



HARRAN ÜNİVERSİTESİ MÜHENDİSLİK DERGİSİ

HARRAN UNIVERSITY JOURNAL of ENGINEERING

e-ISSN: 2528-8733 (ONLINE)

URL: <http://dergipark.gov.tr/humder>

Bulanık Mantık Destekli Trafik Yoğunluğu Tahmini

Fuzzy Logic-Based Traffic Congestion Prediction

Yazar(lar) (Author(s)): Cem ÖZKURT¹, Ahmet KALA^{2, *}, Kübra KONUK³, Ayşe Nur SAYLAM⁴

¹ ORCID ID: 0000-0002-1251-7715

² ORCID ID: 0000-0002-0598-1181

³ ORCID ID: 0009-0004-7500-7394

⁴ ORCID ID: 0009-0005-4497-3861

Bu makaleye şu şekilde atıfta bulunabilirsiniz (To cite to this article): Özkurt C., Kala A., Konuk K., SAYLAM A.N., “Bulanık Mantık Destekli Trafik Yoğunluğu Tahmini”, *Harran Üniversitesi Mühendislik Dergisi*, 10(3): 184-197, (2025).

Erişim linki (To link to this article): [10.46578/humder.1680871](http://dergipark.gov.tr/humder.1680871)



Bulanık Mantık Destekli Trafik Yoğunluğu Tahmini

Cem ÖZKURT^{1,2}, Ahmet KALA³, Kübra KONUK⁴, Ayşe Nur SAYLAM⁴

¹Bilgisayar Mühendisliği Bölümü, Teknoloji Fakültesi, Sakarya Uygulamalı Bilimler Üniversitesi, Sakarya, Türkiye

²Yapay Zekâ ve Veri Bilimi Uygulama ve Araştırma Merkezi, Sakarya Uygulamalı Bilimler Üniversitesi, Sakarya, Türkiye

³Bilgi İşlem Daire Başkanlığı, Rektörlük, Sakarya Uygulamalı Bilimler Üniversitesi, Sakarya, Türkiye

⁴Mekatronik Mühendisliği Bölümü, Teknoloji Fakültesi, Sakarya Uygulamalı Bilimler Üniversitesi, Sakarya, Türkiye

Makale Bilgisi

Başvuru: 21/04/2025
Düzeltilme: 22/04/2025
Kabul: 24/06/2025
Yayınlanma: 30/06/2025

Ahntı

Özkurt C., Kala A., Konuk K., SAYLAM A.N., "Bulanık Mantık Destekli Trafik Yoğunluğu Tahmini", Harran Üniversitesi Mühendislik Dergisi, 10(3): 184-197, (2025).

Öz

Trafik yoğunluğu, modern şehirlerde bireysel seyahat sürelerini uzatan, çevresel kirliliği artıran ve ekonomik kayıplara yol açan önemli bir sorundur. İstanbul gibi büyük metropollerde ortalama trafik yoğunluğu %70'in üzerinde seyrederken, zirve saatlerde %85'e kadar çıkmaktadır. Artan nüfus ve araç sayısı, yalnızca günlük yaşamı zorlaştırmakla kalmayıp, şehir altyapısını da zorlamaktadır. Bu nedenle, trafik yoğunluğunu etkin bir şekilde yönetmek ve tahmin edebilmek, sürdürülebilir ulaşım ve akıllı şehir yönetimi açısından büyük önem taşımaktadır. Ancak, trafiği etkileyen faktörlerin dinamik ve belirsiz yapısı, geleneksel yöntemlerle yeterince doğru tahmin edilememektedir. Bu çalışmada, 2022 yılına ait İstanbul Büyükşehir Belediyesi tarafından sağlanmış saatlik bazda toplam 8.539 trafik yoğunluğu kaydı ile Meteostat kaynağından elde edilen ve 365 güne ait günlük hava durumu verileri birleştirilerek Mamdani tipi bulanık mantık tabanlı bir trafik tahmin modeli geliştirilmiştir. Modelin performansı, MAE: 5.32, RMSE: 7.45 ve R²: 0.87 gibi yüksek başarımlı göstergeleriyle değerlendirilmiştir. Literatürde yaygın olarak kullanılan Doğrusal Regresyon (LR), Çoklu Doğrusal Regresyon (MLR), Karar Ağacı (DT), Rastgele Orman (RF), XGBoost ve LSTM modelleriyle deneysel karşılaştırma yapılmış ve her model için MAE, RMSE ve R² değerleri beş katlı zamana duyarlı bloklu çapraz doğrulama ile raporlanmıştır. Bulgular, Mamdani modelinin özellikle yorumlanabilirlik ve şeffaflık açısından üstün olduğunu, ancak LSTM ve XGBoost gibi modellerin hata oranlarında daha düşük seviyelere ulaşabildiğini ortaya koymuştur. Sonuç olarak, çalışma, düşük önileme ihtiyacı, şeffaf karar yapısı ve kabul edilebilir hata seviyeleriyle uygulamaya yönelik açıklanabilir model ihtiyacını karşılamaktadır.

Anahtar Kelimeler: Trafik Yoğunluğu Tahmini, Bulanık Mantık, Akıllı Ulaşım Sistemleri

Fuzzy Logic-Based Traffic Congestion Prediction

Article Information

Received: 21/04/2025
Revised: 22/04/2025
Accepted: 24/06/2025
Published: 30/06/2025

Citation

Özkurt C., Kala A., Konuk K., Saylam A.N., "Fuzzy Logic-Based Traffic Congestion Prediction", *Harran University Journal of Engineering*, 10(3): 184-197, (2025).

Abstract

Traffic congestion is a major issue in modern cities, leading to longer individual travel times, increased environmental pollution, and economic losses. In large metropolitan areas like Istanbul, the average traffic congestion level exceeds 70%, reaching up to 85% during peak hours. The growing population and number of vehicles not only complicate daily life but also strain urban infrastructure. Therefore, effectively managing and predicting traffic congestion is crucial for sustainable transportation and smart city management. However, the dynamic and uncertain nature of factors influencing traffic makes it difficult to achieve accurate predictions using traditional methods. In this study, a Mamdani-type fuzzy logic-based traffic prediction model was developed by integrating a total of 8,539 hourly traffic congestion records provided by the Istanbul Metropolitan Municipality for the year 2022 and 365 rows of daily weather data obtained from the Meteostat source. The performance of the model was evaluated with strong success indicators such as MAE: 5.32, RMSE: 7.45, and R²: 0.87. Experimental comparisons were made with widely used models in the literature such as Linear Regression (LR), Multiple Linear Regression (MLR), Decision Tree (DT), Random Forest (RF), XGBoost, and LSTM, and for each model, MAE, RMSE, and R² values were reported using five-fold time-sensitive block cross-validation. The results showed that the Mamdani model is superior particularly in terms of interpretability and transparency, whereas models like LSTM and XGBoost achieved lower error rates. As a result, the study meets the need for an explainable model for practical applications with its low preprocessing requirement, transparent decision structure, and acceptable error levels.

