

Researcher

CILT/VOL **4**

SAYI/ISSUE **02**

YIL/YEAR **2024**

Researcher

CİLT/VOL 04

SAYI/ISSUE 02

YIL/YEAR 2024

Sahibi / Owner

Ankara Bilim Üniversitesi / Ankara Bilim University

İmtiyaz Sahibi / Licensee

Prof. Dr. Yavuz DEMİR (Ankara Bilim University)

Baş Editör / Editor in Chief

Prof. Dr. Hakan ÇAĞLAR (Ankara Bilim University)

Editör / Editor

Assoc. Prof. Dr. Yavuz Selim ÖZDEMİR (Ankara Bilim University)

Alan Editörleri / Section Editors

Assoc. Prof. Dr. Ender SEVİNÇ (Ankara Bilim University)

Assoc. Prof. Dr. Oğuzhan Ahmet ARIK (Erciyes University)

Asst. Prof. Dr. Emir Hüseyin ÖZDER (Ankara Bilim University)

Asst. Prof. Dr. Ercüment KARAPINAR (Ankara Bilim University)

Yayın Kurulu / Editorial Board

Prof. Dr. Hakan ÇAĞLAR (Ankara Bilim University)

Prof. Dr. İsmail COŞKUN (Ankara Bilim University)

Prof. Dr. Halim Haldun GÖKTAŞ (Ankara Bilim University)

Prof. Dr. Cem Harun MEYDAN (Ankara Bilim University)

Prof. Dr. Babek Erdebilli (B.D. Rouyendegh) (Ankara Yıldırım Beyazıt University)

Prof. Dr. Tansel DÖKEROĞLU (TED University)

Assoc. Prof. Dr. Yavuz Selim ÖZDEMİR (Ankara Bilim University)

Assoc. Prof. Dr. Ender SEVİNÇ (Ankara Bilim University)

Asst. Prof. Dr. Ercüment KARAPINAR (Ankara Bilim University)

Asst. Prof. Dr. Volkan ÇAKIR (Birmingham City University)

Danışma Kurulu / Advisory Board

Prof. Dr. Yavuz DEMİR (Ankara Bilim University)

Prof. Dr. Beycan İBRAHİMOĞLU (Ankara Bilim University)

Prof. Dr. Ahmet COŞAR (Ankara Medipol University)

Prof. Dr. Abdullah AVEY (Süleyman Demirel University)

Prof. Dr. Ashraf M. ZENKOUR (King Abdul Aziz University)

Prof. Dr. Sci Nguyen Dinh DUC (Vietnam National University)

Prof. Dr. Mohammad SHARİYAT (K.N. Toosi University of Technology)

Prof. Dr. Mohammad Reza ESLAMİ, (Amirkabir University of Technology)

Prof. Dr. Hui-Shen SHEN (Shanghai Jiao Tong University)

Prof. Dr.-Ing. Eckart SCHNACK (Karlsruhe Institute of Technology)

Assoc. Prof. Dr. Nicholas FANTUZZI (University Bologna)

Dil Editörü / Language Editor

Asst. Prof. Dr. Ayşe Saki DEMİREL (Ankara Bilim University)

Sekretarya / Editorial Secretariat

İlay GÜVENÇ (Ankara Bilim University)

e-ISSN:2717-9494

Yayıncı / Publisher: Ankara Bilim Üniversitesi / Ankara Bilim University

Basım Tarihi / Date of Publication: Aralık 2024/ December 2024

Yayın Türü / Publication Type: Uluslararası Süreli Yayın / International Periodical

İletişim Bilgileri / Contact Information: Maltepe Mahallesi Şehit Gönenc Caddesi No: 5 Çankaya Ankara

Web Sitesi / Website: <https://dergipark.org.tr/tr/pub/researcher>

E-posta / E-mail: researcher@ankarabilim.edu.tr

Researcher uluslararası, hakemli ve yılda iki sayı yayınlanan dergidir. İngilizce ve Türkçe dilindeki metinler kabul edilir.
The Researcher is a peer-reviewed, international journal publishing two issues a year. Manuscripts are accepted in English and Turkish languages.

ANKARA, ARALIK 2024 / DECEMBER 2024

Önsöz

Yayın hayatına 2013 yılında başlamış olan "Researcher: Social Sciences Studies" (RSSS), 2020 Ağustos ayı itibariyle "Researcher" ismiyle Ankara Bilim Üniversitesi bünyesinde yayın hayatına devam etmektedir. Fen Bilimleri alanına katkıda bulunmayı hedefleyen özgün araştırma makalelerinin yayımlandığı bir dergidir. Dergi, özel sayılar dışında yılda iki kez yayımlanmaktadır.

Amaçları doğrultusunda dergimizin yayın odağında; Endüstri Mühendisliği, Bilgisayar Mühendisliği ve Elektrik Elektronik Mühendisliği alanları bulunmaktadır. Dergide yayımlanmak üzere gönderilen aday makaleler Türkçe ve İngilizce dillerinde yazılabilir. Dergiye gönderilen makalelerin daha önce başka bir dergide yayımlanmamış veya yayımlanmak üzere başka bir dergiye gönderilmemiş olması gerekmektedir. Bir makalenin dergide yayımlanabilmesi için en az iki hakem tarafından olumlu rapor verilmesi gerekir.

Değerlendirme sonucu kabul edilen çalışmalar sırasıyla; intihal kontrolünün yapılması, kaynakça düzenlemesi, gönderme ve atıf kontrolü, mizanpaj ve dizgisinin yapılması süreçlerinden geçer.

Researcher, Dergipark üzerinden bilimsel araştırmaların içeriğine anında açık erişim sağlamaktadır.

Researcher makale işlem ücreti (gönderme, değerlendirme veya basım ücreti) ve makalelere erişim için abonelik ücreti talep etmediği için ücretsiz yayın yapan dergi statüsündedir, Dergimiz herhangi bir kâr amacı gütmemekte ve hiçbir gelir kaynağı bulunmamaktadır.

Baş Editör

Prof. Dr. Hakan ÇAĞLAR

Editör

Doç. Dr. Yavuz Selim ÖZDEMİR

İçindekiler / Index

Türkiye'deki Toplam Elektrik Tüketiminin Holt-Winters Üstel Düzleştirme Yöntemi ile Tahmini

Elif SEZER, Güngör YILDIRIM, Mahmut Temel ÖZDEMİR 107-112

An Investigation on the Execution of the Document Clustering Process on Internet News

Metin Oktay BOZ, Jale BEKTAŞ 113-119

Functional Resonance Analysis Method for the Manufacturing Industry: A Bibliometric Analysis of the Literature

Nazlı Gülüm MUTLU 120-129

Detection of Brain Tumor using Boosting Algorithms based on Feature Selection

Ezgi ÖZER 130-140

Türkiye'nin CO2 Emisyonununun Anfis ile Tahmin Edilmesi

Oğuzhan Ahmet ARIK, Eda HAMAMCIOĞLU 141-156

İnsansız Hava Araçlarında İnsan Hatasının Etkilerinin Sistematik Analizi ve Sınıflandırılması-İHA Tasarımı ve Ergonomi

İbrahim AKYÜREK, ERGÜN ERASLAN 157-165

Akciğer Kanseri Tespitinde Sınıf Aktivasyon Haritaları Kullanarak Açıklanabilir Derin Öğrenme Modeli ve Radyolog Değerlendirmesi

Savaş TUNÇER, Oğuzhan KATAR, Tülin ÖZTÜRK, Özal YILDIRIM 166-175

Evrışimli Sinir Ağları Kullanarak Beyin Tümörü Sınıflandırması


Firuze Damla ERYILMAZ, Meriç ÇETİN 176-183

Sentiment Analysis for UdeMy Reviews with Natural Language Processing and Machine Learning Methods

Sedat SÖNMEZ, Tanju AÇI, Hidayet TAKCI, Hakan KEKÜL..... 184-191

Analyzing the Causes of Deforestation with Statistical Quality Control Methods in Turkey

Melike ERDOGAN, Rabia TORMAN 192-210



Türkiye'deki Toplam Elektrik Tüketiminin Holt-Winters Üstel Düzleştirme Yöntemi ile Tahmini

Elif SEZER^{1*}, Güngör YILDIRIM², Mahmut Temel ÖZDEMİR³

¹Munzur Üniversitesi Mühendislik Fakültesi Elektrik-Elektronik Müh. Bölümü, Tunceli/Türkiye; ORCID: 0000-0002-3237-6286

²Fırat Üniversitesi Mühendislik Fakültesi Bilgisayar Müh. Bölümü, 23100, Elazığ/Türkiye; ORCID: 0000-0002-4096-4838

³Fırat Üniversitesi Mühendislik Fakültesi Elektrik-Elektronik Müh. Bölümü, 23100, Elazığ/Türkiye; ORCID: 0000-0002-5795-2550

* Corresponding Author: elifkalic@munzur.edu.tr

Received: 8 March 2024; Accepted: 18. July 2024

Reference/Atf: E. Sezer, G. Yıldırım, and M. T. Özdemir, "Türkiye'deki Toplam Elektrik Tüketiminin Holt-Winters Üstel Düzleştirme Yöntemi ile Tahmini", Researcher, vol. 04, no. 02, pp. 107–112, 2024.



Özet

Elektrik tüketim tahmini, güç sistemlerinin planlanması ve işletilmesi açısından kritik bir rol oynamaktadır. Günümüz modern zaman serileri analiz yöntemleri ile geçmiş verilere dayalı gerçekçi ve ölçülebilir tahminler yapılabilmektedir. Bu çalışmada, Türkiye'deki gerçek zamanlı elektrik tüketim verileri üzerinden kısa dönem yük tahminlerine (KDYT) ve orta dönem yük tahminlerine (ODYT) odaklanılmıştır. Bu tahminler için Üstel Düzleştirme Yöntemlerinden olan Holt-Winters metodu kullanılmıştır. Veri setleri, EPIAŞ Şeffaflık Platformundan alınan gerçek zamanlı tüketim miktarlarından oluşturulmuştur. Holt-Winters metodunun başarımı haftalık, aylık ve yıllık veriler üzerinden hem örneklem içi (in-sample) hem de örneklem dışı (out of sample) tahminler için gözlemlenmiştir. Yapılan deneyler sonucunda, mevsimsellik içeren verilerde, modelin önceki yıllara ait elektrik tüketim miktarlarını tahmin etmede başarımlı sağlayabildiği görülmüştür. Bu başarımlı esas alınarak, ayrıca gelecek günlere ait tüketim tahminleri de gerçekleştirilmiş ve sonuçlar paylaşılmıştır.

Anahtar kelimeler: Elektrik tüketimi tahmini, Holt-Winters metodu, Kısa Dönem yük tahmini, orta dönem yük tahmini

Abstract

Electricity consumption forecasting plays a critical role in the planning and operation of power systems. With modern time series analysis methods, realistic and measurable forecasts can be made based on historical data patterns. This study focuses on short-term load forecasting (STLF) and medium-term load forecasting (MTLF) based on electricity consumption data in Turkey. The Holt-Winters method, which is one of the exponential smoothing methods, is used for these forecasts. The datasets are based on real-time consumption data from the EPIAŞ transparency platform. The performance of the Holt-Winters method is observed for both in-sample and out-of-sample forecasts on weekly, monthly, and annual data. The results show that the model is able to predict the electricity consumption of previous years for seasonal data. Based on this performance, future consumption forecasts are also made and the results are shared.

Keywords: Electricity consumption forecasting, Holt-Winters method, Short-term forecasting, medium-term forecasting

1. Giriş

Enerji tüketimleri ülkelerin ekonomik, teknolojik ve sosyal büyümeleri ile doğrudan ilişkilidir. Günümüzde elektrik enerjisine olan talep sürekli artmaktadır ve dahası mevcut enerji kaynakları endişe verici bir hızla tükenmektedir. Bu nedenle, enerji kaynaklarını etkili bir şekilde yönetmek ve kaynak planlamasını yapmak için enerji kullanım tahminleri elzemdir [1]. Başarılı tahminler, üretim maliyetlerini azaltılabilir ve çevresel riskleri en aza indirilebilir [2]. Dahası enerji arzı ile talebi arasında denge sağlanabilir ve başarılı elektrik enerjisi fiyatlandırması yapılabilir. Yük tahmini, yapıldığı zaman aralığına göre kısa dönem, orta dönem ve uzun dönem yük tahmini olmak üzere üç kategoriye ayrılabilir. Uzun Dönem Yük Tahminleri (UDYT) bir yıldan uzun, Orta Dönem Yük Tahminleri (ODYT) bir

haftadan bir yıla kadar, Kısa Dönem Yük Tahminleri ise bir saatten bir haftaya kadar olan süreleri kapsar [3]. KDYT, güç santralleri arasında yük dağılımını optimize etmeye ve jeneratörlerin devreye giriş-çıkış zamanlarını belirlemeye yardımcı olur [4]. Ayrıca kullanıcıların enerji tüketimini azaltma veya enerji kullanım düzenini değiştirme amacıyla enerji talep yönetimini kolaylaştırır. ODYT ise, güç sistemlerinin yıllık işletme bakım programlarının hazırlanmasında, kısa vadede elektrik iletim sistemine entegre edilecek santrallerin planlanma çalışmalarında ve hidroelektrik sistemlerin rezerv yönetimini belirlemede oldukça önemlidir [5].

Türkiye de dahil olmak üzere birçok ülkenin kurumları, araştırmacı ve mühendisleri enerji tüketim analizleri için çalışmalar yapmaktadır. Kaytez, Türkiye'nin 2018 yılına kadar net elektrik tüketim tahminlerini, çoklu lineer regresyon analizi, yapay sinir ağları ve destek vektör makineleri gibi makine öğrenmesi yöntemleri ile yapmıştır [6]. Bu çalışmada kurulu güç, brüt elektrik üretimi, nüfus ve toplam abone sayısı gibi faktörler, bağımsız değişkenler olarak ele alınmıştır. Kargar ve Charsoghi, İran'daki yıllık elektrik tüketimini tahmin etmek için ekonomik kriterleri de göz önünde bulundurmıştır [7]. Bu amaçla nüfus, gayri safi yurt içi hâsıla, ithalat ve ihracat değişkenleri girdi olarak kabul edilerek, ARIMA ve yapay sinir ağı modelleri ile tahminler geliştirilmiştir. Abdoos ve Hemmati, kısa dönem yük tahmini için geçmişteki benzer yük ve sıcaklık değerlerini kullanarak yeni bir hibrit akıllı tahmin yöntemi önermiştir. Tahmin doğruluğunu artırmak için gün tiplerini belirleyerek destek vektör makineleri regresyonu kullanılmıştır [8]. Fan ve Hyndman yapay sinir ağlarını kullanarak Avustralya'da bir veya daha fazla bölge için kısa dönem yük tahminleri gerçekleştirmiştir [9]. Çalışmada, takvim değişkenleri, gecikmeli gerçek talep gözlemleri ve sıcaklık izleri kullanılan modelin temel girdilerdir.

Elektrik tüketim verileri zaman serileri olarak ele alındığında, geçmişteki benzer davranış desenleri veya matematiksel anlamlı tepkiler gelecek tahminlerini kolaylaştırabilir [10]. Günümüzde bu tip zaman serisi analizleri yapan birçok yöntem bulunmaktadır. Bunlar arasında, sinyal işleme alanında sıklıkla kullanılan düzleştirme yöntemi temelli yaklaşımlar özellikle lineer veya mevsimsellik (seasonality) içeren zaman serilerinde başarılı sonuçlar üretebilmektedir. Kolay kullanımlı bu basit yöntemler, verilerdeki dalgalanmaların filtre edilmesine olanak sağlayarak gerçekçi tahminler sağlayabilir [11]. Bu çalışmada, Özger ve diğerleri ile Özkan ve diğerlerinin [15,16] kullandığı mevcut zaman serilerinin karakteristiğini dikkate alarak enerji tahminleri için düzleştirme temelli yaklaşımlardan olan Holt-Winters yöntemi kullanılmıştır. Bu çalışma literatürden farklı olarak haftalık, aylık ve yıllık tüketimler de tahmin edilmiştir. Bu yöntem ile hem örneklem içi (in-sample) hem de örneklem dışı (out of sample) analizler gerçekleştirilmiştir.

Çalışmanın bundan sonraki organizasyonu şu şekildedir; Holt-Winters metodunun temel ayrıntıları ve kullanılan veri setlerinin tanıtımı ve karakteristik yapıları Bölüm 2'de verilecek, deneylerin sonuçları Bölüm 3'te paylaşılacaktır. Bölüm 4'te ise sonuç ve öneriler yer alacaktır.

2. Materyal Metod

Bu bölümde öncelikle Holt-Winters yöntemine ait detaylar verilecek daha sonra kullanılan veri setleri tanıtarak gerekli ön işlem ve karakter analiz sonuçları paylaşılacaktır.

2.1. Holt-Winters Üstel Düzleştirme Yöntemi

Holt-Winters, eğilim (trend) ve mevsimsel etki içeren zaman serilerinin analiz ve tahminlerinde kullanılan bir üstel düzleştirme yöntemidir. Tahminlerde geçmiş verilerin ağırlıklandırılmış değerleri belirleyicidir. Üstel azalma karakteristiğine sahip bu ağırlıklandırma iteratif bir şekilde gerçekleştirilir. Tekli Üstel Düzleştirme (SES) ve Doğrusal Üstel Düzleştirme (Holt's Lineer) yöntemlerinden farklı olarak mevsimselliğin de dikkate alınmasından dolayı üç safhalı bir düzleştirme yürütülmektedir [11-14]. Her üç safhayı temsil eden üç parametre α , β , ve γ 'dir. α , orjinal verinin düzleştirme parametresi olup mevcut seviye (değer) tahminine dâhil edilirken geçmiş değerlere ne kadar ağırlık verileceğini belirler. β trend düzleştirme için kullanılan doğrusal düzleştirme parametresidir. Mevsimsellik ise γ düzleştirme parametresi kontrol edilmektedir. Her üç parametre de 0 ile 1 arasında nümerik değerlere

sahiptir ($0 < \alpha, \beta, \gamma < 1$). Holt-Winters yönteminin genel ifadeleri Denklem 1-4 'de ve bu denklemlerde kullanılan sembollere ait açıklamalar da Tablo-1 'de verilmiştir.

$$L_t = \alpha \frac{Y_t}{S_{t-m}} + (1 - \alpha)(L_{t-1} - T_{t-1}) \quad (1)$$

$$T_t = \beta(L_t - L_{t-1}) + (1 - \beta)T_{t-1} \quad (2)$$

$$S_t = \gamma \frac{Y_t}{L_t} + (1 - \gamma)S_{t-m} \quad (3)$$

$$F_{t+k} = (L_t + T_t k)S_{t-m+k} \quad (4)$$


Tablo 1: Kullanılan parametrelere ait açıklamalar

Parametre	Açıklama
m	Mevsim uzunluğu(Bir yıl içerisindeki mevsim sayısı)
Y_t	Değişkenin t anındaki gözlem değeri
L_t	Serinin t dönemindeki genel seviyesi
T_t	Trend bileşeni
S_t	Mevsimsel bileşen
F_{t+k}	k ileri dönem için tahmin değeri
α	Modelin ortalama düzey düzleştirme sabiti
β	Trend düzleştirme sabiti
γ	Mevsimsel düzleştirme sabiti

Holts-Winters yöntemi mevsimsellik bilgisinin tipine göre iki farklı modele sahiptir. Bunlar; Çarpımsal (Multiplicative Seasonal) ve Toplamsal (Additive Seasonal) modellerdir. Mevsimsel değişimlerin seri boyunca büyük oranda sabit olduğu durumlarda toplamsal model, mevsimsel değişimlerin serinin seviyesiyle orantılı olarak değiştiği durumlarda ise çarpımsal model tercih edilir.

2.2. Veri setleri ve Karakteristik Yapıları

Çalışmada, KDYT ve ODAYT için EPIAŞ Şeffaflık Platformundan alınan ve Türkiye'deki gerçek zamanlı tüketim miktarını gösteren verilerden elde edilen 3 adet veri seti kullanılmıştır. Bunlardan ilki, 17.08.2023 tarihi 00:00 saati ile 23.08.2023 tarihi 23:00 saati arasındaki 168 adet saatlik veriden oluşan haftalık veri setidir (HTVS). İkincisi, aylık veri seti (ATVS) olup 24.07.2023 tarihi 00:00 saati ile 23.08.2023 tarihi 23:00 saati arasındaki 744 adet saatlik bilgileri içermektedir. Son veri seti ise 24.08.2022 tarihi 00:00 saati ile 23.08.2023 tarihi 23:00 saati arasındaki 8760 adet saatlik veriden oluşan yıllık veri setidir (YTVS). Zaman serisi analizlerinde veri seti karakteristikleri kullanılacak yöntemin belirlenmesinde önem arz eder. Holt-Winters yöntemi, trend ve mevsimsellik içeren zaman serilerine odaklandığı için veri setlerinde bu karakteristiklerin olup olmadığı incelenmelidir. Yapılan çözümlere ait sonuçlar Şekil-1'de görülebilir. Her üç veri setinde de aslında çok periyodik olmayan mevsimsellik (seasonality / cycling) görülmektedir. Bununla birlikte belirli zamanlarda trend davranışı da kısmi olarak vardır. Veri setlerinin durağanlık testleri ise Augmented Dickey Fuller (ADF) ve Kwiatkowski-Phillips-Schmidt-Shin (KPSS) yöntemleri ile yapılmıştır. Bu testlere ait detaylı sonuçlar ise Tablo-2'de paylaşılmıştır. Durağanlık testleri yapan istatistiksel yöntemler aynı veri setleri için farklı sonuçlar verebilmektedir. Bunun nedeni veri setinin eğilim-durağan veya fark-durağan karakteristiğe sahip olmasıdır. KPSS'nin durağan, ADF ise durağan olmadığını durumlar eğilim-durağanlığı (trend stationary), KPSS'in durağan olmadığını, ADF ise durağan olduğu durumlar ise fark-durağanlığı (difference stationary) gösterir. Buna göre, haftalık ve aylık tüketim veri setlerinin karakteristiği eğilim-durağan iken, yıllık tüketim veri setinin fark-durağan karakteristiğe sahip olduğu görülmektedir.



Şekil 1. Kullanılan veri setlerine ait trend ve mevsimsellik çözümleme sonuçları

Tablo 2. Durağanlık Testleri

	ADF			KPSS		
	Kritik Değer	p-Value	ADF Sonucu	Kritik Değer	p-Value	KPSS Sonucu
Haftalık Tüketim	-2.155	0.223	Durağan Değil	0.128	0.100	Durağan
Aylık Tüketim	-1.870	0.346	Durağan Değil	0.068	0.100	Durağan
Yıllık Tüketim	-6.313	3.19e-08	Durağan	2.772	0.010	Durağan Değil

3. Talep Tahminleri

Deneylerde tüm veri setleri % 80-20 oranında eğitim ve test verileri olarak ayrılmıştır. Model eğitimleri eğitim verileri ile örneklem içi (in-sample), başarımlar ise test verileri ile kontrol edilmiştir. Örneklem dışı başarımlar, haftalık gelecek tahminlerinde 12 saat, aylık gelecek tahminlerinde 72 saat ve yıllık gelecek tahminlerinde 168 saat için yapılmıştır. Modellerin performans değerlendirmeleri ise Denklem 5-6'da verilen R^2 ve Kök Ortalama Kare Hata (Root Mean Squared Error-RMSE) metrikleri üzerinden irdelenmiştir. Burada, SS_{Hata} hataların karelerinin toplamını, SS_{Toplam} bağımlı değişkenin değerleri ile ortalama değer arasındaki farkların kareleri toplamıdır.

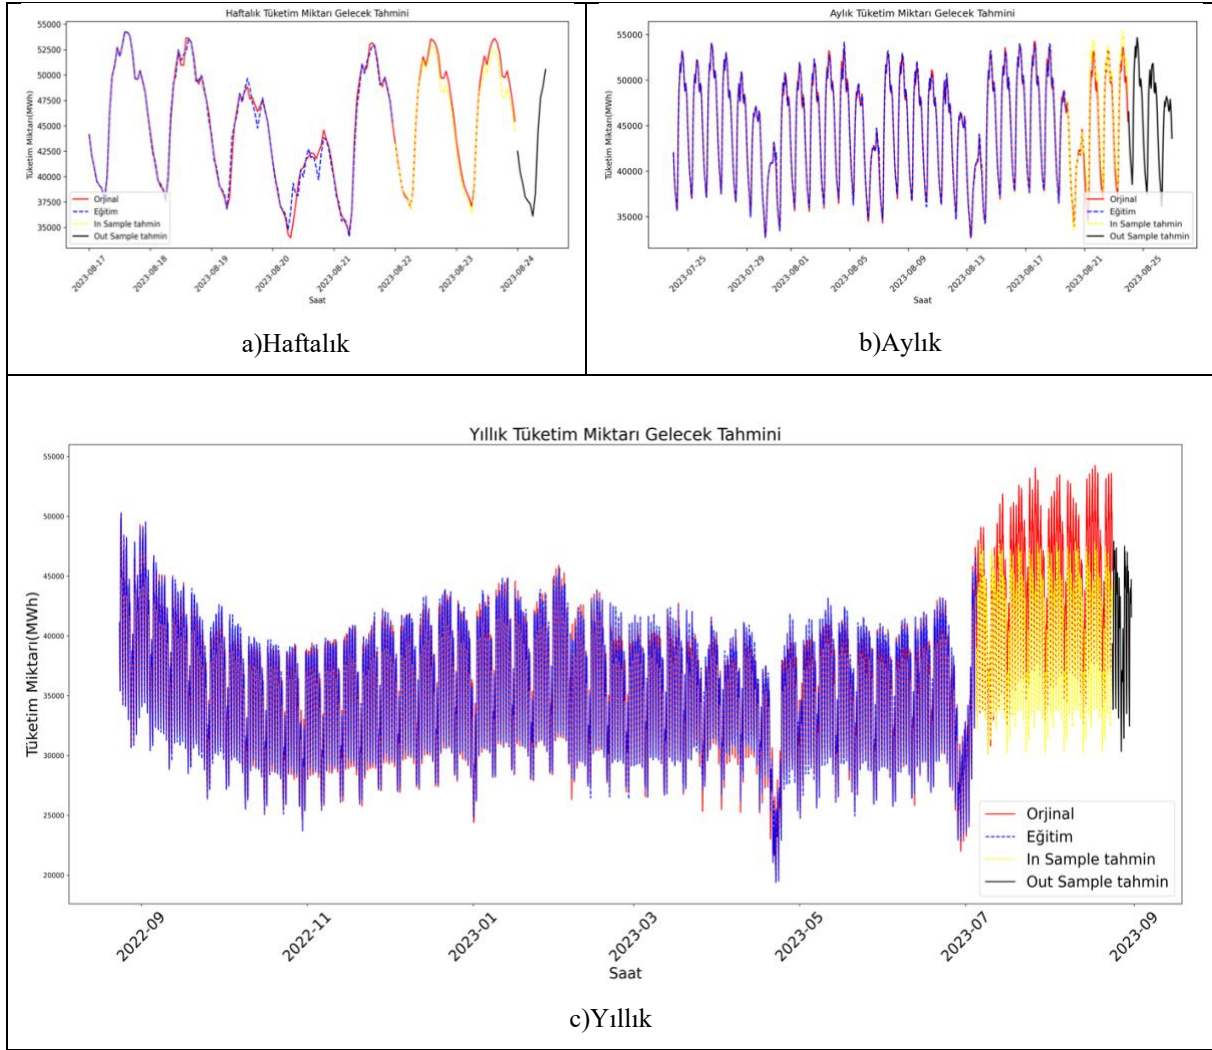
$$R^2 = 1 - \frac{SS_{Hata}}{SS_{Toplam}} \quad (5)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (Tahmin_i - Gerçek_i)^2}{N}} \quad (6)$$

Çalışmada kullanılan her bir veri seti için modelin performansı farklı başarımlar metrikleri ile değerlendirilmiş ve örneklem içi başarımlar sonuçları Tablo 3'te gösterilmiştir. Bu sonuçlara göre hem RMSE hem de R^2 değeri açısından ATVS ile modelin diğer veri setlerine göre daha iyi, HTVS ile modelin ATVS'ye göre daha kötü ancak YTVS'ye göre daha iyi performans gösterdiği görülmüştür.

Tablo 3. Örneklem içi başarımlar sonuçları

	RMSE	R^2
Haftalık Tüketim Veri Seti	775.048	0.981
Aylık Tüketim Veri Seti	614.819	0.987
Yıllık Tüketim Veri Seti	1628.657	0.922



Şekil 2. Örneklem dışı tahminler

Modeller test setleri üzerinde uygulandıktan sonra elde edilen sonuçlar ve gerçekleştirilen gelecek tahmini Şekil 2'de gösterilmektedir. Şekillerin her biri orijinal, eğitim, örneklem içi tahmin edilen ve örneklem dışı tahmin edilen enerji tüketiminin saatlik gözlemlerinin çıktısını temsil eder. Modellerin her birinde eğitim ve örneklem içi tahminlerin çok küçük farklarla orijinal değerleri takip ettiği görülmektedir. Örneklem dışı tahminlerde ise HTVS ve ATVS ile gelecek enerji tüketiminin önceki dönemlerle benzer olacağı, YTVS ile gelecek enerji tüketiminin bir önceki yıla göre azalacağı gözlemlenmektedir.

Yapılan analizler, özellikle akıllı şebeke sistemleri gibi nesnelerin interneti temelli alt yapı teknolojilerinin gözlem ünitelerde veya karar verici modüllerde kullanılması önemli avantajlar sağlayabilecektir. Öte yandan son yıllarda ortaya çıkan ve farklı disiplinlerde kullanılan kural tabanlı veya rastgele arama temelli teknikler ile geliştirilecek hibrit yaklaşımlar, bu analizlere farklı bakış açıları katabilir [17,18].

4.Sonuç ve Öneriler

Bu çalışmada Türkiye' deki KDYT ve ODYT analizlerine odaklanılmıştır. Bu analizler, EPIAŞ Şeffaflık Platformundan alınan ve Türkiye'deki gerçek zamanlı tüketim miktarını gösteren verilerden elde edilen 3 adet veri seti üzerinden yapılmıştır. Haftalık, aylık ve yıllık olmak üzere üç farklı periyot için yapılan bu analizler, önemli düzleştirme yöntemlerinden olan Holt-Winters metodu ile gerçekleştirilmiştir. Analiz ve tahmin sonuçları, mevsimsellik içeren bu verilerle modelin başarılı olduğunu göstermektedir.

Örneklem için tahminlerde R^2 başarımları 0.9'un üzerinde olup bu modeller ile yapılan örneklem dışı tahminlerde yakın dönem tüketim miktarlarının devam edeceğini göstermektedir. Yazarlar bundan sonraki çalışmalarında çoklu parametre girdilerini dikkate alan hibrit analizlere odaklanacaktır.

Yazarların Katkısı

Bu makalenin yazılmasına tüm yazarlar eşit katkıda bulunmuştur.

Çıkar Çatışması

Yazarlar çıkar çatışması olmadığını beyan etmektedir.

Referanslar

- [1] D. Akmaz. "Çok Katmanlı Algılayıcı Algoritması, Korelasyon Tabanlı Özellik Seçme Yöntemi ve Eğri Uydurma Tekniği ile Türkiye'de Toplam Elektrik Tüketiminin Tahmin Edilmesi." *Fırat Üniversitesi Mühendislik Bilimleri Dergisi* 34.2 (2022): 677-686
- [2] Khan, Ahsan Raza ve diğerleri. "Load forecasting, dynamic pricing and DSM in smart grid: A review." *Renewable and Sustainable Energy Reviews* 54 (2016): 1311-1322.
- [3] M. Saçlı. "Dağıtım Şebekesinde Kısa Dönem Yük Tahmini." Phd Thesis, Fen Bilimleri Enstitüsü.
- [4] Khotanzad, Alireza ve diğerleri. "ANNSTLF-a neural-network-based electric load forecasting system." *IEEE Transactions on Neural networks* 8.4 (1997): 835-846.
- [5] T. Akman, C. Yılmaz, Y. Sönmez. "Elektrik Yükü Tahmin Yöntemlerinin Analizi." *Gazi Mühendislik Bilimleri Dergisi* 4.3 (2018): 168-175.
- [6] F. Kaytez. "En Küçük Kareler Destek Vektör Makineleri ile Türkiye'nin Uzun Dönem Elektrik Tüketim Tahmini ve Modellenmesi." Ankara: Gazi Üniversitesi FBE, Doktora Tezi, Yayınlanmamış (2012).
- [7] M. C. Kargar, K. Charsoghi. "Predicting annual electricity consumption in Iran using artificial neural networks (NARX)." *Indian J. Sci. Res* 5.1 (2014): 231-242.
- [8] A. Abdoos, M. Hemmati, "Short term load forecasting using a hybrid intelligent method." *Knowledge-Based Systems* 76 (2015): 139-147.
- [9] S. Fan, R.J Hyndman. "Short-term load forecasting based on a semi-parametric additive model." *IEEE transactions on power systems* 27.1 (2011): 134-141.
- [10] Ö. Demirel, A. Kakilli, M. Tektaş, "Anfis ve arma modelleri ile elektrik enerjisi yük tahmini." *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi* 25.3 (2010).
- [11] I. Akgül. "Zaman serisi analizi ve öngörü modelleri." *Öneri Dergisi* 1.1 (1994): 52-69.
- [12] S. Makridakis, S.C. Wheelwright, R.J. Hyndman. *Forecasting: Methods And Applications*. New York: John Wiley And Sons (2008).
- [13] P.S. Kalekar. "Time series forecasting using holt-winters exponential smoothing." *Kanwal Rekhi school of information Technology* 4329008.13 (2004): 1-13.
- [14] M. Çuhadar, İ. Güngör, A. Göksu. "Turizm Talebinin Yapay Sinir Ağları İle Tahmini Ve Zaman Serisi Yöntemleri İle Karşılaştırmalı Analizi: Antalya İline Yönelik Bir Uygulama." *Suleyman Demirel University Journal of Faculty of Economics & Administrative Sciences* 14.1 (2009).
- [15] E. Özkan, E. Güler, Z. Aladağ. "Elektrik enerjisi tüketim verileri için uygun tahmin yöntemi seçimi." *Endüstri Mühendisliği* 31.2 (2020): 198-214.
- [16] Y. Özger ve diğerleri. "Electrical load forecasting using genetic algorithm based holt-winters exponential smoothing method." *Sakarya University Journal of Computer and Information Sciences* 3.2 (2019): 108-123.
- [17] G. Yıldırım, "A novel hybrid multi-thread metaheuristic approach for fake news detection in social media". *Appl Intell* 53, 11182–11202, <https://doi.org/10.1007/s10489-022-03972-9>, (2023).
- [18] G.ıldırım, "A novel grid-based many-objective swarm intelligence approach for sentiment analysis in social media", *Neurocomputing*, Vol.503, 2022, <https://doi.org/10.1016/j.neucom.2022.06.092>, (2022).



An Investigation on the Execution of the Document Clustering Process on Internet News

Metin Oktay BOZ¹, Jale BEKTAŞ²

¹Mersin üniversitesi; 0009-0006-8620-7775

²Mersin üniversitesi; 0000-0002-8793-1486

* Corresponding Author: 22023010006@mersin.edu.tr

Received: 27 June 2024 ; Accepted: 18 June 2024

Reference/Atf: M. O. Boz and J. Bektaş, "An Investigation on the Execution of the Document Clustering Process on Internet News", Researcher, vol. 04, no. 02, pp. 113–119, 2024.



Abstract

Numerous investigations have focused on recognizing Internet news as valid documents. This study encompasses the application of text mining techniques to generate a TF-IDF matrix and the subsequent automatic identification and categorization of an optimal number of clusters. The research examines the impact of K-Means document clustering on internet news articles, integrating the User Engagement dataset which includes articles from various esteemed publishers. Prior to implementing the K-Means algorithm, several preprocessing steps were undertaken to prepare the TF-IDF matrix. Due to the absence of the content attribute data, the description attribute was selected for document clustering. During preprocessing, extraneous ASCII symbols, punctuation marks, line breaks, emails, mentions, internet extensions, stopwords, and words outside the 2 to 21 character range were removed. Words were stemmed to consolidate different forms of the same root. The Elbow method was employed on the TF-IDF matrix to determine the optimal number of clusters, followed by an analysis of results using prominent words and word clouds. Ultimately, five clusters of document counts 797, 408, 89, 364, and 8755 were identified.

Keywords: K-Means, TF-IDF, Clustering, Document Clustering

1. Introduction

In this study, we embark on a journey through the intricate domain of document clustering, with a particular focus on the "Internet news data with readers engagement" dataset. Our mission unfolds in several pivotal stages, each contributing to the overarching goal of unveiling insightful cluster analysis. It all begins with meticulous data preprocessing, where we meticulously cleanse the dataset of empty rows and parse texts into individual words, setting the stage for effective clustering. Leveraging the TF-IDF (Term Frequency-Inverse Document Frequency) method, we extract features to gauge the significance of words within documents, laying a robust foundation for subsequent analysis. The heart of our study lies in the application of the K-Means algorithm, a cornerstone of unsupervised machine learning, which diligently partitions the dataset into K clusters based on similarity. Through iterative refinement and the judicious use of the Elbow Method to determine the optimal number of clusters, we unveil clusters ripe for analysis. Visualizations further enhance our understanding by showcasing the most prominent terms within each cluster, revealing distinct thematic threads lurking within the corpus, ranging from geopolitics to journalism. This systematic approach not only refines the dataset but also unveils nuanced insights, illuminating the latent patterns and narratives embedded within the textual data.

2. Data Preprocessing

Before processing the dataset, it must be prepared depending on the algorithm or operations to be applied. To perform preprocessing, understanding the structure of the dataset is essential. Within the dataset, there are two headers suitable for clustering: 'description' and 'content'. While data from the 'content' header is preferred for its representation of the articles' content, the 'description' header, containing summaries of the news, is also utilized due to the unavailability of complete content in the dataset. Data in this header was cleaned of empty rows before processing, resulting in a dataset

comprising 10,413 rows. Following the removal of empty spaces, text within the dataset was segmented into individual words. Furthermore, stop words in English, words with less than two characters, ASCII symbols, commas, special characters, emails and mentions, and internet extensions were cleansed using appropriate functions. Additionally, for more meaningful clustering results, words within the dataset were organized to retain only their roots.

Latest figures suggest Government is on course to hit its tax and spending targets
 latest figur suggest governmet cours hit tax spend target

Figure 1: Comparison Before and After Data Preprocessing

3. Feature Extraction with TF-IDF

At this stage, determining the importance of a word for a document is crucial for utilizing the preprocessed dataset in the K-Means algorithm. TF-IDF (Term Frequency-Inverse Document Frequency) is a numerical statistic aimed at reflecting the importance of a term for the document it is deemed relevant to. This method operates by increasing the weight of a term when it appears multiple times in a document, while decreasing the weight when it is common across many documents. This weight typically ranges between 0 and 1, signifying the term's significance within the context of the document.

	0	1	2	3	4	5	6	7	8	9	...	10403	10404	10405	10406	10407	10408	10409	10410	10411	10412		
tesla	0.398867	0.0	0.0	0.000000	0.0	0.0	0.0	0.0	0.0	0.0	...	0.0	0.000000	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.000000	
board	0.365565	0.0	0.0	0.000000	0.0	0.0	0.0	0.0	0.0	0.0	...	0.0	0.000000	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.000000
culver	0.261741	0.0	0.0	0.000000	0.0	0.0	0.0	0.0	0.0	0.0	...	0.0	0.000000	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.000000
autopilot	0.245217	0.0	0.0	0.000000	0.0	0.0	0.0	0.0	0.0	0.0	...	0.0	0.000000	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.000000
mode	0.224751	0.0	0.0	0.000000	0.0	0.0	0.0	0.0	0.0	0.0	...	0.0	0.000000	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.000000
struck	0.220808	0.0	0.0	0.000000	0.0	0.0	0.0	0.0	0.0	0.0	...	0.0	0.000000	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.000000
truck	0.206473	0.0	0.0	0.000000	0.0	0.0	0.0	0.0	0.0	0.0	...	0.0	0.000000	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.000000
assist	0.198552	0.0	0.0	0.000000	0.0	0.0	0.0	0.0	0.0	0.0	...	0.0	0.000000	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.000000
transport	0.194501	0.0	0.0	0.000000	0.0	0.0	0.0	0.0	0.0	0.0	...	0.0	0.000000	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.000000
model	0.191618	0.0	0.0	0.000000	0.0	0.0	0.0	0.0	0.0	0.0	...	0.0	0.000000	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.000000
safeti	0.187761	0.0	0.0	0.000000	0.0	0.0	0.0	0.0	0.0	0.0	...	0.0	0.000000	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.000000
driver	0.186580	0.0	0.0	0.000000	0.0	0.0	0.0	0.0	0.0	0.0	...	0.0	0.000000	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.000000
crash	0.174416	0.0	0.0	0.000000	0.0	0.0	0.0	0.0	0.0	0.0	...	0.0	0.000000	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.000000
involv	0.170811	0.0	0.0	0.000000	0.0	0.0	0.0	0.0	0.0	0.0	...	0.0	0.000000	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.000000
system	0.170473	0.0	0.0	0.000000	0.0	0.0	0.0	0.0	0.0	0.0	...	0.0	0.000000	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.000000
seri	0.163884	0.0	0.0	0.264569	0.0	0.0	0.0	0.0	0.0	0.0	...	0.0	0.000000	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.000000
california	0.157189	0.0	0.0	0.000000	0.0	0.0	0.0	0.0	0.0	0.0	...	0.0	0.000000	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.000000
fire	0.149508	0.0	0.0	0.000000	0.0	0.0	0.0	0.0	0.0	0.0	...	0.0	0.000000	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.000000
citi	0.142234	0.0	0.0	0.000000	0.0	0.0	0.0	0.0	0.0	0.0	...	0.0	0.123276	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.000000
investig	0.136722	0.0	0.0	0.000000	0.0	0.0	0.0	0.0	0.0	0.0	...	0.0	0.000000	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.15508

Figure 2: The Top 15 Terms with Highest Weight

4. Application of K-Means Algorithm and Cluster Analysis

K-Means stands as one of the simplest and most popular machine learning algorithms to date. Operating without the utilization of labeled data, it epitomizes an unsupervised algorithm, signifying that in this context, no single text belongs to a specific class or group. It functions as a clustering algorithm that categorizes a dataset into K clusters. The underlying principle of this algorithm revolves around defining the clusters by K centroids. Each centroid represents a center of a cluster. The algorithm iteratively operates by initially randomly placing each centroid into the dataset's vector space and then shifting them towards points closer to themselves. With each iteration, the distances between each centroid and

points are recalculated, and centroids are relocated to the centers of the nearest points. The algorithm concludes when either the positions or groups no longer change, or when the distance by which centroids change falls below a predefined threshold. Given the ambiguity regarding the ideal number of clusters initially, the K-Means algorithm was executed with cluster numbers ranging from 1 to 10, and the results were scrutinized to determine the optimal K value. The Elbow Method was employed for this determination, wherein the sum of squared distances of points to the cluster centroids is calculated for each K value, and a graphical representation is generated. The inflection point on the graph, where the rate of decrease in the sums begins to diminish, denotes the most suitable K value.

