

**T.C.
AKDENİZ ÜNİVERSİTESİ**



**SENSÖR ARIZALARINA KARŞI AFET DİRENÇLİ DERİN ÖĞRENME
TABANLI SÜRDÜRÜLEBİLİR ADAPTİF TRAFİK SİNYALİZASYONUNUN
GELİŞTİRİLMESİ**

Seyitali İLYAS

**FEN BİLİMLERİ ENSTİTÜSÜ
ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ
ANABİLİM DALI
DOKTORA TEZİ**

EKİM 2025

ANTALYA

T.C.
AKDENİZ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**SENSÖR ARIZALARINA KARŞI AFET DİRENÇLİ DERİN ÖĞRENME
TABANLI SÜRDÜRÜLEBİLİR ADAPTİF TRAFİK SİNYALİZASYONUNUN
GELİŞTİRİLMESİ**

Seyitali İLYAS
ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ
ANABİLİM DALI
DOKTORA TEZİ

**Bu tez, TÜBİTAK (ARDEB) tarafından 124E123 no'lu proje, TÜBİTAK (BİDEB)
tarafından 2211-C Yurt İçi Öncelikli Alanlar Doktora programı ve Bursa
Büyükşehir Belediyesi tarafından Lisansüstü Tez Desteği kapsamında
desteklenmiştir.**

EKİM 2025

T.C.
AKDENİZ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

SENSÖR ARIZALARINA KARŞI AFET DİRENÇLİ DERİN ÖĞRENME
TABANLI SÜRDÜRÜLEBİLİR ADAPTİF TRAFİK SİNYALİZASYONUNUN
GELİŞTİRİLMESİ

Seyitali İLYAS
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ
ANABİLİM DALI
DOKTORA TEZİ

Bu tez 17/10/2025 tarihinde jüri tarafından Oybirliği ile kabul edilmiştir.

Dr. Öğr. Üyesi Yalçın Albayrak (Danışman)
Prof. Dr. Selçuk HELHEL
Prof. Dr. Hüseyin GÖKSU
Doç. Dr. Selim DÜNDAR
Doç. Dr. Murat İNCE

ÖZET

SENSÖR ARIZALARINA KARŞI AFET DİRENÇLİ DERİN ÖĞRENME TABANLI SÜRDÜRÜLEBİLİR ADAPTİF TRAFİK SİNYALİZASYONUNUN GELİŞTİRİLMESİ

Seyitali İLYAS

Doktora Tezi, Elektrik Elektronik Mühendisliği Anabilim Dalı

Danışman: Dr. Öğr. Üyesi Yalçın ALBAYRAK

İkinci Danışman: Doç. Dr. Sevil KÖFTECİ

Ekim 2025; 228 sayfa

Bu çalışma, geçmiş verilerle beslenerek geleceğe yönelik tahminler üreten bir dijital ikiz altyapısının geliştirilmesi kapsamında, adaptif sinyalizasyon kavşaklarda trafik sürekliliğinin sağlanabilmesi amacıyla gerçekleştirilmiştir. Bu bağlamda, kavşaklarda sensör arızası senaryolarına yönelik çözüm önerileri geliştirilmiş, adaptif trafik sinyalizasyon sistemlerinin modellenmesi ve en iyilemesi yapılmıştır.

Bursa Büyükşehir Belediyesi ve Antalya Büyükşehir Belediyesi Akıllı Kavşaklar Projeleri kapsamında kurulan Trafik Kontrol Merkezleri'nde elde edilen trafik verileri, bu çalışmanın temelini oluşturmuştur. Çalışmada, akıllı kavşak sistemlerinin daha verimli ve sürdürülebilir hale getirilmesi amacıyla derin öğrenme tabanlı yaklaşım geliştirilmiştir. SUMO Türkiye Uyarlaması aracılığıyla gerçekleştirilen benzetim çalışmaları ile trafik akış dinamikleri analiz edilmiş, veri analitiği yöntemleri uygulanmıştır. Tüm araç sınıfları için Birim Otomobil Eşdeğeri (Passenger Car Unit, PCU) dönüşümleri esas alınarak tahmin modelleri geliştirilmiş ve kapsamlı bir değerlendirme yapılmıştır. Bulgular LSTM, GRU, RNN, CNN tabanlı derin öğrenme modellerinin trafik hacmi tahmini açısından üstün performans sergilediğini ortaya koymuştur.

Bu çalışmanın sonucunda Heybe Kavşağı uygulamasında adaptif bir sinyalizasyon kavşakta sensör arızası durumunda, kavşak önceden belirlenmiş sabit zamanlı sinyal planında çalışmak yerine DQL tabanlı modele göre çalışmıştır. Böylece hizmet seviyesi E'den B'ye değişmiştir, ayrıca ortalama gecikme %61.3 azalmıştır ve ortalama hız %134.6 artmıştır.

Ardışık sinyalizasyon kavşakların bulunduğu uygulamada sürdürülebilirliği doğrudan etkileyen çevresel etkiler açısından değerlendirmeler kapsamında, SUMO benzetimi ile elde edilen emisyon çıktılarına göre yakıt tüketimleri esas alınarak, Yaşam Döngüsü Değerlendirmesi (Life Cycle Assessment, LCA) yapılmıştır. LCA sonucunda trafikten kaynaklı emisyonların Küresel Isınma Potansiyellerinin (Global Warming Potential, GWP) yanı sıra, ince partikül madde oluşumu, karasal ekosistemlerde ozon üretimi ve karasal asitlenme üzerinde de etkilere sahip olduğunu göstermiştir. Senaryoların uygulanması durumunda, akıllı sinyalizasyon uygulamalarının sadece karbondioksit emisyonlarında değil, aynı zamanda trafikten kaynaklı çeşitli çevresel etki kategorilerinde de iyileştirmeler sağlayabileceğini ortaya koymuştur. Senaryoların uygulanması ile

GWP’de ve çevresel etkilerde %4-%8 iyileştirme sağlanabileceği belirlenmiştir. Bu çalışma, özellikle donanım arızası senaryolarında trafik hacmi tahmini ve adaptif kontrol mekanizmalarının entegrasyonunun akıllı trafik sistemlerinin dayanıklılığına katkı sağlayabileceğini ortaya koymuştur.

Bursa ili Nilüfer ilçesinde bulunan Işıktepe Kavşağının analiz sonuçlarına göre sabit sinyal süreli sistemin çalıştırıldığı senaryoya kıyasla, adaptif sinyal süreli modun çalıştırıldığı senaryo daha başarılı performans göstermiştir. Buna göre ortalama yolculuk süresi %19.8 oranında azalmış olup, ortalama hız %27.6 oranında artmıştır. Karbondioksit (CO₂) emisyonlarında %13.3, karbonmonoksit (CO) emisyonlarında %17.3, hidrokarbon (HC) emisyonlarında %16.8, azot oksit (NO_x) emisyonlarında %13.9 ve partikül madde (PM_x) emisyonlarında %11.8 oranında azalma sağlanmıştır.

Elde edilen sonuçlar, trafik yönetiminin daha çevreci, ekonomik ve etkili bir yapıya kavuşmasını sağlarken, afet durumlarında akıllı kavşak sistemlerinin daha dirençli hale gelmesi için yenilikçi teknolojiler sunmaktadır. Çalışmanın sonunda, önerilen modeller ve dijital ikiz altyapısının, şehirlerin ulaşım sistemlerini daha sürdürülebilir bir geleceğe taşıyacağı öngörülmektedir.

ANAHTAR KELİMELEER: Veri Analizi, Derin Öğrenme, Kavşak Performansı, Sürdürülebilirlik, SUMO Türkiye Uyarlaması, Yaşam Döngüsü Analizi

JÜRİ: Dr. Öğr. Üyesi Yalçın ALBAYRAK

Prof. Dr. Selçuk HELHEL

Prof Dr. Hüseyin GÖKSU

Doç. Dr. Selim DÜNDAR

Doç. Dr. Murat İNCE

ABSTRACT

DEVELOPMENT OF DISASTER-RESILIENT DEEP LEARNING-BASED SUSTAINABLE ADAPTIVE TRAFFIC SIGNALIZATION AGAINST SENSOR FAILURES

Seyitali İLYAS

PhD Thesis in Electrical and Electronics Engineering

Supervisor: Asst. Prof. Dr. Yalçın ALBAYRAK

Co-Supervisor: Assoc. Prof. Dr. Sevil KÖFTECİ

October 2025; 228 pages

This study was conducted to ensure traffic continuity at adaptive signalized intersections within the scope of developing a digital twin infrastructure that generates future predictions by utilizing historical data. In this context, solutions were proposed for sensor failure scenarios at intersections, and the modeling and optimization of adaptive traffic signal systems were carried out.

The traffic data obtained from the Traffic Control Centers established under the Smart Intersections Projects of Bursa Metropolitan Municipality and Antalya Metropolitan Municipality formed the basis of this research. To enhance the efficiency and sustainability of smart intersection systems, a deep learning-based approach was developed. Traffic flow dynamics were analyzed through simulation studies conducted using the SUMO Türkiye Adaptation, and data analytics methods were applied. Predictive models were developed based on the Passenger Car Unit (PCU) conversions of all vehicle classes, and their results were comprehensively evaluated. The findings revealed that deep learning models such as LSTM, GRU, RNN, CNN demonstrated superior performance in traffic volume prediction.

As a result of this study, in the Heybe Intersection application, under a sensor failure scenario in an adaptive signalized intersection, the intersection operated based on a DQL-based model instead of reverting to a pre-defined fixed-time signal plan. This led to an improvement in the level of service from E to B, a 61.3% reduction in average delay, and a 134.6% increase in average speed.

In another application involving sequential signalized intersections, a life cycle assessment (LCA) was conducted based on fuel consumption derived from emission outputs obtained through SUMO simulations, in order to assess environmental impacts that directly influence sustainability. The LCA results revealed that traffic-related emissions affect not only global warming potential but also fine particulate matter formation, tropospheric ozone formation in terrestrial ecosystems, and terrestrial acidification. Scenario-based simulations indicated that smart signalization systems could offer improvements not only in CO₂ emissions but also across multiple traffic-related environmental impact categories. It was determined that the implementation of scenarios could lead to a 4–8% improvement in global warming potential and related environmental

effects.

This study showed that, especially under hardware failure scenarios, the integration of traffic volume prediction and adaptive control mechanisms can enhance the resilience of smart traffic systems. According to the analysis results of the Işıktepe Intersection located in Nilüfer district of Bursa, the scenario using adaptive signal timing outperformed the fixed-time signal plan scenario. Accordingly, the average travel time was reduced by 19.8%, while the average speed increased by 27.6%. Emissions were also reduced: carbon dioxide (CO₂) by 13.3%, carbon monoxide (CO) by 17.3%, hydrocarbons (HC) by 16.8%, nitrogen oxides (NO_x) by 13.9%, and particulate matter (PM_x) by 11.8%.

The results obtained not only contribute to making traffic management more environmentally friendly, economical, and effective, but also present innovative technologies to increase the resilience of smart intersection systems in emergency scenarios. Ultimately, the proposed models and digital twin infrastructure are expected to help transform urban transportation systems toward a more sustainable future.

KEYWORDS: Data Analysis, Deep Learning, Intersection Performance, Sustainability, SUMO Türkiye Adaptation, Life Cycle Assessment

COMMITTEE: Asst. Prof. Dr. Yalçın ALBAYRAK

Prof. Dr. Selçuk HELHEL

Prof. Dr. Hüseyin GÖKSU

Assoc. Prof. Dr. Selim DÜNDAR

Assoc. Prof. Dr. Murat İNCE

ÖNSÖZ

Bu tez ile Türkiye’de sürdürülebilir ulaşım ve dijital dönüşüm alanında yapay zekâ destekli akıllı ulaşım sistemlerinin geliştirilmesine katkı sunmak amaçlanmış olup araştırma sürecinde veri analizi, derin öğrenme ve benzetim tabanlı modellemelerden faydalanılmıştır.

Tez danışmanım Dr. Öğr. Üyesi Yalçın Albayrak’a, yol göstericiliği ve sürekli desteği için en içten teşekkürlerimi sunarım. Ulaştırma ve çevre mühendisliği alanındaki katkılarından dolayı ikinci Tez danışmanım Doç. Dr. Sevil Köfteci’ye ve Prof. Dr. Aslı Seyhan Çıgğın’a, Tez sürecindeki yapıcı geri bildirimleri için Prof. Dr. Selçuk Helhel’e ve Doç. Dr. Selim Dünder’a teşekkür ederim.

Araştırmamı destekleyen TÜBİTAK (ARDEB – 124E123), TÜBİTAK (BİDEB – 2211-C), veri paylaşımı ve desteklerinden dolayı Antalya Büyükşehir Belediyesi’ne ve Bursa Büyükşehir Belediyesi’ne teşekkür ederim.

Her zaman yanımda olan anneme, babama, kız kardeşime ve en büyük manevi desteğim olan eşime teşekkür ederim.

İÇİNDEKİLER

ÖZET.....	i
ABSTRACT.....	iii
ÖNSÖZ	v
İÇİNDEKİLER	vi
AKADEMİK BEYAN	ix
SİMGELER VE KISALTMALAR.....	x
ŞEKİLLER DİZİNİ.....	xii
ÇİZELGELER DİZİNİ	xx
1. GİRİŞ.....	1
1.1. Problem Tanımı.....	1
1.2. Tezin Yapısı	2
2. KAYNAK TARAMASI.....	5
3. MATERYAL VE METOT.....	13
3.1. Trafik Yönetiminde Kullanılan Akıllı Kavşak Bilgileri	13
3.1.1. Araç sayım verilerinin elde edilme süreci.....	13
3.1.2. Heybe Kavşağı	16
3.1.3. Türkay Kavşağı	19
3.1.4. Işıktepe Kavşağı	22
3.2. Trafik Hacim Verilerinin Aykırılık Analizi ve Tahmin Modelleri Geliştirme Süreci.....	24
3.2.1. Aykırılık tespiti, veri temizleme ve derin öğrenme modelleri ile trafik hacmi tahmini	27
3.2.2. Model performansının değerlendirilmesi	34
3.3. SUMO Türkiye Uyarlaması	35
3.3.1. Heybe Kavşağı SUMO modellemesi	38
3.3.2. Ardışık Kavşaklar SUMO modellemesi.....	39
3.3.3. Işıktepe Kavşağı SUMO modellemesi	41
3.4. Derin Takviyeli Öğrenme ile Trafik Yönetimi.....	43
3.4.1. Q-Değer fonksiyonu güncelleme (Bellman denklemi)	43
3.4.2. Durum temsili.....	43
3.4.3. Aksiyon seti.....	44

3.4.4. Ödül fonksiyonu	44
3.4.5. Deneyim tekrar oynatma	44
3.4.6. Epsilon-Greedy stratejisi	45
3.4.7. Hedef ağ güncellemesi	45
3.4.8. Heybe Kavşağı'nda DQL uygulaması.....	45
3.5. Benzetimlerde Kullanılan Trafik Parametreleri	50
3.6. Benzetim Kalibrasyon ve Doğrulama Çalışmaları.....	51
3.7. Yaşam Döngüsü Değerlendirmesi.....	52
3.7.1. Yaşam Döngüsü Envanteri.....	52
3.7.2. Yaşam Döngüsü Etki Değerlendirmesi	54
4. BULGULAR VE TARTIŞMA	57
4.1. Heybe Kavşağı Veri Seti	57
4.1.1. Heybe Kavşağı 37887-37889 istikameti farklı zaman dilimlerine göre trafik hacimleri.....	60
4.1.2. Heybe Kavşağı 37887-37889 istikameti aykırılık analizi ve temizleme yöntemlerinin karşılaştırılması	63
4.1.3. Heybe Kavşağı 37887-37889 istikameti aykırılık analizi sonrası derin öğrenme modellerinin eğitimi.....	70
4.1.4. Heybe Kavşağı 37887-37889 istikameti ham veri ile derin öğrenme modellerinin eğitimi.....	82
4.1.5. Heybe Kavşağı 37889-37887 istikameti farklı zaman dilimlerine göre trafik hacimleri.....	94
4.1.6. Heybe Kavşağı 37889-37887 istikameti aykırılık analizi ve temizleme yöntemlerinin karşılaştırılması	97
4.1.7. Heybe Kavşağı 37889-37887 istikameti aykırılık analizi sonrası derin öğrenme modellerinin eğitimi.....	104
4.1.8. Heybe Kavşağı 37889-37887 istikameti ham veri ile derin öğrenme modellerinin eğitimi.....	116
4.2. Türkay Kavşağı Veri Seti	128
4.2.1. Türkay Kavşağı 37860-37862 istikameti farklı zaman dilimlerine göre trafik hacimleri.....	131

4.2.2. Türkay Kavşağı 37860-37862 istikameti aykırılık analizi ve temizleme yöntemlerinin karşılaştırılması	134
4.2.3. Türkay Kavşağı 37860-37862 istikameti aykırılık analizi sonrası derin öğrenme modellerinin eğitimi.....	141
4.2.4. Türkay Kavşağı 37860-37862 istikameti ham veri ile derin öğrenme modellerinin eğitimi.....	153
4.2.5. Türkay Kavşağı 37862-37860 istikameti farklı zaman dilimlerine göre trafik hacimleri.....	165
4.2.6. Türkay Kavşağı 37862-37860 istikameti aykırılık analizi ve temizleme yöntemlerinin karşılaştırılması	168
4.2.7. Türkay Kavşağı 37862-37860 istikameti aykırılık analizi sonrası derin öğrenme modellerinin eğitimi.....	175
4.2.8. Türkay Kavşağı 37862-37860 istikameti ham veri ile derin öğrenme modellerinin eğitimi.....	187
4.3. Benzetim Doğrulama Sonuçları	199
4.4. Heybe Kavşağı SUMO analiz sonuçları.....	201
4.4.1. Derin Q-Öğrenme uygulaması sonuçları.....	202
4.5. Ardışık kavşaklar SUMO analiz sonuçları	204
4.5.1. Sinyalizasyon senaryoları için LCA analizi	207
4.6. Işıktepe Kavşağı SUMO analiz sonuçları	209
5. SONUÇLAR	213
6. KAYNAKLAR.....	219
7. EKLER	227
ÖZGEÇMİŞ	

AKADEMİK BEYAN

Doktora Tezi olarak sunduğum “Sensör Arızalarına Karşı Afet Dirençli Derin Öğrenme Tabanlı Sürdürülebilir Adaptif Trafik Sinyalizasyonunun Geliştirilmesi” adlı bu çalışmanın, akademik kurallar ve etik değerlere uygun olarak yazıldığını belirtir, bu tez çalışmasında bana ait olmayan tüm bilgilerin kaynağını gösterdiğimi beyan ederim.

17/10/2025

Seyitali İLYAS



SİMGELER VE KISALTMALAR

Simgeler

g	: gram
sa	: saat
k	: trafik yoğunluğu
km	: kilometre
L	: litre
m	: metre
q	: trafik akım oranı
s	: saniye
v	: hız
α	: öğrenme oranı
γ	: indirim katsayısı
ε	: keşif oranı

Kısaltmalar

CNN	: Evrişimli Sinir Ağı
CO ₂	: Karbondioksit
DQN	: Derin Q-Ağları
GRU	: Geçitli Tekrarlayan Birim
HC	: Hidrokarbon
LSTM	: Uzun Kısa Süreli Bellek Ağı
BiLSTM	: Çift Yönlü LSTM
MSE	: Ortalama Kare Hata
PM _x	: Partikül Madde
R ²	: Belirleme Katsayısı

SVR	: Destek Vektör Regresyonu
CNN	: Evriřimli Sinir Ađı
CO	: Karbonmonoksit
DQL	: Derin Q-Öđrenme
GUI	: Grafiksel Kullanıcı Arayüzü
LCA	: Yařam Döngüsü Deđerlendirmesi
LOS	: Hizmet Seviyesi
MAE	: Ortalama Mutlak Hata
MLP-NN	: Çok Katmanlı Algılayıcı Sinir Ađı
NOx	: Azot Oksitler
RNN	: Tekrarlayan Sinir Ađı
SUMO	: Kentsel Hareketlilik Simülasyonu
PCU	: Birim Otomobil Eřdeđeri

“Simgeler ve Kısaltmalar” başlığında belirtilmeyenler, tezin içerisinde açıklanmıştır. Tezde ondalık yazım kullanılmıştır, ondalık ayırıcı olarak “.” kullanılmıştır.

ŞEKİLLER DİZİNİ

Şekil 1.1. Trafik kontrol sistemi arıza durum akış diyagramı.....	2
Şekil 3.1. Derin öğrenme ile trafik hacmi tahmini ve en iyileme sürecinin akış şeması	13
Şekil 3.2. Antalya Trafik Kontrol Merkezi kavşak kontrol paneli arayüzü.....	14
Şekil 3.3. Adaptif akıllı kavşak kamera görüntüleri (a) balık gözü kameralarla elde edilen kavşak görüntüleri; (b) balık gözü kameralar üzerinden tanımlanan sanal bölgeler; (c) akıllı kavşakta kamera yerleşim planı ve görüş alanları	15
Şekil 3.4. Heybe Kavşağı'nın Google Earth görüntüsü	17
Şekil 3.5. Heybe Kavşağı Antalya Trafik Kontrol Merkezi görüntüsü	17
Şekil 3.6. Türkay Kavşağı Google Earth görüntüsü	20
Şekil 3.7. Türkay Kavşağı Antalya Trafik Kontrol Merkezi görüntüsü	20
Şekil 3.8. Işıktepe Kavşağı'nın Google Earth görüntüsü	22
Şekil 3.9. Trafik hacmi tahmin süreci akış diyagramı	26
Şekil 3.10. SUMO Türkiye Uyarlaması program arayüzü	36
Şekil 3.11. SUMO GUI program görseli	36
Şekil 3.12. SUMO Türkiye Uyarlaması 3 boyutlu görsel.....	37
Şekil 3.13. SUMO benzetim aşamaları.....	38
Şekil 3.14. Heybe Kavşağı trafik hacim verilerinin analiz ve modelleme süreç akışı.....	39
Şekil 3.15. Heybe Kavşağının görüntüsü a) Google Haritalar; b) Netedit; c) SUMO	39
Şekil 3.16. Heybe Kavşağı ve Türkay Kavşağı Trafik hacim verilerinin analiz ve modelleme süreç akışı.....	40
Şekil 3.17. Heybe Kavşağı ve Türkay Kavşağı benzetim görüntüsü.....	41
Şekil 3.18. Işıktepe Kavşağının Netedit ortamında çiziminin görüntüsü	42
Şekil 3.19. Işıktepe Kavşağının benzetim görüntüsü.....	42
Şekil 3.20. DQL Modeli.....	46

Şekil 3.21. Durum matrisinin yollar üzerinde konumlanmış görüntüsü.....	47
Şekil 3.22. Trafik ışığı fazları	49
Şekil 4.1. Heybe Kavşağı trafik hacim verileri a) geliş istikameti; b) gidiş istikameti; c) dönüş istikameti	59
Şekil 4.2. Atatürk Bulvarı-17. Cadde kesişimdeki akıllı kavşak geliş ve gidiş istikametine göre trafik hacim verileri	60
Şekil 4.3. Heybe Kavşağı 37887-37889 güzergahı araç sayımları a) 15 dakikalık; b) saatlik; c) günlük; d) haftalık; e) aylık	62
Şekil 4.4. Heybe Kavşağı 37887-37889 güzergahındaki araç sınıflarına göre PCU cinsinden trafik hacim dağılımı	62
Şekil 4.5. Heybe Kavşağı 37887-37889 güzergahına ait araç sınıflarının korelasyon matrisi	63
Şekil 4.6. Heybe Kavşağı 37887-37889 güzergahı aykırılık tespit yöntemleri a) Z-Skoru; b) Mahalanobis mesafesiyle; c) PCA.....	65
Şekil 4.7. Mahalanobis modeli performans karşılaştırması a) MSE; b) MAE; c) R^2	66
Şekil 4.8. PCA modeli performans karşılaştırması a) MSE; b) MAE; c) R^2	68
Şekil 4.9. Z-Score modeli performans karşılaştırması a) MSE; b) MAE; c) R^2	69
Şekil 4.10. Heybe Kavşağı 37887-37889 istikameti (aykırılıklardan arındırılmış veri) için (a) LSTM modeli; (b) doğrulama grafiği	71
Şekil 4.11. Heybe Kavşağı 37887-37889 istikameti (aykırılıklardan arındırılmış veri) için (a) BiLSTM modeli; (b) doğrulama grafiği.....	72
Şekil 4.12. Heybe Kavşağı 37887-37889 istikameti (aykırılıklardan arındırılmış veri) için (a) GRU modeli; (b) doğrulama grafiği.....	74
Şekil 4.13. Heybe Kavşağı 37887-37889 istikameti (aykırılıklardan arındırılmış veri) için (a) LSTM + CNN modeli; (b) doğrulama grafiği.....	75
Şekil 4.14. Heybe Kavşağı 37887-37889 istikameti (aykırılıklardan arındırılmış veri) için (a) RNN modeli; (b) doğrulama grafiği.....	76
Şekil 4.15. Heybe Kavşağı 37887-37889 istikameti (aykırılıklardan arındırılmış veri) için (a) Dikkat Mekanizması Tabanlı LSTM modeli; (b) doğrulama grafiği	78
Şekil 4.16. Heybe Kavşağı 37887-37889 istikameti (aykırılıklardan	

arındırılmış veri) için (a) Yığınlanmış LSTM modeli; (b) doğrulama grafiği.....	79
Şekil 4.17. Heybe Kavşağı 37887-37889 istikameti (aykırılıklardan arındırılmış veri) için (a) LSTM + GRU modeli; (b) doğrulama grafiği.....	80
Şekil 4.18. Heybe Kavşağı 37887-37889 istikameti (ham veri) için (a) LSTM modeli; (b) doğrulama grafiği	83
Şekil 4.19. Heybe Kavşağı 37887-37889 istikameti (ham veri) için (a) BiLSTM modeli; (b) doğrulama grafiği	84
Şekil 4.20. Heybe Kavşağı 37887-37889 istikameti (ham veri) için (a) GRU modeli; (b) doğrulama grafiği.....	85
Şekil 4.21. Heybe Kavşağı 37887-37889 istikameti (ham veri) için (a) LSTM + CNN modeli; (b) doğrulama grafiği	87
Şekil 4.22. Heybe Kavşağı 37887-37889 istikameti (ham veri) için (a) RNN modeli; (b) doğrulama grafiği.....	88
Şekil 4.23. Heybe Kavşağı 37887-37889 istikameti (ham veri) için (a) Dikkat Mekanizması Tabanlı LSTM modeli; (b) doğrulama grafiği.....	89
Şekil 4.24. Heybe Kavşağı 37887-37889 istikameti (ham veri) için (a) Yığınlanmış LSTM modeli; (b) doğrulama grafiği	91
Şekil 4.25. Heybe Kavşağı 37887-37889 istikameti (ham veri) için (a) LSTM + GRU modeli; (b) doğrulama grafiği	92
Şekil 4.26. Heybe Kavşağı 37889-37887 güzergahı araç sayımları a) 15 dakikalık; b) saatlik; c) günlük; d) haftalık; e) aylık	96
Şekil 4.27. Heybe Kavşağı 37889-37887 güzergahındaki araç sınıflarına göre PCU cinsinden trafik hacim dağılımı.....	96
Şekil 4.28. Heybe Kavşağı 37889-37887 güzergahına ait araç sınıflarının korelasyon matrisi	97
Şekil 4.29. Heybe Kavşağı aykırılık tespit yöntemleri a) Z-Skoru; b) Mahalanobis mesafesiyle; c) PCA	99
Şekil 4.30. Mahalanobis modeli performans karşılaştırması a) MSE; b) MAE; c) R^2	100
Şekil 4.31. PCA modeli performans karşılaştırması a) MSE; b) MAE; c) R^2	102
Şekil 4.32. Z-Score modeli performans karşılaştırması a) MSE; b) MAE; c) R^2	103
Şekil 4.33. Heybe Kavşağı 37889-37887 istikameti (aykırılıklardan	

arındırılmış veri) için (a) LSTM modeli; (b) doğrulama grafiği	105
Şekil 4.34. Heybe Kavşağı 37889-37887 istikameti (aykırılıklardan arındırılmış veri) için (a) BiLSTM modeli; (b) doğrulama grafiği.....	106
Şekil 4.35. Heybe Kavşağı 37889-37887 istikameti (aykırılıklardan arındırılmış veri) için (a) GRU modeli; (b) doğrulama grafiği.....	108
Şekil 4.36. Heybe Kavşağı 37889-37887 istikameti (aykırılıklardan arındırılmış veri) için (a) LSTM + CNN modeli; (b) doğrulama grafiği.....	109
Şekil 4.37. Heybe Kavşağı 37889-37887 istikameti (aykırılıklardan arındırılmış veri) için (a) RNN modeli; (b) doğrulama grafiği.....	110
Şekil 4.38. Heybe Kavşağı 37889-37887 istikameti (aykırılıklardan arındırılmış veri) için (a) Dikkat Mekanizması Tabanlı LSTM modeli; (b) doğrulama grafiği	112
Şekil 4.39. Heybe Kavşağı 37889-37887 istikameti (aykırılıklardan arındırılmış veri) için (a) Yığınlanmış LSTM modeli; (b) doğrulama grafiği.....	113
Şekil 4.40. Heybe Kavşağı 37889-37887 istikameti (aykırılıklardan arındırılmış veri) için (a) LSTM + GRU modeli; (b) doğrulama grafiği.....	114
Şekil 4.41. Heybe Kavşağı 37889-37887 istikameti (ham veri) için (a) LSTM modeli; (b) doğrulama grafiği	117
Şekil 4.42. Heybe Kavşağı 37889-37887 istikameti (ham veri) için (a) BiLSTM modeli; (b) doğrulama grafiği	118
Şekil 4.43. Heybe Kavşağı 37889-37887 istikameti (ham veri) için (a) GRU modeli; (b) doğrulama grafiği.....	120
Şekil 4.44. Heybe Kavşağı 37889-37887 istikameti (ham veri) için (a) LSTM + CNN modeli; (b) doğrulama grafiği	121
Şekil 4.45. Heybe Kavşağı 37889-37887 istikameti (ham veri) için (a) RNN modeli; (b) doğrulama grafiği.....	122
Şekil 4.46. Heybe Kavşağı 37889-37887 istikameti (ham veri) için (a) Dikkat Mekanizması Tabanlı LSTM modeli; (b) doğrulama grafiği.....	124
Şekil 4.47. Heybe Kavşağı 37889-37887 istikameti (ham veri) için (a) Yığınlanmış LSTM modeli; (b) doğrulama grafiği	125
Şekil 4.48. Heybe Kavşağı 37889-37887 istikameti (ham veri) için (a) LSTM + GRU modeli; (b) doğrulama grafiği	126
Şekil 4.49. Türkay Kavşağı trafik hacim verileri a) geliş istikameti; b) gidiş istikameti; c) dönüş istikameti	130