Keywords: Traffic Congestion Prediction, Fuzzy Logic, Intelligent Transportation Systems

*İletişim yazarı, e-mail: ahmetkala@subu.edu.tr

*Corresponding author, ahmetkala@subu.edu.tr

DOI: 10.46578/humder.1680871

1. GİRİŞ (INTRODUCTION)

Trafik yoğunluğu, büyük şehirlerde toplumsal yaşamı ve ekonomik faaliyetleri olumsuz etkileyen önemli bir sorundur. Artan nüfus ve motorlu taşıt sayısı, mevcut ulaşım altyapısını yetersiz bırakmakta; bu da seyahat sürelerinin uzamasına, yakıt tüketiminin ve sera gazı salımlarının artmasına neden olmaktadır. İstanbul gibi metropollerde ortalama trafik yoğunluğu %70'in üzerindeyken, zirve saatlerde bu oran %85'e kadar çıkmaktadır. Bu durum, ulaşım planlaması ve trafik yönetimi açısından doğru tahmin modellerine olan ihtiyacı artırmaktadır.

Geleneksel trafik tahmin yöntemleri, doğrusal regresyon veya zaman serisi modellemeleri gibi istatistiksel tekniklere dayanmaktadır. Ancak bu yöntemler, trafik sistemlerinin çok değişkenli ve belirsiz doğasını modellemede sınırlı kalmaktadır. Araç sayısı, hız, hava durumu ve yol durumu gibi değişkenlerin karmaşık ilişkileri, deterministik modellerin ötesinde çözümler gerektirmektedir.

Bu bağlamda, son yıllarda yapay zekâ tabanlı modeller trafik tahmininde yaygın biçimde kullanılmaya başlanmıştır. Özellikle uzun-kısa süreli hafıza (LSTM), gradyan artırma (XGBoost), kapılı tekrarlayan üniteler (GRU) ve grafik sinir ağları (GNN) gibi modern teknikler, trafik akışında hem zamansal hem mekânsal bağımlılıkları modelleyebilme yetenekleri sayesinde başarılı sonuçlar üretmiştir [1-3]. Ancak bu modellerin çoğu yüksek hesaplama maliyeti, düşük yorumlanabilirlik ve yoğun ön işleme ihtiyacı nedeniyle uygulamada sınırlılıklar taşımaktadır.

Bulanık mantık sistemleri, belirsizlik içeren ortamlarda insan benzeri karar verme süreçlerini modelleme kabiliyeti sayesinde trafik gibi karmaşık sistemler için etkili bir alternatif sunmaktadır. Mamdani tipi bulanık çıkarım yapıları, IF-THEN kurallarına dayalı yapısı ile modelin davranışının şeffaf biçimde izlenmesine olanak sağlar. Ayrıca, yorumlanabilirliği yüksek, düşük ön işleme gerektiren ve kural tabanlı yapısıyla saha uygulamalarında avantajlıdır [4, 5].

Mevcut literatürde, bulanık mantık sistemleri genellikle trafik ışığı kontrolü, kavşak optimizasyonu veya simülasyon ortamlarına odaklanmıştır. Gerçek şehir verileri ile saatlik trafik yoğunluğu tahmini amacıyla geliştirilmiş ve geleneksel yöntemlerle karşılaştırmalı analiz içeren çalışmalar oldukça sınırlıdır [6].

Bu çalışma, İstanbul Büyükşehir Belediyesi tarafından sağlanan 2022 yılına ait toplam 8.539 saatlik trafik yoğunluğu verisi ile Meteostat'tan temin edilen 365 günlük hava durumu verilerini bütünleştirerek Mamdani tabanlı bir bulanık mantık modeli geliştirmeyi amaçlamaktadır. Modelde araç sayısı, ortalama hız, sıcaklık ve yağış olmak üzere dört temel değişken kullanılmış; başarıyı ise yalnızca geleneksel regresyon modelleriyle değil, aynı zamanda modern yapay öğrenme algoritmaları olan Karar Ağacı, Rastgele Orman, XGBoost ve LSTM ile de deneysel olarak karşılaştırılmıştır.

Geliştirilen model, R^2 değeri 0.87 gibi yüksek açıklayıcılık kapasitesi ve MAE: 5.32, RMSE: 7.45 gibi düşük hata oranları ile öne çıkmaktadır. Ayrıca yorumlanabilir karar yapısı ve belirsiz değişkenlerle çalışma becerisi sayesinde, akıllı ulaşım sistemlerine entegre edilebilecek potansiyele sahip bir yapay zekâ yaklaşımı sunmaktadır [4, 6].

2. İLGİLİ ÇALIŞMALAR (RELATED WORKS)

Kentsel alanlarda artan trafik yoğunluğu sorunları, özellikle nüfus yoğunluğu ve araç sahipliğindeki artış nedeniyle modern şehir yönetimi için önemli bir zorluk haline gelmiştir. Geleneksel trafik yönetimi teknikleri, kentsel trafik modellerinin karmaşıklığı ve değişkenliğiyle başa çıkmakta genellikle yetersiz kalmakta ve bu da dinamik çözümler sunabilen akıllı sistemlerin araştırılmasını gerektirmektedir. Bulanık mantık, belirsiz veya kesin olmayan girdilere dayalı kararlar alabilme yeteneği sayesinde yapay zekânın bir dalı olarak öne çıkmıştır. Bu özelliği, belirsizliğin doğasında olduğu trafik koşullarını modellemek için özellikle uygundur. Bulanık mantık sistemleri, insan benzeri muhakeme ve uyum yeteneğini karar alma süreçlerine dahil ederek daha incelikli trafik yönetimi stratejileri geliştirilmesine olanak tanır [4, 7, 8].

Bulanık mantığın trafik yönetimindeki en etkili uygulamalarından biri, kentsel ulaşım ağlarının kritik noktaları olan kavşaklarda trafik akışını optimize etmektir. Araştırmacılar, araç yoğunluğu ve trafik akışı gibi gerçek zamanlı verilere dayanarak trafik ışığı zamanlamalarını dinamik olarak ayarlayan bulanık mantık denetleyicileri geliştirmiştir. Örneğin, yapılan çalışmalar, uyarlanabilir bulanık mantık kontrollü trafik ışıklarının kavşaklarda bekleme sürelerini önemli ölçüde azaltarak genel trafik verimliliğini artırdığını göstermiştir [6, 9].

Ayrıca, sensör teknolojileriyle entegre edilen bulanık mantık sistemleri, trafik koşullarını daha doğru bir şekilde izlemek için geliştirilmiştir. Bu sistemler, araç sayısı, kuyruk uzunluğu ve geçmiş trafik verileri gibi çeşitli girdi değişkenlerini kullanarak trafik ışığı zamanlamalarını gerçek zamanlı olarak ayarlar. Bu yaklaşım, trafik yönetiminin duyarlılığını ve etkinliğini artırarak sıkışıklığı ve bununla ilişkili sorunları azaltır [5, 10, 11]. Araştırmalar, bu tür dinamik denetleyicilerin yalnızca trafik sıkışıklığını hafifletmekle kalmayıp, aynı zamanda kırmızı ışıklarda bekleme süresini en aza indirerek emisyonları, kaza oranlarını ve yakıt tüketimini azalttığını göstermektedir [12-14].