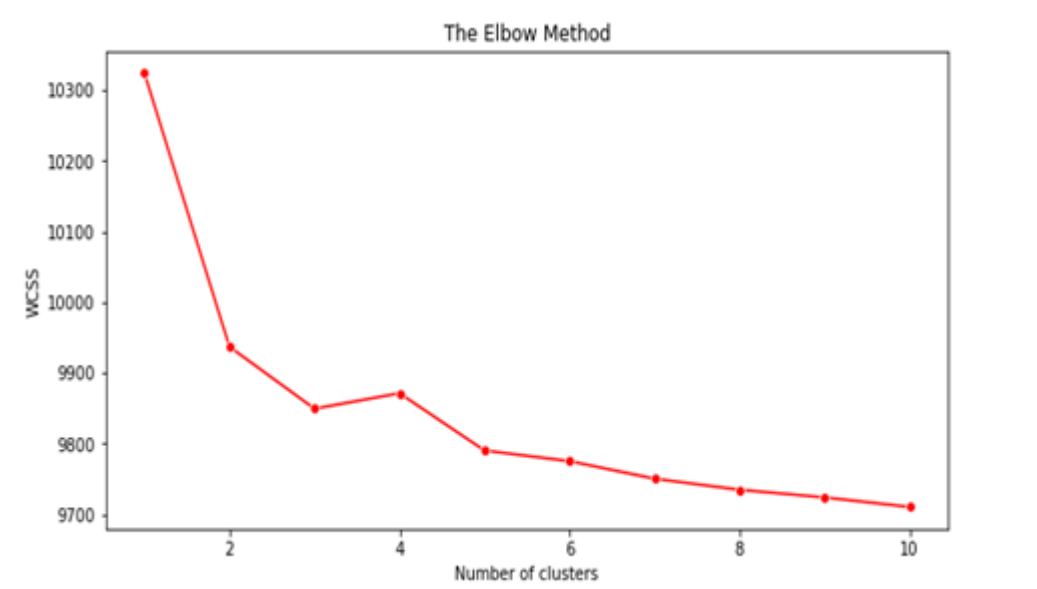


Figure 3: The Graphs Drawn for Each K Value

Based on the trend observed in the graph, where the difference starts diminishing from the point where K equals 5, this value is chosen as the optimal one.

5. Results and Evaluation

Following the execution of the K-Means algorithm with a K value of 5, the most popular terms in each cluster were visualized, and word clouds were generated.

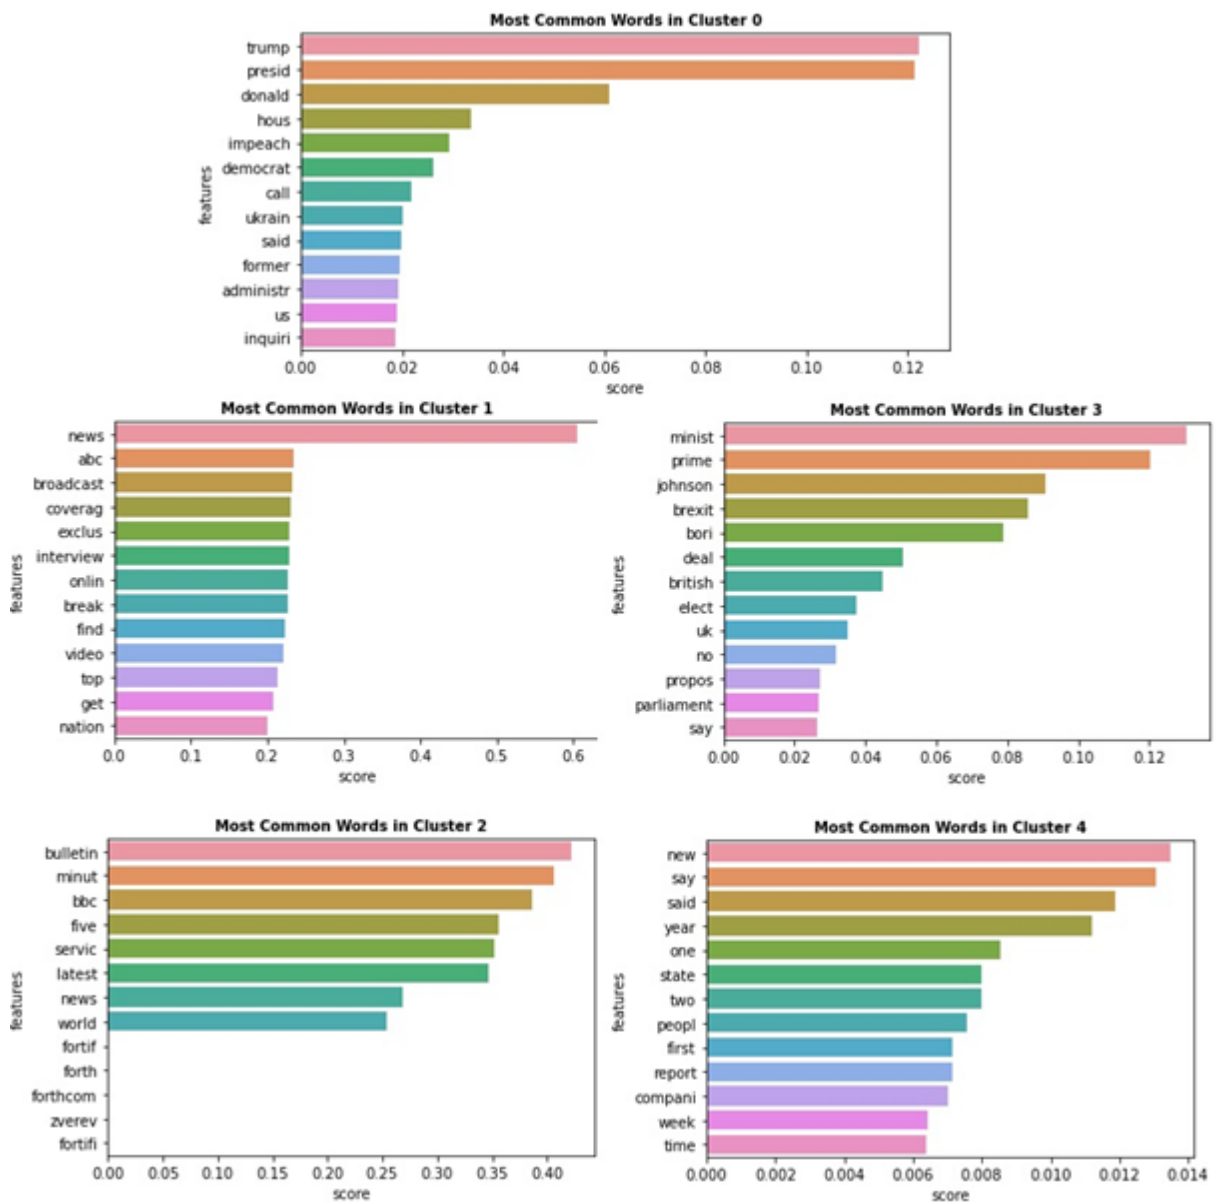


Figure 4: The Most Popular Terms for Each Cluster




Figure 5: F Word Clouds Created for Each Cluster

Upon examining the clusters generated by the K-Means algorithm, distinct thematic threads and patterns emerged, shedding light on the underlying structures within the dataset. Notably, the first cluster prominently featured terms related to the United States, suggesting a concentration of news articles pertaining to American affairs. In contrast, the second cluster showcased terms associated with publishing, indicative of articles discussing the journalism industry and its practices. The third cluster revealed a focus on journalism-related terms, suggesting a thematic emphasis on the profession itself. Similarly, the fourth cluster exhibited a concentration of terms related to the United Kingdom, indicating a distinct regional focus within the dataset. Finally, the fifth cluster presented a diverse array of fundamental terms, reflecting a broad spectrum of topics encompassing various aspects of news and information dissemination.

Furthermore, the respective sizes of each cluster provided valuable insights into the distribution of articles across different thematic categories. The largest cluster, comprising 8755 documents, represented a comprehensive collection of articles covering diverse subjects. In contrast, smaller clusters, such as the third and fourth clusters with 89 and 364 documents respectively, highlighted more specialized topics within the dataset. These findings underscore the effectiveness of the K-Means algorithm in discerning meaningful patterns and clustering documents based on their thematic content.

Through this systematic approach, our study has successfully elucidated the inherent structure of the dataset, offering valuable insights into the composition and distribution of internet news articles.

6. General Evaluation and Conclusions

To facilitate the application of the K-Means algorithm and achieve cleaner results, preprocessing was conducted on the dataset. Once the dataset was refined to a state conducive for obtaining accurate outcomes, feature extraction was performed using the TF-IDF method. This methodology enabled the determination of the weight associated with each term for every document, providing valuable insights into the dataset's structure. Subsequently, the K-Means algorithm was applied with cluster numbers ranging from 1 to 10, and the optimal K value was determined using the Elbow Method, resulting in a choice of 5 clusters. Within these 5 clusters, the most popular terms were identified for each, and word clouds were generated accordingly. Upon examining the clusters, distinct thematic threads emerged, with the prominence of terms related to the United States in the first cluster, publishing in the second, journalism in the third, and the United Kingdom in the fourth. The fifth cluster exhibited a collection of fundamental terms. The respective term counts for the clusters were as follows: 797, 408, 89, 364, and 8755. Throughout the implementation process, insights from the article "Text Clustering with K-Means" were taken into consideration.

Contribution of Researchers

Metin Oktay BOZ was responsible for the collection of a large dataset comprising internet news articles and the execution of various preprocessing steps. This involved the removal of extraneous characters, handling stop-words, and filtering out irrelevant information, which enhanced the quality of the dataset. Also performed the feature extraction and vectorization of the news texts. The TF-IDF (Term Frequency-Inverse Document Frequency) method was used to transform the news articles into vectorized representations, with each article represented by a vector based on the importance levels of its contained words. Furthermore, he applied the K-Means algorithm, a clustering technique that partitions the dataset into a predetermined number of clusters, using the vectorized representations of the news articles. This facilitated the grouping of news articles based on similar themes. Finally, he conducted the cluster analysis and interpreted the findings. This analysis revealed how news articles were grouped around specific topics and explored the contribution of clustering results to understanding and analyzing news content.

Asst.Prof.Dr. Jale BEKTAŞ provided invaluable guidance and support throughout the study, contributing to the design of the study, interpretation of results, and review of the manuscript.


Throughout all these stages, Metin Oktay BOZ and Asst.Prof.Dr. Jale BEKTAŞ collaborated to ensure the quality and accuracy of the research.

Conflicts of Interest

The authors declare that there are no conflicts of interest regarding the publication of this research. The collection, analysis, and interpretation of data, as well as the writing of the manuscript, were conducted in an objective and unbiased manner. No financial or personal relationships with any individuals or organizations that could potentially bias the findings of this study exist. Furthermore, there are no competing interests related to employment, consultancy, patents, products in development, or marketed products that could influence the research process or outcomes. This research was conducted solely for academic and scientific purposes, with the aim of contributing to the field of document clustering and analysis.

References

- [1] Adolfsson, A., Ackerman, M., & Brownstein, N. C. (2019). To cluster, or not to cluster: An analysis of clusterability methods. *Pattern Recognition*, 88, 13-26.
- [2] Al-Anazi, S., AlMahmoud, H., & Al-Turaiki, I. (2016). Finding Similar Documents Using Different Clustering Techniques. *Procedia Computer Science*, 82, 28-34.
- [3] Bezdan, T., Stoean, C., Naamany, A. A., Bacanin, N., Rashid, T. A., Zivkovic, M., & Venkatachalam, K. (2021). Hybrid Fruit-Fly Optimization Algorithm with K-Means for Text Document Clustering. *Mathematics*, 9(16), 1929.
- [4] Capó, M., Pérez, A., & Lozano, J. A. (2020). An efficient K-means clustering algorithm for tall data. *Data Mining and Knowledge Discovery*, 34, 776–811.
- [5] Hartigan, J. A., & Wong, M. A. (1979). Algorithm AS 136: A K-Means Clustering Algorithm. *Journal of the Royal Statistical Society. Series C (Applied Statistics)*, 28(1), 100-108.
- [6] Hu, G., Zhou, S., Guan, J., & Hu, X. (2008). Towards effective document clustering: A constrained K-means based approach. *Information Processing & Management*, 44(4), 1397-1409.
- [7] Janowski, S. (2020). Internet News Data with Readers Engagement. <https://www.kaggle.com/datasets/szymonjanowski/internet-articles-data-with-users-engagement>. [Accessed: 19-Dec-2023].
- [8] Jarvis, R. A., & Patrick, E. A. (1973). Clustering Using a Similarity Measure Based on Shared Near Neighbors. *IEEE Transactions on Computers*, C-22(11), 1025-1034.
- [9] Liang, M., & Niu, T. (2022). Research on Text Classification Techniques Based on Improved TF-IDF Algorithm and LSTM Inputs. *Procedia Computer Science*, 208, 460-470.
- [10] Luo, C., Li, Y., & Chung, S. M. (2009). Text document clustering based on neighbors. *Data & Knowledge Engineering*, 68(11), 1271-1288.
- [11] Mahdavi, M., & Abolhassani, H. (2009). Harmony K-means algorithm for document clustering. *Data Mining and Knowledge Discovery*, 18, 370–391.
- [12] Minaee, S., Gao, J., Kalchbrenner, N., Cambria, E., Nikzad, N., & Chenaghlu, M. (2021). Deep Learning--based Text Classification: A Comprehensive Review. *ACM Computing Surveys*, 54(3), Article 62, 1–40.
- [13] Mussabayev, R., Mladenovic, N., Jarboui, B., & Mussabayev, R. (2023). How to Use K-means for Big Data Clustering? *Pattern Recognition*, 137, 109269.
- [14] Ridzuan, F., & Zainon, W. M. N. (2019). A Review on Data Cleansing Methods for Big Data. *Procedia Computer Science*, 161, 731-738.
- [15] Sa, L. (2019). Text Clustering with K-Means. <https://medium.com/@lucasdesa/text-clustering-with-k-means-a039d84a941b>. [Accessed: 05-Jan-2024].
- [16] Saha, B., & Srivastava, D. (2014). Data quality: The other face of Big Data. In 2014 IEEE 30th International Conference on Data Engineering (pp. 31 March 2014 - 04 April 2014). IEEE. <https://doi.org/10.1109/ICDE.2014.6816764>
- [17] Thangaraj, M., & Sivakami, M. (2018). Text Classification Techniques: A Literature Review. *Interdisciplinary Journal of Information, Knowledge, and Management*, 13, 117-135.



Functional Resonance Analysis Method for the Manufacturing Industry: A Bibliometric Analysis of the Literature

Nazlı Gülüm MUTLU^{1*}

¹ Bingöl University, Department of Occupational Health and Safety, Bingöl, Turkey; ORCID: 0000-0003-0210-5175

* Corresponding Author: ngmutlu@bingol.edu.tr

Received: 5 March 2024; Accepted: 23 July 2024

Reference/Atf: N. G. Mutlu, “Functional Resonance Analysis Method for the Manufacturing Industry: A Bibliometric Analysis of the Literature”, Researcher, vol. 04, no. 02, pp. 120–129, 2024.



Abstract

The manufacturing industry is a socio-technical system with high and medium-high technology, and companies within these sectors aim to enhance their capabilities to maintain a competitive edge and ensure long-term sustainability. Organizational performance plays a crucial role in the ecosystem, but performance outcomes may not always align with continuous planning due to changes that can occur. Therefore, managing variability based on the human factor, particularly in the manufacturing industry, which has a significant impact on the national economy, is a top priority when developing solutions to address the challenges faced by these sectors. The Functional Resonance Analysis Method (FRAM) is a safety analysis technique that aims to analyze variability that causes deviations and well-performing situations. This study conducts a bibliometric analysis to provide insight into studies that have benefited from FRAM in the manufacturing industry. The study found that 52% of published works are journal articles, and Tarcisio Abreu Saurin and Eric Hollnagel are the most prominent authors in the field. For researchers, the top three journals for publishing and citing are Safety Science, Reliability Engineering & System Safety, and Ergonomics, respectively. Brazil, China, and Italy lead in the number of publications, with a limited number coming from Turkey. To identify research gaps, it is suggested that researchers use keywords such as FRAM, socio-technical systems, and resilience engineering. The results of this study are expected to motivate future research that will support the long-term viability of Turkey manufacturing industry, particularly.

Keywords: Manufacturing industry, socio-technical systems, safety analysis, FRAM, bibliometric analysis

1. Introduction

According to the NACE Rev.2 guide, manufacturing comprises 24 divisions [1]. While manufacturing is considered a substantial alteration, renovation, or reconstruction of materials, the output of the manufacturing process can either be ready for consumption or, in the form of semi-finished goods, serve as input for further manufacturing. Additionally, the assembly of the component parts of manufactured or purchased products is considered in manufacturing. Contemporary manufacturing systems are classified into five groups: cellular manufacturing, computer-aided manufacturing, just-in-time manufacturing, flexible manufacturing, and optimized manufacturing systems [2]. The manufacturing industry plays a crucial role in the economic development of countries [3, 4]. The sectors within it are known to possess high and medium-high levels of technology, which is a well-established fact [5]. Manufacturing companies typically prioritize investments in technology to maintain a competitive edge and enhance productivity [6, 7]. Adapting to rapidly evolving technology and understanding the social and technical components of the system, along with their functions, interactions, and potential threats, are essential for maintaining the continuity of the current state [8, 9]. In previous studies, it has been reported that occupational accidents affecting the safety and health of workers in the manufacturing industry are prominent, ranking among the top issues in different sectors [10–13]. Additionally, occupational diseases in the manufacturing industry have been emphasized as significant [14]. The data presented in Figure 1 indicates that the number of accidents per person employed in the manufacturing industry in Turkey is roughly twice as high as the ratio observed in EU member countries. The need for analyzing hazards in the manufacturing sector is unquestionably acknowledged.




Figure 1: The percentage of employee and accidents for the manufacturing industry in Turkey and European Union-27 countries [15, 16]

Safety analysis methods can be divided into two perspectives: Safety-I and Safety-II. Safety-I is based on the idea that identifying the causes of negative outcomes and reducing or eliminating their occurrences will enhance safety, and all accidents can be prevented by avoiding unwanted events in this way [17]. The notion that individual or collective human performance is always variable weakens the belief that eliminating causes alone is sufficient for improving safety [17]. The Functional Resonance Analysis Method (FRAM), proposed by Hollnagel [18], is a safety analysis method based on the Safety-II perspective. It assists in managing functions, interactions among them, and potential undesired effects on complex socio-technical systems, contributing to the enhancement of system safety. FRAM also provides reactive analysis, such as the examination of historical accident records [19, 20]. In FRAM, a function is characterized by six aspects: input (I), output (O), preconditions (P), resources (R), time (T), and control (C) [18]. The Figure 2 demonstrates an example Functional Resonance Analysis Method (FRAM) for a system comprised of four functions. In this scenario, the Output of Function-1 serves as the Control for Function-3, while the Output of Function-2 acts as the Input for Function-3. Lastly, the Output of Function-4 represents the Resources required for Function-3.




Figure 2: Example of FRAM model consist of four functions,

In a study carried out by Patriarca et al. [21], a thorough examination of the literature on FRAM was conducted using the Preferred Reporting Items for Systematic Reviews and Meta-analyses (PRISMA).

The results revealed that the top three sectors where FRAM applications are most prevalent are Aviation, Healthcare, and Industrial Operations. Among the literature reviews focusing on FRAM applications, there are studies such as those by McGill et al. [22] on FRAM applications in healthcare and Salehi et al. [23] on modeling complex socio-technical systems using FRAM. It is worth noting that no specific research has been conducted to investigate FRAM applications in the manufacturing industry. Therefore, this study aims to provide a quantitative overview of FRAM studies in the manufacturing industry through numerical indicators, providing researchers with a comprehensive perspective.

2. Method and Material

This research aims to provide a comprehensive perspective, supported by quantitative data, on the literature regarding the application of FRAM in the manufacturing industry. The decision to focus on the manufacturing industry was made based on the statistical classification of economic activities in the European Community Guide prepared by Carré [1]. Keywords were selected for the query based on relevant sectors and definitions within the industry. The query (ALL(“Functional Resonance Analysis Method”) AND ALL(“manufacture systems”) OR ALL(“manufacturing systems”) OR ALL(“assemble systems”) OR ALL(“production systems”) OR ALL(“manufacturing industry”)) AND PUBYEAR > 2012 AND PUBYEAR < 2024) was executed in the Scopus database on January 1, 2024. However, the five publications for the year 2024 were not included in the study, as the year had not yet been completed. In total, 92 publications of various types, published between 2013 and 2023, were included in the study. The dataset was analyzed using VOS viewer, a widely used tool in bibliometric analysis studies [24–26]. The main results of the analysis included co-authorship of authors, citation of authors, citation of countries, co-occurrence of author keywords, bibliographic coupling of documents, and bibliographic coupling of authors.

3. Results

The prevalence of publications utilizing the Functional Resonance Analysis Method within the manufacturing sector is depicted in Figure 3. A considerable proportion of these publications comprised of journal articles, whereas conference papers were less than half the number of journal articles. Upon analyzing the distribution of research by subject area, it was observed that the top three areas were engineering, computer science, and social science.




Figure 3: Document type in the dataset

In analyzing the publications related to FRAM in the manufacturing industry, a threshold of at least one publication and one citation was established for co-authorship. The study of shared authorship publications revealed that 25 authors were grouped into five clusters, comprising a total of 102 links and 104 total link strengths. The clusters to which the authors belong, along with the links, total link strength, and documents, are presented in Table 1. Tarcisio Abreu Saurin ranked first in terms of shared authorship publications, citations, links, and total link strength. The network map for the co-authorship of authors is illustrated in Figure 4. Although Ricardo Patriarca and Sylvie Nadeau, who each contributed six documents, are among the top three authors with the highest number of documents, and

Patrick Waterson and Peter Underwood, who each received 286 and 171 citations respectively, are among the top three authors with the most citations, they are not among the most connected authors as depicted in Figure 4.




Figure 4: Map for co-authorship of authors

Table 1: The cluster for co-authorship of authors

Cluster number	Cluster color	# Authors	# Links for each one author	# Total link strength for each one author	# Documents for each one author
1	Red	11	12	12	1
2	Green	5	5	5	1
3	Blue	4	1	1	1
		Tarcisio Abreu Saurin	24	26	10
4	Yellow	Michel Jose Anzanello	2	2	1
		Marlon Soliman	2	3	2
5	Violet	2	2	2	1

To assess the citation networks of authors, a citation analysis was conducted with a minimum threshold of one publication and one citation per author. Among the 76 authors, 380 links were identified, and they were grouped into six clusters. The 22 authors in Cluster 1 (red color) were followed by 15 authors in Cluster 2 (green color), 12 authors in Cluster 3 (blue color), 10 authors each in Cluster 4 and Cluster 5 (yellow and violet colors, respectively), and seven authors in Cluster 6 (turquoise color). The top three authors with the most citations are listed in Table 2. Tarcisio Abreu Saurin led in terms of the number of publications, citations, and total link strength. The network map of the citations among the authors is presented in Figure 5.

Table 2: Top 3 for citation of authors

Cluster number	Cluster color	Authors	Documents	Links	Citations	Total link strength
2	Green	Tarcisio Abreu Saurin	10	24	394	58
1	Red	Patric Waterson	2	24	286	43
3	Blue	Sylvie Nadeau	6	23	12	35

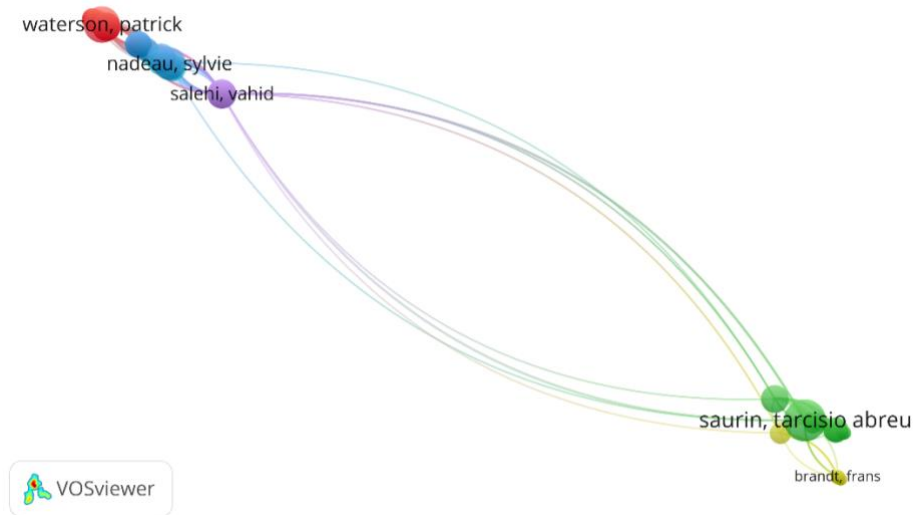


Figure 5: Map of citation of authors

To examine the network map of countries that produced, received citations, and had relationships among them, a threshold was set requiring at least one publication produced and one citation received by each country. A total of 14 countries were identified with relationships among them, forming five clusters within their own. There were 34 links between these countries. The United Kingdom had the most citations, while Brazil had the most documents. The network map of the citations among countries is shown in Figure 6. Turkey is included in Cluster 1, which has three documents, 37 citations, and a total link strength of three.

Table 3: Top 3 for citation of countries

Cluster number	Cluster color	Countries	Documents	Link	Citation	Total link strength
1	Red	United Kingdom	6	11	496	28
3	Blue	Canada	9	9	93	24
2	Green	Brazil	18	7	457	18
3	Blue	China	13	4	169	9
4	Yellow	Italy	12	6	249	14

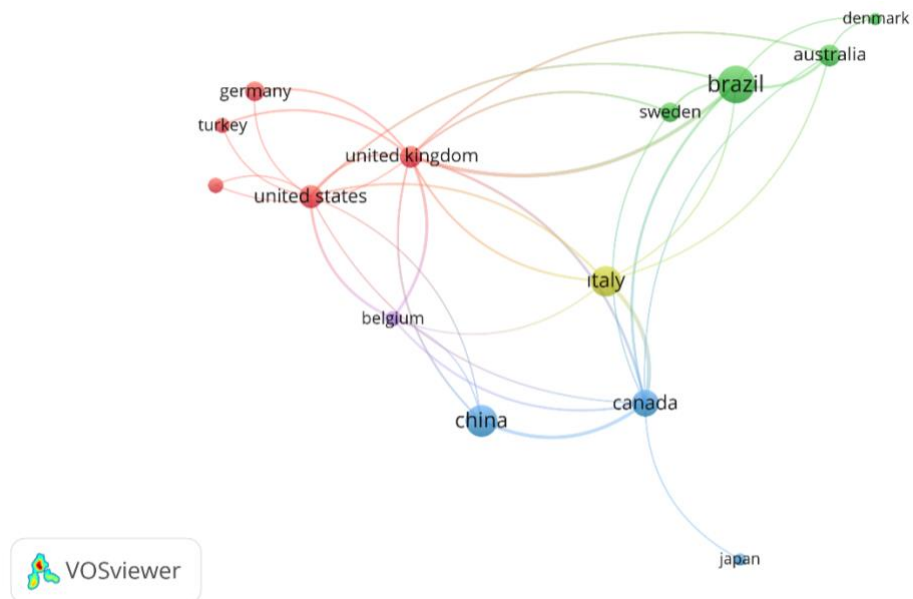


Figure 6: Map of citation of countries based on # document

The research conducted on "Co-occurrence of author keywords" uncovered the categorization of at least two related and observed keywords into seven distinct clusters, resulting in a total of 136 connections between them. Table 4 showcases the top three keywords in terms of overall link strength. Moreover, the network map portraying the co-occurrence of author keywords is illustrated in Figure 7.




Figure 7: Map of co-occurrence of authors keywords

Table 4: The top three keywords for co-occurrence of author keywords

Cluster number	Cluster color	Keyword	# Occurrences	Total link strength
5	Violet	fram	12	32
3	Blue	socio-technical systems	7	25
2	Green	resilience engineering	7	22

In conducting the analysis of “bibliographic coupling of authors”, it was stipulated that an author must have produced at least one publication and received at least one citation. The resulting network map displayed in Figure 8 indicates that 211 authors were grouped into 17 clusters, which represent various aspects of FRAM research in manufacturing. The largest cluster, comprising approximately 29% of the articles, was centered around Tarcisio Abreu Saurin. A network map for the bibliographic coupling of the authors is visible in Figure 8.




Figure 8: Map of bibliographic coupling of authors

The network map for the “Co-citation of cited authors” analysis, considering publications where an author received at least 10 citations, is depicted in Figure 9. This map shows that 116 authors are interconnected, forming five clusters. Although Tarcisio Abreu Saurin was the dominant author in the bibliographic coupling of authors, Hollnagel E. emerged as the most frequently cited author among them. The distribution of citations among the authors was more balanced (see Table 5).

Table 5: The top co-cited publications based link and total link strength

Cluster number	Cluster color	Authors	Link	Citations	Total link strength
4	Yellow	Hollnagel E.	114	291	12841
3	Blue	Patriarca R.	108	100	5957
4	Yellow	Abreu Saurin T.	102	86	3027

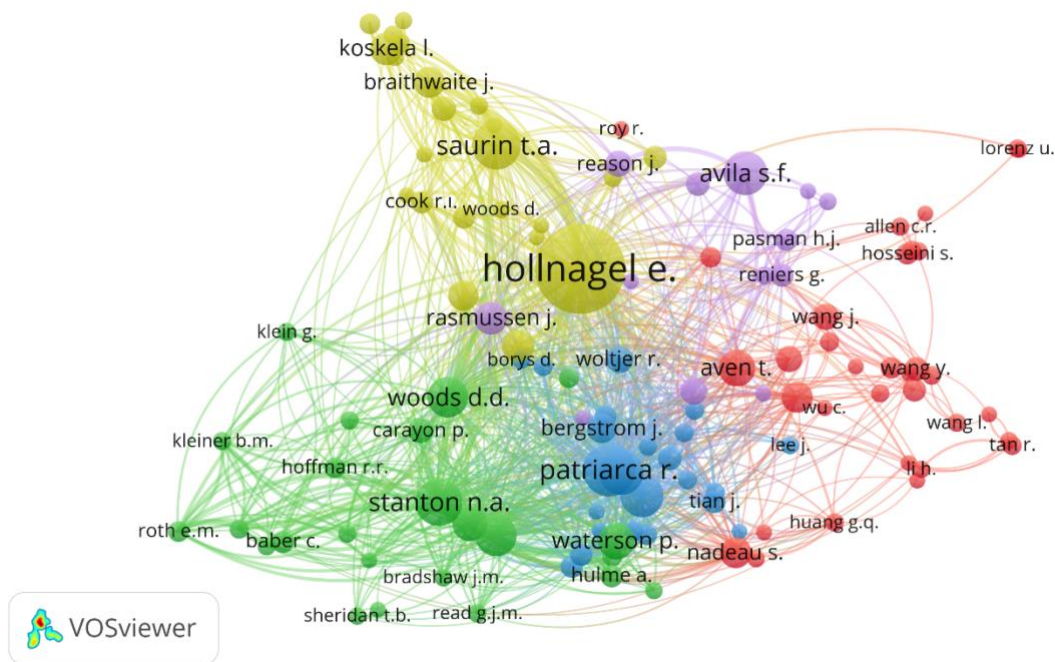


Figure 9: Map of co-citation of cited authors

The “bibliographic coupling of documents” analysis, which involves identifying works that have been cited by at least two independent sources, was conducted with a minimum threshold of one citation. This analysis resulted in the identification of 72 linked publications, which were grouped into eight clusters, and a total of 1043 links and a total link strength of 2265. The three publications with the highest bibliometric matching are Underwood (2013), with 171 citations, Waterson (2015), with 115 citations, and Almeida Marodin (2015), with 97 citations. In terms of total link strength, the top three publications are Braithwaite (2018), with a total link strength of 336, Hollnagel (2018), with a total link strength of 330, and Adriaensen (2019), with a total link strength of 162. The network map for the “Bibliographic coupling of documents” analysis is provided in Figure 10.

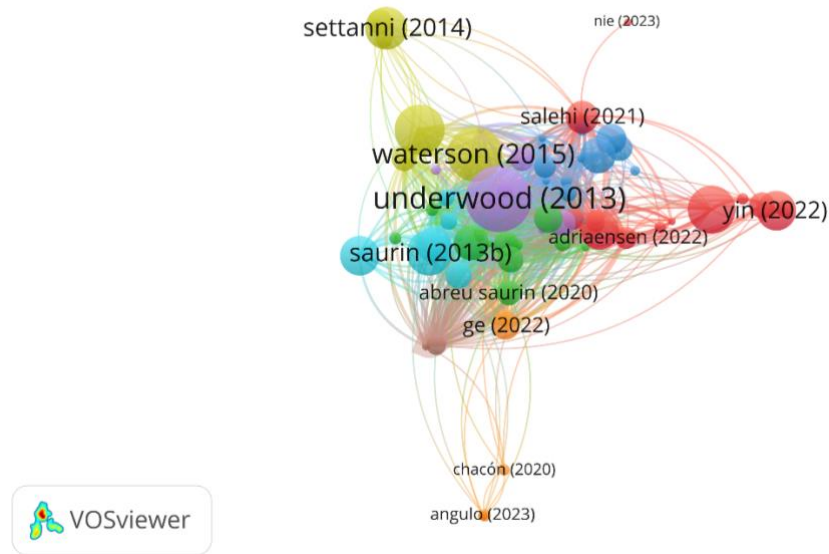


Figure 10: Map of bibliographic coupling of documents

In our analysis of “Co-citation of journal”, we applied a threshold of at least 20 citations per journal. This resulted in the identification of 19 journals that were grouped into four clusters, with a total of 107 links and a total link strength of 6,728. A network map for “Co-citation of journal” is presented in Figure 11. Among the 19 journals, the top three in terms of both citations received and total link strength were: (1) Safety Science (#citations=156, total link strength=2,684), (2) Reliability Engineering & System Safety (#citations=80, total link strength=1,402), and (3) Ergonomics (#citations=99, total link strength=1,578). It is worth noting that “safety science” and “saf. sci.” refer to the same journal, as do “reliability engineering & syst” and “reliab eng syst saf.” This is clear from the network map, which shows records with a single expression in the Scopus database. Furthermore, these journals are indexed using the SCIE index.

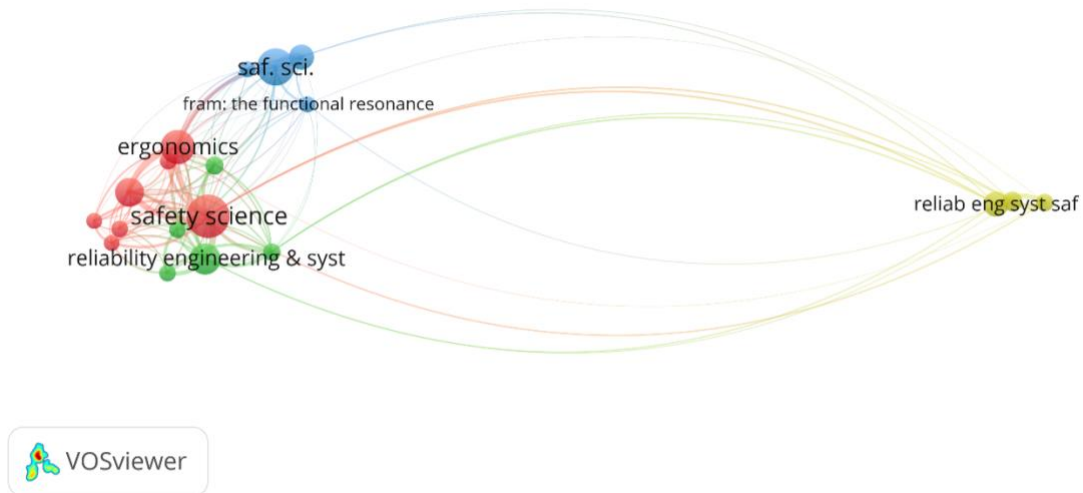


Figure 11: Map of co-citation analysis for journals

3. Conclusion

This study aimed to provide a comprehensive perspective for researchers by utilizing quantitative data on publications related to FRAM in the manufacturing industry from 2013 to 2023. Specifically, the study analyzed publications in the Scopus database and found that a significant number of them were published in the reputable journal, Safety Science. Tarcisio Abreu Saurin and Eric Hollnagel are

prominent authors in this field. The study also identified Brazil, China, and Italy as the countries with the highest number of publications in this domain.

For future research, it is suggested that researchers consider studies related to keywords such as FRAM, sociotechnical systems, and resilience engineering to identify research gaps. However, the study's analysis was limited to the Scopus database, and it is recommended that future studies utilize the Web of Science (WOS) and Google Scholar databases to reassess the consistency of the network map. This is due to the abbreviations and full names of the journals where publications are produced, which may result in incomplete data. Additionally, the inability to access index information for publication types through the Scopus database interface is another limitation to be considered.


Conflicts of Interest

The author declares no conflict of interest.

References

- [1]. Carré, H., "NACE Rev. 2, Statistical classification of economic activities in the European Community". General and regional statistics. p.44, 2008.
- [2]. Tanyaş, M., & Baskak, M., "Üretim Planlama ve Kontrol. İrfan Yayıncılık". p.25, 2015.
- [3]. Clark, D. P., Lima, L. R., & Sawyer, W. C., "Stages of diversification in high performing Asian economies". Journal of Economic Studies, 44(6): 1017-1029, 2017.
- [4]. Haraguchi, N., Cheng, C. F. C., & Smeets, E., "The importance of manufacturing in economic development: has this changed?". World Development, 93: 293-315, 2017.
- [5]. Özel, S., & Öztemel, E., "İşletmelerde Teknoloji Yönetimi ve Yetkinlik Bazlı Değerlendirme". Çanakkale Onsekiz Mart Üniversitesi Yönetim Bilimleri Dergisi, 16(31): 409-425, 2018.
- [6]. Novotná, M., Volek, T., Rost, M., & Vrchota, J., "Impact of technology investment on firm's production efficiency factor in manufacturing". Journal of Business Economics and Management, 22(1): 135-155, 2021.
- [7]. Bosman, L., Hartman, N., & Sutherland, J., "How manufacturing firm characteristics can influence decision making for investing in Industry 4.0 technologies". Journal of Manufacturing Technology Management, 31(5): 1117-1141, 2020.
- [8]. Albery, S., Borys, D., & Tepe, S., "Advantages for risk assessment: Evaluating learnings from question sets inspired by the FRAM and the risk matrix in a manufacturing environment". Safety science, 89: 180-189, 2016.
- [9]. Zheng, Z., Tian, J., & Zhao, T., "Refining operation guidelines with model-checking-aided FRAM to improve manufacturing processes: a case study for aeroengine blade forging". Cognition, Technology & Work, 18: 777-791, 2016.
- [10]. Mutlu, N., Selim, S., & Altuntaş, S., "A multinomial logit model based approach to find patterns among occupational accidents in Turkish manufacturing systems". Journal of the Faculty of Engineering and Architecture of Gazi University, 39(2): 1049-1066, 2024.
- [11]. Mutlu, N. G., Altuntas, S., & Dereli, T., "The evaluation of occupational accident with sequential pattern mining". Safety Science, 166: 106212, 2023.
- [12]. Mutlu, N. G., & Altuntas, S., "Assessment of occupational risks In Turkish manufacturing systems with data-driven models". Journal of Manufacturing Systems, 53: 169-182, 2019.
- [13]. Paguay, M., Febres, J. D., & Valarezo, E., "Occupational Accidents in Ecuador: An Approach from the Construction and Manufacturing Industries". Sustainability, 15(16): 12661, 2023.
- [14]. Kee, D., "Characteristics of Work-Related Musculoskeletal Disorders in Korea". International Journal of Environmental Research and Public Health, 20(2): 1024, 2023.
- [15]. SSI annual statistical report, 2013-2021. <https://www.sgk.gov.tr/Istatistik/Yillik/fcd5e59b-6af9-4d90-a451-ee7500eb1cb4/>. Access date: 6 Feb 2024.
- [16]. Eurostat annual statistical report, 2013-2021. https://ec.europa.eu/eurostat/databrowser/view/hsw_n2_02_custom_9705352/default/table?lang=en. Access date: 6 Feb 2024.
- [17]. Hollnagel, E., "Safety-I and safety-II: the past and future of safety management". CRC press. p.62, 127, 2014.
- [18]. Hollnagel, E., "FRAM: the functional resonance analysis method: modelling complex socio-technical systems". CRC Press, 2012.
- [19]. Riccardo, P., Gianluca, D. P., Giulio, D. G., & Francesco, C., "FRAM for systemic accident analysis: a matrix representation of functional resonance". International journal of reliability, quality and safety engineering, 25(01): 1850001, 2018.
- [20]. Lee, J., & Chung, H., "A new methodology for accident analysis with human and system interaction based on FRAM:

- Case studies in maritime domain”. *Safety science*, 109: 57-66, 2018.
- [21]. Patriarca, R., Di Gravio, G., Woltjer, R., Costantino, F., Praetorius, G., Ferreira, P., & Hollnagel, E., “Framing the FRAM: A literature review on the functional resonance analysis method”. *Safety Science*, 129: 104827, 2020.
- [22]. McGill, A., Smith, D., McCloskey, R., Morris, P., Goudreau, A., & Veitch, B., “The functional resonance analysis method as a health care research methodology: A Scoping review”. *JBI Evidence Synthesis*, 20(4): 1074-1097, 2022.
- [23]. Salehi, V., Veitch, B., & Smith, D., “Modeling complex socio-technical systems using the FRAM: A literature review”. *Human factors and ergonomics in manufacturing & service industries*, 31(1): 118-142, 2021.
- [24]. Ramkumar, B., Harish, V., Renuka, S. D., & Srinivasaiah, R., “Lean Manufacturing: A Bibliometric Analysis, 1970-2020”. *Journal of Scientometric Research*, 10(1): 63-73, 2021.
- [25]. Blanco-Mesa, F., Merigó, J. M., & Gil-Lafuente, A. M., “Fuzzy decision making: A bibliometric-based review”. *Journal of Intelligent & Fuzzy Systems*, 32(3): 2033-2050, 2017.
- [26]. Ivanov, D., Tang, C. S., Dolgui, A., Battini, D., & Das, A., “Researchers' perspectives on Industry 4.0: multi-disciplinary analysis and opportunities for operations management”. *International Journal of Production Research*, 59(7): 2055-2078, 2021.



Detection of Brain Tumor using Boosting Algorithms based on Feature Selection


Ezgi ÖZER^{1*},

¹Department of Computer Engineering, Piri Reis University, İstanbul, Turkey; ORDIC: 0000-0003-1567-2216

* Corresponding Author: eozer@pirireis.edu.tr

Received: 19 May 2024; Accepted: 23 July 2024

Reference/Atf: E. Özer, “Detection of Brain Tumor using Boosting Algorithms based on Feature Selection”, Researcher, vol. 04, no. 02, pp. 130–140, 2024.



Abstract

Brain tumors are one of the most common causes of death. An early and correct identification of brain tumors is critical for effective therapy. Using artificial intelligence-based software programs instead of traditional methods can provide more accurate results in brain tumor detection. Especially recently, there have been many studies in the detection of diseases based on the processing of medical images. In this study, a novel hybrid algorithm was proposed based on three different feature selection algorithms (univariate feature ranking for classification using chi-square tests (f-chi2), rank the importance of features using ReliefF algorithm (f-Relief), rank features for classification using minimum redundancy maximum relevance algorithm (f-mRMR), and the classic and ensemble learning, respectively based on support vector machine (SVM) with different kernel structures and ensemble learning (EL) with boosting methods, were performed to detect the brain tumor using magnetic resonance imaging (MRI) features. K-fold is used to prevent overfitting. Analysis results show that a 100% accuracy score was achieved in the ensemble-based classifier in the detection of brain tumors with the proposed hybrid method. As a novelty for detecting the tumors, statistics-based feature selection methods are proposed, to help reduce the size and thus reduce complexity in complex network problems. The proposed method suggests a feature selection algorithm that can help reduce the data size in future studies.