Şekil 4.50. Trkay Kavşacı'ndaki gzergahlara gre gzlem sayıları	131
Şekil 4.51. Trkay Kavşacı 37860-37862 gzergahı araç sayımları a) 15 dakikalık; b) saatlik; c) gnlk; d) haftalık; e) aylık	133
Şekil 4.52. Trkay Kavşacı 37860-37862 gzergahındaki araç sınıflarına gre PCU cinsinden trafik hacim dağılımı	134
Şekil 4.53. Trkay Kavşacı 37860-37862 gzergahına ait araç sınıflarının korelasyon matrisi	134
Şekil 4.54. Trkay Kavşacı aykırılık tespit yntemleri a) Z-Skoru; b) Mahalanobis mesafesiyle; c) PCA	136
Şekil 4.55. Mahalanobis modeli performans karřılařtırması a) MSE; b) MAE; c) R^2	137
Şekil 4.56. PCA modeli performans karřılařtırması a) MSE; b) MAE; c) R^2	139
Şekil 4.57. Z-Score modeli performans karřılařtırması a) MSE; b) MAE; c) R^2	140
Şekil 4.58. Trkay Kavşacı 37860-37862 istikameti (aykırılıklardan arındırılmıř veri) iin (a) LSTM modeli; (b) doęrulama grafięi	142
Şekil 4.59. Trkay Kavşacı 37860-37862 istikameti (aykırılıklardan arındırılmıř veri) iin (a) BiLSTM modeli; (b) doęrulama grafięi.....	143
Şekil 4.60. Trkay Kavşacı 37860-37862 istikameti (aykırılıklardan arındırılmıř veri) iin (a) GRU modeli; (b) doęrulama grafięi.....	145
Şekil 4.61. Trkay Kavşacı 37860-37862 istikameti (aykırılıklardan arındırılmıř veri) iin (a) LSTM + CNN modeli; (b) doęrulama grafięi.....	146
Şekil 4.62. Trkay Kavşacı 37860-37862 istikameti (aykırılıklardan arındırılmıř veri) iin (a) RNN modeli; (b) doęrulama grafięi.....	147
Şekil 4.63. Trkay Kavşacı 37860-37862 istikameti (aykırılıklardan arındırılmıř veri) iin (a) Dikkat Mekanizması Tabanlı LSTM modeli; (b) doęrulama grafięi	149
Şekil 4.64. Trkay Kavşacı 37860-37862 istikameti (aykırılıklardan arındırılmıř veri) iin (a) Yıęınlanmıř LSTM modeli; (b) doęrulama grafięi.....	150
Şekil 4.65. Trkay Kavşacı 37860-37862 istikameti (aykırılıklardan arındırılmıř veri) iin (a) LSTM + GRU modeli; (b) doęrulama grafięi.....	151
Şekil 4.66. Trkay Kavşacı 37860-37862 istikameti (ham veri) iin (a) LSTM modeli; (b) doęrulama grafięi	154

Şekil 4.67. Türkiye Kavşağı 37860-37862 istikameti (ham veri) için (a) BiLSTM modeli; (b) doğrulama grafiği	155
Şekil 4.68. Türkiye Kavşağı 37860-37862 istikameti (ham veri) için (a) GRU modeli; (b) doğrulama grafiği	157
Şekil 4.69. Türkiye Kavşağı 37860-37862 istikameti (ham veri) için (a) LSTM + CNN modeli; (b) doğrulama grafiği	158
Şekil 4.70. Türkiye Kavşağı 37860-37862 istikameti (ham veri) için (a) RNN modeli; (b) doğrulama grafiği	159
Şekil 4.71. Türkiye Kavşağı 37860-37862 istikameti (ham veri) için (a) Dikkat Mekanizması Tabanlı LSTM modeli; (b) doğrulama grafiği.....	161
Şekil 4.72. Türkiye Kavşağı 37860-37862 istikameti (ham veri) için (a) Yığılanmış LSTM modeli; (b) doğrulama grafiği	162
Şekil 4.73. Türkiye Kavşağı 37860-37862 istikameti (ham veri) için (a) LSTM + GRU modeli; (b) doğrulama grafiği	163
Şekil 4.74. Türkiye Kavşağı 37862-37860 güzergahı araç sayımları a) 15 dakikalık; b) saatlik; c) günlük; d) haftalık; e) aylık	167
Şekil 4.75. Türkiye Kavşağı 37862-37860 güzergahındaki araç sınıflarına göre PCU cinsinden trafik hacim dağılımı.....	168
Şekil 4.76. Türkiye Kavşağı 37862-37860 güzergahındaki araç sınıflarının korelasyon matrisi	168
Şekil 4.77. Türkiye Kavşağı aykırılık tespit yöntemleri a) Z-Skoru; b) Mahalanobis mesafesiyle; c) PCA	170
Şekil 4.78. Mahalanobis modeli performans karşılaştırması a) MSE; b) MAE; c) R^2	171
Şekil 4.79. PCA modeli performans karşılaştırması a) MSE; b) MAE; c) R^2	173
Şekil 4.80. Z-Score modeli performans karşılaştırması a) MSE; b) MAE; c) R^2	174
Şekil 4.81. Türkiye Kavşağı 37862-37860 istikameti (aykırılıklardan arındırılmış veri) için (a) LSTM modeli; (b) doğrulama grafiği	176
Şekil 4.82. Türkiye Kavşağı 37862-37860 istikameti (aykırılıklardan arındırılmış veri) için (a) BiLSTM modeli; (b) doğrulama grafiği.....	177
Şekil 4.83. Türkiye Kavşağı 37862-37860 istikameti (aykırılıklardan arındırılmış veri) için (a) GRU modeli; (b) doğrulama grafiği.....	179

Şekil 4.84. Türkiye Kavşağı 37862-37860 istikameti (aykırılıklardan arındırılmış veri) için (a) LSTM + CNN modeli; (b) doğrulama grafiği.....	180
Şekil 4.85. Türkiye Kavşağı 37862-37860 istikameti (aykırılıklardan arındırılmış veri) için (a) RNN modeli; (b) doğrulama grafiği.....	181
Şekil 4.86. Türkiye Kavşağı 37862-37860 istikameti (aykırılıklardan arındırılmış veri) için (a) Dikkat Mekanizması Tabanlı LSTM modeli; (b) doğrulama grafiği.....	183
Şekil 4.87. Türkiye Kavşağı 37862-37860 istikameti (aykırılıklardan arındırılmış veri) için (a) Yığınlanmış LSTM modeli; (b) doğrulama grafiği.....	184
Şekil 4.88. Türkiye Kavşağı 37862-37860 istikameti (aykırılıklardan arındırılmış veri) için (a) LSTM + GRU modeli; (b) doğrulama grafiği.....	185
Şekil 4.89. Türkiye Kavşağı 37862-37860 istikameti (ham veri) için (a) LSTM modeli; (b) doğrulama grafiği	188
Şekil 4.90. Türkiye Kavşağı 37862-37860 istikameti (ham veri) için (a) BiLSTM modeli; (b) doğrulama grafiği	189
Şekil 4.91. Türkiye Kavşağı 37862-37860 istikameti (ham veri) için (a) GRU modeli; (b) doğrulama grafiği	191
Şekil 4.92. Türkiye Kavşağı 37862-37860 istikameti (ham veri) için (a) LSTM + CNN modeli; (b) doğrulama grafiği	192
Şekil 4.93. Türkiye Kavşağı 37862-37860 istikameti (ham veri) için (a) RNN modeli; (b) doğrulama grafiği	193
Şekil 4.94. Türkiye Kavşağı 37862-37860 istikameti (ham veri) için (a) Dikkat Mekanizması Tabanlı LSTM modeli; (b) doğrulama grafiği.....	195
Şekil 4.95. Türkiye Kavşağı 37862-37860 istikameti (ham veri) için (a) Yığınlanmış LSTM modeli; (b) doğrulama grafiği	196
Şekil 4.96. Türkiye Kavşağı 37862-37860 istikameti (ham veri) için (a) LSTM + GRU modeli; (b) doğrulama grafiği	197
Şekil 4.97. Trafik hacmi tahmini için kalibrasyon süreçlerinde GEH kriterinin uygulanışı (a) Heybe Kavşağı; (b) Ardışık Kavşaklar (c); Işıktepe Kavşağı.....	201
Şekil 4.98. Kümülatif negatif ödülün bölümlere göre değişimi.....	203
Şekil 4.99. Kümülatif gecikmenin bölümlere göre değişimi	203
Şekil 4.100. ReCiPe Uç Nokta (H) metodolojisine göre sinyalizasyon yaklaşımlarının yaşam döngüsü etkileri (zarar kategorileri kapsamında) a)	

insan sađlığı; b) ekosistem kalitesi	208
---	-----



ÇİZELGELER DİZİNİ

Çizelge 3.1. Araç sayım veri setinin ilk 5 satırı.....	16
Çizelge 3.2. Heybe Kavşağı'nın Adaptif Kavşak durumu en az ve en çok süreleri.....	18
Çizelge 3.3. Heybe Kavşağı sabit süreli sinyalizasyon planı.....	18
Çizelge 3.4. Heybe Kavşağı'nın 6:00-7:00 saatleri arasındaki araç sayım verileri	19
Çizelge 3.5. Türkay Kavşağı'nın Adaptif Kavşak durumu en az ve en çok süreleri.....	21
Çizelge 3.6. Türkay Kavşağı sabit süreli sinyalizasyon planı	21
Çizelge 3.7. Türkay Kavşağı'nın 17:00-18:00 saatleri arasındaki araç sayım verileri	22
Çizelge 3.8. Işıktepe Kavşağı geometrik özellikleri	23
Çizelge 3.9. Işıktepe Kavşağı'nın Adaptif Kavşak durumu en az ve en çok süreler.....	23
Çizelge 3.10. Işıktepe Kavşağı sabit süreli sinyalizasyon planı	24
Çizelge 3.11. Işıktepe Kavşağı'nın 15:00-16:00 saatleri arasındaki araç sayım verileri.....	24
Çizelge 3.12. PCU değerleri (UKOME 2023, TS 6407 2013)	27
Çizelge 3.13. Derin Öğrenme Modellerinin Yapısı (Modellerin parametreleri)	33
Çizelge 3.14. Durum matrisinin karşılık geldiği yönler ile gösterimi	48
Çizelge 3.15. Eğitim parametreleri	50
Çizelge 3.16. LCI verilerinin oluşturulmasında kullanılan girdiler ve çıktılar.....	54
Çizelge 4.1. Kavşak kontrol cihazına ait kimlik bilgileri ile yön isimlerinin eşleştirilmesi.....	57
Çizelge 4.2. Aykırılık tespit yöntemlerinin performans metrikleri bakımından karşılaştırılması	70
Çizelge 4.3. Heybe Kavşağı 37887-37889 güzergahı (aykırılıklardan arındırılmış veri) için derin öğrenme modellerinin performans metriklerinin karşılaştırılması	81

Çizelge 4.4. Heybe Kavşağı 37887-37889 güzergahı (ham veri) için derin öğrenme modellerinin performans metriklerinin karşılaştırılması.....	93
Çizelge 4.5. Aykırılık tespit yöntemlerinin performans metrikleri bakımından karşılaştırılması	104
Çizelge 4.6. Heybe Kavşağı 37889-37887 güzergahı (aykırılıklardan arındırılmış veri) için derin öğrenme modellerinin performans metriklerinin karşılaştırılması	115
Çizelge 4.7. Heybe Kavşağı 37889-37887 güzergahı (ham veri) için derin öğrenme modellerinin performans metriklerinin karşılaştırılması.....	127
Çizelge 4.8. Kavşak kontrol cihazına ait kimlik bilgileri ile yön isimlerinin eşleştirilmesi.....	129
Çizelge 4.9. Aykırılık tespit yöntemlerinin performans metrikleri bakımından karşılaştırılması	141
Çizelge 4.10. Türkay Kavşağı 37860-37862 güzergahı (aykırılıklardan arındırılmış veri) için derin öğrenme modellerinin performans metriklerinin karşılaştırılması	152
Çizelge 4.11. Türkay Kavşağı 37860-37862 güzergahı (ham veri) için derin öğrenme modellerinin performans metriklerinin karşılaştırılması.....	164
Çizelge 4.12. Aykırılık tespit yöntemlerinin performans metrikleri bakımından karşılaştırılması	175
Çizelge 4.13. Türkay Kavşağı 37862-37860 güzergahı (aykırılıklardan arındırılmış veri) için derin öğrenme modellerinin performans metriklerinin karşılaştırılması	186
Çizelge 4.14. Türkay Kavşağı 37862-37860 güzergahı (ham veri) için derin öğrenme modellerinin performans metriklerinin karşılaştırılması.....	198
Çizelge 4.15. Adaptif ve sabit süreli sinyalizasyon sistemlerinin trafik parametreleri açısından performans karşılaştırması.....	202
Çizelge 4.16. Heybe Kavşağı farklı trafik yönetim sistemlerinin performans karşılaştırması	204
Çizelge 4.17. Ardışık Kavşaklar farklı trafik yönetim sistemlerinin performans karşılaştırması	205
Çizelge 4.18. Akıllı sinyalizasyon senaryolarının yüzdelik iyileşme oranları.....	205
Çizelge 4.19. Sinyalizasyon senaryolarının GWP açısından karşılaştırılması	207
Çizelge 4.20. Işıktepe Kavşağı farklı trafik yönetim sistemlerinin	

performans karşılaştırması	210
Çizelge 5.1. Tahmin Modelleri Performans Sonuçları	214



1. GİRİŞ

Türkiye’de, 2023 Şubat ayında meydana gelen ve 10 ili etkileyen büyük ölçekli depremler sonrasında iş makineleri, tıbbi araçlar, afet yardım araçları gibi acil ihtiyaç duyulan araçların hızlı bir şekilde ilgili bölgelere ulaşımı konusunda önemli sorunlar yaşanmıştır (Anonim 1). Deprem ve afet riskinin yüksek olduğu şehirlerde bulunan akıllı kavşaklarda meydana gelen aksaklıklar çok daha ağır sonuçlara neden olabilmektedir (Anonim 2). Bu bağlamda ulaştırma sektöründe deprem ve afet gibi durumlarda lojistik aksaklıkları engellemek için daha etkin, afetlere dirençli yeni nesil akıllı ulaşım sistemi teknolojilerinin geliştirilmesi gerekmektedir (Tuğaç 2022; Aydın ve Kekeş 2024). Bu teknolojilerden biri olan dijital ikiz, ulaşım sektöründe hem afet yönetimi açısından yenilikçi bir çözüm sunmaktadır.


Dijital ikiz kavramı ilk kez 2002 yılında Dr. Michael Grieves tarafından, örnek uygulama olarak ABD Ulusal Havacılık ve Uzay Dairesi’nin (NASA) Apollo Programı üzerinden geliştirilmiştir (Aynacı 2020). Dijital ikiz, fiziksel ve sanal ortamlar arasında verilerin iki yönlü ve gerçek zamanlı entegrasyonunu sağlayan bir sistem olarak tanımlanmaktadır. Burada amaç gerçekleştirilecek sorunları yaşanmadan tespit ederek maliyet kaybını engelleyecek eylemde bulunmaktır. Dijital ikiz teknolojisinde fiziksel nesnede yapılan bir değişiklik ile otomatik olarak dijital nesnede değişiklik meydana gelmekte olup bu durumun tersi de oluşabilmektedir (Wang vd. 2022; Tomanik vd. 2023).

Dijital ikiz, dijital gölge, dijital model kavramları birbiriyle ilişkili ancak farklı kavramlardır ve literatürde yapılmış olan çalışmalar tanımlanırken bunların birbiriyle karıştırılabildiği görülmüştür. Dijital model, önceden var olan veya planlanan bir fiziksel nesnenin dijital versiyonu olarak tanımlanmaktadır. Dijital modelde, fiziksel sistem ile dijital model arasında hiçbir otomatik veri alışverişi olmamaktadır. Bu, dijital model oluşturulduktan sonra fiziksel nesnede yapılan bir değişikliğin dijital model üzerinde hiçbir şekilde etkisi olmayacağı anlamına gelmektedir. Dijital gölge kavramı ise fiziksel ve dijital nesne arasında tek yönlü bir akışa sahip olan bir dijital durum temsidir (Fuller vd. 2020; Fujii vd. 2022). Fiziksel nesnedeki bir değişiklik, dijital nesnede bir değişikliğe yol açmaktadır ancak tersi durum gerçekleşmemektedir. Bu tanımlar ışığında dijital ikiz üç unsurdan oluşmaktadır: Nesnelerin İnterneti (IoT) sensörleriyle sağlanan geçmiş veriler, gerçek zamanlı veriler ve makine öğrenmesi algoritmalarıyla oluşturulan modeller kullanılarak elde edilen gelecekteki verilerdir (Dasgupta vd. 2021; Irfan vd. 2022).

1.1. Problem Tanımı

Türkiye’de Ulaştırma ve Altyapı Bakanlığı’nın Strateji Belgesi ve 2020-2023 Eylem Planı kapsamında birçok yerel yönetim tarafından başarılı Trafik Kontrol Merkezi ve Akıllı Kavşak projeleri gerçekleştirmiştir (Kemeç ve Gül 2021; Uzer ve Özaslan 2023; Akıllı Şehirler Portalı 2024a, b, c, d, e). Fakat bu Akıllı Kavşaklar dijital ikiz teknolojisi kapsamında değildir çünkü gelecek tahmini yapmamaktadır (ISSD 2024). Ulaşım konusunda dijital ikiz sistemlerinin Türkiye’de gelişmekte olduğu yurt dışındaki sistemlerin ise gelecek tahminlerinin çok kısıtlı bir gelecek tahmini yaptığı görülmüştür (Aimsun 2023). Oysa afetler sonucunda (örneğin kamera açılarının değişmesi ve tekrar sanal bölge kalibrasyon sürecinin olması) veya bazı teknik nedenlerden dolayı (örneğin kamera bağlantısının kopması, bakım onarım işlemleri) sistemlerin çalışmasında

aksamalar olabilmekte bu durumda akıllı kavşaklar sabit sinyal süreli modda çalışmaktadır. Özellikle uzak noktalarda bulunan sinyalizasyon sistemlerinde beklenmeyen durumlarda müdahale edilmesi uzun zaman alabilmektedir. Bu nedenle operatörler tarafından kavşak kontrol cihazı içerisine en uygun sinyal sürelerinin ve faz planlarının tespit edilerek girilmiş olması gerekmektedir. Ancak operatörün kısıtlı süreli saha gözlemi yetersiz kalabilmektedir çünkü trafik hacmi yıl içerisinde turizm, hava durumu gibi nedenlerle sürekli değişmektedir. Bu sebeple kavşaklarda değişken büyük trafik hacmi verilerinin dikkate alındığı yenilikçi yaklaşıma ihtiyaç duyulmuştur.



Şekil 1.1. Trafik kontrol sistemi arıza durum akış diyagramı

Şekil 1.1’de akış diyagramı, bir trafik kontrol sisteminde karşılaşılabilecek farklı arıza türlerine (lambda arızası, loop sensör arızası) ve bu arızaların yönetimi için uygulanabilecek stratejilere ilişkin süreci göstermektedir. Diyagram, süreçlerin başlangıcından itibaren karar noktalarını ve her bir durumda alınması gereken aksiyonları adım adım açıklamaktadır.

- **Lambda Arızası:** Eğer bir lambda arızası tespit edilirse sistem, trafik güvenliğini sağlamak için otomatik olarak “Flaş Moduna” geçmektedir.
- **Loop Sensör Arızası:** Eğer lambda arızası tespit edilmez ancak loop sensör arızası mevcutsa, sistem sabit zamanlı sinyalizasyon kavşak moduna geçmektedir.
- **Adaptif Sinyalizasyon Kavşak:** Herhangi bir arıza tespit edilmediğinde, sistem adaptif sinyalizasyon kavşak modunda çalışmaya devam etmektedir.

1.2. Tezin Yapısı

Tez çalışması bu bölüm dahil beş ana bölümden oluşmaktadır. Her bölüm Bursa Büyükşehir Belediyesi ve Antalya Büyükşehir Belediyesine ait akıllı kavşakların kapsamlı dijital ikiz mimarisini oluşturulmasına böylece adaptif sinyalizasyon

sistemlerinin modellenerek sinyal sürelerinin en iyilemesine yönelik literatürde olmayan bir şekilde kapsamlı ve bütüncül yaklaşımı detaylandırmaktadır.

İkinci bölümde, dijital ikiz mimarisinin temel bileşenlerinden biri olan trafik hacmi tahmini süreçleri kapsamında kullanılan makine öğrenmesi ve derin öğrenme tekniklerine ilişkin literatür incelenmiştir. Ayrıca, benzetim tabanlı trafik modellemelerinde kullanılan Kent İçi Hareketlilik Analizleri Uygulaması (Simulation of Urban Mobility, SUMO) programına dair çalışmalar ve emisyon azaltımına yönelik senaryolara odaklanan araştırmalar da kapsamlı biçimde analiz edilmiştir.

Üçüncü bölümde materyal ve metot ele alınmıştır. Bu bölümde, veri setlerinin hazırlanma süreci, uygulanan analiz yöntemleri ve kullanılan yazılım altyapısı açıklanmıştır. Ayrıca, trafik hacmi tahmin modellerinin geliştirilme adımları, SUMO'nun Türkiye Uyarlaması ile gerçekleştirilen trafik benzetimleri, LCA ve takviyeli öğrenme algoritmalarına ilişkin süreçler ayrıntılı biçimde sunulmuştur.

Dördüncü bölümde akıllı kavşaklarda trafik hacmi tahmini uygulamalarında daha etkili ve doğru sonuçlar elde etmek için hangi modelin seçilmesi gerektiğine dair akademik bir anlayış sunulmuştur. Bu amaçla Antalya'da bulunan üç akıllı kavşağın en yoğun iki güzergahına ait saatlik araç sayım verileri kullanılmıştır. Bu veriler eğitim ve test veri setlerine ayrılarak çeşitli makine öğrenmesi modelleri oluşturulmuştur. Böylece akıllı kavşaklarda her bir istikamet için trafik hacmi tahmini yapılmış; Ortalama Kare Hata (Mean Squared Error, MSE), Ortalama Mutlak Hata (Mean Absolute Error, MAE) ve Belirleme Katsayısı (Coefficient of Determination, R^2) gibi ölçütler aracılığıyla modellerin performansları karşılaştırılmıştır. Buna göre her bir istikamet için en başarılı model belirlenmiştir.

Daha sonra akıllı kavşaklar için, yeni trafik yönetim stratejileri uygulanmıştır. Bu yönetime göre oluşturulan modeller akıllı kavşak kollarındaki manyetik algılayıcılar çalışmadığı senaryoda, kavşak kollarındaki trafik talebini tahmin ederek, her döngüde sinyal süresi ve faz planı en iyilemesi gerçekleştirmektedir. Bu yaklaşımın değerlendirilmesi amacıyla 2020-2023 Ulusal Akıllı Şehir Stratejisi ve Eylem Planı kapsamında Çevre, Şehircilik ve İklim Değişikliği Bakanlığı - Coğrafi Bilgi Sistemleri Genel Müdürlüğü tarafından geliştirilen SUMO Türkiye Uyarlaması (Kent İçi Hareketlilik Analiz Sistemi) paket programı kullanılmıştır. Bu amaçla ikinci bölüm üç ayrı uygulama kapsamında değerlendirilmiştir:

- İlk uygulamada, SUMO benzetim programı kullanılarak Heybe Kavşağı'nda trafik akışı modellenmiştir. Bu süreçte, gerçek dünya kavşak geometrisi ve trafik akışı verileri, SUMO ortamına aktararak detaylı analizler gerçekleştirilmiştir. Gerçek dünya ortamının SUMO'da modellenmesi ile kavşakta sabit süreli ve adaptif trafik yönetim sistemlerinin performansları karşılaştırılmıştır. Daha sonra, Heybe Kavşağı için Derin Q Öğrenme (Deep Q-Learning, DQL) tabanlı trafik kontrolü uygulanmıştır. Bunun için modelin eğitim sürecinde, SUMO benzetim çalışması ile üretilen trafik akış verileri kullanılarak, trafik sinyallerinin akıllı yönetimi sağlanmıştır. Sonuç olarak önerilen sistem sabit süreli ve adaptif süreli sistemlerle karşılaştırılmıştır.
- İkinci uygulamada, Antalya ilinde yer alan iki ardışık kavşakta trafik kaynaklı çevresel etkiler, LCA yöntemiyle analiz edilmiştir. Çalışmanın son aşamasında,

“referans senaryo” olarak değerlendirilen gerçek dünya ortamı için SUMO benzetim çalışması aracılığıyla elde edilen emisyon ve yakıt tüketimi verileri doğrultusunda, GWP ve diğer çevresel etki kategorileri belirlenmiştir. Ardından, iki farklı akıllı sinyalizasyon senaryosuna ilişkin SUMO çıktıları kullanılarak yürütülen LCA analizleriyle, akıllı sinyal kontrol uygulamalarının çevresel etkileri hangi bileşenlerde azalttığı ortaya konmuştur.

- Üçüncü uygulamada Bursa ili Nilüfer ilçesinde bulunan Işıktepe Kavşağının sabit süreli ve adaptif trafik yönetim sistem senaryoları modellenerek analiz edilmiştir. SUMO benzetim çalışması analiz sonuçları ortalama yolculuk süresi, ortalama hız, ortalama gecikme süresi, karbondioksit (CO₂), karbonmonoksit (CO), hidrokarbon (HC), azot oksit (NO_x) ve partikül madde (PM_x) emisyon değerleri açısından karşılaştırılmıştır.

Son bölümde tez çalışmasının genel değerlendirmesi yapılmıştır. Dijital ikiz teknolojisi kullanılarak geliştirilen modellerin, büyük hacimli trafik verilerinden yararlanarak trafik parametrelerinin verimliliğini artırmaya yönelik kararlar alınmasında önemli katkılar sağladığı vurgulanmıştır. Ayrıca gelecekte yapılabilecek çalışmalar için öneriler sunulmuştur.

2. KAYNAK TARAMASI

Ulaşım alanında dijital ikiz teknolojisi kapsamında büyük bütçeli projelerin yapıldığı ancak uygulama yöntemlerinin detaylı içeriğine az değinildiği görülmüştür (Aimsun 2023). Bu amaçla Literatür incelemesinde dijital ikiz mimarisinin bileşenlerinden biri olan tahmin modellerinin oluşturulması ile ilgili çalışmalar incelenmiştir.

Janković vd. (2021) Sırbistan Cumhuriyeti'ndeki yollarda bulunan otomatik sayaçlardan tarih, saat, yön, araç sayısı bilgilerini içeren verileri toplayarak günlük ve saatlik trafik hacmi tahmini etmiştir. Bunun için Doğrusal Regresyon, Çok Katmanlı Algılayıcı (Multi-Layer Perceptron, MLP), k-En Yakın Komşu (k-Nearest Neighbors, k-NN), M5P, Rastgele Orman (Random Forest, RF) ve REPTree algoritmalarıyla oluşturulmuş modeller kullanılmıştır. İlk senaryoda günlük trafik hacmi tahmini yapılmıştır. M5P algoritmasına (korelasyon katsayısı eğitim için 0.9778, test için 0.9756) dayalı model en iyi performansı göstermiştir. İkinci senaryoda ise saatlik trafik hacmi tahmini yapılmış ve en iyi sonuçlar k-En Yakın Komşu algoritması tarafından elde edilmiştir. Bratsas vd. (2020) çalışmalarında, Yunanistan'ın Selanik karayolu ağından elde ettikleri trafik verilerini kullanarak araçların ortalama hızını tahmin etmiştir. Bu amaçla, Doğrusal Regresyon, Çok Katmanlı Algılayıcı, Destek Vektör Regresyonu (Support Vector Regression, SVR), Rastgele Orman gibi makine öğrenmesi modellerini kullanmıştır. Bu modellerin tahmin başarı oranlarını farklı senaryolar altında birbirleriyle karşılaştırılmıştır. Sonuç olarak, Destek Vektör Regresyon modeli belirli koşullar altında daha istikrarlı bir performans sergilerken, Çok Katmanlı Algılayıcı Sinir Ağı (Multi-Layer Perceptron Neural Network, MLP-NN) modeli daha küçük hatalara sahip olmanın yanı sıra değişken koşullarda en iyi sonuçları vermiştir. Bu çerçevede, her iki modelin de farklı senaryolarda farklı avantajlara sahip olduğu gözlenmiştir. Ali ve Hamed (2018) çalışmalarında Suudi Arabistan'ın Al Ghat şehrindeki yıl, saat, kaza türü, konum, araç sayısı, sürücü vatandaşlık durumu, yaralı, ölü bilgilerini içeren trafik veri setini kullanarak, kazaya neden olan durumları tahmin etmiştir. Apriori algoritması ve Bulanık Kümeleme algoritması arasında yapılan performans karşılaştırmasında, Apriori algoritmasının daha başarılı sonuçlar verdiği gözlenmiştir. Navarro vd. (2022) dört kollu sinyalizasyon kavşağındaki trafik akımlarını tahmin etmek için Münih Araştırma Merkezi'nden alınan veri kümesini kullanmıştır. Trafik akımı tahminindeki başarıları açısından; Tekrarlayan Sinir Ağları (Recurrent Neural Networks, RNN), MLP-NN, Uzun Kısa Süreli Bellek (Long Short-Term Memory, LSTM), Gradyan Artırma (Gradient Boosting), RF, Doğrusal Regresyon ve Stokastik Gradyan İnişi (Stochastic Gradient Descent, SGD) algoritmaları karşılaştırılmıştır. Yapılan analizler, tüm makine öğrenmesi ve derin öğrenme algoritmalarının kurulacak akıllı kavşaklarda trafik yönetiminde uygulanabileceğini göstermiştir. Ancak, performans sonuçları incelendiğinde, MLP-NN'nin daha iyi sonuçlar verdiği ($R^2=0,93$) ve aynı zamanda daha kısa bir eğitim süresinde (18 s) gerçekleştiği belirlenmiştir. Hou vd. (2021) hava değişikliklerinin trafik akışı üzerindeki etkisini dikkate alarak yeni bir tahmin modeli oluşturmuştur. Önerilen modelin daha başarılı performans ortaya koyduğunu tespit edilmiştir. Alajali vd. (2018) çalışmalarında Avustralya'nın Melbourne merkezi iş bölgesindeki kavşaklarda sensörlerden gelen trafik hacmi veri setiyle, kaza ve yol çalışmalarını içeren olay veri setlerini entegre ederek yeni özelliklerin tahmin modellerindeki hata değerlerine etkisini incelemişlerdir. Tahmin için Regresyon Ağaçları (Regression Trees, RT), Gradyan

Artırıcı Karar Ağaçları (Gradient Boosted Regression Trees, GBRT), RF, Aşırı Gradyan Artırma (Extreme Gradient Boosting, XGBoost), SVR modellerini kullanmışlardır. Sadece sensör verileri kullanıldığında SVR, RT, GBRT, RF ve XGBoost modelleri için MSE değerlerinin sırasıyla 0.8883, 0.8838, 0.8772, 0.8815, 0.8773 olduğu belirlenmiştir. Ancak olay verileri sensör verileriyle entegre edildiğinde MSE'ler sırasıyla 0.8859, 0.8829, 0.8684, 0.8770 ve 0.8678 olarak elde edilmiştir. Bu sonuçlar, olay verilerinin entegrasyonunun tahmin modellerinin MSE değerini iyileştirdiğini göstermiştir. Özellikle XGBoost için en iyi MSE değeri elde edildiği görülmüştür. Rou vd. (2024) sinyal sürelerinin en iyilemesi için SARSA-A2C pekiştirmeli öğrenme algoritmasını kullanmış ve VISSIM benzetim çalışması ile test etmiştir. Uygulanan hibrit model, trafik yönetimini geliştirmek amacıyla tahmin modelleri ile sinyal en iyileme algoritmalarını bir araya getirmiştir. Çalışma, Çin'in Şanghai şehrinde yer alan Yan'an Batı Yolu üzerindeki dört ardışık kavşakta gerçekleştirilmiştir. Trafik verileri, yüksek çözünürlüklü trafik kameraları ve sensörler (indüktif döngü dedektörleri, kızılötesi sensörler) kullanılarak Haziran - Eylül 2023 arasında (dört aylık süreçte) toplanmıştır. Bu çalışmada, trafik hacmi tahmini için Hafif Gradyan Artırma Makineleri (Light Gradient Boosting Machine, LightGBM), RF, XGBoost ve Gradyan Artırma algoritmaları gibi topluluk öğrenme yöntemleri kullanılmıştır. Elde edilen sonuçlara göre, ortalama araç durma sayısında %20, toplam gecikmede %11.7, toplam durma süresinde %15.8 ve ortalama araç gecikmesinde %25 azalma sağlanmıştır. Liu vd. (2025) çalışmalarında Amerika'nın California eyaletindeki Los Angeles şehrinde bulunan trafik sensörlerine ait 2012 ve 2017 yılı araç hızlarını içeren iki veri setini kullanmıştır. Gereksiz hesaplama yükü çıkarmadan trafik akımını tahmin etmek için Kaynak-Verimli Federatif Çevrim İçi Öğrenme (Resource-Efficient Federated Online Learning, REFOL) adlı yeni bir yöntem kullanmıştır. Sonuç olarak performans değerlendirmeleri önerilen yöntemin mevcut yöntemlere göre daha başarılı olduğunu göstermiştir. Ye vd. (2024) Amerika Birleşik Devletleri'nin California eyaletine ait 1 Temmuz 2016 – 28 Şubat 2018 tarihleri arasındaki trafik hacmi bilgilerini içeren veri setlerinden yararlanarak bir çalışma gerçekleştirmiştir. Bu kapsamda Otoregresif Entegre Hareketli Ortalama (Autoregressive Integrated Moving Average ARIMA), LSTM + CNN (Evrişimli Sinir Ağı, Convolutional Neural Network), LSTM + GCN (Grafik Evrişimli Ağ, Graph Convolutional Network), LSTM + Transformer (Dönüştürücü) ve Geçitli Tekrarlayan Birim (Gated Recurrent Unit, GRU) gibi toplam 10 farklı tahmin yaklaşımı kullanılmıştır. Elde edilen bulgular, derin öğrenme tabanlı yöntemlerin geleneksel modellere kıyasla anlamlı ölçüde daha yüksek tahmin doğruluğu sağladığını ortaya koymuştur. Shao vd. (2024) çalışmalarında Çin'in Qingdao şehrine ait otuz günlük trafik hacmi verisi ile Amerika Birleşik Devletleri'nin California eyaletinde yer alan San Bernardino şehrine ait, 2016 yılı Temmuz – Ağustos aylarını kapsayan trafik hacmi verisini kullanmıştır. Trafik akımı tahminleri için adaptif hibrit bir model geliştirilmiştir. Önerilen model kısa süreli trafik akımı tahmini için iki modüllü yapıda tasarlanmıştır. Geliştirilen model, on bir farklı model ile karşılaştırılmış ve diğer modellere göre daha başarılı sonuçlar gösterdiği gözlenmiştir.