Araçlar arası iletişim ağları (VANETs) bağlamında, bulanık mantık sistemleri haberleşme teknolojileriyle entegre edilerek trafik koşullarına ilişkin bilgilerin araçlar ve altyapı arasında paylaşılmasını sağlamaktadır. Bu entegrasyon, işbirlikçi bir trafik yönetimi ekosistemi oluşturarak yönlendirme protokollerini optimize eder ve trafik darboğazlarını azaltır [15-17]. Bu akıllı sistemler, yalnızca trafik yönetimi verimliliğini artırmakla kalmaz, aynı zamanda acil durum müdahalelerini desteklemek için kritik araç hareketlerine öncelik verir [18, 19].

Bulanık mantığın trafik sistemlerindeki temel prensibi, trafik modellerini etkileyen karmaşık insan faktörlerini modelleyebilme yeteneğidir. Sürücü davranışları, trafik ışıklarına tepkiler ve dış koşulların neden olduğu değişkenler, trafik akışının kaotik doğasına katkıda bulunur. Bulanık mantık, bu değişkenleri etkili bir şekilde yorumlamak için insan bilişsel süreçlerini taklit eder ve trafik ışığı yönetiminde daha bilinçli kararlar alınmasını sağlar [20-22]. Bulanık küme teorisinden yararlanarak, trafik kontrol sistemleri belirsiz verileri işleyebilir ve hızla değişen ve öngörülemeyen kentsel trafik ortamında bağlama uygun yanıtlar üretebilir [23, 24].

Ayrıca, bulanık mantığın akıllı kavşakların tasarımında da önemli bir rol oynadığı gösterilmiştir. Bu sistemler, yaya dedektörlerini ve yaya trafik hacimlerini araç sayılarıyla birlikte değerlendirerek kapsamlı bir trafik yönetimi yaklaşımı sunar. Bu strateji, yalnızca trafik akışını iyileştirmekle kalmaz, aynı zamanda yaya güvenliğini önceliklendirerek bulanık mantık sistemlerinin farklı kentsel ulaşım ihtiyaçlarını karşılama konusundaki çok yönlülüğünü gösterir [6, 10].


Son yıllarda makine öğrenmesi (ML) ve derin öğrenme (DL) tabanlı yöntemler trafik tahmininde öne çıkmıştır. Özellikle uzun-kısa süreli hafıza ağları (LSTM), kapılı tekrarlayan üniteler (GRU), gradyan artırma (XGBoost) ve grafik sinir ağları (GNN) gibi modeller, zaman serisi tahminlerinde başarılı sonuçlar vermektedir [1, 2, 25]. LSTM, trafik hacmi gibi zamansal desenlerin modellenmesinde yüksek doğruluk sunarken, XGBoost algoritması güçlü regresyon yeteneği sayesinde kısa vadeli tahminlerde sıkça tercih edilmektedir.

Ancak bu modellerin genellikle "kara kutu" yapıda olması, yorumlanabilirliklerinin düşük olması ve yoğun veri ön işleme ihtiyacı, bazı uygulama senaryolarında sınırlayıcı olmaktadır [26]. Bu noktada, belirsizliklerin yüksek olduğu sistemlerde bulanık mantık gibi kural tabanlı yapay zekâ yaklaşımları avantaj sunmaktadır. Bulanık mantık sistemleri, belirsiz, eksik veya dilsel nitelikli verileri işleyebilme kapasitesi sayesinde, trafik yoğunluğu tahmini gibi çok değişkenli problemler için uygun bir zemin oluşturur [4].

Bu bağlamda, çalışmamız; İstanbul gibi yüksek yoğunluklu bir şehir için gerçek saatlik trafik verilerini ve hava durumu değişkenlerini entegre ederek, Mamdani tipi bir bulanık mantık modeli geliştirmekte ve bu modelin doğruluğunu geleneksel regresyon yöntemleri ile karşılaştırmaktadır. Böylece hem açıklanabilir hem de sahada uygulanabilir bir tahmin modeli sunularak literatürdeki bu boşluk hedeflenmektedir.

3. MATERYAL ve YÖNTEM (MATERIAL and METHOD)

Bu bölümde, çalışmada kullanılan veri setleri, bulanık mantık modelinin oluşturulması, kullanılan çıkarım yöntemi ve modelin değerlendirme süreçleri detaylandırılmıştır. Çalışmanın tekrar edilebilirliğini sağlamak amacıyla, her aşama sistematik bir şekilde açıklanmıştır. Bu çalışma kapsamında izlenen metodolojik süreç Şekil 1’de akış diyagramı şeklinde özetlenmiştir. Veri toplama aşamasından modelin değerlendirilmesine kadar olan tüm adımlar sistematik olarak gösterilmiştir.



Şekil 1. Çalışmanın Metodolojik Akış Diyagramı (Methodological Flow Diagram of the Study)

3.1 Veri Toplama (Data Collection)

Bu çalışmada, trafik yoğunluğu tahmini amacıyla Meteostat platformundan elde edilen günlük hava durumu verileri [27] ile İstanbul Büyükşehir Belediyesi (İBB) tarafından sağlanan saatlik trafik yoğunluğu verileri [28] birleştirilmiştir. Trafik verisi, 2022 yılına ait olup toplam 8.539 saatlik kayıt içermektedir. Hava durumu verisi ise aynı yıl boyunca günlük olarak 365 satırdan oluşmaktadır. Analiz kapsamında dört temel değişken belirlenmiş ve modelin giriş parametreleri olarak kullanılmıştır: hava sıcaklığı (°C), trafikte bulunan toplam araç sayısı, araçların ortalama hızı (km/h) ve belirli bir saatte gerçekleşen yağış miktarı (mm). Bu değişkenler, trafik akışının dinamiklerini daha iyi anlamak amacıyla detaylı bir şekilde analiz edilmiştir. Çalışmada kullanılan İBB’ye ait örnek trafik verileri Tablo 1’de sunulmaktadır.

Tablo 1. İBB’ye ait örnek trafik verileri (Sample traffic data of IMM)

Tarih	Asgari Hız	Azami Hız	Ortalama Hız	Araç Sayısı
01-01-2022 00:00:00	40	97	59	32
01-01-2022 01:00:00	45	125	79	22
01-01-2022 02:00:00	80	177	100	9
01-01-2022 03:00:00	110	110	110	1

Tablo 1, çalışmada kullanılan trafik verilerini içermektedir. İstanbul Büyükşehir Belediyesi (İBB) açık veri portalından temin edilen saatlik trafik yoğunluğu verileri, belirli değişkenler çerçevesinde modellenmiştir. Tablo, trafik yoğunluğu tahmin modelinde kullanılan temel parametreleri göstermektedir. Tablonun ilk sütunu “Tarih” olup, her veri noktasının zaman damgasını içermektedir. “Asgari Hız” ve “Azami Hız”

sütunları, belirli bir saatte kaydedilen en düşük ve en yüksek araç hızlarını ifade etmektedir. “Ortalama Hız” sütunu, trafik akışının genel hız seviyesini gösterirken, “Araç Sayısı” sütunu, ilgili saat diliminde belirlenen yoldan geçen toplam araç sayısını temsil etmektedir. Bu veriler, trafik akışını daha iyi anlamak ve trafik yoğunluğu tahmin modelini geliştirmek amacıyla detaylı bir şekilde analiz edilmiştir. Modelde giriş değişkenleri olarak kullanılan bu parametreler, trafik dinamiklerini anlamak ve bulanık mantık tabanlı tahmin süreçlerini desteklemek açısından kritik bir rol oynamaktadır.

