

Trafik Kaza Süresinin Tahmini İçin Topluluk Ağacı ve Sinir Ağları Performansının Karşılaştırılması

A Comparison of the Performance of Ensemble Tree and Neural Networks for The Prediction of Traffic Accident Duration

Hüseyin Korkmaz¹ , Mehmet Ali Ertürk² , Mehmet Adak³ 

¹(Res. Assist.), İstanbul University, Faculty of Transportation and Logistics, İstanbul, Türkiye

²(Assist. Prof), İstanbul University, Faculty of Computer and Information Technologies, İstanbul, Türkiye

³(Prof. Dr.), İstanbul University, Faculty of Transportation and Logistics, İstanbul, Türkiye

ÖZ

Trafik kaza süresi, bir kazanın meydana gelmesi ile kaza yerinin başlangıç durumuna dönmesi arasındaki zaman farkı olarak ifade edilmektedir. Bu araştırmanın birincil amacı İstanbul'daki trafik kaza verilerine dayalı olarak trafik kaza süresini Topluluk Ağacı ve Sinir Ağları yöntemleri ile tahmin etmek ve bu yöntemlerin performanslarını karşılaştırmaktır. Araştırmanın ikincil amacı ise trafik kaza süresini etkileyen temel faktörleri belirlemektir. Bu çalışmada İstanbul Büyükşehir Belediyesi ve Emniyet Genel Müdürlüğü kurumlarından elde edilen İstanbul'a ait kaza bilgisi veri setleri kullanılmıştır. Veri seti, 2013-2021 yılları arasındaki İstanbul'da gerçekleşen 1.905 trafik kaza kaydını içermektedir. Veriler, veri madenciliği kapsamında incelenmiştir. Ayıklanan veri setine istatistik testleri ve makine öğrenmesi algoritmalarından Topluluk Ağacı ve Sinir Ağları uygulanarak trafik kaza süresi tahmini gerçekleştirilmiştir. Bu çalışmada uygulanan algoritmaların performans ölçümleri için R^2 , MSE, RMSE ve MAE metrikleri kullanılmıştır. Topluluk Ağacı algoritmasının eğitimde R-Kare: 0.85 ile başarılı bir performans elde ettiği, testte ise R-Kare: 0.91 ile Sinir Ağları algoritmasının daha iyi performans gösterdiği sonucuna ulaşılmıştır.

ABSTRACT

Traffic accident duration is defined as the time difference between the occurrence and the return of the accident scene's initial state. The aim of this paper is to predict the traffic accident duration based on traffic accident data in İstanbul with Ensemble Tree and Neural Networks methods and to compare the performance of these methods. The secondary aim of the paper is to identify the main factors affecting the accident duration. The accident data sets obtained from İstanbul Metropolitan Municipality and General Directorate of Security are used in this paper. The dataset includes 1.905 traffic accident records in İstanbul from 2013 to 2021. The data were analyzed within the scope of data mining. Statistical tests and machine learning algorithms were applied to the extracted data set and prediction of traffic accident duration was performed. R^2 , MSE, RMSE and MAE metrics were used for the performance measures of the algorithms applied in this paper. It was found that the Ensemble Tree algorithm achieved an R-Square of 0.85 in training, while the Neural Networks algorithm performed better with 0.91 in testing.

Anahtar Kelimeler: Kaza Süresi, Akıllı Ulaşım Sistemleri, Makine Öğrenmesi, Sinir Ağları, Topluluk Ağacı

Keywords: Accident Duration, Intelligent Transportation Systems, Machine Learning, Neural Networks, Ensemble Tree

EXTENDED ABSTRACT

This paper aims to predict the traffic accident duration based on traffic accident data in İstanbul with Ensemble Tree and Neural Networks methods and to compare the performance of these methods. The secondary aim of the paper is to identify the main factors affecting the accident duration. Traffic accident duration is defined as the time difference between the occurrence and the return of the accident scene's initial state. When a traffic incident or accident occurs, the uncertainty of the duration causes concern for drivers, passengers, and traffic operators. Therefore, the duration between the occurrence of a traffic accident and its clearance is a topic worthy of research.

Firstly, a literature review was conducted in this paper. The literature review focuses on recent and up-to-date academic studies published from 2010 until the end of 2022. This literature review has gathered research papers from well-established databases that offer valuable information to researchers and practitioners on analyzing and predicting the duration of traffic accidents. The

Corresponding Author: Hüseyin Korkmaz E-mail: huseyinkorkmaz@istanbul.edu.tr

Submitted: 27.02.2024 • Revision Requested: 25.03.2024 • Last Revision Received: 31.03.2024 • Accepted: 09.04.2024



This article is licensed under a Creative Commons Attribution-NonCommercial 4.0 International License (CC BY-NC 4.0)

objective of this literature review is to uncover the dynamics of traffic incidents and the important factors affecting accident duration in various categories to improve traffic management. Thus, some guidance or recommendations for traffic accident management can be provided and countermeasures can be generated.

The accident data sets obtained from the Istanbul Metropolitan Municipality (IBB) and the General Directorate of Security (EGM) are used in this paper. One of the datasets used for the modelling in this paper is the dataset titled "Transportation Management Center Traffic Announcement Data" for the city of Istanbul published by the IBB Department of Transportation through the IBB Open Data Portal and is open access (İBB UDB, 2023). The IBB traffic announcement dataset covers the years 2013-2021. The dataset contains 159.411 traffic incident records and 13 different variables. The other dataset was obtained from the traffic accidents database provided by the statistics unit of the EGM Traffic Directorate. The EGM traffic accidents dataset covers the years 2013-2021 and all cities in Türkiye. The EGM data set was obtained in the form of two Excel documents "accident information" and "accident vehicle information". The "accident information" data set contains 1.338.387 traffic accident records and 53 different variables, while the "accident vehicle information" data set contains 2.206.474 traffic accident records and 11 different variables. The final dataset includes 1.905 traffic accident records in Istanbul from 2013 to 2021. The data were analyzed within the scope of data mining.

Researchers have frequently used machine learning models to predict the duration of traffic accidents, especially in the last decade. Machine learning is a sub-branch of artificial intelligence and has been widely used as a powerful tool to overcome challenges in different domains. Statistical tests and machine learning algorithms Ensemble Tree and Neural Networks methods were applied to the extracted data set and prediction of traffic accident duration was performed.

R^2 , MSE, RMSE, and MAE metrics were used for the performance measures of the algorithms applied in this paper. In addition, the final data set used in this paper is divided into 80% training and 20% testing set. Moreover, for performance optimization of regression-based machine learning algorithms, different analyses including the K-Fold Cross Validation Method, Principal Component Analysis, Feature Selection and Optimizer were applied. As a result, it was found that the Ensemble Tree algorithm achieved an R-Square of 0.85 in training, while the Neural Networks algorithm performed better with 0.91 in testing.

1. Giriş

Dünyada artan ulaşım talebi ve trafik yoğunluğu; trafik sıkışıklığı, kazalar, gecikmeler, emisyonlar, ekonomik kayıplar ve hava kirliliği gibi ciddi sorunlara neden olmaktadır. Referans (IEA, 2020), 2019 yılında küresel emisyonların %27'sinin ulaşım ve buna bağlı hava kirliliğinden kaynaklandığını ortaya koymuştur. Ayrıca, Birleşik Krallık'ta trafik sıkışıklığının yıllık maliyetinin 2030 yılına kadar 21 milyar sterlin olacağı vurgulanmaktadır (Alonze, 2014). Benzer şekilde, trafik sıkışıklığı Amerika Birleşik Devletleri (ABD) ekonomisine 2019 yılında yaklaşık 190 milyar dolara mal olmuştur (Fleming, 2019; Schrank, Eisele ve Lomax, 2019). Trafik sıkışıklığı gecikmelere, daha düşük trafik akış hızlarına, daha yüksek yakıt tüketimine ve olumsuz çevresel ve ekonomik etkilere yol açmaktadır. Texas Ulaştırma Enstitüsü raporuna göre, ABD ekonomisinde toplam 8.7 milyar saat seyahat gecikmesi, 3.5 milyar galon boşa harcanan yakıt, 36 milyon ton fazla sera gazı emisyonu, 20 milyar dolar kamyon trafiği sıkışıklık maliyeti, 1600 milyar mil seyahat hacmi gerçekleşmiştir (Schrank ve diğerleri, 2019). Veriler, trafik sıkışıklığı sorununun ve ilgili konuların çözülmesinin ne kadar önemli olduğunu ortaya koymaktadır.

Tekrar etmeyen trafik sıkışıklığı (non-recurrent congestion), başlıca trafik kazaları, büyük siyasi toplantılar, spor etkinlikleri, yol çalışmaları veya beklenmedik aşırı hava kazaları nedeniyle meydana gelen başlıca trafik sıkışıklığı türlerinden biridir. ABD otoyollarındaki tekrar etmeyen trafik sıkışıklığının %55'inden fazlasının trafik kazalarından kaynaklandığı belirtilmektedir (Chin, Franzese, Greene, Hwang ve Gibson, 2004; Skabardonis, Varaiya ve Petty, 2003). Referans (Snelder, Bakri ve van Arem, 2013), tekrar etmeyen trafik sıkışıklığının karayolu trafik sıkışıklığının yaklaşık dörtte birini oluşturduğunu vurgulamaktadır. Öngörülemeyen doğası nedeniyle tekrar etmeyen trafik sıkışıklığını tahmin etmek zor olsa da trafik koşulları üzerindeki etkisini en aza indirmek için hızlı ve verimli bir şekilde ele alınması kritik önem taşımaktadır. Ayrıca, (Adler, Ommeren ve Rietveld, 2013) trafik sıkışıklığının 1 dakika azaltılabilmesi halinde kaza/olay (accident/incident) başına 57€ (yoğun sıkışık bölgelerde yaklaşık 1200€) kazanç sağlandığını göstermiştir. Referans (Garrison ve Mannering, 1990) ayrıca aşırı sıkışık yerlerde kaza süresinin her dakikası için 2.000\$ kaybedildiğini vurgulamıştır. Bu nedenle, trafik sıkışıklığının etkisinin ve kaza ya da olay sonrası etkilerin doğru bir şekilde tahmin edilmesi, trafik katılımcılarını daha iyi yönlendirmek, entegre ulaşım sistemlerini daha verimli bir şekilde işletmek ve bu mobilite zorluğunun üstesinden gelmek için çok önemlidir.

Sahadan elde edilen gerçek zamanlı verilerin daha fazla erişilebilir olması, trafik tahmini için Veri Madenciliği (DM) tekniklerinin geliştirilmesini ve kullanılmasını sağlamıştır. 1980'lerin başından itibaren, tek değişkenli zaman serisi modelleri, özellikle Box-Jenkins Otoregresif Entegre Hareketli Ortalama (ARIMA) (Van Der Voort, Dougherty ve Watson, 1996) ve Holt-Winters Üstel Yumuşatma (Exponential Smoothing) (Marshment, Dauffenbach ve Penn, 1996; Williams, Durvasula ve Brown, 1998) modelleri trafik tahmininde yaygın olarak kullanılmıştır. 2000'li yılların başından bu yana, özellikle Sinir Ağı (NN) modelleri hız (Ishak ve Alecsandru, 2004; Xiao, Sun, Ran ve Oh, 2003), seyahat süresi (van Lint, Hoogendoorn ve van Zuylen, 2002) ve trafik akışı (Park, Messer ve Urbanik, 1998; Stephanedes, Michalopoulos ve Plum, 1981) gibi çeşitli trafik parametrelerinin tahmininde yaygın olarak kullanılmaktadır. Günümüzde ARIMA, üstel yumuşatma ve NN modelleri kısa vadeli trafik tahmini için kıyaslama yöntemleri

olarak kullanılmaktadır. Ancak, bu yaklaşımların en büyük eksikliği, trafik akışını basit zaman serisi verileri olarak görmeleri ve trafik kazalarını atlamalarıdır. Ancak, daha sonra yayımlanan çalışmalarda atlanan ve dikkate alınmayan kaza ve olay verileri zamanla araştırma modellerine dahil edilmeye başlanmıştır.

Literatürde istatistiksel yöntemler, DM teknikleri ve Makine Öğrenmesi (ML) teknikleri gibi farklı trafik analiz ve tahmin yaklaşımlarının yanı sıra simülasyon modelleri, trafik olay analizi ve trafik kaza sonrası etki tahmin modelleri de bulunmaktadır. Geliştirilen bu teknikler gözlem, inceleme, ölçüm, kümeleme, sınıflandırma veya simülasyon modellerine dayanmaktadır. Başlarda, trafik olayının süresini analiz etmek ve tahmin etmek için geleneksel olarak çeşitli istatistiksel yöntemler uygulanmıştır. Bu yöntemler arasında doğrusal/parametrik olmayan regresyon (Khattak, Schofer ve Wang, 1995), Bayes sınıflandırıcı (Boyles, Fajardo ve Waller, 2007), Tehlike Tabanlı Süre Modeli (HBDM) (Nam ve Mannering, 2000), Kesikli Seçim Modeli (DCM) (Lin, Zou ve Chang, 2004), Yapısal Eşitlik Modeli (Lee, Chung ve Son, 2009) ve olasılıksal dağılım analizleri (Giuliano, 1989) bulunmaktadır. Son zamanlarda trafik kaza süresinin tahmini için veri temelli deneysel algoritmalara dayanan ve benzersiz veri kullanılabilirliği ile desteklenen yeni bir araştırma alanı ortaya çıkmıştır. Trafik olayı süresini tahmin etmek ve öngörmek için farklı DM-ML yaklaşımları kullanılmıştır. Bu yaklaşımlar arasında Karar Ağacı (DT) ve Sınıflandırma Ağaç Yöntemi (CTM) (Zhan, Gan ve Hadi, 2011), Yapay Sinir Ağları (ANN) (Vlahogianni ve Karlaftis, 2013), Genetik Algoritma (GA) (Ying Lee ve Wei, 2010) ve Destek Vektör Makinesi/İlgililik Vektör Makinesi (SVM/RVM) (Valenti, Lelli ve Cucina, 2010) yer almaktadır. Birçok araştırmacı, trafik kaza süresini tahmin etmek ve önceki yöntemlerin avantajlarından yararlanmak için son zamanlarda özellikle hibrit yöntemler (Kim ve Chang, 2012) kullanmaya başlamıştır. Bu doğrultuda, bu araştırma İstanbul'daki trafik kaza verilerine dayalı olarak trafik kaza süresini Topluluk Ağacı (ET) ve Sinir Ağları yöntemlerini kullanarak tahmin etme ve bu yöntemlerin performanslarını karşılaştırma amacını taşımaktadır.

Bu araştırmanın geri kalanı aşağıdaki şekilde düzenlenmiştir: Bölüm 2'de trafik kaza süresi tahmini ve ML ile ilgili literatür çalışmaları açıklanmaktadır. Bölüm 3'te çalışmanın metodolojisi, veri ve modelleme özetlenmektedir. Bulgular ve model tahmin sonuçları sonraki bölümlerde açıklanmaktadır. Son olarak, tartışma ve sonuç sunulmaktadır.

2. Literatür Araştırması

Literatür araştırması, 2010 yılından 2022 yılının sonuna kadar yayımlanan son ve güncel akademik çalışmalara odaklanmaktadır. Bu literatür araştırması, trafik kazalarının süresini analiz etme ve tahmin etme konusunda araştırmacılara ve uygulayıcılara değerli bilgiler sunan köklü veri tabanlarından araştırma makalelerini bir araya getirmiştir. Bu literatür araştırmasının hedefi, trafik yönetimini geliştirmek için trafik olaylarının dinamiklerini ve çeşitli kategorilerdeki kaza süresini etkileyen önemli faktörleri ortaya çıkarmaktır. Böylece, trafik kazalarının yönetimi için bir rehberlik veya birtakım tavsiyeler sağlanabilir ve karşı önlemler üretilebilir.

Heterojenlik ve gözlemlenemeyen faktörler nedeniyle trafik kaza süresinin tahmin edilmesine yönelik modellemenin karmaşık bir konu olduğu düşünülmektedir. Son on yılda çok sayıda araştırma, çeşitli veri kümelerini kullanarak trafik kaza süresini tahmin etmek için uygun yöntem ve prosedürleri araştırmıştır. Bu literatür çalışmasında, trafik kaza süresinin tahmininde ML algoritmaları kullanılan önceki araştırmalar aşağıdaki bölümde sunulmaktadır.

Bir trafik olayı ya da kazası meydana geldiğinde sürenin belirsizliği sürücüler, yolcular ve trafik operatörleri için endişe yaratmaktadır. Bu nedenle, bir trafik kazasının meydana gelmesi ile ortadan kalkması arasında geçecek sürenin uzunluğu araştırmaya değer bir konudur. Araştırmacılar, özellikle son on yılda, trafik kazası süresinin tahmininde ML modellerini sıklıkla kullanmışlardır. ML, yapay zekânın bir alt dalını oluşturmada ve farklı alanlardaki zorlukların üstesinden gelmek için güçlü bir araç olarak yaygın bir şekilde kullanılmaktadır. Önceki çalışmalarda kullanılan ML, ANN (Li, Wu ve Peng, 2021; Lin ve Li, 2020), Bayes Ağı (BN) (Cong ve diğerleri, 2018; Kuang, Yan, Zhu, Tu ve Fan, 2019), SVM (Yu, Wang, Yao ve Wang, 2016; Zong, Zhang, Xu, Zhu ve Wang, 2013), Rastgele Orman (RF) (Bai, Ji, Dai, Pu ve Qin, 2022; Hamad, Al-Ruzouq, Zeiada, Abu Dabous ve Khalil, 2020), K-En Yakın Komşular (k-NN) (Ji ve diğerleri, 2022; Wang, Li ve Guo, 2018), RVM (Pereira, Rodrigues ve Ben-Akiva, 2013; Valenti ve diğerleri, 2010), ET (Chen ve Tao, 2022; Zhao ve diğerleri, 2022), DT (Ma, Ding, Luan, Wang ve Wang, 2017; Saracoglu ve Ozen, 2020), Derin Öğrenme (DL) (Shang, Xie ve Yu, 2022; Zhu ve diğerleri, 2021), Bulanık Sistem (Fuzzy System) sınıflandırması (Dimitriou ve Vlahogianni, 2015) ve bunların çoklu ve birleşik (multiple and combined) (Hamad, Khalil ve Alozi, 2020; Lee, Kwak, Oh ve Kim, 2022) kullanımlarını kapsamaktadır. Tablo 1, önceki çalışmalarda yer alan ML modellerinin bir listesini, tanımlarını ve temel bileşenlerini özetleyerek sunmaktadır.