Trafik ışıklarının ve trafik yönetim şemalarının planlanmasını ve işletilmesini desteklemek için trafik tahminlerinin oluşturulması dijital ikiz için önemli bir unsurdur. Mevcut literatür detaylı olarak incelendiğinde, son yıllarda dünyanın birçok şehrinde dijital ikiz çerçevesinde çalışmalar yapılmış olduğu belirlenmiştir (Wang vd. 2022; Rezaei vd. 2023; Shin vd. 2023; Faliagka vd. 2024; Shamlitsky vd. 2024). Ancak

literatürdeki bazı çalışmalar tahmin modeli önerisinde bulunmakla sınırlı kalmış, bazıları ise tahmin modeli kullanmadan sentetik veya küçük trafik hacmi verileriyle benzetim programında uygulamalar gerçekleştirmiştir. Bu durum, dijital ikizin temel bileşenlerinden biri olan geçmiş ve gelecek verilerinin birlikte değerlendirilmemesi nedeniyle, dijital ikiz mimarisinin ulaşım ağı oluşturulmasındaki katkısına dair literatürde belirgin bir eksiklik olduğunu göstermektedir. Bu çalışmada, geçmiş veriler kullanılarak gelecek trafik verilerini tahmin eden trafik tahmin modelleri oluşturulmuş olup SUMO benzetim programında çeşitli senaryolar için analizler yapılarak ulaşım parametreleri bakımından sonuçlar karşılaştırılmıştır.

Trafik yönetimi konusunda benzetim programları kullanılarak literatürde birçok çalışma yapılmıştır. Bu bölümde literatürde yapılmış olan çalışmalar incelenmiştir.

Boz (2019) Yıldız Teknik Üniversitesi kampüsünde geometrik düzenleme öncesi ve sonrası durumları SUMO benzetim programı yardımıyla karşılaştırmıştır. Ulaşım ağını oluşturmak için SUMO'nun NETEDIT modülünü, altlık olarak Open Street Map (OSM) verilerini kullanmıştır. Araç rotaları, DuaRouter modülü ile oluşturulmuş; benzetim çıktıları ise Python programlama dili kullanılarak elde edilmiştir. Buna göre yapılan geometrik düzenlemenin trafik yoğunluğunu %71.8 oranında azalttığı gözlenmiştir. Mahmood (2019) sinyalizasyon kavşaklarının adaptif kavşak ve sabit sinyal süreli olarak çalışmaları durumundaki performanslarını SUMO benzetim programı kullanarak karşılaştırmıştır. Bunun için Kilis şehrindeki dört kavşaktan alınan saha verileri kullanılmıştır. Adaptif kavşak uygulaması, önerilen bulanık mantık sistemiyle gerçekleştirilmiştir. Önerilen modelin performansı; toplam bekleme süresi, toplam seyahat süresi, ortalama bekleme süresi ve ortalama seyahat süresi gibi ulaşım performans parametreleri dikkate alınarak karşılaştırılmıştır. Bulanık mantıkla gerçekleştirilen modelin sonuçlarına göre, kavşaklarda ortalama bekleme süresi açısından sırasıyla %76, %56, %50 ve %60 oranlarında performans iyileşmesi gözlemlenmiştir. Topal (2022) trafik ağı bağlantılarını modellemek için SUMO benzetim programını kullanmıştır. SUMO ve Farksal Gelişim sezgisel algoritmasının entegrasyonu, Python programlama dili kullanılarak gerçekleştirilmiştir. Sabit zamanlı sinyalizasyon kavşaklarına ait sinyal süreleri ile sezgisel algoritma kullanılarak en iyilenen modeller, seyahat süreleri açısından karşılaştırılmıştır. Önerilen yöntemin ortalama seyahat süresi bakımından %31.953 daha iyi sonuçlar verdiği gözlemlenmiştir. Balta ve Özçelik (2019) Yazılım Tanımlı Ağlar (Software-Defined Networking, SDN) ve Araçsal Ağlar (Vehicular Ad Hoc Networks, VANET) sistemlerinin birlikte kullanılmasıyla, sinyalizasyon kavşaklarda trafik yönetimini sağlayacak bir mimari önermiştir. Sinyal süresi en iyilemesi gerçekleştirmek için SDN ile entegre çalışan karınca kolonisi algoritması geliştirmiştir. Önerilen model, SUMO benzetim programı kullanılarak Webster yöntemi, bulanık mantık modeli, parçacık sürü en iyileme modeli ve sabit zamanlı sinyalizasyon sistemi ile karşılaştırılmıştır. Çalışmada performans karşılaştırması ortalama araç gecikmesi, kuyruk uzunluğu, işlem süresi, benzetim programı çalışma süresi, uçtan-uca gecikme parametreleri bakımından yapılmıştır. Önerilen yöntemle kuyruk uzunluğu, ortalama gecikme değerleri trafik performans parametrelerinde sabit zamanlı sisteme göre %15-%22 arasında, diğer modellere göre %7-%12 arasında iyileşme olduğu görülmüştür. Çeltekin (2021) çalışmasında nesnelerin interneti tabanlı adaptif trafik sinyal kontrolünü gerçekleştirmiştir. Trafik sinyal en iyilemesi için parçacık sürü algoritması, sosyal öğrenme parçacık sürü algoritması ve edimsel koşullanma ile sosyal öğrenme parçacık

sürü algoritması, takviyeli öğrenme yöntemleri ve varyant teknikleri kullanmıştır. Çalışmada SUMO benzetim programında gerçek ve sentetik verilerden oluşturulan senaryolar için uygulama yapılmıştır. Çalışma sonucunda ortalama hızlarda %10 oranında bir artış sağlandığı tespit edilmiştir. Zhang vd. (2023) Çin'in Pekin şehrinde Shijingshan semtinde 8 sinyalize kavşakta en iyileme çalışması yapmıştır. Bunun için, SUMO benzetim programında çok ajanlı derin öğrenme tabanlı teknikler kullanmışlardır. Sonuç olarak geleneksel sabit zamanlı sinyal kontrolüne göre Ortalama Alan Q-Ağı Bölgesel Trafik Sinyal Kontrolü (Mean Field Q-Network Area Traffic Signal Control, MFQ-ATSC) ve Ortalama Alan Aktör-Eleştirmen Ağı Bölgesel Trafik Sinyal Kontrolü (Mean Field Actor-Critic Network Area Traffic Signal Control, MFAC-ATSC) modellerinin yolculuk süresini sırasıyla %15,74 ve %7,4 iyileştirmiş olduğu tespit edilmiştir. Kumarasamy vd. (2024) sinyal en iyilemesini gerçekleştirmek için Amerika Birleşik Devletleri'nin Tennessee eyaletinde, Chattanooga şehrinde, Luther King (MLK) akıllı koridorunda bulunan on bir sinyalize kavşaktan gelen gerçek zamanlı trafik verilerini kullanmıştır. Dijital ikizi temsil eden gerçek zamanlı trafik benzetimi, PTV-Vissim programı kullanılarak oluşturulmuştur. Dijital İkiz modelini geliştirmek amacıyla, merkezi olmayan ve Grafik Tabanlı Çok Ajanlı Pekiştirmeli Öğrenme Yöntemi (Decentralized Graph-based Multi-Agent Reinforcement Learning, DGMARL) kullanılmıştır. Önerilen model ile mevcut adaptif sinyal kontrol durumu karşılaştırılmıştır. Durma süresi ve durma gecikmeleri temel alınarak geliştirilen yakıt tüketimi performans ölçütü kullanılarak yapılan değerlendirmede, önerilen modelin %55,38 oranında iyileşme sağladığı belirlenmiştir. Hu ve Li (2024), Tayvan'ın Tainan şehrindeki Fuqian Yolu'nun Batı Merkez Bölgesi'nde yer alan yedi sinyalli kavşağın sinyal sürelerinin en iyilemesi için çok ajanlı derin öğrenme modeli geliştirmiştir. Çalışmada Çift Derin Q-Ağı (Double Deep Q-Network, DDQN) ve Derin Q-Ağı (Deep Q-Network, DQN) tabanlı pekiştirmeli öğrenme yöntemleri, geleneksel sabit zamanlı kontrol ve PASSER-V modelleri ile karşılaştırılmıştır. Benzetim çalışması SUMO'da gerçekleştirilmiş ve sonuçlar dört farklı trafik akış koşulunda analiz edilmiştir. Çok etmenli DDQN modelinin, geleneksel yöntemlere kıyasla üstün performans sergilediği gözlemlenmiştir. Farklı trafik senaryolarında bekleme süresi %40–%60 oranında azalmış, araç hızları ise %10–%18 oranında artış göstermiştir. Shen vd. (2023) çalışmalarında Çin'in Şanghai şehrinde, Wujiaochang bölgesinde, kırk yedi heterojen kavşağın bulunduğu trafik ağı için çok ajanlı derin öğrenme tabanlı model geliştirmişlerdir. Çalışmada Avantajlı Aktör-Eleştirmen (Advantage Actor-Critic, A2C) algoritmasının bir türevi olan Heterojen Avantajlı Aktör-Eleştirmen (Heterogeneous Advantage Actor-Critic, HA2C) modeli kullanılarak trafik akışını en iyilemek hedeflenmiştir. SUMO benzetim programında sentetik ve gerçek dünya verileriyle oluşturulan senaryolar analiz edilmiştir. Sonuç olarak, HA2C'nin trafik parametreleri açısından mevcut modellerden daha iyi performans gösterdiği tespit edilmiştir.

Literatürde farklı ülkelerde yapılan benzetim çalışmaları ve saha verisine dayalı analizler, değişen oranlarda CO₂ emisyonlarında azalma bildirmektedir. Bu aralık, kullanılan yönteme, trafik koşullarına ve değerlendirme ölçütlerine bağlıdır (Gao vd. 2020; Zhao vd. 2022; Liv vd. 2023). Mevcut emisyon seviyelerinin hesaplanması ve iyileştirme potansiyelinin analiz edilebilmesi için, karar destek sistemlerine entegre edilen trafik benzetimleri, önemli bir araştırma ve uygulama aracı olarak öne çıkmaktadır. Son yıllarda, sabit zamanlı ve uyarlamalı kontrol gibi geleneksel yöntemlerin yanı sıra, daha gelişmiş bir yaklaşım olan adaptif kontrol yöntemine makine öğrenmesi ve derin

öğrenme algoritmalarının entegre edilmesiyle hibrit sistemler geliştirilmiştir. Bu sistemler, gerçek zamanlı sinyal en iyilemesinde trafik parametrelerini iyileştirerek emisyonların azaltılmasına önemli katkılar sağlamaktadır (Xu vd. 2018; Guo vd. 2019).

Santos vd. (2023) web tabanlı mikroskobik trafik benzetim aracı geliştirip kullanarak Portekiz’de bulunan bir kavşağı modellemiştir. Çalışmada, CO₂ emisyonlarını en aza indirmeye yönelik maliyet temelli bir adaptif sinyal kontrol algoritması geliştirilmiştir. Bu algoritma, karşıt trafik akışlarının durdurulma maliyetlerini (araç sayısı ve hızına bağlı olarak) karşılaştırarak sinyal geçişlerini dinamik şekilde belirlemektedir. Önerilen yöntem mevcuttaki sabit zamanlı sinyal kontrol sistemi ile farklı trafik hacmi senaryolarında karşılaştırılmıştır. Benzetim sonuçlarına göre trafik yoğunluğuna bağlı olarak CO₂ emisyonunun %32 ila %40 arasında azalmış olduğu gözlenmiştir. Wu vd. (2025) Çin’in en yoğun 100 kentinde yürüttükleri çalışmada, büyük veri destekli adaptif sinyal kontrol sistemlerini şehir ölçeğinde uygulamışlardır. Benzetimler ve saha gözlemleriyle desteklenen analizlerde, sinyal sürelerinin gerçek zamanlı trafik verisine göre en iyilemesinin, yoğun saatlerde seyahat süresini %11, düşük yoğunlukta ise %8 oranında azalttığı tespit edilmiştir. Ayrıca, bu yöntem sayesinde karbon emisyonlarında yıllık 31.73 milyon ton (yaklaşık %6.65) oranında azalma sağlanabileceği belirtilmiştir. Çalışmada kullanılan analiz yöntemi, OSM ve Gaode Map verilerine dayalı olarak CBEEngine trafik benzetim ortamında gerçekleştirilmiş ve emisyonlar MOVES modeliyle hesaplanmıştır. Yöntem; sabit zamanlı sinyal kontrolüyle karşılaştırıldığında, dur-kalk sayısını ve bekleme sürelerini azaltarak hem trafik akışını iyileştirmiş hem de çevresel etkileri azaltmıştır. Politi ve Tanyel (2025), Türkiye’nin İzmir kentinde bulunan birbirine yakın sinyalizasyon kavşakları üzerinde gerçekleştirdikleri çalışmada, yakıt tüketimini en aza indirmeye yönelik sürdürülebilir bir trafik yönetimi çerçevesi geliştirmiştir. Gerçek saha verilerine dayalı olarak SIDRA Intersection 6.1 mikroskobik trafik benzetim aracıyla modelleme yapılmış, Yapay Sinir Ağı (Artificial Neural Network, ANN), SVR ve Kısmi En Küçük Kareler Regresyonu (Partial Least Squares Regression, PLSR) gibi makine öğrenme algoritmaları ile yakıt tüketimi tahminlenmiştir. En başarılı tahmin sonuçlarını ANN modeli vermiştir. Sonrasında, sinyal çevrim süresi ve sol dönüş şeridi uzunluğu, Parçacık Sürü (Particle Swarm Optimization, PSO) algoritması ile en iyilenmiştir. Önerilen PSO-ANN tabanlı model sayesinde yakıt tüketiminde %8.9 oranında iyileşme sağlanmıştır. Çalışma, sinyal en iyilemesi ve yapay zekâ temelli yakıt modellemesini entegre ederek çevresel etkileri azaltmaya yönelik sürdürülebilir bir yaklaşım sunmuştur. Kim vd. (2025), Güney Kore’nin Icheon şehrinde gerçekleştirdikleri çalışmada, çoklu kavşaklar için karbon salımını azaltmaya yönelik çok ajanlı derin pekiştirmeli öğrenme tabanlı bir kooperatif sinyal kontrol yöntemi geliştirmişlerdir. DDQN, Dueling DQN ve Öncelikli Deneyim Tekrarı (Prioritized Experience Replay) algoritmaları birleştirilerek oluşturulan model SUMO benzetim ortamında test edilmiştir. Gerçek trafik verileri ile yapılan benzetimler sonucunda, önerilen yöntem, sabit zamanlı ve karşılaştırmalı modellere göre bekleme süresini zirve saatlerde %30, zirve dışı saatlerde %54, CO₂ emisyonlarını ise zirve saatlerde %21, zirve dışı saatlerde %23 oranında azaltmıştır. Wang vd. (2023), Çin’de gerçekleştirdikleri bu çalışmada, Bağlantılı ve Otonom Araçlar (Connected and Autonomous Vehicles, CAV) ile İnsan Sürücülü Araçların (Human-Driven Vehicles, HDV) bir arada bulunduğu karma trafik ortamında, karbon salımını azaltmayı hedefleyen bir Karşılaştırmalı Çift Derin Q-Ağı (Dueling Double Deep Q Network, D3QN) tabanlı trafik sinyal kontrol algoritması geliştirmişlerdir. SUMO benzetim ortamında gerçekleştirilen çalışmada, CO₂ azaltımına

odaklı bir ödül fonksiyonu tanımlanmış ve bu fonksiyon hem bekleme süresi hem de anlık CO₂ salım değerlerini en iyileyecek şekilde tasarlanmıştır. Modelde hem sabit faz dizilimi hem de uyarlanabilir faz dizilimi seçenekleri yer almaktadır. Gerçek zamanlı CO₂ tahmini için, Araçlara Özgü Güç (Vehicle-Specific Power, VSP) yöntemi ve elektrikli araçlar için enerji dönüşüm modeli entegre edilmiştir. D3QN algoritması, klasik DQN ve diğer algoritmalarla karşılaştırıldığında daha hızlı yakınsama, daha düşük CO₂ salımı ve daha az bekleme süresi sağlamıştır. Özellikle düşük ve orta trafik yoğunluklarında CO₂ emisyonlarında %7.42'ye kadar azalma sağlandığı; ortalama bekleme süresinin ise %28.88'e kadar azaltıldığı gözlemlenmiştir. Lv vd. (2025), Çin'in Jinhua kentindeki gerçekleştirdikleri çalışmada, karbon salımını azaltmaya yönelik sinyal zamanlaması en iyilemesi için Rainbow DQN algoritmasına dayalı bir derin pekiştirmeli öğrenme modeli önermişlerdir. Benzetimler, SUMO ortamında ve gerçek trafik verileriyle yapılmıştır. Rainbow DQN tabanlı önerilen model, sabit zamanlı, etkin zamanlı (actuated), klasik DQN ve D3QN tabanlı modellerle karşılaştırılmıştır. Sonuçlar, Rainbow DQN modelinin bekleme süresini %27.58, CO₂ emisyonlarını %7.34 oranında azalttığını göstermiştir. Ayrıca klasik DQN ve D3QN modellerine göre sırasıyla bekleme süresinde %15, emisyonlarda %6.5 oranında ek azalma sağlanmıştır.

Bu çalışmada literatürden farklı olarak:

- Çevre, Şehircilik ve İklim Değişikliği Bakanlığı tarafından geliştirilen 'SUMO Türkiye Uyarlaması' tercih edilerek dijital ikiz mimarisi oluşturulmasında kullanılmıştır (Coğrafi Bilgi Sistemleri Müdürlüğü 2022).
- Literatürde çeşitli yapay zeka algoritmalarıyla sinyal süresi ve faz planı en iyilemesi çalışmalarının olduğu fakat dijital ikiz ortamında, adaptif sinyalizasyon kavşakların olduğu ulaşım ağında beklenmedik trafik senaryoları (örneğin, deprem veya fırtına gibi olaylar sonucunda sensör arızaları) nedeniyle oluşacak olan trafik tıkanıklığının öngörülerek çözüm uygulamasının yapılmadığı görülmüştür. Bu çalışmada literatürdeki eksikliğin giderilmesi amaçlanmıştır.
- Trafik hacmi tahmini ve sinyalizasyon kavşakların derin öğrenme tabanlı yönetimi birlikte ele alınarak değerlendirilmiştir.
- Sensör arızalarının trafik yönetimine etkileri incelenmiş ve bu tür beklenmedik durum için çözüm geliştirilmiştir. Örneğin, kamera bağlantısının kopması veya kamera açıların değişmesi gibi durumlar, sanal bölge kalibrasyonunun yeniden yapılmasını gerektirmektedir (İlyas vd. 2024). Böyle bir durumda, sinyalizasyon sisteminde aksamalar meydana gelmekte ve akıllı kavşaklar, sabit sinyal süreli modda çalışmaktadır.
- Literatürde özetlendiği gibi trafikten kaynaklı emisyonların azaltılmasına yönelik çok çeşitli çalışmalar yürütülmüş olmakla birlikte, yürütülen çalışmaların çoğunluğunda sadece CO₂ emisyonları ve yakıt tüketimleri incelenmiş ve elde edilen sonuçlar karşılaştırılmıştır. Diğer emisyonların insanlara ve çevreye etkileri ile bu etkilerin ne seviyede azaltıldığı detaylı olarak incelenmemiştir. Çevresel etkilerin kapsamlı bir biçimde belirlenmesine yönelik olarak yürütülen çevresel analizlerde, en yaygın kullanılan yöntemlerden biri LCA yöntemidir. LCA herhangi bir proses veya ürünün yaşam döngüsü boyunca ya da yaşam döngüsünün belirli bir kısmında çevresel etkilerinin analiz edilmesini sağlamaktadır (ISO 14040 2006). LCA uygulanmasıyla sadece emisyon miktarları değil, aynı zamanda bu emisyonların etkilediği kategoriler de

belirlenebilmektedir. Ancak, literatürde trafikten kaynaklanan emisyonların azaltılmasına yönelik çalışmaların LCA ile değerlendirildiği çalışmalar oldukça sınırlıdır.


Bu çalışma trafik yönetim merkezi projelerinin kapasite geliştirilmesi amacıyla kullanılabilecek ve akıllı kavşakların afetlere dayanıklı yenilikçi teknoloji ile dönüştürülmesine katkıda bulunacaktır.





3. MATERYAL VE METOT

Tez kapsamında, trafik yönetiminde veri analizi tabanlı bir yaklaşımla tahmin ve en iyileme süreçleri ele alınmıştır. Çalışmada anlık veri akışı bulunmamakla birlikte, geçmiş verilerden yararlanılarak geleceğe yönelik trafik hacmi tahminleri yapılmıştır. Bu yaklaşımın, dijital ikiz sistemlerinin altyapısının geliştirilmesine katkı sağlayacağı ve ilerleyen aşamalarda gerçek hayat entegrasyonları için uygulanabilir bir temel sunacağı öngörülmektedir. Şekil 3.1’de bu sürecin akış şeması sunulmuştur.



Şekil 3.1. Derin öğrenme ile trafik hacmi tahmini ve en iyileme sürecinin akış şeması


3.1. Trafik Yönetiminde Kullanılan Akıllı Kavşak Bilgileri

3.1.1. Araç sayım verilerinin elde edilme süreci

2023 yılında Antalya’da trafik yönetimi açısından önemli gelişmeler olmuştur. Bu kapsamda şehir genelinde 40 adet akıllı kavşak ve 61 adet uzaktan erişimli kavşak tesis edilmiş, aynı zamanda bu kavşakların tümünü izleyen ve yöneten Antalya Trafik Kontrol Merkezi kurulmuştur. Trafik Kontrol Merkezi, adaptif ve uzaktan erişimli kavşaklardan gelen verileri toplayarak trafik akışını gerçek zamanlı olarak izleyebilmekte, trafik yoğunluğunu analiz edebilmektedir.

Trafik Kontrol Merkezi kavşak kontrol paneli, bir şehirdeki çeşitli kavşaklarda trafik ışıklarını, geçiş hakları ve diğer trafik yönetim unsurlarını koordine etmek için kullanılmaktadır. Bu panel, genellikle trafik kontrol merkezi operatörleri tarafından izlenmekte ve kullanılmaktadır. Trafik ışıklarının en düşük ve en yüksek sürelerini ve diğer trafik düzenlemelerini bu panel aracılığıyla ayarlamak mümkündür. Ayrıca bu panel üzerinden akıllı kavşaklar hakkındaki istatistiki verilere erişilebilmektedir.

Şekil 3.2’de Antalya Trafik Kontrol Merkezi kavşak kontrol panelinden alınma görüntü sunulmuştur. S harfi ile belirtilen çemberler uzaktan izlemeli, A harfi ile belirtilenler adaptif kavşakları temsil etmektedir.




Şekil 3.2. Antalya Trafik Kontrol Merkezi kavşak kontrol paneli arayüzü

Şekil 3.3’te, akıllı kavşağa ait kamera yerleşimi ve balık gözü kameralarla elde edilen görüntü örnekleri sunulmuştur. Direklere monte edilmiş balık gözü kameralar aracılığıyla elde edilen ham görüntüler Şekil 3.3(a)’da gösterilmekte olup, kavşaktaki trafik akışının genel görünümünü sağlamaktadır. Bu görüntüler üzerinde tanımlanan sanal bölgeler Şekil 3.3(b)’de verilmiş ve bu bölgeler araç tespiti ile araç sayımı yapılmasına olanak sağlamaktadır. Elde edilen veriler, Trafik Kontrol Merkezi’ne iletilmektedir. Ayrıca, örnek bir kavşağa ait drone görüntüsünde kamera yerleşim planı ve görüş mesafeleri Şekil 3.3(c)’de gösterilmiştir.



(a)



(b)



(c)

Şekil 3.3. Adaptif akıllı kavşak kamera görüntüleri **(a)** balık gözü kameralarla elde edilen kavşak görüntüleri; **(b)** balık gözü kameralar üzerinden tanımlanan sanal bölgeler; **(c)** akıllı kavşakta kamera yerleşim planı ve görüş alanları

Çizelge 3.1’de araç sayım veri setinin ilk 5 satırına yer verilmiştir. Bu örnek veri setinin yapısını ve içerdiği temel bilgileri özetlemektedir.

Çizelge 3.1. Araç sayım veri setinin ilk 5 satırı


Motosiklet	Otomobil	Minibüs	Kamyon	Gelen Rota ID	Giden Rota ID	Tarih-Saat
0	2	0	0	37981	37981	2023-02-14 11:19:59
0	7	0	0	37979	37982	2023-02-14 11:19:59
13	88	3	4	37981	37979	2023-02-14 11:19:59
0	9	0	0	37982	37980	2023-02-14 11:19:59
0	2	0	0	37981	37982	2023-02-14 11:19:59

3.1.2. Heybe Kavşağı

Heybe Kavşağı, Antalya ili Konyaaltı ilçesi Gürsu Mahallesi sınırlarında, Atatürk Bulvarı ile 353. Sokak kesişiminde yer almakta olup 4 kollu sinyal kontrollü bir kavşak olarak hizmet vermektedir. Kavşak, Atatürk Bulvarı'nın kent merkezine doğru devamında bulunmaktadır. Atatürk Bulvarı'nın kent merkezine doğru devam eden Sahil Geliş (R4) ve Kuzey Geliş (R2) kolları, yol hiyerarşisi açısından Merkez Geliş (R1) ve Kemer Geliş (R3) kollarına kıyasla daha alt seviyede konumlandırılmıştır.


Kavşağa bağlanan R2 ve R4 geliş kolları 2 şeritli bir yapı sergilerken, R3 geliş kolu 3 şeritli bir ana yol ve 2 şeritli sola dönüş şeridiyle refüjle ayrılmıştır. R1 geliş kolunda ise sola dönüş şeridi dahil olmak üzere toplam 4 şerit bulunmaktadır. Bu şeritlerden R1 geliş kolundaki sola dönüş şeridi 95 metre, R3 geliş kolundaki 2 şeritli sola dönüş şeridi ise 140 metre uzunluğundadır. (UKOME 2023).

Şekil 3.4'te Heybe Kavşağı'nın Google Earth görüntüsü yer almakta olup, kavşağın geometrik yapısı ve çevresindeki alanlar detaylı bir şekilde görülmektedir.



Şekil 3.4. Heybe Kavşağı'nın Google Earth görüntüsü

Şekil 3.5'te, Heybe Kavşağı'na ait Antalya Trafik Kontrol Merkezi'nden elde edilen görüntü sunulmaktadır. Görüntüde, kavşakta yer alan trafik sinyal grupları detaylı bir şekilde görülmekte olup, bu yapı gerçek zamanlı trafik akışının izlenmesine ve analiz edilmesine olanak sağlamaktadır.



Şekil 3.5. Heybe Kavşağı Antalya Trafik Kontrol Merkezi görüntüsü

Atatürk Bulvarı ile 353. Caddesi'nin kesişiminde yer alan kavşakta, akıllı kavşak modunda 17:00-18:00 saatleri arasında çalıştığı duruma ait sinyal planı Çizelge 3.2'de, sabit sürelerle çalıştığı duruma ait sinyal planı ise Çizelge 3.3'te sunulmaktadır. Yapılan incelemeler, kavşağın 5 fazlı bir sistemle çalıştığını ve sabit sinyal planı modunda devre

süresinin (koruma süreleri hariç) gün boyunca 179 saniye olarak belirlendiğini göstermektedir. Ayrıca, Merkez Geliş (R1) kolunda Q6-Q8 fazlarının, Kemer Geliş (R3) kolunda Q5-Q7 fazlarının, Kuzey Geliş (R2) kolunda Q10 fazının ve Sahil Geliş (R4) kolunda Q9 fazının aktif olduğu tespit edilmiştir.

