires users to have official teacher or teacher candidate status (eTwinning Türkiye, 2023). In addition to verifying user records, the NSO carries out tasks together with the CSS, such as keeping the platform secure, providing support and guidance, issuing National and European Quality Labels to teachers, and approving written projects (Bacescu, 2016; ESEP, 2022). Since knowing the working process of the projects facilitates the understanding of this study, the processes related to eTwinning projects are explained in the next heading.

1.1. eTwinning Projects

eTwinning projects are a type of non-funded collaborative project in which teachers at European schools and students, through teachers, participate (ESEP, 2022). All stages of the project were carried out on www.etwinning.net before 2022. However, after a certain transition period, it can be carried out through the European School Education Platform now. All processes such as project application, finding a European partner for the project, executing the planning processes of the project, and making award applications for the project are carried out actively and quickly on the European School Education Platform (Döğler, 2022). In addition, it provides a secure online environment since the "ab login" login system is used to log in to the platform (ESEP, 2022).

After the project application stages are completed, a project page is created where the operation process of the project can be managed; in project this page where members can be added, the project plan and project products can be uploaded, project-related announcements can be made, and many other tasks and processes can be carried out is named Twinspace (Crisan, 2013). The Twinspace page is the management panel of the project. At first glance, all the products of the project and all the related processes can be monitored regularly on the Twinspace page (Leto, 2018). Twinspace pages are highly functional with their features to manage project processes from a single place and to act as a kind of file for processes such as award applications (Karakaşlar-Gezgin and Gökbaş-Çubuk, 2021).

Considering that all these processes form a broad framework of the projects, the main review criteria of the study can be understood. The most important component that meets this inclusion criterion is what the project is about.

It is known that eTwinning projects can be applied in every subject and discipline. However, the adequacy of projects implemented in the field of special education or that enable the participation of individuals with special needs is undoubtedly of great importance (Yıldırım Doğru et al., 2014). The fact that the main subject of the projects investigated in this study is special education and individuals with special needs requires an overview of the special education projects implemented in eTwinning. This situation is discussed in the next heading.

1.2. Special Educational Projects in eTwinning

Considering that projects contribute to the development of various skills of teachers and students (Fansa, 2021); It is understood that providing educational environments suitable for the developmental conditions of individuals with special needs through projects is of great importance in terms of developing educational activities for these individuals and ensuring their social integration of them. (Yıldırım Doğru et al., 2014). Hence, there is a critical need to examine and analyze projects. When the literature is examined, it has been observed that the studies on eTwinning projects for special education are insufficient. It has been detected that the few studies identified generally focus on the professional development of teachers (Başaran et al., 2020; Gençtürk Erdem et al., 2021;) and are based on teacher opinions (Avcı, 2020; Fazlı, 2022; Küçüktaşçı, 2022). In addition, it has been determined that some studies focus on a single skill of the student(s) rather than the analysis of eTwinning projects (Tsampatzidis, 2021; Çevik, et al., 2021; Fazlı, 2022). Apart from this, it has been determined that studies examining projects generally only provide a general perspective about the projects or examine only a single project. (Boronat, et al. 2015; Čibej, 2022)

Accordingly, it is important to examine projects dealing with the subject of special education/individuals with special needs in this study. The main reason for choosing eTwinning projects is the easy access to the project page (Twinspace) where we can evaluate the outputs (Leto, 2018). On the other hand, choosing projects with high quality values among the projects published on the platform will make this work more meaningful. That is the reason why we chose to focus on award-winning projects in this study. Which award-winning projects are in eTwinning and the next heading explains the awarding process.

1.3. Reward System

A reward system called "National Quality Label" and "European Quality Label" is implemented to evaluate teachers' success in eTwinning projects (Vuorikari et al., 2012). The National Quality Label concretely demonstrates the high level of success of teachers' eTwinning project activities. In other words, it shows that the project complies with certain quality standards (Papadimitriou and Niari, 2019). The European Quality Label is a secondary quality award given by the Central Support Service (CSS), provided that the countries involved in the projects that qualify for the National Quality Label are

recommended by at least one National Support Service (eTwinning Turkey, 2023). In order to receive the European Quality Label, at least two partners must have previously received the National Quality Label. The European Quality Label is awarded annually and is considered a prerequisite for participation in the eTwinning European Awards Competition (Giannis, 2022; eTwinning Turkey, 2023)