Keywords: tumor detection, feature selection, support vector machine, ensemble learning

1. Introduction

A brain tumor is characterized as an unexpectedly large group of brain cells that can significantly affect the central nervous system. Tumorous tissues that do not have physiological functions may form in the human body as a result of abnormal growth of tissues due to uncontrolled proliferation of cells. These types of tumors, which can disrupt the functionality of the brain by increasing its size and pressure, cause different neurological symptoms such as attention deficit, coordination disorder, speech changes, headaches, hallucinations, anxiety, seizures, and memory loss, depending on their location in the brain. As stated by the latest data from the World Health Organization, brain tumors are one of the most common types of cancer death worldwide and can occur at any age. It causes more deaths, especially for under the age of 40 people [1]. The causes of brain tumors are not fully known. They are divided into primary and secondary. Primary brain tumors are benign and do not spread to other parts of the brain. Secondary brain tumors are malignant, they occur when cancer cells spread to the brain from other organs such as the lung or breast [2].

Early detection of brain tumors is critical for treatments. Patients who are diagnosed early on might have a considerably greater survival rate. However, signs of this condition include headaches, vomiting, visual abnormalities or diplopia, tiredness, trouble swallowing, personality or behavior changes, and hand tremors. As a result, neurosurgeons rely heavily on it to identify even the slightest abnormalities in the brain. However, manual controls by radiologists and doctors can be time-consuming and result in incorrect conclusions. It is critical to examine the photos promptly and precisely. Computer-aided automated detection systems have been created to assist radiologists and clinicians in making decisions. Numerous imaging methods exist. The most common techniques for identifying brain cancers are computed tomography (CT), magnetic resonance imaging (MRI), and head biopsies. Latent

characteristics are acquired with these imaging methods. The literature has made extensive use of deep learning and machine learning models for brain tumor diagnosis [3][4][5][6][7][8][9][10].

Developing technology and scientific research allow the development of innovative approaches to cancer detection. Biomedical datasets used for cancer detection are often high-dimensional and multivariate, requiring feature selection to extract meaningful patterns from these data and obtain accurate and reliable results. In this context, feature selection is a key step for enabling meaningful information from large and complex biomedical data sets. Moreover, feature selection helps to improve model performance, reduce the computational cost, reduce the risk of overfitting, reduce meaningless features, and increase the interpretability of the model. So, it can contribute to making the model more effective, faster, and generalizable.

This study aims to investigate the effectiveness of feature selection and machine learning algorithms to develop new and advanced methods for brain tumor detection. Considering the data size, it is not enough for the proposed method to only obtain the tumor with high success. At the same time, it is very important to be able to make faster predictions by using fewer variables. This gives a smoother model. This study focuses on how feature selection and classification methods can be used for cancer detection by examining existing literature about brain tumors. These methods can provide high sensitivity, specificity, and accuracy; and have the potential to contribute to early diagnosis and effective treatment in clinical applications. In this study, the data were analyzed, which have brain tumors and non-tumor. Different feature selection algorithms are performed, including, f-chi2, f-Relief, f-mRMR. After feature selection, ensemble learning-based boosting methods and support vector machine-based kernel structure were performed to detect brain tumors. During the training process, k-fold cross-validation is preferred to handle the overfitting. The following diagram shows the algorithm in this study.

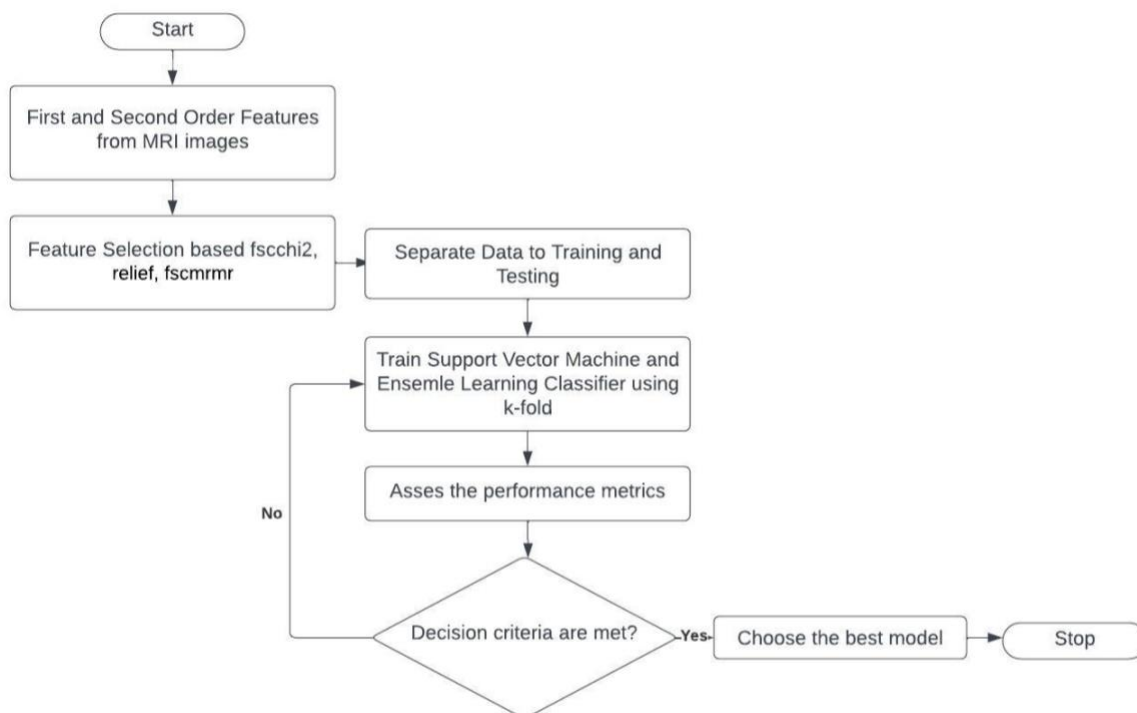


Figure 1: The proposed hybrid algorithm

2. Motivation and Overview

Brain tumor detection techniques are the process of identifying the presence or absence of a tumor using MRI image databases. The goal of tumor detection is usually an MRI image labeled as normal or abnormal. Factors such as the increasing number of patients, tumors of different shapes and sizes, and the fact that they can be found in different parts of the brain and make the process of diagnosing tumors more complicated for experts. It takes a long time for experts to manually diagnose brain tumors. Early

diagnosis of the tumor plays an important role in increasing treatment opportunities and survival rates of patients. For this reason, the use of computer-aided systems to reduce the time spent by experts in the early diagnosis of brain tumors, and making improvements in this field have become the main focus of many studies. Brain tumor detection in MRI images can be done using traditional machine learning methods or deep learning techniques. In recent years, remarkable advances have been made in numerous studies aimed at processing medical images and diagnosing brain tumors. Vani et al. [3] proposed a machine learning-based, Support Vector Machine (SVM) method to classify brain tumors. They stated that they predicted brain tumors positively and negatively with an accuracy of 82% and 81.48%, respectively. Mohsen et al. [4] proposed a new method to classify brain tumors using deep learning methods and the Discrete Wavelet Transform (DWT) model. In experimental studies, they achieved 93.94% accuracy with this model [4]. Shahzadi et al. [5] used the CNN-based hybrid model construct to detect brain tumors. Feature extraction and classification used the Long Short-Term Memory (LSTM) structure together with the AlexNet and VggNet CNN models. In the study, they achieved 71% accuracy with AlexNet-LSTM and 84% accuracy with VGGNet-LSTM. Swati et al. [6] proposed transfer learning for the multiclass classification of brain tumors. For this purpose, AlexNet used CNN models VGG16 and VGG19. In experimental studies, AlexNet achieved accuracy rates of 89.95%, 94.65%, and 94.82% in VGG16 and VGG19 models, respectively. Nayak et al. (2022) performed an algorithm based on DWT and DCNN. In experimental studies, the brain tumors were detected with accuracy, as 97% [9]. Rammurthy, and Mahesh [11] proposed a method Whale Harris Hawks optimization (WHHO) based on deep convolutional neural network (DCNN). Their method gave an 81.6% accuracy for detecting tumors. Pendela et al. [12] proposed an approach based on Exponential Deer Hunting Optimization (ExpDHO), Shepard convolutional neural network (ShCNN), deep convolutional neural network (DCNN), Exponential weighted moving average (EWMA) and they detected the tumor with 91.7% accuracy.

3. Methodology

3.1. Univariate feature ranking for classification using chi-square tests (f-chi2)

Univariate feature ranking for classification using chi-square tests (f-chi2) is a statistical technique. It involves evaluating the relevance of individual features for classification using chi-square tests to evaluate the significance of each feature (variable) in a dataset for categorical result prediction [13]. To determine which features are the most discriminative for a given classification problem, univariate feature ranking using chi-square tests might be a useful step in the feature selection process. It is noteworthy that although this method is instructive, taking feature interactions into account could enhance the feature selection process, particularly in datasets with greater complexity [14].

$$\chi^2(x_k, y_i) = \frac{N(AD - CB)^2}{(A + C)(B + D)(A + B)(C + D)} \quad (1)$$

In Equality 1, x_k belongs to the k th feature and y_i is the i th class. A is the number of samples in y_i that contain the feature x_k . B is the number of samples that contain the feature x_k in other classes. C is the number of records in the class y_i that do not contain the feature x_k . D is the number of samples that do not contain the feature x_k in other classes and N is the total number of samples in the dataset.

3.2. Rank the importance of features using ReliefF algorithm (f-Relief)

The ReliefF (Relief) algorithm is designed to rank the importance of predictors in a dataset. Relief-based algorithms like ReliefF and RReliefF are employed as feature selection techniques to prioritize predictors (features) within a dataset. They are based on the concept of feature weighting. ReliefF is a deterministic version, while RReliefF introduces randomization for enhanced efficiency [15][16]. When significant features are present among noisy or irrelevant ones, these algorithms are very helpful in recognizing the former. Features' relevance and redundancy are assessed using the feature selection algorithms ReliefF and RReliefF. To identify which traits are important, they consider the distance

between instances and their class labels [17]. The following algorithm gives the main idea behind the Relief method [18][19].

Algorithm 1: Relief Method

```

1  Input: M learning instances  $x_k$  described by N features; sampling parameter m
2  Output: for each feature  $F_i$  a quality weight  $-1 \leq W[i] \leq 1$ 
3  for i=1 to N do  $W[i] = 0.0$ 
4  end for
5  for l=1 to m do
6    randomly pick an instance  $x_k$ 
7    find its nearest hit  $x_H$  and nearest miss  $x_M$ 
8    for i=1 to N do
9       $W[i] = W[i] - \text{diff}(i, x_k, x_H)/m + \text{diff}(i, x_k, x_{m-M})/m$ 
10   end for
11 end for
12 return (W)

```

3.3. Rank features for classification using minimum redundancy maximum relevance algorithm (f-MRMR)

The Minimum Redundancy Maximum Relevance algorithm emphasizes the redundancy among the characteristics that are chosen as well as their relevance to the target variable [20]. The goal of f-mRMR is to rank features based on their relevance to the target variable while minimizing redundancy among selected features (Ding and Peng, 2005). The following algorithm shows the basic idea behind f-mRMR [21]:

$$\text{argmax}_{j \in \Omega_S} (f(x_j, y) - \frac{1}{|S|^2} \sum_{l \in S} g(x_j, x_l)) \quad (2)$$

Algorithm 2: f-mRMR Method

```

1   $S \leftarrow \emptyset$ 
2  add  $x_i = \text{argmax}_{j \in \Omega_S} f(x_j, y)$  to S
3  for t=1:k-1 do
4  add the feature that satisfies Eq. xx to S
5  end for
6  return S

```

In Equality 2, the first term and second term maximize the relevance condition and minimizes the redundancy condition, respectively. In this algorithm, x_i is the i th feature in X, $g(x_j, x_l)$ is the function that returns the redundancy between two features x_j and x_l . $f(x_j, y)$ is the function that returns the relevance between a feature x_j and class labels y . S is the selected feature. Ω is all features. Ω_S shows the candidate's features. k is the number of selected features.

3.4. Ensemble Learning

Ensemble learning is a method of combining multiple models and typically aims to improve the predictive performance of the model. Numerous algorithms have been developed for training ensemble classifiers. Bagging, boosting, voting, and stacking algorithms are the most common approaches. Among them, the boosting algorithm is a method for obtaining strong classifiers to produce strong classifiers with low training error from weak classifiers [22][23]. The following algorithm gives the Adaboosting:

Algorithm 3: Adaboosting Method

1	Input: $D = \{d_1, d_2, \dots, d_n\}$ and $d_i = (x_i, y_i)$ $x_i \in X$ and $y_i \in \{y_1, y_2, \dots, y_M\}$
2	M: maximum number of classifiers
3	Output: O is the classifier, $O: X \rightarrow \{y_1, y_2, \dots, y_M\}$
4	Initialize the weights $w_i^1 = \frac{1}{N}$ $i \in \{1, 2, \dots, N\}$
5	For $m = 1$ to M, calculate the following metrics:
6	$Error_m = \sum_{i=1}^N w_i^m h(-y_i O_m(x_i))$ ($Error_m$ is the weighted error for O_m)
7	$a_m = \frac{1}{2} \log \frac{1 - error_m}{error_m}$ (a_m is the weight of weak learners)
8	$v_i^m = w_i^m \exp(-a_m y_i O_m(x_i))$ (Updating the weights)
9	$S_m = \sum_{j=1}^N v_j$ and $w_i^{m+1} = v_i^m / S_m$ (Normalizing the weights)
10	$O(x) = \text{sign} \sum_{j=1}^M a_j O_j(x)$ (Calculating the last classifier)

3.5. Support Vector Machine

The fundamental principle behind support vector machines (SVMs) is to maximize the distance between a discrete hyperplane and the data in an N-dimensional space. In where, N is the number of features, to identify a hyperplane that effectively separates the data from each other. The margin is the length of time between the decision border and the closest training sample [24]. It is introduced in the context of statistical learning theory and structural risk minimization. This approach is highly effective in resolving numerous common problems including density estimation, function estimation, and nonlinear classification. It additionally acts as a guide for numerous new advancements in kernel-based techniques [23]. Kernel functions are utilized to create a convex quadratic problem, where the global optimal value is the quadratic function's minimal value, in cases when the dataset has a nonlinear structure that is not linearly separable. The effectiveness of kernel functions varies depending on the nature of the issue. The following table shows the kernel functions and their formula (Bishop, 2006):

Table 1: Kernel function and formula

Kernel Function	Formula
<i>Linear</i>	$K(x_i, x_j) = \langle x_i, x_j \rangle$
<i>RBF</i>	$K(x_i, x_j) = \exp(-\gamma \ x_i - x_j\ ^2)$
<i>Gaussian</i>	$K(x_i, x_j) = \exp\left(-\frac{\ x_i - x_j\ ^2}{2\sigma^2}\right)$
<i>Polynomial</i>	$K(x_i, x_j) = (1 + \langle x_i, x_j \rangle)^1$
<i>Quadratic</i>	$K(x_i, x_j) = (1 + \langle x_i, x_j \rangle)^2$
<i>Qubic</i>	$K(x_i, x_j) = (1 + \langle x_i, x_j \rangle)^3$

3.6. Performance Metrics

Evaluation metrics provide information about the success of the prediction, by comparing the predictions obtained from the model with the actual results. They are needed to measure which of the created models will give better results. In this work, the following evaluation criteria were used: the model's accuracy, recall, precision, F1 Score, and G Mean [25][26][27][28]. In table 2, it can be found that these metrics' mathematical formulas.

Table 2: The evaluation metrics

Evaluation Metrics	Formula
<i>Accuracy</i>	$(TP + TN)/(TP + TN + FP + FN)$
<i>Sensitivity</i>	$TP/(TP + FN)$
<i>Specificity</i>	$TN/(TN + FP)$
<i>Precision</i>	$TP/(TP + FP)$
<i>F1_Score</i>	$2 * (Precision * Sensitivity)/(Precision + Sensitivity)$
<i>G-Mean</i>	$\sqrt{Precision * Sensitivity}$

In this table, TP, TN, FP and FN are described as follows:

TP; when both the expected and actual values are positive

TN; when both the predicted value and the actual value are negative.

FP (Type 1 Error); when the prediction is positive but the actual is negative.

FN (Type 2 Error); when the prediction is negative but it actually is positive.

4. Analysis

4.1. Dataset

The dataset includes five first-order features (mean, variance, standard deviation, skewness, kurtosis) and eight texture features (contrast, energy, angular second moment, (ASM), entropy, homogeneity, dissimilarity, correlation, coarseness) from the 3762 images, the number of having tumor and without tumor is 1683 and 2079, respectively. Detailed information can be found at Bohaju, 2020 [29]. Following Figure shows the images with tumor and without tumor.




Figure 2: Sample of 3 brain images with labels

4.2. Results

Initially, 13 features were used in the study. With the proposed feature selection methods, the number of features was reduced, and resulted in a reduction in model complexity. During the training process, different hyperparameters were performed to increase the classifiers' performance. To reduce overfitting, k-fold cross-validation was performed during the training processes.

The following tables include results obtained full model and feature selection model using different boostings and kernel structures. In the tables below, NoF, ACC, SPEC, PREC, SENS, F_M, G_M, LOSS are described as number of features, accuracy, specificity, precision, sensitivity, F1 Score, geometric mean, respectively. The classification results are given in the following tables:

Table 3: Ensemble Learning K fold=2

Model		Testing Data								Training Data	
		NoF	ACC	SPEC	PREC	SENS	F_M	G_M	LOSS	ACC	LOSS
Gentle Boost	full model	13	0,99	0,99	0,99	0,99	0,99	0,99	0,01	0,98	0,02
	fschi2	7	0,99	0,99	0,99	0,99	0,99	0,99	0,01	0,98	0,02
	relieff	4	0,99	0,99	0,99	0,99	0,99	0,99	0,02	0,97	0,03
	f-mRMR	3	0,98	0,98	0,98	0,98	0,98	0,98	0,02	0,96	0,04
Ada Boost	full model	13	0,99	0,99	0,99	0,99	0,99	0,99	0,01	0,98	0,02
	fschi2	4	0,99	0,99	0,99	0,99	0,99	0,99	0,02	0,97	0,03
	relieff	4	0,99	0,99	0,99	0,99	0,99	0,99	0,01	0,97	0,03
	f-mRMR	3	0,99	0,99	0,99	0,99	0,99	0,99	0,02	0,96	0,04
Logit Boost	full model	13	0,99	0,99	0,99	0,99	0,99	0,99	0,01	0,98	0,02
	fschi2	4	0,98	0,98	0,98	0,98	0,98	0,98	0,02	0,97	0,03
	relieff	5	0,99	0,99	0,99	0,99	0,99	0,99	0,02	0,98	0,02
	f-mRMR	6	0,99	0,99	0,99	0,99	0,99	0,99	0,01	0,98	0,02

From Table 3, instead of use all features, it can be seen the best results are obtained using Gentle Boost with relieff, AdaBoost with f-mRMR and Logit Boost with relieff. The number of features are 4, 3, and 5, respectively. When k-fold=2, AdaBoost with f-mRMR gave the least complex result.

Table 4: Support vector machine K fold=2.

Model		Testing Data								Training Data	
		NoF	ACC	SPEC	PREC	SENS	F_M	G_M	LOSS	ACC	LOSS
Linear	full model	13	0,96	0,96	0,96	0,96	0,96	0,96	0,04	0,96	0,04
	fschi2	7	0,96	0,96	0,96	0,96	0,96	0,96	0,04	0,96	0,04
	relieff	7	0,96	0,96	0,96	0,96	0,96	0,96	0,04	0,96	0,04
	f-mRMR	6	0,94	0,94	0,94	0,94	0,94	0,94	0,05	0,94	0,06
RBF	full model	13	0,97	0,97	0,97	0,97	0,97	0,97	0,03	0,96	0,04
	fschi2	4	0,98	0,98	0,98	0,98	0,98	0,98	0,02	0,98	0,02
	relieff	4	0,98	0,98	0,98	0,98	0,98	0,98	0,02	0,98	0,02
	f-mRMR	2	0,97	0,97	0,97	0,97	0,97	0,97	0,03	0,96	0,04
Polynomial	full model	13	0,97	0,97	0,97	0,97	0,97	0,97	0,03	0,96	0,04
	fschi2	4	0,98	0,98	0,98	0,98	0,98	0,98	0,02	0,97	0,03
	relieff	3	0,97	0,97	0,97	0,97	0,97	0,97	0,03	0,97	0,03
	f-mRMR	4	0,97	0,97	0,97	0,97	0,97	0,97	0,03	0,96	0,04
Quadratic	full model	13	0,97	0,97	0,97	0,97	0,97	0,97	0,03	0,97	0,03
	fschi2	7	0,98	0,98	0,98	0,98	0,98	0,98	0,03	0,97	0,03
	relieff	2	0,97	0,97	0,97	0,97	0,97	0,97	0,03	0,97	0,03
	f-mRMR	5	0,97	0,97	0,97	0,97	0,97	0,97	0,03	0,97	0,03
Qubic	full model	13	0,98	0,98	0,98	0,98	0,98	0,98	0,02	0,96	0,04
	fschi2	4	0,97	0,97	0,97	0,97	0,97	0,97	0,03	0,97	0,03
	relieff	3	0,97	0,97	0,97	0,97	0,97	0,97	0,03	0,97	0,03
	f-mRMR	5	0,98	0,98	0,98	0,98	0,98	0,98	0,03	0,97	0,03

From Table 4, instead of use all features, it can be seen the best results are obtained using Linear Kernel with f-mRMR, RBF Kernel with relieff, Polynomial Kernel with fschi2, Quadratic Kernel with relieff, and Qubic Kernel with relieff. The number of features are 6, 4, 4, 2, and 3, respectively. When k-fold=2, Quadratic Kernel with relieff, gave the least complex result having 2 features.

Table 5: Ensemble Learning kfold=10.

Model		Testing Data								Training Data	
		NoF	ACC	SPEC	PREC	SENS	F_M	G_M	LOSS	ACC	LOSS
Gentle Boost	full model	13	1,00	1,00	1,00	1,00	1,00	1,00	0,00	0,98	0,02
	fschi2	2	0,99	0,99	0,99	0,99	0,99	0,99	0,01	0,96	0,04
	relieff	5	1,00	1,00	1,00	1,00	1,00	1,00	0,01	0,98	0,02
	f-mRMR	4	1,00	1,00	1,00	1,00	1,00	1,00	0,01	0,98	0,02
AdaBoost	full model	13	1,00	1,00	1,00	1,00	1,00	1,00	0,00	0,98	0,02
	fschi2	6	1,00	1,00	1,00	1,00	1,00	1,00	0,01	0,98	0,02
	relieff	6	1,00	1,00	1,00	1,00	1,00	1,00	0,01	0,98	0,02
	f-mRMR	5	1,00	1,00	1,00	1,00	1,00	1,00	0,01	0,98	0,02
Logit Boost	full model	13	1,00	1,00	1,00	1,00	1,00	1,00	0,00	0,99	0,01
	fschi2	4	1,00	1,00	1,00	1,00	1,00	1,00	0,01	0,97	0,03
	relieff	2	0,99	0,99	0,99	0,99	0,99	0,99	0,01	0,95	0,05
	f-mRMR	2	0,99	0,99	0,99	0,99	0,99	0,99	0,01	0,96	0,04

From Table 3, instead of use all features, it can be seen the best results are obtained using Gentle Boost with f-mRMR, AdaBoost with f-mRMR and LogitBoost with fschi2. The number of features are 4, 5 and 4, respectively. When k-fold=10, Gentle Boosting with f-mRMR gave the least complex result.

Table 6: Support vector machine, kfold=10.

Model		Testing Data								Training Data	
		NoF	ACC	SPEC	PREC	SENS	F_M	G_M	LOSS	ACC	
Linear	full model	13	0,96	0,96	0,96	0,96	0,96	0,96	0,04	0,96	0,04
	fschi2	5	0,96	0,96	0,96	0,96	0,96	0,96	0,04	0,96	0,04
	relieff	3	0,95	0,95	0,95	0,95	0,95	0,95	0,05	0,95	0,05
	f-mRMR	6	0,95	0,95	0,95	0,95	0,95	0,95	0,05	0,95	0,05
RBF	full model	13	0,98	0,98	0,98	0,98	0,98	0,98	0,02	0,97	0,03
	fschi2	4	0,98	0,98	0,98	0,98	0,98	0,98	0,02	0,97	0,03
	relieff	2	0,98	0,98	0,98	0,98	0,98	0,98	0,03	0,97	0,03
	f-mRMR	5	0,98	0,98	0,98	0,98	0,98	0,98	0,02	0,97	0,03
Polynomial	full model	13	0,99	0,99	0,99	0,99	0,99	0,99	0,02	0,97	0,03
	fschi2	4	0,98	0,98	0,98	0,98	0,98	0,98	0,02	0,97	0,03
	relieff	5	0,98	0,98	0,98	0,98	0,98	0,98	0,02	0,97	0,03
	f-mRMR	5	0,98	0,98	0,98	0,98	0,98	0,98	0,02	0,97	0,03
Quadratic	full model	13	0,98	0,98	0,98	0,98	0,98	0,98	0,02	0,97	0,03
	fschi2	5	0,98	0,98	0,98	0,98	0,98	0,98	0,03	0,97	0,03
	relieff	2	0,97	0,97	0,97	0,97	0,97	0,97	0,14	0,87	0,13
	f-mRMR	6	0,98	0,98	0,98	0,98	0,98	0,98	0,02	0,97	0,03
Qubic	full model	13	0,99	0,99	0,99	0,99	0,99	0,99	0,01	0,97	0,03
	fschi2	4	0,98	0,98	0,98	0,98	0,98	0,98	0,02	0,97	0,03
	relieff	3	0,97	0,97	0,97	0,97	0,97	0,97	0,05	0,95	0,05
	f-mRMR	5	0,98	0,98	0,98	0,98	0,98	0,98	0,02	0,97	0,03

From Table 6, instead of use all features, it can be seen the best results are obtained using Linear Kernel with relieff, RBF Kernel with relieff, Polynomial Kernel with fschi2, Quadratic Kernel with fschi2, and Qubic Kernel with fschi2. The number of features are 6, 4, 4, 2, and 3, respectively. When k-fold=2, Quadratic Kernel with relieff, gave the least complex result having 2 features.

5. Discussion and Conclusion

By identifying and ranking the characteristics that are most likely to provide useful information for a classification task, this method improves the interpretability and accuracy of the model. In this study, thirteen extracted features from images are used. As a novelty for detecting the tumors, the statistics-based feature selection methods are proposed, to help reduce the size and thus reduce complexity in complex network problems. From Table 3 to 6, the results obtained from full model and 3 different feature selection methods, ensemble learning with different boosting, and different kernel structures for k fold 2 and 10 are compared. In these tables, the best results are shown in italics. From the results, ensemble learning based on boosting methods gives better results than SVM based on kernel structures. The proposed hybrid algorithm-based feature selection and boosting approaches give good results in classifying data obtained via MRI from patients with and without brain tumors.

Among the feature selection algorithms, the f-chi2, f-Relief, f-mRMR, were used to select the features from all features. To detect the brain tumor, classified machine learning algorithms were performed which are Support vector machine-based kernel and Ensemble Learning based Boosting. Some results were obtained when the K fold was 2 and 10, respectively. The best result was obtained using f-mRMR feature selection method and ensemble learning, when k-fold was 10. The proposed hybrid algorithm reduced the model complexity, by decreasing the number of features. Comparative results of some studies in the literature are given in the table below:

Table 7: The performances of existing approaches in the literature

Source	Classes	Method	Accuracy
Vani et al., 2017 [3]	Tumor/No Tumor	SVM	82%
Mohsen et al., 2018 [4]	Tumor/No Tumor	DWT, DL	93.94%
Shahzadi et al., 2018 [5]	Tumor/No Tumor	AlexNet and VggNet, CNN	84%
Ghahfarrokhi and Khodadadi, 2020 [7]	Tumor/No Tumor	LE, ApEn, FD, GLCM, DWT, SVM, KNN	98,90%
Al-Saffar and Yildirim, 2021 [8]	No Tumor/HGG/LGF	LDI-Means, MI, SVD, SVM, MLP, MES	91,02%
Nayak et al., 2022 [9]	Tumor/No Tumor	DWT, SDA-DA CNN	97%
Isunuri and Kakarla, 2023 [10]	No Tumor/HGG/LGF	EfficientNetB4, EMCMA	98,35%
<i>The Proposed work</i>	<i>Tumor/No Tumor</i>	<i>f-chi2, f-Relief, f-mRMR, EL</i>	<i>100%</i>

LE: Lyapunov Exponent

ApEn: Approximate Entropy

FD: Fractal Dimension

GLCM: Gray-Level Co-occurrence Matrix

DWT: Discrete Wavelet Transform

SVM: Support Vector Machine

KNN: K-Nearest Neighbors

LDI-Means: Local Difference in Intensity - Means

MI: Mutual Information

SVD: Singular Value Decomposition

MLP: Multi-Layer Perceptron

MES: Multiple Eigenvalues Selection

SDA-DA CNN: Deep Autoencoder based Spectral Data Augmentation

EMCMA: Multi-Path Convolution Network with Multi-Head Attention

HGG: High Grade Gliomas

LGF: Low Grade Gliomas

Declaration of Interest

The author declares that there is no conflict of interest.

Financial Support

This work was supported in part by the Scientific and Technological Research Council of TURKEY (TUBITAK) [grant number 1059B141900679].


Declaration of ethical standards

The author(s) of this article declare that the materials and methods used in this study do not require ethical committee permission and/or legal-special permission.

References

- [1] World Health Organization Report (WHO), 2022. <https://www.who.int>
- [2] Doolittle, N.D., "State of the science in brain tumor classification. Paper presented at the Seminars in oncology nursing", 2004.
- [3] Vani, N., Sowmya, A., and Jayamma, N., "Brain Tumor Classification using Support Vector Machine. International Research Journal of Engineering and Technology (IRJET)", 4(7), 792-796, 2017.
- [4] Mohsen, H, El-Dahshan E.S.A., El-Horbaty E.S.M., and Salem A.B.M., "Classification using Deep Learning Neural Networks for Brain Tumors, Future Computing and Informatics Journal", 3(1), 68-71, 2018.
- [5] Shahzadi I, Tang T. B, Meriadeau F., and Quyyum, A., "CNN-LSTM: Cascaded framework for brain tumor classification. IEEE EMBS Conference on Biomedical Engineering and Sciences", IECBES; 3-6 December, Sarawak, Malaysia: IEEE, 633-637, 2018.
- [6] Swati, Z.N.K., Zhao, Q., Kabir, M., Ali, F., Ali, Z., Ahmed, S., and Lu, J., "Brain tumor classification for MR images using transfer learning and fine-tuning", Computerized Medical Imaging and Graphics, 75, 34-46, 2019.
- [7] Ghahfarrokhi, S.S., and Khodadadi, H., "Human brain tumor diagnosis using the combination of the complexity measures and texture features through magnetic resonance image", Biomedical Signal Processing and Control, 61, 2020. <https://doi.org/10.1016/j.bspc.2020.102025>.
- [8] Al-Saffar, Z.A., and Yildirim, T., "A hybrid approach based on multiple Eigenvalues selection (MES) for the automated grading of a brain tumor using MRI", Computer Methods and Programs in Biomedicine, 2021, 201, 105945, ISSN 0169-2607, <https://doi.org/10.1016/j.cmpb.2021.105945>.
- [9] Nayak, D.R., Padhy, N., Mallick, P.K., and, Singh. A., "A deep autoencoder approach for detection of brain tumor images, Computers and Electrical Engineering", 2022, 102, 108238, ISSN 0045-7906, <https://doi.org/10.1016/j.compeleceng.2022.108238>.
- [10] Isunuri, V.B., and Kakarla, J., "EfficientNet and multi-path convolution with multi-head attention network for brain tumor grade classification, Computers and Electrical Engineering", 2023, 108, 108700, ISSN 0045-7906, <https://doi.org/10.1016/j.compeleceng.2023.108700>.
- [11] D. Rammurthy, P. Mahesh, "Whale Harris Hawks optimization based deep learning classifier for brain tumor detection using MRI images," Journal of King Saud University-Computer and Information Sciences, vol. 34, no. 6, pp. 3259-3272, 2020.
- [12] Pendela Kanchanamala, Revathi K.G., M. "Belsam Jeba Ananth, Optimization-enabled hybrid deep learning for brain tumor detection and classification from MRI", Biomedical Signal Processing and Control, Volume 84, 2023, 104955, ISSN 1746-8094, <https://doi.org/10.1016/j.bspc.2023.104955>.
- [13] Hastie, T., Tibshirani, R., and Friedman, J., "The Elements of Statistical Learning Data Mining", Inference, and Prediction, 2007, Second Edition, Springer.
- [14] Hardle, W.K., and Simar, L., Applied Multivariate Statistical Analysis, Fourth Edition, 2015, Springer.
- [15] Kononenko, I., Šimec, E., and Robnik-Šikonja, M., "Overcoming the Myopia of Inductive Learning Algorithms with RELIEFF", Applied Intelligence 7, 1997, 39-55. <https://doi.org/10.1023/A:1008280620621>.
- [16] Robnik-Šikonja, M., and Kononenko, I., "Theoretical and Empirical Analysis of ReliefF and RReliefF. Machine Learning", 2003, 53, 23-69. <https://doi.org/10.1023/A:1025667309714>
- [17] Blum, A.L., and Langley. P., "Selection of Relevant Features and Examples in Machine Learning Artificial Intelligence", 1997, 97 (1), 245-271.

- [18] Liu H., and Motoda, H. (Ed.), Computational Methods of Feature Selection, Chapman and Hall/CRC Data Mining and Knowledge Discovery Series, Kononenko, I and Sikonja, M., 2008, Chapter 9- Non-Myopic Feature Quality Evaluation with (R) ReliefF, New York.
- [19] Urbanowicz, R.J., Meeker, M., La Cava, W., Olson, R.S., Moore, J.H., "Relief-based feature selection: Introduction and review, Journal of Biomedical Informatics", 2018, 85, 189-203, ISSN 1532-0464, <https://doi.org/10.1016/j.jbi.2018.07.014>.
- [20] Peng, H., Long, F., and Ding, C., "Feature selection based on mutual information criteria of max-dependency, max-relevance, and min-redundancy," in IEEE Transactions on Pattern Analysis and Machine Intelligence, 2005, 27(8), 1226-1238, doi: 10.1109/TPAMI.2005.159.
- [21] EL-Manzalawy, Y., Hsieh, T.Y., and Shivakumar, M., "Min-Redundancy and Max-Relevance Multi-View Feature Selection for Predicting Ovarian Cancer Survival using Multi-Omics Data", BMC Med Genomics, 2018, 11(3). doi.org/10.1186/s12920-018-0388-0
- [22] Polikar, R., Ensemble learning. Ensemble machine learning, 2012, 10th ed. Boston, Springer, 1-34.
- [23] Ozer, E., "Early Diagnosis of Epileptic Seizures over EEG Signals using Deep Learning Approach", Mimar Sinan Fine Arts University, 2023, Institute of Science and Technology, PhD Thesis.
- [24] Cortes, C., and Vapnik, V., Support-Vector Networks. Kluwer Academic Publishers, 1995.
- [25] Van Rijsbergen, C.J., Information Retrieval, London: Butterworths, 1979
- [26] Fawcett, T., "An introduction to ROC analysis", Pattern Recognition Letters, 2006, 27(8), 861-874.
- [27] Hastie, T., Tibshirani, R., and Friedman, J., The Elements of Statistical Learning, Springer, 2009.
- [28] Powers, D.M., "Evaluation: From Precision, Recall and F-Measure to ROC, Informedness, Markedness & Correlation", Journal of Machine Learning Technologies, 2011, 2(1), 37-63.
- [29] Bohaju, J., Brain Tumor Data set, Kaggle, 2020. doi.org/10.34740/KAGGLE/DSV/1370629



Türkiye'nin CO2 Emisyonunun Anfis ile Tahmin Edilmesi

Oğuzhan Ahmet ARIK^{1*}, Eda HAMAMCIOĞLU²

¹Erciyes Üniversitesi, Mühendislik Fakültesi, Endüstri Mühendisliği Bölümü, 38039, Kayseri, Türkiye; ORCID: 0000-0002-7088-2104

²2nci Hava Bakım Fabrika Müdürlüğü, Kayseri, Türkiye; ORCID: 0000-0002-3317-4416

* Corresponding Author: oguzhanahmet@erciyes.edu.tr

Received: 9 September 2024; Accepted: 19 December 2024

Reference/Atf: O. A. Arık and E. Hamamcıoğlu, “Türkiye'nin CO2 Emisyonunun Anfis ile Tahmin Edilmesi”, Researcher, vol. 04, no. 02, pp. 141–156, 2024.

Özet



CO2 emisyonu, karbon dioksit gazının atmosfere salınması anlamına gelmekte ve fosil yakıtların yanması, endüstriyel süreçler, ormansızlaşma ve tarım gibi insan faaliyetlerinden kaynaklanmaktadır. Artan CO2 seviyeleri, sera etkisi yaratarak dünya genelinde iklim değişikliğine neden olmaktadır. Türkiye hem ulusal hem de uluslararası düzeyde çevresel sürdürülebilirlik ve iklim değişikliğiyle mücadele konusunda kararlı bir tutum sergilemektedir. Bu bağlamda, Türkiye 2020-2030 dönemi için belirlediği Ulusal Belirlenmiş Katkı (NDC) ile 2030 yılına kadar sera gazı emisyonlarını 2005 seviyelerine göre %21 oranında azaltmayı hedeflemiştir. Türkiye'nin CO2 emisyonlarını azaltma stratejileri arasında yenilenebilir enerji kaynaklarına geçişin teşvik edilmesi, enerji verimliliğinin artırılması, sanayi sektöründe temiz teknolojilere geçiş, ulaşımda elektrikli araçların ve toplu taşıma sistemlerinin yaygınlaştırılması ve tarımda sürdürülebilir uygulamaların desteklenmesi bulunmaktadır. Paris Anlaşması çerçevesinde Türkiye, küresel sıcaklık artışını 2 derece altında tutmayı ve mümkünse 1.5 dereceyle sınırlamayı hedefleyen taahhütlerde bulunmuştur. Bu çalışma, Türkiye'nin CO2 emisyonlarını tahmin etmeyi amaçlamakta ve bu konuda önemli bir boşluğu doldurmaktadır. ANFIS (Adaptive Neuro-Fuzzy Inference System) yöntemi kullanılarak yapılan bu araştırma, Türkiye'nin geçmiş CO2 emisyon verilerini analiz ederek gelecekteki emisyon trendlerini tahmin etmeyi hedeflemektedir. Elde edilen sonuçlar, sürdürülebilir kalkınma stratejilerinin oluşturulmasında, enerji politikalarının şekillendirilmesinde ve çevresel etki değerlendirmelerinde önemli bir rehberlik sağlayabilir. Ayrıca, ANFIS modelinin CO2 emisyon tahminindeki başarısı, benzer çalışmalara ilham kaynağı olabilir ve bu alandaki gelecekteki araştırmalara önemli katkılar sunabilir. Bu çalışma, Türkiye'nin CO2 emisyonlarını azaltma çabalarının ve ANFIS yöntemiyle yapılan tahmin çalışmalarının önemini vurgulamakta, aynı zamanda Paris Anlaşması'nın taahhütlerine uyum sağlamaya yönelik stratejilerini detaylandırmaktadır.

Anahtar kelimeler: CO2 emisyonu, ANFIS, Regresyon Analizi, Ekonomik Büyüme, Enerji Tüketimi, Tahmin, Enerji Verimliliği, Yenilenebilir Enerji

Abstract

CO2 emissions refer to the release of carbon dioxide gas into the atmosphere, primarily resulting from human activities such as the burning of fossil fuels (coal, oil, natural gas), industrial processes, deforestation, and agriculture. Increasing CO2 levels create a greenhouse effect, leading to global climate change. Turkey is committed to environmental sustainability and combating climate change on both national and international levels. In this context, Turkey has set a Nationally Determined Contribution (NDC) for the 2020-2030 period, aiming to reduce greenhouse gas emissions by 21% compared to 2005 levels by 2030. Turkey's strategies to reduce CO2 emissions include promoting the transition to renewable energy sources, enhancing energy efficiency, adopting clean technologies in the industrial sector, expanding the use of electric vehicles and public transportation, and supporting sustainable agricultural practices. Under the Paris Agreement, Turkey has committed to limiting global temperature rise to well below 2 degrees Celsius above pre-industrial levels, and to pursue efforts to limit the increase to 1.5 degrees Celsius. This study aims to fill a significant gap by forecasting Turkey's CO2 emissions using the ANFIS (Adaptive Neuro-Fuzzy Inference System) method. By analyzing Turkey's historical CO2 emission data, this research seeks to predict future emission trends. The results can provide crucial guidance for forming sustainable development strategies, shaping energy policies, and conducting environmental impact assessments. Additionally, the success of the ANFIS model in CO2 emission forecasting can inspire similar studies and contribute significantly to future research in this field. This study emphasizes Turkey's efforts to reduce CO2 emissions and the importance of forecasting studies using the ANFIS method, while detailing strategies to comply with the commitments of the Paris Agreement.

Keywords: CO2 emissions, ANFIS, Economic Growth, Energy Consumption, Prediction, Energy Efficiency, Renewable Energy

1. Giriş

CO2 emisyonu, karbon dioksit gazının atmosfere salınması anlamına gelmekte ve fosil yakıtların yanması, endüstriyel süreçler, ormansızlaşma ve tarım gibi insan faaliyetlerinden kaynaklanmaktadır. Artan CO2 seviyeleri, sera etkisi yaratarak iklim değişikliğine yol açmakta ve ekstrem hava olayları, deniz seviyesinde yükselme ve biyolojik çeşitlilik kaybı gibi sorunlara neden olmaktadır. Türkiye, ulusal ve uluslararası düzeyde çevresel sürdürülebilirlik ve iklim değişikliğiyle mücadele konusunda kararlıdır. 2020-2030 dönemi için belirlenen Ulusal Belirlenmiş Katkı (NDC) kapsamında, Türkiye 2030 yılına kadar sera gazı emisyonlarını 2005 seviyelerine göre %21 oranında azaltmayı hedeflemektedir. Bu hedeflere ulaşmak için yenilenebilir enerji kaynaklarına geçiş, enerji verimliliği, temiz teknolojiler, elektrikli araçlar ve sürdürülebilir tarım uygulamaları gibi stratejiler benimsenmektedir.

Bu çalışma, Türkiye'nin CO2 emisyonlarını ANFIS (Adaptive Neuro-Fuzzy Inference System) yöntemiyle tahmin etmeyi amaçlamaktadır. Geçmiş CO2 emisyon verilerini analiz ederek gelecekteki trendleri öngörmek, sürdürülebilir kalkınma stratejileri ve enerji politikalarının şekillendirilmesinde önemli bir rehber sağlayacaktır. ANFIS modelinin başarısı, benzer araştırmalar için ilham kaynağı olabilir ve bu alanda gelecekteki çalışmalara önemli katkılar sunabilir. Analiz bu kapsamda, Türkiye'nin geçmiş CO2 emisyonlarını azaltma çabalarını ve ANFIS yöntemiyle yapılan tahmin çalışmalarının önemini vurgulamaktadır.

Günümüzde, atmosferik karbondioksit (CO2) emisyonlarının tahmin edilmesi, iklim değişikliği ve çevresel sürdürülebilirlik açısından hayati bir öneme sahiptir. CO2 emisyonlarının doğru tahmin edilmesi, çevresel politika oluşturucuları, endüstri liderleri ve bilim insanları için temel bir gerekliliktir. Literatür taramasının odak noktası, CO2 emisyonlarını tahmin etmek için kullanılan parametrelerin ve yöntemlerin incelenmesidir. Bu bağlamda, bulguların odak noktası, bulanık mantık teorisi temelli bir yapay zekâ yöntemi olan Adaptif Sinirsel Bulanık İnfersans Sistemi (ANFIS) üzerinde yoğunlaşmıştır. Literatür taraması, CO2 emisyonlarını tahmin etmek için kullanılan çeşitli parametrelerin incelenmesiyle birlikte, ANFIS'in bu bağlamdaki rolünü ve etkinliğini anlamaya yardımcı olacaktır. Bu araştırma, CO2 emisyonlarının gelecekteki seviyelerini tahmin etmek için geliştirilen yeni ve etkili yöntemlerin keşfedilmesine katkı sağlayabilir. Bu da iklim değişikliğiyle mücadele ve sürdürülebilir bir gelecek için daha etkili politikaların geliştirilmesine olanak tanır.