Çizelge 3.2. Heybe Kavşağı'nın Adaptif Kavşak durumu en az ve en çok süreleri

Kavşak Kolları	Fazlar	En Az Süre (sn)	En Çok Süre (sn)
Merkez Geliş	Q6-Q8	15	70
Merkez-Kemer Karşılıklı	Q5-Q6	10	20
Kemer Geliş	Q5-Q7	15	50
Sahil Geliş	Q9	10	40
Kuzey Geliş	Q10	15	30

Çizelge 3.3. Heybe Kavşağı sabit süreli sinyalizasyon planı

Kavşak Kolları	Fazlar	Yönler	Yeşil Sinyal Süreleri (sn)
Merkez Geliş	Q6-Q8	R1	79
Merkez-Kemer Karşılıklı	Q5-Q6	R1-R3	20
Kemer Geliş	Q5-Q7	R3	56
Sahil Geliş	Q9	R4	22
Kuzey Geliş	Q10	R2	24

Heybe Kavşağı'nda 8 Temmuz 2023 tarihinde sabah saat 6:00-7:00 arasında her fazda hizmet veren araç sayıları ve hareketleri PCU cinsinden detaylı olarak Çizelge 3.4'te gösterilmektedir.

Çizelge 3.4. Heybe Kavşağı'nın 6:00-7:00 saatleri arasındaki araç sayım verileri

Yön İsmi	Merkez Geliş (R1)	Kemer Geliş (R3)	Sahil Geliş (R4)	Kuzey Geliş (R2)
Merkez Gidiş (R1)	7	571	127	26
Kemer Gidiş (R3)	803	20	49	46
Sahil Gidiş (R4)	35	30	0	35
Kuzey Gidiş (R2)	61	20	79	0
Toplam	906	641	255	107

3.1.3. Türkay Kavşağı

Türkay Kavşağı, Antalya ili Konyaaltı ilçesi sınırlarında, Atatürk Bulvarı ile Gazi Mustafa Kemal Bulvarı kesişiminde yer almakta olup, 4 kollu sinyal kontrollü bir kavşak olarak hizmet vermektedir. Bu kavşak, Heybe Kavşağı sonrası Atatürk Bulvarı'nın kent merkezine doğru devamında konumlanmıştır. Sahil Geliş (R4) ve Kuzey Geliş (R2) kolları, yol hiyerarşisi bakımından Merkez Geliş (R3) ve Kemer Geliş (R1) kollarına kıyasla daha alt seviyede yer almaktadır.


Türkay Kavşağı'na bağlanan R2 ve R4 geliş kolları 3 şeritli bir yapı sergilerken, R1 ve R3 geliş kolları 2 şerit sola dönüş olmak üzere toplamda 5 şeritli bir geliş yoluna sahiptir. Trafik akışını en iyilemek için tasarlanmış olan R1 ve R3 geliş kollarındaki sola dönüş şeritleri 95 metre uzunluğundadır (UKOME 2023).

Şekil 3.6'da Türkay Kavşağı'nın Google Earth görüntüsü yer almakta olup, kavşağın geometrik yapısı ve çevresindeki alanlar detaylı bir şekilde görülmektedir.



Şekil 3.6. Türkey Kavşağı Google Earth görüntüsü

Şekil 3.7’de Türkey Kavşağı’na ait Antalya Trafik Kontrol Merkezi’nden elde edilen görüntü sunulmaktadır. Görüntüde, kavşakta yer alan trafik sinyal grupları detaylı bir şekilde gösterilmektedir.



Şekil 3.7. Türkey Kavşağı Antalya Trafik Kontrol Merkezi görüntüsü

Atatürk Bulvarı ile Gazi Mustafa Kemal Bulvarı kesişiminde yer alan kavşakta, akıllı kavşak modunda 17:00-18:00 saatleri arasında çalıştığı duruma ait sinyal planı Çizelge 3.5’te, sabit sürelerle çalıştığı duruma ait sinyal planı ise Çizelge 3.6’da sunulmaktadır. Yapılan incelemeler, kavşağın 5 fazlı bir sistemle çalıştığını ve sabit sinyal planı modunda devre süresinin (koruma süreleri hariç) gün boyunca 179 saniye

olarak belirlendiğini göstermektedir. Ayrıca, Merkez Geliş (R3) kolunda Q5-Q7 fazlarının, Kemer Geliş (R1) kolunda Q6-Q8 fazlarının, Kuzey Geliş (R2) kolunda Q9 fazının ve Sahil Geliş (R4) kolunda Q10 fazının aktif olduğu tespit edilmiştir.

Çizelge 3.5. Türkay Kavşağı'nın Adaptif Kavşak durumu en az ve en çok süreleri

Kavşak Kolları	Fazlar	En Az Süre (sn)	En Çok Süre (sn)
Kemer Geliş	Q6-Q8	15	40
Merkez-Kemer Karşılıklı	Q5-Q6	15	20
Merkez Geliş	Q5-Q7	15	40
Kuzey Geliş	Q9	15	30
Sahil Geliş	Q10	15	40

Çizelge 3.6. Türkay Kavşağı sabit süreli sinyalizasyon planı

Kavşak Kolları	Fazlar	Yönler	Yeşil Sinyal Süreleri (sn)
Kemer Geliş	Q6-Q8	R1	54
Merkez-Kemer Karşılıklı	Q5-Q6	R3-R1	22
Merkez Geliş	Q5-Q7	R3	75
Kuzey Geliş	Q9	R2	24
Sahil Geliş	Q10	R4	13

Türkay Kavşağı'nda 8 Temmuz 2023 tarihinde saat 17:00-18:00 arasında her fazda hizmet veren araç sayıları ve hareketleri PCU cinsinden detaylı olarak Çizelge 3.7'de gösterilmektedir.


Çizelge 3.7. Türkay Kavşağı'nın 17:00-18:00 saatleri arasındaki araç sayım verileri

Yön İsmi	Merkez Geliş (R1)	Kemer Geliş (R3)	Sahil Geliş (R4)	Kuzey Geliş (R2)
Kemer Gidiş (R3)	1598	30	187	61
Merkez Gidiş (R1)	66	1479	111	254
Sahil Gidiş (R4)	267	113	13	274
Kuzey Gidiş (R2)	92	191	267	10
Toplam	2023	1813	578	599

3.1.4. Işıktepe Kavşağı

Bu bölümde Ata Bulvarı Kırmızı Caddesi kesişiminde bulunan (Işıktepe) akıllı kavşak bilgileri detaylı olarak ele alınmıştır.

Şekil 3.8'de Işıktepe Kavşağı'nın Google Earth görüntüsü yer almakta olup, kavşağın geometrik yapısı ve çevresindeki alanlar detaylı bir şekilde görülmektedir.

**Şekil 3.8.** Işıktepe Kavşağı'nın Google Earth görüntüsü

Çizelge 3.8'de, Işıktepe Kavşağı'nın konumu, fiziksel yapısı vb. özellikleri

açıklanmıştır.

Çizelge 3.8. Işıktepe Kavşağı geometrik özellikleri

	Açıklama
Konum	Bursa ili, Nilüfer ilçesi, Ata Bulvarı ile Kırmızı Caddesi kesişimi
Kavşak Türü	4 kollu sinyal kontrollü kavşak
Bağlanan Yollar	Güney geliş (1 numaralı faz), Kuzey geliş (3 numaralı faz), Doğu geliş (4 numaralı faz), Batı geliş (5 numaralı faz),
Yol Hiyerarşisi	Doğu geliş ve Batı geliş kolları, Güney geliş ve Kuzey geliş kollarına kıyasla daha alt seviyede
Şerit Sayıları	Kuzey geliş ve Güney geliş kolları 4 şeritli (gidiş istikametleri 3 şeritli); Batı geliş-gidiş ve Doğu geliş-gidiş kolları 2 şeritli
Sola Dönüş Şerit Uzunlukları	Güney geliş kolu 105 m

Ata Bulvarı Kırmızı Caddesi kesişiminde yer alan sinyalize kavşağa ait 8 Temmuz 2023 tarihi saat 15:00-16:00 arasındaki araç sayım verileri temin edilmiştir. Akıllı kavşak modunda çalıştığı duruma ait sinyal planı Çizelge 3.9’da, sabit sürelerle çalıştığı duruma ait sinyal planı ise Çizelge 3.10’da sunulmaktadır. Yapılan incelemeler, kavşağın 5 fazlı bir sistemle çalıştığını ve sabit sinyal planı modunda devre süresinin (koruma süreleri hariç) gün boyunca 89 saniye olarak belirlendiğini göstermektedir. Ayrıca, Doğu geliş kolunda 4 numaralı fazın, Batı geliş kolunda 5 numaralı fazın, Güney geliş kolunda 1 numaralı fazın, Kuzey-Güney geliş kolunda 2 numaralı fazın, Kuzey geliş kolunda 3 numaralı fazın aktif olduğu tespit edilmiştir (Bursa Trafik Kontrol Merkezi 2023).

Çizelge 3.9. Işıktepe Kavşağı’nın Adaptif Kavşak durumu en az ve en çok süreler

Kavşak Kolları	Fazlar	En Az Süre (sn)	En Çok Süre (sn)
Doğu Geliş	4	10	15
Batı Geliş	5	10	15
Güney Geliş	1	10	15
Kuzey Güney Karşılıklı	2	10	45
Kuzey Geliş	3	10	25

Çizelge 3.10. Işıktepe Kavşağı sabit süreli sinyalizasyon planı

Kavşak Kolları	Fazlar	Yeşil Sinyal Süreleri (sn)
Doğu Geliş	4	13
Batı Geliş	5	16
Güney Geliş	1	10
Kuzey Güney Karşılıklı	2	30
Kuzey Geliş	3	20

Işıktepe Kavşağı'nda 8 Temmuz 2023 tarihinde sabah saat 15:00-16:00 arasında her fazda hizmet veren araç sayıları ve hareketleri PCU cinsinden detaylı olarak Çizelge 3.11'de gösterilmektedir. Burada "X" ile gösterilen simge u dönüşlerin yasak olduğunu, "-" ile gösterilen simge ise araç geçmediğini belirtmektedir. Bursa örneği için kullanılan trafik verileri Bursa Trafik Kontrol Merkezi'nden temin edilmiş olup bu sayede benzetimlerde gerçek trafik koşullarını doğru bir şekilde yansıtmak mümkün olmuştur.

Çizelge 3.11. Işıktepe Kavşağı'nın 15:00-16:00 saatleri arasındaki araç sayım verileri

Yön İsmi	Kuzey Geliş	Güney Geliş	Doğu Geliş	Batı Geliş
Kuzey Gidiş	X	1307	109	187
Güney Gidiş	2045	X	155	85
Doğu Gidiş	96	68	-	17
Batı Gidiş	177	128	22	-
Toplam Gidiş	2318	1503	286	289

3.2. Trafik Hacim Verilerinin Aykırılık Analizi ve Tahmin Modelleri Geliştirme Süreci


Trafik verilerinde sıkça karşılaşılan aykırılıklar, ölçüm hataları, cihaz sorunları veya olağandışı olaylardan (kazalar, afetler vb.) kaynaklanabilmektedir. Bu aykırılıklar, modellerin doğruluğunu olumsuz etkileyen gürültüler olarak değerlendirilir. Bu nedenle,

çalışmada aykırılık tespiti ve temizleme yöntemleri uygulanarak, veri kalitesini artırmak ve tahmin modellerinin performansını iyileştirmek hedeflenmiştir.

Bu amaçla çalışma oluşturulan trafik hacmi tahmin modelleri, 3 temel aşamada organize edilmiştir. İlk aşamada veri seti analiz edilmiş olup en yoğun trafik akışına sahip güzergâh belirlenmiştir. Sonraki aşamada ilgili istikamet için PCU dönüşümü uygulanmış olup, farklı araç türlerinin genel trafik akışı üzerindeki etkileri korelasyon analizi yapılarak değerlendirilmiştir. Son aşamada ise aykırılık analizi ve veri temizleme işlemi uygulanmış olup, elde edilen yeni veri seti tahmin modellerinin eğitim ve testleri için kullanılmıştır.

Her aşamada kullanılan yöntemler ve araçlar Şekil 3.9’da detaylı bir şekilde gösterilmiştir.





Şekil 3.9. Trafik hacmi tahmin süreci akış diyagramı

Trafikte kayıtlı motosikletlerin illere göre dağılımı incelendiğinde, Antalya'nın 426.590 motosiklet ile Türkiye genelinde ikinci sırada yer aldığı görülmektedir (TÜİK 2024). Bu durum, trafik akışının analizinde araç sınıflarının dikkate alınmasının önemini ortaya koymaktadır.

Çizelge 3.12, farklı araç tiplerini ortak bir ölçüm birimine dönüştürmek için kullanılan PCU dönüşüm katsayılarını göstermektedir. Bu dönüşüm, her araç tipinin trafik üzerindeki farklı etkilerinden kaynaklanmaktadır. PCU, tüm araç tiplerini otomobil

birimlerine dönüştürerek benzetim programının gerçek yaşam koşullarını kalibre etmesine olanak tanımıştır.

Çizelge 3.12. PCU değerleri (UKOME 2023, TS 6407 2013)

Araç Tipi	Otomobil	Motosiklet	Otobüs/Minibüs	Ağır Taşıt
PCU/Antalya	1	0.5	1.5	3
PCU/Bursa	1	0.33	1.3	2.25

3.2.1. Aykırılık tespiti, veri temizleme ve derin öğrenme modelleri ile trafik hacmi tahmini

Veri setinin güvenilirliğini artırmak ve model başarımını en üst düzeye çıkarmak amacıyla aykırılık tespiti ve temizleme işlemleri gerçekleştirilmiştir. Bu kapsamda, aşağıda belirtilen üç farklı aykırılık tespit yöntemi uygulanmıştır:

- **Z-Score:** Verilerin standart normal dağılım özelliklerini kullanarak aykırı değerlerin tespit edilmesini sağlayan istatistiksel bir yöntemdir. Bir veri noktasının ortalamadan kaç standart sapma uzakta olduğunu hesaplar. Belirlenen eşik değerinin üzerindeki gözlemler aykırı kabul edilmektedir.

Z-Score aşağıdaki eşitlikte görüldüğü gibi hesaplanmaktadır:

$$\left(Z_i = \frac{x_i - \mu}{\sigma} \right) \quad (3.1)$$

Burada x_i i'inci veri noktasını, μ veri kümesinin ortalamasını, σ veri kümesinin standart sapmasını, Z_i ise ilgili veri noktasının standartlaştırılmış değerini ifade etmektedir.

Bu çalışmada, Z-Score yönteminde eşik değeri 3 olarak alınmıştır. Ayrıca, her bir değişken için ortalama (μ) ve standart sapma (σ) değerleri eğitim verisi üzerinden hesaplanmış, bu eşik değeri üzerinde kalan gözlemler aykırı kabul edilmiştir.

- **Mahalanobis Mesafesi:** Çok değişkenli istatistiksel yöntemlerden biri olup, bir gözlemin veri kümesinin ortalama vektöründen kovaryans yapısı dikkate alınarak ne kadar uzak olduğunu ölçmektedir. Böylece, veriler arasındaki korelasyonlar da hesaba katılarak aykırı değerlerin tespiti yapılmaktadır.

Mahalanobis mesafesi aşağıdaki eşitlikte görüldüğü gibi hesaplanmaktadır:

$$D_M(x) = \sqrt{((x - \mu)^T \Sigma^{-1} (x - \mu))} \quad (3.2)$$

Burada x gözlem vektörünü, μ veri kümesinin ortalama vektörünü, Σ^{-1} kovaryans matrisinin tersini ifade etmektedir. $D_M(x)$ değeri büyüdükçe, gözlemin

merkezden uzaklığı artmakta ve aykırı değer olma ihtimali yükselmektedir.

Bu çalışmada, Mahalanobis mesafesi uygulanmış ve eşik değeri 3 olarak alınmıştır. Hesaplanan mesafe değerleri standartlaştırılarak Z-Score'a dönüştürülmüş ve belirlenen eşik değeri üzerindeki gözlemler aykırı kabul edilmiştir.

- **Temel Bileşenler Analizi (Principal Component Analysis, PCA):** Yüksek boyutlu veri setlerinde temel bileşenleri ortaya çıkararak, veriyi daha düşük boyutlarda temsil eden istatistiksel bir yöntemdir. PCA, özellikle boyut indirgeme ile aykırı değerlerin belirlenmesinde kullanılmaktadır. Aykırı noktalar, temel bileşenler uzayında diğer gözlemlerden uzak kalan değerler olarak tespit edilmektedir.

PCA dönüşümü aşağıdaki eşitlikte gösterilmektedir:

$$Z = X \cdot W \quad (3.3)$$

Burada X standartlaştırılmış veri matrisini, W özvektörlerden oluşan dönüşüm matrisini, Z ise temel bileşenler uzayına dönüştürülmüş yeni veri kümesini ifade etmektedir.

Bu çalışmada PCA yöntemi uygulanırken veriler öncelikle ölçeklendirilmiş, ardından 2 bileşen seçilerek dönüşüm gerçekleştirilmiştir. Elde edilen temel bileşenler kullanılarak her bir gözlem için Öklid uzaklığı hesaplanmış, eşik değeri 3'ün üzerinde kalan gözlemler aykırı olarak değerlendirilmiştir.

Veri temizleme sürecinin ardından, temizlenmiş veri setleri Doğrusal Regresyon, Karar Ağaçları, En Yakın Komşular (KNN), Çok Katmanlı Algılayıcı (MLP), Rastgele Orman, Gradyan Artırma, Elastic Net, Adaboost, Bagging, Voting ve Stacking makine öğrenmesi algoritmaları kullanılarak değerlendirilmiş ve en etkili temizleme yaklaşımı belirlenmiştir. En iyi performans gösteren güzergaha ait veri seti derin öğrenme tabanlı trafik hacmi tahmini için kullanılmıştır. Bu kapsamda LSTM, Çift Yönlü LSTM (BiLSTM), GRU, LSTM+CNN, Dikkat Mekanizması Tabanlı LSTM, Yığınlanmış LSTM, LSTM+GRU ve RNN olmak üzere sekiz farklı derin öğrenme mimarisi uygulanmıştır. Bu modeller, zaman serisi tahmininde yaygın olarak kullanılan farklı mimarilerin çeşitliliğini temsil etmekte olup, görece basitten orta derecede karmaşık tasarımlara kadar geniş bir yelpazeyi kapsamaktadır.

- **LSTM:** Uzun vadeli bağımlılıkları öğrenme yeteneği nedeniyle zaman serisi analizinde sıkça tercih edilen bir modeldir. İçindeki kapı mekanizmaları sayesinde önemli bilgiyi tutmakta, önemsiz bilgiyi unutmaktadır.

LSTM hücreleri giriş (i_t), unutma (f_t) ve çıkış (o_t) kapıları ile hücre durumunu (C_t) güncelleyerek bilgi akışını düzenlemektedir. Bu kapılar aşağıdaki eşitliklerle hesaplanmaktadır:

$$i_t = \sigma(W_i[h_{t-1}, x_t] + b_i) \quad (3.4)$$

$$f_t = \sigma(W_f[h_{t-1}, x_t] + b_f) \quad (3.5)$$

$$o_t = \sigma(W_o[h_{t-1}, x_t] + b_o) \quad (3.6)$$

Aday hücre durumu ve güncel hücre durumu aşağıda verilen eşitlikler ile hesaplanmaktadır:

$$\tilde{C}_t = \tanh(W_c[ht - 1, x_t] + b_c) \quad (3.7)$$

$$C_t = f_t \odot C_{t-1} + i_t \odot \tilde{C}_t \quad (3.8)$$

Son olarak, güncel gizli durum h_t aşağıdaki eşitlikte görüldüğü gibi elde edilmektedir:

$$h_t = o_t \odot \tanh(C_t) \quad (3.9)$$

Burada x_t giriş verisini, h_{t-1} bir önceki gizli durumu, C_t hücre durumunu, W ve b öğrenilebilir parametreleri ifade etmektedir. σ sigmoid aktivasyon fonksiyonunu, $\odot$ ise eleman bazlı çarpmayı göstermektedir.

- **BiLSTM:** Çift yönlü bilgi akışı sağlayarak, modelin hem geçmiş ($t - 1$) hem de gelecek ($t + 1$) zamana ait bilgileri aynı anda değerlendirmesine olanak tanımaktadır. Bu yapı sayesinde özellikle zaman serilerinde ileri ve geri bağımlılıkların birlikte öğrenilmesi mümkün olmaktadır.

BiLSTM, iki ayrı LSTM katmanından oluşur: biri zaman serisini ileri yönde işlerken diğeri geri yönde işlemektedir. Her iki katmandan elde edilen gizli durumlar birleştirilerek çıktı elde edilmektedir.

İleri ve geri yönlü gizli durumlar aşağıdaki eşitliklerde görüldüğü gibi hesaplanmaktadır:

$$\overrightarrow{h}_t = LSTM(x_t, \overrightarrow{h}_{t-1}) \quad (3.10)$$

$$\overleftarrow{h}_t = LSTM(x_t, \overleftarrow{h}_{t-1}) \quad (3.11)$$

Sonuç olarak çift yönlü LSTM çıktısı aşağıdaki eşitlikte görüldüğü gibi hesaplanmaktadır:

$$h_t = [\overrightarrow{h}_t; \overleftarrow{h}_t] \quad (3.12)$$

Burada x_t giriş verisini, $\overrightarrow{h}_t$ ileri yönlü LSTM'den elde edilen gizli durumu, $\overleftarrow{h}_t$ ise geri yönlü LSTM'den elde edilen gizli durumu göstermektedir. Köşeli parantez içindeki $[:]$ işlemi, iki vektörün birleştirilmesini ifade etmektedir.

- **GRU:** LSTM ile benzer bir yapıya sahip olup daha az parametre kullanması nedeniyle hesaplama açısından daha verimli bir modeldir. GRU, güncelleme (z_t) ve sıfırlama (r_t) kapıları ile hücre durumunu yönetmekte ve bilgi akışını düzenlemektedir.

Bu kapılar aşağıdaki eşitliklerle hesaplanmaktadır:

$$z_t = \sigma(W_z[h_{t-1}, x_t] + b_z) \quad (3.13)$$

$$r_t = \sigma(W_r[h_{t-1}, x_t] + b_r) \quad (3.14)$$

Aday gizli durum ($\tilde{h}_t$) ve güncel gizli durum (h_t) ise aşağıda eşitliklerde görüldüğü gibi hesaplanmaktadır:

$$\tilde{h}_t = \tanh(W_h[r_t \odot h_{t-1} + b_h]) \quad (3.15)$$

$$h_t = (1 - z_t) \odot h_{t-1} + z_t \odot \tilde{h}_t \quad (3.16)$$

Burada x_t giriş verisini, h_{t-1} bir önceki gizli durumu, W ve b öğrenilebilir parametreleri ifade etmektedir. σ sigmoid aktivasyon fonksiyonunu, $\tanh$ hiperbolik tanjant fonksiyonunu, $\odot$ ise eleman bazlı çarpmayı göstermektedir.

- **LSTM + CNN:** Bu model CNN ile LSTM'nin birleştirilmesiyle oluşturulmaktadır. CNN katmanları, zaman serisi verilerindeki yerel örüntüleri ve kısa vadeli bağımlılıkları yakalamakta, LSTM katmanları ise uzun vadeli bağımlılıkları öğrenmektedir. Böylece model, hem uzamsal hem de zamansal ilişkileri aynı anda yakalayabilmektedir.

Öncelikle, giriş verisi x_t üzerinde bir boyutlu konvolüsyon işlemi gerçekleştirilmekte ve filtreler aracılığıyla özellik haritaları çıkarılmaktadır:

$$h_t^c = f(W_c * x_t + b_c) \quad (3.17)$$

Burada W_c konvolüsyon filtrelerini, $*$ konvolüsyon işlemi, b_c bias terimini ve f aktivasyon fonksiyonunu ifade etmektedir. Daha sonra elde edilen özellik haritaları üzerinde alt örnekleme uygulanarak boyut küçültülmekte ve önemli özellikler korunmaktadır.

Elde edilen bu özellikler, LSTM katmanına giriş olarak verilmekte ve LSTM'in kapı mekanizmaları aracılığıyla uzun vadeli bağımlılıkları öğrenmesi sağlanmaktadır. Son aşamada ise LSTM'den elde edilen gizli durumlar yoğun katmana aktarılmakta ve çıktı tahmini gerçekleştirilmektedir.

- **Dikkat Mekanizması Tabanlı LSTM:** Bu model, LSTM'in zamansal bağımlılıkları öğrenme gücünü dikkat mekanizması ile birleştirmektedir. Böylece model, her zaman adımının önemini farklı ağırlıklarla değerlendirerek tahmin performansını artırmaktadır.

Öncelikle her bir zaman adımı için ham dikkat skorları (e_t) hesaplanmakta, ardından bu skorlar normalize edilerek dikkat ağırlıkları (α_t) elde edilmektedir. Bu süreç aşağıdaki eşitliklerde görüldüğü gibi tanımlanmaktadır:

$$e_t = v^T \tanh(W_h h_t + W_s s_{\{t-1\}} + b) \quad (3.18)$$

$$\alpha_t = \frac{\exp(e_t)}{\sum_{k=1}^T \exp(e_k)} \quad (3.19)$$

Sonrasında, tüm gizli durumların ağırlıklı toplamı alınarak bağlam vektörü c_t oluşturulmakta ve çıktı hesaplamasında kullanılmaktadır:

$$c_t = \sum_{t=1}^T \alpha_t h_t \quad (3.20)$$

Burada h_t LSTM tarafından üretilen gizli durumu, s_{t-1} bir önceki zaman adımındaki durumu W_h, W_s, v, b öğrenilebilir parametreleri, e_t ham dikkat skorunu, α_t normalize edilmiş dikkat ağırlığını ve c_t bağlam vektörünü ifade etmektedir. Bu mekanizma sayesinde model, zaman serisinde önemli adımlara daha fazla ağırlık vererek tahmin doğruluğunu artırmaktadır.

- **Yığılanmış LSTM:** Bu model, birden fazla LSTM katmanının ardışık şekilde birleştirilmesiyle oluşturulmaktadır. Tek katmanlı LSTM'lere kıyasla daha derin bir ağ yapısına sahip olduğundan, verilerden daha karmaşık ve yüksek seviyeli temsiller öğrenebilmektedir. İlk LSTM katmanının çıktısı, bir sonraki LSTM katmanına giriş olarak verilmekte ve böylece farklı seviyelerdeki zamansal bağımlılıkların yakalanması mümkün olmaktadır.

Yığılanmış LSTM'de kullanılan denklemler LSTM ile aynıdır. Ancak bu işlemler birden fazla katman boyunca tekrarlanmakta, ilk katmandan çıkan gizli durumlar (h_t^1) ikinci katmana giriş olarak aktarılmakta ve burada yeni gizli durumlar (h_t^2) üretilmektedir. Katman sayısı arttıkça model, daha yüksek seviyeli özellik temsilleri öğrenebilmektedir.

- **LSTM + GRU:** Bu model, LSTM ve GRU'nun güçlü yönlerini birleştirerek hem uzun vadeli bağımlılıkları öğrenebilmekte hem de daha az parametre ile hızlı öğrenme kapasitesi sunabilmektedir. İlk katmanda LSTM hücreleri, giriş (i_t), unutma (f_t) ve çıkış (o_t) kapıları aracılığıyla hücre durumunu güncelleyerek uzun vadeli bilgiyi yakalamaktadır. Bu kapılar aşağıdaki eşitliklerle hesaplanmaktadır:

$$i_t = \sigma(W_i[h_{t-1}, x_t] + b_i) \quad (3.21)$$

$$f_t = \sigma(W_f[h_{t-1}, x_t] + b_f) \quad (3.22)$$

$$o_t = \sigma(W_o[h_{t-1}, x_t] + b_o) \quad (3.23)$$

Aday hücre durumu ve güncel hücre durumu ise şu şekilde hesaplanmaktadır:

$$\tilde{C}_t = \tanh(W_c[h_{t-1}, x_t] + b_c) \quad (3.24)$$

$$C_t = f_t \odot C_{t-1} + i_t \odot \tilde{C}_t \quad (3.25)$$

Son olarak, LSTM'den elde edilen güncel gizli durum h_t şu eşitlikle elde edilmektedir:

$$h_t = o_t \odot \tanh(C_t) \quad (3.26)$$

TM katmanından çıkan gizli durum, GRU katmanına giriş olarak verilmekte ve burada güncelleme (z_t) ve sıfırlama (r_t) kapıları ile bilgi akışı düzenlenmektedir. Bu kapılar aşağıdaki eşitliklerle hesaplanmaktadır:

$$z_t = \sigma(W_z[h_{t-1}, x_t] + b_z) \quad (3.27)$$

$$r_t = \sigma(W_r[h_{t-1}, x_t] + b_r) \quad (3.28)$$

Aday gizli durum ve güncel gizli durum ise şu şekilde elde edilmektedir:

$$\tilde{h}_t = \tanh(W_h[r_t \odot h_{t-1}, x_t] + b_h) \quad (3.29)$$

$$h_t = (1 - z_t) \odot h_{t-1} + z_t \odot \tilde{h}_t \quad (3.30)$$

Burada x_t giriş verisini, h_{t-1} bir önceki gizli durumu, C_t LSTM hücre durumunu, W ve b öğrenilebilir parametreleri ifade etmektedir. σ sigmoid aktivasyonunu, $\tanh$ hiperbolik tanjant fonksiyonunu ve $\odot$ eleman bazlı çarpmayı göstermektedir.

- **RNN:** En temel tekrarlayan sinir ağı yapısıdır ve zaman serisi gibi sıralı verilerin işlenmesinde ilk kullanılan modellerden biridir. LSTM ve GRU'ya kıyasla daha basit bir yapıya sahiptir; kapı mekanizmaları bulunmadığından uzun vadeli bağımlılıkları öğrenmede sınırlı kalabilmektedir. Ancak temel bir yapı olarak karşılaştırmalarda sıkça kullanılmaktadır. RNN'de güncel gizli durum h_t , bir önceki gizli durum h_{t-1} ile giriş verisi x_t kullanılarak aşağıdaki eşitlikte görüldüğü gibi hesaplanmaktadır:

$$h_t = \tanh(W_h h_{t-1} + W_x x_t + b) \quad (3.31)$$

Çıktı değeri y_t ise gizli durum üzerinden aşağıda eşitlikte gösterildiği gibi elde edilmektedir:

$$y_t = W_y h_t + b_y \quad (3.32)$$

Burada x_t giriş verisini, h_{t-1} bir önceki gizli durumu, h_t güncel gizli durumu, W_h , W_x , W_y öğrenilebilir ağırlıkları b , b_y bias terimlerini ve $\tanh$ aktivasyon fonksiyonunu ifade etmektedir.

Çalışmada kullanılan derin öğrenme modellerinin katman yapıları Çizelge 3.13'te özetlenmiştir. Her bir model için oluşturulan mimari zamansal bağımlılıkları, uzamsal ilişkileri veya dikkat mekanizmalarını öğrenebilecek şekilde tasarlanmıştır.