Quality labels, not only contribute positively to teachers' professional development, but also increase their visibility within and outside the society. (Vuorikari et al., 2012). On the other hand, it increases the possibility of finding partners in the next eTwinning projects they will be involved in, proving that their projects reach the European standards. This provides an advantage while applying for Erasmus+ projects. eTwinning also provides a prerequisite for candidacy for European awards. (Döğler, 2022)

In this study, projects that received a quality label were specifically selected because the fact that a project received a quality label proves that the project has reached European standards (Papadimitriou and Niari, 2019) and that the project is sufficient in some aspects. It also shows that the project was evaluated by an independent authority and received a valid rating. Therefore, award-winning projects form the main axis of the study.

2. PURPOSE OF THE RESEARCH

This research aims to systematically analyze the special education projects made on the eTwinning platform between 2017-2019 according to the following review criteria; a) disciplinary areas b) target audiences c) partner countries c) scientific evaluation methods used d) their activities and e) Web 2.0 tools they use.

Since eTwinning projects for special education are discussed in this study, it will serve as a guiding source for other studies in the literature. Because the studies conducted in the field of special education are limited. It prevents a clear understanding of what skills eTwinning projects generally develop in teachers, what subjects they need to work on, and which countries teachers are partnered with. With regard to this study, we will determine which topics teachers generally focus on in projects, which countries they prefer to work with, which technological skills they have developed, and to what extent they can use scientific methods in projects.

In addition, this study reflects a systematic view of the special education projects carried out in eTwinning between 2017-2019, in general in terms of the following principles:

Applied discipline areas, targeted audience, scientific methods used, partnering countries, implemented activities, Web2.0 tools used.

3. METHOD

In the research, special education projects made between 2017-2019 on the eTwinning platform were systematically analyzed. The systematic review is an examination method that examines, evaluates, summarizes and compares studies according to objective criteria. (Hanley and Cutts, 2013)

3.1. Data Collection

Various inclusion criteria were chosen while determining the projects to be included in the systematic review process. These criteria are:

- Being a special education project - including activities for special needs
- Being a project initiated in or participated by Turkey
- Received at least one of the national or European quality label awards
- Being able to see the products, plan and results of the project on the Twinspace page
- To be finished in 2019 and before

The following keywords were used to find the projects on www.etwinning.net (accessed on 08.11.2021): “özel eğitim” “özel gereksinimli” “engelli” “special needs” and “special education”. The results were filtered by the country, "Turkey". Turkey joined eTwinning in 2009 (eTwinning Türkiye, 2023). However, during the screening, it was determined that no special education projects were carried out until 2015. Apart from this, 122 projects were found in the search results. However, in 89 of these projects, the Twinspace page, where we find the contents of the projects, could not be accessed. The oldest accessible special education projects date back to 2016. However, all of the projects carried out in 2016 (f:8) were excluded from the research because they did not meet the inclusion criteria (e.g. receiving a quality label). At the end of the screening, all projects (f: 25) that were implemented and completed between January 2017 and December 2019 and met the inclusion criteria were included in the study. When projects are included, it is an important criterion that they be completed by 2019 at the latest. Since the Covid-19 epidemic started in 2020, projects in 2020 and later were not included in this study.

3.2. Data Analysis

The projects included in the research were classified in terms of the awards they received, the year they were first implemented, and the partnered countries. Afterwards, these projects were classified in terms of their target groups, subjects, activities, whether the scientific method was applied or not and the web 2.0 tools used. In addition, an analysis of these classifications was made by another expert. The main purpose here is to reach the correct and reliable information. As a result of the comparison, 100% consistency was achieved between the data obtained. Thus, the intercoder reliability was determined to be 100%.

3.3. Limitations

The limitations of the research are listed below:

- The research merely covers special educational projects in eTwinning.
- Only the projects between 2017 and 2019 were included in the research.
- Exclusively the projects with Turkish founders were examined in the research.