Arı ve Zeren [1] karbon emisyonları ile kişi başına gelir arasındaki bağlantıyı inceleyerek Çevresel Kuznets Eğrisi (EKC) teorisini sınamışlardır. Çalışmada, karbon emisyonları ile kişi başına gelir arasında ters-U şeklinde bir ilişki olduğu ortaya koyulmuştur. Ayrıca, nüfus yoğunluğu ve enerji tüketiminin CO2 emisyonlarını pozitif yönde etkilediği bulunmuştur. Sel ve Tekgün [2] küresel ölçekte yaşanan yoğun sanayileşme, hızlı nüfus artışı, bilinçsiz enerji tüketimi ve yüksek enerji talebinin CO2 emisyonlarını artırdığı belirtmiştir. Çalışmada, CO2 salınımı tahmininde ANFIS yöntemi kullanılmış ve Kyoto Protokolü ile Paris İklim Anlaşması çerçevesinde değerlendirilmiştir. Mardani vd. [3] Dünya Kalkınma Göstergeleri veri setleri üzerinde yapılan deneysel analizler ile, ANFIS modelinin enerji tüketimi ve ekonomik büyüme temelinde CO2 emisyonlarını başarılı bir şekilde tahmin ettiğini göstermiştir. ANFIS modeli, G20 ülkelerinde enerji tüketimi, CO2 ve ekonomik büyüme arasındaki ilişkiyi incelemiştir. Karaboğa ve Kaya [4], ANFIS'in eğitimi için ABC algoritması kullanmıştır ve bulgularında, Türkiye'ye gelen yabancı ziyaretçi sayısını tahmin etmede başarılı sonuçlar elde edilmiştir. Bayramoğlu vd. [5] Türkiye'nin 2016-2030 dönemindeki enerji talebini belirlemek amacıyla ANFIS yöntemi kullanılmıştır. Türkiye'nin gelecekteki enerji talebinde önemli bir artış olabileceği öngörülmüştür. Koçak [6] Türkiye örneğinde internet kullanımının CO2 emisyonları üzerindeki etkilerini incelemiştir. İnternet kullanımının hem kısa hem de uzun vadede CO2 emisyonlarını olumlu yönde etkilediği bulunmuştur. Sarıtaş ve Akar [7] turizmin karbon emisyonlarına etkisini panel veri analizi ile incelemiştir. Çalışmalarında turizmin karbon salınımını pozitif yönde etkilediği bulunmuştur. Güler ve Kandemir [8] OECD ülkelerinin CO2 emisyon değerlerini kullanarak tahmin analizi gerçekleştirmişlerdir ve Kübik regresyon analizi kullanılarak daha güvenilir sonuçlar elde etmişlerdir. Pabuççu ve Bayramoğlu [9], Türkiye ve AB-28 ülkelerinin sera gazı salım değerlerini

tahmin etmek için YSA modeli kullanılmıştır. Türkiye'nin 2030 yılı için Paris İklim Zirvesi'nde taahhüt ettiği salınım miktarını aşacağı bulunmuştur. Bozkurt ve Okumuş [10] Türkiye'de EKC hipotezini sınamak amacıyla CO2 emisyonu, ekonomik büyüme, enerji tüketimi, ticaret açıklığı oranı ve nüfus yoğunluğu arasındaki uzun vadeli ilişkiyi analiz etmişlerdir. Analiz sonucunda, ekonomik büyümenin CO2 emisyonunu artırdığı bulunmuştur. Jeong vd. [11] inşaat sırasında tüketilen malzemeler nedeniyle apartman ünitelerinden yayılan CO2 emisyonlarını incelemişlerdir. İnşaat malzemelerinin CO2 emisyonları üzerinde önemli etkileri olduğu bulunmuştur. Sun vd. [12] tarım atığı yakılmasından kaynaklanan CO2 emisyonlarını hesaplamışlardır. Anız yakmanın önemli bir CO2 emisyon kaynağı olduğu bulunmuştur. Bengochea vd. [13] Avrupa Birliği'nde ekonomik büyüme ile CO2 emisyonları arasındaki ilişkiyi incelemişlerdir. Emisyonları kontrol etmek için her AB üyesi devletin özel ekonomik durumu ve sanayi yapısı göz önünde bulundurulması gerektiği belirtilmiştir. George ve Ioana [14] Yapay Sinir Ağları ve bulanık mantık tekniklerini kullanarak turizm talebini tahmin etmişlerdir. Modelin performansı klasik istatistiksel ölçülerle değerlendirilmiştir. Harandizadeh vd. [15] farklı toprak türlerinde derin temel taşıma kapasitesini tahmin etmek için iki geliştirilmiş ANFIS tekniği kullanmışlardır. ANFIS modelleri, çoklu regresyon denklemlerine kıyasla daha yüksek hassasiyet göstermiştir. Ho vd. [16] hibrit Taguchi-genetik algoritması (HTGA) ile donatılmış bir ANFIS modeli kullanarak tıbbi bir rejimin uygunluğunu tahmin etmişlerdir. HTGA tabanlı ANFIS modelinin tahmin doğruluğu yüksektir. Roy vd. [17] CRDI destekli dizel motorun CNG çift yakıtlı operasyon altındaki performans ve emisyon parametrelerini tahmin etmek için ANFIS tabanlı model geliştirmişlerdir. Model, yüksek doğrulukla deneysel verilerle eşleşmiştir. Yazar vd. [18] askeri uçak motorları için egzoz gazı emisyonlarını tahmin etmek için ANFIS yapısını kullanmışlardır. ANFIS'in tahmin hata değerleri düşüktür ve eğitim süresi kısadır. Suleymani ve Bemani [19] biyokütlelerin yüksek ısı değerini tahmin etmek için ANFIS yöntemini kullanmışlardır. ANFIS-parçacık sürü optimizasyonunun, HHV'nin tahmin edilmesinde yüksek performans gösterdiği bulunmuştur. Pusat vd. [20] kurutma işlemi sırasında kömür nem içeriğini tahmin etmek için ANFIS yöntemi kullanmışlardır. ANFIS ağı, kömür kurutma işleminde oldukça tatmin edici sonuçlar elde etmiştir. Thanh vd. [21] İnternet kullanıcıları ve mobil hücresel aboneliklerin dijitalleşme, yeşil teknoloji, CO2 emisyonları ve enerji verimliliği arasındaki bağlantıları araştırmışlardır. İnternet kullanıcılarının dijitalleşme üzerinde etkisi büyüktür. Nassef vd. [22] Suudi Arabistan'ın CO2 emisyonlarını tahmin etmek için yapay zekâ araçlarını kullanmışlardır. LSTM modeli en yüksek doğruluğu göstermiştir. Acheampong ve Boateng [23] Avustralya, Brezilya, Çin, Hindistan ve ABD için karbon emisyon yoğunluğunu tahmin etmek amacıyla YSA kullanmışlardır. YSA modelleri yüksek doğruluk göstermiştir. Yeasmin vd. [24] yapay zekanın akıllı şehirlerde CO2 emisyonlarını öngören bir analiz sunmuşlardır. Delanoë vd. [25] dijital teknolojilerin ve yapay zekâ modellerinin CO2 emisyonlarını azaltmaya yönelik çözümleri optimize etmedeki rolünü incelemişlerdir. Yapay zekâ modelleri, bazı durumlarda negatif etkilerin pozitif etkilerden yüksek olabileceğini göstermiştir. Xu vd. [26], Çin'in CO2 emisyonlarının zirve yapma zamanını tahmin etmek için NARX modelini kullanarak 2029, 2031 veya 2035'i öngörmüştür. Meng ve Noman [27], endüstriyel faaliyetlerin CO2 salınımına etkisini ele alarak COVID-19'un etkisiyle ilgili analiz yapmışlardır. Alam ve AlArjani [28], Körfez ülkelerinde CO2 emisyonlarını tahmin etmek için farklı modelleme tekniklerini karşılaştırmışlardır. Palconit vd. [29], karayolu taşıtlarının CO2 emisyonlarını ANFIS modeli ile tahmin etmeye çalışmıştır. Soroush vd. [30], amino asitlerin CO2 yakalama süreçlerindeki potansiyelini incelemiş ve ANFIS modeli geliştirmiştir. Abdlwahaab ve Balik [31], Kanada'da motor özelliklerine dayalı bir ANFIS modeli kullanarak CO2 emisyonlarını analiz etmiştir. Cano ve Jurado [32], Ekvador'un elektrik sistemini optimize ederek yenilenebilir enerji entegrasyonu üzerine çalışmışlardır.

Adaptif Sinirsel Bulanık İnfersans Sistemi (ANFIS), CO2 emisyonlarının tahmin edilmesi konusunda oldukça etkili bir araçtır. ANFIS, farklı veri setlerinde yüksek doğruluk oranları ile tahmin yapabileme kapasitesine sahip olup, özellikle enerji tüketimi, ekonomik büyüme ve çevresel değişkenler gibi faktörler göz önüne alındığında başarılı sonuçlar elde etmektedir. Bu bağlamda, ANFIS'in CO2 emisyonlarının gelecekteki seviyelerini tahmin etmek için kullanılabilir güçlü bir yöntem olduğu söylenebilir.

2. ANFIS

ANFIS, Yapay Sinir Ağları (YSN) ve Bulanık Mantık (BM) sistemlerini birleştiren bir yaklaşımdır. Temel hedefi, giriş verileri ile çıkış verileri arasındaki karmaşık ilişkileri öğrenme yeteneğine sahip, esnek bir model oluşturmaktır. ANFIS'in öne çıkan özelliği, veriler arasındaki belirsizlikleri ele almak için Bulanık Mantık prensiplerini benimserken, öğrenme ve adaptasyon yeteneklerini Yapay Sinir Ağları temelinde sağlamasıdır. Yapay Sinir Ağları, büyük veri setlerindeki desenleri öğrenme konusunda güçlüdür, ancak belirli durumlarda belirsizlikle başa çıkmakta zorlanabilir. ANFIS, bu bağlamda Bulanık Mantık prensiplerini entegre ederek, belirsizlik yönetimi ve öğrenme yeteneklerini birleştirir.

ANFIS genellikle giriş, bulanık kural, belirleme, çıkış ve öğrenme katmanlarından oluşur. Bu katmanlar, giriş verileri ile çıkış arasındaki ilişkiyi modeller. Bulanık kurallar ve üyelik fonksiyonları, belirli durumları ifade etmek için kullanılırken, öğrenme katmanı modelin parametrelerini verilere uyarlamak için görev yapar. Bu metod, karmaşık sistemlerde desenleri tanıma, tahmin etme ve kontrol etme gibi birçok uygulamada kullanılır. ANFIS'in esnek yapısı, belirgin ve belirsiz durumları ele alabilme kabiliyetini içerir, bu da onu çeşitli endüstrilerde etkili bir şekilde kullanılan bir araç haline getirir.

ANFIS, Eğer-İse kuralları ve giriş çıkış bilgi çiftlerinden oluşan bir bulanık çıkarım sistemi içerir. Ancak sistem eğitimi ve kontrolünde Yapay Sinir Ağı (YSA) öğrenme algoritmaları kullanılır. Eğer x ve y girişleri ile z çıkışını ele alırsak temel kural yapısı aşağıdaki gibi ifade edilebilir.

Eğer $x \in C_i$ ve $y \in D_j$ ise $z_i = e_i x + f_j y + g_i$

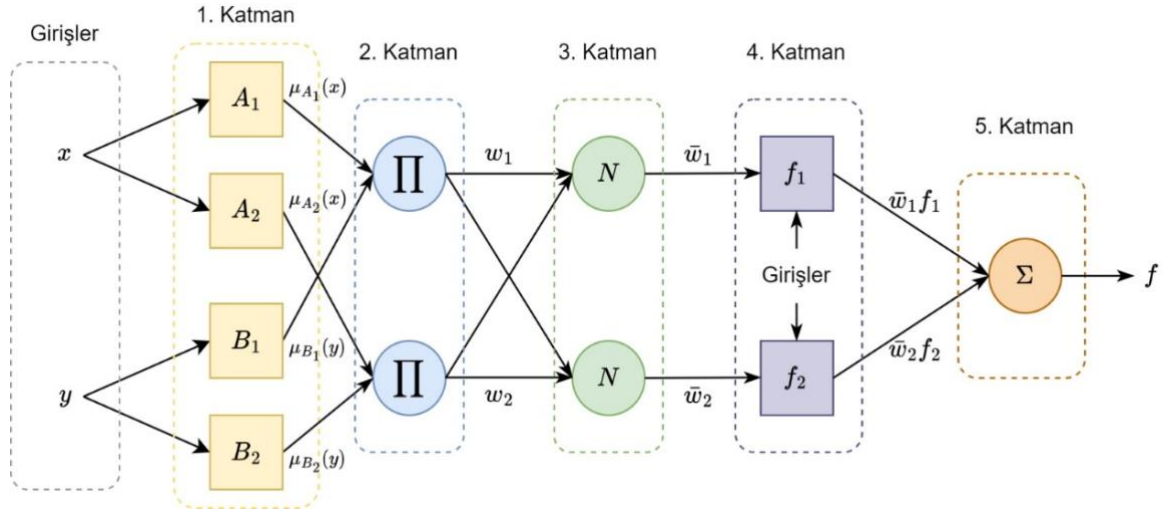
C_i ve D_j , bulanık mantık sistemlerinde kullanılan girdi değişkenlerinin bulanık alt kümelerini ifade eder. Bu alt kümeler, girdilerin belirli bir kategoride olma derecesini tanımlar. p_i , q_i ve r_i ise bulanık mantık kurallarının belirlenmesinde rol oynayan tasarım parametreleridir. Her bir kuralın çıkış değeri (z_i), girdi değişkenlerinin belirli bir kuralla ilişkili çıkış değerlerinin birleşimiyle elde edilir. Bu çıkış değeri, sistemin sonuçlarını ve davranışlarını belirlemek için kullanılır. Bu bağlamda, Eşitlik (1) girdi değişkenlerinin sistem çıkışına olan katkısını belirlemek için temel bir araçtır ve sistemin nasıl çalıştığını anlamak için önemlidir.

$$z = \frac{\sum_{m=1}^k w_m z_m}{\sum_{m=1}^k w_m} \quad (1)$$

Verilen iki bulanık kurala dayalı olarak, birinci derece bulanık Sugeno modeli için önerilen ANFIS mimarisi Şekil 1'de sunulmuştur. ANFIS modelinin katmanlarını genel olarak özetlersek:

1. Katman: Girişler, bulanıklaştırma işlemi için üyelik fonksiyonlarından geçirilerek bulanık hale getirilir.
2. Katman: Bulanık mantık sisteminin işleyişini belirleyen kurallar, bu katmanda inşa edilir.
3. Katman: Hesaplanan katkılar, normalizasyon işlemi ile tek bir değere dönüştürülür.
4. Katman: Bulanık kümelerin üyelik fonksiyonları kullanılarak, bulanık sonuçlar kesin değerlere indirgenir.
5. Katman: Bulanık mantık sistemi, tüm kural çıktılarının toplamını kullanarak tek bir sonuca ulaşır.

Bu mimari, giriş verilerinden başlayarak bulanık mantık kurallarına göre çıkarımlar yapar ve sayısal değerlere dönüştürme ile toplama işlemlerini içerir. ANFIS modeli, karmaşık ilişkileri öğrenme yeteneğiyle dikkat çeken bir yapı sunmaktadır.



Şekil 1: ANFIS Katman Yapısı (ANFIS Layer Structure)

3. Tahmin Parametrelerinin Seçimi

CO2 emisyonlarının tahmin edilmesi, iklim değişikliği ile mücadele ve sürdürülebilir kalkınma hedeflerine ulaşmak için önemli bir adımdır. Bu tahminler, çevresel politikaların belirlenmesi, enerji stratejilerinin oluşturulması ve kaynakların etkin bir şekilde yönetilmesi açısından kritik bir rol oynar. CO2 emisyonlarının tahmin edilmesi için gerekli verilerin tespiti de bu sürecin temelini oluşturur ve şu nedenlerle önemlidir:

Politika Geliştirme: CO2 emisyonlarının tahmin edilmesi, çevresel politikaların etkin bir şekilde oluşturulmasına yardımcı olur. Hükümetler ve kuruluşlar, bu tahminlerle gelecekteki emisyon trendlerini belirleyerek uygun politika önlemleri alabilirler. Örneğin, enerji verimliliğini artırmaya yönelik teşvikler veya yenilenebilir enerji kaynaklarının kullanımını teşvik eden politikalar, bu tahminlere dayanarak geliştirilebilir.

Kaynak Yönetimi: CO2 emisyonlarının tahmini, enerji kaynaklarının etkin bir şekilde yönetilmesine olanak tanır. Bu tahminler, enerji talebinin gelecekteki artışını öngörerek enerji arzını planlamayı ve kaynakların sürdürülebilir bir şekilde kullanılmasını sağlar. Böylece, enerji güvenliği ve ekonomik istikrar sağlanabilir.

Yatırım Kararları: CO2 emisyonlarının tahmin edilmesi, endüstriyel ve ticari faaliyetler için stratejik yatırım kararlarının alınmasına yardımcı olur. Şirketler, gelecekteki emisyon trendlerini göz önünde bulundurarak çevre dostu teknolojilere yatırım yapabilir veya karbon azaltma önlemleri uygulayabilirler.

Çevresel Etkilerin Değerlendirilmesi: CO2 emisyonlarının tahmini, çevresel etkilerin değerlendirilmesine ve iklim değişikliğinin olası sonuçlarının anlaşılmasına katkıda bulunur. Bu tahminler, çevresel duyarlılık ve sürdürülebilirlik stratejilerinin oluşturulmasında önemli bir rol oynar.

Uygun Kaynak Dağıtımı: CO2 emisyonlarının tahmin edilmesi, kaynakların uygun bir şekilde dağıtılmasını sağlar. Örneğin, enerji tüketimini azaltmaya yönelik projeler veya sera gazı emisyonlarını izleme ve raporlama sistemleri için gereken kaynaklar, bu tahminler doğrultusunda yönlendirilebilir.

Bu nedenlerle, CO2 emisyonlarının tahmini için gerekli verilerin tespiti, çevresel sürdürülebilirlik ve iklim değişikliği ile mücadele çabalarının temelini oluşturur. Bu verilerin doğru ve güvenilir olması, alınacak önlemlerin etkinliği ve başarısı açısından hayati öneme sahiptir. CO2 Emisyonunun tahmini için gerekli verilerin tespiti amacıyla literatür detaylı bir şekilde taranmış ve CO2 Emisyonunu etkileyen en önemli faktörler aşağıdaki Tablo 1'de verildiği gibi sıralanmıştır. Tablo 1'de sunulan CO2 emisyonunu etkileyen kriterler için Türkiye'nin 2000 ile 2021 arasındaki verileri kullanılarak, Spearman korelasyon katsayıları ve regresyon analizi katsayıları hesaplanmış ve bu sonuçlar yine Tablo 1'de

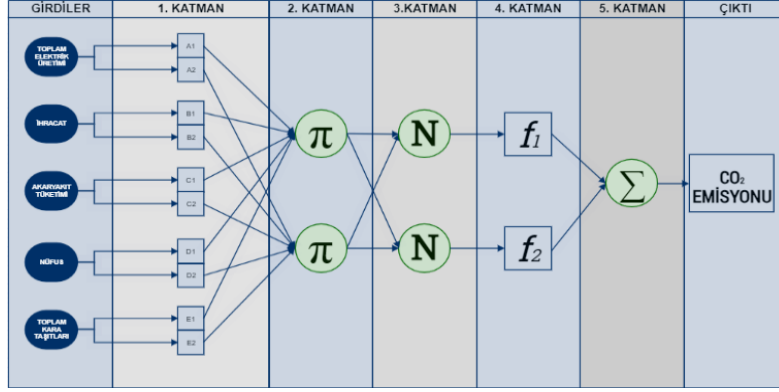
sunulmuştur. Bu analiz, Türkiye'nin CO2 emisyonlarını etkileyen faktörlerin arasındaki ilişkileri anlamak için yapılmıştır.

Tablo 1: CO2 Emisyonunu Etkileyen Faktörlerin Korelasyon ve Regresyon Katsayıları


SIRA NUMARASI	CO2 EMİSYONUNU ETKİLEYEN FAKTÖRLER	KORELASYON KATSAYILARI	REGRESYON ANALİZİ P DEĞERLERİ
1	Toplam Üretimi Elektrik	0.988	0
2	Doğalgaz	-0.449	0.01
3	Hidroelektrik	-0.172	0.285
4	Kömür ve Kömür Türevleri	0.66	0
5	Sıvı Yakıt	-0.941	0
6	Yenilenebilir Enerji	0.936	0
7	İhracat	0.953	0
8	İthalat	0.839	0
9	İnternet Verileri Kullanım	0.986	0
10	Akaryakıt	0.982	0
11	GSYH	0.709	0
12	Nüfus	0.986	0
13	Otomobil	0.685	0.001
14	Minibüs	-0.949	0
15	Otobüs	-0.918	0
16	Kamyonet	0.902	0
17	Kamyon	-0.986	0
18	Motosiklet	0.290	0.026
19	Özel Amaçlı	0.252	0.319
20	Traktör	-0.986	0
21	Kara Taşıtları	0.986	0
22	Yapı İzinleri	0.671	0.001

Tablo 1'de belirtilen sonuçlara göre, yüksek korelasyon katsayısı ilişkisi olan ve düşük regresyon p katsayısı sonucuna varılan 5 ana kriter, Türkiye'nin CO2 emisyonunu tahmin etmek için girdi olarak belirlenmiştir. Korelasyon katsayısı hesaplanırken Spearman korelasyonu tercih edilmiştir. Bu tercihin temel nedeni, bu yöntemin veriler arasındaki ilişkiyi değerlendirirken sıralama düzeyindeki ilişkilere odaklanmasıdır. Spearman korelasyonu, veri setindeki herhangi bir aykırı değerlerin etkisini azaltarak analizin daha güvenilir olmasını sağlar. Özellikle, veriler arasındaki ilişkinin doğrusal olmadığı durumlarda bu yöntem tercih edilir. Bu nedenle analizde Spearman korelasyonu kullanılması, verilerin doğru şekilde değerlendirilmesine ve sonuçların güvenilirliğine katkıda bulunmuştur. Söz konusu faktörler Şekil 2'de ana kriterler ve elde edilen sayısal veriler ise Tablo 2'de gösterilmektedir. Bu

kriterler, Türkiye'nin CO₂ emisyonlarını etkileyen temel faktörleri temsil etmek ve tahmin modellerinin doğruluğunu artırmak için önemli bir rol oynamaktadır. Şekil 3'te Türkiye'de ölçülen CO₂ emisyonlarına ilişkin veriler sunulmaktadır [38]



Şekil 2: CO₂ Emisyonunu Etkileyen Ana Parametreler ve ANFIS Katmanları



Şekil 3: Türkiye'de ölçülen CO₂ emisyonları

Tablo 2: CO2 Emisyonunu Etkileyen Ana Faktörler ve Türkiye Verileri

Elektrik Üretimi (Mwh) [33]	İhracat (BİN USD \$) [34]	Akaryakıt (Ton) [35]	Nüfus [36]	Toplam Kara Taşıtları [37]
p1	p7	p10	p15	p24
124921600	27774906	12677438.47	64113547	6302172
122724700	31334216	13440518.93	65072018	7181601
129399500	36059089	14203599.39	65988663	8655170
140580500	47252836	15393666.00	66867327	8903843
150698300	63167153	16449909.00	67785075	10236357
161956200	73476408	18075998.00	68704715	11145826
176299800	85534676	18100225.00	69601333	12227393
191558129.4	107271750	18103787.00	70158112	13022945
198418000	132027196	19131192.00	71051678	13765395
194812926	102142613	18206872.00	72039206	14316700
211207700	113883219	18461624.00	73142150	15095603
229395100	134906869	19439057.00	74223629	16089528
239496800	152461737	20144101.00	75175827	17033413
240153953	151802637	21128076.00	76147624	17939447
251962817	157610158	21892670.00	77181884	18828721
261783303.5	143838871	24824703.00	78218479	19994472
274407749	142529584	26717671.00	79277962	21090424
297277522.9	156992940	28460979.00	80312698	22218945
304801885	177168756	27807222.69	81407204	22865921
303897559.6	180832722	26737750.00	82579440	23156975
306703092.4	169637755	26372288.00	83384680	24144857
331491935	225214458	29349759.00	84147318	25249119

4. ANFIS'in Eğitilmesi

Algorithms, codes, and pseudocodes should be given in a table structure centered on the page as shown. Farklı üyelik fonksiyonları ile Tablo 2 ve Şekil 3'de sunulan verileri kullanarak farklı ANFIS modelleri eğitilmiştir. Eğitim sonucunda elde edilen tahmin hataları aşağıdaki Tablo 4'de sunulmuştur. Kullanılan üyelik fonksiyonları aşağıda sıralanmıştır. Tablo 4'de yer alan MFs değerleri her bir girdi için tanımlanan üyelik fonksiyonu adetini göstermektedir. Tablo 4'deki tüm eğitimler 150 tekrar ile yapılmıştır.

- Trimf: Üçgen şeklinde, üç parametre ile tanımlanır: Başlangıç, orta nokta ve bitiş değerleri. Belirli bir değere ait olma derecesini belirler.


- Trapmf: Trapezoid şeklinde, dört parametre ile tanımlanır: başlangıç, sol eğim, sağ eğim ve bitiş değerleri. Belirli bir değere ait olma derecesini belirler.
- Gbellmf: Genelleştirilmiş çan şeklinde, üç parametre ile tanımlanır: merkez, yayılma ve eğrilik parametreleri. Belirsizlikli ve değişken durumların modellenmesinde kullanışlıdır.
- Gaussmf: Gauss eğrisi şeklinde, iki parametre ile tanımlanır: merkez ve yayılma. İstatistiksel analizlerde ve yumuşak hesaplama sistemlerinde kullanılır.
- Gauss2mf: İki Gauss eğrisi şeklinde, iki çift parametre ile tanımlanır: her bir Gauss eğrisinin merkezi ve yayılma değerleri. Çift modellenen verilerin analizinde kullanılır.
- Pimf: Üçgen şeklinde, üç parametre ile tanımlanır: başlangıç, orta nokta ve bitiş değerleri. Trimf fonksiyonuna benzer şekilde üçgen bir üyelik fonksiyonudur.

Tablo 4: Farklı Eğitim-Test Oranları ve Üyelik Fonksiyonları İçin ANFIS Sonuçları

EĞİTİM- TEST VERİ ORANI	ÜYELİK FONKSİYONU	MFs	R2	MSE	RMSE
70-30	Trimf	3 3 3 3 3	0.4228	5799.832	76.157
70-30	Trapmf	3 3 3 3 3	0.3324	6778.082	82.329
70-30	Gbellmf	3 3 3 3 3	0.8576	1526.408	39.069
70-30	Gaussmf	3 3 3 3 3	0.9336	735.154	27.114
70-30	Gauss2mf	3 3 3 3 3	0.8939	1332.606	36.505
70-30	Pimf	3 3 3 3 3	0.3324	6778.095	82.329
70-30	Dsigmf	3 3 3 3 3	0.8975	1287.422	35.881
80-20	Trimf	3 3 3 3 3	0.809	1627.750	40.345
80-20	Trapmf	3 3 3 3 3	0.8428	271.015	16.463
80-20	Gbellmf	3 3 3 3 3	0.9725	265.681	16.300
80-20	Gaussmf	3 3 3 3 3	0.9513	602.687	24.550
80-20	Gauss2mf	3 3 3 3 3	0.9855	110.355	10.505
80-20	Pimf	3 3 3 3 3	0.8426	1236.808	35.168
80-20	Dsigmf	3 3 3 3 3	0.9867	100.109	10.005
85-15	Trimf	3 3 3 3 3	0.9755	2022.885	44.976
85-15	Trapmf	3 3 3 3 3	0.9843	1310.100	36.195
85-15	Gbellmf	3 3 3 3 3	0.9805	1701.855	41.254
85-15	Gaussmf	3 3 3 3 3	0.9747	2137.759	46.236
85-15	Gauss2mf	3 3 3 3 3	0.9832	1381.121	37.163
85-15	Pimf	3 3 3 3 3	0.9845	1298.335	36.032
85-15	Dsigmf	3 3 3 3 3	0.9961	1036.510	32.195
90-10	Trimf	3 3 3 3 3	0.9599	330.405	18.177
90-10	Trapmf	3 3 3 3 3	0.9823	149.172	12.214

90-10	Gbellmf	3 3 3 3 3	0.9881	110.791	10.526
90-10	Gaussmf	3 3 3 3 3	0.9825	158.237	12.579
90-10	Gauss2mf	3 3 3 3 3	0.987	123.117	11.096
90-10	Pimf	3 3 3 3 3	0.9829	140.333	11.846
90-10	Dsigmf	3 3 3 3 3	0.9874	119.213	10.918
95-5	Trimf	3 3 3 3 3	0.9784	178.557	13.363
95-5	Trapmf	3 3 3 3 3	0.9831	137.570	11.729
95-5	Gbellmf	3 3 3 3 3	0.9999	0.271	0.520
95-5	Gaussmf	3 3 3 3 3	0.9995	4.644	2.155
95-5	Gauss2mf	3 3 3 3 3	0.9804	162.777	12.758
95-5	Pimf	3 3 3 3 3	0.9822	144.223	12.009
95-5	Dsigmf	3 3 3 3 3	0.9888	94.246	9.708

Yapılan ANFIS tahminlemesi sonuçları, R2 değerleri en yüksek ve MSE ile RMSE değerleri en düşük olan modellerin belirlenmesi amacıyla dikkatle incelenmiştir. Bu değerlendirme neticesinde, eğitim ve test verilerinin 95-5 oranında ayrıldığı göz önünde bulundurularak en iyi performansı gösteren üyelik fonksiyonları olarak Gbellmf ve Gaussmf tespit edilmiştir. Gbellmf ve Gaussmf üyelik fonksiyonları ile eğitilen ANFIS modellerinin CO2 emisyon tahminindeki etkinlikleri ise Şekil 4.'te net bir biçimde ortaya konmuştur.



Şekil 4: Gerçekleşen ve tahminlenen CO2 emisyonları

Tablo 5 bu farklı tahmin modellerinin sonuçlarını ve performans ölçümlerini karşılaştırmalı olarak sunmaktadır. Parametreler (p1, p7, p10, p15, p24) kullanılarak yapılan analizlerde, Gbellmf ve Gaussmf üyelik fonksiyonları ile eğitilen ANFIS modellerinin, klasik regresyon modeline göre daha düşük hata değerlerine ve daha yüksek R2 değerlerine sahip olduğu görülmüştür.


Tablo 5: ANFIS tahmin modeli ve Regresyon Tahmin analizlerinin karşılaştırılması

PARAMETRELER	TAHMİN MODELİ	R2	MSE	RMSE
p1,p7,p10,p15,p24	Gbellmf	0.9999	0.271	0.520
p1,p7,p10,p15,p24	Gaussmf	0.9995	4.644	2.155
p1,p7,p10,p15,p24	Regresyon	0.9969	22.932	4.7887


Tablodaki verilere dayanarak, Gbellmf ve Gaussmf modellerinin regresyon modelinden daha iyi tahminler yaptığı sonucuna varılmıştır. R2, MSE ve RMSE metriklerine göre, Gbellmf ve Gaussmf modellerinin daha düşük hata değerlerine ve daha yüksek R2 değerlerine sahip olduğu gözlemlenmiştir. Bu bulgular, Gbellmf ve Gaussmf modellerinin regresyon modeline kıyasla daha iyi bir performans sergilediğini göstermektedir.

5. Tahmin Senaryoları

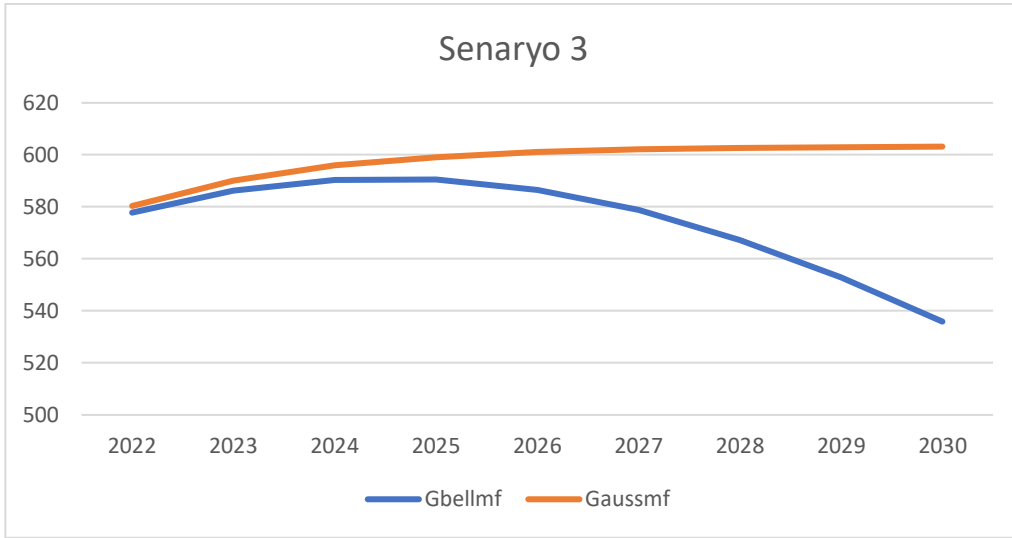
ANFIS ile eğitilen parametreler eşliğinde 2022 ve 2030 yılları arasındaki CO2 emisyonu tahmini için ANFIS modelleri kullanılmıştır. Tahminleme yaparken senaryolar geliştirilmiş ve sonuçlar birbiriyle karşılaştırılmıştır. Senaryo 1’de elektrik, ihracat, akaryakıt, nüfus ve kara taşıtı alanlarında artış oranları belirlenmiştir. Elektrik ve ihracat alanlarında %3.82 ve %4.00 artış öngörülmüşken, akaryakıt ve nüfus alanlarında sırasıyla %1.50 ve %1.30 artış öngörülmüştür. Kara taşıtları için ise %1.00 artış öngörülmüştür. Senaryo 2 elektrik, ihracat, akaryakıt, nüfus ve kara taşıtı alanlarında daha yüksek artış oranlarını içermektedir. Bu senaryo için Elektrik ve ihracat alanlarında %5.50 ve %6.50 artış öngörülmüşken, nüfus alanında %2.50’lik bir artış öngörülmüştür. Diğer yandan, akaryakıt ve kara taşıtı alanlarında ise %1.50 ve %1.00’lik sabit artış oranları kullanılmıştır. Senaryo 3’de, elektrik, ihracat, akaryakıt, nüfus ve kara taşıtı alanlarında farklı artış oranları belirlenmiştir. Elektrik ve ihracat alanlarında %3.82 ve %3.50 artış öngörülmüşken, akaryakıt ve kara taşıtı alanlarında ise %2.50 ve %3.50 artış öngörülmüştür. Nüfus alanında ise %1.30 artış öngörülmüştür. Senaryo 4 diğerlerine benzer şekilde, elektrik, ihracat, akaryakıt, nüfus ve kara taşıtı alanlarında artış oranlarını içermektedir. Elektrik ve ihracat alanlarında %5.50 ve %6.50 artış öngörülmüşken, akaryakıt, nüfus ve kara taşıtı alanlarında ise sırasıyla %2.50, %2.50 ve %3.50 artış öngörülmüştür. İki model ile elde edilen 2022 ve 2030 yılları arasındaki CO2 tahminleri Şekiller 5, 6, 7 ve 8’de verilmiştir.




Şekil 5: Senaryo 1’e göre modellerin karşılaştırılması



Şekil 6: Senaryo 2'ye göre modellerin karşılaştırılması



Şekil 7: Senaryo 3'e göre modellerin karşılaştırılması



Şekil 8: Senaryo 4'e göre modellerin karşılaştırılması

6. Tartışma

Bu çalışmada, GBELLMF ve GaussMF modelleri kullanılarak 2022'den 2026'ya kadar olan dönemde CO2 emisyonlarındaki değişiklikler incelenmiştir. Farklı senaryolar altında yapılan analizler, her iki modelin de CO2 emisyonlarının gelecekteki eğilimlerine dair farklı içgörüler sunduğunu ortaya koymaktadır. Bu modellerin sunduğu çeşitli perspektifler, çevresel politikaların ve teknolojik yeniliklerin etkilerini anlamak açısından önemlidir.

GBELLMF modeli, 2022'den 2025'e kadar olan dönemde CO2 emisyonlarında sürekli bir artış trendi gözlemlerken, 2026'dan itibaren belirgin bir düşüş eğilimi göstermektedir. Bu düşüş, belirli parametrelerin etkilerinin zamanla azalmasıyla ilişkilendirilebilir. Modelin esnekliği, çevresel politikaların ve teknolojik gelişmelerin etkilerini daha dinamik ve değişken bir şekilde yakalayabilme yeteneği sunar. Örneğin, çevre dostu politikaların hızlı bir şekilde yürürlüğe girmesi ve teknolojik yeniliklerin hızla benimsenmesi, GBELLMF modelinde daha hızlı ve belirgin bir şekilde yansıtılabilir. Bu, özellikle uzun vadede çevresel önlemlerin ve teknolojik gelişmelerin etkilerinin nasıl değişebileceğini göstermek açısından değerlidir.

GBELLMF modelinin uzun vadeli etkileri yansıtmaya yeteneği, politika yapımcılar ve araştırmacılar için önemli bir avantaj sunar. Model, CO2 emisyonlarındaki dalgalanmaları ve bu dalgalanmaların altında yatan nedenleri daha iyi analiz edebilir. Bu, çevresel önlemler ve teknolojik yeniliklerin zamanla nasıl bir etki yaratacağını öngörmek açısından kritik öneme sahiptir. Ayrıca, bu modelin sunduğu esneklik, politika değişikliklerinin ve yeniliklerin etkilerini daha hızlı bir şekilde değerlendirebilme imkânı tanır.

GaussMF modelinde ise, CO2 emisyonları sürekli bir artış göstermektedir. Bu model, daha istikrarlı ve sürekli bir büyüme eğilimi ortaya koyar. Bu sürekli artış eğilimi, ekonomik ve demografik faktörlerin daha istikrarlı bir şekilde arttığını gösterebilir. GaussMF modelinin sunduğu süreklilik ve denge, kısa vadeli ekonomik ve demografik değişimlerin daha stabil ve öngörülebilir etkilerini ortaya koyar.

GaussMF modeli, kısa vadede daha az dalgalanma göstermesi nedeniyle ekonomik ve demografik parametrelerin etkisinin daha pürüzsüz ve istikrarlı olduğunu işaret eder. Bu durum, ekonomik büyüme, nüfus artışı ve sanayileşme gibi faktörlerin CO2 emisyonları üzerindeki sürekli ve dengeli etkilerini anlamak açısından önemlidir. Modelin sunduğu bu istikrar, özellikle kısa vadeli politika ve strateji geliştirme süreçlerinde değerlidir.

GBELLMF ve GaussMF modelleri, CO2 emisyonlarının gelecekte nasıl değişebileceğine dair farklı bakış açıları sunmaktadır. GBELLMF modeli, parametrelerin etkilerini daha esnek ve dinamik bir şekilde yansıtırken, GaussMF modeli daha istikrarlı ve sürekli bir büyüme eğilimi göstermektedir. Her iki modelin de sağladığı içgörüler, çevresel politikaların ve teknolojik yeniliklerin CO2 emisyonları üzerindeki etkilerini anlamak için değerlidir.

GBELLMF modeli, uzun vadede çevresel önlemler ve teknolojik gelişmelerin etkilerini daha iyi yansıtırken, GaussMF modeli kısa vadede ekonomik ve demografik değişimlerin daha stabil ve öngörülebilir etkilerini ortaya koymaktadır. Bu modellerin birlikte kullanılması, politika yapımcılar ve araştırmacılar için daha kapsamlı ve dengeli stratejiler geliştirilmesine olanak tanımaktadır.

Örneğin, GBELLMF modelinin sunduğu uzun vadeli içgörüler, çevresel politikaların ve teknolojik yeniliklerin gelecekteki potansiyel etkilerini değerlendirmek için kullanılabilir. Bu, politika yapımcıların uzun vadeli hedefler belirlemelerine ve stratejilerini buna göre ayarlamalarına yardımcı olabilir. Öte yandan, GaussMF modelinin sunduğu kısa vadeli istikrar ve süreklilik, ekonomik ve demografik faktörlerin kısa vadede CO2 emisyonları üzerindeki etkilerini anlamak için değerlidir. Bu, kısa vadeli politikaların ve stratejilerin daha stabil ve öngörülebilir olmasını sağlar.

Sonuç olarak, GBELLMF ve GaussMF modelleri, CO2 emisyonlarının gelecekteki eğilimlerini anlamak ve çevresel politikaların ve teknolojik yeniliklerin etkilerini değerlendirmek için birbirini tamamlayan araçlar olarak kullanılabilir. Bu modellerin birlikte kullanımı, daha dengeli ve kapsamlı stratejiler geliştirilmesine olanak tanır ve böylece CO2 emisyonlarının azaltılmasına yönelik daha etkili politikaların ve yeniliklerin hayata geçirilmesine katkı sağlar.

7. Sonuçlar

Bu çalışmada, Türkiye'nin 2022-2030 yılları arasındaki CO₂ emisyonlarını tahmin etmek amacıyla ANFIS yöntemi kullanılmıştır. Literatür analizi sonucunda, CO₂ emisyonlarını etkileyen temel parametreler belirlenmiş ve Türkiye'ye özgü veriler toplanmıştır. Regresyon ve korelasyon analizleriyle yüksek ilişkili ve anlamlı veriler tespit edilmiştir. Bu veriler doğrultusunda, farklı üyelik fonksiyonlarına sahip alternatif ANFIS modelleri üretilmiş ve en düşük hata oranına sahip iki model seçilmiştir.

Testler, her iki modelin de CO₂ emisyonlarını tahmin etmede yüksek doğruluk sağladığını göstermiştir. Gbellmf üyelik fonksiyonuna sahip Model 1'in MSE değeri 0.271 ve R² değeri 0.9999, Gaussmf üyelik fonksiyonuna sahip Model 2'nin ise MSE değeri 4.644 ve R² değeri 0.9995 olarak tespit edilmiştir. Bu doğruluk seviyeleri, modellerin güvenilirliğini ortaya koymaktadır.

Dört farklı senaryo çerçevesinde yapılan tahminlerde, ekonomik büyüme ve enerji tüketimi artışlarının en fazla olduğu Senaryo 4, CO₂ emisyonlarının en yüksek olduğu senaryo olarak belirlenmiştir. En düşük CO₂ emisyon artışı ise ekonomik ve enerji tüketim artışlarının daha sınırlı olduğu Senaryo 2'de görülmüştür. Model 1, genel olarak CO₂ emisyonlarında daha temkinli bir düşüş trendi öngörürken, Model 2 daha stabil ve artış eğilimindedir.

Çalışma, Türkiye'nin CO₂ emisyonlarını etkileyen faktörleri detaylı bir şekilde analiz ederek, enerji ve çevre politikalarına yönelik önemli çıkarımlar sunmaktadır. Yenilenebilir enerji kaynaklarına yapılan yatırımların artırılması, enerji verimliliğinin iyileştirilmesi, kentsel planlama ve sürdürülebilir ulaşım politikalarının geliştirilmesi, yeşil üretim teknolojilerinin teşvik edilmesi ve karbon ayak izinin azaltılması gerekmektedir.