3.2 Veri Ön İşleme (Data Preprocessing)

Bu çalışmada kullanılan veri setleri, trafik yoğunluğu tahmin modelinin doğruluğunu artırmak ve güvenilir sonuçlar elde etmek amacıyla çeşitli ön işleme adımlarından geçirilmiştir. Veri ön işleme süreci; eksik verilerin kontrolü, veri ölçekleme işlemleri ve model türlerine göre uygun formatta hazırlanması gibi aşamaları içermektedir.

İBB trafik verileri ve Meteostat hava durumu verileri incelendiğinde, trafik verisinin 2022 yılına ait toplam 8.539 saatlik kayıttan oluştuğu belirlenmiştir. Beklenen 8.760 saatlik ($365 \text{ gün} \times 24 \text{ saat}$) veri üzerinden değerlendirildiğinde, yaklaşık %2,5 oranında eksik kayıt bulunduğu tespit edilmiştir. Ancak yapılan kontrollerde sistematik eksiklik, aykırı değer ya da anlamlı bir sapma gözlemlenmemiştir. İBB trafik yoğunluğu verileri saatlik frekansta sağlanırken, Meteostat hava durumu verileri günlük bazda elde edilmiştir. Bu nedenle iki veri seti uygun zaman dilimlerine göre senkronize edilerek analiz için hazır hale getirilmiştir.

Farklı modelleme yaklaşımlarında (ML/DL) kullanılan değişkenlerin ölçek uyumu performans açısından önem arz etmektedir. Bu doğrultuda, makine öğrenmesi ve derin öğrenme modelleri için trafik hızı, araç sayısı ve sıcaklık gibi sürekli değişkenler min-max normalizasyon yöntemiyle 0-1 aralığına dönüştürülmüştür. Bu işlem, ölçek farklarının model eğitim sürecinde oluşturabileceği dengesizlikleri azaltarak daha sağlıklı öğrenme sağlamaktadır. Yağış değişkeni ise kategorik (yağış var/yok) biçimde yeniden kodlanarak sayısal forma dönüştürülmüştür. Bulanık mantık modelinde ise normalizasyon işlemi doğrudan uygulanmamış; bunun yerine, her değişken için uygun aralıklar belirlenerek üçlü üyelik fonksiyonları tanımlanmıştır. Böylece, model girişleri bulanıklaştırma sürecinde doğrudan işlenmiş ve sistemin belirsiz verilerle uyumlu çalışması sağlanmıştır.

3.3 Veri Bölme (Data Splitting)

Model eğitiminde kullanılacak verilerin doğru şekilde bölünmesi, tahmin modellerinin genellebilirliğini ve güvenilirliğini doğrudan etkileyen kritik bir adımdır. Bu çalışmada, klasik yöntem olan tek seferlik %80–%20 eğitim-test bölünmesi yerine, zaman sırasına duyarlı beş katlı bloklu çapraz doğrulama (5-Fold Time Series Cross-Validation) yöntemi uygulanmıştır. Bu strateji, zaman serisi yapısına sahip trafik verilerinde veri sızıntısını önleyerek daha gerçekçi bir değerlendirme ortamı sunmaktadır. Zamana bağlı çapraz doğrulamada, veriler kronolojik sıraya göre artan şekilde bölünmekte ve her fold’da model daha önceki gözlemlerle eğitilip sonraki gözlemlerle test edilmektedir. Bu yapı sayesinde hem modelin kısa vadeli tahmin başarımı hem de zaman içerisinde kararlılığı değerlendirilebilmiştir.

3.4 Geleneksel İstatistiksel Tahmin Yöntemleri (Traditional Statistical Methods)

Doğrusal regresyon (Linear Regression, LR) ve çoklu doğrusal regresyon (Multiple Linear Regression, MLR) istatistiksel modelleme ve tahmin yöntemlerinde yaygın olarak kullanılan tekniklerdir. LR bir bağımlı değişken ile bir bağımsız değişken arasındaki doğrusal ilişkiyi modellemek için kullanılan temel bir istatistiksel yöntemdir. Bu modelde bağımlı değişken, bağımsız değişkenin belirli bir katsayı ile çarpılması ve sabit bir terimin eklenmesiyle tahmin edilir. Matematiksel olarak doğrusal regresyon modeli şu şekilde ifade edilir:

$$Y = \beta_0 + \beta_1 X + \varepsilon \quad (1)$$

Burada Y , tahmin edilmek istenen bağımlı değişkeni temsil ederken, X bağımsız değişkendir. Sabit terim olan β_0 , modelin $X = 0$ olduğunda Y 'nin alacağı değeri gösterirken, β_1 , bağımsız değişkenin bağımlı değişken üzerindeki etkisini ifade eden katsayıdır. Modelin açıklayamadığı değişkenliği temsil eden ε ise hata terimi olarak adlandırılır. LR, bağımsız değişkenin bağımlı değişken üzerindeki etkisini belirlemek ve gelecekteki değerleri tahmin etmek için kullanılır. Örneğin, bir ürünün fiyatı ile satış miktarı arasındaki ilişkiyi analiz etmek amacıyla doğrusal regresyon modeli oluşturulabilir.

MLR, bir bağımlı değişkenin birden fazla bağımsız değişkenle olan ilişkisini modellemek için kullanılan bir yöntemdir. Bu modelde, bağımlı değişken birden fazla bağımsız değişkenin ağırlıklı toplamı olarak ifade edilir ve her bağımsız değişkenin etkisi farklı katsayılarla gösterilir. Matematiksel olarak çoklu doğrusal regresyon modeli şu şekilde ifade edilir:

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_n X_n + \varepsilon \quad (2)$$

Bu denklemde Y , tahmin edilmek istenen bağımlı değişkeni ifade ederken, $X_1, X_2, \dots, X_n$ bağımsız değişkenleri temsil eder. Sabit terim olan β_0 , bağımsız değişkenler sıfır olduğunda bağımlı değişkenin aldığı değeri gösterirken, $\beta_1, \beta_2, \dots, \beta_n$ katsayıları, her bir bağımsız değişkenin bağımlı değişken üzerindeki etkisini ifade eder. Modelin açıklayamadığı değişkenlik ise hata terimi ε ile gösterilir. Çoklu doğrusal regresyon, bağımlı değişkenin birden fazla faktörden etkilendiği durumlarda daha doğru tahminler yapmaya yardımcı olur ve tek bir bağımsız değişkenin yeterli olmadığı kompleks sistemlerde tercih edilir. Örneğin, bir evin fiyatını tahmin etmek için metrekare, oda sayısı, konum ve bina yaşı gibi birden fazla bağımsız değişken kullanılarak analiz yapılabilir.