4. FINDINGS

The projects invested within the scope of this research were classified in accordance with the review criteria. Accordingly, they are classified in terms of the year they were initiated, partnering countries and the quality label awards they received. Afterwards, the projects were examined in terms of their target groups, disciplinary areas, activities applied, the condition of whether scientific evaluation methods are applied or not and Web 2.0 tools used. The results are presented in tables, graphs and pictures.

Special education projects published on the eTwinning platform are classified in Figure 1 in terms of the year they were implemented.




Figure 1: Distribution of projects by year of implementation

In Figure 1, it is seen that the distribution of projects varies according to year, and 2019 is the most active year. The distribution shows that 5 projects in 2017, 8 projects in 2018, and 12 projects in 2019 were initiated.

The distribution of the projects according to the number of partnering countries is presented in Figure 2.




Figure 2: Distribution of the projects according to the number of partnering countries

When the distribution is examined, it is observed that only the projects with Turkish partnerships are more than the other projects. The number of projects with only Turkish partnerships is 11 (44%). In 7 projects (33%) Turkey collaborated with one country, and in 7 projects (33%) three or more countries worked together.

The distribution of the countries that have partnered with Turkey is shown in Table 1.

Country	Number of Project in Partnership
Romania	5
Azerbaijan	4
North Macedonia	3
Portugal	2
United Kingdom	2
Ukraine	2
Poland	2
Italy	2
Georgia	2
Lithuania	2
Slovenia	1
Greece	1
Bosnia and Herzegovina	1
France	1
Bulgaria	1
Croatia	1
Albania	1
Estonia	1
Jordan	1
Tunisia	1

Table 1: Distribution of the countries that have partnered with Turkey

The table presents that the number of projects of the countries that have partnered with Turkey does not show significant variations. The country with the highest number of partnerships is Romania with 5 projects, followed by Azerbaijan with 4 projects and North Macedonia with 3 projects. Turkey has established partnerships with Portugal, the United Kingdom, Ukraine, Poland, Italy, Georgia and Lithuania in 2 projects, and with Slovenia, Greece, Bosnia and Herzegovina, France, Bulgaria, Croatia, Albania, Estonia, Jordan and Tunisia in 1 project each.

The distribution of the projects regarding the National Quality Label and/or European Quality Label awards is shown in Figure 3.

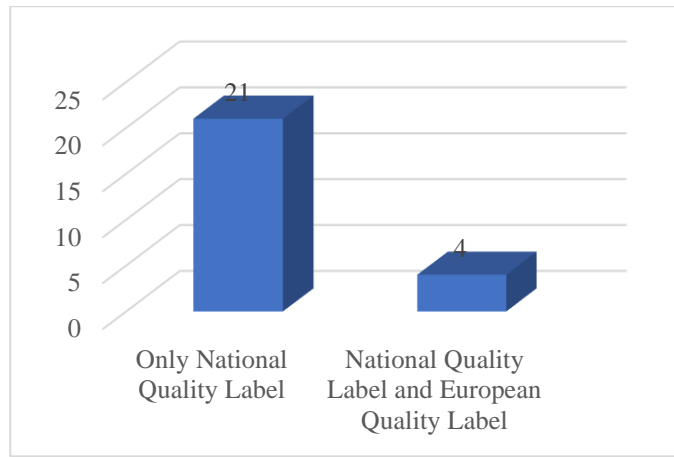


Figure 3: Distribution of projects according to quality label awards

Figure 3 shows that the number of projects that received only the National Quality Label is 21 (85%), while the number of projects that received both National and European Quality Labels is 4 (15%).

The distribution of the projects according to the target group of special needs, their peers, teachers and families are presented in Table 2.

Distribution of Projects by Target Group	Number
Special needs only	7
Peers only	3
Teachers only	0
Families only	1
Both special needs and peers	9
Both peers and teachers	1
Both teachers and families	1
Both special needs and teachers	1
Special needs, peers, teachers, families	2
Total	25

Table 2: Distribution of the projects according to the target group

The table shows that the projects with the target audience of special needs and their peers have the highest number of projects with 9 (36%). Projects in which only special needs are selected as the target group come next, with 7 projects (28%). It is followed by projects in which only peers are selected as the target audience with 3 (12%) projects and projects where individuals with special needs, their peers, teachers and their entire families are selected as the target group with 2 (8%) projects. Only the projects in which families, both peers and teachers, teachers and families, and special needs and teachers were selected as target groups remained in 1 project each. No projects have been carried out for teachers only.