Analiz sonucunda elde edilen bulgular, gelecekteki araştırmalar için önemli yönergeler sunmakta ve daha kapsamlı çalışmalar yapılmasını önermektedir. CO₂ emisyonlarının yanı sıra diğer sera gazlarının etkilerinin de analiz edilmesi, farklı ülkeler veya bölgeler için benzer senaryo analizlerinin gerçekleştirilmesi ve ekonomik, teknolojik ve politik değişkenlerin daha geniş veri setleri ile modellenmesi, tahmin sonuçlarının doğruluğunu artıracaktır. Sonuç olarak, bu çalışma Türkiye'nin CO₂ emisyonlarına ilişkin gelecekteki projeksiyonlar ve enerji politikaları için hayati bilgiler sağlamaktadır. Modellerin doğruluğu ve senaryo analizlerinin çeşitliliği, sürdürülebilirlik hedeflerine ulaşma ve küresel iklim değişikliği ile mücadele stratejilerine önemli katkılar sunmaktadır. Bu çalışma, Türkiye özelinde olduğu kadar küresel düzeyde de iklim politikalarının geliştirilmesine yönelik bilimsel temelli stratejik planlamaların yapılmasına zemin hazırlamaktadır.

Contribution of Researchers

All researchers have contributed equally to writing this paper.

Conflicts of Interest


The authors declare no conflict of interest.

References

- [1] Arı, A., Zeren, F., 2011. CO₂ emisyonu ve ekonomik büyüme: panel veri analizi. *Yönetim ve Ekonomi Dergisi*, 18 (2), s.37-47
- [2] Sel, A., Tekgün, B., 2022. ANFIS yöntemi ile türkiye karbondioksit salınım tahmini. *Süleyman Demirel Üniversitesi Vizyoner Dergisi*, 13 (34):486-504.
- [3] Mardani, A., Streimikiene, D., Nilashi, M., Arias Aranda, D., Loganathan, N., Jusoh, A., 2018. Energy consumption, economic growth, and CO₂ emissions in G20 countries: application of adaptive neuro-fuzzy inference system. *Energies*, 11(10):2771.
- [4] Karaboga, D., Kaya, E., 2020. Estimation of number of foreign visitors with ANFIS by using ABC algorithm. *Soft Computing*, 24(10):7579-7591.
- [5] Bayramoğlu, T., Pabuççu, H., Boz, F.Ç., 2017. Türkiye için ANFIS modeli ile birincil enerji talep tahmini. *Ege*

- Akademik Bakış, 17(3):431-445.
- [6] Koçak, S., The effect of internet use on CO2 emissions: The case of Turkey, pp 451-503 February 24-25, 2022 Ankara, Turkey Baskent International Conference On Multidisciplinary Studies.
- [7] Sarıtaş, T., Akar, G., 2022. Turizmin CO2 emisyonuna etkisi: Panel veri analizi. *Ekonomi Maliye İşletme Dergisi*, 5(1): 104-117.
- [8] Güler, E., Kandemir, S. Y., 2022. Lineer ve kübik regresyon analizleri kullanılarak OECD ülkelerinin CO2 emisyonlarının tahminlemesi. *Avrupa Bilim ve Teknoloji Dergisi*, 34, 175-180.
- [9] Pabuçcu, H., Bayramoğlu, T., 2016. Yapay sinir ağları ile CO2 emisyonu tahmini: Türkiye örneği. *Gazi Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 18(3): 762-778.
- [10] Bozkurt, C., Okumuş, İ., 2015. Türkiye’de ekonomik büyüme, enerji tüketimi, ticari serbestleşme ve nüfus yoğunluğunun CO2 emisyonu üzerindeki etkileri: Yapısal kırılmalı eşbütünleşme analizi. *Mustafa Kemal Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 12(32): 23-35.
- [11] Jeong, Y. S., Lee, S. E., Huh, J. H., 2012. Estimation of CO2 emission of apartment buildings due to major construction materials in the Republic of Korea. *Energy and Buildings*, 49: 437-442.
- [12] Sun, J., Peng, H., Chen, J., Wang, X., Wei, M., Li, W., Mellouki, A., 2016. An estimation of CO2 emission via agricultural crop residue open field burning in China from 1996 to 2013. *Journal of Cleaner Production*, 112: 2625-2631.
- [13] Bengochea-Morancho, A., Higón-Tamarit, F., Martínez-Zarzoso, I., 2001. Economic growth and CO2 emissions in the European Union. *Environmental and Resource Economics*, 19: 165-172.
- [14] George, A., & Ioana, U. C., 2007. Forecasting tourism demand using ANFIS for assuring successful strategies in the view of sustainable development in the tourism sector. In *Proceedings of the 2nd IASME/WSEAS International Conference on Energy & Environment (EE’07)*, Portoroz, Slovenia. pp. 212-217.
- [15] Harandizadeh, H., Toufigh, M. M., Toufigh, V., 2019. Application of improved ANFIS approaches to estimate bearing capacity of piles. *Soft Computing*, 23: 9537-9549.
- [16] Ho, W. H., Chen, J. X., Lee, I. N., Su, H. C., 2011. An ANFIS-based model for predicting adequacy of vancomycin regimen using improved genetic algorithm. *Expert Systems with Applications*, 38(10): 13050-13056.
- [17] Roy, S., Das, A. K., Bhadouria, V. S., Mallik, S. R., Banerjee, R., Bose, P. K., 2015. Adaptive-neuro fuzzy inference system (ANFIS) based prediction of performance and emission parameters of a CRDI assisted diesel engine under CNG dual-fuel operation. *Journal of Natural Gas Science and Engineering*, 27: 274-283.
- [18] Yazar, I., Şöhret, Y., Karakoç, T. H., 2017. ANFIS-based comparative exhaust gases emissions prediction model of a military aircraft engine. *International Journal of Global Warming*, 12(1): 116-128.
- [19] Suleymani, M., Bemani, A., 2018. Application of ANFIS-PSO algorithm as a novel method for estimation of higher heating value of biomass. *Energy Sources, Part A: Recovery, Utilization, and Environmental Effects*, 40(3): 288-293.
- [20] Pusat, S., Akkoyunlu, M. T., Pekel, E., Akkoyunlu, M. C., Özkan, C., & Kara, S. S., Estimation of coal moisture content in convective drying process using ANFIS. *Fuel processing technology*, 147, 12-17, 2016.
- [21] Hieu, N. T., Le Thanh, H., Anh, B. T. M., 2023. Scrutinizing time-varying interlinkages between digitalization, green technologies, CO2 emission, and energy productivity in Vietnam. *Journal of Cleaner Production*, 137581.
- [22] Nassef, A. M., Olabi, A. G., Rezk, H., Abdelkareem, M. A. 2023. Application of Artificial Intelligence to Predict CO2 Emissions: Critical Step towards Sustainable Environment. *Sustainability*, 15(9): 7648.
- [23] Acheampong, A. O., Boateng, E. B., 2019. Modelling carbon emission intensity: Application of artificial neural network. *Journal of Cleaner Production*, 225: 833-856.
- [24] Yeasmin, S., Syed, S. N. J., Shmais, L. A., & Al Dubayyan, R., 2020, November. Artificial Intelligence-based CO2 Emission Predictive Analysis System. In *2020 International Conference on Artificial Intelligence & Modern Assistive Technology (ICAEMAT)*: 1-6.
- [25] Delanoë, P., Tchuente, D., Colin, G. 2023. Method and evaluations of the effective gain of artificial intelligence models for reducing CO2 emissions. *Journal of Environmental Management*, 331, 117261.
- [26] Xu, G., Schwarz, P., Yang, H. 2019. Determining China's CO2 emissions peak with a dynamic nonlinear artificial neural network approach and scenario analysis. *Energy Policy*, 128: 752-762.
- [27] Meng, Y., Noman, H. 2022. Predicting CO2 Emission Footprint Using AI through Machine Learning. *Atmosphere*, 13(11): 1871
- [28] Alam, T., AlArjani, A. 2021. A comparative study of CO2 emission forecasting in the gulf countries using autoregressive integrated moving average, artificial neural network, and holt-winters exponential smoothing models. *Advances in Meteorology*, 2021: 1-9.
- [29] Palconit, M. G. B., Conception II, R. S., Alejandrino, J. D., Nuñez, W. A., Bandala, A. A., Dadios, E. P., 2021, September. Comparative ANFIS Models for Stochastic On-road Vehicle CO 2 Emission using Grid Partitioning, Subtractive, and Fuzzy C-means Clustering. In *2021 IEEE 9th Region 10 Humanitarian Technology Conference (R10-HTC)* (pp. 1-6). IEEE.
- [30] Soroush, E., Mesbah, M., Hajilary, N., Rezakazemi, M., 2019. ANFIS modeling for prediction of CO2 solubility in potassium and sodium based amino acid Salt solutions. *Journal of Environmental Chemical Engineering*, 7(1), 102925.

- [31] Agha, S. A., Balik, H. H., 2023, June. The application of ANFIS to prediction of the amount of emissions from an emitter activity to reduce climate change. In 2023 International Conference on Engineering, Science and Advanced Technology (ICESAT) (pp. 187-192). IEEE.
- [32] Arévalo, P., Cano, A., Jurado, F. 2024. Large-scale integration of renewable energies by 2050 through demand prediction with ANFIS, Ecuador case study. *Energy*, 286, 129446.
- [33] Enerji Atlası. (2023). Türkiye Elektrik Tüketimi. <https://www.enerjiatlası.com/>. (Erişim tarihi: 2024-02-13).
- [34] Türkiye İstatistik Kurumu (TÜİK). (2023). Aralık 2023 Dış Ticaret İstatistikleri. <https://www.tuik.gov.tr/>. <https://ticaret.gov.tr/istatistikler/dis-ticaret-istatistikleri>. (Erişim tarihi: 2024-02-13).
- [35] Petrol İhracatçıları Birliği (PETDER). (2023). Aralık 2023 Akaryakıt Satış İstatistikleri. Petrolleri İhracatçıları Birliği. <https://www.petder.org.tr/>. (Erişim tarihi: 2024-02-13).
- [36] Dünya Bankası. (2023). Türkiye Nüfus Sayıları. Dünya Bankası Veri Bankası. <https://data.worldbank.org/>. (Erişim tarihi: 2024-02-13).
- [37] Türkiye İstatistik Kurumu (TÜİK). (2023). Ocak 2023 Motorlu Kara Taşıtları İstatistikleri. Türkiye İstatistik Kurumu. <https://data.tuik.gov.tr/Bulten/Index?p=Motorlu-Kara-Ta%C5%9F%C4%B1tlar%C4%B1-Ocak-2023-49433&dil=1>. (Erişim tarihi: 2024-02-13).
- [38] T.C. Türkiye İstatistik Kurumu. (2023). Sera Gazı Emisyon İstatistikleri 1990-2021. [Web sitesi]. <https://data.tuik.gov.tr/Bulten/Index?p=Sera-Gazi-Emisyon-Istatistikleri-1990-2021-49672>. (Erişim tarihi: 2024-02-13).



İnsansız Hava Araçlarında İnsan Hatasının Etkilerinin Sistemik Analizi ve Sınıflandırılması-İHA Tasarımı ve Ergonomi

İbrahim AKYÜREK^{1*}, ERGÜN ERASLAN²

¹Ankara Yıldırım Beyazıt Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi, Endüstri Mühendisliği Bölümü İş Sağlığı ve Güvenliği Doktora Programı; ORCID: 0000-0002-0286-7607

² Ankara Yıldırım Beyazıt Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi, Endüstri Mühendisliği Bölümü; ORCID: 0000-0002-5667-0391

* Corresponding Author: ibrahim_akyurek@yahoo.com

Received: 6 December 2023; Accepted: 17 July 2024

Reference/Atf: İ. Akyürek and E. Eraslan, “İnsansız Hava Araçlarında İnsan Hatasının Etkilerinin Sistemik Analizi ve Sınıflandırılması-İHA Tasarımı ve Ergonomi”, Researcher, vol. 04, no. 02, pp. 157–165, 2024.



Özet

Bu çalışmada öncelikle insansız hava araçlarında insan faktörü ile ilgili yayınlanan literatür gözden geçirilmiştir. Bir sonraki adımda, çalışmalarını sınıflandırmak üzere bir içerik analizi yapılmıştır. Literatürdeki çalışmalar sistemik olarak ana ve alt gruplarda toplanmıştır. Sınıflandırmanın ardından literatür tartışılarak eksik alanlar ortaya çıkarılmış ve gelecekteki araştırmalara ışık tutulmaya çalışılmıştır. 69 çalışmanın derinlemesine incelendiği bir makale üzerinden içerik analizi yapılmıştır. Bu süreçte araştırmacıların üzerinde durdukları bazı ortak konular belirlenmeye çalışılmıştır. Beş ana grupta toplanan sınıflandırma içinde İHA Tasarımı ve Ergonomi başlığı üzerine yoğunlaşmıştır. İnsansız hava araçlarının kullanıcı arayüzlerinin ve ekranlarının tasarımında insan faktörlerinin etkisi bulunmaktadır. Operatörün bulunduğu yer kontrol istasyonunun (YKİ) tasarımı ve ergonomik özelliklerinin insan hatasına yol açabilecek faktörleri incelenmiştir. Kullanıcı arayüzü ve ekran tasarımları ile ergonomik yapıların iş yükü, durum farkındalığı ve karar verme gibi değişkenler üzerindeki etkileri araştırılmıştır. İş yükünü azaltacak, durumsal farkındalığı artıracak, algıyı olumlu yönde etkileyecek ve operatörlerin doğru karar vermesine yardımcı olacak optimum tasarım ve ergonomik yapıların geliştirilmesine odaklanılması sağlanmıştır. Ayrıca, insansız hava araçlarının insan faktörünün olumsuz etkilerini ortadan kaldıracak şekilde tasarlanmasıdır. Tasarım ve ergonomik yapıdaki gelişmeler sonucunda insansız hava araçlarının operatörler tarafından daha verimli, etkin ve güvenli bir şekilde kullanılmasının sağlanması amaçlanmaktadır. Yer kontrol istasyonlarının ekran açısı, sıcaklık, ekran karşısındaki duruş, çalışma saati gibi hususlarda ergonomik açıdan yaşanabilecek sorunlar ve çözüm önerileri üzerine çalışılmıştır. Örnek bir yer kontrol istasyonu tasarımı incelenmiş ergonomik faktörler gözden geçirilmiştir. Ekranların açısı, oturma pozisyonu, termal konfor gibi faktörler üzerine önerilerde bulunulmuştur.

Anahtar Kelimeler: İnsansız hava aracı, yer kontrol istasyonu, tasarım, ergonomi

Abstract

In this study, first of all, the published literature on the human factor in unmanned aerial vehicles was reviewed. In the next step, a content analysis was made to classify the studies. Studies in the literature were systematically grouped into main and subgroups. After the classification, the literature was discussed, and missing areas were revealed, and it was tried to shed light on future research. Content analysis was conducted on an article in which 69 studies were examined in depth. In this process, some common issues that the researchers focused on were tried to be determined. In the classification grouped in five main groups, the focus is on UAV Design and Ergonomics. Human factors have an effect on the design of the user interfaces and screens of unmanned aerial vehicles. The design and ergonomic features of the operator's ground control station (GCS), which may cause human error, were investigated. The effects of user interface and screen designs and ergonomic structures on variables such as workload, situation awareness and decision making were investigated. Focusing on the development of optimum design and ergonomic structures that will reduce the workload, increase situational awareness, positively affect perception and help operators make the right decision. In addition, unmanned aerial vehicles are designed to eliminate the negative effects of the human factor. As a result of the developments in the design and ergonomic structure, it is aimed to ensure that the unmanned aerial vehicles are used more efficiently, effectively and safely by the operators. Ergonomic problems and solution proposals have been studied in issues such as the screen angle of the ground control stations, temperature, posture in front of the screen, working hours. The design of a ground

control station is examined, and ergonomic factors are reviewed. Suggestions were made on factors such as the angle of the screens, sitting position, thermal comfort.

Keywords: Unmanned aerial vehicle, ground control station, design, ergonomics

1. GİRİŞ

Sivil Havacılık Örgütü insansız hava araçlarını uzaktan kumandalı ve otomatik olmak üzere iki ana gruba ayırmaktadır.

Günümüzde keşif, taarruz, diğer insansız hava araçlarına karşı savunma, hedef alma askeri eğitim ve mayın temizleme gibi askeri görevlerde insansız hava araçları sıklıkla kullanılmaktadır.

Sivil kullanım alanları arasında doğal afetlerin ve arama kurtarma faaliyetlerinin takibi, tarım alanlarının ve zirai ilaçlamaların izlenmesi, havadan fotoğraf ve video çekimi yer alıyor. Bunun yanı sıra haritacılık, çevre gözlemi, kentsel yapılanma, arkeoloji, orman yangınlarının izlenmesi veya kamusal alanlar gibi birçok faaliyet için insansız hava araçları tercih edilmektedir.

Havacılık sistemlerinde insan faaliyetinin evrimi uçağın varlığı sırasında, içlerindeki bir kişinin rolü, otomasyonun büyümesiyle birlikte önemli değişikliklere uğramıştır. Başlangıçta, pilotun rolü manuel kontrolden oluşuyordu, yavaş yavaş sevk kontrol ve takip operatör faaliyetlerine doğru değişti, ardından "İnsansız hava aracı" ortaya çıkmıştır. Bir uçağı uçurmanın doğrudan insan faaliyeti, kokpit aletlerinin kullanımı ve manuel kontrol, kokpit aletlerinin izlenmesine kadar uzaktan kumanda için yer istasyonu araçlarının kullanımına kadar uçağı neredeyse otomatik olarak kontrol eden uçağın kontrolü olarak tanımlanmaktadır.

Dünya askeri insansız hava araçları pazarının hacminin 2025 yılında 26,8 milyar dolara ulaşması beklenmektedir. Dünyadaki askeri ve sivil insansız hava aracı pazarı 2019 yılında toplam 9,3 milyar dolara ulaşmıştır. Bu pazarın yıllık bileşik büyüme oranı ile %15,5 artarak 2025 yılında 45,8 milyar dolara ulaşması beklenmektedir. Önümüzdeki 5 yılda dünyanın her yerinde insansız hava araçlarının sayısında artış beklenmektedir [1].

İnsansız hava araçlarının yoğun kullanımı, gerekli önlemler alınmadığı takdirde kazaların ve olayların artmasına neden olabilir. Amerika Birleşik Devletleri Federal Havacılık İdaresi'ne (FAA) bildirilen insansız hava aracı kazası sayısı Şubat 2014'te sadece 50 iken, bu sayı Aralık 2016'da 200'ü aşmıştır.

Kaza ve olaylara neden olan faktörler arasında insan faktörü önemli bir rol oynamaktadır. Bu bağlamda insansız hava araçlarında insan faktörünün daha iyi anlaşılması, gelecekte olabilecek kaza ve olayların önlenmesi açısından oldukça faydalı olacaktır.

Bu çalışmada öncelikle insansız hava araçlarında insan faktörü ile ilgili 1945-2020 yılları arasında yayınlanan literatür gözden geçirilmiştir.

Bir sonraki adımda, literatüre sistematik bir bakış açısı kazandırmak için çalışmaları sınıflandırmak üzere bir içerik analizi yapılmıştır.

Sonuç olarak literatürdeki çalışmalar sistematik olarak ana ve alt gruplarda toplanmıştır. Sınıflandırmanın ardından literatür tartışılarak eksik alanlar ortaya çıkarılmıştır.

İHA sistemlerine özgü tasarım tavsiyeleri, ilgili ofis ve iş için literatürde tanımlanmış çevre literatürü gözden geçirilmiş ve bu boşlukları doldurmak için kullanılmıştır.

Kontrol istasyonu üzerinde yapılan çalışmaların genel amacı, Federal Havacılık İdaresi'ne (FAA), İHA sistemlerinin güvenli pilotluğunu sağlayacak insansız hava aracı sistemi (UAS) kontrol istasyonlarının ergonomik tasarımı hakkında bilgi sağlamaktır. İnsansız uçak kazalarının büyük bir yüzdesi, %69'u hem fiziksel iş istasyonu tasarımı hem de insan-makine etkileşimi dahil olmak üzere insan faktörü konularına atfedilmiştir. Literatürde, FAA'ya uygun operatör konforunu ve performansını artıracak ve kas-iskelet yaralanma risklerini azaltacak minimum fiziksel kontrol istasyonu tasarım önerileri sağlamaktır. İHA sistemleri kontrol istasyonu tasarımına özgü literatürün ayrıntılı bir incelemesi yapılmıştır. Kontrol istasyonlarıyla ilgili literatür olmasına rağmen, aslında iş istasyonunun fiziksel tasarımına yönelik çok

az çalışma vardır. Bu nedenle, kontrol istasyonları için bir ön tasarım önerileri vermek üzere mevcut iş istasyonu tasarım literatürü yeniden gözden geçirilmiştir.

Bu tavsiyeler mevcut standartlara ve en son literatüre dayanmakla birlikte, kontrol istasyonunun tasarımında veya içinde değişiklik yapılacak alanları belirlemek için bu tavsiyelerin resmi olarak test edilmesi ve değerlendirilmesinin yanı sıra mevcut kontrol istasyonlarıyla karşılaştırılmasına ihtiyaç vardır

Genel olarak, İHA'ların kontrolünün sabit bir yer ve tesiste gerçekleşmesi beklenmektedir. Bununla birlikte, İHA'ların mobil kontrol istasyonları kullanılarak da kontrol edilmesi gerekebileceğinden, iki ek senaryo için öneriler geliştirilmiştir: 1) hareketli bir ortamda (örn. römork, kamyonet, gemi, uçak) bulunan kontrol istasyonu ve 2) sabit kontrol istasyonudur.

Bu itibarla çevresel her üç seviye için de faktörler (sabit kontrol istasyonu, mobil kontrol istasyonu ve mobil operatörün taşıdığı kontrol istasyonu) dikkate alınmış ve öneriler sunulmuştur.

2. METODOLOJİ

İnsansız hava araçlarında insan faktörü ile ilgili çalışmaları bulmak için bir dizi arama yapılmıştır. “insan faktörü” ve “insan hatası” anahtar kelimeleri, “insansız hava aracı”, “İHA”, “insansız hava aracı”, “insansız havacılık sistemi”, “insansız hava aracı sistemi” ve “UAS” anahtar kelimeleri ile birlikte aranmaktadır. Çalışmaların başlık, “yazar anahtar sözcükleri” ve “öz” alanlarıdır. Zhang et. al. (2018) anahtar kelime seçiminde rehber olarak kullanılmıştır [2].

Tarama ve eleme aşamalarından sonra 69 çalışmanın derinlemesine incelendiği içerik analizi yapılmıştır. Bu süreçte araştırmacıların üzerinde durdukları bazı ortak konular belirlenmeye çalışılmıştır. Shapel et. al. (2007), Chang ve Wang (2010) ve Wiener ve Nager (2014), çalışmaların sınıflandırmasını tanımlamak için kullanılmaktadır. Ayrıca Zhang et. al. (2018) bu süreçte yol gösterici olarak dikkate alınmıştır [2].

Yapılan içerik analizi sonucunda literatürdeki çalışmalar 4 ana grupta toplanmış ve daha sonra aynı yöntem kullanılarak her grubu oluşturan alt gruplar oluşturulmuştur. İnsan Faktörlerinin Tanıtılması ilk sıradadır. Havacılıkta insan faktörleri alanında da sıklıkla çalışılan iş yükü, durumsal farkındalık, karar verme ve iş birliği gibi değişkenleri araştıran insansız hava araçları üzerine çalışmalar bulunmaktadır. Daha sonra “iş yükü”, “durumsal farkındalık”, “karar verme ve özerklik”, “yorgunluk” ve “iş birliği, takım uyumu ve koordinasyonu” olarak adlandırılan alt gruplar oluşturularak çalışmalar ilgili alt gruplara dağıtılır.

Örneğin, bir çalışma aynı zamanda yorgunluk, stres ve uyanıklığı araştırmış olabilir. Bir diğeri ise aynı araştırmadaki yorgunluğu, ekip boyutunu ve iş yükünü incelemektedir. Bu tür çalışmalar “Çok faktörlü araştırmalar” adı verilen farklı bir alt grupta toplanmaktadır.

İHA Tasarımı ve Ergonomi başlığı bu çalışmanın ana konusunu oluşturmaktadır. Çalışma grubu, insansız hava araçlarının kullanıcı arayüzlerinin ve ekranlarının tasarımında insan faktörlerinin etkisi ile ilgilidir. Kullanıcı arayüzü ve ekran tasarımları ile ergonomik yapıların iş yükü, durum farkındalığı ve karar verme gibi değişkenler üzerindeki etkileri araştırılmıştır. Bu çalışmaların birçoğu, iş yükünü azaltacak, durumsal farkındalığı artıracak, algıyı olumlu yönde etkileyecek veya operatörlerin doğru karar vermesine yardımcı olacak optimum tasarım veya ergonomik yapıların geliştirilmesine odaklanmaktadır. İkinci alt gruptaki çalışmalar, benzer bir tasarım ve ergonomi yaklaşımını insansız hava araçlarının kontrol üniteleri ve diğer sistemleri üzerinde yürütmektedir. Bu çalışmalarda, uçuş yönetim sistemleri, navigasyon sistemleri, aviyonik sistemler gibi insansız hava aracı bileşenlerinin tasarımının ve ergonomik yapısının insan faktörü üzerindeki etkileri derinlemesine incelenmektedir [3].

Bu gruptaki çalışmaların ortak amacı, insansız hava araçlarının insan faktörünün olumsuz etkilerini ortadan kaldıracak şekilde tasarlanmasıdır. Tasarım ve ergonomik yapıdaki gelişmeler sonucunda insansız hava araçlarının operatörler tarafından daha verimli, etkin ve güvenli bir şekilde kullanılmasının sağlanması amaçlanmaktadır.

Ekip Üyeleri ise diğer bir ana grup başlığıdır. Bu gruptaki çalışmalar mürettebat konularını insan faktörü açısından ele almaktadır. Üç alt gruba ayrılırlar. Birinci gruptaki çalışmalar, farklı koşullar ve senaryolar altında mürettebat davranışını ve davranışsal tepkileri inceler. Ekiplerin farklı durumlara verdiği tepkiler değerlendirilerek, insan faktörü değişkenlerine dayalı ekip davranış profillerinin oluşturulması amaçlanmaktadır.

İkinci alt gruptaki çalışmalar, ekip seçimi, performans değerlendirmesi ve ekip yetkinliklerini insan faktörleri perspektifinden ele almaktadır. Bu çalışmalardan bazıları, mürettebatın fiziksel yeterlilik, tıbbi durum ve hatta dil yeterliliği açısından performansını ve yeterliliklerini ele almaktadır. Bazı çalışmalar, insansız hava aracı pilotlarının performans ve yeterlilik değerlendirmeleri için insan faktörü odaklı öneriler sunmaktadır. Ayrıca ekip üyesi olarak yetiştirilecek kişilerin seçiminde dikkate alınması gereken insan faktörü konuları da bu alt grupta incelenir [4].

Operasyonel Konular son ana grup başlığıdır. Bu gruptaki çalışmalar, insansız hava araçları ile gerçekleştirilen fiili uçuş operasyonlarını ve ilgili görevleri insan faktörü açısından incelemektedir. Bu gruptaki yalnızca bir çalışma, operatörlerin uçuş prosedürlerine ve kontrol listelerine uyma derecesini otomatik ve sürekli olarak kontrol edecek bir sistem önermektedir. Bu nedenle söz konusu çalışma “işlemler ve kontrol listeleri” adı altında farklı bir alt gruba alınmıştır [5].

Diğer çalışmalar “uçuş operasyonları” adı verilen alt grupta yer almaktadır. Bu çalışmalardan bazıları, insansız hava araçlarının paket teslim, arama kurtarma ve kamu hizmetleri gibi belirli görevlerini insan faktörü açısından iyileştirmenin yollarını arıyor. Ayrıca, bu alt gruptaki çalışmalar, bir operatörün kontrol edebileceği optimum uçak sayısının hesaplanması ve görev parçalarının operatörler ve sistemler arasında dağıtılması gibi konuları araştırır [6].

Bu çalışmada yapılan sınıflandırmanın açık bir sonucu, nispeten yeni olan insansız hava araçları alanında, insan faktörü çalışmalarına bir yol göstermesidir. Ayrıca insan faktörleri alanının ana konuları olan iş yükü, karar verme, durum farkındalığı, yorgunluk gibi değişkenlerle ilgili çok az çalışma olması dikkat çekicidir. Bu değişkenlerin farklı koşullar altında nasıl değiştiği, uçuş operasyonlarının etkinlik, verimlilik ve emniyetini nasıl etkilediğinin araştırılması insansız hava araçlarının geleceği açısından faydalı olacaktır.

Bazı yer kontrol istasyonu (YKİ), karmaşık tasarım öğelerine sahiptir. Küçük veya rutin görevleri gerçekleştirmek için optimize edilmemiş otomasyon arayüzleri bulunmaktadır. YKİ'deki bu tasarım hataları kokpit konumlarına tasarım ve ergonomi ilkeleri uygulanarak önlenabilir. YKİ tasarımındaki sorunlar, geliştirilmekte olan İHA'nin optimize edilmemesine neden olabilir.

Kontrol istasyonu tasarımında;

- İHA'yı kontrol etmek için aktif olarak kullanılmadan önce pilota kontrol bağlantısının kalitesi hakkında bilgi sağlamak
- Pilota, hangisinin aktif olduğunu belirlemek için gerekli bilgileri sağlamak (örn. seçilen frekans, uydu vs. karasal)
- Bağlantı kaybolduğunda veya önemli ölçüde bozulduğunda pilotu uyarmak
- Pilotun iletişim modunu seçmesi için bir araç sağlaması (örn. karasal/uydu, frekans)
- İşitsel veya görsel uyarıların içgüdüselliği
- İş yoğunluğu
- Tutarlılık
- Kontrol girişleri hakkında geri bildirim
- Rahatsız edici uyarılar
- Acil özellikler

Seçilen İHA konsepti aşağıdaki ana maddelere dayanmaktadır;

Hava vektörleri hava ve yüzey uzayında görsel yarıçapın ötesine geçebilen, altında İHA'nın çalışması hem hava hem de yüzey vektörleri için eşzamanlı, ayrı çalışma koşulları; operasyon ve sezgisel ve minimum kaynak kullanımı yoluyla İHA'nın bakımı; İHA işlemi tüm aşamaları kapsar. Uçuş planlamasından bilgilendirmeye kadar görevin boyutu, ağırlığı ve çok yönlülüğü nedeniyle İHA konsepti mevcut bir ürüne dayanmaktadır [7]. İHA dahili bağlantıları şunlardır: güç kaynağı (dahili / harici kaynak), video sinyali iletimi, telemetri sinyalinin iletimi, kontrol ve komut sinyalinin iletimi, harici kullanıcılar ve bağlantılardır [8].

İHA geliştirme ekibi, tasarım aşamasından itibaren bir dizi faktörü dikkate alır, örneğin, yapı ve geometri, donanım ve bağlantı donanımı, yazılım bileşeni ve kullanıcı arayüz dikkate alınan parametrelerden bazılarıdır. Parametreler aşağıdaki gibi detaylandırılmıştır. Geometri ve yapı tasarım özellikleri boyutsal olarak ve tamamen optimize edilmiştir. İHA'nın hareketliliği (sert kap, kulplar, taşıma makaraları) gözden geçirilmiştir.

İHA operatörlerinin başlıca ergonomik sorunları şunlardır [9]

- Duyusal sinyallerde azalma (nesnelere göz temasının bozulması (kamera bir sınırlı görüş alanı, azalmış işitsel ve koku alma duyuları),
- Kontrol istasyonunun psikolojik ve duygusal algısı (bunlar daha çok geleneksel bir kabinden daha kontrol odaları veya ofis iş istasyonları),
- İnsan fizyolojisi açısından gerçekçi olmayan, görevin zamanlaması (için örneğin, 24 saatten fazla) yorgunluk ve ardından ihtiyaç ile ilişkili riskler eşlik eder. Kontrolü başka bir operatöre devretmek, bu da hatalara yol açar;
- Uçuşun acil bir şekilde sonlandırılması ve uçağın imha edilmesi olasılığı
- Otomasyona güven ayrı bir sorundur. Bir uçağın aksine, bir İHA'nın hiçbir şekilde manuel kontrolü yoktur.

İletişim sistemleri, sistem öğeleri ve hariciler arasında veri paylaşımı için araç sağlar. Günümüzde çoğu İHA sistemi, veri iletmek için radyo frekanslarını (RF) kullanır. Bu sistemler yapılandırılmış uydu iletişimleri gibi görsel aralığın ötesinde doğrudan veya dolaylı iletişim için (SATCOM) veya havadan radyo rölesi şeklinde gerçekleşir. İletişim sistemleri, başka sistemlere entegre edilebilen birkaç unsurdan oluşur. Sistem, modemler, vericiler, yükselticiler ve antenlerden oluşur. Antenin entegrasyonu, aerodinamik etkiler ile anten arasında yeterli bir denge bulunmalıdır. İletişim sistemlerinin birbirine bağlı bileşenlerinin kapsama alanı ve yakınlık verileri dikkate alınmalıdır. Anten ve gerekli görüş alanı, entegrasyon yaklaşımını ve tasarımı etkiler. Entegrasyonu iletişim sistemi, ilk tasarım aşamalarından itibaren tasarımda önemli bir rol oynamalıdır, çünkü kritik sistemi uyarlamaya yönelik girişimlerin insansız uçaklar için tasarlanması zahmetli bir çalışmadır.

Bir İHA çalıştırmanın en önemli yönlerinden biri, büyük ölçüde harici kaynaklara dayanan güvenlidir. İHA operatörleri, iletişim sinyalleri ile İHA'yı ve faydalı yüklerini doğrudan kontrol eder. Hava aracı uçuş operatör ü(kontrolör veya yer pilotu) ve görev yükü operatörünün yer kontrol istasyonunda gerçekleştirilebileceği diğer işlevleri şunlardır: (1) görev komutan, (2) iletişim operatörü, (3) akıllı uzman ve (4) hava gözlemcisi.

İHA kayıpları, operatör hatalarına atfedilmektedir. Bir kısmı etkisiz arayüz tasarımı ile ilgilidir. Zayıf bir yer kontrol istasyonu tasarımının bazı olası eksiklikleri, YKİ'nin; (1) aşırı iş yükü yaratması, (2) kritik bilgileri etkili bir şekilde sunmaması, (3) acil durum oluşumu ve (4) YKİ içinde operatör stresi oluşturan rahatsız edici bir duruma sahiptir.

Operatörün çalışma ortamı rahat olmalıdır ve arayüz etkili olmalıdır; aksi takdirde operasyonel yorgunluk ve olası İHA kayıpları olasıdır. İnsanı ele alan bir tasarım planlandığında, ergonomik standartların dikkate alınması gerekmektedir. İnsan faktörleri mühendisliği alanı bilimsel bilgiyi kullanır bir insan-makine sisteminin tasarımını ve kullanımını belirlemede insan davranışı hakkında bilgi sağlar. Amaç, insan hatasını en aza indirerek sistem verimliliğini, performansını, konforu ve emniyeti artırmaktır. Gelişebilecek tekrarlayan hareketlerden kaynaklı zorlanmaları önlemek için uygun ergonomik tasarıma ihtiyaç bulunmaktadır [10].

YKİ içindeki operatör, ihtiyaç duyulduğunda ilgili tüm bilgilere erişebilmelidir. Yüksek hacimli verilerle rahatsız olmaması gerekir. Ayrıca, YKİ' deki sıcaklık ve nem, maksimum konfor ve etkinlik sağlamak için kontrol edilmelidir. Ek olarak, eş zamanlı faaliyetlerin sayısı normal bir insandan az veya ona eşit olmalıdır. Bu nedenle, joystick, pedal ve gösterge sayısı sınırlandırılmalıdır. Oturma ortamı ve koltuk/masa ilişkisi ergonomik esaslara göre tasarlanmalıdır. Yazılım/algorithm, arayüzün operatöre izin verecek şekilde menü odaklı olacak şekilde tasarlanmalıdır (Belki birkaç tuş ile gerekli bilgileri bulmak için). Birden fazla olduğunda her operatörün görevleri açıkça tanımlanmalıdır.

Yanlış monitör konumlandırması, boyun ve göz yorgunluğuna neden olabilir. Baskı oluşturan koltuk sırt üzerinde rahatsızlığa yol açabilir. Otururken monitör göz hizasında olmalıdır. "Görüş Konisi" kişinin göz hizasında tepeden başlayan ve 30°'lik bir açıyla açılan görme alanını tarayan en yakın yerde bulunmalıdır. Monitörler çok olduğunda uzakta, insanlar iyi görmek için öne eğilme eğilimindedir. Bu, insanlar yaşlandıkça giderek daha sık tekrarlanmaktadır. Çünkü görme neredeyse kaçınılmaz olarak zamanla azalır. Temel kural; kişi kolunu uzatabilir ve sadece parmak uçlarıyla ekrana dokunabilirse, o zaman doğru konuma ulaşılmıştır. Bilekleri ve kolları optimum pozisyonda tutmak, tekrarlayan hareket riskini azaltmak, joystick, boyunduruk ve anahtarlar otururken dirseklerle aynı seviyede olmalıdır. Herkesin standart bir boyutu yoktur, basit bir düzeltme ayarlanabilir. Düzgün oturmak %20-30 arasında olmalıdır. Alt sırttaki baskıdan koltuk 17 inç ile 19 inç arasında bel desteğine sahip olmalıdır. Vücut, sırtı koltuğa gelecek şekilde konumlandırılmalıdır. Paneli görmek için kendini öne doğru eğilmiş bulursa, hareket etmesi gerekir. Bacak konumlandırma, koltuktaki genel konuma katkıda bulunur, bu nedenle bacakların bükülü olduğundan emin olunmalı, dizlerde yaklaşık 90o açıda olmalıdır. (Şekil 1). Bu durum, sırttaki baskıyı hafifletmeye yardımcı olur. Hareket esastır ancak sirkülasyon için, bu nedenle konumlandırmada ince değişikliklere izin verilmeli ve ayakta durulmalı ya da en az birkaç adım yürünmelidir. Ayaklar yere sağlam basmalıdır. Uygun bilek hizalaması için gereken oturma pozisyonu ayakların yere ulaşmamasına neden oluyorsa, desteğin yüksekliği dizleri dik açıda tutacak şekilde ayakları desteklemek için ayaklık kullanılmalıdır.



Şekil 1: Yer Kontrol İstasyonu

YKİ içinde bir dizi monitör ve ekran bulunmaktadır. Bir monitör, bir video görüntüsü taşır. Monitörlerin altında, üzerinde kontrol çubuklarının bulunduğu kontrol güverteleri bulunur. Uçuş sırasında İHA'nın doğrudan operatör kontrolü buradan sağlanır. Görev verilerini, yazılım güncellemelerini veya İHA'ya yol noktalarını girmek için tuş takımı kontrolleri, kontrol güvertesinde bulunur. Uçağı başlatmak, uçuş öncesi test verilerini seçmek ve uçak kalkışını etkinleştirmek için kontroller sağlanır. Orada olacak kayıt ortamıyla birlikte yük durumunu ve verileri (görüntü ve/veya diğer veri türleri) gösteren ekranlar olacaktır. İHA'da ve faydalı yükün çalışmasını kontrol etmek ve göstermek için bir ekran da dahil edilebilir. Görüntü ekranı, İHA sensörlerinin tam çözünürlüğünden yararlanmak için operatörün görebileceği şekilde yeterince büyük olmalıdır. YKİ operatörleri, kontrol ettikleri İHA'da hareketli bir harita ekranında bir simge belirir ve ekranda görüntülenen faydalı yük görüntüsünü izler. Denizden yakın mesafe İHA fırlatıldığında, kontrol istasyonu denize yakın bir gemide konumlandırılır.

İHA operatörünün faaliyetinin özellikleri şu şekilde sıralanır; İnsansız hava araçlarında insan faktörünün tezahürleri her operasyonda ortaya çıkmaktadır. Örneğin, bir uçağın pilotu fiziksel olarak algılar ve işlerse bilgi kokpitte yer alır. Aynı zamanda İHA operatörü zihinsel olarak algılar ve bilgileri kontrol nesnesinden uzaktan işler şeklinde yürütür. İHA operatörlerinin faaliyeti, ağırlıklı olarak bilişsel tepki ve düşünce süreçleri ile dikkatleri yüksek olmalıdır. Beklenmedik bir durumda İHA operasyon görevlerinin yüksek başarı oranı ve görevlerin önemli süresi, artan strese ve fazla çalışmaya neden olur.

İnsansız hava aracı sistemlerinde insan faktörü eğitimi disiplinler arasıdır. Teknolojilerin ve ekipmanın güvenliği, insan faaliyetinin güvenliği önem arz etmektedir. Her hangi bir teknolojinin veya sistemin yaşam döngüsü, riskleri önleme ve olası riskleri en aza indirme yeteneği insan faktörünün olumsuz sonuçlarını azaltabilmektedir. Toplumun karmaşık sistemlerinin (ulaşım, enerji vb.) güvenliğini sağlama ihtiyacı üzerinden eğitim uzmanları insan faktörünün doğası üzerine yoğunlaşmaktadır. İnsansız sistemlerin tasarımında insan operatörünün psikofizyolojik ve bilişsel özellikleri arayüz ve bunların teknik nitelikleri ve yetenekleri dikkate alınmadan yapılan geliştirme faaliyetlerinde güvenlik sorunu yaratacaktır. . Bu nedenle günümüzde İHA'ları da içeren karmaşık sistemlerin tasarımında ve işletilmesinde, insanın bireysel yeteneklerini ve sınırlarını dikkate almak gerekir [12].

Bir İHA için YKİ tasarlanırken, YKİ tipini seçmeli, ölçüm cihazlarını, operatör sayısını seçmeli ve ardından bazı hesaplamalar ve analizler yapılmalıdır. Genel olarak, YKİ tasarımı için birincil kriterler şunlardır: (1) üretim teknolojisi, (2) sistem validasyonu, (3) görev, (4) hava durumu, (5) güvenilirlik, (6) yaşam döngüsü maliyeti, (7) İHA konfigürasyonu, (8) insan faktörleri, (9) sürdürülebilirlik, (10) dayanıklılık, (11) iletişim sistemi, (12) ağırlık ve (13) kontrol seviyesi [13].

Genel olarak tasarım süreci, net bir çizgi oluşturmak için bir ödün verme çalışmasıyla başlar. Maliyet, performans (yani doğruluk) gereklilikleri arasında devam eder ve optimizasyon ile sona erer [14]. Tasarımcı iki öge hakkında karar vermelidir. YKİ tipini ve ya istenen ekipmanı seçmelidir. Sonrasında hesaplama sürecini yürütürken, tasarım gerekliliklerinin sağlandığından emin olmak için kontrol edilmelidir. Tasarım sürecinin çok önemli bir parçası YKİ'yi hava aracına entegre etmektir. Eğer tüm ekipman/ekranlar seçilir/tedarik edilir, entegrasyon süreci devam etmelidir. Aksilik ve hatanın minimum düzeyde olduğundan emin olmak için operatörlerin konfor düzeyi ve etkinliği (ergonomik göstergeler) sırasıyla belirlenmelidir.

Çoğu YKİ tasarımının, İHA uçuş bilgilerinin yanı sıra yeterli düzeyde operasyon alanı bilgisi sağladığı bulunmuştur. Operatör reaksiyon hızı ve performansı da çok önemlidir. Tehditlerin hızlı bir şekilde tanımlanmasını sağlarken, savaş alanı durumlarının iyileştirilmiş görünürlüğü, gelişmiş grafik teknikleri kullanılarak gerçekleştirilmiştir [15].

Tehdidin büyüklüğünün erken tespiti ve tanımlanması, hızlı karar alınmasını sağlar. İnsan arayüzü, hızlı tepki ve gerekli bilgilerin geniş sunumu için dokunmatik ekran ve çoklu ekran sistemine dönüşmüştür. Bir görüntü ekranının konfigürasyonu açısından operatörün bireysel rahatlığı, özelleştirme ile gerçekleştirilmiştir [16].