ANN ve BN, literatürde en yaygın kullanılan ML algoritmalarıdır. ANN'ler insan beyninin karmaşık yapısından esinlenerek basitleştirilmiş elektronik gösterimlerdir (Hassoun, 1995). ANN modelinin kullanıldığı çalışmalarda mutlak ortalama hata değerleri ortalama %3-30 arasında değişmektedir (Chi-Sen Li ve Chen, 2014; Li, Sheng, Du, Wang ve Ran, 2020; Lin ve Li, 2020). Bu da ANN modellerinin trafik kaza süresi için tahmin gücünün yüksek olduğunu göstermektedir. Bu çalışmalarda kullanılan veri boyutu, veri kalitesi ve diğer faktörlerin ANN modellerinin trafik kaza süresi için yüksek tahmin gücünü etkileyebileceği de unutulmamalıdır. Diğer taraftan BN, Bayes olasılığı ve çizge teorilerini birleştiren ve tümevarımsal bilgi keşfi yaklaşımını kullanan bir tekniktir (Pearl, 1988). BN, yapay zekâ ve ML gibi ilgili sahalarda geniş uygulama alanı bulmuştur. BN modelini kullanan önceki çalışmalarda, mutlak ortalama hata değerlerinin yaklaşık %67'ye kadar çıktığı gözlemlenmiştir (Cong ve diğerleri, 2018;

Ghosh ve Dauwels, 2022). İlgili faktörlerin etkisi göz ardı edilirse, BN modellerinin trafik kazası süresi için tahmin gücünün yüksek olmadığı söylenebilir.

İncelenen makalelerde kullanılan diğer ML algoritması ET, performansı ve sağlamlığı artırmak için birden fazla modelden gelen tahminleri birleştirir (Breiman, 1996; Schapire, 1990). RF, genellemeyi iyileştirirken istikrarsızlığı önleyerek aşırı uyumu ele almak için çeşitli DT'lerden oluşan bir orman oluşturur (Tin Kam Ho, 1995). Özetle, bu teknikler çok çeşitli ML ve yapay zekâ araçlarını temsil etmektedir. Uygulayıcılar, birden fazla modelin tahminlerini birleştirerek (ET), karara dayalı yapılar kullanarak (DT, RF) çok çeşitli zorlukların üstesinden gelebilir ve sağlam çözümler geliştirebilirler.

Tablo 1. Makine öğrenmesi çalışmaları.

Yöntem Kategorisi	Referans	Yöntem	Veri özellikleri	Veri türü	Çalışma yeri	Performans ölçütleri	Süre zaman aşaması
Çoklu ML	(Ghosh, Asif, Dauwels, Fastenrath ve Guo, 2019)	Sınıflandırma ve regresyon ağacı (CART), Çok katmanlı algılayıcı (MLP), Tree bagger, Destek vektör regresyonu (SVR), Uyarlanabilir bulanık NN, Gauss karışım regresyonu (GMR)	11.278 olay Ağustos 2016 - Ocak 2017 tarihleri arasında	5 dk.	Singapur	MAPE: 20–50%, Tahmin hatası: 55.84%	Olay süresi
	(Grigorev, Mihaita, Lee ve Chen, 2022)	Çift seviyeli ML çerçevesi aykırı değer giderme ve intra–extra ortak optimizasyon algoritması (IEO-ML)	574 kaza 2017 yılı boyunca	-	Avustralya, Sydney ve ABD, Kaliforniya/San Francisco	En iyi MAPE: 9.34%, Kesinlik, Duyarlılık, Doğruluk, F1-score	Olay süresi
	(Hamad, Khalil, ve diğerleri, 2020)	Regresyon karar ağacı, SVM, ET (Bagged ve Boosted), Gauss proses regresyonu, ANN	119.670 olay 1 Ocak 2004 - 31 Aralık 2013 tarihleri arasında	-	ABD, Texas/Houston	MAE, RMSE, Ortalama eğitim süresi	Olay süresi
	(Hamad, Obaid, Haridy, Zeiada ve Al-Khateeb, 2022)	Faktöriyel deney tasarımı, İleri sıralı özellik seçimi ve çoklu ML teknikleri (Doğrusal regresyon, DT, SVM, ET, GMR ve ANN)	90.000 üzerinde ve birçok yılı kapsayan kısa süreli olay kayıtları	-	ABD, Texas/Houston	RMSE: 12.7 dk., MAE: 10.1 dk.	Olay süresi
	(Lee ve diğerleri, 2022)	LIME (Doğrusal regresyon, En küçük mutlak küçültme ve seçim operatörü (LASSO), Ridge regresyon, SVR ile Radyal taban fonksiyonu (RBF), DT, RF, XGBoost, CatBoost, Işık gradyanı artırma makinesi (LGBM) ve MLP)	1.425 olay 2 Eylül - 1 Aralık 2020 tarihleri arasında	5 ve 30 dk.	Güney Kore, Seoul	En iyi MAPE: 80.8%	Olay süresi
	(Pereira ve diğerleri, 2013)	Doğrusal regresyon, SVR/RVM, ANN, DT, RBF ve Gizil Dirichlet ataması (LDA) olarak bilinen konu modelleme tekniği	10.139 kaza Ocak 2010 - Aralık 2011 tarihleri arasında	20 dk.	Singapur	MAPE: aralık 40-100%, MAE: 15.5 dk., ME: 9.9 dk. (28%)	Olay süresi
	(Valenti ve diğerleri, 2010)	Çoklu doğrusal regresyon, DT, ANN, SVM/RVM, k-NN	237 olay 2005 yılına ait üç ayda (Ocak, Nisan, Ağustos)	5 ve 10 dk.	İtalya	En iyi MAPE: 34%, En iyi MAE: 13,65 dk., En iyi RMSE: 17.29 dk.	Olay süresi
	(Won, Kim ve Chang, 2018)	Hibrit Birliktelik kuralı madenciliği (ARM)	6.463 olay 2012 - 2016 yılları arasında	30, 60, ve 120 dk.	ABD, Maryland	Doğruluk: 85%	Temizleme süresi
	(Mohammed, Abdullah ve Al Hussaini, 2021)	SVM, RF ve ANN	352 olay Ocak 2015 - Ocak 2017 tarihleri arasında	5 dk.	ABD, Missouri	SVM için en iyi MAE: 14.23 dk., RF için en iyi RMSE: 18.91 dk., MSE	Olay süresi
	(Sheikh ve Regan, 2022)	Bağımsız bileşen analizi, Hibrit gözlemci- Genelleştirilmiş olabilirlik oranı, Hız tabanlı hücre iletim modeli (CTM-v), Parçalı anahtarlamalı doğrusal model (PWSL), Geri Yayılımlı sinir ağı (BPNN), SVM ve k-NN	25 olay ve 50.656 toplam örneklem 16 Şubat - 19 Mart 1993 ve 27 Temmuz - 29 Ekim 1993 tarihleri arasında	3, 12, ve 30 dk.	ABD, Kaliforniya/San Francisco Bay Area	DR, FAR, Sınıflandırma oranı, MTTD, AUC ve ROC	Olay süresi

Tablo 1. Devamı.


NN	(Ying Lee ve Wei, 2010)	ANN modelleri ve GA	39 kaza 2004 – 2005 yılları arasında	5 dk.	Tayvan	En iyi MAPE: 8.93%, En iyi MAE: 416.6 sn., En iyi R ² : 0.944	Kaza süresi
	(Lee, Wei ve Chao, 2017)	ANN ve k-NN	46 olay 2012 yılı boyunca	5 dk.	Tayvan	En iyi MAPE: 25.4%	Temizleme ve müdahale süresi
	(Li ve Chen, 2013)	NN	76 kaza 16 Eylül - 16 Ekim 2009 tarihleri arasında	5 dk.	Tayvan	MAPE: 6.47%, RMSE: 2.02 dk.	Seyahat süresi
	(Chi-Sen Li ve Chen, 2014)	NN, CART ve K-ortalamlar (K-means)	76 kaza 16 Eylül - 16 Ekim 2009 tarihleri arasında	5 ve 10 dk.	Tayvan	MAPE: 6-9%	Seyahat süresi
	(Li ve diğerleri, 2020)	Kısıtlı Boltzmann makinesi (RBM) tabanlı bir derin füzyon modeli	968 kaza	5 ve 10 dk.	ABD, Kaliforniya	MAPE: 20.23%, RMSE: 11.84 dk.	Müdahale ve temizleme süresi
	(Li ve diğerleri, 2021)	Spiking sinir ağı (SNN) ve Evrişimsel sinir ağı (CNN)	11.940 kaza Şubat 2016 - 2020 tarihleri arasında	30 dk.	ABD, Kaliforniya	MAPE: 12.07%, RMSE: 8.13 dk.	Müdahale ve temizleme süresi
	(Lin ve Li, 2020)	NN, SVM, RF	13.338 kaza 2017 yılı boyunca	5 dk.	Çin, Beijing	En iyi MAPE: 3.05% (RF), 6.42% (SVM), 5.59% (NN); En iyi RMSE: 5.50 dk. (RF), 10.62 dk. (SVM), 6.05 dk. (NN)	Kaza oluşum süresi
	(Park, Haghani ve Zhang, 2016)	Bayes ANNs	13.987 olay 2010 - 2011 yılları arasında	30 dk.	ABD, Maryland	MAE: 18-29%, MSPE: 25-56%	Olay süresi
ET	(Vlahogianni ve Karlaftis, 2013)	Kısmi lojistik regresyon yapay sinir ağı (PLANN)	1.449 kaza 2012 yılında	-	Yunanistan, Athena	En iyi doğruluk: 9.23%, AIC, ROC, MDL	Olay süresi
	(Chen ve Tao, 2022)	TF-IDF-RF (Terim Frekansı-Ters Belge Frekansı-RF) ve Metin madenciliği	3.046 kaza Ocak 2020 - Nisan 2021 tarihleri arasında	-	Çin, Shaanxi	MAPE: 73-75%, RMSE, R2	Kaza süresi
	(Tang, Zheng, Han, Liu ve Cai, 2020)	Aşırı gradyan yükseltme makinesi algoritması (XGBoost), Bayes optimizasyonu, K-ortalamlar (K-means)	2.565 olay 1 Ocak - 31 Aralık 2011 tarihleri arasında	-	ABD, Washington/Seatle	MAPE: 22.1%	Temizleme süresi
	(Won, 2020)	Aykırı değer tespit yöntemleri (PCA, Medoidler etrafında bölümlenme (PAM) ve Isolation Forest), ET ve Hibrit ARM	2.455 olay 2012 - 2017 yılları arasında	30 ve 60 dk.	ABD, Maryland	En iyi MAE: 13.42 dk., En iyi MSE: 367.76 dk., AIC	Olay süresi
	(Zhao ve Deng, 2022)	Heterojen ET modeli (XGBoost, LGBM, CatBoost, Stacking ve Elastic Network)	2.366.002 başlangıç eğitim seti verisi 8 Şubat 2016 - 14 May 2020 ve 24.143 kayıt test seti verisi 14 May - 30 Haziran 2020 tarihleri arasında	-	ABD	MAPE: 35.6%, MAE: 30.7432 dk., MSE: 4252.1728	Kaza süresi
	(Zhao ve diğerleri, 2022)	Kümeleme-Tabanlı ET, K-ortalamlar (K-means), ANN, RF regresyon modeli	18.462 olay 14 Eylül 2020 - 5 Ocak 2021 tarihleri arasında	-	Singapur	MSE: 5314.78, RMSE: 72.90 dk.	Olay süresi
RF	(Bai ve diğerleri, 2022)	RSF model ve Çarpım sınırı tahmincisi (K-M) analizi	349 veri Ocak 2018 - Aralık 2020 tarihleri arasında	10 saatlik	Çin, Yunnan	MAE: 11.32 dk., MSE: 346.99, RSF model: 0.756 ve 0.867	Bildirme, müdahale ve temizleme süresi
	(Hamad, Al-Ruzouq, ve diğerleri, 2020)	RF ve ANN	140.653 olay 1 Ocak 2004 - 31 Aralık 2013 tarihleri arasında	-	ABD, Texas/Houston	En iyi MAE: 14.979 dk., RMSE: 20.231 dk.	Olay süresi
	(Liu, Zheng, Li ve Tang, 2022)	RF, k-NN, SVR	44.916 kaza Şubat 2016 - Haziran 2020 tarihleri arasında	5 dk.	ABD, Kaliforniya/Los Angeles	En iyi MAPE: 1.310%, En iyi RMSE: 11.214, En iyi MSE: 1.488	İkincil çarpışma/ aralık süresi
	(Shang, Tan, Gao ve Feng, 2019)	Komşuluk bileşenleri analizi (NCA) ve Bayes optimizasyon algoritması (BOA) ile optimize edilmiş RF	440 olay	10, 30, 60, ve 90 dk.	ABD, Kaliforniya	RF ve SVM için sınıflandırma doğruluğu: 84%	-

3. Yöntem

Bu araştırmanın birincil amacı İstanbul'daki trafik kaza verilerine dayalı olarak trafik kaza süresini ET ve NN yöntemleri ile tahmin etmek ve bu yöntemlerin performanslarını karşılaştırmaktır. Araştırmanın ikincil amacı ise trafik kaza süresini etkileyen temel faktörleri belirlemektir. Kaza süresinin tahmin edilebilmesi kaza nedeniyle meydana gelen trafik sıkışıklığının ne kadar süreceğinin de tahmin edilebilmesine imkân sağlayacaktır. Bu amaç için trafik kaza verilerine ihtiyaç duyulmaktadır. Bu araştırma kapsamında kullanılan İstanbul'a ait veri setleri İstanbul Büyükşehir Belediyesi (İBB) ve Emniyet Genel Müdürlüğü (EGM) olmak üzere iki farklı kaynaktan elde edilmiştir. Elde edilen veriler veri madenciliği kullanılarak incelenmiştir. Veri madenciliği, çalışma verilerinin en doğru şekilde analiz edilebilmesine imkân tanırken hata oranını da düşürmektedir. Böylece zaman ve performans kayıpları da önlenmiş olmaktadır. Ayıklanan nihai veri setine istatistik testleri ve ML algoritmaları uygulanarak trafik kaza süresi tahmini gerçekleştirilmiştir.

3.1. Materyal ve Veri Ön İşleme

Bu çalışmada analiz için kullanılan veri setlerinden biri İBB Ulaşım Daire Başkanlığı tarafından İBB Açık Veri Portalı üzerinden yayımlanmış olan İstanbul şehrine ait "Ulaşım Yönetim Merkezi Trafik Duyuru Verisi" başlıklı veri setidir ve açık erişimlidir (İBB UDB, 2023). İBB trafik duyuru veri seti 2013-2021 yıllarını kapsamaktadır. Veri seti içerisinde İstanbul'da gerçekleşen 159.411 trafik olay kaydı ve 13 farklı değişken bulunmaktadır. Diğer veri seti ise EGM Trafik Başkanlığı istatistik birimi tarafından sağlanan trafik kazaları veri tabanından elde edilmiştir. EGM trafik kazaları veri seti 2013-2021 yıllarını ve tüm Türkiye şehirlerini kapsamaktadır. EGM veri seti "kaza bilgisi" ve "kaza araç bilgisi" olmak üzere iki Excel dokümanı şeklinde elde edilmiştir. "Kaza bilgisi" veri seti içerisinde 1.338.387 trafik kaza kaydı ve 53 farklı değişken bulunurken; "kaza araç bilgisi" veri seti içerisinde 2.206.474 trafik kaza kaydı ve 11 farklı değişken bulunmaktadır. Bu araştırmanın aşamalarını açıklayan akış şeması Şekil 1'de sunulmaktadır.



Şekil 1. Araştırma süreci akış şeması.

Veri ön işleme (data preprocessing), bir dizi alt işlemi içerir. Bu işlemler arasında veri setlerini birleştirme, kapsam dışı ve eksik değer içeren sütunları çıkarma, eksik verileri tamamlama, aykırı ve tekrarlanan değerleri çıkarma, veri düzenleme, normalizasyon ve standardizasyon gibi adımlar bulunmaktadır. Eksik verilerin belirlenmesi, aykırı değerlerin düzeltilmesi ve veri setinin genel olarak temizlenmesi, analitik modellerin doğruluğunu artırır ve sonuçların daha güvenilir olmasını sağlar.