The distribution of the projects with respect to the disciplinary areas is presented in Figure 4




Figure 4: Distribution of the projects with respect to the disciplinary areas

Figure 4 shows that 12 of the projects, approximately half (48%), focus on Awareness Studies. On the other hand, the number of projects in which Art Skills are studied is limited to 4 (16%). The number of projects where Academic Skills are studied and projects focused on Daily Life Skills is 3 (12%). While the number of projects where Academic Skills and Art Skills are worked together is limited to 2 (8%), it is seen that the least studied disciplinary area is Academic Skills and Technological Skills with only 1 project (4%). It was determined that there was no project in which only Technological Skills were studied (f:0).

The data on the classification of the activities implemented in the projects are shown in Figure 5.




Figure 5: Distribution of the activities implemented

As seen in Figure 5, Social Activities were implemented in 10 projects. The number of projects including Social Activities and Art Activities plus Social Activities together was 5 followed by; Art Activities in 4 projects; Game Activities in 3 projects; Lesson Activities in 2 projects; and Lesson Activities plus Social Activities in 1 project.

The data on whether scientific evaluation methods are applied in the projects are shown in Figure

5. RESULTS AND DISCUSSION

The consistent increase in special education projects on the eTwinning platform over the years indicates that teachers' digital skills required by the platform have developed over time. Considering that these projects, which can be managed through a network-based system, require active use of digital skills (Bozdağ, 2017), it is believed that the increase in projects over the years is a parallel result of the improvement in teachers' digital skills.

The majority (f:11) of the special education projects carried out on the eTwinning platform being partnered with Turkish teachers demonstrates the willingness of Turkish teachers to collaborate with fellow Turkish teachers in projects. The main reason for teachers who have limitations in working with any European partner is believed to be language barriers. This inference aligns with the findings of a study conducted by Ersoy (2013) based on focus group interviews with teachers participating in Erasmus+ projects.

In the Erasmus+ Program Guide published in 2022, member countries are divided into three groups for the grant support amounts for Staff Mobility (Table 4). This categorization is primarily based on the standard of living levels in countries. When the findings regarding the countries with which Turkey has established partnerships in eTwinning projects are interpreted according to this categorization, it can be observed that the most partnerships are formed with the 3rd Group countries, including Turkey. This could be due to economic and cultural reasons. When examining Table 1, it can be seen that countries such as Romania and North Macedonia, which share a common history and similar cultures with Turkey, rank high. However, considering the complexity of the process of involving partners in projects, this is a limited inference. On the other hand, when looking at the development levels of countries, it is understandable that the 3rd Group countries have a similar profile, which leads to the selection of these countries for partnerships. This finding is also supported by the fact that no partnership was established with any of the 1st Group countries. The 1st Group countries are classified as the most developed countries. Despite partnerships being established with four of the 2nd Group countries (Italy, France, Greece, Portugal), the notable finding is the absence of any partnership with Germany. This is significant because Turks constitute the largest ethnic group in Germany (Republic of Turkey Ministry of Foreign Affairs, 2022). Therefore, an analysis is needed to understand the reasons why teachers inclined to work with Turkish partners do not establish partnerships with a country like Germany, which has a dense and active Turkish population, as shown in Figure 2.

Focusing on the countries that are not included in the groups in Table 4 (Table 5), it is seen that Azerbaijan is the second most partnered country. The proximity of Azerbaijani and Turkish languages, Azerbaijan's similar cultural structure to Turkey, and the neighboring relationship between the two countries are inherent reasons for this finding. It is also possible that partnerships were established with the rest of the countries for similar reasons, except for the United Kingdom.