Ekranın boyutu ile birlikte ekran sayısı da artma eğilimindedir. Operatörün yorgunluğunu azaltmak için ekranı yukarı ve aşağı yerleştirme eğilimi vardır. Ayrıca, savaş alanı durumunu ayrıntılı olarak ifade etmek için üç boyutlu bir taktik harita kullanır. Farklı bilgiler için sembol renklere göre sınıflandırılmıştır. Pilotların iş yükünü azaltmak için sistemi çalıştıracak ek operasyonel personel mevcuttur [17].

İnsansız sistemler için yer kontrol istasyonu geliştirmek için, tasarım aşamalarından yerleşim, bilgi bileşeni, temsil şeması ve insan operasyon yöntemleri gibi birçok faktörün dikkate alınması gerekir. Bu kadar çok faktörün çok zor olabileceğini göz önünde bulundurarak, dünyanın dört bir yanındaki büyük İHA istasyonlarından tasarım faktörlerinin derinlemesine bir araştırması yapılmaktadır [18]. Tasarım özelliklerini ve özelliklerini analiz edilmelidir. Söz konusu parametreler, ekran görüntüleme bilgileri, görüntüleme yöntemi, ekran sayısı, taktik durum bilgisi, taktik harita ekipmanının çalışması, operatör sayısı, operatörün konumu, düzeni ve operasyon ortamını içerir.

3. SONUÇ ve TARTIŞMA

İnsansız hava araçlarının birçok alanda kullanılmaya başlanmasıyla, son yıllarda insan faktörünün bu alandaki rolü hızla önem kazanmaktadır. İnsan faktörlerinin insansız hava aracı operasyonları üzerindeki etkisini bilmek, güvenlik açısından giderek daha kritik hale gelmektedir. Bu çalışmada, insansız hava araçlarında insan faktörü konularına ilişkin literatüre sistematik bir bakış sunulmaktadır. Çalışmalar, ele aldıkları konulara göre gruplara ve alt gruplara ayrılmaktadır. Bu sayede ne tür çalışmalar yapıldığı, hangi konuların incelendiği ve gelecekte ne tür çalışmalar yapılabileceğinin anlaşılması amaçlanmaktadır.

İnsansız hava sistemleri, ergonomik problemlere sahiptir, İHA operatörünün özellikleri ve İHA'nın teknik özellikleri karmaşık sistemlerdir. Operatörlerin tasarımında, çalıştırılmasında ve eğitiminde insan faktörü önemli yer almaktadır. Ayrıca ergonomiyi zorunlu bir disiplin olarak uygulamaya sokmak acil bir ihtiyaçtır. İnsan-makine etkileşiminin karmaşık süreçlerinin anlaşılmasıdır; riskleri tahmin etme yeteneği ve bu riskleri önceden göz önünde bulundurarak sistemlerin geliştirilmesi insan hatalarının azaltılmasında büyük pay sahibi olacaktır.

İnsansız hava araçlarında insan hataları faktörleri içinde İHA tasarımı ve Ergonomi başlığı içinde yer kontrol istasyonları gözden geçirilmiştir. Yapılan literatür araştırması sonunda insan faktörü açısından önemli bir yeri olan ergonomi unsuru üzerinden pilotun yer aldığı ve uzun saatler geçirdiği yer kontrol istasyonunda sistem tasarımı ve yerleşimi konusunda önerilerde bulunulmuştur.

Pilotun duruşu, koltuğu, kullandığı klavye mouse, joystick vb. tüm aparatlara erişimi uzun saatler çalışıldığı düşünüldüğünde eklem ve kol kaslarını yormayacak şekilde tasarlanmalıdır. Ekran açısı ve yüksekliği boyun sinirlerine bası yapmayacak şekilde ayarlanmalıdır. Ayakların pozisyonu ile kapalı alanda termol konfor şartları gözden geçirilmelidir. Arazi şartlarında kabin içi sıcaklık kontrollü olmalı ve oda sıcaklığı şartları sağlanmalıdır.


Çalışma, gelecekte yapılacak tasarım ve ürün geliştirme çalışmalarına ön bir gereklilik sağlaması açısından önemlidir. İnsansız hava araçlarının gelecekte çok daha sık kullanılacağı düşünüldüğünde yer kontrol istasyonlarının tasarımı ve ergonomisi üzerine çalışılması gereken konulardandır.

References

- [1] A. C. Watts, V. G. Ambrosia, and E. A. Hinkley, "Unmanned Aircraft Systems in Remote Sensing and Scientific Research: Classification and Considerations of Use," *Remote. Sens.*, 2012, doi: 10.3390/rs4061671
- [2] X. Zhang, G. Jia, and Z. Chen, "The Literature Review of Human Factors Research on Unmanned Aerial Vehicle –What Chinese Researcher Need to Do Next?," in *Cross-Cultural Design. Methods, Tools, and Users*, Cham, 2018, pp. 375–384, doi: 10.1007/978-3-319-92141-9_29.
- [3] "List of unmanned aerial vehicle applications," Wikipedia. Jun. 29, 2020, Accessed: Aug. 05, 2020. [Online]. Available: https://en.wikipedia.org/w/index.php?title=List_of_unmanned_aerial_vehicle_applications&oldid=965129299.
- [4] "UAS by the Numbers." https://www.faa.gov/uas/resources/by_the_numbers/ (accessed Aug. 05, 2020). [6] "Military Drones Market Size, Growth, Trend and Forecast to 2025 | MarketsandMarkets." <https://www.marketsandmarkets.com/Market-Reports/military-drone-market221577711.html> (accessed Aug. 05, 2020).
- [5] "Military Drones Market Size, Growth, Trend and Forecast to 2025 | MarketsandMarkets." <https://www.marketsandmarkets.com/Market-Reports/military-drone-market221577711.html> (accessed Aug. 05, 2020).
- [6] "Unmanned Aerial Vehicle Market, UAV Size, Share, system and Industry Analysis and Market Forecast to 2024 | MarketsandMarketsTM." <https://www.marketsandmarkets.com/Market-Reports/unmanned-aerial-vehicles-uavmarket-662.html> (accessed Aug. 05, 2020).
- [7] Ground control station. Benchmark Study, 2015, available at <http://dronencode.github.io/UXDesign/Research/Benchmark/GCSBenchmark.pdf>
- Hong, J., Kim, S. and Kwon, Y. (James) (2015) Analysis of Modern Design Approach for Anti-Air Radar Screen. Technical Report of Ajou University, Suwon, South Korea.
- [8] Jongsoo, I., et al. (2006) Study of Aircraft Landing Loads and Ground Handling Loads. Proceedings of The Korean Society for Aeronautical and Space Sciences, Fall Conference, 189-197.
- [9] Jang, J., et al. (2011) Development of GCS for Small UAV with Automatic Takeoff and Landing Mode. Proceedings of The Korean Society for Aeronautical and Space Sciences, Fall Conference, 1637-1641.
- [10] Backes, P.G., et al. (1995) Ground Control Station Development for the Dexterous Orbital Servicing System. Proceedings of the IEEE International Conference on Robotics and Automation, 21-27 May 1995, 1259-1264.

<http://dx.doi.org/10.1109/robot.1995.525454>

- [11] Aydemir, M.E., et al. (2013) Ground Station Design Procedures for CANSAT. The 6th International Conference on Recent Advances in Space Technologies, 909-912.
- [12] Olmos, O., et al. (2014) Tactical Displays for Combat Awareness: An Examination of Dimensionality and Frame of Reference Concepts and the Application of Cognitive Engineering. The International Journal of Aviation Psychology, 10, 247-271. http://dx.doi.org/10.1207/S15327108IJAP1003_03
- [13] Hobbs, A., & Lyall, B. (2016). Human factors guidelines for unmanned aircraft systems. Ergonomics in Design, 24, 23-28. DOI:10.1177/1064804616640632
- [14] Pedersen, H. K., Cooke, N. J., Pringle, H. L., & Connor, O. (2006). UAV human factors: Operator perspectives. In N. J. Cooke, H. L. Pringle, H. K. Pedersen, & O. Connor (Eds.), Human factors of remotely operated vehicles. San Diego, CA: Elsevier, 21–33.
- [15] Shneiderman, B., & Plaisant, C. (2005). Designing the user interface: Strategies for effective human-computer interaction. Boston, MA: Pearson.
- [16] Sanders, M. S., & McCormick, E. J. (1993). Human factors in engineering and design (7th ed.). New York, NY: McGraw-Hill
- [17] Mygal, G., Protasenko, O. (2020). Human resources are a factor in applying of man-machine systems safety. Municipal Economy of Cities 6(159), 139-146. DOI:10.33042/2522-1809-2020-6-159-139-146
- [18] Parasuraman, R., Mehta, R. (2013). Neuroergonomics: a review of applications to physical and cognitive work. Frontiers in Human Neuroscience, 7(889), 1-10. <https://doi.org/10.3389/fnhum.2013.00889>



Akciğer Kanseri Tespitinde Sınıf Aktivasyon Haritaları Kullanarak Açıklanabilir Derin Öğrenme Modeli ve Radyolog Değerlendirmesi

Savaş TUNÇER^{1*}, Oğuzhan KATAR², Tülin ÖZTÜRK³, Özal YILDIRIM⁴

¹ Yazılım Mühendisliği Bölümü, Teknoloji Fakültesi, Fırat Üniversitesi, Elazığ, Türkiye; ORCID: [0000-0003-2455-5388](https://orcid.org/0000-0003-2455-5388)

² Yazılım Mühendisliği Bölümü, Teknoloji Fakültesi, Fırat Üniversitesi, Elazığ, Türkiye; ORCID: [0000-0002-5628-3543](https://orcid.org/0000-0002-5628-3543)

³ Elazığ Fethi Sekin Şehir Hastanesi, Radyoloji Bölümü, Elazığ, Türkiye; ORCID: [0000-0001-8942-5264](https://orcid.org/0000-0001-8942-5264)

⁴ Yapay Zeka ve Veri Mühendisliği Bölümü, Mühendislik Fakültesi, Fırat Üniversitesi, Elazığ, Türkiye; ORCID: [0000-0001-5375-3012](https://orcid.org/0000-0001-5375-3012)

* Corresponding Author: savastuncer62@gmail.com

Received: 24 July 2024; Accepted: 16 October 2024

Reference/Atf: S. Tunçer, O. Katar, T. Öztürk, and Ö. Yıldırım, “Akciğer Kanseri Tespitinde Sınıf Aktivasyon Haritaları Kullanarak Açıklanabilir Derin Öğrenme Modeli ve Radyolog Değerlendirmesi”, Researcher, vol. 04, no. 02, pp. 166–175, 2024.

Özet



Akciğer kanseri dünya genelinde yaygın ve ölümcül olan kanser türlerinden biridir. Akciğer kanserinin erken tanısı, hastalığın tedavi edilebilir aşamada tespit edilmesine olanak tanır ve bu da hastanın yaşam şansını önemli ölçüde artırır. Yapay zekânın bu alanda kullanımı, bir dizi avantaj sağlayarak hastalığın daha etkili bir şekilde tespitine yardımcı olabilir. Son zamanlarda derin öğrenme yaklaşımları görüntü sınıflandırma çalışmalarında baskın bir rol almaktadır. Derin öğrenme yöntemlerinin en önemli dezavantajlarından birisi kapalı-kutu yapısı nedeniyle güvenilirlik açısından şeffaflık eksikliğidir. Bu amaçla açıklanabilir modeller önemli bir araştırma haline gelmiştir. Açıklanabilir derin öğrenme modelleri, genellikle sınıf aktivasyon haritaları (Class Activation Maps - CAM) gibi tekniklere dayanmaktadır. Bu çalışmada, akciğer kanseri tespitinde açıklanabilir bir derin öğrenme modeli oluşturulmuştur. Model içerisinde grad-CAM, score-CAM, faster score-cam gibi bazı önemli sınıf aktivasyon teknikleri ile ısı haritaları elde edilmiştir. Makale kapsamındaki deneysel çalışmalar, akciğer bilgisayarlı tomografi (BT) görüntülerini içeren ve açık erişimli bir veri seti olan IQ-OTHNCCD veri seti üzerinde yürütülmüştür. Sınıflandırma aşamasında konvolüsyonel sinir ağları (KSA) tabanlı ResNet101V2, VGG16, MobileNetV2, DenseNet201 ve EfficientNetB0 modelleri kullanılmıştır. Deneysel sonuçlara göre EfficientNetB0 modeli %98.63 ile en yüksek sınıflandırma doğruluğuna ulaşmıştır. Sınıflandırıcı modele uygulanan farklı CAM teknikleri ile ısı haritaları elde edilmiştir. Elde edilen ısı haritaları uzman radyolog tarafından değerlendirilerek sonuçlar tartışılmıştır. Şekil 1’de örnek bir model çıktısı gösterilmiştir.

Anahtar Kelimeler: Akciğer kanseri, Açıklanabilir derin öğrenme, Konvolüsyonel sinir ağları

Explainable Deep Learning Model and Radiologist Evaluation Using Class Activation Maps in Lung Cancer Detection

Abstract

Lung cancer is one of the common and widespread cancer types worldwide. Early diagnosis of lung cancer makes it possible to detect it at an individually treatable stage, which significantly increases the scope of life offered. The use of artificial intelligence in this area can help detect it more effectively, providing a number of advantages. Recently, deep learning treatments have been making their appearance and are taking a dominant role. One of the most important risks of deep learning methods is the lack of transparency in terms of reliability due to their closed-box structure. These intended explicable models have become an important research topic. Explainable deep learning models are generally based on techniques such as Class Activation Maps (CAM). An explainable deep learning model for detecting lung cancer in these patients. Heat maps were obtained with some important class activation techniques in the model, such as grad-CAM, Score-CAM, Fast Score-Cam. The individual samples in the article are run on the IQ-OTHNCCD dataset, an open-access dataset containing lung computed tomography (CT) images. In the classification phase, convolutional neural networks (CNN) based ResNet101V2, VGG16, MobileNetV2, DenseNet201 and EfficientNetB0 models were used. The highest outputs of 98.63% were found in

the EfficientNetB0 model spent experimentally. Heat maps were obtained with different CAM techniques applied to the classifier model. The resulting heat maps were evaluated by a specialist radiologist and the results were examined.

Keywords: Lung cancer, Explainable deep learning, Convolutional neural networks

1.Giriş

Dünya çapındaki kanser ölümlerinin neredeyse dörtte biri akciğer kanserinden kaynaklanmaktadır ve bu hastalık, hem erkeklerde hem de kadınlarda kanserden ölümlerin önde gelen nedenidir. Yakın tarihlere kadar bilinmeyen bir hastalıkta meydana gelen yüksek artışın nedenleri birçok araştırmanın konusu olmuştur. Başlıca nedenleri olarak, sanayinin neden olduğu gaz ve tozlardan kaynaklanan artan hava kirliliği; yolların asfaltlanması; taşıt trafiğindeki artış; Birinci Dünya Savaşı'nda gaza maruz kalma; 1918'deki grip salgını ve benzen veya benzinle çalışmak görülmüştür. Ancak akciğer kanseri, daha az otomobilin, daha az sanayinin, daha az asfalt yolun olduğu ülkelerde ve benzen veya benzine maruz kalmayan işçilerde aynı oranda arttığı görüldüğünde, araştırmalar başka etkenleri arama üzerine yoğunlaşmıştır [1]. Son zamanlarda sigara içmekten bir olasılık olarak bahsedilmektedir. Tümör metastazlarının çok çeşitli olması veya tanı anında hasta sağlığının kötü olması nedeniyle cerrahi rezeksiyonun gerçekleştirilmesi çoğu zaman imkânsızdır [2]. Akciğer kanseri taraması, radyoterapi, cerrahi teknikler ve sistemik tedavideki son gelişmeler, tanı, tedaviye karar verme ve nüks değerlendirmesinde artan karmaşıklığa yol açmıştır. Akciğer kanserinde hayatta kalmanın en önemli belirleyicisi tanı anında hastalığın evresidir, bu nedenle erken tanı için etkili bir tarama yöntemi geliştirmek, akciğer kanseri bakımında uzun vadeli bir hedef olmuştur. Son on yılda, büyük klinik çalışmaların sonuçlarına dayanarak, yüksek riskli bireylerde düşük doz bilgisayarlı tomografi (LDCT) kullanılarak akciğer kanseri tarama programları bazı klinik ortamlarda uygulanmıştır [3].

Yapay zekâ, karmaşık algoritmalar ve yazılımlar kullanarak, karmaşık verilerin analizinde, yorumlanmasında ve anlaşılmasında insan bilişini taklit etme yeteneğine sahiptir ve şu anda çeşitli sağlık hizmetlerinde başarıyla uygulanmaktadır. Akciğer kanserinin değerlendirmesinde oluşan sorunlara karşı yapay zekâ tabanlı tahmin modelleri geliştirilmektedir ve yapay zekânın gelecekte tarama, teşhis, tedavi seçimi ve kurtarma tedavisine ilişkin karar vermede rol oynayabileceği görülmektedir. Yapay zekânın görüntülerdeki bilgiyi nicelleştirme yeteneğinden ve insanlarla karşılaştırıldığında görüntülerdeki karmaşık modelleri tanıma konusundaki üstün yeteneğinden yararlanan yapay zeka, akciğer kanseri taraması ortamında elde edilen LDCT görüntülerinin yorumlanmasında klinik çalışanlarına yardımcı olma potansiyeline sahiptir. Son on yılda akciğer kanseri tespitini iyileştirmeyi amaçlayan çeşitli yapay zekâ modelleri geliştirilmiş ve bazı algoritmalar, iyi huylu akciğer nodüllerini kötü huylu akciğer nodüllerinden ayırma konusunda deneyimli radyologlarla eşit, hatta onlardan daha iyi performans göstermiştir [3]. Görüntüleme, akciğer kanseri yönetiminin tüm bileşenleri için gereklidir ve yapay zekâ uygulamalarında önemli bir rol oynama potansiyeline sahiptir. Yapay zekâ, akciğer kanseri tanısı, tedavisi ve yanıt değerlendirmesinde prognostic biomarker keşfinde kullanılarak, onu kişiselleştirilmiş tıpta önemli bir noktaya getirmiştir [4]. Bununla birlikte, keşif çalışmaları potansiyel faydayı gösterse de, yapay zekânın klinik karar vermede kullanılabilmesi için önce sıkı doğrulama ve standardizasyona ihtiyaç vardır.

Makine öğrenimi, bileşen içinde daha önce yapılan tahminlere dayalı olarak akıllı öğrenmenin gerçekleşmesini sağladığı için yapay zekâ yazılımını bir adım daha ileriye taşımaktadır. Yazılım, ilerledikçe karmaşık karar verme süreçlerini gerçekleştirir ve önceki faaliyetlerden öğrenir. Farklı Makine öğrenimi algoritmaları kullanılarak akciğer kanseri tespitine dayalı araştırmalar yapılmaktadır. Karar Ağacı, Naive Bayes ve yapay sinir ağı gibi algoritmaları karşılaştırmak için tahmine dayalı veri madenciliği algoritmalarını kullanarak akciğer kanseri hastalarında ameliyat sonrası yaşam beklentisinin tahmin edilmesiyle ilgilenilmiş, KNN, SVM, NN ve Lojistik Regresyon gibi sınıflandırıcılar uygulanarak karşılık gelen doğruluk oranları elde edilmektedir [5]. Bilgisayarlı tomografi (BT) görüntüleme, akciğer kanseri tanısı ve tespiti için kullanılan etkili bir tıbbi tarama testidir. Doktorlar elde edilen BT görüntülerini akciğer dokularını analiz etmek ve teşhis etmek için kullanır. Derin öğrenme, veri temsillerinin öğrenilmesi söz konusu olduğunda yüksek düzeyde soyutlama elde etmek için birden fazla işlem katmanından oluşan özel bir makine öğrenimi türüdür. Yaygın olarak makine öğrenimi yaklaşımının bir dalı ve bir derin öğrenme sınıfı olarak bilinen Evrişimli Sinir Ağı (CNN),

günümüzde birçok görüntü bölümlene yaklaşımının yerini almaktadır [6]. BT görüntüleri üzerinde tıbbi görüntü segmentasyonu için derin öğrenme tekniklerinin uygulanması, büyük miktarda veriyi hızlı ve doğru bir şekilde öğrenme ve işleme yetenekleri nedeniyle büyük ilgi görmektedir.

Derin öğrenme yöntemleri kullanılarak BT görüntüleri içeren datasetler üzerinde sınıflandırma ve segmentasyon işlemlerinin yapılması birçok çalışmaya konu olmuştur. Kullanılan datasetler içerisinde LIDC öne çıkan datasetlerden biridir. Amerikan Ulusal Sağlık Enstitüsü Vakfı tarafından açık kaynak olarak sunulan, The Lung Image Database Consortium (LIDC) kelimesinin kısaltmasından oluşan ve Türkçe karşılığı Akciğer Görüntü Veritabanı Konsorsiyumu adlı dataset içerisinde 2000 adet üzerinde CT görüntüsü bulunmaktadır. Yokota et al., (2014) [7] tarafından yapılan çalışmada Pulmoner nodüllerin buzlu camla opaklık tespiti (GGO) yönteminde kullanmak amacıyla yapay zekâ algoritmalarını LIDC dataset üzerinde uygulamışlardır. Yapay sinir ağı (ANN) kullanılarak oluşturulan otomatik algoritma sayesinde 82,1% TP, 6,7% FP oranı elde edilmiştir.

Mhaske et al., (2019)[8] tarafından yapılan çalışmada Bilgisayar Destekli Teşhis (CAD) sisteminin değerlendirilmesi yapılmış ve BT görüntüleri üzerinde segmentasyon, özellikle çıkarma ve sınıflandırma işlemleri CNN-LSTM adlı bir hibrit yapay sinir ağı kullanılarak yapılmıştır. Önceden işlenip bölümlere ayrılan görüntüler üzerinde CNN aracılığıyla özellik çıkarımı, LSTM modeli üzerinde tahmin ve sınıflandırma gerçekleştirilmiştir. LIDC veri tabanı üzerinden yapılan bu çalışmada 97% oranına erişen bir doğruluk tespit edilmiştir.

Otomatik akciğer kanseri tespiti ve sınıflandırması (ALCDC) sistemi BT görüntüleri üzerinde tümörlerin tespit edilmesi ve sınıflandırılması için tasarlanmış, LIDC datasetinin kullanıldığı çalışmada veriler test edilmiş ve %97,2 doğruluk, %95,6 duyarlılıkla en iyi sonuçlar elde edilmiştir [9].

LDNNET, softmax sınıflandırıcıyı birleştiren convnet'lere dayalı uyarlanabilir bir mimari olup LIDC-IDRI dataseti üzerinde kullanılmış datasetin eğitimi sonucunda doğruluk oranı 0.982072 kadar ulaşmıştır [10].

Akciğer kanserini incelemek için İşaretleyici Kontrollü Havza, Bölge Büyümesi ve İşaretleyici Kontrollü Kaplamalı Havza adlı üç görüntü segmentasyon yaklaşımı LIDC dataset üzerine Random Forest Ensemble ve RUSBoost yöntemleri uygulanarak değerlendirilmiş sonuç olarak doku eğitim veri seti için en yüksek doğruluğu sağladığı görülmüştür [11].


Derin öğrenme modellerinin kapsadıkları çok sayıda katmandan dolayı karmaşıklık düzeyleri yüksektir. Bu durum onların yorumlanmasını zorlaştırmaktadır. Herhangi bir CNN tabanlı modeli görsel açıklamalar üretmek daha şeffaf hale getirmek için yeni bir sınıf ayırıcı yerleştirme tekniği olan Gradyan ağırlıklı Sınıf Aktivasyon Haritalaması (Grad-CAM) tekniği son dönemlerde kullanılmaya başlamıştır. Grad-CAM, görüntülerdeki önemli bölgeleri vurgulamak için ağırlıklar (grad ağırlıklar) olarak degradeleri (meyil) kullanır [12] Grad-CAM görselleştirmelerin sınıflar arasında daha doğru bir şekilde ayırım yapabilmekte, bir sınıflandırıcının güvenilirliğini daha iyi ortaya çıkarabilmekte ve veri kümelerindeki yargıların belirlenmesine yardımcı olabilmekte ve görüntü sınıflandırma, görüntü altyazılama ve VQA dâhil olmak üzere çeşitli kullanıma hazır mimariler Grad-CAM 'e geniş çapta uygulanabilmektedir[13]. BT görüntüleri üzerinden COVID-19 tespitini renkli görselleştirme olarak sunmak amacıyla Grad-CAM tekniği uygulanmış ve böylece çalışma sonuçlarının yorumlanması kolaylaşmıştır[14].

Score-CAM Pertürbasyon tabanlı ve CAM tabanlı yöntemler arasındaki boşluğu dolduran ve aktivasyon haritalarının ağırlığını sezgisel olarak anlaşılır bir şekilde türeten yeni bir gradyan içermeyen görsel açıklama yöntemidir [15]. Pertürbasyon teorisi, tam olarak çözümlenemeyen bir problemin, bu probleme bağlı başka bir problem çözümünün kullanılarak matematiksel açıklamasının yapılması olarak tarif edilebilir. Score-CAM, her aktivasyon haritasının ağırlığı için *güven artışı* kullanır, eğimlere olan bağımlılığı ortadan kaldırır ve daha makul bir ağırlık temsiline sahiptir [16]. BT görüntüleri üzerinde COVID-19 tespiti için denetlenemeyen öğrenme + rasgele kırpma, denetlenemeyen öğrenme + merkez kırpma gibi teknikler Score-CAM kullanılarak yapılabilmektedir [17].

2. Materyal ve Yöntem

2.1. Veri Seti

Bu çalışmada Irak-Onkoloji Eğitim Hastanesi/Ulusal Kanser Hastalıkları Merkezi (IQ-OTH/NCCD) 'den 2019 yılından toplanan akciğer kanseri veri seti [18] kullanılmıştır. Data Set kanseri tanısı konmuş hastaların BT taramalarından oluşmaktadır. Data sette 1098 görüntü bulunmakta ve bu görüntüler benign (iyi huylu) ve malignant (kötü huylu) olmak üzere iki sınıfta toplanmaktadır. Data set eğitiminde iki ayrı sınıftaki veriler 20% test ve 80% train olarak ayrılarak model eğitimi yapılmıştır. Şekil 1'de kullanılan veri seti içerisindeki sınıflara ait bazı örnek görüntüler verilmiştir.



Şekil 1: Akciğer kanseri veri seti içerisindeki bazı örnek görüntüler

2.2. Önerilen Tespit Modeli

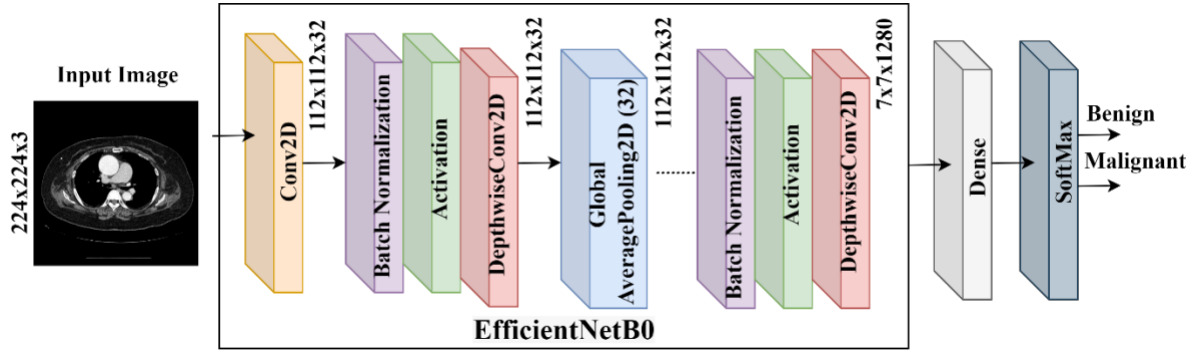
Konvolüsyonel sinir ağları (KSA) derin öğrenmeyle birlikte yapay zeka içerisinde yer alan bir kavramdır. Yapısında filtrelerle girdiden özellikleri çıkaran konvolüsyon katmanı, hesaplama performansı boyutunu azaltmak için bir havuzlama katmanı ve bir sinir ağı katmanı [19] bulunmaktadır. KSA modelleri bu tarz katmanların parametrelerin ayarlanarak birleştirilmesiyle oluşturulmaktadır. Bu çalışmada baştan bir model kurmak yerine transfer öğrenme yaklaşımı uygulanmıştır. Büyük veri kümeleri üzerinde eğitilen ResNet101V2, VGG16, MobileNetV2, DenseNet201 ve EfficientNetB0 modelleri ile deneysel çalışmalar gerçekleştirilmiştir. Model doğrulukları arasında kıyaslama yapıldığında EfficientNetB0 modeli en yüksek sınıflandırma doğruluğuna ulaşılmıştır. EfficientNet verimliliği artırmak için kullanılan bir modeldir. Kullanılan parametre sayılarının değişmesiyle B0 ve B7 arasında 8 modelden oluşmaktadır. Model oluşturulurken konvolüsyon katmanında üç argüman kullanılmıştır. İlk "weights" (ağırlıklar) parametresine "imagenet" değeri girilerek ImageNet'te ön eğitim yapılması sağlanmıştır. Havuzlama katmanında Global Average Pooling2D işlemi uygulanmıştır. Ortalama olarak pooling işlemi yapılmakta ve girdinin ortamsal çevirileri yerine ortamsal bilgiyi toplar. Bu yöntemde özellik haritalarının üstüne tam bağlı katmanların dâhil edilmesi yerine özellik katmanlarının ortalaması alınır ve oluşturulan vektör "softmax" katmanına bağlanır [20]. Bir sinir ağı öğrendikçe nöron ağırlıkları belirli özelliklere göre yararlanarak öğrenme gerçekleştirir. Komşu nöronlar da bu öğrenmelere güvenerek ezberle gidebilmektedir. Bu durum çok ilerlerse modelin aşırı öğrenmesine dönüşür ve model kırılabilir bir yapı kazanır. Bunu önlemek amacıyla "Dropout" fonksiyonu kullanılarak 20% bir olasılıkla nöronlar rasgele bir şekilde ağdan çıkarılmıştır. Böylece diğer nöronların devreye sokularak eksik nöronların yerine tahminleri yapmaları sağlanmıştır. Sinir ağı katmanında Dense önceki katmandaki tüm düğümleri mevcut katmana bağlar. Düzleştirme yoluna gider ve girişin hangi sınıfa ait olduğunu göstermektedir. Dense parametresi olarak 2 sınıfla çalışıldığı için "2" ve aktivasyon fonksiyonu olarak "softmax" girilmiştir. Modelin sınıflandırmaya uygun çıktı vermesi için "softmax" kullanılmıştır. KSA içinde olasılık kontrolü sırasında negatif değerler softmax sayesinde önlenir. "softmax" model vektörel olarak verilirken mutlak değerler üzerinden hareket eder.

Model giriş BT görüntülerinin etiketlerini benign ve malignant olarak belirlemek için sınıflandırma görevini gerçekleştirir. Modelin katman detayları ve katman parametreleri Tablo 1'de verilmiştir.

Tablo 1: Modelin katman detayları ve katman parametreleri

Katman No	Katman Tipi	Çıkış Boyutu	Eğitilebilir Parametre Sayısı
1	Conv2D	(32,256,256)	864
2	Conv2D	(16,256,256)	512
3	Conv2D	(96,256,256)	1536
4	Conv2D	(24,128,128)	2304
5	Conv2D	(144,128,128)	3456
6	Conv2D	(24,128,128)	3456
7	Conv2D	(40,64,64)	5760
8	Conv2D	(40,64,64)	9600
9	Conv2D	(80,32,32)	19200
10	Conv2D	(80,32,32)	38400
11	Conv2D	(112,32,32)	53760
12	Conv2D	(192,16,16)	129024
13	Conv2D	(320,16,16)	368640
14	Conv2D	(1280,16,16)	409600
15	Pooling2D	1280	0
16	Dense	2	2562

Önerilen modelde 14 evrişim katmanı bulunmaktadır. Şekil 2’de görüldüğü gibi her EffcientNetB0 katmanında bir evrişim katmanı ve onu takip eden BatchNormalization, Activation ve DepthwiseConv2D işlemleri ardışık biçimde bulunmaktadır. Batch_normalization işlemi yığın normalleştirilmesi yoluyla girdileri yeniden ölçeklendirip sinir ağlarının eğitimine hız ve kararlılık katmaktadır. Böylece ağ katmanları önceki katmanların öğrenmesini beklemeden eş zamanlı öğrenir.



Şekil 2: Önerilen model mimarisi (EfficientNetB0)


Model derleme sürecinde bazı parametreler kullanılarak eğitim ortamı kontrol edilmiştir. Bu parametrelerden biri olan “optimizer” , “Adam” değerini almıştır. Bu değer eğitim boyunca öğrenme oranının ayarlayan bir algoritmadır. İdeal öğrenme oranı (lr) değeri olarak Adam için çalışmada 0.0001 değeri verilmiştir. Model eğitiminde kayıp fonksiyonu olarak $loss='categorical_crossentropy'$ kullanılmış ve bu fonksiyon iki olasılık dağılımı arasındaki mesafeyi ölçmektedir. Ölçüm değeri metrik olarak accuracy (doğruluk) atanmıştır. “ModelCheckpoint” argümanı kullanılarak belli aralıklarla eğitimin model ağırlıkları kaydedilmiştir. $Verbose=1$ değeri ile anlık olarak güncellenen sonuçlar gösterilmiştir. Her yinelemede ezberi engellemek için ve eğitim verilerine daha iyi uymasını sağlamak için eğitim verisi güncellenmiştir. Bunun için de “EarlyStopping” argümanı kullanılmıştır. Çalışmada eğitim esnasından takip edilen değerlerde epochs adımları boyunca iyileşme olmadığı takdirde devreye öğrenme hızını küçülten bir katsayı olarak ReduceLROnPlateau fonksiyonu kullanılmıştır. Belirlenen katsayı $factor=0.3$ olarak girilmiştir.

2.3. Sınıf Aktivasyon Haritaları

Derin öğrenme yöntemlerinin kapalı-kutu yapısı nedeniyle güvenilirliğin düşmesinin önüne geçmek amacıyla, genellikle sınıf aktivasyon haritaları (Class Activation Maps - CAM) gibi tekniklerin kullanıldığı açıklanabilir modeller önemli bir araştırma konusu olmuştur. Çalışmada oluşturulan derin öğrenme modeli üzerinde Grad-CAM, Layer-CAM, Smoothgrad-CAM++ gibi bazı önemli sınıf aktivasyon teknikleri ile ısı haritaları elde edilmiştir. Grad-CAM Gradyan ağırlıklı CAM tekniğidir. Kaba bir yerelleştirme haritası oluşturmak için son katmandaki hedef (çalışmada tümör) gradyanları kullanarak önemli bölgelerde tahmin yürütür. En yüksek softmax olasılığına ait etiket seçilerek 2 boyutlu (2D) bir resim için gradyan hesabı 3D şeklinde sonuç verir. Bu haritalamada Global Average Pooling işlemi yapılır. CAM aksine GradCAM için yeniden eğitim gerekmez. Grad-CAM++ tekniği ikinci dereceden gradyanları kullanarak işlem yapmaktadır. XGrad-CAM tekniği aksiyom tabanlıdır. Aksiyomlar yöntem için gerekli düşünülen süreklilik, uygulamanın değişmezliği, hassasiyet ve koruma gibi değerlerdir. Grad-CAM ve türevlerinin hepsinde parametre olarak bir giriş modeli, bir hedef katman ve toplu boyutlandırma haricinde beklenen giriş tensörünün şekli bulunmaktadır. Çalışmada eğitilen model, model parametresine, modelin son katmanı olan top_conv hedef katmana eklenerek işlem yapılmıştır. Smoothgrad-CAM++ tekniğinde ise yukarıda bahsedilen parametrelere ek olarak yumuşatma için kullanılacak örnek sayısı "num_samples" parametresine çalışma için 4 değeri, gürültünün standart sapması std için çalışmada 0.3 değeri kullanılmıştır. LayerCAM kullanıma hazır herhangi bir CNN tabanlı modele uygulanabilir ve nesne lokalizasyonu ve semantik segmentasyon için fayda sağlayan farklı katmanlardan sınıf aktivasyon haritaları oluşturur.

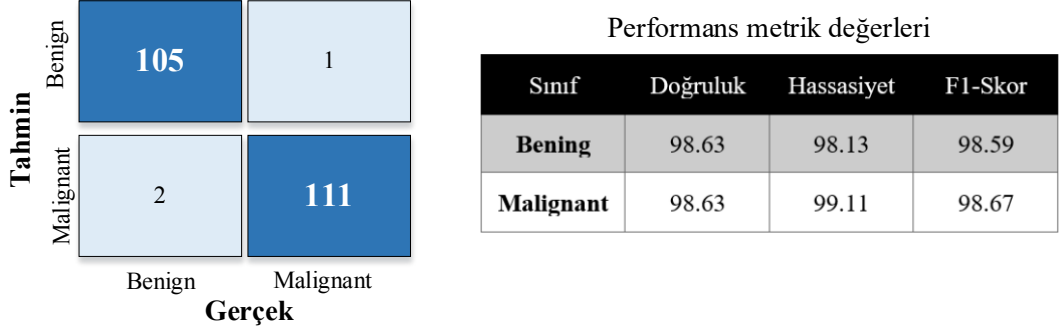
3. Deneysel Sonuçlar

Model eğitimi sonucu accuracy değeri 98.63% ve loss değeri 1.749% olarak tespit edilmiştir. Şekil 3'de görüldüğü gibi Epochs adımları ilerledikçe kayıp değerleri çok küçük kalmakta ve yüksek oranda tahmin doğruluğu sağlanmaktadır.



Şekil 3: Model eğitim ve tahmin doğruluğu, eğitim ve tahminde kayıp değişimi


Her bir görüntünün sınıfa aitliğinin bulunmasındaki doğruluğun ölçüldüğü karmaşık matrisleri Şekil 4'de görülmektedir. *Benign* sınıfı için 0, *malignant* sınıfı için 1 kullanılmıştır. Sonuçlara göre seçilen *benign* sınıfına ait 106 test verisinden 1 tanesi dışında, *malignant* sınıfına ait 113 test verisinden 2 tanesi dışında diğerlerinde doğru tahmin yapılmıştır. Doğruluk metriğinin %98.63 olarak ölçüldüğü test görüntülerde hassasiyet değerinin *malignant* sınıfı için %99.11 olarak yüksek olduğu görülmektedir.



Şekil 4: Model eğitimine ait karışıklık matrisi ve performans metrik değerleri

Görsel Sonuçlar ve Radyolog Yorumları

Test verileri üzerinde modelin odaklandığı bölgeleri tespit etmek için sınıf aktivasyon fonksiyonları kullanılmıştır. Sınıf aktivasyon fonksiyonlarından elde edilen görseller uzman radyolog tarafından yorumlanmıştır. Böylece modele açıklanabilir bir yapı kazandırılmıştır. Şekil 5’te Grad-CAM, Layer-CAM ve Smooth GRAD-CAM++ teknikleri ile elde edilen görüntüler verilmiştir.



Şekil 5: Grad-CAM, Layer-CAM ve Smooth GRAD-CAM++ teknikleri ile elde edilen görüntüler

Aktivasyon haritalarından görüleceği gibi modelin bazı görüntülerde modelin akciğer morfolojisine odaklandığı görülmektedir. Kanserli bölgedeki akciğer şekli tümörden dolayı bozulduğu için model normal olan akciğer üzerindeki odakları üzerinden karar vermiştir. Bazı görüntülerde doğrudan tümör olan akciğer bölgesine de odaklandığı görülebilmektedir.

Radyolog Yorumları:

- 1. Vakada sağ akciğer üst lobda primer akciğer kitle lezyonu, sol akciğerde birkaç adet milimetrik boyutlu metastatik (yayılım) pulmoner nodül mevcuttur. Model aktivasyon haritasında sağ akciğerdeki primer lezyona odaklanmıştır. Fakat kitlenin sol akciğere yayılımını gösteren daha küçük boyutlu metastatik lezyonlara odaklanmadığı görülmektedir.
- 2. Vakada sol akciğerde iyi huylu parankimal atelektazik bant olarak yorumladığımız iyi huylu lezyon dışında kanser bulgusu gösterecek başka bir lezyon izlenmemiştir. Fakat model herhangi bir bulgu olamayan normal akciğer dokusuna yanlış pozitif odaklanma göstermiştir. Bu görüntülerde modelin ayrıca normal kemik doku ve kalp dokusuna da odaklandığı izlenmiştir.

- 3. Vakada sol akciğer taban kesiminde büyük boyutlu bir kanser kitlesi mevcuttur. Sağ akciğer parankimi doğal izlenmiştir. Modelin normal akciğer parankimine daha fazla olmak üzere hem normal akciğer hem sol akciğerdeki kitleye odaklandığı izlenmiştir.
- 4. Vakada sağ akciğerde yaygın akciğer zarı ve bir kısım batın(karın) kesitlerini tutan kitle lezyonu izlenmiştir. Modelin tamamen başarılı şekilde doğrudan kitlelere odaklandığı izlenmiştir.

Sonuç olarak model en başarılı odaklanmayı 4. Vakada göstermiştir. Bunun nedeninin mevcut kitlenin daha büyük bir anatomik alanı tutmasından kaynaklı olduğu düşünülmektedir. Sonraki başarılı odaklanmanın 1. Vaka ve 3. odaklanma göstermiştir. Buradaki kitle lezyonu çok büyük boyutlu olmamakla birlikte model yine de lezyonu işaret etmektedir. İlk vakadaki küçük boyutlu lezyonlar işaretlenmemiştir. Model büyük boyutlu kitleleri tespit edebilmektedir. Kitle bulunan görüntülerde odaklanmanın olduğu yerin ayna hayali izdüşümü olan yerlerde hafif yanlış odaklanmalar mevcuttur. Bu yanlış görüntülerin azaltılması gerekmektedir.

Yazarların Katkısı

Bu makalenin yazılmasına tüm yazarlar eşit katkıda bulunmuştur.


Çıkar Çatışması

Yazarlar çıkar çatışması olmadığını belirtmektedir.