Araştırma kapsamında elde edilen “İBB Trafik Duyuruları”, “EGM Kaza Bilgisi” ve “EGM Kaza Araç Bilgisi” olmak üzere toplamda üç ayrı veri seti bulunmaktadır. İBB veri setinde sadece İstanbul şehri için kaza kayıtları bulunurken EGM veri setinde tüm Türkiye şehirlerine ait kaza kayıtları bulunmaktadır. Dolayısıyla ilk yapılması gerek işlem EGM veri setindeki kaza kayıtlarını sadece İstanbul şehrinin verilerini içerecek şekilde filtrelemek olmuştur. Daha sonra; analiz, modelleme ve tahminleme yapılabilmesi için üç ayrı veri setinin birleştirilerek tek bir veri seti haline dönüştürülmesi gerekmektedir. Bu durumda ilk olarak EGM Trafik Başkanlığı’ndan elde edilen kaza bilgisi veri seti ile kaza araç bilgisi veri seti “KazaId” değişkeni esas alınarak eşleştirilmiş ve birleştirilmiştir. “KazaId” değişkeni her iki veri setinde de bulunmakta ve her kaza kaydı için benzersiz bir kimlik numarası belirtmektedir. Eşleştirme neticesinde birleştirilen veri seti içerisinde 1.338.387 trafik kaza kaydı ve 63 farklı değişken elde edilmiştir. EGM veri setlerinin kendi içerisinde birleştirilmesi sonrasında İBB trafik duyuruları veri seti üzerinden kaza süresi (AccDuration) bilgisi hesaplanmıştır. AccDuration, yani trafik kaza süresi, bir kazanın meydana gelmesi ile kaza yerinin başlangıç durumuna dönmesi arasındaki zaman farkı olarak ifade edilmektedir. Daha sonra EGM birleştirilmiş veri seti ile İBB trafik duyuruları veri setindeki “konum” ve “zaman” bilgilerini içeren değişkenler esas alınarak trafik kaza kayıtları eşleştirilmiştir.

Sonraki adımlarda bazı veri ön işleme uygulamaları gerçekleştirilmiştir. Öncelikle, veri setindeki gereksiz bilgiler içeren ya da eksik değerlere sahip sütunlar çıkarılmıştır. Gereksiz veya eksik değer içeren sütunlar, analiz hedeflerine katkıda bulunmayan veya model performansını olumsuz etkileyen verileri içerebilir. Veri seti içerisinde eksik veri bulunan satır sayısı çok azdır. Bu kayıtlar, sayılarının çok az olması nedeniyle modelleme ve tahmin performansını olumsuz etkilememesi için veri setinden çıkarılmıştır. Aynı şekilde aykırı ve tekrarlanan değerleri çıkarma işlemi de tamamlanmıştır. Daha sonra, veri düzenleme işlemi yapılmıştır. Veri düzenleme, genel olarak kategorik değişkenlerin temizlenmesi ve bir standart ile tekrar ifade edilmesi olarak ifade edilebilir. Veri düzenleme safhası, iki yaklaşım ile tamamlanmıştır. Bu yaklaşımlar tek-sıcak kodlama (one-hot encoding) ve etiket kodlama (label encoding) olarak adlandırılmaktadır. Veri dönüştürme ise, genel olarak nümerik değişkenlerin yeniden ölçeklendirilmesi ve standartlaştırılması olarak tanımlanabilir. Bu çalışmada önce veriler düzenlenmiş daha sonra veri dönüştürme kapsamında normalizasyon ve standardizasyon uygulamaları gerçekleştirilmiştir. Diğer yandan veri setine ait kategorik değişkenler, içerisinde bulunan metinsel ifadelerden arındırılarak rakamsal olarak sınıflandırma işlemine tabi tutulmuş etiketlenmiş ve kategorize edilmiştir.

Normalizasyon ve standardizasyon, veri ön işlemede kullanılan iki önemli yöntemdir. Normalizasyon veriyi 0 ile 1 değerleri arasında yeniden ölçeklendirirken, standardizasyon veriyi aynı ortalamaya (0) ve aynı standart sapmaya (1) sahip olacak şekilde yeniden ölçeklendirir (Karataş, 2021). Bu çalışmada en popüler normalizasyon yöntemlerinden biri olan min-maks normalizasyon yöntemi (min-max scaler) kullanılmıştır. Normalizasyon, Denklem 1 ile uygulanmaktadır.

$$X_{yeni} = \frac{X - X_{min}}{X_{maks} - X_{min}} \quad (1)$$

Denklem 1’de belirtilen X_{yeni} terimi değişken içerisindeki ilgili değer normalizasyon formülü ile hesaplanmış olan yeni değerini, X_{min} terimi ilgili değişkende bulunan en küçük değeri ve X_{maks} terimi ilgili değişkende bulunan en büyük değeri ifade etmektedir. Değişken değerlerini standartlaştıran standardizasyon ise Denklem 2 ile gerçekleştirilmektedir.

$$z = \frac{X - \mu}{s} \quad (2)$$

Denklem 2’de belirtilen z terimi standardizasyon ile hesaplanmış yeni z -puan değerini, X terimi örneklem sayısını, μ terimi örneklemin ortalamasını ve s terimi de standart sapmayı ifade etmektedir.

Elde edilen veri setinde mükerrer veri bulunamamıştır. Bu nedenle, tekrarlanan değerleri çıkarma kapsamında bu veri setinden herhangi bir kesinti yapılmamıştır. Ancak, elde edilen veri seti içerisindeki “AccDuration” değişkeninde aykırı değerler bulunduğu tespit edilmiştir. “AccDuration” değişkeni içerisindeki veriler incelendiğinde en kısa kaza süresinin yaklaşık 1 dakika ve en uzun kaza süresinin de yaklaşık 1.440 dakika (24 saat) olduğu ve verilerin bu değerler aralığında değişkenlik gösterdiği gözlemlenmiştir. Değişken verilerinin dağılımına bakıldığında ise özellikle 120 dakikanın üzerindeki verilerin aykırı değerler olduğu tespit edilmiştir. Diğer yandan, literatürdeki çalışmalara göre 90 ya da 120 dakikanın üzerindeki kaza sürelerinin büyük ölçekli kaza olarak tanımlandığı ve farklı bir çalışma ile incelenmesi gerektiği ifade edilmektedir (Zhang, Zhang ve Khattak, 2012). Kısa süreli kazalar ile uzun süreli kazalar arasındaki etkileyici faktörlerin ve tahmin belirleyicilerinin farklı olabileceğine dikkat çekilmektedir. Tüm bu değerlendirmeler neticesinde ilgili aykırı değerler veri setinden çıkarılarak, veri setinin genel kalitesi artırılmış ve modelleme ile tahminleme süreçlerinin daha sağlıklı bir temele oturmasına olanak sağlanmıştır.

3.2. Veri Analizi

Veri ön işleme sürecinde veri setlerinin birleştirilip, eksik ve aykırı değerler çıkarıldıktan, filtreleme ve hata kontrol işlemleri yapıldıktan sonra nihai veri seti elde edilmiştir. Nihai veri seti, 2013-2021 yılları arasındaki İstanbul'da gerçekleşen 1.905 trafik kaza kaydını içermektedir. Bu çalışmada kullanılan nihai veri setinde kaza süresi 90 dakikadan kısa süren veriler dikkate alınmıştır. Bunun temel iki nedeni bulunmaktadır. Birincisi, kaza süresi 90 dakikanın üzerindeki verilerin dağınık olması ve çok fazla aykırı değere sahip olması; ikincisi ise bu çalışmanın odağının büyük ölçekli değil, küçük ölçekli ve kısa süreli kazaların tahmin edilmesidir. Diğer yandan, literatürdeki çalışmalara göre 90 ya da 120 dakikanın üzerindeki kaza sürelerinin büyük ölçekli kaza olarak tanımlandığı ve farklı bir çalışma ile incelenmesi gerektiği ifade edilmektedir (Zhang ve diğerleri, 2012). Bu nedenlerle kaza süresi 90 dakikanın üzerinde bulunan kaza kayıtları veri setinden çıkarılmıştır.

Nihai veri seti üzerinde birtakım istatistiksel analizler gerçekleştirilmiştir. İstatistiksel analiz, elde edilen veriler üzerinden anlam çıkarmak, desenleri tanımlamak, değişkenler arasındaki ilişkileri anlamak ve gelecekteki olayları tahmin etmek için istatistik yöntemlerini kullanarak yapılan bir analiz türüdür. Bu çalışmada, istatistiksel analiz kapsamında tanımlayıcı analiz (descriptive analysis), korelasyon analizi, konumsal, zamansal ve çevresel analizler gerçekleştirilmiştir.

Tanımlayıcı analiz, veri setinin genel özelliklerini anlamak, önemli örüntüleri ve trendleri belirlemek ve ileri analiz için bir temel oluşturmak için kullanılmaktadır. Tanımlayıcı analiz, nihai veri seti içerisinde yer alan İstanbul'daki trafik kazalarının ve ilgili değişkenlerinin genel özelliklerini ayrıntılı bir şekilde ortaya koymayı amaçlamaktadır. Elde edilen nihai veri seti ve tanımlayıcı analiz sonuçları Tablo 2'de gösterilmektedir.

Tablo 2. Nihai veri seti ve tanımlayıcı analiz sonuçları.

Değişken Adı	Veri Tipi	Benzersiz Değer Sayısı	Tekrarlanan Değer	Min.	Maks.	Ranj (Genişlik)	Ortalama	Ortanca	Mod	Standart Sapma	Varyans
Kazallcesi	Kategorik	38	Var	2	41	39	20,35	20	7	-	-
KazaYerlesimYeri	Kategorik	2	Var	1	2	1	1,26	1	1	-	-
YolunTipi	Kategorik	4	Var	1	4	3	1,22	1	1	-	-
YolKaplama	Kategorik	4	Var	1	4	3	1,01	1	1	-	-
YolunSinifi	Kategorik	9	Var	1	12	11	3,42	3	4	-	-
GeoYatay	Kategorik	3	Var	1	3	2	1,07	1	1	-	-
GeoDusey	Kategorik	4	Var	1	4	3	1,17	1	1	-	-
GeoKavsak	Kategorik	8	Var	1	8	7	7,58	8	8	-	-
GeoGecit	Kategorik	5	Var	1	5	4	4,93	5	5	-	-
GeoDiger	Kategorik	7	Var	1	8	7	7,80	8	8	-	-
GunDurumu	Kategorik	3	Var	1	3	2	1,41	1	1	-	-
HavaDurumu	Kategorik	6	Var	1	10	9	1,33	1	1	-	-
YolunYuzeyi	Kategorik	5	Var	1	6	5	1,16	1	1	-	-
ilkYardim	Kategorik	3	Var	1	3	2	1,07	1	1	-	-
KazaOlusTuru	Kategorik	13	Var	1	14	13	4,54	3	2	-	-
CarpismaYeri	Kategorik	10	Var	1	11	10	1,26	1	1	-	-
KazaYolKusuru	Kategorik	5	Var	1	8	7	7,99	8	8	-	-
YolGenisligi	Kategorik	8	Var	1	8	7	1,93	1	1	-	-
OtoKorkuluk	Kategorik	2	Var	1	2	1	1,23	1	1	-	-
YayaYolu	Kategorik	3	Var	1	3	2	1,85	2	2	-	-
EmniyetSeritiBanket	Kategorik	3	Var	1	3	2	1,65	2	2	-	-
YolSeritCizgisi	Kategorik	3	Var	1	3	2	1,05	1	1	-	-
TrafikIsaretLevhasi	Kategorik	3	Var	1	3	2	1,82	2	2	-	-
TrafikLambasi	Kategorik	3	Var	1	3	2	2,71	3	3	-	-
Aydinlatma	Kategorik	3	Var	1	3	2	1,42	1	1	-	-
TrafikGorevli	Kategorik	2	Var	1	2	1	1,98	2	2	-	-
GoruseEngelCisim	Kategorik	1	Var	2	2	0	2,00	2	2	-	-
HasarGorenUnsur	Kategorik	2	Var	1	2	1	1,81	2	2	-	-
YoldaCalisma	Kategorik	2	Var	1	2	1	1,99	2	2	-	-
ToplamOluSayisi	Nümerik	2	Var	0	1	1	0,02	0	0	0,12	0,02
ToplamYaraliSayisi	Nümerik	16	Var	0	28	28	1,60	1	1	1,42	2,01
Bisiklet	Nümerik	2	Var	0	1	1	0,00	0	0	0,04	0,00
AtArabasi	Nümerik	1	Var	0	0	0	0,00	0	0	0,00	0,00
MotorluBisiklet	Nümerik	3	Var	0	2	2	0,03	0	0	0,16	0,03
Motosiklet	Nümerik	3	Var	0	2	2	0,29	0	0	0,48	0,23
Otomobil	Nümerik	8	Var	0	7	7	1,21	1	1	1,00	1,00
Minibus	Nümerik	4	Var	0	3	3	0,07	0	0	0,28	0,08
Kamyonet	Nümerik	5	Var	0	4	4	0,30	0	0	0,55	0,30
Kamyon	Nümerik	4	Var	0	3	3	0,05	0	0	0,22	0,05
Cekici	Nümerik	3	Var	0	2	2	0,04	0	0	0,19	0,04
Otobus	Nümerik	3	Var	0	2	2	0,06	0	0	0,26	0,07
Traktor	Nümerik	1	Var	0	0	0	0,00	0	0	0,00	0,00
AraziTasiti	Nümerik	2	Var	0	1	1	0,00	0	0	0,04	0,00
OzelAmacli	Nümerik	2	Var	0	1	1	0,01	0	0	0,08	0,01
IsMakinesi	Nümerik	2	Var	0	1	1	0,00	0	0	0,05	0,00
Ambulans	Nümerik	2	Var	0	1	1	0,00	0	0	0,05	0,00
Tanker	Nümerik	3	Var	0	2	2	0,00	0	0	0,05	0,00
Tren	Nümerik	1	Var	0	0	0	0,00	0	0	0,00	0,00
Tramvay	Nümerik	2	Var	0	1	1	0,00	0	0	0,05	0,00
DigerArac	Nümerik	2	Var	0	1	1	0,02	0	0	0,12	0,01
ElektrikliSkuter	Nümerik	1	Var	0	0	0	0,00	0	0	0,00	0,00
AccDuration	Nümerik	1074	Var	2,083	89,983	87,900	45,807	37,417	28,80	20,809	432,995

Korelasyon analizi, iki veya daha fazla değişken arasındaki ilişkiyi ve bu ilişkinin gücünü ölçen istatistiksel bir tekniktir. Korelasyon analizi genellikle Pearson Korelasyon Katsayısı kullanılarak yapılmaktadır (Miles ve Banyard, 2007). Pearson korelasyonu, iki sürekli değişken arasındaki doğrusal ilişkiyi ölçen parametrik bir ölçüdür (Gibbons, 1997; Howell, 1992). Değerleri -1 ile +1 arasında değişmektedir (Cohen, 2013). +1, tam pozitif korelasyon, yani bir değişken arttığında diğer değişken de doğrusal bir şekilde artmaktadır. 0, iki değişken arasında korelasyon yoktur manasındadır. -1, tam negatif korelasyon, yani bir değişken arttığında diğer değişken doğrusal bir şekilde azalmaktadır. Araştırma kapsamında gerçekleştirilen korelasyon analiz sonuçlarına göre aralarında korelasyon bulunan değişkenler ve ilgili değerler Tablo 3'te sunulmaktadır.

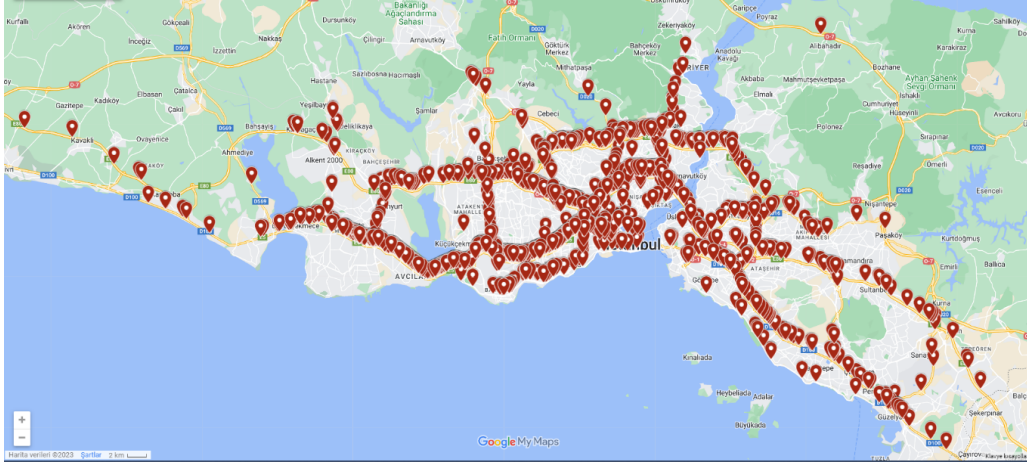
Tablo 3. Korelasyon analiz sonuçları.