3.5 Makine Öğrenme Yöntemleri (Machine Learning Methods)

Bu çalışmada geliştirilen Mamdani tipi bulanık mantık modelinin performansı, literatürde sıkça kullanılan çeşitli makine öğrenmesi (ML) ve derin öğrenme (DL) algoritmaları ile karşılaştırmalı olarak değerlendirilmiştir. Karşılaştırma yapılan modeller ve genel özellikleri aşağıda özetlenmiştir:

- Karar Ağacı (DT): Veriyi dallara ayırarak sınıflandırma veya regresyon yapan, kural tabanlı ve yorumlanabilir bir makine öğrenmesi algoritmasıdır.
- Rastgele Orman (RF): Birden fazla karar ağacından oluşan topluluk (ensemble) modeli olup, aşırı öğrenme riskini azaltarak yüksek doğruluk sağlamayı hedefler.
- Gradyan Artırmalı Ağaç (XGBoost): Art arda oluşturulan ağaç modelleriyle artık hataları minimize eden güçlü ve optimize edilmiş bir topluluk öğrenme yöntemidir.
- Uzun-Kısa Süreli Bellek Ağı (LSTM): Özellikle zaman serisi verilerde uzun vadeli bağımlılıkları öğrenebilen, tekrarlayan sinir ağı (RNN) türüdür.

Tablo 2’de, her bir makine öğrenmesi ve derin öğrenme modeline ait temel parametre ayarları sunulmaktadır:

Tablo 2. Kullanılan ML/DL modellerinin temel parametreleri (Main parameters of ML/DL models used)

Model	Parametreler
DT	Maksimum derinlik = 10, minimum bölünme örnek sayısı = 5
RF	Ağaç sayısı = 100, maksimum derinlik = 12
XGBoost	Öğrenme oranı = 0.1, ağaç sayısı = 100, maksimum derinlik = 6, örnekleme oranı = 0.8
LSTM	Eğitim tekrar sayısı = 50, toplu işlem boyutu = 32, gizli katman nöron sayısı = 64, optimizasyon algoritması = Adam, bırakma oranı = 0.2, girdi dizisi uzunluğu = 6

3.6 Bulanık Mantık Modeli (Fuzzy Logic Model)

Bulanık mantık modeli, belirsizlikleri ve kesin olmayan verileri değerlendirmek için kullanılan bir yapay zeka yöntemidir. Bu çalışmada Mamdani bulanık çıkarım yöntemi kullanılarak trafik yoğunluğu tahmin modeli geliştirilmiştir. Mamdani yöntemi, yorumlanabilirlik (explainability) sağlaması ve kurallara dayalı

karar yapısı sayesinde özellikle açıklanabilir yapay zekâ uygulamaları için tercih edilmiştir [3]. Modelde dört temel giriş değişkeni (araç sayısı, ortalama hız, sıcaklık, yağış) tanımlanmış; her biri için üçlü üyelik fonksiyonları (düşük–orta–yüksek) oluşturulmuştur. Yağış durumu ikili olarak modellenmiştir (yağış var/yok). Her bir kombinasyon için toplamda 54 kuraldan oluşan bir kural tabanı kurulmuştur. Modelin oluşturulma süreci aşağıdaki adımlardan oluşmaktadır:

3.6.1 Giriş değişkenlerinin tanımlanması (Defining input variables)

Modelde kullanılan dört temel giriş değişkeni belirlenmiştir: hava sıcaklığı, araç sayısı, ortalama hız ve yağış durumu. Her bir değişken için bulanık küme aralıkları Tablo 3'te gösterilmektedir.

Tablo 3. Dört temel giriş değişkeni (Four main input variables)

Değişkenler	Üyelik 1	Üyelik 2	Üyelik 3
Sıcaklık	Düşük (D)	Orta (O)	Yüksek (Y)
Araç Sayısı	Az	Orta	Çok
Ortalama Hız	Yavaş	Orta	Hızlı
Yağış Durumu	Yağış Yok (0)	Yağış Var (1)	-

3.6.2 Bulanıklaştırma (Fuzzification)

Bulanıklaştırma aşamasında, giriş değişkenleri belirli bulanık üyelik fonksiyonlarına atanmıştır. Bu çalışmada, değişkenler için lojistik (sigmoid) üçgen üyelik fonksiyonu kullanılmıştır. Üyelik fonksiyonları şu denklem ile tanımlanmıştır:

$$\mu_A(x) = \frac{1}{1 + e^{-\alpha(x-c)}} \quad (3)$$

Burada $\mu_A(x)$, değişkenin üyelik derecesini; α eğimin keskinliğini; c ise merkez değerini göstermektedir.

3.6.3 Kural tabanı (Rule base)

Kural tabanı, giriş değişkenlerinin tüm olası kombinasyonlarını içerecek şekilde oluşturulmuştur. Her kombinasyon için trafik yoğunluğu, deneyim, geçmiş verilere dayalı analizler ve mantıklı ilişkiler göz önünde bulundurularak çalışmada, trafik yoğunluğunu tahmin etmek için 54 farklı kural belirlenmiştir. Modelin temel karar mekanizmasını oluşturan kural tabanının bir kısmı Tablo 4'de sunulmaktadır:

Tablo 4. Örnek trafik yoğunluğu tahmin kuralları (Sample traffic congestion prediction rules)

Ortalama Hız	Araç Sayısı	Sıcaklık	Yağış	Trafik Yoğunluğu
Düşük	Düşük	Düşük	0	Düşük
Düşük	Düşük	Düşük	1	Orta
Düşük	Düşük	Orta	0	Düşük
Düşük	Düşük	Orta	1	Orta
Düşük	Düşük	Yüksek	0	Düşük
Düşük	Düşük	Yüksek	1	Orta
Düşük	Orta	Düşük	0	Orta
Düşük	Orta	Düşük	1	Yüksek
Düşük	Orta	Orta	0	Orta
Düşük	Orta	Orta	1	Yüksek

Bu kural tabanı, 54 farklı “Eğer-O Halde” (IF-THEN) kuralından oluşmaktadır. Her bir kural, giriş değişkenlerinin belirli bir kombinasyonuna karşılık gelen trafik yoğunluğu seviyesini belirlemektedir.

3.6.4 Mamdani bulanık çıkarım yöntemi (Mamdani fuzzy inference method)

Bu çalışmada, bulanık mantık sistemi olarak Mamdani çıkarım yöntemi kullanılmıştır. Mamdani bulanık mantık yöntemi, "Eğer-O Halde" kurallarını kullanarak giriş değişkenlerine dayalı bir karar mekanizması oluşturur. Bu yöntem, aşağıdaki adımlardan oluşur:

- Bulanıklaştırma: Sayısal giriş değerlerinin uygun üyelik fonksiyonlarına atanması.
- Kural Değerlendirme: Tüm kuralların giriş verilerine göre hesaplanması.
- Bulanık Çıkış Üretimi: Kural tabanına göre bulanık sonuçların elde edilmesi.
- Durulaştırma (Defuzzification): Ağırlık Merkezi (Centroid) yöntemi ile kesin çıkış değerinin belirlenmesi.