1st Group of Countries	Denmark, Finland, Ireland, Iceland, Liechtenstein, Luxembourg, Norway, Sweden
2nd Group of Countries	Austria, Belgium, France, Germany, Greece, Italy, Malta, Netherlands, Portugal, Republic of Cyprus, Spain
3rd Group of Countries	Bulgaria, Croatia, Czech Republic, Estonia, Latvia, Lithuania, Hungary, North Macedonia, Poland, Romania, Serbia, Slovakia, Slovenia, Turkey

Table 4: Table on Categorization for Erasmus+ Staff Mobility Grant Support Amounts. (Erasmus+ Programme Guide, 2023, Version 2)

Other Countries	Albania, Azerbaijan, Bosnia and Herzegovina, Georgia, Jordan, Tunisia, United Kingdom, Ukraine
------------------------	--

Table 5: Classification of Countries not included in the categorization in Table 4

The fact that the number of projects that have received the National Quality Label (f:21), which concretely demonstrates that the teachers' eTwinning project activities have achieved a high level of success, is more than 5 times the European Quality Label (f:4), proves that the implemented projects do not reach European standards in terms of quality. Two separate factors may have contributed to this situation: primarily conducting projects with only Turkish partners and implementing projects that do not meet quality standards. Therefore, Turkish teachers need to collaborate with more European partners and pay more attention to quality standards.

When examining the data related to the target audience of the projects, the results obtained align with the study conducted by Yıldırım Doğru and others (2014) on special education projects. However, this finding is limited due to the study not including a classification similar to Table 2 and not examining eTwinning projects. Although the mentioned study found a sufficient number of projects for teachers, this study could not identify any projects specifically targeting teachers. The data for projects targeting families show similarities to the mentioned study. On the other hand, despite the absence of a specific identification or classification of projects targeting peers in the mentioned study, this study has reached significant data on projects targeting peers. This indicates that peers are frequently selected as the target audience in projects conducted in the field of special education.

According to the findings related to the disciplinary areas in which the projects operate, awareness-raising activities are the most commonly preferred disciplinary area. This finding aligns with previous literature studies emphasizing the need to prioritize awareness-raising activities for individuals with special needs (Melekoğlu, 2013; İlgar, 2017; Nalbant, 2018; Cremin et al., 2021). eTwinning projects provide suitable environments for awareness-raising activities as they bring individuals from different nations together. Therefore, the findings of this study meet the expectations of the study. On

the other hand, it is surprising that there are no projects solely focused on developing technological skills. eTwinning considers the development of technological skills as an important goal. The reason for this may be the teachers' biases that individuals with special needs cannot acquire technological skills. However, since this study does not provide any evidence in this regard, this situation is only expressed as an interpretation by the author.

It is an expected result that the majority of the projects include social skills activities. This is because another significant contribution of the platform is to enhance socio-cultural interaction and bring people from different cultures together. The fact that social activities are the most implemented activities in this study supports the qualitative study conducted by Huertas-Abril and Muszyńska (2022), which stated that eTwinning projects contribute to the increase of individuals' socio-cultural skills.

When examining the literature, no studies were found regarding whether eTwinning projects include scientific evaluation methods. Therefore, it is important to examine projects in terms of this aspect. When looking at the 25 projects examined, the fact that scientific evaluation methods were used only in 13 projects indicates that the evaluation criteria for awarding projects are insufficient. Considering that only award-winning projects were examined due to the aim of the research, this becomes an even more noteworthy result. It is important to know what kind of criteria are included when projects are awarded. This would allow for the updating of evaluation criteria. However, it should be noted that all the data obtained are limited to this study sample.

Although the use of surveys in all projects that include scientific evaluation methods can be associated with the fact that surveys are frequently preferred in scientific studies (Arıkan, 2018), it indicates that the evaluation mechanisms of the projects are insufficient. This is because of that groups such as teachers, parents, and students actively participating in the process through various practices, sometimes necessitating the use of multiple evaluation methods. In this regard, effective evaluation processes are ensured for project outcomes.

Using Web 2.0 tools throughout the project is a prerequisite for generating an effective eTwinning project. (Alexander, 2006) According to studies that emphasize the contribution of Web 2.0 tools to the development of various skills (Karaaşlar-Gezgin and Gökbaş-Çabuk, 2021; Çetin-Cengiz and İzci, 2021; Castellanos-Vega & Durak, 2022), it has been found that the use of Web 2.0 tools in eTwinning projects enhances their effectiveness. Therefore, it is clear that as the number of Web 2.0 tools used increases, the effectiveness of the projects also increases. When examining Figure 1, it can be observed that a wide variety of Web 2.0 tools are used in the projects included in the research. Thus, it can be stated that the examined projects pay attention to the diversity while using the Web 2.0 tools.