Değişkenler	KazaOlusTuru	AracSayisinaGoreKaza	SonucOluSurucu	SonucOluYaya	SonucYaraliYolcu	ToplamOluSayisi	ToplamYaraliSayisi	KazaOlumlu	KazaYaralamali	Otomobil	ToplamAracSayisi	AccDuration
KazaOlusTuru	1,00											
AracSayisinaGoreKaza	-0,67	1,00										
SonucOluSurucu	0,02	-0,01	1,00									
SonucOluYaya	0,11	-0,09	-0,01	1,00								
SonucYaraliYolcu	-0,07	0,10	-0,02	-0,02	1,00							
ToplamOluSayisi	0,10	-0,08	0,63	0,70	-0,03	1,00						
ToplamYaraliSayisi	-0,06	0,08	-0,06	-0,05	0,93	-0,07	1,00					
KazaOlumlu	0,10	-0,08	0,63	0,70	-0,03	1,00	-0,07	1,00				
KazaYaralamali	-0,10	0,08	-0,63	-0,70	0,03	-1,00	0,07	-1,00	1,00			
Otomobil	-0,32	0,59	-0,04	-0,05	0,11	-0,06	0,10	-0,06	0,06	1,00		
ToplamAracSayisi	-0,53	0,90	-0,01	-0,08	0,11	-0,07	0,09	-0,07	0,07	0,68	1,00	
AccDuration	-0,41	0,84	-0,01	-0,06	0,10	-0,04	0,08	-0,04	0,04	0,62	0,84	1,00

Bu araştırma kapsamında kullanılan nihai veri seti değişkenlerine korelasyon analizi uygulanmıştır. Tablo 3'te sunulan korelasyon matrisine göre -0,50 değerinden küçük ve 0,50 değerinden büyük korelasyonlar kırmızı renk ile vurgulanmaktadır. Analiz sonuçlarına göre bazı değişkenler arasında yüksek pozitif ve negatif korelasyonlar olduğu tespit edilmiştir. KazaOlumlu ile ToplamOluSayisi değişkenleri arasında +1, KazaYaralamali ile ToplamOluSayisi ve KazaOlumlu değişkenleri arasında -1, ToplamYaraliSayisi ile SonucYaraliYolcu değişkenleri arasında 0,93 değerlerinde negatif veya pozitif doğrusal bir ilişki olduğu görülmüştür. Bu durumda Multikolinerite (Multicollinearity) problemi ortaya çıkmaktadır. Multikolinerite, bir tahmin modelindeki bağımsız değişkenler arasında yüksek bir korelasyon veya ilişkinin olduğu durumu ifade etmektedir (Farrar ve Glauber, 1967). Yani, bir veya daha fazla bağımsız değişkenin diğer bağımsız değişken(ler) ile güçlü bir şekilde ilişkili olduğu durumları kapsar. Bu durum, tahmin modelinde sorunlara neden olabilir. Bu noktada, doğru bir analiz ve yüksek tahmin gücü gerçekleştirilebilmek amacıyla negatif ve pozitif korelasyona neden olan ve ayrıca model performansını olumsuz etkileyebileceği değerlendirilen SonucOluSurucu, SonucOluYolcu, SonucOluYaya, SonucYaraliYolcu, SonucYaraliYaya, KazaOlumlu, KazaYaralamali, AracSayisinaGoreKaza, ToplamAracSayisi isimli değişkenler modelden çıkarılmıştır.


Diğer bir analiz olarak konumsal analiz uygulanmıştır. Nihai veri setine göre 2013-2021 yılları arasında İstanbul'da gerçekleşen trafik kazalarının konumları Şekil 2'de görselleştirilmiştir. Google Haritalar aracılığıyla oluşturulan bu görsel, İstanbul'un farklı bölgelerindeki trafik kazalarının coğrafi olarak dağılımını göstermektedir. İlçe ve ana arter yol bazında detaylı bir analiz sunan bu harita, kaza sıklığının yoğun olduğu alanları ve güzergâhları belirlemek ve bu bölgelerdeki trafik güvenliğini artırmak için alınacak tedbirleri yönlendirmek adına değerli bir kaynak olduğu düşünülmektedir. Haritaya bakıldığında İstanbul'daki kazaların büyük bir bölümünün TEM, E-80, E5, D-100 Karayolu, Sahil Yolu isimleriyle bilinen ana arter yollarda ve E5-TEM bağlantı yollarında gerçekleştiği görülmektedir. Bu analiz, ML algoritmalarının kaza konum verileri üzerindeki rolünü değerlendirmek adına önemli ipuçları sunmaktadır. Elde edilen sonuçlar, algoritmaların belirli yıllardaki kaza eğilimlerini belirleme ve bu verilere dayanarak gelecekteki kazaları tahmin etme potansiyeline sahip olduğunu göstermektedir.

İstanbul'da 39 ilçe bulunmaktadır. Adalar hariç 38 ilçede 2013-2021 yılları arasında gerçekleşen toplam trafik kaza sayılarının görselleştirildiği grafik Şekil 3'te gösterilmektedir. Çizgi grafikte her bir nokta, o ilçede meydana gelen toplam trafik kaza sayısını temsil etmektedir. Toplam kaza sayıları değerlendirildiğinde, 4.182 ile en yüksek kaza sayısının Zeytinburnu ve ardından



Şekil 2. İstanbul'da gerçekleşen trafik kaza konumlarının coğrafi dağılımı.


3.080 ile Küçükçekmece ve 2.436 ile Fatih ilçelerinde ve en düşük kaza sayısının da 10 ile Arnavutköy ilçesinde gerçekleştiği görülmektedir. İlçelere göre gerçekleşen toplam kaza sayıları dalgalı bir dağılım göstermektedir. Bu dalgalı dağılımın sebepleri zamansal ve çevresel faktörlerdeki farklılıklar olabileceği gibi; ilçelerdeki yol ağı yapısı, kavşak ve ana arter yollara katılımların yönetimi, cazibe ve iş merkezlerine yakınlık gibi diğer faktörlerin de etkisi olabileceği değerlendirilmektedir.



Şekil 3. İstanbul'da gerçekleşen trafik kaza konumlarının coğrafi dağılımı.


Veri analizi kapsamında değerlendirilen zamansal analiz, İstanbul'daki trafik kaza verilerinin zaman içinde nasıl değiştiğini anlamak ve bu değişikliklerin trafik kaza süresine olan etkilerini incelemeyi amaçlamaktadır. Şekil 4'te görüldüğü üzere, 2013-2018 yılları arasında yukarı yönlü bir eğilimin olduğu ve toplam kaza sayılarında sürekli bir artış yaşandığı gözlemlenmiştir. 2018-2020 yılları arasında ise aşağı yönlü bir eğilim ile belirgin bir azalış yaşandığı görülmektedir. Bu yıllar arasında ve dünya genelinde yaşanan Kovid19 salgını ve sokağa çıkma yasaklarının bu düşüşte önemli bir paya sahip olabileceği değerlendirilmektedir. Bununla birlikte, 35 toplam kaza sayısı ile en düşük kazanın yaşandığı yıl 2013, 294 kaza sayısı ile en yüksek yıl 2018 olmuştur. Bu noktada, toplam kaza sayıları bakımından gözlemlenen eğilimler ve uç değerler, trafik yönetiminin ve güvenliğinin değerlendirilmesinde katkı sağlayabilir.

İstanbul'da gerçekleşen toplam trafik kaza sayılarının saatlik dilimlere göre dağılımı Şekil 5'te gösterilmektedir. Sunulan histogram, İstanbul'da meydana gelen trafik kazalarının saatlik değişimini 24 saatlik dilime göre ayrıntılı bir şekilde ortaya koymaktadır. Buna göre, 455 toplam trafik kaza sayısı ile trafik kazalarının en yoğun şekilde yaşandığı saat dilimi 08.30 ile 11.50



Şekil 4. Yıllara göre toplam kaza sayılarının dağılımı.


olarak gözlemlenmektedir. Ardından sırasıyla, 449 toplam trafik kaza sayısı ile saat 05.10 ile 08.30 arası ve 441 kaza sayısı ile saat 11.50 ile 15.10 arası gelmektedir. Özellikle, işe gidiş ve iş saatlerindeki yoğunluğun kazalar üzerindeki etkileri dikkat çekmektedir. Diğer açıdan, 101 toplam trafik kaza sayısı ile 22.30 ile 01.50 saatleri arası, trafik kazalarının en az yaşandığı saat dilimi olmuştur. Bu bulgular, trafik kazalarını azaltma çabalarının saatlik dinamiklere yönelik daha spesifik ve hedefli bir şekilde planlanmasına olanak tanımaktadır. Saatlik değişimin detaylı bir analizi, trafik güvenliği uygulamalarının daha etkin bir şekilde uyarlanabilmesi için önemli bir temel sunmaktadır.



Şekil 5. Saat aralıklarına göre toplam kaza sayılarının dağılımı.


Bu bölümde sunulan Şekil 6, İstanbul'da meydana gelen trafik kaza sürelerinin yıllara göre nasıl bir dağılım gösterdiğini görselleştirmektedir. Grafik üzerinden elde edilecek bilgiler, trafik kazalarının sürelerinin yıllar arasında nasıl bir dağılım gösterdiğini anlamak açısından değerli ipuçları sunmaktadır. Örneğin, 2013 yılından 2018 yılına kadar toplam kaza sürelerinde düzenli bir artış yaşandığı görülmektedir. 2018 yılından 2020 yılına kadar ise belirgin bir azalış yaşandığı gözlemlenmektedir. Bu yıllar arasında ve dünya genelinde yaşanan Covid19 salgını ve sokağa çıkma yasaklarının bu düşüşte önemli bir paya sahip olabileceği değerlendirilmektedir. Ek olarak, toplam kaza süresinin en düşük olduğu yıl 2013 iken, en yüksek yıl 2018 olmuştur. Bahsi geçen yıllardaki kaza sürelerinde gözlemlenen artışlar veya azalmalar, trafik güvenliği üzerinde etkili olan faktörlerin belirlenmesine katkıda bulunabilir. Bu noktada, trafik kazalarının ve sebep oldukları trafik sıkışıklıklarından kaynaklanan zamansal, çevresel ve

ekonomik kayıplar düşünüldüğünde, kaza sürelerini en aza indirme çabaları her geçen gün değer kazanmaktadır. Ayrıca, değişimlerin veya belirli dönemlerdeki eğilimlerin, kaza sürelerini nasıl etkilediğini anlamak, trafik güvenliği politikalarının planlanması açısından da önem taşımaktadır.



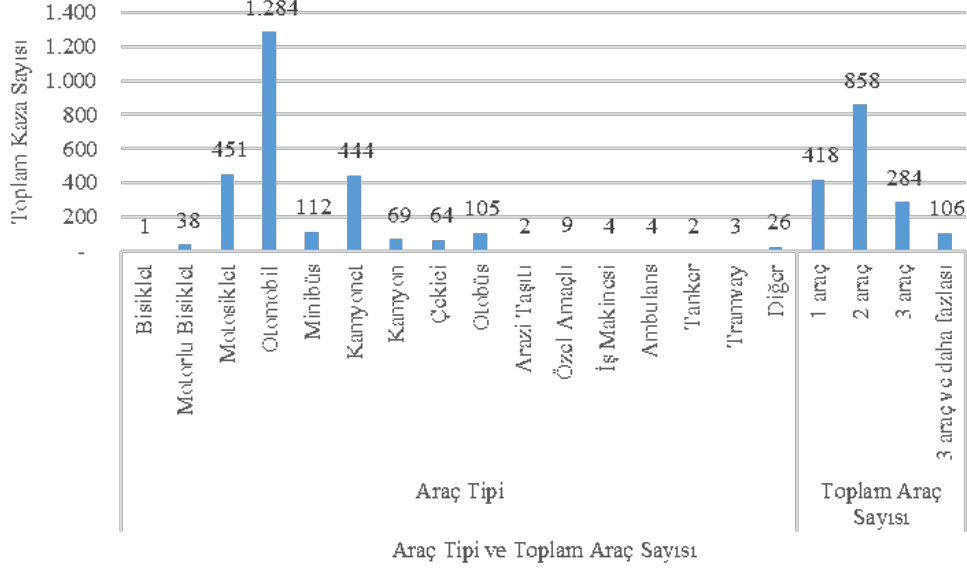
Şekil 6. Yıllara göre toplam kaza sürelerinin dağılımı.

Bu bölüm, İstanbul'daki trafik kazalarının yıllık değişimine odaklanarak özellikle kaza şiddetinin nasıl evrildiğini anlamayı amaçlamaktadır. Şekil 7'de, yıl bazlı trafik kazalarında gerçekleşen toplam yaralı ve ölü sayıları sunulmaktadır. Grafiğe bakıldığında, 2013 yılı içerisinde yaşanan trafik kazalarının toplam şiddeti 66 yaralı ve 1 ölü olarak gerçekleşmiştir. 2013 yılından 2018 yılına dek ölü ve yaralı sayıları bakımından kazaların şiddeti artmıştır. 2018 yılı, toplam kaza şiddeti 512 yaralı ve 12 ölü ile en yüksek yaralı ve ölü sayısına sahip yıl olarak değerlendirilmektedir. 2018 yılından 2020 yılına kadar az da olsa sürekli bir düşüş yaşandığı görülmektedir. Bu yıllar arasında ve dünya genelinde yaşanan Kovid19 salgını ve sokağa çıkma yasaklarının bu düşüşte önemli bir paya sahip olabileceği değerlendirilmektedir.



Şekil 7. Yıllara göre trafik kazalarında gerçekleşen toplam yaralı ve ölü sayıları.

Diğer bir açıdan, araç tipi bazlı trafik kaza analizi gerçekleştirildiğinde, farklı araç kategorilerinin trafik kazalarına olan etkisi görülmektedir. Bu bağlamda; otomobiller, kamyonlar, motosikletler, bisikletler gibi farklı araç tiplerinin kazalara karışma oranları ve bu kazalardaki rolü incelenmektedir. Grafiğe bakıldığında, kazalara en sık karışan ilk üç araç tipinin sırasıyla otomobil, kamyonet ve motosiklet olduğu görülmektedir. Araç tipi bazlı analiz, kazaların spesifik araç kategorileri için nasıl farklılık gösterdiğini anlamak açısından önemlidir. Araç tipi ve toplam araç sayısına göre toplam kaza sayısı dağılımını gösteren grafik Şekil 8'de gösterilmektedir.



Şekil 8. Araç tipi ve toplam araç sayısına göre toplam kaza sayısı dağılımı.

3.3. Modelleme

Bu araştırma, elde edilen veri setinin yapısı ve ele alınan probleme göre denetimli bir regresyon ML tekniğini gerektirmektedir. Veri setindeki bağımlı değişkenin sürekli bir değer olması gereken durumlarda kullanılan bu algoritmalar, veri analizi ve tahmin yetenekleriyle ön plana çıkmaktadırlar. Bu çalışmada etiketlenmiş bir veri seti üzerinde denetimli öğrenme kapsamında regresyon algoritmaları kullanılmıştır. Birçok denetimli regresyon tekniği mevcut olsa da bu çalışmada, literatürde oldukça yaygın olarak kullanılan ve bu çalışmanın sonuçlarının literatür ile karşılaştırılabilmesi için ET ve NN algoritmaları kullanılmış ve performansları karşılaştırılmıştır.

3.3.1. Topluluk Ağacı Modelleme

ET yöntemi, genellikle birden fazla karar ağacının bir araya getirilmesiyle oluşturulan bir topluluk öğrenme yöntemidir. Bu teknik, RF ve gradyan artırma ağaçları gibi modellerle uygulanır. ET, tek bir karar ağacının gücünü ve genelleme yeteneğini artırmak için bir araya getirilen bir dizi ağacı içerir. Her bir ağaç, farklı bir alt küme veri üzerinde eğitilir ve bu nedenle farklı özellikleri veya örüntüleri öğrenir. Sonuç olarak ET, her bir ağacın gücünü bir araya getirerek daha kararlı ve geliştirilmiş bir tahmin elde eder. ET'nin avantajlarından biri, aşırı öğrenme/uyum (overfitting) riskini azaltma yetenekleridir. Her bir ağaç, yalnızca rastgele örneklemeler üzerinde eğitildiği için, her ağaç genellikle farklı özellikleri veya örüntüleri öğrenir. Bu da topluluk olarak bir araya getirildiğinde, genelleme yeteneği daha yüksek bir model elde edilmesini sağlar. Ayrıca ET, büyük veri kümeleriyle çalışırken yüksek performans sağlar. Paralel hesaplama yeteneklerinden dolayı, büyük veri kümelerinde hızlı ve etkili bir şekilde çalışabilirler. Ancak ET algoritmasında dikkate alınması gereken bazı hususlar vardır. Örneğin, modelin karmaşıklığını artırabilirler ve anlaşılması ve yorumlanması daha zor olabilir. Ayrıca, bazı durumlarda eğitim süreçleri daha uzun olabilir ve daha fazla hesaplama gücü gerektirebilir.

ET içerisinde iki tür vardır: torbalanmış (bagged) ağaçlar ve güçlendirilmiş (boosted) ağaçlar. Torbalanmış ağaçlar, diğer adıyla RF, bir ağaçta birçok bootstrap geliştirerek ve ardından bunları karar ağacında birleştirerek toplulukta farklı modeller oluşturur. Nihai karar, ağacın nihai kararının ortalaması alınarak hesaplanır. Güçlendirilmiş ağaçlar da iki adımdan oluşan bir regresyon ağaçları topluluğudur. İlk olarak, bir dizi ortalama performans gösteren model üretmek için orijinal verilerin alt kümelerini

kullanır. Daha sonra, belirli bir maliyet fonksiyonu kullanarak bunları bir araya getirerek performanslarını artırır. Genel olarak, bir RF modelinin matematiksel gösterimi Denklem 3'te sunulmaktadır.

$$y(x) = \frac{1}{B} \sum_{i=1}^B T_i(x) \quad (3)$$

Bu gösterimde; $y(x)$ verilen giriş örneği x için yapılan tahmini çıktı değerini temsil eder. B modelde kullanılan ağaçların sayısını belirtir, $T_i(x)$ i numaralı ağacın giriş örneği x için yaptığı tahmini ifade etmektedir.