3.7 Modelin değerlendirme süreci

Model performansının değerlendirilmesi için Ortalama Mutlak Hata (MAE), Kök Ortalama Kare Hatası (RMSE) ve R^2 (Belirlilik Katsayısı) metrikleri kullanılmıştır. Bu metrikler, bağımsız değişkenlerin bağımlı değişken üzerindeki değişkenliği ne kadar açıkladığını belirlemek ve hata oranlarını analiz etmek amacıyla tercih edilmiştir.

MAE, tahmin edilen değerler ile gerçek değerler arasındaki farkların mutlak ortalamasını alarak modelin genel hata seviyesini ölçer. MAE, aşağıdaki formülle hesaplanır:

$$MAE = \sqrt{\frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|} \quad (4)$$

Burada, burada y_i gerçek değerleri, $\hat{y}_i$ modelin tahmin ettiği değerleri ve n toplam veri sayısını ifade eder. RMSE ise hata değerlerinin karelerinin ortalamasının karekökü alınarak hesaplanır. Bu metrik, büyük hatalara daha duyarlıdır ve modelin hata dağılımı hakkında daha ayrıntılı bilgi sunar. RMSE, aşağıdaki formülle hesaplanır:

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

R^2 (Belirlilik Katsayısı), modelin bağımlı değişkendeki değişimi ne kadar iyi açıkladığını gösteren bir ölçüttür. 0 ile 1 arasında bir değer alır ve modele ait tahminlerin gerçek değerlere ne derece yakın olduğunu belirlemek için kullanılır. R^2 , şu şekilde hesaplanır:

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (6)$$

Burada, y_i , gerçek değerlerin ortalamasıdır. R^2 'nin 1'e yakın olması, modelin yüksek doğrulukla tahmin yaptığını gösterirken, düşük R^2 değerleri modelin veriyi yeterince iyi açıklayamadığını işaret eder.

4. BULGULAR ve TARTIŞMA (RESULTS and DISCUSSIONS)

Bu bölümde, geliştirilen bulanık mantık tabanlı trafik yoğunluğu tahmin modelinin performansı değerlendirilmiş ve elde edilen sonuçlar ayrıntılı olarak sunulmuştur.

4.1 Üyelik Fonksiyonları ve Kural Tabanı (Membership Functions and Rule Base)


Bulanık mantık tabanlı modellerde, giriş değişkenlerinin bulanık kümelerle atanması üyelik fonksiyonları aracılığıyla gerçekleştirilir. Bu çalışmada, trafik yoğunluğunu etkileyen dört temel değişken (araç sayısı, ortalama hız, sıcaklık ve yağış durumu) için üyelik fonksiyonları tanımlanmıştır.

4.1.1 Araç sayısına göre üyelik fonksiyonları (Membership functions based on the number of vehicles)

Araç sayısı, trafik yoğunluğunu doğrudan etkileyen bir değişkendir. Şekil 2'de gösterildiği üzere, araç sayısına bağlı olarak üç farklı üyelik fonksiyonu tanımlanmıştır:

- Düşük (Low): 0-20 araç aralığında geçerlidir. Araç sayısı sıfıra yaklaştıkça üyelik derecesi 1'e ulaşırken, 20 araçta sıfıra düşer.
- Orta (Medium): 20-60 araç aralığında geçerlidir. 40 araç civarında maksimum üyelik derecesine ulaşır.
- Yüksek (High): 60 araç ve üzerinde geçerlidir. Araç sayısı arttıkça üyelik derecesi artar ve 100 araçta maksimuma ulaşır.

Bu fonksiyonlar, trafik yoğunluğunun araç sayısına bağlı olarak nasıl değiştiğini net bir şekilde ortaya koymaktadır.




Şekil 2. Araç Sayısına Göre Üyelik Fonksiyonları (Membership Functions Based on the number of vehicles)

4.1.2 Ortalama hıza göre üyelik fonksiyonları (Membership functions based on average speed)

Ortalama hız, trafik akışının bir göstergesidir. Şekil 3'te gösterildiği gibi, ortalama hız için üç üyelik fonksiyonu tanımlanmıştır:

- Düşük (Low): 0-20 km/h aralığında geçerlidir. Hız sıfıra yaklaştıkça üyelik derecesi artar.
- Orta (Medium): 20-60 km/h aralığında geçerlidir. 40 km/h'de maksimum üyelik derecesine ulaşır.
- Yüksek (High): 60 km/h ve üzerinde geçerlidir. Hız arttıkça üyelik derecesi artar.

Bu fonksiyonlar, düşük hızların trafik sıkışıklığıyla ilişkili olduğunu, yüksek hızların ise daha serbest trafik akışını temsil ettiğini göstermektedir.




Şekil 3. Ortalama Hıza Göre Üyelik Fonksiyonları (Membership Functions Based on Average Speed)

4.1.3 Sıcaklığa göre üyelik fonksiyonları (Membership functions based on temperature)

Sıcaklık, trafik yoğunluğunu dolaylı olarak etkileyen bir faktördür. Şekil 4'te gösterildiği gibi, sıcaklık için üç üyelik fonksiyonu tanımlanmıştır:

- Düşük (Low): 0-10°C aralığında geçerlidir. Sıcaklık sıfıra yaklaştıkça üyelik derecesi artar.
- Orta (Medium): 10-30°C aralığında geçerlidir. 20°C'de maksimum üyelik derecesine ulaşır.
- Yüksek (High): 30°C ve üzerinde geçerlidir. Sıcaklık arttıkça üyelik derecesi artar.

Bu fonksiyonlar, düşük ve yüksek sıcaklıkların trafik yoğunluğunu artırabileceğini, orta sıcaklıkların ise daha dengeli bir trafik akışı sağlayabileceğini göstermektedir.




Şekil 4. Sıcaklığa Göre Üyelik Fonksiyonları (Membership Functions Based on Temperature)

4.1.4 Yağış durumuna göre üyelik fonksiyonları (Membership functions based on precipitation condition)

Yağış, trafik yoğunluğunu önemli ölçüde etkileyen bir değişkendir. Şekil 5'te gösterildiği gibi, yağış durumu için iki üyelik fonksiyonu tanımlanmıştır:

- Yağış Yok (No Precipitation): Yağış miktarı sıfıra yaklaştıkça üyelik derecesi artar.
- Yağış Var (Precipitation): Yağış miktarı arttıkça üyelik derecesi artar.

Bu fonksiyonlar, yağışlı havalarda trafik sıkışıklığının artabileceğini öngörmektedir.



Şekil 5. Yağışa Göre Üyelik Fonksiyonları (Membership Functions Based on Precipitation Condition))

Bu fonksiyonlar, her değişkenin farklı seviyelerini belirlemek için kullanılmış ve modelin daha esnek bir şekilde çalışmasını sağlamıştır.