Referanslar

- [1] Witschi H. A short history of lung cancer. *Toxicol Sci.* 2001;64(1):4–6.
- [2] Kaya U, Yılmaz A, Dikmen Y, Beigelman-Aubry C, Dunet V, Brun AL, et al. Comparison of the automatic segmentation of multiple organs at risk in CT images of lung cancer between deep convolutional neural network-based and atlas-based techniques. *Diagn Interv Imaging* [Internet]. 2019;97(16):973–89. Available from: <https://doi.org/10.1080/0284186X.2018.1529421>
- [3] Espinoza JL, Dong LT. Artificial intelligence tools for refining lung cancer screening. *J Clin Med.* 2020;9(12):1–17.
- [4] Christie JR, Lang P, Zelko LM, Palma DA, Abdelrazek M, Mattonen SA. Artificial Intelligence in Lung Cancer: Bridging the Gap Between Computational Power and Clinical Decision-Making. *Can Assoc Radiol J.* 2021;72(1):86–97.
- [5] Radhika PR, Nair RAS, Veena G. A Comparative Study of Lung Cancer Detection using Machine Learning Algorithms. *Proc 2019 3rd IEEE Int Conf Electr Comput Commun Technol ICECCT 2019.* 2019;1–4.
- [6] Ait Skourt B, El Hassani A, Majda A. Lung CT image segmentation using deep neural networks. *Procedia Comput Sci* [Internet]. 2018;127:109–13. Available from: <https://doi.org/10.1016/j.procs.2018.01.104>
- [7]. Yokota K, Maeda S, Kim H, Tan JK, Ishikawa S, Tachibana R, et al. Automatic detection of GGO regions on CT images in LIDC dataset based on statistical features. *2014 Jt 7th Int Conf Soft Comput Intell Syst SCIS 2014 15th Int Symp Adv Intell Syst ISIS 2014.* 2014;1374–7.
- [8] Mhaske D, Rajeswari K, Tekade R. Deep learning algorithm for classification and prediction of lung cancer using CT scan images. *Proc - 2019 5th Int Conf Comput Commun Control Autom ICCUBEA 2019.* 2019;
- [9] Abdul W. An Automatic Lung Cancer Detection and Classification (ALCDC) System Using Convolutional Neural Network. *Proc - Int Conf Dev eSystems Eng DeSE.* 2020;2020-Decem:443–6.
- [10] Chen Y, Wang Y, Hu F, Feng L, Zhou T, Zheng C. Ldnnet: Towards robust classification of lung nodule and cancer using lung dense neural network. *IEEE Access.* 2021;9:50301–20.
- [11] Bharati S, Podder P, Paul PK. Lung cancer recognition and prediction according to random forest ensemble and RUSBoost algorithm using LIDC data. *Int J Hybrid Intell Syst.* 2019;15(2):91–100.
- [12] Chen L, Chen J, Hajmirsadeghi H, Mori G. Adapting grad-CAM for embedding networks. *Proc - 2020 IEEE Winter Conf Appl Comput Vision, WACV 2020.* 2020;2783–92.
- [13] Selvaraju RR, Cogswell M, Das A, Vedantam R, Parikh D, Batra D. Grad-CAM: Visual Explanations from Deep Networks via Gradient-Based Localization. *Proc IEEE Int Conf Comput Vis.* 2017;2017-Octob:618–26.
- [14] Panwar H, Gupta PK, Siddiqui MK, Morales-Menendez R, Bhardwaj P, Singh V. A deep learning and grad-CAM based color visualization approach for fast detection of COVID-19 cases using chest X-ray and CT-Scan images. *Chaos, Solitons and Fractals* [Internet]. 2020;140:110190. Available from: <https://doi.org/10.1016/j.chaos.2020.110190>
- [15] Pradhan K, Chawla P. Medical Internet of things using machine learning algorithms for lung cancer detection. *J Manag*

- Anal. 2020;7(4):591–623.
- [16] Zakriya KJ, Christmas C, Wenz JF, Franckowiak S, Anderson R, Sieber FE. Preoperative Factors Associated with Postoperative Change. 2002;1628–32.
- [17] Fan BB, Yang H. Analysis of identifying COVID-19 with deep learning model. J Phys Conf Ser. 2020;1601(5).
- [18] alyasriy hamdalla, AL-Huseiny M. The IQ-OTH/NCCD lung cancer dataset. 2023;4.
- [19] Goodfellow, I., Bengio, Y., & Courville A. Deep learning. 2016.
- [20] Gong W, Chen H, Zhang Z, Zhang M, Gao H. A Data-Driven-Based Fault Diagnosis Approach for Electrical Power DC-DC Inverter by Using Modified Convolutional Neural Network with Global Average Pooling and 2-D Feature Image. IEEE Access. 2020;8:73677–97.



Evrişimli Sinir Ağları Kullanarak Beyin Tümörü Sınıflandırması

Firuze Damla ERYILMAZ¹, Meriç ÇETİN^{1*}

¹Pamukkale Üniversitesi, Bilgisayar Mühendisliği Bölümü, Kınıklı Kampüsü, Denizli, TÜRKİYE, 0000-0002-7871-4850

* Corresponding Author: mcetin@pau.edu.tr

Received: 14 August 2024 ; Accepted: 16 October 2024

Reference/Atf: F. D. Eryılmaz Baran and M. Cetin, “Evrişimli Sinir Ağları Kullanarak Beyin Tümörü Sınıflandırması”, Researcher, vol. 04, no. 02, pp. 76–83, 2024.



Özet

Bu çalışmada, evrişimli sinir ağlarına dayalı olarak beyin MRI görüntülerinden beyin tümörünün erken teşhisini kolaylaştıran üç farklı derin öğrenme çerçevesi tasarlanmıştır. Beyin tümörü sınıflandırmasını yapabilmek için ResNet50, VGG16 ve InceptionV3 gibi literatürde çokça kullanılan mimariler tercih edilmiştir. Deneyler için hem orjinal MRI görüntüleri hem de çeşitli manipülasyon teknikleri ile oluşturulan sentetik veriler kullanılmıştır. İkili beyin tümörü sınıflandırma sürecine ek olarak, tasarlanan üç evrişimli sinir ağı modelinde iki farklı aktivasyon fonksiyonunun kullanımdaki etkisi de araştırılmıştır. Yapılan deneylere ait performans ölçütleri doğruluk, F-skor, kesinlik, hassasiyet ve hata oranı metrikleri ile sunulmuştur. Simülasyon sonuçlarında, evrişimli sinir ağının son katmanındaki aktivasyon fonksiyonunun seçimine göre sırasıyla InceptionV3 modeli için ortalama %96,75 doğruluk oranı ve ResNet50 modeli için ortalama %97,75 doğruluk oranı elde edilmiştir.

Anahtar Kelimeler: CNN, beyin tümörü, sınıflandırma, resnet50, vgg16, inceptionv3.

Abstract

In this paper, three different deep learning frameworks were designed based on convolutional neural networks that facilitate the early diagnosis of brain tumors from brain MRI images. In order to classify brain tumors, several architectures that are widely used in the literature such as ResNet50, VGG16 and InceptionV3 have been preferred. Both the original MRI images and synthetic images generated by various manipulation techniques were used for the experiments. In addition to the binary brain tumor classification process, the effect of two different activation functions on the use of the designed three-convolutional neural network model was also investigated. Performance measures of the experiments have been presented with accuracy, F-score, precision, precision and error rate metrics. In the simulation results, according to the selection of the activation function in the last layer of the convolutional neural network, an average %96.75 accuracy rate for the InceptionV3 model and an average of %97.75 accuracy rate for the ResNet50 model were obtained, respectively.

Keywords: CNN, brain tumor, classification, resnet50, vgg16, inceptionv3.

1. Giriş

Beyin hücrelerinin yenilenmesi sürecinde anormal hücrelerin büyümesi ve birikimi nedeniyle kümeleşmesi beyin tümörü olarak adlandırılmaktadır [1]. Beyin tümörü varlığında kafatası içindeki basınç nedeniyle tümörün bulunduğu yere göre hastalarda şiddetli baş ağrısı, bayılma atakları, denge ve yürüme problemleri, görme problemleri, konuşma bozuklukları, kişilik değişiklikleri gibi çeşitli belirtiler ortaya çıkmaktadır. Beyin tümörü tanısı, hastalık öyküsü, nörolojik muayene, yüksek verimli klinik görüntüleme cihazları ve patolojik incelemeler sonucu ile konulmaktadır. Teşhis için manyetik rezonans görüntüleme (MRI) ve beyin tomografisi öncelikle başvurulan yöntemlerdir [2].

Son yıllarda, makine öğrenmesi alanındaki gelişmeler sağlık alanında doktorların hastalıkları daha erken ve daha doğru bir şekilde teşhis etmesine olanak tanımıştır [3]. Evrişimli sinir ağları (CNN), özellikle tıbbi görüntülerin etiketlenmesinde, sınıflandırılmasında, segmentasyon işlemlerinde, nesne tespiti ve nesne takibinde sıklıkla tercih edilen bir makine öğrenme yöntemi olarak kullanılmaktadır. Bununla

birlikte, beyin tümörünün derecesini sınıflandırmak için destek vektör makineleri (SVM), bulanık kümeleme, lojistik regresyon, K-ortalamlar gibi denetimsiz öğrenme ve rasgele orman sınıflandırıcısı, yapay sinir ağları ve Naive Bayes gibi denetimli öğrenme teknikleri de kullanılmaktadır [1]. Bazı uygulamalarda aynı görev için hibrit evrişimli sinir ağları sınıflandırma görevini üstlenir [4].

Literatürde beyin tümörü sınıflandırması üzerine birden çok hesaplama katmanı ile verilerin temsilini sağlayan ve farklı derin öğrenme mimarilerinin kullanıldığı pek çok çalışma mevcuttur. Bu çalışmalar kısaca şu şekilde özetlenmiştir: Saxena ve ark., [5] beyin tümörü verilerini sınıflandırmak için transfer öğrenme yöntemini kullanarak ResNet50 modelinde %95 oranında bir doğruluk elde etmiştir. [6]'da, beyin tümörü verilerini sınıflandırmak için ayrık dalgacık dönüşümü kullanılarak tasarlanan model ile %93,94 oranında bir doğruluk elde edilmiştir. Çıtak ve ark., beyin tümörü üzerinde yaptıkları çalışmada [7] SVM, çok katmanlı algılayıcılar ve lojistik regresyon yöntemleri ile %93 oranında bir sınıflandırma başarımı elde etmişlerdir. Farklı bir çalışmada [8], GoogleNet temelli öğrenme transferi yapılarak beyin MRI görüntülerinin sınıflandırılması sağlanmış ve %97.1 doğruluk elde edilmiştir. [9]'da evrişimli kodlayıcı ağlara sahip çok katmanlı bir mimari beyin tümörü sınıflandırması için kullanılmıştır. Rehman ve ark., [10] önceden eğitilmiş üç farklı CNN modelini (VGG16, AlexNet ve GoogleNet) transfer öğrenme yaklaşımı ile birlikte kullanarak meningioma, glioma ve hipofiz şeklindeki 3 spesifik beyin tümörünü %98.67 doğruluk ile sınıflandırmıştır. [11]'de tümör derecelerini tahmin etmek üzere Naive Bayes ve k-en yakın komşu teknikleri kullanılarak %92.9 oranında doğruluk elde edilmiştir.

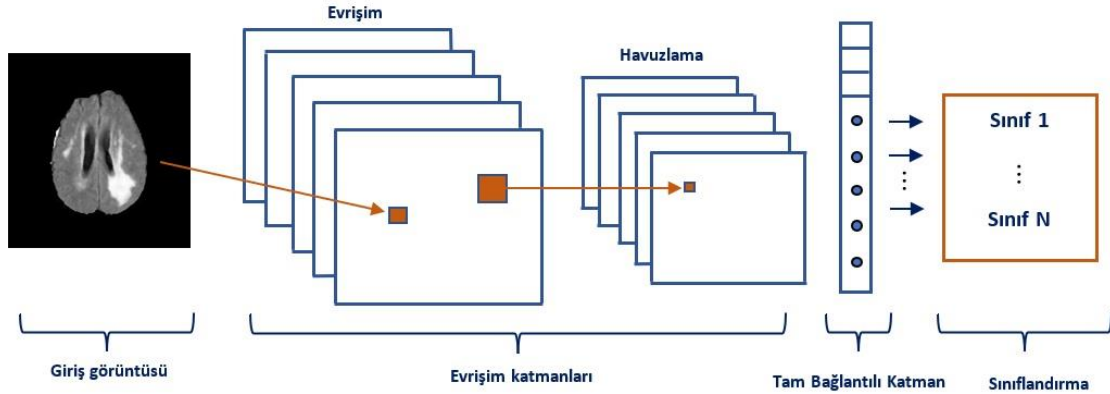
Bu çalışmada evrişimli derin sinir ağları kullanılarak beyin MRI görüntülerinden beyin tümörü sınıflandırması yapılması amaçlanmıştır. Bu amaçla, benzetim çalışmalarında ImageNet gibi çok sayıda veri kümesi üzerinde önceden eğitilmiş ResNet50 [12], VGG16 [13] ve InceptionV3 [14] olmak üzere üç CNN mimarisi beyin MRI görüntüleri veri seti üzerinde kullanılmıştır. Elde edilen sınıflandırma doğruluk değerlerine göre, evrişimli sinir ağları kullanılarak beyin tümörünün erken aşamada yakalanmasının mümkün olabileceği gösterilmiştir. Bu anlamda hem hastaya müdahalenin büyük ölçüde azalması, hem de sağlık ekiplerinin iş yükünü azaltan destekleyici süreçlerin kullanılması söz konusu olacaktır. Bu bildirinin devam eden bölümünde evrişimli sinir ağları, veri seti, ön işleme süreci ve tasarlanan modeller tanıtılmıştır. Bölüm 3'te performans ölçütleri vurgulanmış ve deneysel sonuçlar sunulmuştur. Son bölümde ise elde edilen sonuçlar değerlendirilmiştir.

2. Materyal ve Yöntem

Bu çalışmada, beyin tümörü sınıflandırma problemi için önceden eğitilmiş üç farklı evrişimli sinir ağı tercih edilmiştir. Bu bölümde öncelikle kullanılan modeller tanıtılmış, devamında veri seti ve performans ölçütleri hakkında bilgi verilmiştir.

2.1 Evrişimli Sinir Ağları

Özellikle görüntü tanıma problemlerinde kullanılan bir makine öğrenme tekniği olan evrişimli sinir ağları geleneksel yöntemlerin aksine, uzman bilgisine ihtiyaç duymaksızın veriye ait özellikleri otomatik çıkarabilme özelliğine sahiptir [15]. Derin sinir ağları eğitilebilen birçok katmandan oluşmaktadır. Çalışmada tasarlanan mimariye ait genel prensip şeması Şekil 1'de sunulmuştur.




Şekil 1: Evrişimsel Sinir Ağı Mimarisi

Böyle bir evrişimli derin sinir ağında girdi olarak verilen görüntülerin bilgisayarlar tarafından tanınması ve işlenebilecek bir formata dönüştürülmesi gerekir. Bu nedenle görüntüler önce matris formatına dönüştürülür. Tasarlanan ağ yapısı görüntülerdeki ve dolayısıyla matrislerdeki farklılıklara göre hangi görüntünün hangi etikete ait olduğunu belirler. Eğitim aşamasında bu farklılıkların etiket üzerindeki etkilerini öğrenir ve ardından bunları kullanarak yeni görüntüler için tahminler yapar. CNN, bu işlemleri etkin bir şekilde gerçekleştirmek için evrişim katmanı, havuzlama katmanı ve tam bağlantılı katman gibi farklı katmanlardan oluşur. Öznitelik çıkarma işlemi hem evrişim hem de havuzlama katmanlarında gerçekleşir. Sınıflandırma işlemi tam bağlantılı katmanda gerçekleşir. CNN mimarisinin temel katmanı olan evrişim katmanı giriş deseninin özelliklerini belirlemekten sorumludur. Bu katmanda, giriş görüntüsü 2x2, 3x3 ve 5x5 gibi filtrelerden geçirilir. Bu işlemin sonucunda görüntüdeki daha belirgin olan öznitelikler çıkarılarak yeni bir görüntü elde edilir. Bu görüntü özellik haritası olarak da bilinmektedir. Adım parametresi giriş matrisi üzerinden geçiş için ayarlanan adım sayısıdır. Bu katmandaki evrişimli işlem doğrusal bir işlemdir ve derinlik boyutu boyunca tüm filtrelerin aktivasyon haritalarının istiflenmesiyle çıktı hacmi elde edilir. Doğrusal işlem çoğunlukla, aynı girdi ile ağırlıkların çarpılmasını içerir. Evrişim katmanından sonra gelen havuzlama katmanı özellik haritalarının boyutlarını azaltmak için kullanılmaktadır. Bu durumda, evrişim katmanı tarafından oluşturulan özellik haritaları yerine özetlenen yeni veriler üzerinde işlemler gerçekleştirilir. Bu sayede, öğrenilecek parametre sayısı ve yapılan hesaplama yükü azaltılmış olur. CNN'in son ve en önemli katmanı olan tam bağlantılı katmanı, çok katmanlı bir algılayıcı gibi işlev görür. Tam bağlantılı katmanda yaygın olarak ReLU aktivasyon fonksiyonu kullanılırken, Softmax ve Sigmoid fonksiyonları son katmandaki çıktı görüntülerini tahmin etmek için tercih edilir. Tam bağlantılı katmandaki nöronlar, önceki katmandaki tüm aktivasyon fonksiyonları ile tam bağlantıya sahiptir.

Bu çalışmada, beyin tümörü ile ilgili görüntülerin ikili olarak sınıflandırılmasını sağlamak için evrişimli derin ağ mimarisindeki ResNet50, VGG16 ve InceptionV3 modelleri kullanılmıştır. Inception V3 [14] modeli, 2014 yılında GoogLeNet olarak tanıtılan Inception V1 temel modelinin üstün bir versiyonudur. Toplam 42 katmana ve önceki versiyonlarına göre daha düşük hata oranına sahiptir. VGG16 [13] modeli, 1000 sınıfa ait 14 milyondan fazla görüntüden oluşan ImageNet veri seti için %92,7 test doğruluğu sağlamıştır. Bu mimaride büyük boyutlu filtreler birden fazla 3x3 çekirdek boyutunda filtreyle değiştirilmiştir. Daha küçük boyutlu filtrelerle ağı derinliğini artırma sayesinde daha başarılı iyileştirme sonuçları elde edilmiştir. Basit bir ağ modeli olan VGG16'nin öncesindeki modellerden en önemli farkı evrişim katmanlarının ikili ya da üçlü kullanılmasıdır. Ayrıca, tam bağlantılı katmanında görüntü matrisleri bir öznitelik vektörüne dönüştürülür. Hata oranı oldukça düşük olan ResNet50 [12], havuzlama katmanı ile birlikte 48 adet evrişim katmanına sahip ResNet modelinin farklı bir çeşididir. 3.8×10^9 kayan nokta işlemine sahiptir. ImageNet veri kümesi üzerinde eğitilmiş 50 katmanlı bir mimaridir.

2.2 Veri Seti

Çalışmada, Google LLC'nin bir yan kuruluşu olan Kaggle kullanılarak, 2019'da yayınlanan "Brain MRI Images for Brain Tumor Detection" (Beyin Tümör Belirleme için Beyin MRI Görüntüleri) veri seti ile "Brain Tumor" (Beyin Tümörü) veri seti kullanılmıştır. Görüntü boyutları birbirinden farklı olduğu için tüm görüntüler 224x224 piksel boyutuna getirilmiştir. Veri içeriğini çeşitlendirmek için orijinal görüntüler üzerinde bulanıklaştırma, döndürme, büyütme, yakınlaştırma gibi manipüle yöntemleri kullanılarak sentetik veriler oluşturulmuştur. Devamında, veri setleri birleştirilmiş ve toplamda 2000 adet görüntü üzerinde işlem yapılmıştır. Sentetik ve doğal görüntülerden oluşan 2000 adet görüntünün yarısı tümürlü yarısı tümürsüz olmak üzere kategorize edilmiştir. Eğitim, doğrulama ve test aşamalarında kullanılmak üzere veri seti sırasıyla 800, 800, 400 adet görüntü içerecek şekilde rastgele bölünmüştür. Şekil 2'de veri kümesindeki görüntülere ait örnekler sunulmuştur.



Şekil 2: Sınıflandırma için Kullanılan Görüntü Örnekleri

2.3 Performans Ölçütleri

Sınıflandırma performanslarını değerlendirmek için literatürde çeşitli değerlendirme kriterleri kullanılmaktadır. Beyin tümörü sınıflandırması için tasarlanan üç farklı evrişimli sinir ağı modelinin ve bu modellerde kullanılan aktivasyon fonksiyonu değişiminin etkisini değerlendirmek üzere tercih edilen istatistiksel performans ölçütleri şu şekildedir: doğruluk, F-skor, kesinlik, hassasiyet ve hata oranıdır. Ölçüt denklemlerinde doğru tahmin edilen pozitif sonuçlar "DP", yanlış tahmin edilen pozitif sonuçlar "YP", doğru tahmin edilen negatif sonuçlar "DN", yanlış tahmin edilen negatif sonuçlar ise "YN" ile ifade edilmektedir. Doğruluk ölçütü sınıflandırıcının doğru tahmin ettiği örneklerin tüm örneklere oranı olup

$$\text{Doğruluk} = \frac{DP + DN}{DP + YP + DN + YN} \times 100, \quad (1)$$

şeklinindedir. Bu metrik negatif bir durumun tahmin edildiği ve gerçek değerinin negatif olduğu durumları gösterir. Hassasiyet kriteri doğru tanımlanmış veri yüzdesini belirtir ve

$$\text{Hassasiyet} = \frac{DP}{DP + YN} \times 100, \quad (2)$$

şeklinde ifade edilir. Kesinlik metriği pozitif tahmin değerinin yüzdesidir ve şu şekilde tanımlanır:

$$Kesinlik = \frac{DP}{DP + YP} \times 100, \quad (3)$$

Bir testin doğruluğunu ölçmek için kullanılan F-Skor değeri kesinlik ve hassasiyet arasındaki harmonik ortalamadır. F-Skor puan aralığı [0, 1]'dir.

$$F - Skor = 2 \times \frac{(Kesinlik \times Hassasiyet)}{(Kesinlik + Hassasiyet)}, \quad (4)$$


Hata oranı, gerçek değer ve elde edilen değer arasındaki farkın mutlak değeri şeklinde hesaplanmaktadır.

3. Nümerik Sonuçlar


Çalışmada, evrişimsel sinir ağları ile tümör sınıflandırması yapmak amacıyla MRI görüntülerinden oluşan iki veri seti üzerinde öncelikle ağ eğitimi tamamlanmıştır. Devamında "tümörlü" ve "tümörsüz" olmak üzere sınıflandırma sonuçlarını elde etmek üzere tahminleme yapılmıştır. İkili tümör sınıflandırma sürecine ek olarak, tasarlanan üç farklı CNN mimarisi için "sigmoid" ve "softmax" aktivasyon fonksiyonlarının kullanımdaki etkisi de araştırılmıştır. En çok kullanılan aktivasyon fonksiyonlarından biri olan sigmoid fonksiyonu karar vermeye yönelik olasılıksal bir yaklaşımdır, sürekli ve değer aralığı [0,1] arasındadır. Ağ çıktısının hangi sınıfa ait olduğuna dair olasılıksal bir değer üretir. Türev değerinin fonksiyon sınır bölgelerinde sifra yakınsaması öğrenmenin yavaşlamasına veya durmasına sebebiyet verir. Bu sebeple çok katmanlı ağlarda sigmoid fonksiyonu yerine softmax fonksiyonunun kullanımı tavsiye edilir. Çoğu zaman çoklu sigmoid olarak da bilinen softmax fonksiyonu, çok sınıflı hedef değişkeni içeren sınıflandırma problemleri için daha uygundur. Softmax fonksiyonu ağ çıktısı olarak her sınıfa ait olasılık sonucunu üretir.

Deneyisel çalışmalarda tasarlanan derin öğrenme modellerini eğitmek için Python programlama dili kullanılmıştır. Tüm deneyler, merkezi işlem birimi (CPU), Tesla K80 grafik işlem birimi (GPU) veya tensor işlem birimi (TPU) donanımı ile çevrimiçi bulut hizmeti kullanılarak Ubuntu işletim sistemine sahip Google Colaboratory (Colab) Linux sunucusunda ücretsiz olarak gerçekleştirilmiştir. Veri setleri Kaggle veri seti web sitesinden temin edilmiştir. Veri manipülasyonu için VisualStudioCode editöründe Python programlama dili ve Pillow kütüphanesi kullanılmıştır.

Model seçiminde InceptionV3, VGG16 ve ResNet50 CNN mimarileri tercih edilmiştir. Modeller ile birlikte kullanılan kütüphaneler numpy, OpenCV, os, matplotlib, Sklearn, Tensorflow ve Keras kütüphaneleridir. Tümör sınıflandırması için tasarlanan üç mimarinin son katmanındaki aktivasyon fonksiyonu seçimine göre modellerin sergiledikleri performans değerleri Tablo 1'de listelenmiştir. ResNet50, VGG16 ve InceptionV3 ile 10 evre süresince yapılan deneylerde elde edilen doğruluk ve hata oranları Şekil 3 ve Şekil 4'te sunulmuştur. Sonuçlara göre, CNN modellerinde son katmanın aktivasyon fonksiyonu sigmoid ise en yüksek ortalama doğruluk oranı %96,75 ile InceptionV3 modelinde, softmax ise en yüksek ortalama doğruluk oranı %97,75 ile ResNet50 modelinde elde edilmiştir.



Şekil 3: Üç Farklı CNN Modeline Ait Doğruluk Performansları



Şekil 4: Üç Farklı CNN Modeline Ait Hata Oranları

Tablo 1: Model Performansları

Aktivasyon Fonksiyonu: Sigmoid					
Model	Doğruluk	F-Skor	Kesinlik	Hassasiyet	Hata Oranı
VGG16	0.9175	0.9192	0.9400	0.8995	0.0825
ResNet50	0.9500	0.9473	0.9000	1.0000	0.0500
InceptionV3	0.9675	0.9673	0.9650	0.9698	0.0325
Aktivasyon Fonksiyonu: Softmax					
Model	Doğruluk	F-Skor	Kesinlik	Hassasiyet	Hata Oranı
VGG16	0.925	0.9253	0.9207	0.9300	0.0750
ResNet50	0.9775	0.9771	0.9650	0.9897	0.0225
InceptionV3	0.9025	0.8937	0.9763	0.8250	0.0975

4. Sonuç

Bu çalışmada, beyin tümörünün erken aşamada tespitini sağlamak üzere derin öğrenme tabanlı ikili sınıflandırma işlemi gerçekleştirilmiştir. Bu kapsamda, önceden eğitilen ResNet50, InceptionV3, VGG16 modelleri üzerinde çeşitli performans karşılaştırmaları yapılmıştır. Veri seti büyüklüğü ve çeşitliliğinin sınıflandırma performansını artıracak düşünülerek manipülasyon teknikleri ile sentetik veriler oluşturulmuş ve bu veriler orjinal veri setleriyle birleştirilmiştir. Elde edilen bu sonuçlar, literatürdeki örnekleri ile karşılaştırıldığında tasarlanan CNN modellerinin tümör tespitinde oldukça başarılı bir performans sergilediğini göstermektedir.

Yazarların Katkısı

Bu makalenin yazılmasına tüm yazarlar eşit katkıda bulunmuştur.

Çıkar Çatışması


Yazarlar çıkar çatışması olmadığını belirtmektedir

Referanslar

- [1] J. Amin *et al.*, "Brain tumor detection: A Long Short-term Memory (LSTM)-based Learning Model." *Neural Computing and Applications*, vol. 32, no. 20, pp. 15965-15973, 2020.
- [2] A. Saleh, R. Sukaik, S. S. Abu-Naser, "Brain Tumor Classification Using Deep Learning." *International Conference on Assistive and Rehabilitation Technologies.*, pp. 131-136, 2020.
- [3] H. A. Khan *et al.*, "Brain Tumor Classification in MRI Image Using Convolutional Neural Network." *Math. Biosci. Eng.*, 17, pp. 6203, 2020.
- [4] T. Sadad *et al.*, "Brain Tumor Detection and Multi-Classification Using Advanced Deep Learning Techniques. *Microscopy Research and Technique.*" vol. 84, no. 6, pp. 1296-1308, 2021.
- [5] P. Saxena, A. Maheshwari, S. Maheshwari, "Predictive Modeling of Brain Tumor: A Deep Learning Approach." *Innovations in Computational Intelligence and Computer Vision.* pp. 275-285, 2021.
- [6] H. Mohsen *et al.*, "Classification Using Deep Learning Neural Networks for Brain Tumors." *Future Computing and Informatics Journal*, vol. 3, no. 1, pp. 68-71, 2018.
- [7] F. Citak *et al.*, "Machine Learning in Grading of Gliomas Based on Multi-parametric Magnetic Resonance Imaging at 3t. *Computers in Biology and Medicine*, 99, pp. 154-160, 2018.
- [8] S. Deepak and P. Ameer, "Brain Tumor Classification Using Deep CNN Features via Transfer Learning." *Computers in Biology and Medicine*, 111, pp. 103345, 2019.
- [9] K. Vaidhya, S. Thirunavukkarasu, V. Alex, and G. Krishnamurthi, "Multi-modal Brain Tumor Segmentation Using Stacked Denoising Autoencoders." *BrainLes.* Springer, pp. 181-194, 2015.
- [10] A. Rehman, S. Naz, M. I. Razzak, F. Akram and M. Imran, "A Deep Learning-based Framework for Automatic Brain Tumors Classification Using Transfer Learning." *Circuits, Systems, and Signal Processing*, vol. 39, no. 2, pp. 757-775,

2020.

- [11] V. Romeo *et al.*, “ Prediction of Tumor Grade and Nodal Status in Oropharyngeal and Oral Cavity Squamous-cell Carcinoma Using a Radiomic Approach. *Anticancer Research*, vol. 40, no.1, pp. 271-280, 2020.
- [12] K. He, X. Zhang, S. Ren and J. Sun, “Deep Residual Learning for Image Recognition.” *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pp. 770-778, 2016.
- [13] K. Simonyan and A. Zisserman, “Very Deep Convolutional Networks for Large-scale Image Recognition.” *ArXiv Preprint arXiv:1409.1556*, 2014.
- [14] C. Szegedy, V. Vanhoucke, S. Ioffe, J. Shlens and Z. Wojna, “Rethinking the Inception Architecture for Computer Vision.” *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pp. 2818-2826, 2016.
- [15] H. Kutlu and E. Avcı, “A Novel Method for Classifying Liver and Brain Tumors Using Convolutional Neural Networks, Discrete Wavelet Transform and Long Short-term Memory Networks.” *Sensors*, vol. 19, no. 9, pp. 1992, 2019.



Sentiment Analysis for Udemy Reviews with Natural Language Processing and Machine Learning Methods

Sedat SÖNMEZ^{1*}, Tanju AÇI², Hidayet TAKCI³, Hakan KEKÜL⁴

¹Sivas Cumhuriyet University, Institute of Science, Department of Artificial Intelligence and Data Science, Sivas, Türkiye; ORCID: [0009-0009-6271-036X](https://orcid.org/0009-0009-6271-036X)

²Sivas Cumhuriyet University, Institute of Science, Department of Computer Engineering, Sivas, Türkiye; ORCID: [0009-0008-5822-3393](https://orcid.org/0009-0008-5822-3393)

³Sivas Cumhuriyet University, Faculty of Engineering, Department of Computer Engineering, Sivas, Türkiye; ORCID: [0000-0002-4448-4284](https://orcid.org/0000-0002-4448-4284)

⁴Sivas Cumhuriyet University, Faculty of Technology, Department of Software Engineering, Sivas, Türkiye; ORCID: [0000-0001-6269-8713](https://orcid.org/0000-0001-6269-8713)

* Corresponding Author: 20239258007@cumhuriyet.edu.tr

Received: 6 August 2024; Accepted: 16 October 2024

Reference/Atf: S. Sönmez, T. Açı, H. Takcı, and H. Kekül, "Sentiment Analysis for Udemy Reviews with Natural Language Processing and Machine Learning Methods", Researcher, vol. 04, no. 02, pp. 184–191, 2024.

Abstract



Understanding and classifying sentiment content in textual data is an important requirement for many industries. Text-based data such as social media platforms, customer feedback and product reviews are a rich source of human emotions and opinions. Extracting meaningful information from this text data and understanding the emotional content helps businesses make strategic decisions, develop products and improve their services. Machine learning methods are widely used to perform sentiment analysis on large amounts of text data. These methods are used to process text data, extract features, train models and classify emotional content. Natural language processing techniques are used to solve a range of problems such as increasing an application's user satisfaction, improving its services or optimising marketing strategies. In this study, emotional tones are determined by analysing course comments in the Udemy application. Prediction is made by classifying positive or negative comments. Udemy application comments on Google Play were used and sentiment analysis is performed using K-Nearest Neighbour (KNN) and Random Forest Classification (RFC) algorithms. As a result of the analyses, it was observed that the KNN algorithm predicted with 84% accuracy. Accuracy, F1 Score, Recall, Precision metrics were used as performance measures.

Keywords: Sentiment analysis, Udemy, RFC algorithm, KNN algorithm, machine learning

1. Introduction

Sentiment analysis is essentially a text processing task and aims to identify the emotional expression of given text. Initial studies of sentiment analysis focused on emotional polarity, which aims to classify text as positive, negative or neutral[1].

Sentiment Analysis is a scientific inference method that aims to quickly analyze and report individuals' opinions about social, political events, products, services, brands, etc. in large data sets that have emerged as the internet plays an important role in the daily lives of many segments of society at the global level [2].

Technological developments, individuals' desire to access courses at any time and place they want, as well as the freedom to choose courses with the content they want, have increased the demand for educational platforms such as Udemy, Udacity, KhanAcademy. Increasing demand makes customer satisfaction even more important. Analysing the comments about a course and making a positive or negative evaluation quickly require an effective system. When the literature was analysed, it was seen that there were very few studies on the Udemy application. Thanks to sentiment analysis, we can use someone else's recommendation.

In his study on sentiment analysis in 2020, Tuzcu first applied the Multilayer Perceptron (MLP) algorithm. Using RapidMiner software, Support Vector Machines (SVM), Logistic Regression (LR) and

Naive Bayes (NB) algorithms were applied on the dataset. The results of the analyses were compared and the classification success of the MLP algorithm was found to be 89%. The classification success of positive samples was higher than negative samples [3].

In his study in 2021, Tokcaer reviewed the literature in the field of sentiment analysis in Turkish texts and identified frequently preferred methods, open-source libraries and databases; and also discussed important issues in terms of research. The findings revealed that open-source libraries are widely used in the preprocessing stage of texts. The most frequently used libraries are Zemberek-NLP and ITU NLP Turkish Parser. Research on Turkish texts has shown that binary or ternary word groups, i.e. n-gram approaches, improve the analysis performance. However, it should be noted that punctuation marks and unrelated words remain as attributes that can contribute positively to the analysis performance. It is observed that statistical models such as Chi-Square and Information Gain are widely used in the feature selection phase [4].

In their study conducted in 2020, İlhan and Sağaltıcı performed sentiment analysis using machine learning algorithms on the classified comment data obtained from X. They performed sentiment analysis with the N-gram method and compared the performances of methods such as NB and SVM, which are frequently used in this analysis. As a result of the evaluations, it was determined that the SVM classifier had the highest performance [5].

In their study conducted in 2023, Daşğın and Âdem evaluated the positive and negative reviews of the courses using machine learning and deep learning methods on the Udemy application. They used BayesNet, J48, OneR and SVM among the classical machine learning algorithms and found the highest accuracy rate with 91.57% from the BayesNet algorithm. They also applied Random, GloVe and Word2Vec word embedding techniques to the dataset. They tried GRU and CNN-LSTM hybrid architectures from deep learning architectures and obtained the highest accuracy rate with 95.67% from the combination of GloVe word embedding technique and GRU architecture [6].

Şahinaslan et al. classified 15,082 data into positive, negative and neutral emotion classes using NB classification algorithm in their study conducted in 2022. As a result of their WEKA analysis, they found that the classification success rate was 65.56%. For the analysis, they used comment data from many world languages on the YouTube platform. Their study supports the idea that people's emotions and thoughts can be analysed by sharing their opinions, thoughts and satisfaction on social media platforms [7].

2. Recommended Method

Within supervised machine learning algorithms, there are algorithms that do not take much time and perform well, where predictions are made based on the similarities of observations to each other. The main purpose of classification is to find out which class the objects belong to by looking at their properties. In this study, KNN and RFC algorithms are used because they are simple and effective.

2.1 K-Nearest Neighbour Algorithm

KNN is one of the classification algorithms and is a simple and effective method used to solve classification problems. The algorithm performs classification operations by using the proximity of a given feature to another feature that is closest to it [8].




Figure 1: KNN algorithm

If the graph in Figure 1 is interpreted, the distances of the three points close to the unknown sample (green point) are analysed. If the closest proximity of the known red point is confirmed, it is inferred that the unknown sample is also red. It is based on the assumption that your best friend is red, so you are red too. In the KNN algorithm, the number of K nearest neighbours is taken into account instead of one nearest neighbour. Commonly used distance measures are:

Euclidean Distance: As seen in Figure 2, the distances of the points neighbouring the unknown point are calculated by using the Pythagorean theorem used in mathematics. For this, Equation 1 is used according to the x and y coordinates of the points.




Figure 2: Calculation of Euclidean distance

$$d = \sqrt{(x_2 - x_1)^2 + (y_2 - y_1)^2} \quad (1)$$

Manhattan (City-block) Distance: It is obtained by taking the absolute values of the differences of the coordinates of the sample points in the data set and summing these values. Equation 2 is used in this measurement method.

$$d(i, j) = \sum_{n=1}^m |x_{in} - x_{jn}| \quad (2)$$

Minkowski Distance: The Minkowski distance is a measurement in Euclidean space. It is created by generalising the Euclidean distance and Manhattan distance. When $p=2$, the Minkowski distance is equal to the Manhattan distance. When $p=1$, the Minkowski distance is equal to the Euclidean distance as shown in Equation 3.

$$d(i, j) = \left(\sum_{n=1}^m |x_{in} - x_{jn}|^p \right)^{1/p} \quad (3)$$

Compliance with some standards determined during the determination of the K value is beneficial for the model to give healthy results. At the same time, the maximum value of K should not be greater than the square root of the number of samples (n) in the data set.

In our study, 3, 5 and 7 values for the K parameter were tested. The most successful K value was found to be 3.

2.2 Random Forest Classification Algorithm

RFC algorithm is one of the supervised classification algorithms and can be used in regression and classification problems. This algorithm aims to increase the accuracy in the classification process by creating multiple decision trees. The RFC algorithm works in the form of multiple decision trees that work independently of each other, coming together and selecting the value with the highest score. It is possible to show this process in Figure 3. As the number of trees increases, the probability of obtaining the correct result increases. The main difference with the decision tree (DT) algorithm is that the root node is found and the division of nodes is randomised [9].

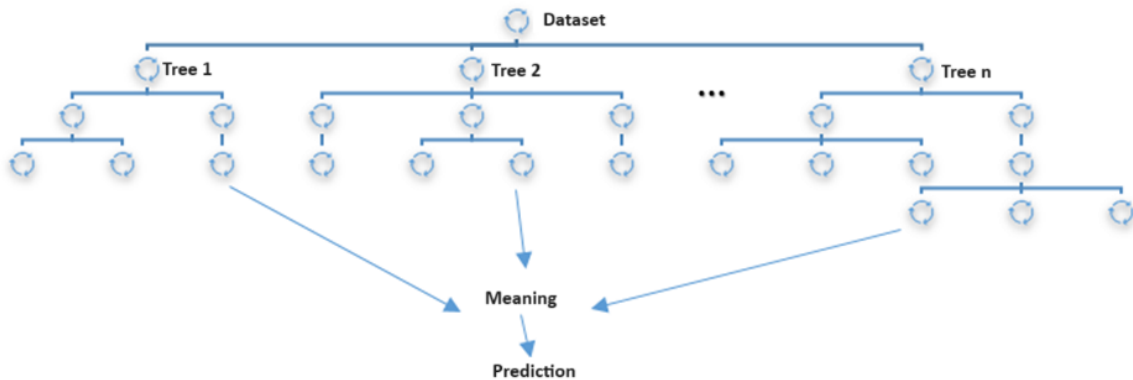


Figure 3: Finding the root node in the RFC algorithm

In our study, the value expressing the depth of decision tree generation on the algorithm was set as 2 and the results were modelled accordingly.

No feature extraction was performed on the original data set. Empty values and repetitive rows were not encountered during the data preparation phase.

3. Results and Experimental Study

In this study, an original dataset was created by extracting user comments from a training platform application, and after some preprocessing, emotion classifications were made with many classification algorithms and the results were compared. Python programming language and Spyder software were used to implement the applications.

3.1 Dataset

The original dataset was collected automatically by Web Scraping method using Python's selenium library from the application named Udemy. It contains comments of 880 users. 880 rows consist of 2 columns. A balanced dataset consisting of 400 positive and 400 negative comments was created by emotion classification on the comments taken from the dataset. An example from the dataset is given in Table 2.

Table 1: A sample from the original data set

Sn.	Comment	Score	Content
0	Don't use the app!! Use your browser. If you...	0	use app use browser use app good luck use control use
1	I wish that I could be in control of the search. The filter is disabled for ...	0	wish could control search filter disable odd...
2	The content is great for when it works, however I've only been able...	0	content great work however able watch video...
3	Has it all. Just wish there was a. option to go strictly audio...	1	wish option strictly audio applicable course...
4	Mostly good. It doesn't work in split screen mode on my table though...	0	mostly good work split screen mode table though...
5	This app has degraded itself to be designed to sell...	0	app degrade design sell course rather medium actually watch..

3.2 Text Preprocessing

For text analysis, the interpretations to be used should undergo certain pre-processing steps. In this study, the following were done as data pre-processing steps;

- ✓ Empty lines were deleted.
- ✓ All characters other than the letters between A-Z (instead of punctuation marks) were replaced with the space character.
- ✓ English words that do not make sense on their own (the, a, or, and, etc.) were separated from the data set.
- ✓ Words have been reduced to their roots.

TF-IDF method was preferred as the term weighting method. TF-IDF is obtained by multiplying the term frequency (TF) and inverse document frequency (IDF) values of the terms. In this way, the text data were digitised. As a result of the digitisation process, the data were normalised.

3.3. Classification

In this study, model applications on the original dataset with KNN and RFC algorithms were performed using Pandas, NumPy and Scikit-learn (sklearn) libraries in Python programming language. Pandas was used for data storage and processing, NumPy library for mathematical operations and Scikit-learn (sklearn) library for creating, training, testing and evaluating machine learning models. These libraries were used to cover all stages of the machine learning model starting from the data processing process.

The algorithm performed the training process by dividing the original data set into 10 parts. This approach aimed to avoid memorisation by training the data set in parts instead of the whole data set. In this way, it is aimed to achieve a more generalised learning and a better understanding of the patterns in the data set.

In the training process, the model was trained on a dataset created by scanning the 300 most frequently used words in each comment fragment. This approach prevented the inclusion of meaningless or unnecessary words in the learning process.

Accuracy, F1 Score, Recall and Precision metrics were used as performance measures. The performance evaluation metric results obtained in this direction are shown in Table 2 and Table 3.

Table 2: KNN Algorithm performance evaluation results

Metrics	K values		
	3	7	10
Accuracy Score	0.840	0.803	0.768
F1 Score	0.842	0.796	0.751
Recall Score	0.818	0.745	0.672
Precision Score	0.868	0.857	0.852

Table 3: RFC Algorithm performance evaluation results

Metrics	Accuracy Score	F1 Score	Recall Score	Precision Score
Results	0.758	0.736	0.650	0.848

The Receiver Operating Characteristic Curve (ROC curve) was also used to evaluate the performance of the learning algorithm. The ROC curve, which is a preferred evaluation tool especially in classification problems, is a graph showing the relationship between sensitivity and specificity. This graph is used to evaluate the accuracy performance of the model at different thresholds and is an important visual tool to understand the success of the classification model [10].

Sensitivity: As seen in Equation 4, it refers to the true positive rate. That is, the ratio of true positives to the total number of positive samples. Sensitivity measures how good a model is for not missing true positives.

$$Sensitivity = \frac{Number\ of\ True\ Positives}{Number\ of\ True\ Negatives + Number\ of\ False\ Positives} \quad (4)$$

Specificity: As seen in Equation 5, it refers to the true negative rate. That is, the ratio of true negatives to the total number of negative samples. Specificity measures how good a model is for not missing true negatives.

$$Specificity = \frac{Number\ of\ True\ Negatives}{Number\ of\ True\ Negatives + Number\ of\ False\ Positives} \quad (5)$$

ROC Curve: X axis represents specificity. Y axis represents sensitivity. The ROC curve shows the sensitivity and specificity performance of the model at different probability thresholds. As the curve moves from the upper left corner to the lower right corner, it shows that the performance of the model improves.

Area Under the Curve (AUC): It refers to the area under the ROC curve. The AUC value is used as a metric that measures the classification performance of the model with a single number. The closer the AUC value is to 1, the better the model performs.

The ROC curve and AUC are widely used to evaluate model performance, especially in imbalanced classification problems. A large area under the curve indicates a good classification ability of the model. The ROC curve graph of the KNN and RFC algorithms models is given in Figure 4.




Figure 4: ROC curves of KNN-RFC algorithms

According to the ROC curve metric of the KNN algorithm, the area under ROC was calculated as 0.92.

According to the RFC algorithm ROC curve metric, the area under ROC is calculated as 0.85.