3.3.2. Sinir Ağları Modelleme

NN, ML içerisindeki en güçlü ve esnek araçlardan biridir. Biyolojik sinir ağlarının çalışma prensiplerinden esinlenerek tasarlanmışlardır. NN, karmaşık veri yapılarını öğrenmek, sınıflandırmak ve tahmin etmek için kullanılırlar. Görsel tanıma, doğal dil işleme, ses tanıma, oyun stratejileri ve daha birçok alanında başarıyla uygulanmışlardır. NN, birçok nöron adı verilen basit birimlerden oluşur. Bu nöronlar, girdi verilerini alır, bunları işler ve sonuçları bir çıktıya dönüştürürler. NN'nin temel yapı taşı olan bu nöronlar, girdilerle çıktılar arasında ağırlıklarla ayrılmış bağlantılarla ilişkilidir. Nöronlar, bu bağlantıları ve ağırlıkları kullanarak girdileri işler ve sonuç olarak bir çıktı üretirler. NN genellikle katmanlar halinde düzenlenir. En basit NN yapısı olan tek katmanlı bir yapıdan, çok katmanlı derin sinir ağlarına kadar çeşitli yapılar mevcuttur. En yaygın yapı olan çok katmanlı yapılarda, girdi katmanı, gizli katmanlar ve çıktı katmanı bulunur. Her katman, önceki katmanın çıktılarını alır, işler ve sonuçları bir sonraki katmana iletir.

NN genellikle bir eğitim sürecinden geçirilir. Bu süreçte, ağa verilen eğitim verisi üzerinde öğrenme gerçekleşir. Ağın çıktıları, gerçek etiketler veya hedeflerle karşılaştırılır ve bu karşılaştırmaların sonucunda ağın içindeki parametreler, özellikle de bağlantı ağırlıkları, güncellenir. Bu güncellemeler, ağın daha doğru tahminler yapmasını sağlamak için gerçekleştirilir. Eğitim süreci, genellikle geri yayılım (backpropagation) adı verilen bir algoritma ile gerçekleştirilir. NN, esneklikleri ve genelleyebilme yetenekleri nedeniyle birçok uygulama alanında büyük başarı elde etmişlerdir. Ancak, büyük miktarda veri ve hesaplama gücü gerektirebilirler. Bu nedenle, NN genellikle büyük ölçekli problemlerle ve DL gibi karmaşık algoritmalarla ilişkilendirilirler. Son yıllarda, DL teknikleriyle birlikte, NN özellikle görsel tanıma, doğal dil işleme ve oyun yapay zekası gibi alanlarda devrim niteliğinde ilerlemeler kaydetmiştir. NN'nin matematiksel olarak ifade edilen temel bir formülü, bir sinir hücresinin çıktısını hesaplamak için kullanılan işlemi tanımlar. Genel olarak, bir sinir hücresinin çıktısı Denklem 4'te sunulmaktadır.

$$y = f(\sum_{i=1}^n w_i x_i + b) \quad (4)$$

Bu gösterimde; y sinir hücresinin çıktısını, f aktivasyon fonksiyonunu (Bu fonksiyon, sinir hücresinin çıktısını belirli bir aralığa sıkıştırmak için kullanılır. Örnek olarak sigmoid, ReLU, tanh gibi fonksiyonlar kullanılabilir.), x_i girdi değerini ve w_i girdinin ağırlığını, b bias terimini (Bu terim, sinir hücresinin girdilerine eklenen sabit bir değerdir.) temsil etmektedir.

3.3.3. Performans Ölçüm Metrikleri

Model performansını değerlendirmek için kullanılan ölçüm metrikleri, modelin tahmin yeteneğini değerlendirmek için kullanılan kıstaslardır. Bu çalışmada uygulanan algoritmaların performans ölçümleri için R^2 , MSE, RMSE ve MAE metrikleri kullanılmıştır. R-Kare Belirleme Katsayısı (R^2), regresyon modelinin bağımsız değişkenlerle bağımlı değişken arasındaki varyansın ne kadarını açıkladığını ölçen bir metriktir. Başka bir deyişle, R^2 bağımsız değişkenin bağımlı değişkendeki toplam değişikliklerin yüzdesini açıklayabildiğini gösterir. Değerleri 0 ile 1 arasında değişir, 1'e yaklaştıkça modelin daha iyi performans sergilediğini gösterir. MSE, hataların karesinin ortalamasını hesaplar ve modelin performansını değerlendiren bir diğer önemli metriktir. MSE, modelin gerçek değerlerle tahmin ettiği değerler arasındaki ortalama karesel farkı ölçen bir metriktir. Düşük MSE değerleri, modelin daha iyi tahminler yaptığını gösterir. MSE, büyük hatalara daha fazla vurgu yapar ve bu nedenle aykırı değerlerin etkisini daha fazla hisseder. RMSE, MSE'nin karekökünü ifade eder. Regresyon modellerinin performansını değerlendirmek için kullanılan bir ölçüm metriği olan RMSE, modelin gerçek değerlerle tahmin ettiği değerler arasındaki hata miktarını ölçer. Bu metrik, modelin tahminlerinin gerçek değerlere olan yakınlığını ifade eder ve hata miktarını bir sayısal değerle temsil eder. RMSE'nin hesaplanması, modelin ne kadar başarılı olduğunu anlamamıza yardımcı olur. RMSE sifra yaklaştıkça hata oranı azalır. Bu çalışmada kullanılan performans ölçüm metrikleri ve matematiksel gösterimleri Tablo 4'te sunulmaktadır.


Tüm bu metrikler, İstanbul'daki trafik kaza verilerine dayalı regresyon modellerinin performansını objektif bir şekilde değerlendirmek ve modelin tahmin yeteneklerini anlamak için kullanılmıştır. Elde edilen sonuçlar, trafik kaza sürelerini tahmin etmek amacıyla geliştirilen regresyon modellerinin güvenilirliğini değerlendirmede önemli bir rol oynamaktadır.

Tablo 4. Performans ölçüm metrikleri ve matematiksel gösterimleri.

Performans Ölçüm Metrikleri	Matematiksel Gösterim	Açıklama	Referans
R-Kare Belirleme Katsayısı (R^2)	$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y}_i)^2}$	n gözlem sayısı, y_i gerçek değerler, \hat{y}_i modelin tahmin ettiği değerler \bar{y}_i gerçek değerlerin ortalaması	(Barrett, 2000; Di Bucchianico, 2008)
Ortalama Kare Hata (MSE)	$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2$	n gözlem sayısı, y_i gerçek değerler \hat{y}_i modelin tahmin ettiği değerler	(Hyndman ve Koehler, 2006; Makridakis ve diğerleri, 1982)
Kök Ortalama Kare Hata (RMSE)	$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}$	n gözlem sayısı, y_i gerçek değerler \hat{y}_i modelin tahmin ettiği değerler	(Hyndman ve Koehler, 2006; Nevitt ve Hancock, 2000)
Ortalama Mutlak Hata (MAE)	$MAE = \frac{1}{n} \sum_{i=1}^n y_i - \hat{y}_i $	n gözlem sayısı, y_i gerçek değerler \hat{y}_i modelin tahmin ettiği değerler	(Hyndman ve Koehler, 2006; Sammut ve Webb, 2010)

4. Bulgular


Bulgular bölümünde, uygulanan regresyon temelli ML algoritmalarının performans sonuçlarına odaklanılmaktadır. ML algoritmalarının eğitim ve test süreçlerinde MATLAB R2023b kullanılmıştır. MATLAB, veri analizi ve ML uygulamalarında yaygın olarak tercih edilen bir araçtır ve bu araştırma kapsamında elde edilen sonuçların değerlendirilmesinde temel bir rol oynamıştır. Bu araştırma kapsamında MATLAB R2023b içerisinde kullanılan araç kutularına ait görseller Şekil 9'da sunulmaktadır.

**Şekil 9.** MATLAB R2023b içerisinde kullanılan araçlar.

Bu bölümde sunulan performans sonuçları, trafik kaza sürelerini tahmin etme amacıyla geliştirilen modellerin etkinliği, doğruluğu ve güvenilirliği hakkında detaylı bir perspektif sağlamaktadır. Elde edilen bulgular, bu modellerin pratik uygulamalarda ne kadar başarılı olabileceği konusunda önemli bir temel oluşturacaktır. Bu araştırma kapsamında kullanılan nihai veri setine ait trafik kaza sürelerini gösteren grafik Şekil 10'da sunulmaktadır.

4.1. Eğitim ve Test Veri Seti Dağılımları

Bu bölümde, uygulanan ML algoritmalarının eğitim ve test süreçlerinde kullanılan veri setlerinin sayıları ve oranları incelenmiştir. Elde edilen sonuçlar, başarımların değerlendirilmesi açısından kritik öneme sahiptir. Bu araştırma kapsamında kullanılan nihai veri seti %80 oranında eğitim ve %20 oranında test seti olmak üzere ayrılmıştır. ML algoritmaları için kullanılan eğitim ve test veri seti sayıları ile oranları Tablo 5'te sunulmaktadır. Bu tabloda, her iki regresyon algoritmasının öğrenme sürecinde ne kadar veriye dayandığı ve bu verilerin hangi oranda test edildiği gösterilmektedir.



Şekil 10. Nihai veri setine göre gerçekleşen kaza sürelerinin dağılımı.

Tablo 5. Eğitim ve test veri seti örneklem sayıları ve oranları.

Set Türü	Kaza Örneklem Sayısı	Oran
Eğitim Seti	1.524	%80
Test Seti	381	%20
Toplam	1.905	%100

4.2. Model ve Performans Optimizasyonu

Regresyon modelleme süreçleri, kullanılan algoritmanın temel yapılandırma ayarlarından başlayarak, modelin genel performansını artırmaya yönelik gerçekleştirilen optimizasyon adımlarıyla devam etmiştir. Bu aşama, her bir regresyon algoritmasının en iyi performansı elde etmek üzere ayarlandığı kritik bir aşamadır. Regresyon temelli ML algoritmaları ve modellerinin performans optimizasyonu için K-Katlı Çapraz Doğrulama Yöntemi, PCA, FS ve Optimize Edici olmak üzere farklı analizler bulunmaktadır.

4.2.1. K-Katlı Çapraz Doğrulama Yöntemi

Geliştirilen bir tahmin modelinin doğruluğunu artırmak için çeşitli tekniklerin uygulanabilmektedir. Bu tekniklerden biri olan k-katlı çapraz doğrulama yöntemi (k-fold cross validation), modelin performansının güvenilir bir şekilde değerlendirilebilmesi için önemli bir araçtır. Bu araştırma kapsamında 5-katlamalı çapraz doğrulama yöntemi kullanılmıştır. 5-katlamalı çapraz doğrulama, veri setinin beş eşit parçaya ayrılmasını içeren bir tekniktir. Bu parçalardan biri test veri seti olarak kullanılırken, geriye kalan dört parça eğitim veri seti olarak kullanılır. Ardından, model eğitilir ve test edilir ve bu işlem beş kez tekrarlanır, her seferinde farklı bir parça test veri seti olarak seçilir. Her bir test işlemi sonucunda elde edilen performans ölçümleri ortalaması alınarak modelin genel performansı hesaplanır. Bu yöntemin temel avantajlarından biri, veri setinin tamamının eğitim ve test için kullanılmasını sağlamasıdır. Bu, modelin farklı veri kesitlerine karşı ne kadar iyi performans gösterdiğini daha güvenilir bir şekilde değerlendirmemizi sağlar. Ayrıca, veri setinin her parçasının hem eğitim hem de test amaçlı kullanılması, modelin aşırı öğrenme riskini de azaltır.

4.2.2. Temel Bileşenler Analizi

Regresyon modellemelerinde PCA, kullanılan değişkenlerin model üzerindeki etkisini anlamak adına önemli bir adımdır. Gerçekleştirilen tahmin modeli denemeleri neticesinde, PCA analizinin tahmin performansını yaklaşık %5-10 oranında olumlu yönde etkilediği gözlemlenmiştir. Bu nedenle kullanılan her iki regresyon temelli ML algoritmalarında PCA analizi gerçekleştirilmiştir. PCA sonuçlarına odaklanarak, regresyon modellerinin hangi değişkenler üzerinde yoğunlaştığı ve bu değişkenlerin tahmin gücünün ne olduğu görülebilmektedir. PCA, en az %95 oranında varyansı açıklayacak düzeyde uygulanmıştır. Araştırma kapsamında kullanılan nihai veri seti içerisinde yeterli düzeyde nümerik tahmin edici bulunmaktadır. Dolayısıyla, PCA %95 varyansı açıklamak için yeterli bileşeni tutmaktadır. Veri setinde bulunan 28 kategorik öngörücünün (predictors) tamamı PCA uygulanmadan modelde kullanılmıştır. Kategorik değişkenlere PCA uygulanmamaktadır.

4.2.3. Özellik Seçimi

Her bir regresyon modelleme yönteminde, kullanılan özelliklerin seçimi üzerine özel bir vurgu yapılmıştır. FS adımları, modelin karmaşıklığını azaltmak, aşırı öğrenmeyi önlemek ve tahmin gücünü artırmak amacıyla gerçekleştirilmiştir. Gerçekleştirilen tahmin modeli denemeleri neticesinde, FS analizlerinin tahmin performansını yaklaşık %3-5 oranında etkilediği gözlemlenmiştir. Regresyon temelli algoritmaların tamamında kullanılan FS analizi kapsamında seçilen değişkenler, gerçekleştirilen testler ve değişkenlerin skorları Tablo 6'da sunulmaktadır. Araştırma kapsamında uygulanan regresyon algoritmaları için FS analizinde F Test skorları kullanılmıştır ve buna göre sıfırdan büyük skora sahip olan 46 farklı değişken, modellerin eğitiminde ve testinde kullanılmak üzere belirlenmiştir.

Tablo 6. Özellik seçimi analizi kapsamında gerçekleştirilen test skorları.

F Test		MRMR	
Sıra No.	Değişken Adı	Sıra No.	Değişken Adı
1	Otomobil	1	Kazalcesi
2	KazaOlusTuru	2	Otomobil
3	Kazalcesi	3	KazaOlusTuru
4	Kamyonet	4	Kamyonet
5	CarpismaYeri	5	Minibus
6	YolunSinifi	6	ToplamOluSayisi
7	Minibus	7	Motosiklet
8	Motosiklet	8	AraziTasiti
9	ToplamYaraliSayisi	9	Cekici
10	GeoGecit	10	Kamyon
11	HasarGorenUnsur	11	CarpismaYeri
12	OtoKorkuluk	12	Tanker
13	Kamyon	13	MotorluBisiklet
14	TrafikLambasi	14	DigerArac
15	TrafikIsaretLevhasi	15	HasarGorenUnsur
16	AraziTasiti	16	GeoGecit
17	GeoYatay	17	YolunYuzeyi
18	DigerArac	18	ToplamYaraliSayisi
19	YolGenisligi	19	GeoYatay
20	GeoKavsak	20	IsMakinesi
21	YolunYuzeyi	21	GeoKavsak
22	ToplamOluSayisi	22	Otobus
23	YoldaCalisma	23	YolunSinifi
24	TrafikGorevlisi	24	Tramvay
25	IsMakinesi	25	Bisiket
26	YayaYolu	26	TrafikIsaretLevhasi

Tablo 6. Devamı.

27 EmniyetSeritiBanket	1,6662	27 YolGenisligi	0,0031
28 Cekici	1,3070	28 OtoKorkuluk	0,0027
29 KazaYolKusuru	1,2793	29 TrafikLambasi	0,0023
30 GeoDiger	1,0779	30 HavaDurumu	0,0010
31 Tanker	1,0232	31 OzelAmacli	0,0008
32 HavaDurumu	0,6768	32 YayaYolu	0,0006
33 YolSeritCizgisi	0,5721	33 Ambulans	0,0005
34 MotorluBisiklet	0,5264	34 GeoDusey	0,0004
35 Tramvay	0,5220	35 TrafikGorevlisi	0,0001
36 ilkYardm	0,5070	36 YoldaCalisma	0,0000
37 OzelAmacli	0,4454	37 YolSeritCizgisi	0,0000
38 YolKaplama	0,4228	38 KazaYoIKusuru	0,0000
39 GeoDusey	0,3902	39 Aydinlatma	0,0000
40 GunDurumu	0,2983	40 YolKaplama	0,0000
41 KazaYerlesimYeri	0,1763	41 ilkYardm	0,0000
42 Aydinlatma	0,0629	42 KazaYerlesimYeri	0,0000
43 YolunTipi	0,0207	43 YolunTipi	0,0000
44 Bisiklet	0,0200	44 GeoDiger	0,0000
45 Ambulans	0,0152	45 GunDurumu	0,0000
46 Otobus	0,0016	46 EmniyetSeritiBanket	0,0000
47 GoruseEngelCisim	0,0000	47 GoruseEngelCisim	0,0000
48 AtArabasi	0,0000	48 AtArabasi	0,0000
49 Traktor	0,0000	49 Traktor	0,0000
50 Tren	0,0000	50 Tren	0,0000
51 ElektrikliSkuter	0,0000	51 ElektrikliSkuter	0,0000

4.2.4. Hiperparametreler ve Optimize Edici

Hiperparametreler, modelin geliştiricisi tarafından eğitim öncesinde belirlenen parametrelerdir. Bu parametreler, modelin ilk yapılandırılmasını ve eğitim sürecinin başlangıcındaki ayarlarını ifade eder. Model parametrelerinden farklı olarak, hiperparametreler eğitim aşamasında öğrenilmez. Model parametreleri, eğitim süreci ilerledikçe veriye uyum sağlayabilirken, hiperparametreler sabit kalır ve modelin temel yapılandırmasını belirler. Regresyon temelli bazı algoritmalarda hiperparametreler kullanılabilir ve farklı ayarlamalar yapılarak modellerin tahmin gücü artırılabilir. Bu çalışmada uygulanan modellere ait hiperparametre özellikleri ilgili model başlığının altında sunulmaktadır. Diğer yandan, optimize seçenekleri yalnızca optimize edilebilir modeller için geçerlidir. Bu çalışmada uygulanan her iki regresyon temelli ML algoritmalarında da optimize edici (optimizer) kullanılmamıştır.