4.2 Model Performansı ve Sonuçların Değerlendirilmesi (Model Performance and Evaluation of Results)

Geliştirilen Mamdani tipi bulanık mantık tabanlı trafik yoğunluğu tahmin modeli, istatistiksel yöntemler ve farklı makine öğrenmesi ve derin öğrenme algoritmalarıyla karşılaştırmalı olarak değerlendirilmiştir. Değerlendirme sürecinde İstanbul Büyükşehir Belediyesi'nden (İBB) alınan gerçek trafik yoğunluğu verileri kullanılmış ve modellerin tahmin sonuçları, performans metrikleri (MAE, RMSE ve R^2) üzerinden analiz edilmiştir. Sonuçlar, araç sayısındaki artış ve ortalama hızdaki düşüşün trafik yoğunluğunu artırdığı; yağış varlığının da tahmin edilen yoğunluk seviyelerinde yükselmeye yol açtığını göstermiştir. Sonuçlar, Tablo 5'te karşılaştırmalı olarak sunulmuş ve Şekil 6 ile Şekil 7'de grafiksel olarak görselleştirilmiştir.


Tablo 5. Modellerin performans karşılaştırması (Ortalama $\pm$ Standart Sapma) (Performance comparison of models (Mean $\pm$ Standard Deviation))

Model	MAE ($\pm$ SS)	RMSE ($\pm$ SS)	R^2 ($\pm$ SS)
Mamdani BM	5.32 $\pm$ 0.85	7.45 $\pm$ 1.12	0.87 $\pm$ 0.03
LR	7.89 $\pm$ 0.76	10.45 $\pm$ 1.35	0.47 $\pm$ 0.06
MLR	6.54 $\pm$ 0.63	9.21 $\pm$ 1.21	0.63 $\pm$ 0.05
DT	6.11 $\pm$ 0.70	8.45 $\pm$ 1.04	0.71 $\pm$ 0.04
RF	5.03 $\pm$ 0.61	6.92 $\pm$ 0.98	0.89 $\pm$ 0.03
XGBoost	4.71 $\pm$ 0.89	6.48 $\pm$ 1.27	0.90 $\pm$ 0.05
LSTM	4.42 $\pm$ 1.05	6.11 $\pm$ 1.38	0.91 $\pm$ 0.06


Tablo ve şekillere göre Mamdani bulanık mantık modeli, MAE: 5.32 ve RMSE: 7.45 değerleriyle düşük hata oranları sunarken; R^2 : 0.87 değeri ile bağımlı değişkendeki değişimi yüksek oranda açıklayabildiğini göstermiştir. Bu performans, doğrusal regresyon (LR: MAE = 7.89, RMSE = 10.45, R^2 = 0.47) ve çoklu doğrusal regresyon (MLR: MAE = 6.54, RMSE = 9.21, R^2 = 0.63) modellerine kıyasla belirgin derecede daha iyidir.

Modern makine öğrenmesi ve derin öğrenme modelleri arasında en düşük hata değerlerine LSTM (MAE: 4.42, RMSE: 6.11, R^2 : 0.91) ve XGBoost (MAE: 4.71, RMSE: 6.48, R^2 : 0.90) ulaşmıştır. Ayrıca, LSTM ve XGBoost gibi sıralı bağımlılıkları modelleme kapasitesi yüksek algoritmalarda, veri blokları arasındaki zaman temelli varyasyonlar nedeniyle hata metriklerinin standart sapmalarında diğer modellere kıyasla daha yüksek değerler gözlemlenmiştir. Bu durum, söz konusu modellerin zamana duyarlılık açısından daha hassas olduğunu ve model kararlılığının veri bloklarındaki yapısal farklılıklardan etkilenebileceğini göstermektedir. Ancak bu modellerin yüksek hesaplama gücü gereksinimi, karmaşık yapılandırılmaları ve

yorumlanabilirliğinin sınırlı olması, trafik yönetimi gibi karar desteği gerektiren alanlarda doğrudan uygulanabilirliğini kısıtlamaktadır. Mamdani modelinin açıklanabilir kural tabanı (örneğin: "Eğer hız düşük ve araç sayısı yüksekse, yoğunluk yüksektir") kullanıcıların sistem içgörüsünü daha kolay elde etmesine olanak tanımaktadır.



Şekil 6. Modellerin MAE ve RMSE Değerleri (MAE and RMSE Values of Models)



Şekil 7. Modellerin R² Değerleri (R² Values of Models)

5. SONUÇ (CONCLUSION)

Bu çalışma, trafik yoğunluğunun tahmini amacıyla Mamdani tipi bulanık mantık modelinin etkinliğini değerlendirmekte ve modelin gerçek şehir verileriyle uygulanabilirliğini ortaya koymaktadır. İstanbul Büyükşehir Belediyesi'ne ait 2022 yılına ait saatlik trafik yoğunluğu verileri ile Meteostat'tan elde edilen günlük hava durumu verileri birleştirilerek, araç sayısı, ortalama hız, sıcaklık ve yağış olmak üzere dört temel değişken üzerinden tahmin modeli geliştirilmiştir.

Geliştirilen model, MAE: 5.32, RMSE: 7.45 ve R²: 0.87 gibi yüksek doğruluk metrikleri ile başarılı bir performans sergilemiştir. Modelin performansı, yalnızca geleneksel doğrusal yöntemlerle (LR, MLR) değil, aynı zamanda modern makine öğrenmesi ve derin öğrenme algoritmaları (DT, RF, XGBoost, LSTM)

ile karşılaştırılmış; her model için beş katlı zaman sıralı çapraz doğrulama uygulanmış ve metrikler ortalama $\pm$ standart sapma biçiminde raporlanmıştır. Bu sayede hem doğruluk hem de sonuçların kararlılığı bütüncül şekilde değerlendirilmiştir.

Mamdani modeli, özellikle açıklanabilirlik ve kullanıcı tarafından anlaşılabilir kural tabanlı karar mekanizması açısından öne çıkmış, modern modellerin sunduğu düşük hata seviyelerine yakın sonuçlar üretmesine rağmen, şeffaflığı ve düşük hesaplama maliyeti sayesinde pratik avantajlar sunmuştur. Bu yönüyle çalışma, belirsizlik içeren trafik verilerinin, açıklanabilir yapay zekâ sistemleri ile etkili biçimde modellenebileceğini ortaya koymaktadır.

Bu çalışma bazı sınırlamalara sahiptir. Öncelikle, analiz yalnızca İstanbul iline ait 2022 verileri ile sınırlıdır; farklı şehirlerde ya da farklı zaman dilimlerinde modelin performansı değişebilir. İkinci olarak, bu çalışmada yalnızca dört değişken kullanılmıştır.

Gelecekte yapılacak çalışmalar kapsamında modelin farklı coğrafyalarda test edilmesi, daha fazla sayıda değişkenin entegrasyonu ve gerçek zamanlı veri akışıyla dinamik güncellemeler yapılması önerilmektedir. Ayrıca, hibrit modeller geliştirerek bulanık mantık sistemlerinin derin öğrenme veya istatistiksel yaklaşımlarla birleştirilmesi, doğruluk seviyesini artırabilir.

ÇIKAR ÇATIŞMASI (CONFLICT OF INTEREST)

Makale yazarları, aralarında herhangi bir çıkar çatışması olmadığını beyan ederler.