4. Conclusion

In this study, sentiment analysis was performed with various machine learning techniques on an original dataset containing course reviews on Udemy. Since our dataset is original and no previous work has been done, it has not been compared with previous studies. RFC and KNN classifiers, which are commonly used classification algorithms, were used. The performance of these classifiers was compared using various model performance measures. In the study, 3, 5 and 7 values for the K parameter were tested and the most successful K value was determined as 3. According to the performance criteria analysed, the highest performance was obtained from the KNN algorithm with a rate of 84%. With piecewise training, the model gained better generalisation ability and became more successful on real world data.

Contribution of Researchers


All researchers have contributed equally to writing this paper.

Conflicts of Interest

The authors declare no conflict of interest.

References

- [1] S. E. Şeker, 'Duygu Analizi (Sentimental Analysis)', *YBS Ansiklopedi*, vol. 3, no. 3, pp. 21–36, 2016.
- [2] O. Kaynar, Y. Görmez, M. Yıldız, and A. Albayrak, 'Makine Öğrenmesi Yöntemleri ile Duygu Analizi', *Int. Artif. Intell. Data Process. Symp.*, pp. 234–241, 2016, [Online]. Available: <https://www.researchgate.net/publication/311136507>
- [3] S. Tuzcu, 'Çevrimiçi Kullanıcı Yorumlarının Duygu Analizi ile Sınıflandırılması', *Eskişehir Türk Dünyası Uygul. ve Araştırma Merk. Bilişim Derg.*, vol. 1, no. 2, pp. 1–5, 2020, Accessed: Nov. 26, 2023. [Online]. Available: <https://dergipark.org.tr/tr/pub/estudambilisim/issue/53654/676052>
- [4] S. Tokcaer, 'Türkçe Metinlerde Duygu Analizi', *J. Yaşar Univ.*, vol. 16, no. 63, pp. 1516–1536, 2021, doi: 10.19168/jyasar.928843.
- [5] N. İlhan and D. Sağaltıcı, 'Twitter'da Duygu Analizi', *Harran Üniversitesi Mühendislik Derg.*, vol. 5, no. 2, pp. 146–156, Aug. 2020, doi: 10.46578/humder.772929.
- [6] R. Daşgın and K. Adem, 'Kitleleşmiş Çevrimiçi Ders Platformlarında Kurslara Yapılan Yorumların Metin Madenciliği Kullanılarak Duygu Analizi', *Uluslararası Muhendis. Arastirma ve Gelistirme Derg.*, vol. 15, no. 2023, pp. 636–646, 2023, doi: 10.29137/umagd.1266187.
- [7] Ö. Şahinaslan, H. Dalyan, and E. Şahinaslan, 'Naive Bayes Sınıflandırıcısı Kullanılarak YouTube Verileri Üzerinden Çok Dilli Duygu Analizi', *Bilişim Teknol. Derg.*, vol. 15, no. 2, pp. 221–229, Apr. 2022, doi: 10.17671/gazibtd.999960.
- [8] D. Kılınç, E. Borandağ, F. Yücalar, V. Tunalı, M. Şimşek, and A. Özçift, 'KNN Algoritması ve R Dili ile Metin Madenciliği Kullanılarak Bilimsel Makale Tasnifi', *Marmara Fen Bilim. Derg.*, vol. 28, no. 3, 2016, doi: 10.7240/mufbed.69674.
- [9] D. Akmaç, E. Elektronik Mühendisliği, M. Fakültesi, and M. Üniversitesi, 'Stockwell Dönüşümü, ONE-R Özellik Seçme Yöntemi ve Rastgele Orman Algoritması ile Güç Kalitesi Bozulumu Sinyallerinin Sınıflandırılması', *Fırat Univ. J. Eng. Sci.*, vol. 34, no. 1, pp. 267–276, Mar. 2022, doi: 10.35234/FUMBD.1018023.
- [10] F. TAŞDEMİR, 'ROC Analizi ve R Yazılımı ile Verilerin Sınıflama Doğruluklarının Karşılaştırılması', *Ulus. Eğitim Akad. Derg.*, vol. 6, no. 2, pp. 230–241, Oct. 2022, doi: 10.32960/uead.1166987.



Analyzing the Causes of Deforestation with Statistical Quality Control Methods in Turkey

Melike ERDOĞAN^{1*}, Rabia TORMAN²

¹Duzce University, Department of Industrial Engineering, 81620, Duzce; ORCID: 0000-0003-0329-8562

²Duzce University, Department of Industrial Engineering, 81620, Duzce; ORCID: 0009-0004-4609-4556

*Corresponding Author: melikeerdogan@duzce.edu.tr

Received: 6 September 2024; Accepted: 19 December 2024

Reference/Atf: M. Erdoğan and R. Torman, “Analyzing the Causes of Deforestation with Statistical Quality Control Methods in Turkey”, Researcher, vol. 04, no. 02, pp. 192–210, 2024.

Abstract



The forests that cover the earth are the main source of everything for living things. The sustainability of forests is of great importance for ecosystems, biodiversity, erosion prevention, climate diversity, tourism, protection of global balance and water resources. Today, forests are subject to change and destruction among the resources on earth. As a result of human interventions and actions, forests are damaged unpredictably. With the combination of many reasons, the negative concept called deforestation has come to the agenda as an issue that is increasingly attracting attention today. Deforestation is a problem that should be discussed, studied and urgent solutions should be sought for Turkey. In this study, the causes of deforestation in Turkey are examined and analyzed using statistical quality control methods. In this context, the effects of agricultural activities, forest crimes, forest fires, global warming and climate change, urbanization and overpopulation on deforestation have been investigated. Whether the causes are statistically under control or not are analyzed, out-of-control points are identified with the help of control charts and suggestions are presented for the elimination of these causes. The causes of deforestation have been evaluated using MINITAB software with the help of systematic statistical quality control tools. With the effect of the study, it is aimed to develop awareness in cooperation with the authorities and society and to determine relevant actions to prevent deforestation. By identifying the reasons that cause most to deforestation, policies are revealed to eliminate the problem of deforestation in Turkey. With this paper, it is foreseen that the actions to be taken regarding deforestation in the forest area of Turkey will have an impact on the global forest area and will create an international awareness and example and will serve as a guiding study for decision-makers.

Keywords: Control Chart, Deforestation, Policy Development, Statistical Quality Control

1. Introduction

Forests are of great economic, ecological and socio-cultural importance. Today, great efforts are made to protect forests and manage their life sustainably. The United Nations Conference on Environment and Development in Rio in 1992, it was recognised that deforestation a threat to the environment in terms of both change and biodiversity and forests are a 'life-support system' for humanity was made. Forests are home to about 6,000 different species that we need at every stage of our lives being a source of raw material for wood and non-wood forest products with a place of use. In addition, today forests come to the fore in terms of biodiversity, carbon storage, oxygen, carbon storage and oxygen storage. Being a source of water, regulating surface and groundwater, having a positive impact on climate, the world's indispensable common values with social benefits such as preventing erosion among them. Almost all of Turkey's forests are under the jurisdiction of the state. The vast majority of the forests are under the control of the General Directorate of Forestry. Privately owned forest area is less than two thousandths of the total forest area (approximately 30,000 hectares) [1]. Turkey's forests are managed on the basis of forest management plans prepared on the basis of the smallest management unit, the forest management chief, with 10 - 20 year return periods. As a general evaluation, it can be said that the area, richness and annual increase of forests today are increasing compared to the past. In recent planning and implementation activities, the consideration of other product and service functions of forests other than wood production is effective in this change. In addition, the activities carried out for the protection and evolution of forests are also effective in increasing forests in terms of area, wealth

and increase. The size and changes in forest areas are based on the results of forest inventory assessments carried out to date and by years in the following [1];

- 1999: 20,763,248 hectares (26.7% of the country),
- 2004: 21,188,747 hectares (27.2% of the country),
- 2012: 21,678,134 hectares (27.7% of the country),
- 2015: 22,342,935 hectares (28.6% of the country),
- 2020: 22,933,000 hectares (29.4% of the country) .

According to this statistics, there has been an increase of approximately 2.7 million hectares in forest area in the last 47 years. Turkey today has an ecologically rich diversity with an area of 78 million hectares. Within this richness, forests have an important place in terms of species and composition [1].

With the understanding of the importance of forests in combating climate change, new concepts have entered the forestry literature such as "deforestation". Although deforestation is defined in various ways by different institutions, it means long-term conversion of forest areas to other uses [2]. Forests play a vital role in combating climate change, erosion, protecting biodiversity and increasing water availability, and are also a source of food and shelter for humans and wildlife. World the majority of threatened species live in forests and and 1.6 billion people depend on forests for food, fresh water, clothing, traditional medicine and shelter [3].

In this study, the reasons of deforestation in Turkey is aimed to analyze in detail with statistical quality control methods. The effects of agricultural activities, forest crimes, forest fires, global warming and climate change, urbanization and overpopulation on deforestation in Turkey have examined through statistical analysis. It is aimed to analyze the effects of the area used for agricultural activities and the effect of uncontrolled agriculture on deforestation in Turkey, land occupation and land opening activities within forest crimes, forest area lost as a result of forest fires, the effect of global warming and climate change on forest life, the effect of population growth as a result of urbanization and overpopulation on deforestation in Turkey by adopting control charts. In this context, in order to ensure a sustainable forest life and to eliminate the causes or effects of deforestation, the most critical causes are identified and policies are recommended to reduce or eliminate these causes. With the reasons examined, it is aimed to offer solutions to this problem, which attracts attention today and will continue to be talked about and worried about in the future. The research questions (RQ) of the paper can be presented as:

RQ1: What are the causes of deforestation in Turkey?

RQ2: Are these causes statistically under control? If there is an out of control situation When, if ever, has it happened?

RQ3: When did the detected out-of-control points occur?

RQ4: What is the most important cause of deforestation in Turkey?

RQ5: Which policies can be recommended to reduce and eliminate the occurrence of these causes?

In the light of these questions, the rest of the paper is organized as follows. Section 2 gives the literature review for the research. Section 3 includes the adopted methodology. Section 4 gives real case statistical analysis for the deforestation in Turkey. Finally, Section 4 give results and future directions.

2. Literature Review

Similar studies in the literature have been examined to understand the problem and current applications. Table 1 presents the results of the literature review with the keywords used "deforestation", "deforestation in Turkey", "statistical quality control", "statistical process control" and "Shewhart control charts" via scopus platform.

Table 1: Literature Review Details

	Author(s)	Publication Year	Aim of the Study	Adopted Methodology
1	Podur et al. [4]	2002	In Canada, Ontario and the northwest Annual fire occurrence in Ontario and in the mean and variance of the burning area detect significant changes	Statistical Quality Methods
2	Hennemuth et al. [5]	2012	Statistical methods for the analysis of simulated data and observed climate data to analyze the impact of climate change and adaptation applied in projects and institutions	General Statistical Methods
3	Gunsen and Atmis [6]	2019	Deforestation and deforestation analysis in Turkey	Correlation Analysis
4	Devecioğlu et al. [7]	2019	To examine the factors causing deforestation in Turkey and to measure public knowledge and interest in environmental problems (desertification, erosion, etc.)	Correlation Analysis, Survey
5	Rehana and Mujumdar [8]	2012	Present an integrated river water quality management modeling framework using GCM projections of modeled hydroclimatic variables	Statistical Quality Methods
6	Kuvan [9]	2011	Examination of the negative environmental impacts of tourism	Qualitative Analysis
7	Unal et al. [10]	2018	Regression analysis between forest area and urbanization	Regression Analysis
8	Akkemik et al. [11]	2012	Examining the relationship between archaeological data and deforestation	Data Analysis
9	Telkenaroglu and Dikmen [12]	2017	To examine deforestation due to urbanization in Trabzon, Turkey between 2006 and 2016	Data Analysis
10	Sabuncu [13]	2019	Mapping and monitoring of the land	Data Analysis
11	Coskun and Gencay [14]	2011	To analyze deforestation according to the Kyoto Protocol for the adequacy of Turkish environmental and forest legislation	Legal Analysis
12	Colak [15]	2009	Examination and interpretation of restored, rehabilitated, deforested and degraded forest areas in Turkey with data	Data Analysis
13	Gulser et al. [16]	2021	Effects of deforestation on soil properties and soil organic C (SOC) stock in adjacent pasture and forest areas on the same slope position	Data Analysis
14	Zambrano-Monserrate et al. [17]	2018	An empirical investigation of the relationship between deforestation and economic growth	DEF Analysis
15	Avsar [18]	1997	To examine the extent of deforestation in Kahramanmaraş-Elbistan region and the problems caused by it	Statistical Analysis

16	Malkoc and Nurlu [19]	2016	Calculating the deforestation rate and modeling the Reference and Carbon Emission Reduction Scenarios under the REDD+ Project through guiding factors	Statistical Analysis
17	Gumuscu et al. [20]	2014	To examine deforestation in the historical process	Qualitative Analysis

When the study in the researched field has been analyzed by years, most studies have been found in 2019. The scarcity of studies in the literature related to the researched topic and the applied method is also visualized in Figure 1. By checking this histogram, it can be claimed that the issue of deforestation has become popular in recent years and addressing it will benefit the whole world.




Figure 1: Literature Search Histogram

As a result of the literature review, there is no study on analyzing deforestation and its causes in Turkey with statistical quality control methods. This indicates that the adopted method will be used for the first time in the field and shows the originality of the study. It can be said that this study will be a guiding study to fill the literature gap in the related field.

The authors may claim that there is no study that investigates the causes of deforestation for a country, as in this study, and furthermore, that there is no study that addresses this with numerical approaches such as statistical quality control methods.

3. Materials and Methods

In this section, control charts which adopted in the analysis of the problem addressed in this paper is presented.

3.1 Control Charts

Control charts are the main tools used to realize process control economically and reliably with statistical methods. Armand V. Feigenbaum defines the control diagram as a graphic tool for chronologically comparing the quality specifications of the product, its constituent parts or other components according to the limits determined on the basis of past experience [21]. Control charts can be grouped into two groups, control charts for variables and control charts for attributes. Control charts for variables are Xbar - R Charts, Xbar - S Charts, I - MR Charts while control charts for attributes are p chart, np chart, u chart and c chart. The details of these control charts are given in the following sub-sections.

3.1.1 Control Charts for Variables

i. \bar{X} - R Charts

Xbar- R charts are control charts used in variables where quality characteristics can be measured and expressed numerically. Assuming that a quality characteristic fits a normal distribution with mean μ and standard deviation σ and that the process parameters (μ and σ) are known, control limits can be calculated as in the following equations (UCL: Upper control limit, CL: Center Line, LCL: Lower Control Limit) [22], [23]:

\bar{X} Chart Control Limits

$$\text{UCL: } \mu + A\sigma \quad (1)$$

$$\text{CL: } \mu \quad (2)$$

$$\text{LCL: } \mu - A\sigma \quad (3)$$

R Chart Control Limits

$$\text{UCL : } D_2\sigma \quad (4)$$

$$\text{CL: } d_2\sigma \quad (5)$$

$$\text{LCL: } D_1\sigma \quad (6)$$

If the mean μ and the standard deviation σ are not known, control limits can be calculated as in the following equations:

\bar{X} Chart Control Limits

$$\text{UCL: } \bar{\bar{X}} + A_2\bar{R} \quad (7)$$

$$\text{CL: } \bar{\bar{X}} \quad (8)$$

$$\text{LCL: } \bar{\bar{X}} - A_2\bar{R} \quad (9)$$

R Chart Control Limits

$$\text{UCL : } D_4\bar{R} \quad (10)$$

$$\text{CL: } \bar{R} \quad (11)$$

$$\text{LCL: } D_3\bar{R} \quad (12)$$

ii. \bar{X} - S Charts

If the sample volume in a production process is greater than or equal to 10, the S chart is used instead of the R Chart. Because if the sample volume is equal to or greater than 10, the efficiency and reliability of the range of variation decreases. Although the s diagram can also be used in cases where the sample volume is less than 10, the R diagram is preferred for ease of calculation [23].

\bar{X} Chart Control Limits

$$UCL: \mu + A\sigma \quad (13)$$

$$CL: \mu \quad (14)$$

$$LCL: \mu - A\sigma \quad (15)$$

S Chart Control Limits

$$UCL : B_6\sigma \quad (16)$$

$$CL: c_4\sigma \quad (17)$$

$$LCL: B_5\sigma \quad (18)$$

If the mean μ and the standard deviation σ are not known, control limits can be calculated as in the following equations:

 \bar{X} Chart Control Limits

$$UCL: \bar{\bar{X}} + A_3\bar{S} \quad (19)$$

$$CL: \bar{\bar{X}} \quad (20)$$

$$LCL: \bar{\bar{X}} - A_3\bar{S} \quad (21)$$

S Chart Control Limits

$$UCL : B_4\bar{S} \quad (22)$$

$$CL: \bar{S} \quad (23)$$

$$LCL: B_3\bar{S} \quad (24)$$

iii. I - mR Charts

To understand the state of the process, the design of the control scheme will be based on unit or individual measures and two basic measures will be controlled. On the one hand, the mean, which is a measure of central tendency and used to measure the variability of individual observations, and on the other hand, the range of variation, which is used to measure the spread between individual observations [23].

I Chart Control Limits

$$UCL: \bar{\bar{X}} + 2.66m\bar{R} \quad (25)$$

$$CL: \bar{\bar{X}} \quad (26)$$

$$LCL: \bar{\bar{X}} - 2.66m\bar{R} \quad (27)$$

mR Chart Control Limits

$$UCL : 3.268m\bar{R} \quad (28)$$

$$CL: m\bar{R} \quad (29)$$

$$LCL: 0 \quad (30)$$

3.1.2 Control Charts for Attributes

Control charts can be used for qualitative variables where the quality attribute is countable. Similarly to variables, the decision is made whether the process is under control or not. In this case, the number of defective items in a batch and the number of defects contained in a unit can be identified and analyzed [23]. Four types of attribute control charts can be identified, and divided into two groups. These are the (p) (np) group, which focuses on sample characteristics, and the (c) (u) group, which focuses on functional characteristics of products.

i. p-Control Charts

A defect rate control chart, commonly called a p-chart, is used to understand whether the ratio of non-conforming output to the total number of outputs in the population is under control. The non-conformance value can usually be expressed as a decimal or percentage number. The following steps should be followed when creating these graphs. Defect rate (p) is defined as the ratio of the number of defective products/services in a subgroup to the subgroup size. The number of observations made gives the sample (n). The average failure rate (\bar{p}) is the ratio of the sum of the errors in the subgroups to the sum of the number of observations in the subgroups[23].

$$UCL = \bar{p} + 3\sqrt{\frac{\bar{p}(1-\bar{p})}{n}} \quad (31)$$

$$CL = \bar{p} \quad (32)$$

$$LCL = \bar{p} - 3\sqrt{\frac{\bar{p}(1-\bar{p})}{n}} \quad (33)$$

ii. np- Control Charts

The np-charts apply to sampling characteristics in the same way as the plot described in the previous section. Unlike the (p) plot, (np) is related to the number of failures in a given population [23].

$$UCL = np + 3\sqrt{np(1-p)} \quad (34)$$

$$CL = np \quad (35)$$

$$LCL = np - 3\sqrt{np(1-p)} \quad (36)$$

iii. c- Control Charts

While keeping the sample size constant, the calculation of control limits requires some values, such as the calculation of the number of defects per sample. The mean number of nonconformities per sample is the total number of nonconforming units divided by the number of samples [23].

$$UCL = \bar{c} + 3\sqrt{\bar{c}} \quad (37)$$

$$CL = \bar{c} \quad (38)$$

$$LCL = \bar{c} - 3\sqrt{\bar{c}} \quad (39)$$

iv. *u*-Control Charts

The (*u*) graph is a control chart for the average number of defects per unit. It is useful for determining the number of defects in a unit. In many ways, it is very similar to the control chart (*c*) but differs in terms of sample size [23].

$$UCL = u + 3\sqrt{\frac{u}{n}} \quad (40)$$

$$CL = u \quad (41)$$

$$LCL = u - 3\sqrt{\frac{u}{n}} \quad (42)$$

4. Real Case Application

As a result of literature research, deforestation in Turkey is assessed in terms of five main causes in this paper. After analyzing the data types, I-MR control charts have been created for each cause. Individual Moving Range (I-MR) chart is a tool used to monitor and control process performance and widely used especially in continuous data collection processes. The I-MR control charts shows each measurement value followed by consecutive moving ranges of these measurement values. In this paper, for analyzing the out-of-control points, points outside the lower control limit have not been included in the interpretation of the results. Because the points below the lower limit actually show us low values for the reasons that cause deforestation, which is a desired result. It is true that sub-control points have the potential to indicate a real change in the process, but it does not always mean that these points are a definite problem with the performance of the process. Instead, these points are taken into account, considered in conjunction with other data, and treated as a signpost for a more detailed examination of the process if necessary. In order to examine the impact on deforestation, statistical analysis has been conducted for 5 causes. These causes are "Agricultural activities", "Forest fires", "Forest crimes", "Global warming and Climate change", "Urbanization and overpopulation". Data on forest fires and forest crimes are taken from official reports of the General Directorate of Forestry. Agricultural activity and total greenhouse gas emission data are taken from TurkStat reports. Population growth data are from The World Bank. In order to examine the compliance with Nelson's Rules in the control graphs plotted, this section was enabled while plotting the graphs in Minitab. Thus, the analysis has been revealed deeply. Nelson's Rules is a method in process control that determines whether some measured variable is out of control (unpredictable or consistent). Rules for detecting "out of control" or non-random conditions were first proposed by Walter A. Shewhart in the 1920s [24]. The rules are applied to a control chart where the magnitude of some variable is plotted against time. The rules are based on the mean value and standard deviation of the samples. Figure 2 shows the Nelson rules [25].




Figure 2: Nelson Rules [25]

4.1. Statistical Analysis for Agricultural Activities

The first reason examined is agricultural activities in Turkey. Data has been taken from Tuik to be examined and analyzed [26]. The graph created with the I-MR control chart by looking at 22 years of agricultural area data in Turkey is shown in Figure 3.




Figure 3: I-MR Chart of Agricultural Activities

According to the control chart in Figure 3, there is a decreasing trend in agricultural areas. In 2001, 2002, 2003, 2004, 2005 and 2006, the data has been exceeded the upper control limit. In 2011, 2016, 2017, 2018, 2019, 2020 and 2021, the points have been detected below the lower control limit. A detailed analysis of the reasons for the out-of-limit points is shown in Figure 4 Fishbone Diagram which shows the causes of the narrowing of agricultural areas.

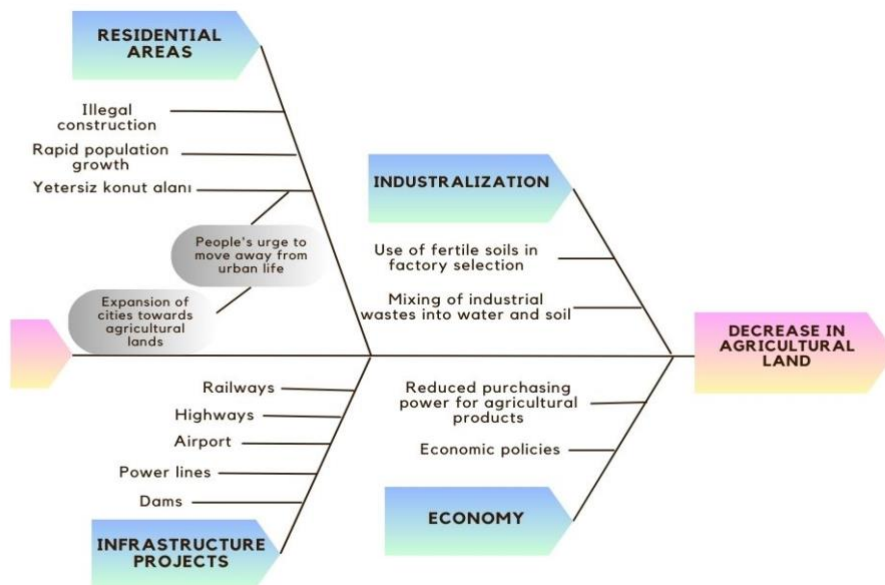


Figure 4: Fishbone Diagram for Decrease in Agricultural Areas

The reason for the declining trend of agricultural areas over the years is the use of fertile lands for factory areas under the name of industrialization and the mixing of industrial wastes into water and soil. Infrastructure projects such as railroads, highways, airports, energy lines and dam construction have caused shrinkage in agricultural areas. Housing areas surrounding agricultural lands, illegal construction, rapid population growth, and the urge of people to move away from urban life due to

insufficient housing space are the reasons why agricultural lands are used for different purposes. Economic policies and reduced purchasing power for agricultural products, farmers being affected by changes in the country's economy, explain the out-of-control points [27]. According to the MR control charts, the variation between consecutive observations shows that the process variation is high which means data for 22 years show large variations.

4.2. Statistical Analysis for Forest Fires

The second cause analyzed is forest fires in Turkey. The data has been taken from the General Directorate of Forestry to be examined and analyzed in detail [28]. The control chart created with the I-MR control graph by looking at 26 years of forest fire data in Turkey is shown in Figure 5.




Figure 5: I-MR Chart of Forest Fires

When the data for fires have been analyzed, it is seen that there has been a significant increase in forest fires in 2001, 2003 and 2007 due to negligence and carelessness. In 2013, 2016 and 2020, in addition to these reasons, the highest number of fires in 20 years has been obtained with the effect of unidentified fires. In 2013, the number of forest fires reached its highest level with 3755 fires, burning 11446 hectares of forest area. In 2013, 15% of forest fires had been caused by smoking, 3% by field clearing, 3% by shepherds' fires, 1% by picnic fires, 2% by stubble burning, 1% by hunting, 6% by other causes, 35% by unknown causes and 2% by energy transmission lines [28]. According to the MR graph, it is observed that the process variation is high by looking at the change between consecutive observations. Looking at 26 years of data, large changes were observed at some times.

When the general causes of 26 years of forest fires are analyzed, 5 main topics has been stand out. The detailed analysis of the out-of-limit points is presented in the fishbone diagram in Figure 6.

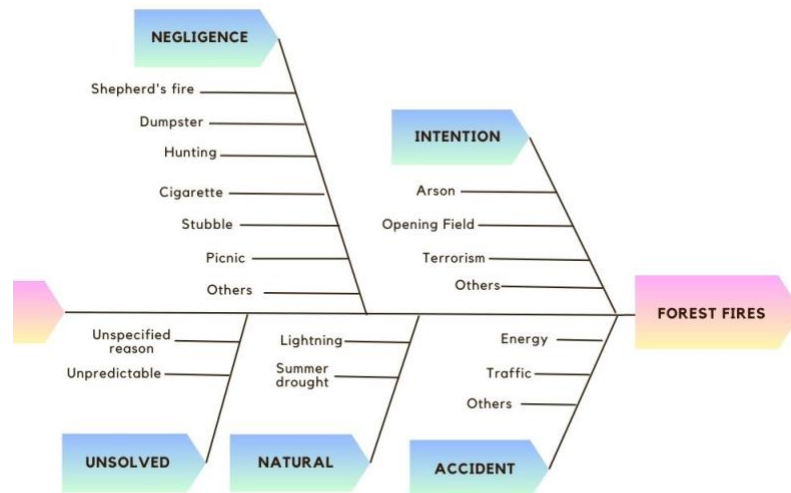


Figure 6: Fishbone Diagram for Forest Fires

As can be seen in the Fishbone Diagram, it has been determined that crimes such as deliberate arson and terrorism or such as land clearing are effective in forest fires. Apart from these crimes, fires caused by shepherd's fires, garbage dumps, hunting, cigarette butts, stubble burning and picnics were also experienced within the scope of social negligence. Traffic accidents and energy-related accidents were also observed. There are also natural causes such as unidentified unidentified fires and lightning.

4.3. Statistical Analysis for Forest Crimes

The third reason examined is forest crimes in Turkey. The data was taken from the General Directorate of Forestry to be examined and analyzed [43]. Figure 7 shows the graph drawn with the I-MR control chart by using the data of the crime of opening an area, which is included in 32 years of forest crime data in Turkey. Figure 8 shows the graph drawn with the I-MR control chart by using the data of the crime of land occupation, which is included in 23 years of forest crime data in Turkey.




Figure 7: I-MR Control Chart of Opening Field in Forestry Areas

The red dots in the graph indicate that Nelson's rule is not fulfilled at that point. According to the I chart, the data from 1992 to 2008 are out of control because nine or more consecutive points are on the same side of the mean (points in red with 2 written on them). Two or three out of three consecutive points are more than 2 standard deviations from the mean in the same direction (points shown in red and labeled 5). Four or five out of five consecutive points are more than 1 standard deviation from the mean in the same direction (points shown in red and labeled 6). Between 2014 and 2019, the points exceeded the upper control limit and went out of control. The reason for this was found to be illegally built scouting facilities. When the I chart is analyzed, the data for the years 2001-2004 show that the 2nd rule of Nelson's rules, "Nine or more points in a row are on the same side of the mean." The data for 2014 and 2019 exceeded the upper control limit.




Figure 8: I-MR Control Chart of Agricultural Land Occupation

When the control charts were investigated for Agricultural Land Occupation, the upper control limit was exceeded for the I-control chart in 2016. The reason for the out-of-control point is that according to the 2018 Regularity Audit Report of the Court of Accounts of the General Directorate of Forestry, approximately seven thousand hectares of forest area have been occupied by the Turkish Scouting Federation since 2016 by building wooden bungalows, classrooms, haystacks, guard huts, toilets, ski center and chairlift facilities in the forest area in Bolu Aladağ Başalan Plateau without permission from the forest administration. It was evaluated that the provisions of Articles 17, 79 and 93 of the Forestry Law No. 6831 were not complied with and the current situation posed a risk of public damage by not calculating the amount of public receivable arising from the unauthorized occupation and use [29]. The main reason for out-of-control point can be based on yhis occupation.

When the MR chart is analyzed, it is also seen that the upper control limit was exceeded in 2016 and 2017 when the occupation happened. Occupation of forestry land is a criminal offense. The penalty for opening, cultivating and settling fields in forest areas is included in Article 93/1 of the Forestry Law. Therefore, those who commit the prohibited acts specified in Article 17 of the Forestry Law are sentenced to imprisonment from 6 months to 2 years [30].

Despite this, forest crimes continue to be committed today. The deterrent effect of punishment decreases due to economic reasons such as livelihood concerns, insufficient land ownership and heating problems. Administrative reasons, the state of forest cadastre and social reasons such as demographic structure, migration, settlement status, and cultural structure are the reasons that push people to open and occupy areas.




Figure 9: Fishbone Diagram for Forest Crimes

4.4. Statistical Analysis for Global Warming and Climate Change

The fourth reason examined is global warming and climate change for deforestation. To analyze this cause, greenhouse gas emissions in Turkey are analyzed. The data was taken from TurkStat to be examined and analyzed. The graph drawn with the I-MR control chart by looking at 32 years of greenhouse gas data in the atmosphere in Turkey is shown in Figure 10.




Figure 10: I-MR Control Chart of Total Greenhouse Gas Emissions

When the control charts are analyzed, it can be said that greenhouse gas emissions in Turkey are not under control. According to Turkish Statistical Institute data, Turkey's greenhouse gas emissions increased by 157.1% between 1990 and 2021 [26]. In the 2020-2021 period, with an increase of 7.7

percent, Turkey's greenhouse gas emissions reached 564.4 million tons of carbon dioxide equivalent (CO₂). According to experts, the increase in 20 years shows that Turkey has not been able to separate the link between economic growth and greenhouse gas emissions. Figure 11 shows the possible reasons why the points are out of control.

Accordingly, it is said that more assertive steps should be taken towards clean production techniques, energy conversion and electrification. Fossil fuels such as Lignite, Fuel-Oil, Diesel, LPG, Naphtha, Natural Gas, excessive use of hard coal in industry and daily life, heat production and gases released after it, and of course gases released after electricity production increase greenhouse gas emissions in the long term [31].




Figure 11: Fishbone Diagram for Greenhouse Gas Emission

According to the MR chart, it is observed that the process variation is high by looking at the change between consecutive observations.

4.5. Statistical Analysis for Urbanization and Overpopulation

The other cause examined is urbanization and overpopulation in Turkey for deforestation. Data from The World Bank was used to examine and analyze of urbanization and overpopulation. Figure 12 shows the I-MR control chart plotted against 37 years of population growth data for Turkey.




Figure 12: I-MR Control Chart of Population Growth

When the graph is analyzed, it can be said that urbanization due to population growth in Turkey are not under control. Economic growth due to labor supply and labor policies are the main reasons. Domestic and international migration, increase in fertility as a result of the improvement of health care opportunities in parallel with the developing country systems, solutions against infertility, increased survival rate in newborns and children, vaccine and drug treatments, newborn early disease screening, vaccine and drug treatments, increased survival chances in newborns and children explain the increase in population growth [32]. Population growth is one of the important cause for deforestation in Turkey. Figure 13 shows the possible causes and sub-causes for the population increase.

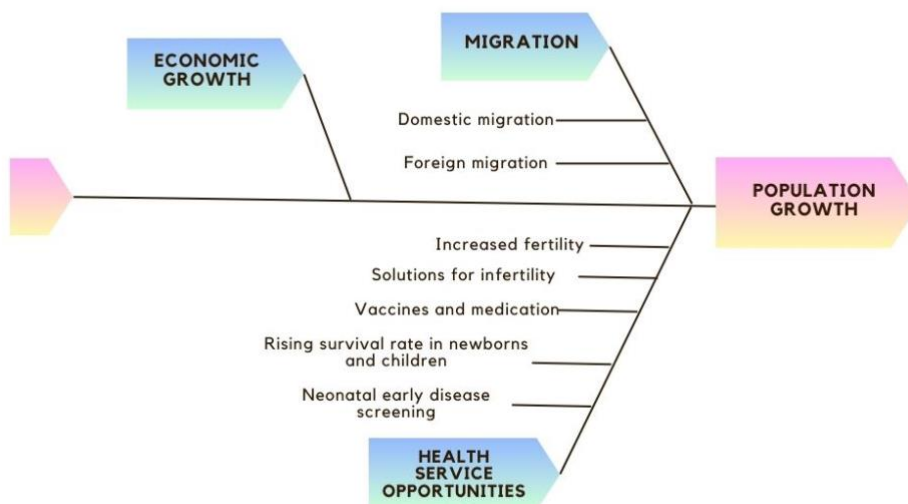


Figure 13: Fishbone Diagram for Population Growth

5. Conclusions and Future Suggestions

Deforestation, a problem that attracts attention and requires intervention today, is a major threat to forests, which contain essential resources for living things. Turkey, with its vast forest cover, is also facing this threat. In this study, the causes of deforestation in Turkey are examined and interpreted by using statistical quality control methods. After analyzing the studies in the literature, there is no research has been found that analyzed the causes of deforestation using the statistical quality control method. The data on the causes of deforestation were first determined, and organized in MS Excel application. Data on forest fires and forest crimes are taken from official reports of the General Directorate of Forestry. Agricultural activity and total greenhouse gas emission data are taken from TurkStat reports. Population growth data are from The World Bank. The data were transferred to the Minitab package program and the most appropriate control chart I-MR (Individual -Moving Range) control chart for the data was drawn. The analysis was explored in Minitab not only for out-of-control points but also for special cases called Nelson's Rules. As a result of the control charts drawn, control limits were examined, out-of-control points were identified and causes related to the deforestation were investigated. Some policies were proposed for out-of-control points and situations by conducting cause investigations.

As a result of this study, the effects of agricultural activities, forest fires, forest crimes, global warming and climate change, urbanization and overpopulation on deforestation were revealed. Global warming and climate change, urbanization and overpopulation have been found to have a major impact on deforestation. The effects of each cause on deforestation are examined in the paper in detail.

In general, many problems can be eliminated with social awareness and consciousness. Agricultural activities, forest crimes and forest fires are among the causes that can be easily addressed in the short term. It is clear that if society is educated on this issue, measures will be taken automatically. State policies should also support the elimination of the causes. However, not all of these causes are problems that can be prevented by state policies. A global awareness and action for deforestation beyond national borders has become essential.

In the long term, actions against deforestation in Turkey will have positive impacts on the international forest landscape and set an example for other countries. It can be one of the steps taken for global awareness beyond the borders of the country.

In future studies, other possible causes that may affect deforestation can be revealed and these factors can also be examined using statistical methods.

Contribution of Researchers

All researchers have contributed equally to writing this paper.

Conflicts of Interest

The authors declare no conflict of interest.

References

- [1] "OGM | Anasayfa." [Online]. Available: <https://www.ogm.gov.tr/tr>. [Accessed: 05-Sep-2024].
- [2] D. Tolunay, "Dünyada ve Türkiye'de Ormansızlaşma, Ormancılık Politikaları ve Köylülerin Durumu," 2017.
- [3] "Status of the World's Soil Resources: Main Report," 2015.
- [4] J. Podur, D. L. Martell, and K. Knight, "Statistical quality control analysis of forest fire activity in Canada," <https://doi.org/10.1139/x01-183>, vol. 32, no. 2, pp. 195–205, 2011, doi: 10.1139/X01-183.
- [5] B. Hennemuth *et al.*, "Statistical methods for the analysis of simulated and observed climate data, applied in projects and institutions dealing with climate change impact and adaptation," 2012.

- [6] H. B. Günşen and E. Atmiş, "Analysis of forest change and deforestation in Turkey," *Int. For. Rev.*, vol. 21, no. 2, pp. 182–194, May 2019, doi: 10.1505/146554819826606577.
- [7] B. Devocioğlu, A. Tolunay, and M. Özmiş, "ORMANSIZLAŞMANIN ÖNLENMESİNE YÖNELİK GÖRÜŞLERİN BELİRLENMESİ: ISPARTA İLİ ÖRNEĞİ," *Turkish J. For. Sci.*, vol. 3, no. 2, pp. 115–128, Oct. 2019, doi: 10.32328/TURKJFORSCI.571026.
- [8] S. Rehana and P. P. Mujumdar, "Climate change induced risk in water quality control problems," *J. Hydrol.*, vol. 444–445, pp. 63–77, Jun. 2012, doi: 10.1016/J.JHYDROL.2012.03.042.
- [9] Y. Kuvan, "Mass Tourism Development and Deforestation in Turkey," *Anatolia*, vol. 21, no. 1, pp. 155–168, 2010, doi: 10.1080/13032917.2010.9687096.
- [10] H. E. Ünal, Ü. Birben, and F. Bolat, "Rural population mobility, deforestation, and urbanization: case of Turkey," *Environ. Monit. Assess.*, vol. 191, no. 1, pp. 1–12, Jan. 2019, doi: 10.1007/S10661-018-7149-6/TABLES/9.
- [11] Ü. Akkemik et al., "The archaeology of deforestation in south coastal Turkey," *Int. J. Sustain. Dev. World Ecol.*, vol. 19, no. 5, pp. 395–405, Oct. 2012, doi: 10.1080/13504509.2012.684363.
- [12] C. Telkenaroglu and M. Dikmen, "DEFORESTATION DUE to URBANIZATION: A CASE STUDY for TRABZON, TURKEY," *ISPRS Ann. Photogramm. Remote Sens. Spat. Inf. Sci.*, vol. 4, no. 4W4, pp. 379–382, Nov. 2017, doi: 10.5194/ISPRS-ANNALS-IV-4-W4-379-2017.
- [13] A. Sabuncu, "Monitoring Deforestation by Multitemporal Data Using Remote Sensing Technologies: A Case Study of Sinop-Turkey," *Fresenius Environ. Bull.*, 2020.
- [14] A. Aydin Coşkun and G. Gençay, "Kyoto Protocol and 'deforestation': A legal analysis on Turkish environment and forest legislation," *For. Policy Econ.*, vol. 13, no. 5, pp. 366–377, Jun. 2011, doi: 10.1016/J.FORPOL.2011.03.013.
- [15] A. Colak, S. Kırcı, I. Rotherham, and A. Ince, "Restoration and Rehabilitation of Deforested and Degraded Forest Landscapes in Turkey.," p. 566, 2010.
- [16] C. Gülser, İ. Ekberli, and F. Gülser, "Effects of deforestation on soil properties and organic carbon stock of a hillslope position land in Black Sea Region of Turkey," *Eurasian J. Soil Sci.*, vol. 10, no. 4, pp. 278–284, Oct. 2021, doi: 10.18393/EJSS.942488.
- [17] M. A. Zambrano-Monserrate, C. Carvajal-Lara, R. Urgilés-Sanchez, and M. A. Ruano, "Deforestation as an indicator of environmental degradation: Analysis of five European countries," *Ecol. Indic.*, vol. 90, pp. 1–8, Jul. 2018, doi: 10.1016/J.ECOLIND.2018.02.049.
- [18] M. D. Avşar, "K.Maraş-Elbistan Yöresinde Ormansızlaşma, Getirdiği Problemler ve Çözüm Önerileri," *KSÜ Fen ve Mühendislik Derg.*, Jan. 1997.
- [19] E. Malkoç and E. Nurlu, "ORMAN PEYZAJINDA REDD EĞİLİM MODELLEMESİ: BOZDAĞ ÖRNEĞİ," in *6. UZAKTAN ALGILAMA-CBS SEMPOZYUMU*, 2016.
- [20] O. Gümüşçü, A. Uğur, and T. Aygören, "Deforestation in Sixteenth Century Anatolia: The Case of Hüdavendigâr (Bursa) Sancak," *BELLE TEN*, vol. 78, no. 281, pp. 167–200, Apr. 2014, doi: 10.37879/BELLE TEN.2014.167.
- [21] A. V. Feigenbaum, *Total Quality Control*. New York: McGraw-Hill, 1991.
- [22] Z. B. A. Aydın and V. S. A. Kargı, "İSTATİSTİKSEL KALİTE KONTROL TEKNİKLERİ İLE OTOMOTİV SEKTÖRÜNDE BİR UYGULAMA," *Yönetim ve Ekon. Araştırmaları Derg.*, vol. 16, no. 1, pp. 41–63, Mar. 2018, doi: 10.11611/YEAD.332129.
- [23] D. C. Montgomery, "Statistical quality control: a modern introduction," *Stat. Qual. Control*, p. 380, 2013.
- [24] W. A. Shewhart, "Quality Control Charts," *Bell Syst. Tech. J.*, vol. 5, no. 4, pp. 593–603, Oct. 1926, doi: 10.1002/j.1538-7305.1926.tb00125.x.
- [25] L. S. Nelson, "SHEWHART CONTROL CHART - TESTS FOR SPECIAL CAUSES.," *J. Qual. Technol.*, vol. 16, no. 4, pp. 237–239, 1984, doi: 10.1080/00224065.1984.11978921/ASSET//CMS/ASSET/ADFFBA2F-2BD3-4F76-843D-DE0E4E9F451E/00224065.1984.11978921.FP.PNG.
- [26] "Turkish Statistical Institute," 2014. [Online]. Available: <http://www.tuik.gov.tr/Start.do>. [Accessed: 14-Dec-2018].
- [27] Z. KARAKAYACI, "Tarım Arazilerinin Dışı Kullanımının Sürdürülebilir Kalkınma Açısından Değerlendirilmesi," *Ziraat Mühendisliği*, no. 355, pp. 48–53, Jul. 2010.
- [28] F. Erdemli, "2023 Yılı Orman Yangınları," 2023.
- [29] "Sayıştay Denetim Raporu," 2022.
- [30] N. Kahyaoğlu, E. Güvendi, and M. H. Ertuğrul, "Türkiye'deki Orman Suçlarının Değerlendirilmesi," *Bayburt Üniversitesi Fen Bilim. Derg.*, vol. 5, no. 1, pp. 115–123, Jun. 2022, doi: 10.55117/BUFBFD.1025434.
- [31] "İklim krizi: Türkiye'nin sera gazı salımları neden artıyor, tehlikeli F-gazları niçin kullanılıyor? - BBC News Türkçe."

[Online]. Available: <https://www.bbc.com/turkce/articles/cjkyzkvxxvg1o>. [Accessed: 05-Sep-2024].

- [32] R. Kasarcı, "Türkiye'de Nüfus Gelişimi," *Türkiye Coğrafyası Araştırma ve Uygul. Merk. Derg.*, 1993.