4.3. Topluluk Ağacı Model Sonuçları


ET modeli, eğitim ve test aşamalarındaki performans sonuçları ile trafik kaza sürelerini tahmin etme yeteneğini yansıtmaktadır. Model, eğitim sürecinde ortalama RMSE: 8.0549 birimlik bir hata payıyla ve R-Kare: 0.85 değeriyle doğrulama veri setine uygunluk sağlamıştır. Test sonuçlarına baktığımızda, modelin gerçek verilere uyum sağlamada devam ettiği görülmektedir. Test veri setinde elde edilen RMSE: 8.1325 birimlik değeri ve R-Kare: 0.84 değeri, modelin genel performansının oldukça etkileyici olduğunu göstermektedir. Diğer yandan, ET modeli önceden ayarlanmış hiperparametrelerle Boosted Trees kullanılarak oluşturulmuştur. Model, minimum 8 yaprak sayısı ile ağaçları güçlendirmek ve genel performansı artırmak amacıyla 30 öğrenciyi (learner) içermektedir. ET modeline ait genel sonuçlar ve detaylar Tablo 7'de gösterilmektedir.

Eğitim süresi 48.307 sn., tahminleme hızı 2800 gözlem/sn. (saniye başına gözlem sayısı — observations per second - obs/sec) olarak hesaplanmış ve eğitim süreci, modelin doğrulama seti üzerindeki performansını optimize etmeye yönelik gerçekleştirilmiştir. Model, eğitim veri setini hızlı bir şekilde öğrenmiş ve sıkça güncellenmiştir. Eğitim sonuçlarına göre diğer performans metrikleri MSE: 64.882 ve MAE: 4.4869 olarak gerçekleşmiştir. Modelin test sonuçları, gerçek dünya verilerine uygulandığında elde edilen başarıyı temsil etmektedir. Test setindeki RMSE: 8.1325 birimlik değeri ve R-Kare: 0.84 değeri, modelin tahmin yeteneğinin oldukça başarılı olduğunu göstermektedir. Test sonuçlarına göre diğer performans metrikleri MSE: 66.138 ve MAE: 4.4097 olarak gerçekleşmiştir. Bu performans çıktıları, ET modelinin trafik kaza sürelerini tahmin etme konusundaki başarısını yansıtmaktadır.

Tablo 7. ET model sonuçları.

Model 2.1: ET		
Durum: Test edildi		
Eğitim Sonuçları	Test Sonuçları	Model Hiperparametreleri
RMSE (Eğitim) : 8.0549	RMSE (Test) : 8.1325	Ön Ayar : Boosted Trees
R-Kare (Eğitim) : 0.85	R-Kare (Test) : 0.84	Minimum Yaprak Boyutu : 8
MSE (Eğitim) : 64.882	MSE (Test) : 66.138	Öğrenici Sayısı : 30
MAE (Eğitim) : 4.4869	MAE (Test) : 4.4097	Öğrenme Oranı : 0.1
Tahminleme Hızı : ~2800 gözlem/sn.		Örneklenecek Tahminci Sayısı : Tümüni Seç
Eğitim Süresi : 48.307 sn.		
Model Boyutu (Kompakt) : ~940 KB		

Eğitim ve test sonuçlarına göre gerçek değerler ile tahmin edilen değerler, hata oranı ve artıkların gösterildiği performans grafikleri Şekil 11’de sunulmaktadır.



Şekil 11. ET modeli eğitim ve test performans sonuçlarının görselleştirilmesi.

Şekil 11’de sunulan ve devam eden bölümde de aynı şekilde altı adet grafik olarak sunulacak olan şekillere ait açıklamalar aşağıdaki gibidir:

a. Gözlem ve tahmin değerleri dağılımı (Eğitim): Bu grafik, eğitim veri seti içerisindeki gözlemlenen kaza süresi değerleri ile ilgili ML modelinin tahmin sonuçlarından elde edilen yanıt (response) değerlerinin dağılımını göstermektedir.

b. Gözlem ve tahmin değerleri hata dağılımı (Eğitim): Bu grafik, eğitim veri seti içerisindeki gözlemlenen kaza süresi değerleri ile ilgili ML modelinin tahmin sonuçlarından elde edilen yanıt (response) değerlerinin dağılımını ve bu değerler arasındaki hata düzeylerini göstermektedir.

c. Gözlem ve tahmin değerleri karşılaştırması (Eğitim): Bu grafik, eğitim veri seti içerisindeki gözlemlenen kaza süresi değerlerinin tahmin edilen değerlerle mükemmel tahmin eğrisine (köşegen) göre karşılaştırılmasını göstermektedir.

d. Artık değer dağılımı (Eğitim): Bu grafik, eğitim veri seti içerisindeki gözlemlenen kaza süresi değerleri ile modelin tahmin değerleri arasındaki kaza süresi farkını göstermektedir.

e. Gözlem ve tahmin değerleri karşılaştırması (Test): Bu grafik, test veri seti içerisindeki gözlemlenen kaza süresi değerlerinin tahmin edilen değerlerle mükemmel tahmin eğrisine (köşegen) göre karşılaştırılmasını göstermektedir.

f. Artık değer dağılımı (Test): Bu grafik, test veri seti içerisindeki gözlemlenen kaza süresi değerleri ile modelin tahmin değerleri arasındaki kaza süresi farkını göstermektedir.

4.4. Sinir Ağları Model Sonuçları

NN modelinin eğitim ve test aşamalarındaki performans sonuçları, trafik kaza sürelerini tahmin etme yeteneğini göstermektedir. Model, eğitim sürecinde ortalama RMSE: 9.778 birimlik bir hata payıyla ve R-Kare: 0.78 değeriyle doğrulama veri setine uygunluk sağlamıştır. Test sonuçlarına baktığımızda, modelin gerçek verilere uyum sağlamada devam ettiği görülmektedir. Modelin test sonuçları, gerçek dünya verilerine uygulandığında elde edilen başarıyı temsil etmektedir. Test veri setinde elde edilen RMSE: 7.9798 birimlik değeri ve yüksek R-Kare: 0.85 değeri, modelin genel performansının güçlü olduğunu göstermektedir. Diğer yandan, NN model mimarisi geniş bir yapıya sahiptir. Tam bağlantılı tek bir katman içeren bu model, 100 birimlik ilk katman boyutu ve ReLU aktivasyon fonksiyonu kullanmaktadır. Modelin iterasyon sınırlaması 1000, düzenleme katsayısı (Lambda) ise 0 olarak belirlenmiştir. NN modeline ait genel sonuçlar ve detaylar Tablo 4.4'te gösterilmektedir.

Tablo 8. NN model sonuçları.

Model 2.1: NN		
Durum: Test edildi		
Eğitim Sonuçları	Test Sonuçları	Model Hiperparametreleri
RMSE (Eğitim) : 9.778	RMSE (Test) : 7.9798	Standardizasyon : Evet
R-Kare (Eğitim) : 0.78	R-Kare (Test) : 0.85	İlk Katman Boyutu : 100
MSE (Eğitim) : 95.61	MSE (Test) : 63.677	Aktivasyon : ReLU
MAE (Eğitim) : 6.3111	MAE (Test) : 5.1563	Yineleme Sınırı : 1000
Tahminleme Hızı : ~3200 gözlem/sn.		Tam Bağlı Katman Sayısı : 1
Eğitim Süresi : 486.56 sn.		Ön Ayar : Geniş Sinir Ağları
Model Boyutu (Kompakt) : ~165 KB		Düzenleme Kuvveti (Lambda) : Otomatik

Eğitim süresi 486.56 sn., tahminleme hızı 3200 gözlem/sn. olarak hesaplanmış ve eğitim süreci, modelin doğrulama seti üzerindeki performansını optimize etmeye yönelik gerçekleştirilmiştir. Model, eğitim veri setini hızlı bir şekilde öğrenmiş ve sıkça güncellenmiştir. Eğitim sonuçlarına göre diğer performans metrikleri MSE: 95.61 ve MAE: 6.3111 olarak gerçekleşmiştir. Modelin test sonuçları, gerçek dünya verilerine uygulandığında elde edilen başarıyı temsil etmektedir. Test setindeki RMSE: 7.9798 birimlik değeri ve R-Kare: 0.85 değeri, modelin tahmin yeteneğinin oldukça başarılı olduğunu göstermektedir. Test sonuçlarına göre diğer performans metrikleri MSE: 63.677 ve MAE: 5.1563 olarak gerçekleşmiştir. Bu performans çıktıları, NN modelinin trafik kaza sürelerini tahmin etme konusundaki başarısını yansıtmaktadır. Eğitim ve test sonuçlarına göre gerçek değerler ile tahmin edilen değerler, hata oranı ve artıkların gösterildiği performans grafikleri Şekil 12'de sunulmaktadır.

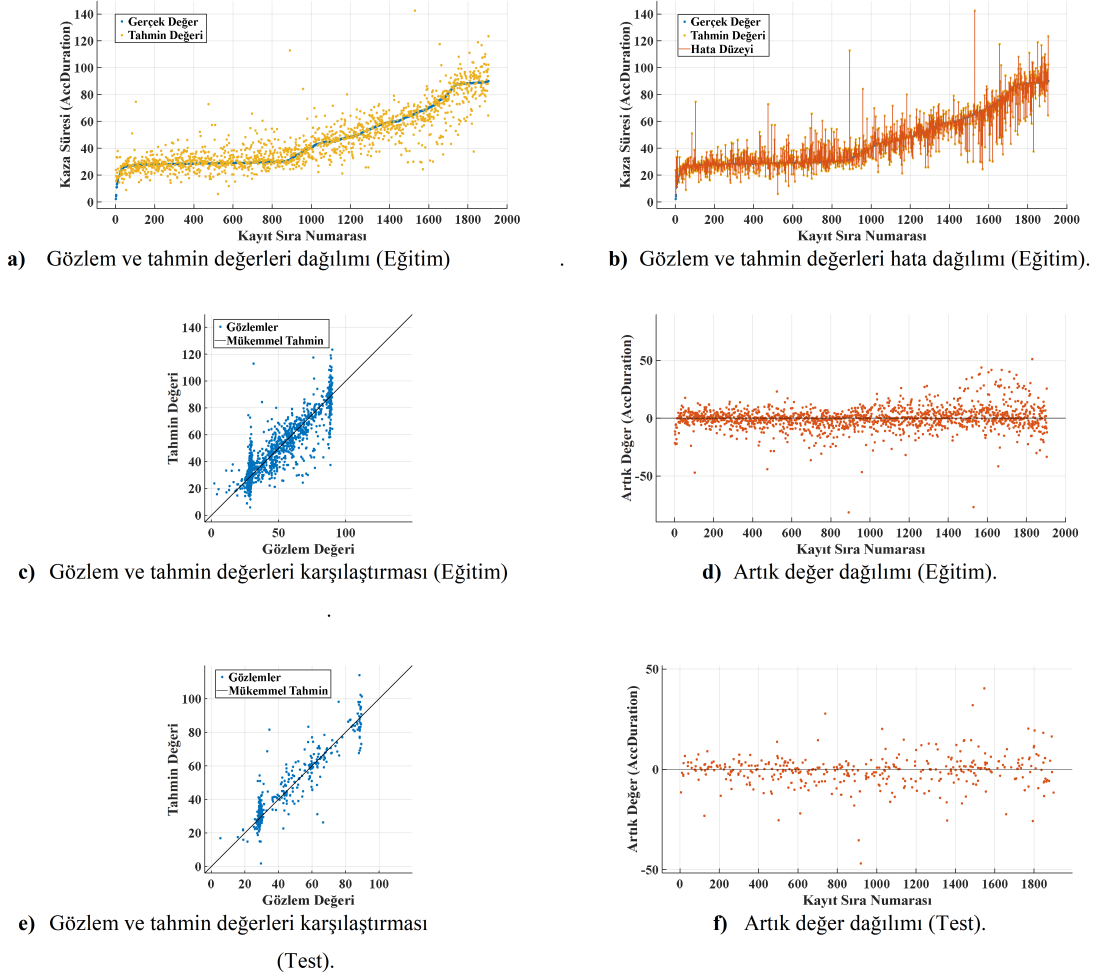
4.5. Model Performans Karşılaştırması

Bu bölümde, ET ve NN regresyon temelli ML algoritmalarının performansları karşılaştırılmıştır. Bu çalışmada uygulanan algoritmaların eğitim sonuçlarına göre daha başarılı algoritma R-Kare: 0.85 ile ET olurken, test sonuçlarına göre daha başarılı algoritma R-Kare: 0.91 ile NN olmuştur. Karşılaştırmalardan çıkan sonuçlara göre, her bir modelin avantajları ve dezavantajları bulunmaktadır. En iyi model seçimi, belirli bir uygulamanın gereksinimlerine ve veri yapısına bağlı olarak yapılmalıdır.

ET modeli, yüksek performans sergileyerek eğitim setinde RMSE: 8.05 ve MSE: 64.88 ile düşük hata oranlarına ulaşmıştır. Eğitim sonuçlarına göre R-Kare: 0.85 değeri ile daha başarılı tahmin modeli ET olmuştur. Test setindeki RMSE: 8.13 ve MSE: 66.14 değerleri, modelin genelleme yeteneğini göstermektedir. R-Kare değerleri, modelin veriyi ne kadar iyi açıkladığını gösterir. Eğitim setindeki R-Kare: 0.85 ve test setindeki R-Kare: 0.84 değerleri, modelin doğru tahminler yaptığını göstermektedir.

NN modeli, eğitim setindeki RMSE: 10.23 ve MSE: 104.70 ile uygun bir performans sergilemiştir. Test setindeki RMSE: 6.03 ve MSE: 36.40 değerleri, modelin gerçek dünya verilerine nasıl tepki verdiğini gösterir. Test sonuçlarına göre R-Kare: 0.91 değeri ile daha başarılı tahmin modeli NN olmuştur. R-Kare değerleri, modelin veriyi ne kadar iyi açıkladığını gösterir. Eğitim setindeki R-Kare: 0.76 ve test setindeki R-Kare: 0.91 değerleri, modelin doğru tahminler yaptığını göstermektedir.

Bu değerlendirme sonuçlarına göre, farklı performans metrikleri kullanılarak elde edilen sonuçların karşılaştırılması yapılmıştır. Eğitim sonuçlarına göre ET algoritmasının daha düşük RMSE, MSE ve daha yüksek R-Kare değerlerine sahip olduğu görülmektedir, bu da bu modelin daha iyi bir öğrenme ve tahmin yapma yeteneğine sahip olduğunu göstermektedir. Test sonuçlarına göre ise NN



Şekil 12. NN modeli eğitim ve test performans sonuçlarının görselleştirilmesi.


algoritmasının daha düşük RMSE, MSE ve daha yüksek R-Kare değerlerine sahip olduğu görülmektedir, bu da bu modelin gerçek dünya verilerine göre daha yüksek bir tahmin gücüne sahip olduğunu göstermektedir. Ancak, her bir modelin farklı uygulama ve problem bağlamında çeşitli avantajları ve dezavantajları olabileceği unutulmamalıdır. Regresyon temelli her iki ML algoritmasının da karşılaştırmalı eğitim ve test sonuçları Tablo 9'da sunulmaktadır.

Tablo 9. Tüm modellerin karşılaştırmalı eğitim ve test sonuçları.

Model Kategorisi	Model Tipi	RMSE (Eğitim)	MSE (Eğitim)	R-Kare (Eğitim)	MAE (Eğitim)	MAE (Test)	MSE (Test)	RMSE (Test)	R-Kare (Test)	Eğitim Süresi (gözlem/sn.)
ET	Güçlendirilmiş Ağaç	8,0549	64,8820	0,8517	4,4869	4,4097	66,1380	8,1325	0,8418	2800
	Torbalanmış Ağaç	8,4863	72,0170	0,8354	4,6533	4,3278	69,1320	8,3145	0,8347	2200
NN	Dar Sinir Ağı	12,1520	147,6700	0,6625	6,5236	7,1062	87,0470	9,3299	0,7918	4000
	Orta Sinir Ağı	11,1030	123,2700	0,7183	6,5034	5,7172	82,5370	9,0850	0,8026	4100
	Geniş Sinir Ağı	9,7780	95,6100	0,7815	6,3111	5,1563	63,6770	7,9798	0,8477	3200
	Çift Katmanlı Sinir Ağı	9,9638	99,2780	0,7731	4,7465	3,1859	36,4590	6,0381	0,9128	4600
	Üç Katmanlı Sinir Ağı	10,2320	104,7000	0,7607	4,9801	3,3531	36,4060	6,0337	0,9129	3200


Her iki ML modeline ait performans metriklerinin karşılaştırıldığı bazı grafikler sonraki bölümde sunulmaktadır. Şekil 13, her bir ML modelinin eğitim sürecinde elde ettiği performans sonuçlarını göstermektedir. Modeller arasında karşılaştırma yapabilmek adına kullanılan metrikler arasında RMSE ve MAE bulunmaktadır. Her bir modelin eğitim performansındaki değişim ve başarılar, grafik üzerinde belirli renkler ve sembollerle temsil edilmiştir. Bu grafik, her bir modelin eğitim sürecinde ne kadar başarılı olduğunu göstererek, model performanslarının görsel bir karşılaştırmasını sağlamaktadır.