ARAŞTIRMA ve YAYIN ETİĞİ BEYANI (STATEMENT OF PUBLICATION ETHICS)

Çalışmanın tüm süreçlerinin araştırma ve yayın etiğine uygun olduğunu, etik kurallara ve bilimsel atıf gösterme ilkelerine uyduğunu beyan ederim.

YAZAR KATKISI (AUTHOR STATEMENT)

Cem ÖZKURT: Fikir, Tasarım ve Dizayn, Danışmanlık, Veri Toplama, Analiz/Yorum ve Ana Metni Yazma. **Ahmet KALA:** Tasarım ve Dizayn, Danışmanlık, Analiz/Yorum, Literatür Taraması ve Ana Metni Yazma. **Kübra KONUK:** Veri İşleme, Literatür Taraması ve Taslak Hazırlama. **Ayşe Nur SAYLAM:** Veri Toplama, Veri İşleme, Literatür Taraması ve Taslak Hazırlama.

KAYNAKLAR (REFERENCES)

- [1] Lv, Y. et al. (2015). Traffic flow prediction with big data: A deep learning approach. *IEEE Trans. Intell. Transp. Syst.*, 16(2), 865–873.
- [2] Zhou, Y., & Ding, Y. (2019). Traffic congestion prediction based on XGBoost. *Procedia Computer Science*, 147, 568–573.
- [3] Wu, Z. et al. (2019). Graph WaveNet for deep spatial-temporal graph modeling. *IJCAI*, 1907–1913.
- [4] Abdou, A., Farrag, M., & Tolba, A. (2022). A fuzzy logic-based smart traffic management system. *Journal of Computer Science*, 18(11), 1085–1099.
- [5] Jafari, S., Shahbazi, Z., & Byun, Y. (2021). Traffic control prediction design based on fuzzy logic and Lyapunov approaches to improve the performance of road intersection. *Processes*, 9(12), 2205.
- [6] Desmira, D., Hamid, M., Bakar, N., Nurtanto, M., & Sunardi, S. (2022). A smart traffic light using a microcontroller based on the fuzzy logic. *IAES International Journal of Artificial Intelligence*, 11(3), 809–816.
- [7] Mualifah, L., & Abadi, A. (2019). Optimizing the traffic control system of Sultan Agung Street Yogyakarta using fuzzy logic controller. *Journal of Physics: Conference Series*, 1320(1), 012028.
- [8] İnağ, T., & Arıkan, M. (2024). A fuzzy based intelligent traffic light control (ITLC) method: An implementation in Ankara city. *Bitlis Eren Üniversitesi Fen Bilimleri Dergisi*, 13(1), 292–306.
- [9] Chen, W., Zhao, H., Li, T., & Liu, Y. (2015). Intelligent traffic signal controller based on type-2 fuzzy logic and SGAI. *Journal of Intelligent & Fuzzy Systems*, 29(6), 2611–2618.

- [10] Karyaningsih, D., & Rizky, R. (2020). Implementation of fuzzy Mamdani method for traffic lights smart city in Rangkasbitung, Lebak Regency, Banten Province (Case study of the traffic light T-junction, Cibadak, By Pas Sukarno Hatta Street). *Jurnal KomtekInfo*, 7(3), 176–185.
- [11] Chabchoub, A., Hamouda, A., Al-Ahmadi, S., & Chérif, A. (2021). Intelligent traffic light controller using fuzzy logic and image processing. *International Journal of Advanced Computer Science and Applications*, 12(4), 396–399.
- [12] Tripathi, J., Kumar, D., & Singh, U. (2023). A review of different fuzzy models to evaluate vehicular traffic system. *SAMRIDDHI: A Journal of Physical Sciences, Engineering and Technology*, 15(1), 49–54.
- [13] Nguyen, H., Le, H., Nguyễn, V., & Lam, H. (2024). Development of the intelligent traffic light system based on image processing and fuzzy control techniques. *CTU Journal of Innovation and Sustainable Development*, 16(3), 9–20.
- [14] Wu, Y. (2024). Enhancing urban traffic flow through fuzzy logic-based signal light control optimization. *International Journal of E-Collaboration*, 20(1), 1–13.
- [15] Agrawal, A., & Paulus, R. (2021). Smart intersection design for traffic, pedestrian and emergency transit clearance using fuzzy inference system. *International Journal of Advanced Computer Science and Applications*, 12(3), 516–522.
- [16] Toan, T. (2021). Fuzzy-based quantification of congestion for traffic control. *Transport and Communications Science Journal*, 72(1), 1–8.
- [17] Naderi, M., Mahdaee, K., & Rahmani, P. (2023). Hierarchical traffic light-aware routing via fuzzy reinforcement learning in software-defined vehicular networks. *Peer-to-Peer Networking and Applications*, 16(2), 1174–1198.
- [18] Cunha, F., Villas, L., Boukerche, A., Maia, G., Viana, A., Mini, R., & Loureiro, A. A. F. (2016). Data communication in VANETs: Protocols, applications and challenges. *Ad Hoc Networks*, 44, 90–103.
- [19] Ding, Q., Sun, B., & Zhang, X. (2016). A traffic-light-aware routing protocol based on street connectivity for urban vehicular ad hoc networks. *IEEE Communications Letters*, 20(8), 1635–1638.
- [20] Collotta, M., Bello, L., & Pau, G. (2015). A novel approach for dynamic traffic lights management based on wireless sensor networks and multiple fuzzy logic controllers. *Expert Systems With Applications*, 42(13), 5403–5415.
- [21] Sahu, S., Agarwal, R., & Tyagi, R. K. (2019). Fuzzy vehicle control system for single intersection. *International Journal of Recent Technology and Engineering*, 8(2S7), 457–462.
- [22] Jiang, T., Wang, Z., & Chen, F. (2021). Urban traffic signals timing at four-phase signalized intersection based on optimized two-stage fuzzy control scheme. *Mathematical Problems in Engineering*, 2021, Article ID 5532568.
- [23] Arifin, M., Razi, S., Haque, A., & Mohammad, N. (2019). A microcontroller based intelligent traffic control system. *American Journal of Embedded Systems and Applications*, 7(1), 21–26.
- [24] Gupta, R., & Chaudhari, O. (2020). Application of fuzzy logic in prevention of road accidents using multi criteria decision alert. *Current Journal of Applied Science and Technology*, 39(36), 51–61.
- [25] Zhao, Z. et al. (2017). LSTM network: A deep learning approach for short-term traffic forecast. *IET Intelligent Transport Systems*, 11(2), 68–75.
- [26] Rudin, C. (2019). Stop explaining black box ML models for high stakes decisions and use interpretable models instead. *Nature Machine Intelligence*, 1(5), 206–215.
- [27] Meteostat. (2025, March 10). Istanbul climate data (2022). <https://meteostat.net/en/place/tr/istanbul?s=17060&t=2022-01-01/2022-12-31>.
- [28] İstanbul Büyükşehir Belediyesi. (2025, March 10). Hourly traffic density data set. <https://data.ibb.gov.tr/dataset/hourly-traffic-density-data-set>