6. SUGGESTIONS

The following are some suggestions for future studies and project implementations based on this research:

1. Examining projects over a broader time range would provide a larger sample and contribute more to the literature. Therefore, it is recommended to repeat the study with wider time intervals.

2. The study can be conducted in areas other than special education.
3. Research can be conducted to examine the quality label process of projects.
4. Recommendations can be provided to help projects meet the quality label criteria.
5. Measures can be taken to promote collaborations with more partners and establish partnerships with countries that are not currently engaged.

7. REFERENCES

- Alexander, B. (2006). Web 2.0: A New Wave Of Innovation For Teaching and Learning? *EDUCAUSE Review*, 41(2), 32-44.
- Arıkan, R. (2018). A Generale Review on Interview Techniques. *Haliç Üniversitesi Sosyal Bilimler Dergisi*, 1(1), 97-159.
- Avcı, F. (2020). Teachers Opinions and Assessments on the eTwinning Platform as an Online Learning Environment. *Cumhuriyet International Journal of Education*, 10(1), 1-22.
- Bacescu, M. C. (2016). eTwinning–The Community For Schools In Europe. *eLearning and Software for Education «(eLSE)»* (s. 12(2), 353-359). Bucharest: Carol I National Defence University Publishing House.
- Başaran, M., Kaya, Z., Akbaş, N., & Yalçın, N. (2020). Reflection of eTwinning Activity on Teachers' Professional Development in Project-Based Teaching Process . *Journal of Educational Theory and Practice Research*, 6(3), 373-392.
- Boronat, R., Balart, R., Garcia-Sanoguera, D., Boronat, T., Sanchez-Nacher, L., Fenollar, O., & Fombuena, V. (2015). The Etwinning Platform. An Experience Of The Implementation Of A Collaborative Project Online. *Conference name: 9th International Technology, Education and Development Conference* (s. 4052-4057). Madrid: IATED.
- Bozdağ, Ç. (2017). Technology Integration in Turkish and German Schools: A Comparative Analysis of eTwinning. *Journal of Ege Education Technologies*, 1(1), 42-64.
- Camilleri, R.-A. (2016). Global Education and Intercultural Awareness in eTwinning. *Cogent Education*, 1-13.
- Castellanos Vega, R., & Durak, E. (2022). e-Twinning And Activities Of Daily Living In Special Education. *International Journal of Education and New Approaches*, 5(2), 186-197.
- Čibej, M. (2022). International eTwinning Projects for Children with Special Needs. *Mednarodna konferenca EDUizziv* (s. 260-267). Ljubljana: EDUvision.
- Cremin, K., Healy, O., Spirtos, M., & Quinn, S. (2021). Autism Awareness Interventions for Children and Adolescents: a Scoping Review. *Journal of Developmental and Physical Disabilities*, 33, 27-50.
- Crisan, G. I. (2013). The Impact of Teachers' Participation in eTwinning on Their Teaching and Training. *Acta Didactica Napocensia*, 6(4), 19-28.
- Çetin Cengiz, D., & İzci, E. (2021). Students Attending Etwinning Projects Parent Perceptions On The Development Of Technological Competencies. *Diyalektolog Ulusal Sosyal Bilimler Dergisi*, 28: 89-108.
- Çevik, M., Barış, N., Şirin, M., Ortak Kılınç, Ö., Kaplan, Y., Atabey Özdemir, B., . . . Delice, T. (2021). The Effect of Digital Activities on the Technology Awareness and Computational Thinking Skills

of Gifted Students (eTwinning Project Example). *International Journal of Modern Education Studies*, 205-244.