Çizelge 3.13. Derin Öğrenme Modellerinin Yapısı (Modellerin parametreleri)

Model Adı	Katmanlar ve Nöron Sayısı	Toplam Katman Sayısı
LSTM	LSTM (50) → Dropout (0.2) → LSTM (50) → Dropout (0.2) → Dense (25) → Dense (1)	6
BiLSTM	BiLSTM (50) → Dropout (0.2) → BiLSTM (50) → Dropout (0.2) → Dense (25) → Dense (1)	6
GRU	GRU (50) → Dropout (0.2) → GRU (50) → Dropout (0.2) → Dense (25) → Dense (1)	6
LSTM + CNN	Conv1D (64 filtre) → MaxPooling1D (2) → LSTM (50) → Dropout (0.2) → LSTM (50) → Dropout (0.2) → Dense (25) → Dense (1)	8
RNN	SimpleRNN (50) → Dropout (0.2) → SimpleRNN (50) → Dropout (0.2) → Dense (25) → Dense (1)	6
Dikkat Mekanizması Tabanlı LSTM	LSTM (50) → Dikkat Mekanizması → LSTM (50) → Dense (25) → Dropout (0.2) → Dense (1)	6
Yığılanmış LSTM	LSTM (50) → Dropout (0.2) → LSTM (50) → Dropout (0.2) → LSTM (50) → Dropout (0.2) → Dense (25) → Dense (1)	8
LSTM + GRU	LSTM (50) → Dropout (0.2) → GRU (50) → Dropout (0.2) → Dense (25) → Dense (1)	6

Model eğitiminde eniyileme algoritması olarak Adam, kayıp fonksiyonu olarak MSE kullanılmış ve başlangıç öğrenme oranı 1×10^{-3} olarak tanımlanmıştır. Aşırı öğrenmeyi azaltmak için bazı mimari varyantlarda 0.2 oranında Dropout uygulanmıştır. Doğrulama kaybında art arda yedi epok boyunca iyileşme gözlenmediğinde eğitim, erken durdurma stratejisiyle sonlandırılmış; ayrıca beş epok ilerleme olmadığında öğrenme oranı 0.5 katsayısıyla düşürülerek sürecin kararlılığı artırılmıştır. Tüm deneyler 32 yığın boyutu ve 50 epok üst sınırıyla yürütülmüştür. Bu üst sınır, Ekler bölümünde sunulan EK-1: LSTM + GRU için eğitim ve doğrulama kayıpları grafiğinde (500 epokluk örnek çalışma) doğrulama kaybındaki iyileşmenin erken dönemde yavaşladığının görülmesi dikkate alınarak belirlenmiştir.

Veri seti zaman sıralı olarak %70 eğitim, %15 doğrulama ve %15 test olacak şekilde ayrılmış; erken durdurma mekanizmasıyla en düşük doğrulama kaybına sahip olan ağırlıklar korunmuştur. Çalışmada iki farklı veri seti kullanılmıştır: ham veriler ve aykırılık analizinden geçirilerek temizlenmiş veriler. Böylece, modeller her iki veri seti üzerinde ayrı ayrı eğitilmiş ve performans farklılıkları test metrikleri üzerinden karşılaştırılmıştır.

Model eğitiminin sonunda elde edilen tahminlerin ne kadar başarılı olduğunu anlamının yolu onları doğru metriklerle değerlendirmekten geçmektedir. Bu çalışmada kullanılan modellerin performans değerlendirmesi MSE, MAE ve R^2 metrikleri

kullanılarak yapılmıştır.

Veri sızıntısını önlemek amacıyla, tüm ölçekleyiciler yalnızca eğitim verisi üzerinde fit edilmiştir. Ayrıca, zaman serisi pencerelerinin oluşturulması sürecinde test setinin başlangıç pencerelerinin doğru tanımlanabilmesi için eğitim setinin son n adımı test setine eklenmiştir. Bu yaklaşım, test aşamasında geçmiş bilgiye erişimin doğru şekilde modellenmesini sağlamış ve değerlendirme sürecinde metodolojik tutarlılık garanti edilmiştir.

3.2.2. Model performansının değerlendirilmesi

Deneyisel aşamada oluşturulan modellerin performansını değerlendirmek için MAE, R^2 , MSE metrikleri kullanılmıştır. Bu metrikler, modelin tahminlerinin gerçek değerlerden ne kadar uzakta olduğunu farklı açılardan ölçmektedir.

MAE: Ortalama mutlak hata, bir tahminin gerçek değerden ortalama olarak ne kadar uzak olduğunu ölçen bir istatistiksel ölçüttür.

MAE, her bir tahmin hatasının mutlak değerlerinin ortalamasını hesaplamaktadır. Mutlak değer, bir sayının işaretini göz ardı ederek o sayının pozitif değerini almaktadır. Bu nedenle, MAE, bir tahminin gerçek değerden ne kadar farklı olduğunu ölçmektedir, ancak bu farkın yönünü dikkate almamaktadır.

MAE, özellikle regresyon modellerinin performansını ölçmek için kullanılmaktadır. Bir regresyon modeli, bir girdi değişkeniyle bir çıktı değişkeni arasındaki ilişkiyi modelleyen bir matematiksel fonksiyondur. MAE, modelin gerçek değerlerden ne kadar sapma gösterdiğini ölçerek, modelin ne kadar iyi performans gösterdiğini anlamamıza yardımcı olmaktadır. MAE aşağıda verilen eşitlikten hesaplanmaktadır.

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - x_i| \quad (3.33)$$

Burada y_i gözlemlenen (gerçek) değerleri, x_i modelden elde edilen tahmin değerlerini ve n toplam gözlem sayısını ifade etmektedir.

R^2 : Önerilen tahmin modellerinin performansını karşılaştırmak için Belirleme Katsayısı kullanılmıştır. Bu yöntemle bağımlı ve bağımsız değişkenler arasındaki etkinin matematiksel model sonucuna dayalı karşılaştırması yapılabilmektedir.

R^2 aşağıda verilen eşitlikten hesaplanmaktadır.

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - x_i)^2}{\sum_{i=1}^n (y_i - x_0)^2} \quad (3.34)$$

Yani toplam hatalar karesi ile tüm toplam karelerin birbirine oranı hesaplanarak birden çıkarılmıştır. Burada y_i gözlemlenen değerleri, x_i modelden elde edilen tahmin değerlerini ve x_0 ise gözlemlerin ortalamasını ifade etmektedir.

Genel olarak R^2 değerinin bire yaklaşması durumunda modelin tahmin performansının yüksek olduğu, sıfıra yaklaşması durumunda modelin başarısız olduğu sonucu çıkarılabilmektedir (İlyas ve Albayrak 2023).

MSE: Bir modelin tahmin sonuçlarının gerçek değerlerden ortalama olarak ne kadar saptığını ölçen bir metriktir. MSE, hata karelerinin ortalaması alınarak hesaplanmaktadır ve bu nedenle, büyük hataların daha fazla cezalandırıldığı bir ölçüm sağlamaktadır.

MSE'nin hesaplanma formülü aşağıda verilen eşitlikten hesaplanmaktadır.

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - x_i)^2 \quad (3.35)$$

Burada y_i gözlemlenen değerleri, x_i modelden elde edilen tahmin değerlerini ve n toplam gözlem sayısını ifade etmektedir.


MSE her zaman sıfır veya pozitif bir değer almaktadır. Sıfıra yakın değerler, modelin tahminlerinde yüksek doğruluk sağladığını göstermektedir. Büyük hatalara karşı daha hassastır, bu da modelin büyük hatalardan kaçınmasını sağlamaktadır. Sürekli değişkenlerin tahmin edildiği regresyon modellerinin performansını değerlendirmek için sıklıkla kullanılmaktadır.

3.3. SUMO Türkiye Uyarlaması


Proje kapsamında önerilen yenilikçi çözüm, mevcut sistemle karşılaştırmalı olarak analiz edilmiştir. Bu analiz, Çevre, Şehircilik ve İklim Değişikliği Bakanlığı, Coğrafi Bilgi Sistemleri Genel Müdürlüğü, Akıllı Şehirler Dairesi tarafından geliştirilen SUMO Türkiye Uyarlaması benzetim programı kullanılarak gerçekleştirilmiştir. Analizlerde, trafik parametreleri olarak ortalama araç gecikmesi, ortalama seyahat süresi, kuyruk uzunluğu, yakıt tüketimi ve emisyon gibi metrikler dikkate alınmıştır (T.C. Çevre Şehircilik ve İklim Değişikliği Bakanlığı 2023b).

SUMO Türkiye Uyarlaması, OpenStreetMap (OSM) tabanlı harita verilerini NETEDIT modülüne aktararak ulaşım ağı modellemesi yapılmasına olanak tanımaktadır. Ayrıca, benzetim modülü ile trafik akışları ve trafik yoğunluğu görsel olarak analiz edilebilmektedir.

Şekil 3.10'da SUMO Türkiye Uyarlaması'nın arayüzü gösterilmektedir. OSM butonu, harita verilerinin içe aktarılmasını sağlamakta ve bu veriler kullanılarak ulaşım ağı modellemesi yapılmaktadır. NETEDIT modülü, ağ düzenlemesine erişim sunmaktadır. Benzetim modülü ise, trafik hareketinin görsel olarak gözlemlenmesini sağlamaktadır. Bu araçlar, trafik parametrelerinin detaylı bir şekilde analiz edilmesine ve önerilen yenilikçi çözümün etkileri üzerinde kapsamlı bir değerlendirme yapılmasını mümkün kılmaktadır. Şekil 3.11'de SUMO Türkiye Uyarlaması 2 boyutlu program çıktısı gösterilmiştir.



Şekil 3.10. SUMO Türkiye Uyarlaması program arayüzü



Şekil 3.11. SUMO GUI program görseli


Şekil 3.12’de görüldüğü üzere SUMO’nun GUI modülüyle 2 boyutlu olarak çalıştırılan benzetim programı SUMO Türkiye uyarlaması ile 3 boyutlu olarak gözlenebilmektedir. Burada binaların yükseklikleri gerçek bina yükseklikleri ile uyuşmamakta olup görsel olarak daha net bir görünüm sağlanması amaçlanmıştır. Coğrafi Bilgi Sistemler Müdürlüğü, şehirlerin dronlar kullanılarak oluşturulan 3 boyutlu modellerini geliştirmektedir. Çalışmalar tamamlandıktan sonra bu modellerin entegrasyonu sağlanarak, gerçek verilerle uyumlu görsel çıktılar elde edilebilecektir (Coğrafi Bilgi Sistemleri Müdürlüğü 2022).



Şekil 3.12. SUMO Türkiye Uyarlaması 3 boyutlu görsel

Bu Tezde SUMO simülatörü ve Python'un TraCI arayüzü kullanılmıştır. SUMO'da bir benzetim senaryosu oluşturmak için üç temel aşama izlenmiş olup Şekil 3.13'te bu süreçlerin genel akışı gösterilmiştir:

- Trafik ağı modelleme: Kavşağın geometrik düzeni, yol bağlantıları, şerit sayıları ve trafik sinyal planları SUMO ağına dahil edilmiştir.
- Trafik talebi tanımlama: Kavşaktan geçen araçların geliş yönleri, trafik hacimleri PCU cinsinden dağılımları belirlenmiş ve SUMO'ya aktarılmıştır.
- Benzetim çalıştırma ve analiz: SUMO ortamında trafik akışı benzetilerek sabit süreli ve adaptif sinyal kontrol sistemleri için performans karşılaştırmaları yapılmıştır. Yapılan benzetim çalışmalarında yaya davranışları dikkate alınmamış ve ideal koşullar temel alınmıştır.



Şekil 3.13. SUMO benzetim aşamaları


3.3.1. Heybe Kavşağı SUMO modellemesi

Akıllı kavşaklar, trafik ışıkları, kameralar, sensörler, radarlar ve yazılım uygulamaları gibi çeşitli teknolojik bileşenleri entegre ederek işlev görmektedirler. Böylece sürücülere ve trafik yöneticilerine birçok avantaj sunmaktadırlar. Bu bölümde Şekil 3.14’te gösterilen Heybe Kavşağı’na ait trafik hacim verilerinin analiz ve modelleme süreç akışı işlenmiştir. Süreç, kavşağın dijital ortamda çizilmesiyle başlamıştır. Ardından, sinyal planlarının ve Başlangıç-Son (Origin-Destination, OD) matrisinin sisteme girilmesiyle analiz aşamasına geçilmiştir.


Sensör verilerinin durumu dikkate alınarak üç farklı senaryo oluşturulmuştur:

- Senaryo 1: Sensör arızasının bulunmadığı adaptif kavşak senaryosu (Heybe 1)
- Senaryo 2: Mevcut geleneksel çözüm kapsamında sensör arızasının yaşandığı sabit süreli sinyalizasyon senaryosu (Heybe 0)
- Senaryo 3: Sensör arızasının yaşandığı durumda önerilen alternatif yöntem (dijital operatör yönetimli kavşak) senaryosu.

Bu üç senaryo, SUMO Türkiye uyarlamasıyla benzetim gerçekleştirilerek analiz edilmiş ve elde edilen sonuçlar karşılaştırmalı olarak değerlendirilmiştir.



Şekil 3.14. Heybe Kavşağı trafik hacim verilerinin analiz ve modelleme süreç akışı



Şekil 3.15. Heybe Kavşağının görüntüsü a) Google Haritalar; b) Netedit; c) SUMO

Şekil 3.15'te Heybe kavşağının üç farklı bağlamdaki temsili göstermektedir. Şekil 3.15 (a)'da Google Haritalardan alınan hava görüntüsü, kavşağın gerçek dünyadaki görünümünü, yol altyapısını ve çevresel detayları ayrıntılı bir şekilde sunmaktadır. Şekil 3.15 (b)'de kavşağın Netedit ortamında modellenmiş hali yer almaktadır. Netedit, benzetim için yol ağlarını düzenlemek amacıyla kullanılan bir araçtır ve bu temsil, yolları, şeritleri ve kavşakları sade ve yapılandırılmış bir şekilde göstermektedir. Şekil 3.15 (c)'de ise kavşağın SUMO ortamındaki benzetimi yer almaktadır. SUMO'da, kavşakta dinamik trafik akışı, araç hareketleri gibi unsurlar modellenerek detaylı trafik analizi yapılabilmektedir. Bu şekil, gerçek dünyadaki bir kavşağın benzetim ortamına nasıl dönüştürüldüğünü ve modelleme sürecinde gerçekleşen soyutlama aşamalarını etkili bir şekilde yansıtmaktadır.


3.3.2. Ardışık Kavşaklar SUMO modellemesi

Bu bölümde Şekil 3.16'da gösterilen Heybe Kavşağı ve Türkay Kavşağı'na ait trafik hacim verilerinin analiz ve modelleme süreç akışı işlenmiştir. Süreç, kavşağın dijital ortamda çizilmesiyle başlamaktadır. Ardından, sinyal planlarının ve OD matrisinin sisteme girilmesiyle analiz aşamasına geçilmiştir.

Sensör verilerinin durumu dikkate alınarak üç farklı senaryo oluşturulmuştur:

- Senaryo 1: Sensör arızasının bulunmadığı adaptif kavşak senaryosu (Türkay 1, Heybe 1)
- Senaryo 2: Mevcut geleneksel yaklaşım kapsamında sensör arızasının yaşandığı sabit süreli sinyalizasyon senaryosu (Türkay 0, Heybe 0)
- Senaryo 3: Sensör arızasının yaşandığı durumda önerilen alternatif yöntem (Türkay Kavşağı için veri analizi tabanlı yaklaşım) senaryosu (Türkay 1, Heybe 0).

Bu üç senaryo, SUMO Türkiye uyarlamasıyla benzetim gerçekleştirilerek analiz edilmiş ve elde edilen sonuçlar karşılaştırmalı olarak değerlendirilmiştir.



Şekil 3.16. Heybe Kavşağı ve Türkay Kavşağı Trafik hacim verilerinin analiz ve modelleme süreç akışı



Şekil 3.17. Heybe Kavşağı ve Türkay Kavşağı benzetim görüntüsü


Şekil 3.17’de, Heybe kavşağı ve Türkay Kavşağının Google Haritalardan alınan görüntüsünün altlık olarak kullanılması ile Netedit ortamında modellenmesi sonrası SUMO ortamındaki benzetimi yer almaktadır. SUMO’da, kavşakta dinamik trafik akışı, araç hareketleri gibi unsurlar modellenerek detaylı trafik analizi yapılabilmektedir. Bu şekil, gerçek dünyadaki bir kavşağın benzetim ortamına nasıl dönüştürüldüğünü ve modelleme sürecinde gerçekleşen soyutlama aşamalarını etkili bir şekilde yansıtmaktadır.

3.3.3. Işıktepe Kavşağı SUMO modellemesi


Bu bölümde Atat Bulvarı-Kırmızı Cadde Kesişim Kavşağından alınan trafik verileri kullanılarak SUMO Türkiye Uyarlaması benzetim programı kullanılarak analizler yapılmıştır. Bu amaçla Bursa Trafik Kontrol Merkezinden sinyalize kavşak hakkında detaylı veriler toplanmış ve kalibrasyon parametreleri olarak kullanılmıştır. OSM verileri kullanılarak Netedit modülünde ağ tasarımı yapılmış ve SUMO’nun GUI modülünde model çalıştırılmıştır.

Şekil 3.18’de, Işıktepe Kavşağının Google Haritalardan alınan görüntüsünün altlık olarak kullanılması ile Netedit ortamında modellenmesi sonrası çizimi gösterilmiş olup Şekil 3.19’da SUMO ortamındaki benzetimi yer almaktadır. SUMO’da, kavşakta dinamik trafik akışı, araç hareketleri gibi unsurlar modellenerek detaylı trafik analizi

yapılabilmektedir. Bu şekil, gerçek dünyadaki bir kavşağın benzetim ortamına nasıl dönüştürüldüğünü ve modelleme sürecinde gerçekleşen soyutlama aşamalarını etkili bir şekilde yansıtmaktadır.



Şekil 3.18. Işıktepe Kavşağının Netedit ortamında çiziminin görüntüsü



Şekil 3.19. Işıktepe Kavşağının benzetim görüntüsü

Işıktepe Kavşağı, sensör verilerinin durumu dikkate alınarak iki farklı senaryo kapsamında değerlendirilmiştir. Senaryo 1, sensör arızası nedeniyle kavşağın sabit süreli

sinyalizasyonla çalıştığı durumu ifade etmektedir. Senaryo 2 ise kavşağın adaptif sinyal süreli işlediği durumu temsil etmektedir. Bu iki senaryo, SUMO Türkiye uyarlaması kullanılarak benzetim yoluyla analiz edilmiş ve elde edilen sonuçlar karşılaştırmalı olarak değerlendirilmiştir.

3.4. Derin Takviyeli Öğrenme ile Trafik Yönetimi

Kentleşme ve nüfus yoğunluğu artmaya devam ettikçe, trafik yönetimi modern şehirler için büyük bir zorluk haline gelmiştir. Geleneksel trafik sinyali kontrol yöntemleri genellikle değişen trafik koşullarına uyum sağlamakta zorlanır ve bu da daha gelişmiş çözümlere olan ihtiyacı vurgulamaktadır. DRL algoritmaları, bu sorunu ele almak için yenilikçi stratejiler sunarak, öğrenmeye dayalı en iyileme teknikleri aracılığıyla trafik sinyallerinin verimli bir şekilde yönetilmesine olanak tanımaktadır. Bu yöntemler arasında, DQL yaygın olarak kullanılan bir yaklaşım olarak öne çıkmaktadır. DQL algoritmaları, Q-değer fonksiyonunu yinelemeli olarak güncellemek, trafik akışını en iyilemek ve gerçek zamanlı karar alma yoluyla araç bekleme sürelerini azaltmak için Bellman denklemini kullanmaktadır (Tunc vd. 2024). Bu bölümde, DQL'in trafik yönetimine uygulanışı, Q-değer fonksiyonunun güncellenmesi, ödül fonksiyonu, aksiyon seti ve deneyim tekrar oynatma gibi temel bileşenler üzerinden incelenmiştir.

3.4.1. Q-Değer fonksiyonu güncelleme (Bellman denklemi)

Trafik yönetiminde, Bellman denklemi kavşaklarda alınan eylemlerin uzun vadeli etkilerini değerlendirmekte, trafik akışını en verimli hale getirmekte ve takviyeli öğrenme mekanizmaları aracılığıyla karar alma sürecini iyileştirmektedir. Bellman denklemine dayalı Q değerini güncellemenin temel adımları aşağıda özetlenmiştir.

DQL algoritması, Bellman denklemi aracılığıyla Q-değerlerini güncelleyerek en uygun aksiyon seçim sürecini yönlendirmektedir.

$$Q(s, a; \theta) \leftarrow Q(s, a; \theta) + \alpha \left(r + \gamma \max_{a'} Q(s', a'; \theta^-) - Q(s, a; \theta) \right) \quad (3.36)$$

$Q(s, a; \theta)$, sinir ağı parametreleri θ ile tanımlanan ana ağıın Q-değerini temsil etmektedir. Burada, s mevcut durumu ifade etmekte olup hücrel temsile dayanmaktadır. a , ilgili durumda gerçekleştirilen aksiyonu belirleyerek seçilen trafik sinyal fazını göstermektedir. r , bekleme süresi farkına bağlı olarak tanımlanan anlık ödül fonksiyonudur. s' , sistemin yeni durumunu tanımlarken, a' ise bu yeni durumda alınabilecek en uygun aksiyonu temsil etmektedir. α , modelin öğrenme oranını, γ ise gelecekteki ödülleri iskonto etme katsayısını göstermektedir. Son olarak, θ^- , hedef ağ parametrelerini ifade etmektedir.

Bu formülasyon, DQL modelinin eylem seçimini yinelemeli olarak iyileştirmesini ve sinyalli kavşaklarda uyarlanabilir trafik kontrol stratejilerini geliştirmesini sağlamaktadır (Vidali vd. 2019).

3.4.2. Durum temsili

Durum vektörü, kavşaktaki araçların hücrel düzeyde modellenmesiyle

oluşturulmaktadır.

$$s_t = \{h_1, h_2, \dots, h_N\} \quad (3.37)$$

Burada, h_i yolun belirli bir bölgesindeki (hücredeki) araç sayısını temsil etmektedir. N , kavşaktaki toplam yol segmenti sayısını belirtmekte olup, s_t t zamanındaki durum vektörüdür ve ağdaki tüm hücreler için doluluk bilgilerini içermektedir.

3.4.3. Aksiyon seti

Aksiyonlar, trafik ışığı fazlarını değiştirmekle ilgilidir:

$$A = \{F_1, F_2, F_3, F_4, F_5\} \quad (3.38)$$

Burada, F_1 kuzey-güney yönü için yeşil ışığı, F_2 ise doğu-batı yönündeki araç akışı için yeşil ışığı temsil etmektedir. F_3 , kuzey-güney yönünde dönüş yapan araçlar için yeşil ışığı ifade ederken, F_4 doğu-batı yönündeki dönüş hareketi için yeşil ışığı temsil etmektedir. Aksiyon uzayında yeşil sürenin sabit olduğu ve DQL algoritmasının yalnızca en uygun fazı seçmeye odaklandığı kabul edilmektedir.

3.4.4. Ödül fonksiyonu

Ödül fonksiyonu, bekleme süresi farkına dayanmaktadır.

$$r_t = W_t - W_{t+1} \quad (3.39)$$

Burada, W_t önceki zaman adımındaki toplam bekleme süresini, W_{t+1} ise güncellenmiş zaman adımındaki toplam bekleme süresini temsil etmektedir. Bu ödül fonksiyonu, trafik akışının iyileştirilmesini sağlayacak şekilde tasarlanmıştır. Bekleme süresi azaldığında, $r_t = W_t - W_{t+1}$ denklemi pozitif bir ödül üreterek iyi bir aksiyonun seçildiğini göstermektedir. Ancak, bekleme süresi arttığında r_t negatif değer alır ve bu durum, aksiyonun trafik akışını olumsuz etkilediğini ifade etmektedir. Bu yapı DQL algoritmasının en uygun aksiyonları seçmesine yönelik bir geri bildirim mekanizması sağlamaktadır.

3.4.5. Deneyim tekrar oynatma

Deneyim tekrar oynatma yöntemi, öğrenme sürecinde daha kararlı ve verimli bir güncelleme sağlamak amacıyla kullanılmaktadır. Bu yöntemde, deneyimler bir bellek havuzunda saklanmakta ve rastgele örneklenerek model eğitimi gerçekleştirilmektedir.

$$\mathcal{D} = \{(s_t, a_t, r_t, s_{t+1})\} \quad (3.40)$$

Burada, $(\mathcal{D})$ bellek havuzunu ifade ederken, her bir deneyim dört bileşenden oluşmaktadır: s_t mevcut durum, a_t bu durumda seçilen aksiyon, r_t alınan ödül ve s_{t+1} aksiyon sonrasındaki yeni durumu temsil etmektedir.

Bu yöntem, ardışık deneyimler arasındaki korelasyonu azaltarak daha dengeli bir öğrenme süreci sunmakta ve modelin genelleme kapasitesini artırmaktadır.

3.4.6. Epsilon-Greedy stratejisi

Önerilen modelde, öğrenme sürecinde keşif ve sömürü dengesini sağlamak amacıyla ($\epsilon - greedy$) stratejisi uygulanmaktadır. Bu strateji kapsamında, Denklem 3.41’de gösterildiği gibi belirli bir olasılıkla rastgele aksiyon seçilmektedir.

$$a_t = \text{random action, if } p < \epsilon \quad (3.41)$$

Aksi takdirde, mevcut bilgiye dayanarak Denklem 3.42’de gösterildiği gibi en iyi aksiyon tercih edilmektedir.

$$a_t = \text{argmax}_{(a')} Q(s, a'; \theta), \text{ if } p \geq \epsilon \quad (3.42)$$

Burada, $\epsilon > \text{rand}()$ koşulu sağlandığında ajan, rastgele bir aksiyon seçerek keşif sürecini teşvik etmektedir. Aksi durumda ($\epsilon \leq \text{rand}()$), yani rastgelelik eşiği aşılmadığında, ajan mevcut bilgiye dayanarak en yüksek Q-değerine sahip aksiyonu seçmektedir.

Bu yöntem, ajanın bilinmeyen durumları keşfetmesini sağlarken, öğrenme sürecinin ilerleyen aşamalarında daha iyi aksiyonların seçilmesine olanak tanımaktadır. Böylece, keşif ve sömürü dengesinin korunması sağlanarak modelin genel performansı iyileştirilmektedir.

3.4.7. Hedef ağ güncellemesi

DQL algoritmasında, öğrenme sürecinin kararlılığını artırmak ve hedef değerlerin ani değişimlerden kaynaklanan dalgalanmalarını önlemek amacıyla hedef ağ güncelleme mekanizması uygulanmaktadır. Bu süreç, hedef ağın parametrelerinin kademeli olarak ana ağ parametrelerine yakınsamasını sağlamak için aşağıdaki formül ile gerçekleştirilmektedir.

$$\theta^- \leftarrow \tau \theta + (1 - \tau) \theta^- \quad (3.43)$$


Burada, θ ana ağın parametrelerini, θ^- ise hedef ağın parametrelerini temsil etmektedir. τ (tau), $[0,1]$ aralığında küçük bir katsayı olup, hedef ağın güncelleme hızını belirlemektedir. Küçük τ değerleri, hedef ağın daha yavaş güncellenmesini sağlayarak öğrenme sürecindeki kararsızlıkları azaltırken, büyük τ değerleri daha hızlı bir güncelleme gerçekleştirerek ana ağ ile hedef ağ arasındaki farkı en aza indirmektedir.

3.4.8. Heybe Kavşağı’nda DQL uygulaması

Bu çalışma, özel olarak geliştirilmiş bir yazılım altyapısı aracılığıyla bir DQL algoritmasını trafik yönetim sistemine entegre etmiştir. Bu altyapı, trafik benzetiminin etkili bir şekilde yürütülmesini sağlamak üzere en iyilenmiş birden fazla bileşenden oluşmaktadır. Bu bölüm, önerilen yaklaşımda kullanılan sinir ağı mimarisini ana hatlarıyla açıklamaktadır. Giriş katmanı, kavşaktaki gerçek zamanlı trafik koşullarını temsil eden 42 özelliğe sahip bir durum vektörünü girdi olarak almaktadır. Gizli katmanlar, ağın giriş verilerinin soyut temsillerini öğrenmesine olanak tanıyan 400 nörondan oluşmaktadır. Çıktı katmanı ise her biri ayrı bir trafik kontrol eylemine karşılık

gelen beş nöron içermektedir. Ağ, verileri tam bağlantılı katmanlar aracılığıyla işlemekte ve trafik akışını en iyi hale getirmek için en uygun eylemi belirlemektedir.

Şekil 3.20, trafik yönetimi için DQL modelinin genel operasyonel çerçevesini göstermektedir. Model, kavşaktaki trafik sıkışıklığı seviyelerini temsil eden bir konum matrisini girdi olarak almakta ve uygulanacak en uygun trafik sinyali fazını belirlemek için derin bir sinir ağı mimarisinden yararlanmaktadır. Seçilen eylem trafik sinyallerini kontrol ederek yürütülmekte ve araç akışını doğrudan etkilemektedir. Model performansını artırmak için ödül fonksiyonunu ve güncellenen çevresel durumu sürekli olarak değerlendiren bir geri bildirim döngüsü entegre edilmiştir. Bu yinelemeli mekanizma, dinamik trafik kontrolü için karar verme stratejisini en iyilerken aynı zamanda keşif-sömürü dengesini sağlayarak öğrenme sürecini iyileştirmektedir.




Şekil 3.20. DQL Modeli

Şekil 3.21, belirli bir anda dört yönlü bir kavşaktaki gerçek zamanlı trafik koşullarını gösterir. Şeritler, her biri yolun belirli bir bölümünü temsil eden hücresel alanlara bölünmüştür. Araçlar bu hücreleri doldurarak konumlarını belirli bir zaman dilimi içinde görselleştirmektedir. Merkezi kavşak, düz hareketler, sola dönüşler ve sağa dönüşler dahil olmak üzere çeşitli yönlerde trafik akışlarını yönlendirir. Şeritlerdeki renkli işaretler belirli trafik eylemlerini ve şerit kullanımını belirtmektedir. Kavşağı çevreleyen yeşil bölgeler, yol kenarını ve çevresel altyapıyı sembolize etmektedir. Trafik koşullarının bu anlık görüntüsü, trafik sıkışıklığını ve akışını değerlendirmek için kullanılır ve karmaşık trafik yönetim sistemlerinde sinyal fazı ayarlamalarını en iyilemek için temel veriler sunmaktadır.

Çizelge 3.14, dört yönlü kavşağa ait 6x7 boyutundaki durum matrisini göstermektedir. Bu matris, her bir yön için araçların hücresel temsiline dayalı durumunu ifade etmektedir. Her satır belirli bir trafik hareketini (örneğin, sola veya sağa dönüş, düz ilerleme) temsil ederken, sütunlar bu yönlerdeki hücrelerin durumlarını göstermektedir. Hücre değerleri, ilgili hücrede bir aracın bulunup bulunmadığını ifade eder; 1 sayısı araç varlığını, 0 sayısı ise hücrenin boş olduğunu belirtmektedir.