Şekil 14, her bir ML modelinin test sürecinde elde ettiği performans sonuçlarını göstermektedir. Modeller arasında karşılaştırma yapabilmek adına kullanılan metrikler arasında RMSE ve MAE bulunmaktadır. Her bir modelin eğitim performansındaki değişim



Şekil 13. ET ve NN modelleri için eğitim performans karşılaştırma.


ve başarılar, grafik üzerinde belirli renkler ve sembollerle temsil edilmiştir. Bu grafik, her bir modelin eğitim sürecinde ne kadar başarılı olduğunu göstererek, model performanslarının görsel bir karşılaştırmasını sağlamaktadır.



Şekil 14. ET ve NN modelleri için test performans karşılaştırma.

Şekil 15, her bir ML modelinin eğitim süresini saniye başına gözlem sayısı olarak gözlem/sn. birimi üzerinden göstermektedir. Modellerin eğitim süreleri, belirli bir metrik veya performans ölçüsü üzerinden değerlendirilmiş olup, her bir modelin eğitim süresindeki değişim ve farklılıkların görsel bir karşılaştırmasını sağlar. Bu grafik, her bir modelin eğitim sürelerini farklı sütunlarla

temsil ederek, modeller arasındaki zaman performansındaki varlığı görsel olarak vurgular. Modellerin eğitim süresindeki bu dağılım, her bir algoritmanın hesaplama karmaşıklığı ve veri setine uyum sağlama süreçlerini anlamak adına önemli bir gösterge sunmaktadır.



Şekil 15. Tüm ML modelleri için eğitim süresi dağılımı.

5. Tartışma ve Sonuç

Bu araştırmanın temel amacı İstanbul'daki trafik kaza verilerine dayalı olarak trafik kaza süresini ET ve NN yöntemleri ile tahmin etmek ve bu yöntemlerin performanslarını karşılaştırmaktır. Araştırmanın ikincil amacı ise trafik kaza süresini etkileyen önemli faktörleri belirlemektir. Bu çalışmada İBB ve EGM kaynaklarından elde edilen İstanbul'a ait karayolu trafik kazası veri setleri kullanılmıştır. Elde edilen nihai veri seti, 2013 yılından 2021 yılına kadar olan süreçte İstanbul'da gerçekleşen 1.905 trafik kaza kaydını içermektedir. Bu çalışmada, nihai veri seti veri madenciliği teknikleri ile incelenmiştir. Ayıklanan veri setine istatistik testleri ve ML algoritmalarından olan ET ve NN teknikleri uygulanarak trafik kaza süresi tahmini gerçekleştirilmiştir. Bu çalışmada uygulanan algoritmaların performans ölçümleri için R^2 , MSE, RMSE ve MAE metrikleri kullanılmıştır. ET algoritmasının eğitimde R-Kare: 0.85 ile başarılı bir performans elde ettiği, teste ise R-Kare: 0.91 ile NN algoritmasının daha iyi performans gösterdiği sonucuna ulaşılmıştır.

Literatür çalışmalarında kullanılan MAPE, RMSE, MSE, MAE ve R-Kare performans ölçüm metrikleri, tahmin doğruluğunun analizinde en sık kullanılan metriklerdir. Bu çalışmada da R^2 , MSE, RMSE ve MAE metrikleri kullanılmıştır. MAE, MSE ve RMSE değerleri düştükçe ve R-Kare değeri arttıkça tahmin modeli daha doğru hale gelir, yani gerçek değerler ile tahmin edilen değerler arasında iyi bir uyum sağlanmış olur. Bu çalışmada elde edilen bulgular, önceki çalışmaların bulguları ile kıyaslandığında sonuçların genel olarak başarılı olduğu ve ilerleme kaydedildiği değerlendirilebilmektedir. ML modelleri kullanılan önceki çalışmalarda elde edilen R-Kare değerleri en düşük 0.17 (Bayes ve OLS regresyon) (Wali, Khattak ve Liu, 2022) ile en yüksek 0.94 (ANN) (Ying Lee ve Wei, 2010) olarak gerçekleşmiştir. Bu aralık esas alınır, bu çalışmada elde edilmiş olan en yüksek R-Kare: 0.85 (ET/test seti) ve 0.91 (NN/test seti) değerlerinin literatür ortalamasına göre oldukça başarılı sonuçlar olduğu görülebilmektedir.

Bir tahmin modelinin başarılı olup olmadığını anlamak için tek bir metrik ile değerlendirilmesi doğru olmayacaktır. Bu noktada, önceki çalışmalarda elde edilen diğer önemli bir metrik olan RMSE değerlerine bakıldığında, RF modelini kullanan bir çalışmada gerçekleşen ve aynı zamanda literatürdeki en düşük RMSE değeri 5.50 dakika (Lin ve Li, 2020) olarak gerçekleşmiştir. Dolayısıyla, bu çalışmada gerçekleşen ve veri setindeki kayıtlara ait kaza süresinin uzun olmaları da dikkate alınarak RMSE: 8.31 (RF/test seti) sonucunun kabul edilebilir bir başarı yakaladığı değerlendirilmektedir. Bir başka geçmiş çalışmada HBDM modeli kullanılarak

gerçekleşen ve aynı zamanda literatürdeki en yüksek RMSE değerinin 205 dakika (Zhang, Liu, Li ve Khattak, 2021) olduğu da göz ardı edilmemelidir. RMSE değerlerindeki bu farklılığın ve geniş aralığın temel sebebi kullanılan veri setindeki konumsal, çevresel ve zamansal farklılıklardan kaynaklanmaktadır. Diğer taraftan, NN kullanarak RMSE 6.05 değerini elde eden bir çalışmaya (Lin ve Li, 2020) göre bu çalışmada gerçekleşen RMSE: 6.03 (NN/test seti) sonucunun literatüre paralel bir şekilde başarılı olduğu gözlemlenmiştir.

Diğer bir performans ölçüm metriği olan MAE açısından karşılaştırma yapılırsa, M5P karar ağacı modelini kullanan bir çalışmanın model sonucuna göre gerçekleşen ve aynı zamanda literatürdeki en yüksek MAE değeri 34.01 dakika (Zhan ve diğerleri, 2011) olarak gerçekleşmiştir. Diğer taraftan, önceki çalışmalarda Bayes Model Ortalaması (BMA) modelini kullanan bir çalışmanın tahmin modeli sonucuna göre gerçekleşen ve aynı zamanda literatürdeki en düşük MAE değeri 5.968 dakika (Zou ve diğerleri, 2021) olmuştur. Bu aralık esas alındığında, bu çalışmada elde edilen tahmin modeli sonuçlarına göre en düşük MAE:3.18 dakika (NN/test seti) değeri, kullanılan regresyon temelli ML modellerinin tahmin gücünün başarısını bir kez daha ortaya koymaktadır.

Bu araştırmanın ikincil hedefi, trafik kaza süresini etkileyen önemli etki faktörlerin belirlenmesidir. Bu doğrultuda, uygulanan F Testi ve PCA analizi sonucunda kaza süresini etkileyen en önemli etki faktörleri ve açıklanan varyans oranları şöyledir: Otomobil %51.5, KazaOlusTuru %27.0, Kazalcesi %8.7, Kamyonet %4.9, CarpismaYeri %2.1, YolunSinifi %1.6, Minibus %1.3, Motosiklet %0.9, ToplamYaraliSayisi %0.6 ve GeoGecit %0.4. Bu sonuçlara göre genel olarak etki faktörleri önceki çalışmalarda belirlenen etki faktörleri ile benzerlik göstermektedir. Fakat, bu çalışmaya göre etki faktörleri arasında bulunan GeoGecit, önceki çalışmalarda rastlanılmayan bir etki faktörü olarak öne çıkmaktadır. GeoGecit kategorik değişkeni şu sınıfları içermektedir: 1-Kontrollü Demiryolu, 2-KontROLSÜZ Demiryolu, 3-Okul Geçidi, 4-Yaya Geçidi ve 5-Geçit Yok. Buna göre, İstanbul'da gerçekleşen trafik kazalarının göz ardı edilemeyecek bir kısmının okul geçidi, yaya geçidi ya da ana arter yollar ve yan yolların kesişiminde bulunan tren ve tramvay hemzemin geçitlerinde yaşandığı sonucuna varılabilmektedir.

Bu araştırma, belirli bir kapsam içinde yürütülmüş olsa da bazı sınırlılıklar ve kısıtlamalar içermektedir. Bu sınırlılıkların başında veri kapsamı gelmektedir. Bu çalışma, 2013-2021 yılları arasındaki İstanbul'da gerçekleşen trafik kazalarına odaklanmaktadır. Bu nedenle, genel bir çerçeveyi temsil etmekten ziyade, sınırlı bir veri kümesi kullanılmıştır. İkinci sınırlılık algoritma seçimidir. Çalışmada kullanılması tercih edilen yöntem regresyon temelli ML olmuştur. Bu yöntemin veya algoritmaların dışındaki diğer potansiyel yöntemlerin incelenmemesi sınırlılık oluşturabilir. Son sınırlılık ise veri seti parametreleridir. Trafik kazalarının analizinde konumsal, zamansal ve çevresel olarak önemli faktörler bulunmaktadır. Ancak, bu çalışmada kullanılan veri setinin sınırlamaları nedeniyle tüm konumsal, zamansal ve çevresel faktörlerin ayrıntılı bir şekilde ele alınması mümkün olmayabilir.

Bu araştırmanın sonuçlarına dayanarak gelecekte bazı potansiyel çalışmaların yürütülebileceği öngörülmektedir. Daha geniş bir coğrafi alan ve uzun bir zaman dilimini kapsayan veri setleri kullanılarak trafik kaza süresi tahmininde daha kapsamlı bir analiz yapılabilir. Araştırmada kullanılan regresyon temelli algoritmaların yanı sıra, sınıflandırma temelli ML algoritmalarının kullanılarak performanslarının karşılaştırıldığı bir çalışma gerçekleştirilebilir. Trafik akışı, trafik yoğunluğu gibi trafikle ilgili faktörlerin modele dahil edilmesi ve detaylı bir şekilde incelenmesi, trafik kaza süresinin tahmininde daha yüksek performans sağlayabilir. Diğer yandan, farklı yapay zekâ yöntemleri ya da derin öğrenme gibi gelişmiş modelleme tekniklerinin kullanılması, daha karmaşık ilişkileri ortaya çıkarabilir ve tahmin yeteneklerini artırabilir. Ayrıca, modelleme sürecine dahil edilmesi zor olan deneyimler, bilgi ve psikolojik nitelikler de dahil olmak üzere farklı sürücülerin çeşitli özelliklerinin tahmin modeline dahil edilmesi önem arz etmektedir. Bu nedenle, trafik kazası süresinin tahmininde rastgelelik, heterojenlik ve zamanla değişen değişkenlerin kontrol edilmesi, gelecekteki potansiyel araştırmalara yön verecektir. Ek olarak, insan faktörlerinin trafik kazalarının olasılığını ve sıklığını artırdığını vurgulamak da önemlidir. Tüm bu potansiyel çalışmalar kapsamındaki öngörüler, bu araştırmanın sınırlılıklarını aşmayı ve trafik kaza süresinin analizi ve tahmini alanındaki bilgiyi daha da genişletmeyi amaçlamaktadır.

Hakem Değerlendirmesi: Dış bağımsız.

Yazar Katkıları: Çalışma Konsepti/Tasarım- H.K.; Veri Toplama- H.K.; Veri Analizi/Yorumlama- H.K., M.A.E., M.A.; Yazı Taslağı- H.K.; İçeriğin Eleştirel İncelemesi- H.K., M.A.E., M.A.; Son Onay ve Sorumluluk- H.K., M.A.E., M.A.

Çıkar Çatışması: Yazarlar çıkar çatışması beyan etmemişlerdir.

Finansal Destek: Yazarlar finansal destek beyan etmemişlerdir.

Not: Makalenin değerlendirme, hakem ve karar süreçlerinde Baş Editör yer almamış, ilgili süreçler Baş Editör Yardımcısı ve yazı kurulu üyesi editörler tarafından yürütülmüştür.

Peer Review: Externally peer-reviewed.

Author Contributions: Conception/Design of Study- H.K.; Data Acquisition- H.K.; Data Analysis/ Interpretation- H.K., M.A.E., M.A.; Drafting Manuscript- H.K.; Critical Revision of Manuscript- H.K., M.A.E., M.A.; Final Approval and Accountability- H.K., M.A.E., M.A.

Conflict of Interest: Authors declared no conflict of interest.

Financial Disclosure: Authors declared no financial support.

Note: The Editor-in-Chief was not involved in the evaluation, peer-review and decision processes of the article. These processes were carried out by the Co-Editor-in-Chief and the member editors of the editorial management board.

Yazarların ORCID ID'leri / ORCID IDs of the authors

Hüseyin Korkmaz	0000-0002-2438-6919
Mehmet Ali Ertürk	0000-0002-4030-1110
Mehmet Adak	0000-0002-7788-1227

KAYNAKLAR / REFERENCES

- Adler, M. W., Ommeren, J. Van ve Rietveld, P. (2013). Road congestion and incident duration. *Economics of Transportation*, 2(4), 109-118. doi:10.1016/j.ecotra.2013.12.003
- Alonze, S. (2014). Traffic Congestion to Cost the UK Economy More Than £300 Billion Over the Next 16 Years. *Inrix Press Releases*. 25 Eylül 2021 tarihinde <https://inrix.com/press-releases/traffic-congestion-to-cost-the-uk-economy-more-than-300-billion-over-the-next-16-years/> adresinden erişildi.
- Bai, S., Ji, X., Dai, B., Pu, Y. ve Qin, W. (2022). An Integrated Model for the Geohazard Accident Duration on a Regional Mountain Road Network Using Text Data. *Sustainability (Switzerland)*, 14(19). doi:10.3390/su141912429
- Barrett, G. B. (2000). The Coefficient of Determination: Understanding r squared and R squared. *The Mathematics Teacher*, 93(3), 230-234.
- Boyles, S., Fajardo, D. ve Waller, S. T. (2007). A naive Bayesian classifier for incident duration prediction. *86th Annual Meeting of the Transportation Research Board, Washington, DC* içinde .
- Breiman, L. (1996). Bagging predictors. *Machine Learning*, 24(2), 123-140. doi:10.1007/BF00058655
- Chen, J. ve Tao, W. (2022). Traffic accident duration prediction using text mining and ensemble learning on expressways. *Scientific Reports*, 12(1), 21478. doi:10.1038/s41598-022-25988-4
- Chin, S. M., Franzese, O., Greene, D. L., Hwang, H. L. ve Gibson, R. C. (2004). *Temporary Losses of Highway Capacity and Impacts on Performance: Phase 2*. (null, Ed.)null (C. null). <https://rosap.ntl.bts.gov/view/dot/37083> adresinden erişildi.
- Cohen, J. (2013). *Statistical power analysis for the behavioral sciences*. Routledge.
- Cong, H., Chen, C., Lin, P.-S., Zhang, G., Milton, J. ve Zhi, Y. (2018). Traffic Incident Duration Estimation Based on a Dual-Learning Bayesian Network Model. *Transportation Research Record*, 2672(45), 196-209. doi:10.1177/0361198118796938
- Di Bucchianico, A. (2008). Coefficient of determination (R²). *Encyclopedia of statistics in quality and reliability*.
- Dimitriou, L. ve Vlahogianni, E. I. (2015). Fuzzy modeling of freeway accident duration with rainfall and traffic flow interactions. *Analytic Methods in Accident Research*, 5-6, 59-71. doi:10.1016/j.amar.2015.04.001
- Farrar, D. E. ve Glauber, R. R. (1967). Multicollinearity in Regression Analysis: The Problem Revisited. *The Review of Economics and Statistics*, 49(1), 92. doi:10.2307/1937887
- Fleming, S. (2019). Traffic congestion cost the US economy nearly \$87 billion in 2018. *World Economic Forum*. 25 Eylül 2021 tarihinde <https://www.weforum.org/agenda/2019/03/traffic-congestion-cost-the-us-economy-nearly-87-billion-in-2018/> adresinden erişildi.
- Garrison, D. ve Mannering, F. L. (1990). Assessing the traffic impacts of freeway incidents and driver information. *ITE journal*, 60(8), 19-23. <http://dx.doi.org/> adresinden erişildi.
- Ghosh, B., Asif, M. T., Dauwels, J., Fastenrath, U. ve Guo, H. (2019). Dynamic Prediction of the Incident Duration Using Adaptive Feature Set. *IEEE Transactions on Intelligent Transportation Systems*, 20(11), 4019-4031. doi:10.1109/TITS.2018.2878637
- Ghosh, B. ve Dauwels, J. (2022). Comparison of different Bayesian methods for estimating error bars with incident duration prediction. *Journal*