- Demir, N., & Kayaoğlu, M. N. (2022). Multi-dimensional Foreign Language Education: The Case Of An eTwinning Project in Turkey. *Computer Assisted Language Learning*, 35(9), 2201-2238.
- Döger, M. F. (2022). The Transformation Role of Social Networks in Education eTwinning Action Example. *Kahramanmaraş Sutcu Imam University Journal of Education (KSUJED)*, 4(2), 83-103.
- eTwinning Türkiye*. (2023, 12 03). Republic of Türkiye Ministry of National Education Innovation and Educational Technologies General Directorate: (<http://etwinning.meb.gov.tr>) Quoted from website.
- Fansa, M. (2021). Being a Teacher in the Role of Youth Worker in Erasmus+ Project. *Anadolu University Journal of Education Faculty (AUJEF)*, 5(4), 427-446.
- Fât, S. (2012). The Impact Study of eTwinning Projects in Romania. In *Conference Proceedings of "eLearning and Software for Education" (eLSE)* (s. 152-156). Bucharest: Carol I National Defence University Publishing House.
- Fazlı, B. (2022). Inclusion of Inclusion Students in eTwinning Projects: A Phenomenology Study. *Journal of Literature Linguistics Education and Scientific Research*, 1: 115-128.
- Gajek, E. (2007). eTwinning Przykładem e-learningu W oświacie/eTwinning As An Example Of e-learning in Education. *e-mentor*, 2(19).
- Gajek, E. (2009). *eTwinning-A Way To Education Of The Future*. Warsaw: Foundation for the Development of the Education System.
- Gençtürk Erdem, E., Başak Başar, F., Toktay, G., Yayğaz, İ. H., & Rüyam, K.-S. (2021). Contribution of eTwinning Projects to Digital Literacy Skills of Teachers. *International Journal of Social Sciences and Education Research*, 7(3), 204-2019.
- Giannis, T. (2022). Interpreting the Statistics of eTwinning: European Quality Label . *International Journal of Educational Innovation*, 4(2), 4-15.
- Hanley, T., & Cutts, L. (2013). What is a systematic review? *Counselling Psychology Review* , 28(4), 3-6.
- Huertas-Abril, C. A., & Muszyńska, B. (2022). The Role Of Etwinning Tools In Social And Curriculum Integration Using Multimodal Communication. *Teaching English with Technology*, 22(3-4), 63-84.
- İlgar, Ş. (2017). An Investigation Of The Awareness Of Teacher Candidates About Children With Special Needs (İu Hasan Alı Yucel Faculty Of Education Sample). *HAYEF: Journal of Education*, 14(1), 313-338.
- Karakaşlar-Gezgin, S., & Gökbaş-Çubuk, M. (2021). Implementing eTwinning Projects: Founder Teacher. *Anatolian Journal of Teacher*, 5(2), 380-398.
- Küçüktaşçı, M. (2022). *Okul Yöneticileri ve Öğretmenlerin eTwinning Projelerine İlişkin Görüşleri (Master Project)*. Denizli: Pamukkale Üniversitesi Eğitim Bilimleri Entitüsü.
- Leto, E. (2018). eTwinning and The Project Based Learning Approach. *International Conference The Future of Education 8th Edition* (s. 237-239). Florence: Libreria Universitaria.
- Melekoğlu, M. A. (2013). Examining the Impact of Interaction Project with Students with Special Needs on Development of Positive Attitude and Awareness of General Education Teachers towards Inclusion. *Educational Sciences: Theory and Practice*, 13(2), 1067-1074.

- Nalbant, S. (2018). Effectiveness of the Awareness-Raising by Sport on Children with Special Needs. *İÜ Spor Bilimleri Dergisi*, 8(1), 24-36.
- Papadakis, S. (2016). Creativity and innovation in European education. Ten years eTwinning. Past, present and the future . *Int. J. Technology Enhanced Learning*, 279-296.
- Papadimitriou, S. T., & Niari, M. I. (2019). Open Badges: Assessing Quality Elements in Open Education Systems: Case Studies. *Journal of Learning for Development- JLAD*, 6(1), 49-63.
- Tsampatzidis, T. (2021). Innovative and prize-winning educational music activities in special education thought the eTwinning Project. *European Journal of Special Education Research*, 101-119.
- Vuorikari, R., Garoia, V., Punie, Y., Cachia, R., Redecker, C., & Cao, Y. (2012). *Teacher networks- Today's and tomorrow's challenges and opportunities for the teaching profession*. Brussels, Belgium : European Schoolnet (EUN Partnership AISBL) .
- Yıldırım Doğru, S., Özlü, Ö., Kançeşme, C., & Doğru, S. (2014). Quantification of Projects Done on Special Education. *Bolu Abant İzzet Baysal University Journal of Faculty of Education*, 15: 286-296.