- WL (West Left): Batı yönünden gelen ve sola dönüş yapan araçların bulunduğu şerit hücrelerini temsil etmektedir.
- WR (West Right): Batı yönünden gelen ve sağa dönüş yapan veya düz devam eden araçların bulunduğu şerit hücrelerini ifade etmektedir.
- S (South): Güney yönünden gelen ve ileri hareket eden araçların konumunu göstermektedir.
- EL (East Left): Doğu yönünden gelen ve sola dönüş yapan araçların bulunduğu şerit hücrelerini temsil etmektedir.
- ER (East Right): Doğu yönünden gelen ve sağa dönüş yapan veya düz devam eden araçların bulunduğu şerit hücrelerini ifade etmektedir.
- N (North): Kuzey yönünden gelen araçların konumunu göstermektedir.

Bu matris, kavşaktaki trafik yoğunluğunu ve akışını analiz etmek için kullanılmakta olup, derin takviyeli öğrenme algoritmaları için temel girdi olarak hizmet vermektedir. Matris, trafik ışıklarının fazlarını en iyilemede ve kavşaklarda bekleme süresini azaltmada kritik bir araçtır.




Şekil 3.21. Durum matrisinin yollar üzerinde konumlanmış görüntüsü

Çizelge 3.14. Durum matrisinin karşılık geldiği yönler ile gösterimi

Mesafe	40 m	20 m	12 m	7 m	7 m	7 m	7 m
WL	0	0	0	0	0	0	1
WR	0	0	1	1	1	1	1
S	0	0	0	0	0	1	0
EL	0	0	0	0	0	1	0
ER	0	0	1	0	1	1	0
N	0	0	0	0	0	0	1

Şekil 3.22, dört yönlü bir kavşakta trafik ışığı fazlarının ardışık 20 adım boyunca nasıl değiştiğini görselleştirmektedir. Her bir kare, belirli bir adımda kavşak üzerindeki trafik akışını ve trafik ışıklarının durumunu göstermektedir. Kırmızı, sarı, yeşil ve kırmızı-sarı (SUMO çıktısında turuncu olarak gösterilmektedir) ışıklar, araçların durması, hazırlık yapması, hareket etmesi, yavaşlayarak durması gereken durumları temsil etmektedir. Burada Adım 1 (birinci faz), Adım 5 (ikinci faz), Adım 9 (üçüncü faz), Adım 13 (dördüncü faz), Adım 17 (beşinci faz) fazları temsil etmekte olup sinyalize kavşak 5 fazlı modda çalışmaktadır. Diğer adımlar koruma sürelerini temsil etmekte olup kırmızı-sarı durum Antalya özelinde sinyalize kavşaklarda fazlar arasındaki bir koruma süresidir.



Şekil 3.22. Trafik ışığı fazları

Çizelge 3.15, trafik yönetim sistemi için kullanılan derin takviyeli öğrenme algoritmasının eğitim sürecine ait temel parametreleri göstermektedir. Bu parametreler, DQL modelinin verimli bir şekilde eğitilmesini sağlayarak, trafik akışını etkili bir şekilde yönetmek için en uygun sinyal fazı kararlarını öğrenmesine olanak tanımıştır.

Çizelge 3.15. Eğitim parametreleri

Parametreler	Değerler
Öğrenme Oranı	0.001
Gamma	0.99
Yığın Boyutu	64
En Çok Adım Sayısı	10,000
Epsilon Azalma Oranı	0.995
Bölüm	100 (3600 s)
Sarı Işık Süresi	2
Kırmızı Işık Süresi	3
Kırmızı-Sarı Işık Süresi	2

3.5. Benzetimlerde Kullanılan Trafik Parametreleri

Trafik akışının etkin bir şekilde değerlendirilmesi için, benzetim süresince elde edilen farklı trafik parametreleri analiz edilmiştir. Bu parametreler, trafik yoğunluğu, gecikme süreleri, hız profilleri ve çevresel etkiler gibi çeşitli metrikleri kapsamaktadır. Her bir parametrenin hesaplanma yöntemi ve anlamı aşağıda detaylandırılmıştır:

Ortalama Kuyruk Uzunluğu (Araç): Benzetim boyunca her adımda kuyrukta bekleyen araç sayısının ortalaması alınarak hesaplanmaktadır. Bu parametre, kavşaklardaki trafik sıkışıklığını değerlendirmek ve akıcılığı ölçmek için kullanılmaktadır. Kuyruk uzunluğunun azalması, trafik akışının iyileştiğini göstermektedir.

Toplam Bekleme Süresi: Her araç için trafik ışıklarında veya sıkışıklık nedeniyle harcanan toplam bekleme süresini ifade etmektedir. Araçlar durduğunda bu süre artmakta olup, benzetim boyunca tüm araçlar için bu değerlerin toplamı alınmıştır.

Ortalama Gecikme Süresi (s): Her araç için varış süresi ile ideal varış süresi arasındaki farkın ortalaması alınarak hesaplanmaktadır. Bu metrik, trafiğin akıcı olup olmadığını ve sistemin taşıt hareketlerini ne kadar etkili bir şekilde yönlendirdiğini

ölçmek için kritik bir parametre olarak kullanılmaktadır.

Ortalama Hız (km/sa): Benzetim boyunca, her adımda mevcut araçların hızlarının ortalaması alınarak hesaplanmaktadır. Bu değer, trafiğin akıcılığı ve sıkışıklığının etkisi hakkında bilgi vermektedir. Yüksek ortalama hız değerleri, daha iyi trafik akışını ifade etmektedir.

Ortalama Karbon Emisyonu (g): Benzetimdeki araçlardan kaynaklanan karbon emisyonlarının ortalaması alınarak hesaplanmaktadır. Bu parametre, trafik yoğunluğunun çevresel etkilerini ölçmek için kullanılmaktadır. Daha düşük değerler, daha çevre dostu bir trafik sistemi anlamına gelmektedir.

Ortalama Yakıt Tüketimi (L): Her araç için tüketilen yakıt miktarlarının ortalaması alınarak hesaplanmaktadır. Bu metrik, trafik yönetiminin enerji verimliliği üzerindeki etkisini değerlendirmek için kullanılmaktadır. Düşük yakıt tüketimi, enerji tasarrufunu ve sürdürülebilirliği işaret etmektedir.

Hizmet Seviyesi (LOS): Trafik akışının kalitesini ve sistemin verimliliğini değerlendirmek için kullanılan bir ölçüt olarak hizmet seviyesi belirlenmektedir. Bu parametre, hız, gecikme ve kuyruk uzunluğu gibi değerlerin birleşiminden elde edilen trafik akış kalitesini ifade etmektedir. Yüksek hizmet seviyesi, sistemin kullanıcılar için daha etkili ve tatmin edici olduğunu göstermektedir.

3.6. Benzetim Kalibrasyon ve Doğrulama Çalışmaları

Heybe Kavşağı, Türkay Kavşağı, Işıktepe Kavşağı benzetim modellerinin geliştirilmesi sırasında çeşitli parametreler (yol genişliği, yol kapasitesi, şerit sayısı, dönüş şeritleri, hız sınırları, yol eğimi, sinyal süreleri ve faz planı vb.) dikkate alınarak detaylı modelleme süreçleri yürütülmüştür.

Araç hareketlerinin gerçekçi bir şekilde benzetim programında çalıştırılması için trafik kontrol merkezinden alınan görüntüler üzerinde yapılan gözlemler yoluyla sürücülere ilişkin agresiflik düzeyleri, tepki süreleri ve şerit değiştirme eğilimleri gibi davranışsal parametreler elde edilmiştir. Böylece kavşaklardaki akış yönleri ve trafik yoğunlukları gözlemlenerek toplanan veriler, model parametrelerinin doğruluğunu artırmak için kullanılmıştır.

Ulaştırma mühendisliği çalışmalarında, kalibrasyon, trafik akışını analiz etmek, yol ağı performansını değerlendirmek ve altyapı tasarlamak için kullanılan benzetim modellerinin doğruluğunu ve güvenilirliğini önemli ölçüde etkileyen kritik bir süreçtir (Park ve Qi 2005). Kalibrasyon sonrası doğrulama için yaygın olarak kullanılan tekniklerden biri GEH (Geoffrey E. Havers) kriteridir; bu kriter, gözlemlenen veriler ile benzetim sonuçları arasındaki uyumu değerlendirmek için istatistiksel bir ölçüt sunar (An vd. 2022). Bu kriter, araştırmacıların model parametrelerini gerçek dünya koşullarıyla daha iyi uyum sağlayacak şekilde ayarlamalarına yardımcı olur.

Mikroskobik benzetimden doğru sonuçlar elde etmek için, bu çalışmada Denklem 3.44'te sunulan GEH istatistiksel testi kullanılmıştır.

$$GEH = \sqrt{\frac{2(E - V)^2}{E + V}} \quad (3.44)$$

Burada E, benzetim modelinden elde edilen tahmini saatlik trafik hacmini, V ise gerçek dünyada gözlemlenen gerçek saatlik trafik sayımını temsil etmektedir. GEH değeri beşin altında ise, bu durum modelin gerçek hayattaki trafik davranışını doğru bir şekilde temsil ettiğini gösterir (Li ve Ranjitkar 2015).

3.7. Yaşam Döngüsü Değerlendirmesi

Dünya Sağlık Örgütü iklim değişikliğini 21. yüzyılda küresel sağlığa yönelik en büyük tehdit olarak nitelendirmektedir (Pachauri vd. 2014). İklim değişikliğine neden olan ve atmosferdeki doğal dengeyi bozan ana faktör sera gazı emisyonlarıdır (European Commission 2023). Bu bağlamda Birleşmiş Milletler İklim Değişikliği Çerçeve Sözleşmesi kapsamında Türkiye'nin de aralarında bulunduğu 175 ülke Paris Anlaşması'nı imzalamıştır (T.C. Çevre Şehircilik ve İklim Değişikliği Bakanlığı 2016). Bu anlaşmanın temel amacı emisyon azaltımıdır (Akgül 2021).

Avrupa Birliği'nin toplam sera gazı emisyonlarının yaklaşık %25'i ulaşım sektöründen kaynaklanmaktadır. Türkiye İstatistik Kurumu (TÜİK) sera gazı envanter verilerine göre ise 2016 yılında Türkiye'nin toplam sera gazı emisyonu CO₂ eşdeğeri olarak 496.1 milyon ton olarak hesaplanmış olup bu miktarın 81.8 milyon tonu ulaşım kaynaklanmıştır (Dönmezçelik vd. 2023). Bu noktada, ulaşım sektörünün iklim değişikliğine etkisine de odaklanarak sera gazı emisyonlarını azaltacak politika ve teknolojilerin geliştirilmesi amacıyla Türkiye Cumhuriyeti Cumhurbaşkanlığı tarafından Türkiye'nin 2053 Net Sıfır Emisyon Hedefi doğrultusunda "İklim Değişikliği Başkanlığı Uzun Dönemli İklim Değişikliği Stratejisi ve Eylem Planları" belirlenmiştir (T.C. Çevre Şehircilik ve İklim Değişikliği Bakanlığı 2023a).

Bu hedefler doğrultusunda, ulaştırma sektöründe farklı senaryoların çevresel etkilerini değerlendirmek amacıyla bu çalışmada LCA yöntemi kullanılmıştır. LCA, ISO 14040 ve ISO 14044 standartlarına uygun olarak openLCA 2.0 yazılımı kullanılarak yürütülmüştür (ISO 14040 2006; ISO 14044 2006). Arka plan sistem süreçlerinin modellenmesinde, Avrupa Komisyonu Ortak Araştırma Merkezi tarafından geliştirilen Avrupa Referans Yaşam Döngüsü Veritabanı (ELCD) v3.2 sürümü kullanılmıştır. ELCD veritabanı, yakıtlarla ilgili enerji temelli Yaşam Döngüsü Envanteri (LCI) verilerini içermesi nedeniyle tercih edilmiştir (Fazio vd. 2015). LCA uygulamasında ulaşım ağındaki trafik akışı göz önüne alınarak fonksiyonel birim bir saat olarak seçilmiştir. Ayrıca sinyalizasyon senaryolarının çevresel iyileştirme etkilerini ortaya koymak amacıyla, kapıdan-kapıya yaklaşımı uygulanmıştır. Bu doğrultuda sistem sınırları ilk kavşağın girişi ile ikinci kavşağın çıkışı olarak seçilmiştir.

3.7.1. Yaşam Döngüsü Envanteri

SUMO ile yürütülen benzetim çalışmalarında emisyonlar SUMO'ya entegre edilmiş Karayolu Taşımacılığı için El Kitabı Emisyon Faktörleri (HBEFA) versiyon 4.2 emisyon modeline göre hesaplanmakta olup, bu hesaplamalarda araç tipi SUMO tarafından varsayılan olarak tanımlanan Avrupa emisyon standardına (EURO sınıfı) göre Euro 4 sınıfı benzinli araç olarak tanımlanmıştır. SUMO HBEFA verilerini araç

motorunun sürüş direnç kuvvetini yenmek için üretmesi gereken gücün fonksiyonunu basitleştirerek elde edilen sürekli bir fonksiyona uydurularak emisyonları tahmin etmektedir (Krajewicz vd. 2015). Basitleştirilmiş fonksiyon Denklem 3.45'te görüldüğü gibi tanımlanmıştır.

$$c_0 + c_1va + c_2va^2 + c_3v + c_4v^2 + c_5v^3 \quad (3.45)$$

Burada v anlık araç hızını (m/s) ve a anlık ivmeyi (m/s²) ifade etmektedir. Ayrıca c_0 - c_5 katsayıları, SUMO içinde HBEFA v4.2.'den elde edilen yakıt, standartlara ve teknolojiye bağlı doğrusal parametrelerdir. Tüm emisyon tipleri için aynı şekilde emisyonlar hesaplanmıştır.

Yürütülen benzetim çalışmaları sonucunda referans durum ve senaryolar için toplam CO₂, CO, HC, NO_x, PM emisyonları ile yakıt tüketimleri benzetim çıktısı olarak elde edilmiştir. Elde edilen veriler 1000 araç için düzeltilmiştir. CO emisyonları dolaylı sera gazı emisyonları olarak değerlendirildiği (Jaramillo vd. 2022) için CO₂ eşdeğerine çevrilmiştir. HBEFA 4.2'ye göre, HC emisyonları; metan (CH₄), BTEX (benzen, toluen, etilbenzen, ksilen) ve metan dışı hidrokarbonlardan (NMHC) oluştuğu belirtilmektedir. HBEFA 4.1 kapsamında, Euro 4 sınıfı benzinli araçlar için hidrokarbon bileşenlerinin %40'ının CH₄, %1'inin benzen, %1.3'ünün toluen ve %1.3'ünün ksilen olduğu kabul edilmektedir (Notter vd. 2019). Bu doğrultuda, SUMO ile yürütülen benzetimler ile elde edilen toplam hidrokarbon bileşenleri önerildiği gibi hesaplanmıştır. Bu bileşenler dışında kalan kısım ise NMHC olarak tanımlanmakta olup, LCA çalışmalarında bu kısım, daha önce yürütülen çalışmalarda önerildiği gibi (Alshayeb vd. 2022) Metan İçermeyen Uçucu Organik Bileşikler (NMVOC) ile eşdeğer kabul edilmiştir. Benzetim sonucu elde edilen PM miktarı PM_{2.5} ve PM₁₀'dan oluşmaktadır. Ancak, bu bileşenlerin miktarı belirli olmadığı için bu çalışma kapsamında tüm PM'in PM_{2.5} olduğu kabul edilmiştir. SUMO ile elde edilen emisyon miktarları, yukarıda belirtilen düzenlemeler doğrultusunda elementer akış kategorisinde, havaya salınan emisyonlar başlığı altındaki çıktı bileşenleri olarak tanımlanmıştır (Çizelge 3.16). SUMO benzetim çalışmasının bir diğer çıktısı olan yakıt tüketimi ise sistem girdisi olarak değerlendirilmiş; bu girdiye karşılık gelen arka plan verisi olarak ELCD 3.0 veritabanında yer alan "Gasoline mix (regular) at refinery" süreci seçilmiştir.

Çizelge 3.16. LCI verilerinin oluşturulmasında kullanılan girdiler ve çıktılar

	Senaryo 2 (Referans Durum)	Senaryo 3	Senaryo 1
Girdiler			
Fonksiyonel birim	1 saat		
Yakıt tüketimi (kg)	1354.64	1296.48	1250.01
Çıktılar (Havaya Salınan Emisyonlar)			
Benzen (g)	9.21	8.49	7.81
Karbon dioksit (CO ₂) (kg)	4529.61	4324.09	4156.02
Metan (CH ₄) (g)	368.27	339.70	312.49
Azot oksitler (NO _x) (g)	1887.06	1801.05	1733.29
Metan içermeyen uçucu organik bileşikler (NMVOC) (g)	519.26	478.97	440.61
PM _{2.5} (g)	101.84	97.02	93.58
Toluen (g)	11.97	11.04	10.16
Ksilen (g)	11.97	11.04	10.16

3.7.2. Yaşam Döngüsü Etki Değerlendirmesi

Yaşam Döngüsü Etki Değerlendirmesi (LCIA) ara nokta ve uç nokta yöntemlerini kullanmaktadır. Ara nokta yönteminde nihai zararlar hesaplamadan neden-sonuç zincirinin ortasında yer alan etki kategorilerine göre değerlendirme yapılmaktadır. Uç nokta yönteminde ise çevresel etkiler değerlendirilirken ara nokta etki kategorileri insan sağlığı, ekosistem kalitesi ve kaynak tüketimi gibi kategorilere dönüştürülmektedir (Patel 2022).

ReCiPe yöntemi ara nokta (sorun odaklı) yaklaşımı ile uç nokta (zarar odaklı) yaklaşımının birleştirilmesiyle oluşturulmuştur (Goedkoop vd. 2013). ReCiPe yöntemi neden-sonuç yollarının uyumlu biçimde uygulanmasına olanak tanıyan ve en yaygın kullanılan yöntemlerden biridir (Huijbregts vd. 2017). Bu yöntem, çok sayıda çevresel etki kategorisini kapsayan göstergeleri içermektedir.

ReCiPe yöntemi, 18 adet ara nokta kategorisinden oluşmaktadır. Bunlar; küresel ısınma, stratosferik ozon incelmeleri, iyonlaştırıcı radyasyon, ozon oluşumu/insan sağlığı, ince partikül madde oluşumu, ozon oluşumu/karasal ekosistemler, karasal asidifikasyon, tatlı su ötrofikasyonu, denizel ötrofikasyon, karasal ekotoksitesite, tatlı su ekotoksitesitesi, denizel ekotoksitesite, insan kanserojen toksisitesi, insan kanserojen olmayan toksisite, arazi kullanımı, mineral kaynak kıtlığı, fosil kaynak kıtlığı ve su tüketimidir. Uç nokta

kategorileri ise insan sađlığı, ekosistem kalitesi ve kaynak tükenmesi başlıklarını kapsamaktadır. Bu uç nokta etkileri, ilgili ara nokta kategorileri ile zarar faktörlerinin çarpılması yoluyla hesaplanmaktadır.

Ara nokta karakterizasyonu genellikle parametre belirsizliđi daha düşük olan sonuçlar üretmektedir. Öte yandan, uç nokta karakterizasyonu, çevresel etkilerin yorumlanması açısından daha anlaşılır sonuçlar sağlamaktadır. İnsan sađlığı üzerindeki etkiler hastalık ya da ölüm ile sonuçlanan sađlık etkilerini ve kaybedilen yaşam yıllarını yansıtmaktadır. Ekosistem kalitesi, karasal, tatlı su ve denizel ekosistemlerde belirli bir zaman ve mekânda meydana gelen tür kaybını temsil etmektedir. Kaynak tükenmesi ise gelecekteki mineral ve fosil kaynakların çıkarılmasıyla ilişkili ilave maliyetleri ifade etmektedir (Goedkoop vd. 2013). Uç nokta yöntemi nihai çevresel etkilerin daha iyi anlaşılmasına ve değerlendirilmesine olanak tanıdığından daha avantajlı bulunmakta ve literatürde sıklıkla tercih edilmektedir (Bare vd. 2000; Ding vd. 2021).

ReCiPe yönteminde, varsayımlar ve tercihlerdeki farklılıkları gruplamak amacıyla üç farklı bakış açısı uygulanmaktadır: bireyci (I), hiyerarşik (H) ve eşitlikçi (E). Bu çalışmada, 100 yıllık kabul edilebilir zaman çerçevesine sahip ve literatürde bilimsel bakış açısı olarak yaygın biçimde kullanılan hiyerarşik (H) yaklaşım tercih edilmiştir. Sinyalizasyon yaklaşımlarının çevresel etkilerini değerlendirmek amacıyla, ReCiPe uç nokta (H) yöntemi ile yaşam döngüsü etkileri hesaplanmış; farklı senaryoların GWP'lerdeki değişimi değerlendirmek için ise ara nokta (H) yöntemi kullanılmıştır.



4. BULGULAR VE TARTIŞMA

Ulaşım sistemlerinin en iyilemesinde kritik bir rol oynayan veri analizi, bu çalışmanın odak noktasını oluşturmaktadır. Bu nedenle, kullanılan veri setleri ve bunların akıllı kavşak bilgileriyle olan ilişkisi bu bölümde ayrıntılı biçimde ele alınmıştır.

Trafik akışını modellemeye yönelik olarak trafik hacmi tahmin çalışmaları gerçekleştirilmiştir. Bu kapsamda, en yoğun istikamete ait araç sayım verileri PCU cinsine dönüştürülmüş ve ardından veri ön işleme, özellik seçimi, aykırılık analizi ve modelleme olmak üzere dört aşamalı bir yöntem uygulanmıştır.

4.1. Heybe Kavşağı Veri Seti

Atatürk Bulvarı ile 353. Sokak kesişiminde yer alan sinyalize kavşağa ait araç sayım verileri, 3 Şubat 2023 ile 18 Temmuz 2023 tarihleri arasında, toplam 165 günlük bir süreyi kapsamaktadır. Bu veriler, Antalya Trafik Kontrol Merkezi tarafından temin edilmiştir.


Analiz için kullanılan veri seti, kavşağa 5 saniye aralıklarla gelen araç sınıflarının (otomobil, motosiklet, minibüs ve kamyon) sayılarını içermektedir. Bu kapsamlı veri seti, toplamda 703.514 satırdan oluşmaktadır. Veri setinin detaylı analizi, araç sınıflarının trafik akışına etkisini anlamak ve kavşak performansını değerlendirmek amacıyla gerçekleştirilmiştir.

Çizelge 4.1’de Heybe Kavşağına ait oto sinyal verici grupları, geliş kolları ile yön bazlı eşleştirilmiştir.


Çizelge 4.1. Kavşak kontrol cihazına ait kimlik bilgileri ile yön isimlerinin eşleştirilmesi

ID	KkcId	Yön İsimleri
37887	9703	R1-Q6/Q8-Merkez Geliş
37888	9703	R2-Q10-Kuzey Geliş
37889	9703	R3-Q5/Q7-Kemer Geliş
37890	9703	R4-Q9-Sahil Geliş


Heybe Kavşağına ait trafik hacmi ve araç sınıflarına yönelik veriler analiz edilmiştir. Şekil 4.1’de görüldüğü üzere otomobil sınıfı araçlar en yüksek orana sahipken, motosiklet sınıfındaki araçların da dikkate değer bir yoğunlukta olduğu gözlemlenmiştir. Bu durum, trafik akışının araç sınıfları açısından çeşitlilik gösterdiğini ve kavşağın farklı araç türleri açısından yoğun bir geçiş noktası olduğunu ortaya koymaktadır.



(a)



(b)




(c)

Şekil 4.1. Heybe Kavşağı trafik hacim verileri **a)** geliş istikameti; **b)** gidiş istikameti; **c)** dönüş istikameti

Analiz sonuçlarına göre, Merkez İstikameti (Yön 1) ve Kemer İstikameti (Yön 3) ana arterlerinden gelen araçların, diğer yönlere kıyasla daha fazla olduğu tespit edilmiştir. Dolayısıyla, trafik yoğunluğunun ağırlıklı olarak bu kollarda yaşandığı anlaşılmaktadır. Trafik hacim verilerinin büyüklük sırasına göre sıralaması büyükten küçüğe doğru şu şekilde gerçekleşmiştir: Yön 1 (ID 37887), Yön 3 (ID 37889), Yön 2 (ID 37890) ve Yön 4 (ID 37888). Ayrıca, motosiklet sınıfındaki araçların genellikle ana arterlerden kavşağa giriş yaptığı ve çoğunlukla karşı istikametinde bulunan ana aks üzerinden kavşaktan ayrıldığı gözlemlenmiştir.


Şekil 4.2’de Heybe Kavşağı için güzergahlara göre gözlem sayılarının dağılımı gösterilmektedir. Grafik, veri setinde farklı güzergahlardan toplanan gözlem sayısını temsil etmektedir. Bazı güzergahlarda gözlem sayısının diğerlerine göre belirgin şekilde düşük olduğu görülmektedir. Bu durum, belirli güzergahlarda veri toplama yoğunluğunun veya sıklığının daha az olduğunu göstermekte olup, güzergahlar arasında veri setindeki temsiliyet farklılıklarını ortaya koymaktadır.




Şekil 4.2. Atatürk Bulvarı-17. Cadde kesişimindeki akıllı kavşak geliş ve gidiş istikametine göre trafik hacim verileri

4.1.1. Heybe Kavşağı 37887-37889 istikameti farklı zaman dilimlerine göre trafik hacimleri


Bu bölümde, 37887-37889 güzergahına ait trafik hacim verileri analiz edilmiştir. Veri seti, belirli bir zaman dilimi boyunca toplanan 5 dakikalık gözlemlerden oluşmaktadır. Şekil 4.3'te, farklı zaman dilimlerinde (15 dakika, saatlik, günlük, haftalık ve aylık) araç sınıflarına göre trafik akışındaki değişimler gösterilmektedir. Otomobil sınıfı araçlar, tüm zaman dilimlerinde en yoğun araç türü olarak dikkat çekerken, motosiklet ve diğer araç türlerinin hacmi nispeten daha düşük seviyelerde seyretmektedir. Zaman içinde araç geçişlerindeki dalgalanmalar, özellikle günün belirli saatlerinde trafik yoğunluğunun arttığını göstermektedir.




(a)




(b)



(c)




(d)



(e)


Şekil 4.3. Heybe Kavşağı 37887-37889 güzergahı araç sayımları a) 15 dakikalık; b) saatlik; c) günlük; d) haftalık; e) aylık

Şekil 4.4'te, her bir araç sınıfının trafik hacmine yaptığı katkı ve toplam trafik yoğunluğu PCU cinsinden gösterilmiştir. Bu dönüşüm, özellikle farklı araç türlerinin (otomobil, motosiklet, ticari araçlar) trafik üzerindeki etkisini daha anlaşılır ve karşılaştırılabilir hale getirmektedir. Otomobiller, tüm araç sınıfları arasında trafik hacmine en büyük katkıyı sağlarken, motosikletler ve diğer ticari araçlar daha düşük oranlarda katkıda bulunmuştur.



Şekil 4.4. Heybe Kavşağı 37887-37889 güzergahındaki araç sınıflarına göre PCU cinsinden trafik hacim dağılımı

Trafik verileri arasındaki ilişkiler, korelasyon matrisi yardımıyla değerlendirilmiştir. Şekil 4.5'te yer alan korelasyon matrisi, araç sınıflarının birbirleriyle ve toplam araç sayısı ile olan ilişki derecelerini görselleştirmektedir. Özellikle otomobil ve motosiklet sınıfının toplam trafik hacmiyle yüksek oranda pozitif korelasyona sahip olduğu, tır sınıfının ise diğer araç türlerine göre daha düşük bir korelasyon gösterdiği tespit edilmiştir. Bu sonuçlar, güzergah üzerindeki araç sınıfı dağılımının trafik yoğunluğu üzerindeki etkilerini anlamada önemli bir rehber oluşturmaktadır.




Şekil 4.5. Heybe Kavşağı 37887-37889 güzergahına ait araç sınıflarının korelasyon matrisi


4.1.2. Heybe Kavşağı 37887-37889 istikameti aykırılık analizi ve temizleme yöntemlerinin karşılaştırılması

Trafik verilerinde aykırılık tespiti ve temizleme, model performansını ve analiz sonuçlarının güvenilirliğini artırmak için önemli bir adımdır. Bu bölümde, 37887-37889 güzergahına ait veri seti üzerinde Z-Score, Mahalanobis Mesafesi ve PCA yöntemleri aykırılık tespit etmek amacıyla uygulanmıştır.


Şekil 4.6’da her bir aykırılık tespit yöntemi ile belirlenen aykırılıklar görselleştirilmiştir. Z-Score yöntemiyle 133, Mahalanobis Mesafesiyle 251 ve PCA yöntemiyle 179 aykırılık tespit edilmiştir.



(a)




(b)




(c)

Şekil 4.6. Heybe Kavşağı 37887-37889 güzergahı aykırılık tespit yöntemleri **a)** Z-Skoru; **b)** Mahalanobis mesafesiyle; **c)** PCA


Veri setinden aykırı değerler çıkarıldıktan sonra temizlenmiş veri setleri üzerinde çeşitli makine öğrenimi modelleri eğitilmiş ve performans metrikleri karşılaştırılmıştır. Şekil 4.7’de Mahalanobis, Şekil 4.8’de PCA ve 4.9’da Z-Score yöntemlerine göre modellenmiş verilerin performans metrikleri sunulmuştur.



(a)




(b)




(c)


Şekil 4.7. Mahalanobis modeli performans karşılaştırması a) MSE; b) MAE; c) R^2



(a)




(b)




(c)


Şekil 4.8. PCA modeli performans karşılaştırması **a)** MSE; **b)** MAE; **c)** R^2



(a)



(b)



(c)

Şekil 4.9. Z-Score modeli performans karşılaştırması a) MSE; b) MAE; c) R^2


Çizelge 4.2’de sırasıyla Z-Score, Mahalanobis ve PCA yöntemlerine ait performans metrikleri (MSE, MAE, R^2) özetlenmiştir. Mahalanobis yöntemi ile temizlenen veri seti, yüksek R^2 değeri ve düşük hata oranlarıyla en iyi performansı göstermiştir. Bununla birlikte, PCA yöntemi dengeli bir performans sergilerken, Z-Score yöntemi belirli modellerde üstünlük sağlamıştır.