- of Intelligent Transportation Systems: Technology, Planning, and Operations*, 26(4), 420-431. doi:10.1080/15472450.2021.1894936
- Gibbons, J. D. (1997). Nonparametric methods for quantitative analysis. *Journal of the Operational Research Society*, 48(8), 853.
- Giuliano, G. (1989). Incident characteristics, frequency, and duration on a high volume urban freeway. *Transportation Research Part A: General*, 23(5), 387-396. doi:10.1016/0191-2607(89)90086-1
- Grigorev, A., Mihaita, A.-S., Lee, S. ve Chen, F. (2022). Incident duration prediction using a bi-level machine learning framework with outlier removal and intra-extra joint optimisation. *Transportation Research Part C: Emerging Technologies*, 141. doi:10.1016/j.trc.2022.103721
- Hamad, K., Al-Ruzouq, R., Zeiada, W., Abu Dabous, S. ve Khalil, M. A. (2020). Predicting incident duration using random forests. *Transportmetrica A: Transport Science*, 16(3), 1269-1293. doi:10.1080/23249935.2020.1733132
- Hamad, K., Khalil, M. A. ve Alozi, A. R. (2020). Predicting Freeway Incident Duration Using Machine Learning. *International Journal of Intelligent Transportation Systems Research*, 18(2), 367-380. doi:10.1007/s13177-019-00205-1
- Hamad, K., Obaid, L., Haridy, S., Zeiada, W. ve Al-Khateeb, G. (2022). Factorial design-machine learning approach for predicting incident durations. *Computer-Aided Civil and Infrastructure Engineering*. doi:10.1111/mice.12883
- Hassoun, M. H. (1995). Fundamentals of artificial neural networks. MIT press.
- Howell, D. C. (1992). *Statistical methods for psychology*. PWS-Kent Publishing Co.
- Hyndman, R. J. ve Koehler, A. B. (2006). Another look at measures of forecast accuracy. *International Journal of Forecasting*, 22(4), 679-688. doi:10.1016/j.ijforecast.2006.03.001
- İBB UDB. (2023). İBB Ulaşım Dairesi Başkanlığı, Ulaşım Yönetim Merkezi Trafik Duyuru Verisi. *İBB Açık Veri Portalı*. 29 Aralık 2023 tarihinde <https://data.ibb.gov.tr/dataset/ulasim-yonetim-merkezi-trafik-duyuru-verisi> adresinden erişildi.
- IEA. (2020). *Energy Technology Perspectives Special Report on Clean Energy Innovation*. Paris. <https://www.iea.org/reports/clean-energyinnovation> adresinden erişildi.
- Ishak, S. ve Alecsandru, C. (2004). Optimizing Traffic Prediction Performance of Neural Networks under Various Topological, Input, and Traffic Condition Settings. *Journal of Transportation Engineering*, 130(4), 452-465. doi:10.1061/(ASCE)0733-947X(2004)130:4(452)
- Ji, K. K., Li, Z. Z., Chen, J., Wang, G. Y., Liu, K. L. ve Luo, Y. (2022). Freeway Accident Duration Prediction Based On Social Network Information. *Neural Network World*, 32(2), 93-112. doi:10.14311/NNW.2022.32.006
- Karataş, G. (2021). The Effects of Normalization and Standardization an Internet of Things Attack Detection. *European Journal of Science and Technology*, (29), 187-192. doi:10.31590/ejosat.1017427
- Khattak, A. J., Schofer, J. L. ve Wang, M.-H. (1995). A Simple Time Sequential Procedure For Predicting Freeway Incident Duration. *I V H S Journal*, 2(2), 113-138. doi:10.1080/10248079508903820
- Kim, W. ve Chang, G.-L. (2012). Development of a Hybrid Prediction Model for Freeway Incident Duration: A Case Study in Maryland. *International Journal of Intelligent Transportation Systems Research*, 10(1), 22-33. doi:10.1007/s13177-011-0039-8
- Kuang, L., Yan, H., Zhu, Y., Tu, S. ve Fan, X. (2019). Predicting duration of traffic accidents based on cost-sensitive Bayesian network and weighted K-nearest neighbor. *Journal of Intelligent Transportation Systems: Technology, Planning, and Operations*, 23(2), 161-174. doi:10.1080/15472450.2018.1536978
- Lee, J., Kwak, J., Oh, Y. ve Kim, S. (2022). Quantifying incident impacts and identifying influential features in urban traffic networks. *Transportmetrica B*. doi:10.1080/21680566.2022.2063205
- Lee, J.-Y., Chung, J.-H. ve Son, B. (2009). Incident clearance time analysis for Korean freeways using structural equation model. *Proceedings of the Eastern Asia Society for Transportation Studies Vol. 7 (The 8th International Conference of Eastern Asia Society for Transportation Studies, 2009)* içinde (s. 360). Eastern Asia Society for Transportation Studies.
- Lee, Y., Wei, C.-H. ve Chao, K.-C. (2017). Non-parametric machine learning methods for evaluating the effects of traffic accident duration on freeways. *Archives of Transport*, 43(3), 91-104. doi:10.5604/01.3001.0010.4228
- Lee, Ying ve Wei, C.-H. (2010). A computerized feature selection method using genetic algorithms to forecast freeway accident duration times. *Computer-Aided Civil and Infrastructure Engineering*, 25(2), 132-148. doi:https://doi.org/10.1111/j.1467-8667.2009.00626.x
- Li, Chi-Sen ve Chen, M.-C. (2014). A data mining based approach for travel time prediction in freeway with non-recurrent congestion. *Neurocomputing*, 133, 74-83. doi:10.1016/j.neucom.2013.11.029
- Li, C.-S. ve Chen, M.-C. (2013). Identifying important variables for predicting travel time of freeway with non-recurrent congestion with neural networks. *Neural Computing and Applications*, 23(6), 1611-1629. doi:10.1007/s00521-012-1114-z
- Li, D., Wu, J. ve Peng, D. (2021). Online Traffic Accident Spatial-Temporal Post-Impact Prediction Model on Highways Based on Spiking Neural Networks. *Journal of Advanced Transportation*, 2021. doi:10.1155/2021/9290921
- Li, L., Sheng, X., Du, B., Wang, Y. ve Ran, B. (2020). A deep fusion model based on restricted Boltzmann machines for traffic accident duration prediction. *Engineering Applications of Artificial Intelligence*, 93. doi:10.1016/j.engappai.2020.103686
- Lin, P.-W., Zou, N. ve Chang, G.-L. (2004). Integration of a discrete choice model and a rule-based system for estimation of incident duration: a case study in Maryland. *CD-ROM of Proceedings of the 83rd TRB Annual Meeting, Washington, DC* içinde .
- Lin, Y. ve Li, R. (2020). Real-time traffic accidents post-impact prediction: Based on crowdsourcing data. *Accident Analysis and Prevention*, 145. doi:10.1016/j.aap.2020.105696
- Liu, F., Zheng, L., Li, M. ve Tang, J. (2022). Analysis and Prediction of the Interval Duration between the First and Second Accidents considering the Spatiotemporal Threshold. *Journal of Advanced Transportation*, 2022, 1-14. doi:10.1155/2022/6312139
- Ma, X., Ding, C., Luan, S., Wang, Y. ve Wang, Y. (2017). Prioritizing Influential Factors for Freeway Incident Clearance Time Prediction Using the Gradient Boosting Decision Trees Method. *IEEE Transactions on Intelligent Transportation Systems*, 18(9), 2303-2310. doi:10.1109/TITS.2016.2635719

- Makridakis, S., Andersen, A., Carbone, R., Fildes, R., Hibon, M., Lewandowski, R., . . . Winkler, R. (1982). The accuracy of extrapolation (time series) methods: Results of a forecasting competition. *Journal of Forecasting*, 1(2), 111-153. doi:10.1002/for.3980010202
- Marshment, B., Dauffenbach, R. ve Penn, D. A. (1996). Short-Range Intercity Traffic Forecasting Using Econometric Techniques.
- Miles, J. ve Banyard, P. (2007). Understanding and using statistics in psychology: A practical introduction.
- Mohammed, Z. A., Abdullah, M. N. ve Al Hussaini, I. H. (2021). Predicting Incident Duration Based on Machine Learning Methods. *Iraqi Journal of Computer, Communication, Control and System Engineering*, 21(1), 1-15. doi:10.33103/uot.ijccce.21.1.1
- Nam, D. ve Mannering, F. (2000). An exploratory hazard-based analysis of highway incident duration. *Transportation Research Part A: Policy and Practice*, 34(2), 85-102. doi:10.1016/S0965-8564(98)00065-2
- Nevitt, J. ve Hancock, G. R. (2000). Improving the Root Mean Square Error of Approximation for Nonnormal Conditions in Structural Equation Modeling. *The Journal of Experimental Education*, 68(3), 251-268. doi:10.1080/00220970009600095
- Park, B., Messer, C. J. ve Urbanik, T. (1998). Short-Term Freeway Traffic Volume Forecasting Using Radial Basis Function Neural Network. *Transportation Research Record: Journal of the Transportation Research Board*, 1651(1), 39-47. doi:10.3141/1651-06
- Park, H., Haghani, A. ve Zhang, X. (2016). Interpretation of Bayesian neural networks for predicting the duration of detected incidents. *Journal of Intelligent Transportation Systems: Technology, Planning, and Operations*, 20(4), 385-400. doi:10.1080/15472450.2015.1082428
- Pearl, J. (1988). *Probabilistic reasoning in intelligent systems: networks of plausible inference*. Morgan kaufmann.
- Pereira, F. C., Rodrigues, F. ve Ben-Akiva, M. (2013). Text analysis in incident duration prediction. *Transportation Research Part C: Emerging Technologies*, 37, 177-192. doi:https://doi.org/10.1016/j.trc.2013.10.002
- Sammut, C. ve Webb, G. I. (2010). Mean absolute error. *Encyclopedia of Machine Learning*, 652.
- Saracoglu, A. ve Ozen, H. (2020). Estimation of Traffic Incident Duration: A Comparative Study of Decision Tree Models. *Arabian Journal for Science and Engineering*, 45(10), 8099-8110. doi:10.1007/s13369-020-04615-2
- Schapire, R. E. (1990). The strength of weak learnability. *Machine Learning*, 5(2), 197-227. doi:10.1007/BF00116037
- Schrank, D., Eisele, B. ve Lomax, T. (2019). Urban mobility report 2019.
- Shang, Q., Tan, D., Gao, S. ve Feng, L. (2019). A Hybrid Method for Traffic Incident Duration Prediction Using BOA-Optimized Random Forest Combined with Neighborhood Components Analysis. *Journal of Advanced Transportation*, 2019. doi:10.1155/2019/4202735
- Shang, Q., Xie, T. ve Yu, Y. (2022). Prediction of Duration of Traffic Incidents by Hybrid Deep Learning Based on Multi-Source Incomplete Data. *International Journal of Environmental Research and Public Health*, 19(17). doi:10.3390/ijerph191710903
- Sheikh, M. S. ve Regan, A. (2022). A complex network analysis approach for estimation and detection of traffic incidents based on independent component analysis. *Physica A: Statistical Mechanics and its Applications*, 586, 126504. doi:10.1016/j.physa.2021.126504
- Skabardonis, A., Varaiya, P. ve Petty, K. F. (2003). Measuring Recurrent and Nonrecurrent Traffic Congestion. *Transportation Research Record: Journal of the Transportation Research Board*, 1856(1), 118-124. doi:10.3141/1856-12
- Snelder, M., Bakri, T. ve van Arem, B. (2013). Delays Caused by Incidents. *Transportation Research Record: Journal of the Transportation Research Board*, 2333(1), 1-8. doi:10.3141/2333-01
- Stephanedes, Y. J., Michalopoulos, P. G. ve Plum, R. A. (1981). Improved Estimation of Traffic Flow for Real-Time Control. *Transportation Research Record*, 795, 28-39.
- Tang, J., Zheng, L., Han, C., Liu, F. ve Cai, J. (2020). Traffic Incident Clearance Time Prediction and Influencing Factor Analysis Using Extreme Gradient Boosting Model. *Journal of Advanced Transportation*, 2020. doi:10.1155/2020/6401082
- Tin Kam Ho. (1995). Random decision forests. *Proceedings of 3rd International Conference on Document Analysis and Recognition* içinde (C. 1, ss. 278-282). Montreal, QC, Canada: IEEE Comput. Soc. Press. doi:10.1109/ICDAR.1995.598994
- Valenti, G., Lelli, M. ve Cucina, D. (2010). A comparative study of models for the incident duration prediction. *European Transport Research Review*, 2(2), 103-111. doi:10.1007/s12544-010-0031-4
- Van Der Voort, M., Dougherty, M. ve Watson, S. (1996). Combining kohonen maps with arima time series models to forecast traffic flow. *Transportation Research Part C: Emerging Technologies*, 4(5), 307-318. doi:https://doi.org/10.1016/S0968-090X(97)82903-8
- van Lint, J. W. C., Hoogendoorn, S. P. ve van Zuylen, H. J. (2002). Freeway Travel Time Prediction with State-Space Neural Networks: Modeling State-Space Dynamics with Recurrent Neural Networks. *Transportation Research Record: Journal of the Transportation Research Board*, 1811(1), 30-39. doi:10.3141/1811-04
- Vlahogianni, E. I. ve Karlaftis, M. G. (2013). Fuzzy-entropy neural network freeway incident duration modeling with single and competing uncertainties. *Computer-Aided Civil and Infrastructure Engineering*, 28(6), 420-433. doi:10.1111/mice.12010
- Wali, B., Khattak, A. J. ve Liu, J. (2022). Heterogeneity assessment in incident duration modelling: Implications for development of practical strategies for small & large scale incidents. *Journal of Intelligent Transportation Systems*, 26(5), 586-601. doi:10.1080/15472450.2021.1944135
- Wang, S., Li, R. ve Guo, M. (2018). Application of nonparametric regression in predicting traffic incident duration. *Transport*, 33(1), 22-31. doi:10.3846/16484142.2015.1004104
- Williams, B. M., Durvasula, P. K. ve Brown, D. E. (1998). Urban Freeway Traffic Flow Prediction: Application of Seasonal Autoregressive Integrated Moving Average and Exponential Smoothing Models. *Transportation Research Record: Journal of the Transportation Research Board*, 1644(1), 132-141. doi:10.3141/1644-14
- Won, M. (2020). *Outlier Analysis to Improve the Performance of an Incident Duration Estimation and Incident Management System*. *Transportation Research Record* (C. 2674). doi:10.1177/0361198120916472
- Won, M., Kim, H. ve Chang, G.-L. (2018). *Knowledge-based system for estimating incident clearance duration for Maryland I-95*. *Transportation Research Record* (C. 2672). doi:10.1177/0361198118792119
- Xiao, H., Sun, H., Ran, B. ve Oh, Y. (2003). Fuzzy-Neural Network Traffic Prediction Framework with Wavelet Decomposition. *Transportation*

- Research Record: Journal of the Transportation Research Board*, 1836(1), 16-20. doi:10.3141/1836-03
- Yu, B., Wang, Y. T., Yao, J. B. ve Wang, J. Y. (2016). A comparison of the performance of ANN and SVM for the prediction of traffic accident duration. *Neural Network World*, 26(3), 271-287. doi:10.14311/NNW.2016.26.015
- Zhan, C., Gan, A. ve Hadi, M. (2011). Prediction of Lane Clearance Time of Freeway Incidents Using the M5P Tree Algorithm. *IEEE Transactions on Intelligent Transportation Systems*, 12(4), 1549-1557. doi:10.1109/TITS.2011.2161634
- Zhang, H., Zhang, Y. ve Khattak, A. J. (2012). Analysis of Large-Scale Incidents on Urban Freeways. *Transportation Research Record: Journal of the Transportation Research Board*, 2278(1), 74-84. doi:10.3141/2278-09
- Zhang, Z., Liu, J., Li, X. ve Khattak, A. J. (2021). Do Larger Sample Sizes Increase the Reliability of Traffic Incident Duration Models? A Case Study of East Tennessee Incidents. *Transportation Research Record: Journal of the Transportation Research Board*, 2675(6), 265-280. doi:10.1177/0361198121992063
- Zhao, H., Gunardi, W., Liu, Y., Kiew, C., Teng, T.-H. ve Yang, X. B. (2022). Prediction of Traffic Incident Duration Using Clustering-Based Ensemble Learning Method. *Journal of Transportation Engineering Part A: Systems*, 148(7). doi:10.1061/JTEPBS.0000688
- Zhao, Y. ve Deng, W. (2022). Prediction in Traffic Accident Duration Based on Heterogeneous Ensemble Learning. *Applied Artificial Intelligence*, 36(1). doi:10.1080/08839514.2021.2018643
- Zhu, W., Wu, J., Fu, T., Wang, J., Zhang, J. ve Shangguan, Q. (2021). Dynamic prediction of traffic incident duration on urban expressways: a deep learning approach based on LSTM and MLP. *Journal of Intelligent and Connected Vehicles*, 4(2), 80-91. doi:10.1108/JICV-03-2021-0004
- Zong, F., Zhang, H. Y., Xu, H. G., Zhu, X. M. ve Wang, L. (2013). Predicting Severity and Duration of Road Traffic Accident. *MATHEMATICAL PROBLEMS IN ENGINEERING*, 2013. doi:10.1155/2013/547904 WE - Science Citation Index Expanded (SCI-EXPANDED)
- Zou, Y., Lin, B., Yang, X., Wu, L., Muneeb Abid, M. ve Tang, J. (2021). Application of the Bayesian Model Averaging in Analyzing Freeway Traffic Incident Clearance Time for Emergency Management. *Journal of Advanced Transportation*, 2021. doi:10.1155/2021/6671983

Atf Biçimi / How cite this article

Korkmaz, H., Ertürk, M.A., & Adak M. (2024). A comparison of the performance of ensemble tree and neural networks for the prediction of traffic accident duration. *Journal of Transportation and Logistics*, 9(1), 20-47. <https://doi.org/10.26650/JTL.2024.1444128>