Çizelge 4.2. Aykırılık tespit yöntemlerinin performans metrikleri bakımından karşılaştırılması


Model	MSE			MAE			R ²		
Doğrusal Regresyon	953.109	923.961	948.020	25.310	25.187	25.327	0.389	0.414	0.396
Karar Ağaçları	443.268	421.275	430.409	15.672	15.273	15.559	0.716	0.733	0.726
KNN	572.813	534.897	498.353	17.812	17.014	16.167	0.675	0.661	0.683
MLP	463.594	446.051	452.867	16.079	15.656	16.126	0.703	0.717	0.711
Rastgele Orman	443.255	421.273	430.372	15.672	15.272	15.559	0.716	0.733	0.726
Gradyan Artırma	443.278	421.233	430.357	15.673	15.273	15.559	0.716	0.733	0.726
Elastic Net	953.106	924.023	948.051	25.313	25.191	25.321	0.389	0.414	0.396
AdaBoost	478.180	475.431	467.232	16.685	16.671	16.685	0.694	0.699	0.702
Bagging	443.138	421.194	430.433	15.649	15.274	15.565	0.716	0.733	0.726
Voting	566.920	544.926	559.612	18.841	18.590	18.806	0.637	0.655	0.643
Stacking	443.255	421.224	430.415	15.672	15.273	15.561	0.716	0.733	0.726

4.1.3. Heybe Kavşağı 37887-37889 istikameti aykırılık analizi sonrası derin öğrenme modellerinin eğitimi

Trafik verilerinin işlenmesi ve aykırılık analizinin ardından, Heybe Kavşağı 37887-37889 istikametine ait veri seti sekiz farklı derin öğrenme modeli (LSTM, BiLSTM, GRU, LSTM+CNN, RNN, Dikkat Mekanizması Tabanlı LSTM, Yığınlanmış LSTM ve LSTM+GRU) ile eğitilmiştir. Aykırılıklardan arındırılmış bileşenlerle oluşturulan bu veri seti, modellerin performanslarını değerlendirmek amacıyla analiz edilmiştir. Modellerin çıktıları aşağıda görselleştirmelerle birlikte sunulmuş olup, tahmin grafiklerinde mavi çizgi gerçek değerleri, turuncu çizgi ise model tarafından üretilen tahminleri göstermektedir. Kayıp grafiklerinde ise mavi çizgi eğitim kaybını, turuncu çizgi doğrulama kaybını temsil etmektedir. Bu görselleştirmeler, modellerin hem tahmin doğruluğunu hem de eğitim sürecindeki öğrenme davranışlarını değerlendirmek amacıyla kullanılmıştır.



(a)




(b)

Şekil 4.10. Heybe Kavşağı 37887-37889 istikameti (aykırılıklardan arındırılmış veri) için (a) LSTM modeli; (b) doğrulama grafiği


Şekil 4.10’da Heybe Kavşağı 37887-37889 istikameti (aykırılıklardan arındırılmış veri) için LSTM modeline ait çıktılar gösterilmiştir:

- Şekil 4.10(a) tahmin grafiğinde görüldüğü üzere LSTM modeli, gerçek değerlerle tahmin değerlerini genel eğilim açısından başarılı şekilde yakalamış ve özellikle periyodik trafik dalgalanmalarını temsil edebilmiştir. Bununla birlikte, ani pik değerlerinde sapmalar görülmüş, model bu değerleri tam olarak yansıtmakta sınırlı kalmıştır.

- Şekil 4.10(b) doğrulama grafiğinde modelin eğitim ve doğrulama kayıpları karşılaştırılmıştır. Eğitim kaybı düzenli biçimde azalırken doğrulama kaybında belirli seviyelerde dalgalanmalar gözlenmiştir. Bu durum, modelin genelleme kapasitesinin sınırlı olduğunu ve kısmi aşırı öğrenme eğilimi gösterdiğini ortaya koymaktadır.



(a)




(b)


Şekil 4.11. Heybe Kavşağı 37887-37889 istikameti (aykırılıklardan arındırılmış veri) için (a) BiLSTM modeli; (b) doğrulama grafiği

Şekil 4.11’de Heybe Kavşağı 37887-37889 istikameti (aykırılıklardan arındırılmış veri) için BiLSTM modeline ait çıktılar gösterilmiştir:

- Şekil 4.11(a) tahmin grafiğinde görüldüğü üzere BiLSTM modeli, gerçek değerlerle tahmin değerlerini genel eğilim açısından başarılı şekilde yakalamış ve özellikle trafik akışındaki periyodik dalgalanmaları etkili biçimde temsil edebilmiştir. Ancak yüksek pik değerlerinde sapmalar gözlenmiş, modelin ani trafik yoğunluklarını tam olarak yansıtmakta sınırlı kaldığı belirlenmiştir.
- Şekil 4.11(b) doğrulama grafiğinde eğitim ve doğrulama kayıpları karşılaştırılmıştır. Eğitim kaybı düzenli bir azalış göstermiştir, ancak doğrulama kaybında belirgin dalgalanmalar bulunmuştur. Bu durum, modelin genelleme kapasitesinin sınırlı olduğunu ve aşırı öğrenmeye kısmi eğilim gösterdiğini ortaya koymaktadır.



(a)




(b)


Şekil 4.12. Heybe Kavşağı 37887-37889 istikameti (aykırılıklardan arındırılmış veri) için (a) GRU modeli; (b) doğrulama grafiği

Şekil 4.12’de Heybe Kavşağı 37887-37889 istikameti (aykırılıklardan arındırılmış veri) için GRU modeline ait çıktılar gösterilmiştir:

- Şekil 4.12(a) tahmin grafiğinde görüldüğü üzere GRU modeli, trafik akışındaki periyodik dalgalanmaları başarılı şekilde öğrenmiş ve tahmin değerleri ile gerçek değerler arasında yüksek düzeyde uyum sağlamıştır. Özellikle orta yoğunluk seviyelerinde tahminlerin oldukça isabetli olduğu, ancak yüksek pik değerlerinde kısmi sapmaların bulunduğu görülmektedir.
- Şekil 4.12(b) doğrulama grafiğinde eğitim kaybının düzenli olarak azaldığı, doğrulama kaybının ise zamanla dengelenerek kararlı bir eğriye oturduğu gözlemlenmektedir. Bu durum, GRU modelinin aşırı öğrenme eğilimi göstermeden dengeli bir genelleme performansı sunduğunu ortaya koymaktadır.



(a)



(b)


Şekil 4.13. Heybe Kavşağı 37887-37889 istikameti (aykırılıklardan arındırılmış veri) için **(a)** LSTM + CNN modeli; **(b)** doğrulama grafiği

Şekil 4.13'te Heybe Kavşağı 37887-37889 istikameti (aykırılıklardan arındırılmış veri) için LSTM + CNN modeline ait çıktılar gösterilmiştir:


- Şekil 4.13(a) tahmin grafiğinde görüldüğü üzere LSTM + CNN modeli, trafik akışındaki periyodik yapıları ve genel eğilimi başarılı bir şekilde yakalamış, tahmin değerleri gerçek değerlere oldukça yakın seyretmiştir. Özellikle orta yoğunluk seviyelerinde modelin tahminleri güçlü bir uyum göstermiştir. Bununla

birlikte, yüksek pik değerlerinde kısmi sapmalar gözlenmiş, bu durum modelin ani artışları tam olarak yakalayamadığını ortaya koymuştur.

- Şekil 4.13(b) doğrulama grafiğinde eğitim ve doğrulama kayıplarının zaman içinde azaldığı ve birbirine yakın seyrettiği görülmektedir. Bu sonuç, modelin dengeli bir öğrenme süreci gerçekleştirdiğini ve genelleme kapasitesinin istikrarlı olduğunu göstermektedir.



(a)




(b)

Şekil 4.14. Heybe Kavşağı 37887-37889 istikameti (aykırılıklardan arındırılmış veri) için (a) RNN modeli; (b) doğrulama grafiği


Şekil 4.14'te Heybe Kavşağı 37887-37889 istikameti (aykırılıklardan arındırılmış

veri) için RNN modeline ait çıktılar gösterilmiştir:

- Şekil 4.14(a) tahmin grafiğinde görüldüğü üzere RNN modeli, trafik akışındaki genel eğilimi kısmen yakalamış; orta yoğunluk seviyelerinde tahminlerle gerçek değerler arasında uyum sağlarken, yüksek pik noktalarında belirgin sapmalar sergilemiştir.
- Şekil 4.14(b) doğrulama grafiğinde eğitim kaybı düzenli biçimde azalırken doğrulama kaybı da genel olarak paralel seyretmiştir. Zaman zaman görülen küçük dalgalanmalar, modelin genelleme kapasitesinin sınırlı ama istikrarlı bir düzeyde olduğunu göstermektedir.



(a)




(b)


Şekil 4.15. Heybe Kavşağı 37887-37889 istikameti (aykırılıklardan arındırılmış veri) için (a) Dikkat Mekanizması Tabanlı LSTM modeli; (b) doğrulama grafiği

Şekil 4.15'te Heybe Kavşağı 37887-37889 istikameti (aykırılıklardan arındırılmış veri) için Dikkat Mekanizması Tabanlı LSTM modeline ait çıktılar gösterilmiştir:

- Şekil 4.15(a) tahmin grafiğinde görüldüğü üzere Dikkat Mekanizması Tabanlı LSTM modeli, trafik akışındaki periyodik eğilimleri ve genel yapıyı başarılı şekilde yakalamıştır. Model, orta yoğunluk seviyelerinde gerçek değerlerle güçlü bir uyum sağlamış; ancak yüksek pik noktalarında kısmi sapmalar gözlenmiştir. Bu durum, modelin ani trafik artışlarını tam anlamıyla yansıtmakta zorlandığını göstermektedir.
- Şekil 4.15(b) doğrulama grafiğinde eğitim ve doğrulama kayıplarının birlikte azaldığı ve birbirine yakın seyrettiği görülmektedir. Bu sonuç, modelin dengeli bir öğrenme süreci geçirdiğini, genelleme kapasitesinin istikrarlı olduğunu ve aşırı öğrenme eğiliminin belirgin olmadığını ortaya koymaktadır.



(a)



(b)


Şekil 4.16. Heybe Kavşağı 37887-37889 istikameti (aykırılıklardan arındırılmış veri) için **(a)** Yığınlanmış LSTM modeli; **(b)** doğrulama grafiği

Şekil 4.16’da Heybe Kavşağı 37887-37889 istikameti (aykırılıklardan arındırılmış veri) için Yığınlanmış LSTM modeline ait çıktılar gösterilmiştir:


- Şekil 4.16(a) tahmin grafiğinde görüldüğü üzere Yığınlanmış LSTM modeli, trafik akışındaki periyodik eğilimleri ve genel yapıyı başarılı bir şekilde yakalamıştır. Tahmin değerleri ile gerçek değerler arasında genel olarak güçlü bir uyum sağlanmış, ancak yüksek trafik yoğunluklarının yaşandığı pik noktalarda

belirgin sapmalar gözlenmiştir. Bu durum, modelin ani değişimlere duyarlılığının sınırlı olduğunu ortaya koymaktadır.

- Şekil 4.16(b) doğrulama grafiğinde eğitim kaybı düzenli bir azalış göstermiş, doğrulama kaybı ise zaman içinde dalgalanmalarla birlikte görece sabit bir düzeye oturmuştur. Bu tablo, modelin genelleme kapasitesinin makul seviyede olduğunu ve aşırı öğrenme eğiliminin sınırlı kaldığını göstermektedir.



(a)



(b)

Şekil 4.17. Heybe Kavşağı 37887-37889 istikameti (aykırılıklardan arındırılmış veri) için (a) LSTM + GRU modeli; (b) doğrulama grafiği

Şekil 4.17’de Heybe Kavşağı 37887-37889 istikameti (aykırılıklardan arındırılmış

veri) için LSTM + GRU modeline ait çıktılar gösterilmiştir:

- Şekil 4.17(a) tahmin grafiğinde görüldüğü üzere LSTM + GRU modeli, trafik akışındaki periyodik yapıları ve genel eğilimi başarılı bir şekilde yakalamıştır. Tahmin değerleri ile gerçek değerler arasında güçlü bir uyum sağlanmış, orta yoğunluk seviyelerinde oldukça isabetli tahminler üretilmiştir. Bununla birlikte, yüksek trafik piklerinde kısmi sapmalar gözlenmiş, modelin ani artışları tam anlamıyla yansıtmakta sınırlı kaldığı belirlenmiştir.
- Şekil 4.17(b) doğrulama grafiğinde eğitim kaybının düzenli biçimde azaldığı, doğrulama kaybının ise dalgalanmalarla birlikte zamanla dengelendiği görülmektedir. Bu tablo, modelin aşırı öğrenme eğilimi göstermeden dengeli bir genelleme kapasitesi sunduğunu ve istikrarlı bir öğrenme süreci gerçekleştirdiğini ortaya koymaktadır.

Çizelge 4.3'te Heybe Kavşağı 37887-37889 güzergahı (aykırılıklardan arındırılmış veri) için derin öğrenme modellerinin eğitim ve test süreçlerindeki performans metrikleri kapsamlı bir şekilde sunulmuştur. Her model, eğitim ve test aşamalarındaki hata oranları (MSE, MAE) ve başarı oranları (R^2) ile karşılaştırılmıştır.

Çizelge 4.3. Heybe Kavşağı 37887-37889 güzergahı (aykırılıklardan arındırılmış veri) için derin öğrenme modellerinin performans metriklerinin karşılaştırılması

Model	Eğitim MSE	Test MSE	Eğitim MAE	Test MAE	Eğitim R^2	Test R^2
LSTM	223.629	301.83	11.217	12.862	0.847	0.834
BiLSTM	224.039	308.115	11.269	13.021	0.847	0.831
GRU	206.015	306.547	10.79	12.834	0.859	0.832
LSTM + CNN	211.457	299.367	10.98	12.764	0.855	0.836
RNN	230.458	308.193	11.744	13.147	0.842	0.831
Dikkat Mekanizması Tabanlı LSTM	209.388	334.455	10.914	13.277	0.857	0.816
Yığınlanmış LSTM	222.604	314.658	11.194	13.103	0.848	0.827
LSTM + GRU	212.086	281.567	10.956	12.462	0.855	0.845
Ortalama	217.460	306.842	11.133	12.934	0.851	0.832

Eğitim metriklerine göre:

- En düşük Eğitim MSE değerine GRU modeli (206.015) sahiptir. Bu, GRU modelinin eğitim verisindeki hata oranının diğer modellere göre daha düşük olduğunu göstermektedir.

- Eğitim MAE değerlerinde de GRU modeli (10.79) öne çıkmaktadır, bu da modelin hata büyüklüğünün az olduğunu ifade etmektedir.
- Eğitim R^2 değeri açısından en iyi performans yine GRU modeli (0.859) ile elde edilmiştir. Bu, modelin eğitim verilerine oldukça iyi uyum sağladığını göstermektedir.

Test metriklerine göre:


- En düşük Test MSE değeri LSTM + GRU modelinde (281.567) görülmektedir. Bu, test verisindeki hata oranının diğer modellere göre düşük olduğunu göstermektedir.
- Test MAE açısından en iyi performans yine LSTM + GRU modelinde (12.462) elde edilmiştir. Bu, modelin test verisindeki tahminlerinde daha az hata yaptığını göstermektedir.
- Test R^2 değerinde en iyi performans LSTM + GRU modeli (0.845) göstermiştir.

Heybe Kavşağı 37887-37889 istikameti (aykırılıklardan arındırılmış veri) genel değerlendirme:


- LSTM + GRU modeli, hem test metriklerinde (düşük MSE ve MAE, yüksek R^2) hem de doğrulama grafiğinde sergilediği dengeli öğrenme süreciyle en başarılı model olarak öne çıkmaktadır.

4.1.4. Heybe Kavşağı 37887-37889 istikameti ham veri ile derin öğrenme modellerinin eğitimi

Heybe Kavşağı 37887-37889 istikametine ait ham veri seti, sekiz farklı derin öğrenme modeli (LSTM, BiLSTM, GRU, LSTM+CNN, RNN, Dikkat Mekanizması Tabanlı LSTM, Yığınlanmış LSTM ve LSTM+GRU) kullanılarak eğitilmiştir. Veri temizleme işlemleri uygulanmadan oluşturulan bu veri seti, modellerin performanslarını karşılaştırmak amacıyla analiz edilmiştir. Modellerin çıktıları aşağıda görselleştirmelerle birlikte sunulmuş olup, tahmin grafiklerinde mavi çizgi gerçek değerleri, turuncu çizgi ise model tarafından tahmin edilen değerleri göstermektedir. Kayıp grafiklerinde ise mavi çizgi eğitim kaybını, turuncu çizgi doğrulama kaybını temsil etmektedir. Bu görselleştirmeler, modellerin hem tahmin başarısını hem de eğitim sürecindeki öğrenme davranışlarını değerlendirmek amacıyla kullanılmıştır.



(a)




(b)

Şekil 4.18. Heybe Kavşağı 37887-37889 istikameti (ham veri) için (a) LSTM modeli; (b) doğrulama grafiği


Şekil 4.18’de Heybe Kavşağı 37887-37889 istikameti (ham veri) için LSTM modeline ait çıktılar gösterilmiştir:

- Şekil 4.18(a) tahmin grafiğinde görüldüğü üzere LSTM modeli, trafik akışındaki periyodik dalgalanmaları genel hatlarıyla yakalamış ve tahmin değerleri ile gerçek değerler arasında uyum sağlamıştır. Ancak yüksek pik değerlerinde sapmalar görülmüş, model bu ani trafik artışlarını tam olarak yansıtmakta sınırlı kalmıştır.
- Şekil 4.18(b) doğrulama grafiğinde eğitim kaybının düzenli biçimde azaldığı, doğrulama kaybının ise dalgalı bir seyir izlediği görülmektedir. Bu durum,

modelin genelleme kapasitesinin sınırlı olduğunu ve kısmi istikrarsızlıklar gösterdiğini ortaya koymaktadır.



(a)



(b)


Şekil 4.19. Heybe Kavşağı 37887-37889 istikameti (ham veri) için (a) BiLSTM modeli; (b) doğrulama grafiği

Şekil 4.19’da Heybe Kavşağı 37887-37889 istikameti (ham veri) için BiLSTM modeline ait çıktılar gösterilmiştir:


- Şekil 4.19(a) tahmin grafiğinde görüldüğü üzere BiLSTM modeli, trafik akışındaki periyodik eğilimleri ve genel yapıyı başarılı şekilde yakalamıştır. Orta

yoğunluk seviyelerinde tahminlerle gerçek değerler arasında güçlü bir uyum sağlanırken, yüksek pik değerlerinde sapmalar gözlenmiştir. Bu durum, modelin ani trafik yoğunluklarını tam anlamıyla yansıtmakta sınırlı kaldığını göstermektedir.

- Şekil 4.19(b) doğrulama grafiğinde eğitim kaybı düzenli biçimde azalırken doğrulama kaybının dalgalı bir seyir izlediği görülmektedir. Bu tablo, modelin genelleme kapasitesinin sınırlı olduğunu ve aşırı öğrenme eğilimine kısmen yatkınlık gösterdiğini ortaya koymaktadır.



(a)




(b)


Şekil 4.20. Heybe Kavşağı 37887-37889 istikameti (ham veri) için (a) GRU modeli; (b) doğrulama grafiği

Şekil 4.20’de Heybe Kavşağı 37887-37889 istikameti (ham veri) için GRU modeline ait çıktılar gösterilmiştir:

- Şekil 4.20(a) tahmin grafiğinde görüldüğü üzere GRU modeli, trafik akışındaki periyodik dalgalanmaları başarılı bir şekilde yakalamış ve tahmin değerleri ile gerçek değerler arasında güçlü bir uyum sağlamıştır. Orta yoğunluk seviyelerinde modelin tahminleri oldukça isabetli olurken, yüksek pik değerlerinde kısmi sapmalar gözlenmiş ve ani trafik artışlarının tam olarak yansıtlamadığı belirlenmiştir.
- Şekil 4.20(b) doğrulama grafiğinde eğitim kaybının düzenli biçimde azaldığı, doğrulama kaybının ise dalgalı olmakla birlikte genel olarak dengeli bir seyir izlediği görülmektedir. Bu durum, modelin aşırı öğrenmeye eğilim göstermeden istikrarlı bir genelleme kapasitesi sunduğunu ortaya koymaktadır.



(a)




(b)


Şekil 4.21. Heybe Kavşağı 37887-37889 istikameti (ham veri) için (a) LSTM + CNN modeli; (b) doğrulama grafiği

Şekil 4.21’de Heybe Kavşağı 37887-37889 istikameti (ham veri) için LSTM + CNN modeline ait çıktılar gösterilmiştir:

- Şekil 4.21(a) tahmin grafiğinde görüldüğü üzere LSTM + CNN modeli, trafik akışındaki periyodik yapıları başarılı şekilde yakalamış ve genel eğilimi gerçek değerlere yakın biçimde temsil etmiştir. Orta yoğunluk seviyelerinde tahminler güçlü bir uyum gösterirken, yüksek pik değerlerinde kısmi sapmalar gözlenmiştir. Bu durum, modelin ani trafik artışlarını tam olarak yansıtmakta sınırlı kaldığını ortaya koymaktadır.
- Şekil 4.21(b) doğrulama grafiğinde eğitim kaybının düzenli biçimde azaldığı, doğrulama kaybının ise eğitim kaybına kıyasla daha yüksek seviyelerde ve dalgalı bir seyir izlediği görülmektedir. Bu tablo, modelin genel olarak dengeli bir öğrenme süreci gerçekleştirdiğini ancak ham verinin gürültülü yapısı nedeniyle genelleme kapasitesinde kısmi sınırlılıklar bulunduğunu göstermektedir.



(a)




(b)

Şekil 4.22. Heybe Kavşağı 37887-37889 istikameti (ham veri) için (a) RNN modeli; (b) doğrulama grafiği


Şekil 4.22’de Heybe Kavşağı 37887-37889 istikameti (ham veri) için RNN modeline ait çıktılar gösterilmiştir:

- Şekil 4.22(a) tahmin grafiğinde görüldüğü üzere RNN modeli, trafik akışındaki temel periyodik eğilimleri kısmen yakalayabilmiş ancak tahmin değerleri ile gerçek değerler arasında belirgin farklar oluşmuştur. Özellikle yüksek pik değerlerinde sapmalar daha belirgin hale gelmiş, bu durum modelin karmaşık trafik dinamiklerini yansıtmakta sınırlı kaldığını ortaya koymaktadır.

- Şekil 4.22(b) doğrulama grafiğinde eğitim kaybı hızlı bir şekilde azalırken, doğrulama kaybının düşük seviyelerde sabitlenerek eğitim kaybına paralel seyrettiği gözlenmektedir. Bu tablo, modelin aşırı öğrenme eğilimine girmediğini ancak genelleme kapasitesinin sınırlı olduğunu göstermektedir.



(a)




(b)


Şekil 4.23. Heybe Kavşağı 37887-37889 istikameti (ham veri) için (a) Dikkat Mekanizması Tabanlı LSTM modeli; (b) doğrulama grafiği

Şekil 4.23'te Heybe Kavşağı 37887-37889 istikameti (ham veri) için LSTM + Dikkat Mekanizması Tabanlı LSTM modeline ait çıktılar gösterilmiştir:

- Şekil 4.23(a) tahmin grafiğinde görüldüğü üzere Dikkat Mekanizması Tabanlı LSTM modeli, trafik akışındaki periyodik dalgalanmaları genel hatlarıyla yakalayabilmiş ve tahmin değerleri gerçek değerlere yakın bir seyir izlemiştir. Ancak yüksek trafik yoğunluğu anlarında sapmalar gözlenmiş, bu durum modelin ani artışları tam olarak yansıtmakta sınırlı kaldığını göstermektedir.
- Şekil 4.23(b) doğrulama grafiğinde, eğitim kaybının düzenli olarak azaldığı ve doğrulama kaybının da belirgin dalgalanmalar yaşasa da zamanla dengelendiği görülmektedir. Eğriler arasındaki mesafenin sabitlenmesi, modelin aşırı öğrenme eğilimi göstermediğini ve makul düzeyde genelleme kapasitesine sahip olduğunu ortaya koymaktadır.



(a)




(b)


Şekil 4.24. Heybe Kavşağı 37887-37889 istikameti (ham veri) için (a) Yığılanmış LSTM modeli; (b) doğrulama grafiği

Şekil 4.24'te Heybe Kavşağı 37887-37889 istikameti (ham veri) için Yığılanmış LSTM modeline ait çıktılar gösterilmiştir:

- Şekil 4.24(a) tahmin grafiğinde görüldüğü üzere Yığılanmış LSTM modeli, trafik akışındaki periyodik dalgalanmaları genel hatlarıyla yakalamış ve tahmin değerleri gerçek değerlere yakın bir eğilim sergilemiştir. Ancak yüksek trafik yoğunluklarında sapmalar dikkat çekmiş, modelin ani pik değerlerini tam olarak yakalamakta zorlandığı gözlemlenmiştir.
- Şekil 4.24(b) doğrulama grafiğinde, eğitim kaybının düzenli biçimde azaldığı, doğrulama kaybının ise dalgalı bir seyir izleyerek zamanla dengelendiği görülmektedir. Bu durum, modelin genelleme kapasitesinin makul düzeyde olduğunu ve aşırı öğrenme eğiliminin belirgin olmadığını ortaya koymaktadır.



(a)



(b)

Şekil 4.25. Heybe Kavşağı 37887-37889 istikameti (ham veri) için (a) LSTM + GRU modeli; (b) doğrulama grafiği

Şekil 4.25'te Heybe Kavşağı 37887-37889 istikameti (ham veri) için LSTM + GRU modeline ait çıktılar gösterilmiştir:

- Şekil 4.25(a) tahmin grafiğinde görüldüğü üzere LSTM + GRU modeli, trafik akışındaki genel eğilimi ve periyodik dalgalanmaları başarılı şekilde yakalamıştır. Orta yoğunluk seviyelerinde tahminler gerçek değerlerle yüksek uyum göstermiştir. Ancak ham veri kullanılması nedeniyle yüksek pik değerlerinde

sapmalar gözlenmiş, modelin ani artışları tam olarak yakalayamadığı belirlenmiştir.

- Şekil 4.25(b) doğrulama grafiğinde eğitim ve doğrulama kayıpları karşılaştırıldığında, her iki eğrinin de zaman içinde azaldığı ve doğrulama kaybının dengeli bir eğriye oturduğu görülmektedir. Bu durum, modelin istikrarlı bir öğrenme süreci geçirdiğini ve genelleme kapasitesinin güçlü olduğunu göstermektedir.

Çizelge 4.4'te Heybe Kavşağı 37887-37889 güzergahı (ham veri) için derin öğrenme modellerinin eğitim ve test süreçlerindeki performans metrikleri kapsamlı bir şekilde sunulmuştur. Her model, eğitim ve test aşamalarındaki hata oranları (MSE, MAE) ve başarı oranları (R^2) ile karşılaştırılmıştır.

Çizelge 4.4. Heybe Kavşağı 37887-37889 güzergahı (ham veri) için derin öğrenme modellerinin performans metriklerinin karşılaştırılması

Model	Eğitim MSE	Test MSE	Eğitim MAE	Test MAE	Eğitim R^2	Test R^2
LSTM	215.632	282.711	11.109	12.562	0.852	0.845
BiLSTM	212.341	286.616	10.965	12.546	0.855	0.843
GRU	215.527	284.687	11.044	12.570	0.853	0.844
LSTM + CNN	214.117	283.718	11.050	12.528	0.854	0.844
RNN	220.610	304.046	11.221	12.844	0.849	0.833
Dikkat Mekanizması Tabanlı LSTM	210.343	301.224	10.832	12.721	0.856	0.835
Yığınlanmış LSTM	216.744	288.035	11.153	12.674	0.852	0.842
LSTM + GRU	212.315	276.672	10.941	12.366	0.855	0.848
Ortalama	214.704	288.464	11.039	12.601	0.853	0.842

Eğitim metriklerine göre:

- En düşük Eğitim MSE değerine Dikkat Mekanizması Tabanlı LSTM modeli (210.343) sahiptir. Bu, Dikkat Mekanizması Tabanlı LSTM modelinin eğitim verisindeki hata oranının diğer modellere göre daha düşük olduğunu göstermektedir.
- Eğitim MAE değerlerinde de Dikkat Mekanizması Tabanlı LSTM modeli (10.832) öne çıkmaktadır, bu da modelin hata büyüklüğünün az olduğunu ifade etmektedir.

- Eğitim R^2 değeri açısından en iyi performans yine Dikkat Mekanizması Tabanlı LSTM modeli (0.856) ile elde edilmiştir. Bu, modelin eğitim verilerine oldukça iyi uyum sağladığını göstermektedir.

Test metriklerine göre:


- En düşük Test MSE değeri LSTM + GRU modelinde (276.672) görülmektedir. Bu, test verisindeki hata oranının diğer modellere göre düşük olduğunu göstermektedir.
- Test MAE açısından en iyi performans yine LSTM + GRU modelinde (12.366) elde edilmiştir. Bu, modelin test verisindeki tahminlerinde daha az hata yaptığını göstermektedir.
- Test R^2 değerinde en iyi performans LSTM + GRU modeli (0.848) göstermiştir.

Heybe Kavşağı 37887-37889 istikameti (ham veri) genel değerlendirme:


- LSTM + GRU modeli, test metriklerinde (düşük MSE ve MAE, yüksek R^2) en iyi sonuçları vererek en başarılı model olmuştur.
- Dikkat Mekanizması Tabanlı LSTM modeli ise eğitim sürecinde en iyi sonuçları üretmiş, ancak test setinde daha yüksek hata değerleri ile sınırlı kalmıştır.

4.1.5. Heybe Kavşağı 37889-37887 istikameti farklı zaman dilimlerine göre trafik hacimleri


Bu bölümde, 37889-37887 güzergahına ait trafik hacim verileri analiz edilmiştir. Veri seti, belirli bir zaman dilimi boyunca toplanan 5 dakikalık gözlemlerden oluşmaktadır. Şekil 4.26'da farklı zaman dilimlerinde (15 dakika, saatlik, günlük, haftalık ve aylık) araç sınıflarına göre trafik akışındaki değişimler gösterilmektedir. Otomobil sınıfı araçlar, tüm zaman dilimlerinde en yoğun araç türü olarak dikkat çekerken, motosiklet ve diğer araç türlerinin hacmi nispeten daha düşük seviyelerde seyretmektedir. Zaman içinde araç geçişlerindeki dalgalanmalar, özellikle günün belirli saatlerinde trafik yoğunluğunun arttığını göstermektedir.




(a)




(b)



(c)




(d)



(e)


Şekil 4.26. Heybe Kavşağı 37889-37887 güzergahı araç sayımları a) 15 dakikalık; b) saatlik; c) günlük; d) haftalık; e) aylık

Şekil 4.27’de, her bir araç sınıfının trafik hacmine yaptığı katkı ve toplam trafik yoğunluğu PCU cinsinden gösterilmiştir. Bu dönüşüm, özellikle farklı araç türlerinin (otomobil, motosiklet, ticari araçlar) trafik üzerindeki etkisini daha anlaşılır ve karşılaştırılabilir hale getirmektedir. Otomobiller, tüm araç sınıfları arasında trafik hacmine en büyük katkıyı sağlarken, motosikletler ve diğer ticari araçlar daha düşük oranlarda katkıda bulunmuştur.



Şekil 4.27. Heybe Kavşağı 37889-37887 güzergahındaki araç sınıflarına göre PCU cinsinden trafik hacim dağılımı

Trafik verileri arasındaki ilişkiler, korelasyon matrisi yardımıyla değerlendirilmiştir. Şekil 4.28’de yer alan korelasyon matrisi, araç sınıflarının birbirleriyle ve toplam araç sayısı ile olan ilişki derecelerini görselleştirmektedir. Diğer araç türlerine göre özellikle otomobil sınıfının toplam trafik hacmiyle yüksek oranda pozitif korelasyona sahip olduğu tespit edilmiştir.




Şekil 4.28. Heybe Kavşağı 37889-37887 güzergahına ait araç sınıflarının korelasyon matrisi


4.1.6. Heybe Kavşağı 37889-37887 istikameti aykırılık analizi ve temizleme yöntemlerinin karşılaştırılması

Bu bölümde, 37889-37887 güzergahına ait veri seti üzerinde Z-Score, Mahalanobis Mesafesi, PCA yöntemleri kullanılarak aykırılık tespiti gerçekleştirilmiştir.


Şekil 4.29’da her bir aykırılık tespit yöntemiyle belirlenen aykırılıklar görselleştirilmiştir. Z-Score yöntemiyle 57, Mahalanobis Mesafesiyle 274 ve PCA yöntemiyle 94 aykırılık tespit edilmiştir.



(a)




(b)




(c)

Şekil 4.29. Heybe Kavşağı aykırılık tespit yöntemleri **a)** Z-Skoru; **b)** Mahalanobis mesafesiyle; **c)** PCA


Veri setinden aykırı değerler çıkarıldıktan sonra, temizlenmiş veri setleri üzerinde çeşitli makine öğrenimi modelleri eğitilmiş ve performans metrikleri karşılaştırılmıştır. Şekil 4.30'da Mahalanobis, Şekil 4.31'de PCA ve Şekil 4.32'de Z-Score yöntemlerine göre modellenmiş verilerin performans metrikleri sunulmuştur.



(a)




(b)




(c)


Şekil 4.30. Mahalanobis modeli performans karşılaştırması a) MSE; b) MAE; c) R^2



(a)




(b)




(c)


Şekil 4.31. PCA modeli performans karşılaştırması a) MSE; b) MAE; c) R^2



(a)



(b)



(c)

Şekil 4.32. Z-Score modeli performans karşılaştırması a) MSE; b) MAE; c) R^2


Çizelge 4.5'te sırasıyla Z-Score, Mahalanobis ve PCA yöntemlerine ait performans metrikleri (MSE, MAE, R^2) özetlenmiştir. Mahalanobis yöntemi, yüksek R^2 değeri ve düşük hata oranlarıyla en iyi performansı göstermiştir. Bununla birlikte, PCA yöntemi dengeli bir performans sergilerken, Z-Score yöntemi belirli modellerde üstünlük sağlamıştır.

Çizelge 4.5. Aykırılık tespit yöntemlerinin performans metrikleri bakımından karşılaştırılması


Model	MSE			MAE			R ²		
Doğrusal Regresyon	1249.399	1176.094	1212.219	28.804	28.244	28.477	0.382	0.410	0.390
Karar Ağaçları	699.611	661.988	690.251	20.193	19.651	20.071	0.654	0.668	0.653
KNN	860.857	809.504	906.887	22.552	21.973	22.907	0.574	0.594	0.544
MLP	712.850	682.232	709.152	20.457	19.991	20.319	0.647	0.658	0.643
Rastgele Orman	699.600	661.900	690.178	20.196	19.649	20.070	0.654	0.668	0.653
Gradyan Artırma	699.642	662.017	690.134	20.193	19.652	20.070	0.654	0.668	0.653
Elastic Net	1249.352	1176.084	1212.177	28.805	28.245	28.478	0.382	0.410	0.390
AdaBoost	726.081	688.043	710.987	20.889	20.450	20.752	0.641	0.655	0.642
Bagging	699.620	662.209	690.054	20.191	19.654	20.065	0.654	0.668	0.653
Voting	837.253	788.864	815.581	23.074	22.499	22.779	0.586	0.605	0.590
Stacking	699.685	661.953	690.178	20.194	19.653	20.071	0.654	0.668	0.653

4.1.7. Heybe Kavşağı 37889-37887 istikameti aykırılık analizi sonrası derin öğrenme modellerinin eğitimi

Trafik verilerinin işlenmesi ve aykırılık analizinin ardından, Heybe Kavşağı 37889-37887 istikametine ait veri seti sekiz farklı derin öğrenme modeli (LSTM, BiLSTM, GRU, LSTM+CNN, RNN, Dikkat Mekanizması Tabanlı LSTM, Yığınlanmış LSTM ve LSTM+GRU) ile eğitilmiştir. Aykırılıklardan arındırılmış bileşenlerle oluşturulan bu veri seti, modellerin performanslarını değerlendirmek amacıyla analiz edilmiştir. Modellerin çıktıları aşağıda görselleştirmelerle birlikte sunulmuş olup, tahmin grafiklerinde mavi çizgi gerçek değerleri, turuncu çizgi ise model tarafından üretilen tahminleri göstermektedir. Kayıp grafiklerinde ise mavi çizgi eğitim kaybını, turuncu çizgi doğrulama kaybını temsil etmektedir. Bu görselleştirmeler, modellerin hem tahmin doğruluğunu hem de eğitim sürecindeki öğrenme davranışlarını değerlendirmek amacıyla kullanılmıştır.



(a)




(b)

Şekil 4.33. Heybe Kavşağı 37889-37887 istikameti (aykırılıklardan arındırılmış veri) için (a) LSTM modeli; (b) doğrulama grafiği


Şekil 4.33'te Heybe Kavşağı 37889-37887 istikameti (aykırılıklardan arındırılmış veri) için LSTM modeline ait çıktılar gösterilmiştir:

- Şekil 4.33(a) tahmin grafiğinde görüldüğü üzere LSTM modeli, genel trafik akışındaki eğilimleri yakalamış ve periyodik dalgalanmaları kısmen temsil edebilmiştir. Ancak ham veri kullanılması nedeniyle, yüksek pik değerlerinde belirgin sapmalar oluşmuş ve modelin ani trafik yoğunluklarını yansıtmaya kapasitesi sınırlı kalmıştır.

- Şekil 4.33(b) doğrulama grafiğinde eğitim kaybı düzenli bir şekilde azalırken doğrulama kaybının dalgalı bir seyir izlediği gözlemlenmiştir. Bu durum, modelin öğrenme sürecinde ilerleme kaydettiğini ancak genelleme performansında istikrar sağlamakta zorlandığını ortaya koymaktadır.



(a)




(b)


Şekil 4.34. Heybe Kavşağı 37889-37887 istikameti (aykırılıklardan arındırılmış veri) için **(a)** BiLSTM modeli; **(b)** doğrulama grafiği

Şekil 4.34'te Heybe Kavşağı 37889-37887 istikameti (aykırılıklardan arındırılmış veri) için BiLSTM modeline ait çıktılar gösterilmiştir:

- Şekil 4.34(a) tahmin grafiğinde BiLSTM modeli, trafik akışındaki periyodik eğilimleri genel olarak yakalamış olsa da tahmin değerleri ile gerçek değerler arasında özellikle yüksek pik seviyelerinde belirgin sapmalar gözlenmektedir. Bu durum, modelin ani trafik artışlarını tam olarak yansıtmakta sınırlı kaldığını göstermektedir.
- Şekil 4.34(b) doğrulama grafiğinde, eğitim kaybının düzenli bir biçimde azaldığı, ancak doğrulama kaybının daha dalgalı bir seyir izlediği görülmektedir. Doğrulama kaybındaki bu dalgalanmalar, modelin genelleme kapasitesinin sınırlı olduğunu ve aşırı öğrenmeye eğilim gösterdiğini ortaya koymaktadır.



(a)




(b)


Şekil 4.35. Heybe Kavşağı 37889-37887 istikameti (aykırılıklardan arındırılmış veri) için (a) GRU modeli; (b) doğrulama grafiği

Şekil 4.35'te Heybe Kavşağı 37889-37887 istikameti (aykırılıklardan arındırılmış veri) için GRU modeline ait çıktılar gösterilmiştir:

- Şekil 4.35(a) tahmin grafiğinde görüldüğü üzere GRU modeli, trafik akışındaki periyodik dalgalanmaları başarılı şekilde öğrenmiş ve tahmin değerleri ile gerçek değerler arasında yüksek düzeyde uyum sağlamıştır. Özellikle orta yoğunluk seviyelerinde tahminlerin oldukça isabetli olduğu, ancak yüksek pik değerlerinde kısmi sapmaların bulunduğu gözlemlenmiştir.
- Şekil 4.35(b) doğrulama grafiğinde eğitim kaybının düzenli olarak azaldığı, doğrulama kaybının ise daha yüksek seviyelerde seyrettiği ve aradaki farkın giderek açıldığı görülmektedir. Bu durum, modelin eğitim verisini iyi öğrenmesine rağmen genelleme kapasitesinin sınırlı kaldığını ve aşırı öğrenme eğilimi gösterdiğini ortaya koymaktadır.



(a)




(b)

Şekil 4.36. Heybe Kavşağı 37889-37887 istikameti (aykırılıklardan arındırılmış veri) için (a) LSTM + CNN modeli; (b) doğrulama grafiği


Şekil 4.36’da Heybe Kavşağı 37889-37887 istikameti (aykırılıklardan arındırılmış veri) için LSTM + CNN modeline ait çıktılar gösterilmiştir:

- Şekil 4.36(a) tahmin grafiğinde görüldüğü üzere LSTM + CNN modeli, trafik akışındaki periyodik dalgalanmaları ve genel eğilimi yakalamış, tahmin değerleri ile gerçek değerler arasında belirli bir uyum sağlamıştır. Ancak yüksek trafik yoğunluğu içeren pik değerlerinde belirgin sapmalar gözlenmiş, bu durum modelin ani artışları tam olarak yansıtmakta zorlandığını ortaya koymuştur.

- Şekil 4.36(b) doğrulama grafiğinde ise eğitim kaybının düzenli şekilde azalmasına karşın doğrulama kaybının dalgalı bir seyir izlediği görülmektedir. Doğrulama kaybının bu istikrarsız yapısı, modelin genelleme kapasitesinde sınırlılıkların bulunduğunu ve aşırı öğrenme eğilimi gösterdiğini işaret etmektedir.



(a)




(b)


Şekil 4.37. Heybe Kavşağı 37889-37887 istikameti (aykırılıklardan arındırılmış veri) için (a) RNN modeli; (b) doğrulama grafiği

Şekil 4.37’de Heybe Kavşağı 37889-37887 istikameti (aykırılıklardan arındırılmış veri) için RNN modeline ait çıktılar gösterilmiştir:

- Şekil 4.37(a) tahmin grafiğinde görüldüğü üzere RNN modeli, trafik akışındaki periyodik dalgalanmaları genel eğilim açısından takip edebilmiştir. Ancak tahmin değerleri ile gerçek değerler arasında özellikle yüksek pik noktalarında belirgin sapmalar gözlenmiştir. Bu durum, modelin ani trafik yoğunluklarını yansıtmakta sınırlı kaldığını ortaya koymaktadır.
- Şekil 4.37(b) doğrulama grafiğinde eğitim ve doğrulama kayıplarının başlangıçta hızlı bir şekilde azaldığı, ardından birbirine paralel biçimde istikrarlı bir seyir izlediği görülmektedir. Bu eğilim, modelin aşırı öğrenme eğilimi göstermediğini ve genelleme kapasitesinin dengeli olduğunu işaret etmektedir.



(a)




(b)


Şekil 4.38. Heybe Kavşağı 37889-37887 istikameti (aykırılıklardan arındırılmış veri) için **(a)** Dikkat Mekanizması Tabanlı LSTM modeli; **(b)** doğrulama grafiği

Şekil 4.38’de Heybe Kavşağı 37889-37887 istikameti (aykırılıklardan arındırılmış veri) için Dikkat Mekanizması Tabanlı LSTM modeline ait çıktılar gösterilmiştir:

- Şekil 4.38(a) tahmin grafiğinde görüldüğü üzere Dikkat Mekanizması Tabanlı LSTM modeli, trafik akışındaki genel eğilimi yakalamış ve periyodik dalgalanmaları başarılı şekilde temsil etmiştir. Ancak, yüksek pik değerlerinde belirgin sapmalar gözlenmiş, bu durum modelin ani trafik yoğunluklarını tam olarak yakalayamadığını ortaya koymuştur.
- Şekil 4.38(b) doğrulama grafiğinde, eğitim kaybının düzenli bir şekilde azalmasına karşın doğrulama kaybının daha dalgalı bir seyir izlediği görülmektedir. Bu durum, modelin öğrenme sürecinde zaman zaman dalgalanmalar yaşadığını ve genelleme kapasitesinin sınırlı kaldığını göstermektedir.



(a)




(b)


Şekil 4.39. Heybe Kavşağı 37889-37887 istikameti (aykırılıklardan arındırılmış veri) için (a) Yığılanmış LSTM modeli; (b) doğrulama grafiği

Şekil 4.39’da Heybe Kavşağı 37889-37887 istikameti (aykırılıklardan arındırılmış veri) için Yığılanmış LSTM modeline ait çıktılar gösterilmiştir:

- Şekil 4.39(a) tahmin grafiğinde görüldüğü üzere Yığılanmış LSTM modeli, trafik akışındaki periyodik yapıları genel eğilim açısından başarılı şekilde öğrenmiştir. Orta yoğunluk seviyelerinde tahminler gerçek değerlere yakın seyrederken, yüksek pik noktalarında belirgin sapmalar gözlenmiştir. Bu durum, modelin ani trafik artışlarını yakalamakta zorlandığını göstermektedir.
- Şekil 4.39(b) doğrulama grafiğinde ise eğitim kaybının istikrarlı şekilde azaldığı, doğrulama kaybının ise eğitim süreci boyunca dalgalanma gösterdiği izlenmektedir. İki eğri arasındaki farkın giderek açılması, modelin aşırı öğrenme eğilimi sergilediğini ve genelleme kapasitesinin sınırlı kaldığını ortaya koymaktadır.



(a)



(b)

Şekil 4.40. Heybe Kavşağı 37889-37887 istikameti (aykırılıklardan arındırılmış veri) için (a) LSTM + GRU modeli; (b) doğrulama grafiği

Şekil 4.40'ta Heybe Kavşağı 37889-37887 istikameti (aykırılıklardan arındırılmış veri) için LSTM + GRU modeline ait çıktılar gösterilmiştir:

- Şekil 4.40(a) tahmin grafiğinde görüldüğü üzere LSTM + GRU modeli, trafik akışındaki genel periyodik eğilimleri başarıyla yakalamış, tahmin değerleri ile gerçek değerler arasında belirgin bir uyum sağlamıştır. Bununla birlikte, yüksek pik değerlerinde sapmalar gözlenmiş ve modelin ani trafik artışlarını tam olarak yakalayamadığı belirlenmiştir.

- Şekil 4.40(b) doğrulama grafiğinde ise eğitim kaybının düzenli olarak azaldığı, doğrulama kaybının ise zaman içerisinde dalgalı bir seyir izleyerek daha yüksek seviyelerde kaldığı görülmektedir. Bu durum, modelin genelleme kapasitesinin sınırlı olduğunu ve kısmi aşırı öğrenme eğilimi gösterdiğini ortaya koymaktadır.

Çizelge 4.6’da Heybe Kavşağı 37889-37887 güzergahı (aykırılıklardan arındırılmış veri) için derin öğrenme modellerinin eğitim ve test süreçlerindeki performans metrikleri kapsamlı bir şekilde sunulmuştur. Her model, eğitim ve test aşamalarındaki hata oranları (MSE, MAE) ve başarı oranları (R^2) ile karşılaştırılmıştır.

Çizelge 4.6. Heybe Kavşağı 37889-37887 güzergahı (aykırılıklardan arındırılmış veri) için derin öğrenme modellerinin performans metriklerinin karşılaştırılması

Model	Eğitim MSE	Test MSE	Eğitim MAE	Test MAE	Eğitim R^2	Test R^2
LSTM	454.392	598.505	16.169	18.749	0.754	0.73
BiLSTM	441.586	609.12	15.84	18.8	0.761	0.725
GRU	442.208	613.636	15.864	18.882	0.761	0.723
LSTM + CNN	453.14	618.58	16.085	18.959	0.755	0.721
RNN	480.268	626.223	16.734	19.189	0.74	0.717
Dikkat Mekanizması Tabanlı LSTM	457.285	646.609	16.214	19.474	0.753	0.708
Yığılanmış LSTM	442.186	641.098	15.88	19.196	0.761	0.711
LSTM + GRU	444.313	597.047	15.951	18.687	0.76	0.73
Ortalama	451.922	618.852	16.092	18.992	0.756	0.721

Eğitim metriklerine göre:

- En düşük Eğitim MSE değerine BiLSTM modeli (441.586) sahiptir. Bu, BiLSTM modelinin eğitim verisindeki hata oranının diğer modellere göre daha düşük olduğunu göstermektedir.
- Eğitim MAE değerlerinde en iyi performans yine BiLSTM modeli (15.84) ile elde edilmiştir. Bu, hata büyüklüğünün görece düşük olduğunu ifade etmektedir.
- Eğitim R^2 değeri açısından en yüksek performans BiLSTM (0.761), GRU (0.761) ve Yığılanmış LSTM (0.761) modelleri tarafından paylaşılmaktadır.

Test metriklerine göre:


- En düşük Test MSE değeri LSTM + GRU modelinde (597.047) görülmektedir. Bu, test verisindeki hata oranının diğer modellere göre düşük olduğunu göstermektedir.
- Test MAE açısından en iyi performans yine LSTM + GRU modelinde (18.687) elde edilmiştir. Bu, modelin test verisindeki tahminlerinde daha az hata yaptığını göstermektedir.
- Test R^2 değeri bakımından en yüksek performans LSTM + GRU (0.730) ve LSTM (0.730) modellerinde görülmektedir.

Heybe Kavşağı 37889-37887 istikameti (aykırılıklardan arındırılmış veri) genel değerlendirme:


- LSTM + GRU modeli, test metriklerinde (en düşük MSE ve MAE, en yüksek R^2) elde ettiği sonuçlarla en başarılı model olarak öne çıkmaktadır.
- BiLSTM modeli, eğitim sürecinde en düşük hata oranlarına ulaşarak güçlü bir performans göstermiştir, ancak test sonuçları LSTM + GRU kadar başarılı değildir.

4.1.8. Heybe Kavşağı 37889-37887 istikameti ham veri ile derin öğrenme modellerinin eğitimi

Heybe Kavşağı 37889-37887 istikametine ait ham veri seti, sekiz farklı derin öğrenme modeli (LSTM, BiLSTM, GRU, LSTM+CNN, RNN, Dikkat Mekanizması Tabanlı LSTM, Yığınlanmış LSTM ve LSTM+GRU) kullanılarak eğitilmiştir. Veri temizleme işlemleri uygulanmadan oluşturulan bu veri seti, modellerin performanslarını karşılaştırmak amacıyla analiz edilmiştir. Modellerin çıktıları aşağıda görselleştirmelerle birlikte sunulmuş olup, tahmin grafiklerinde mavi çizgi gerçek değerleri, turuncu çizgi ise model tarafından tahmin edilen değerleri göstermektedir. Kayıp grafiklerinde ise mavi çizgi eğitim kaybını, turuncu çizgi doğrulama kaybını temsil etmektedir. Bu görselleştirmeler, modellerin hem tahmin başarısını hem de eğitim sürecindeki öğrenme davranışlarını değerlendirmek amacıyla kullanılmıştır.



(a)




(b)

Şekil 4.41. Heybe Kavşağı 37889-37887 istikameti (ham veri) için (a) LSTM modeli; (b) doğrulama grafiği


Şekil 4.41’de Heybe Kavşağı 37889-37887 istikameti (ham veri) için LSTM modeline ait çıktılar gösterilmiştir:

- Şekil 4.41(a) tahmin grafiğinde görüldüğü üzere LSTM modeli, trafik akışındaki genel eğilimi ve periyodik dalgalanmaları başarılı şekilde yakalamıştır. Ancak ham veri kullanılması nedeniyle ani pik değerlerinde sapmalar daha belirgin hale gelmiş, model bu değerleri tam olarak yansıtmakta sınırlı kalmıştır.
- Şekil 4.41(b) doğrulama grafiğinde eğitim ve doğrulama kayıpları karşılaştırılmıştır. Doğrulama kaybı başlangıçta dalgalı bir seyir izledikten sonra

eğitim kaybına paralel şekilde istikrar kazanmıştır. Ancak ilerleyen epoklarda iki eğri arasındaki farkın yavaş yavaş açıldığı gözlemlenmiştir. Bu durum, modelin başlangıçta dengeli bir öğrenme süreci yakaladığını, ancak daha ileri epoklarda kısmi aşırı öğrenme eğilimi göstermeye başladığını ortaya koymaktadır.



(a)




(b)


Şekil 4.42. Heybe Kavşağı 37889-37887 istikameti (ham veri) için (a) BiLSTM modeli; (b) doğrulama grafiği

Şekil 4.42’de Heybe Kavşağı 37889-37887 istikameti (ham veri) için BiLSTM modeline ait çıktılar gösterilmiştir:

- Şekil 4.42(a) tahmin grafiğinde görüldüğü üzere BiLSTM modeli, trafik akışındaki periyodik yapıları ve genel eğilimi büyük ölçüde yakalayabilmiştir. Özellikle orta yoğunluk seviyelerinde tahminler gerçek değerlere yakın seyretmiş, ancak yüksek pik değerlerinde kısmi sapmalar gözlenmiştir. Bu durum, modelin ani trafik yoğunluklarını tam olarak yansıtmakta sınırlı kaldığını göstermektedir.
- Şekil 4.42(b) doğrulama grafiğinde eğitim ve doğrulama kayıpları karşılaştırılmıştır. Başlangıçta doğrulama kaybı yüksek seviyeden başlamış ve dalgalı bir seyir izlemiştir. Daha sonraki epoklarda her iki kayıp eğrisinin de paralel biçimde azaldığı görülmekle birlikte, epok ilerledikçe aradaki farkın açılmaya başladığı dikkat çekmektedir. Bu sonuç, modelin kısmi düzeyde aşırı öğrenme eğilimi gösterdiğini ve genelleme kapasitesinin sınırlı kaldığını ortaya koymaktadır.



(a)




(b)


Şekil 4.43. Heybe Kavşağı 37889-37887 istikameti (ham veri) için (a) GRU modeli; (b) doğrulama grafiği

Şekil 4.43'te Heybe Kavşağı 37889-37887 istikameti (ham veri) için GRU modeline ait çıktılar sunulmuştur:

- Şekil 4.43(a) tahmin grafiğinde GRU modelinin trafik akışındaki genel eğilimi ve periyodik dalgalanmaları başarıyla yakaladığı görülmektedir. Orta yoğunluk seviyelerinde modelin tahminleri güçlü bir uyum göstermektedir. Bununla birlikte, yüksek pik değerlerinde sapmalar belirginleşmiş ve model ani trafik artışlarını tam olarak yakalayamamıştır.
- Şekil 4.43(b) doğrulama grafiğinde eğitim ve doğrulama kayıpları karşılaştırılmıştır. Eğitim kaybı düzenli biçimde azalırken doğrulama kaybı başlangıçta dalgalı bir seyir izlemiş, daha sonra daha kararlı bir yapıya oturmuştur. Ancak iki eğri arasındaki farkın zamanla artması, modelin kısmi aşırı öğrenme eğilimi gösterdiğini ve genelleme kapasitesinde sınırlılıklar bulunduğunu ortaya koymaktadır.



(a)



(b)



Şekil 4.44. Heybe Kavşağı 37889-37887 istikameti (ham veri) için **(a)** LSTM + CNN modeli; **(b)** doğrulama grafiği

Şekil 4.44'te Heybe Kavşağı 37889-37887 istikameti (ham veri) için LSTM + CNN modeline ait çıktılar gösterilmiştir:

- Şekil 4.44(a): Tahmin grafiğinde LSTM + CNN modeli, trafik akışındaki periyodik yapıları ve genel eğilimi başarılı şekilde yakalamış, tahmin değerleri büyük ölçüde gerçek değerlere yaklaşmıştır. Özellikle orta yoğunluk seviyelerinde modelin tahminleri güçlü uyum göstermiştir. Ancak yüksek pik

değerlerinde sapmalar belirginleşmiş, model bu ani artışları tam olarak yansıtmakta sınırlı kalmıştır.


- Şekil 4.44(b): Eğitim ve doğrulama kayıpları karşılaştırıldığında, eğitim kaybının düzenli olarak azaldığı, doğrulama kaybının ise başlangıçta dalgalanmalar sergiledikten sonra daha dengeli bir seyir izlediği görülmektedir. Bununla birlikte, eğitim ve doğrulama kayıpları arasındaki mesafe giderek açılmıştır. Bu durum, modelin öğrenme sürecinde kısmi aşırı öğrenme eğilimi gösterdiğini ve genelleme kapasitesinin sınırlı olduğunu ortaya koymaktadır.




Şekil 4.45. Heybe Kavşağı 37889-37887 istikameti (ham veri) için **(a)** RNN modeli; **(b)** doğrulama grafiği

Şekil 4.45'te 37889-37887 istikameti (ham veri) için RNN modeline ait çıktılar gösterilmiştir:

- Şekil 4.45(a) tahmin grafiğinde görüldüğü üzere, RNN modeli trafik akışındaki periyodik dalgalanmaları genel eğilim açısından yakalayabilmiştir. Özellikle orta yoğunluk seviyelerinde tahminler gerçek değerlere yakın seyretmiştir. Ancak yüksek pik değerlerinde belirgin sapmalar gözlenmiş, bu durum modelin ani trafik yoğunluklarını tam olarak temsil etmekte yetersiz kaldığını ortaya koymuştur.
- Şekil 4.45(b) doğrulama grafiğinde eğitim ve doğrulama kayıplarının başlangıçta birbirine oldukça yakın seyrettiği, ilerleyen epoklarda ise birbirine paralel ve kararlı bir eğilim gösterdiği görülmektedir. Bu durum, modelin aşırı öğrenme eğilimi göstermediğini ve genelleme kapasitesinin istikrarlı olduğunu ortaya koymaktadır.



(a)




(b)


Şekil 4.46. Heybe Kavşağı 37889-37887 istikameti (ham veri) için (a) Dikkat Mekanizması Tabanlı LSTM modeli; (b) doğrulama grafiği

Şekil 4.46’da Heybe Kavşağı 37889-37887 istikameti (ham veri) için Dikkat Mekanizması Tabanlı LSTM modeline ait çıktılar gösterilmiştir:

- Şekil 4.46(a) tahmin grafiğinde görüldüğü üzere Dikkat Mekanizması Tabanlı LSTM modeli, trafik akışındaki genel eğilimi ve periyodik dalgalanmaları başarılı şekilde yakalamış, tahmin değerleri ile gerçek değerler arasında uyum sağlamıştır. Ancak yüksek pik değerlerinde kısmi sapmalar gözlenmiş ve model bu ani artışları tam olarak yansıtmakta sınırlı kalmıştır.
- Şekil 4.46(b) doğrulama grafiğinde eğitim ve doğrulama kayıplarının başlangıçta dalgalı bir seyir izlediği, daha sonraki dönemlerde ise paralel bir eğilim gösterdiği görülmektedir. Eğitim kaybı düzenli olarak azalırken, doğrulama kaybı daha yatay kalmış ve süreç sonunda aradaki farkın kademeli olarak açıldığı gözlemlenmiştir. Bu durum, modelin genelleme kapasitesinin genel olarak istikrarlı olmakla birlikte, kısmi düzeyde aşırı öğrenme eğilimi sergilediğini ortaya koymaktadır.



(a)



(b)


Şekil 4.47. Heybe Kavşağı 37889-37887 istikameti (ham veri) için **(a)** Yığılanmış LSTM modeli; **(b)** doğrulama grafiği

Şekil 4.47’de Heybe Kavşağı 37889-37887 istikameti (ham veri) için Yığılanmış LSTM modeline ait çıktılar gösterilmiştir:


- Şekil 4.47(a) tahmin grafiğinde görüldüğü üzere Yığılanmış LSTM modeli, genel eğilimi ve periyodik trafik akışını büyük ölçüde başarılı bir şekilde yakalamıştır. Orta yoğunluk seviyelerinde tahminler ile gerçek değerler arasında güçlü bir uyum sağlanırken, yüksek pik değerlerinde kısmi sapmalar

görülmektedir. Bu durum, modelin ani trafik artışlarını tam olarak yakalayamadığını göstermektedir.

- Şekil 4.47(b) doğrulama grafiğinde eğitim ve doğrulama kayıpları karşılaştırıldığında, her iki eğrinin de düzenli olarak azaldığı, ancak doğrulama kaybının eğitim kaybına kıyasla bir miktar daha yüksek seyrettiği gözlenmektedir. Bu eğilim, modelin öğrenme sürecinde istikrarlı bir performans sergilediğini ancak sınırlı bir genelleme kapasitesine sahip olduğunu ortaya koymaktadır.



(a)



(b)

Şekil 4.48. Heybe Kavşağı 37889-37887 istikameti (ham veri) için (a) LSTM + GRU modeli; (b) doğrulama grafiği

Şekil 4.48’de Heybe Kavşağı 37889–37887 istikameti (ham veri) için LSTM + GRU modeline ait çıktılar sunulmuştur:

- Şekil 4.48(a) tahmin grafiğinde, modelin trafik akışındaki periyodik desenleri ve genel eğilimi yakalamada başarılı olduğu görülmektedir. Tahmin değerleri orta yoğunluk seviyelerinde gerçek değerlere yakın seyretse de yüksek pik değerlerinde belirgin sapmalar gözlenmiştir. Bu durum, modelin ani trafik yoğunluklarını tam olarak yansıtmakta sınırlı kaldığını ortaya koymaktadır.
- Şekil 4.48(b) doğrulama grafiğinde, doğrulama kaybının başlangıçta dalgalı bir seyir izlediği, ardından eğitim kaybıyla paralel ilerlediği, ancak süreç sonunda iki eğri arasındaki farkın yavaşça açılmaya başladığı görülmektedir. Bu durum, modelin başlangıçta kararlı bir öğrenme süreci geçirdiğini fakat ilerleyen aşamalarda kısmi aşırı öğrenme eğilimi sergilediğini göstermektedir.

Çizelge 4.7’de Heybe Kavşağı 37889-37887 güzergahı (ham veri) için derin öğrenme modellerinin eğitim ve test süreçlerindeki performans metrikleri kapsamlı bir şekilde sunulmuştur. Her model, eğitim ve test aşamalarındaki hata oranları (MSE, MAE) ve başarı oranları (R^2) ile karşılaştırılmıştır.

Çizelge 4.7. Heybe Kavşağı 37889-37887 güzergahı (ham veri) için derin öğrenme modellerinin performans metriklerinin karşılaştırılması

Model	Eğitim MSE	Test MSE	Eğitim MAE	Test MAE	Eğitim R^2	Test R^2
LSTM	480.252	597.419	16.348	18.712	0.757	0.730
BiLSTM	477.971	593.148	16.265	18.62	0.758	0.732
GRU	471.963	590.996	16.142	18.575	0.761	0.733
LSTM + CNN	468.439	614.84	15.943	18.804	0.763	0.722
RNN	484.39	622.128	16.485	19.032	0.755	0.719
Dikkat Mekanizması Tabanlı LSTM	479.878	657.753	16.219	19.587	0.757	0.703
Yığınlanmış LSTM	485.706	614.834	16.405	18.981	0.754	0.722
LSTM + GRU	475.658	587.428	16.264	18.557	0.759	0.735
Ortalama	478.032	609.818	16.259	18.858	0.758	0.725

Eğitim metriklerine göre:

- En düşük Eğitim MSE değeri LSTM + CNN modelinde (468.439) elde edilmiştir. Bu, modelin eğitim verisindeki hata oranının diğer modellere göre daha düşük olduğunu göstermektedir.
- Eğitim MAE değerinde de en iyi performans LSTM + CNN modeline (15.943) aittir. Bu, hata büyüklüğünün görece düşük olduğunu göstermektedir.
- Eğitim R^2 değeri bakımından en yüksek performans LSTM + CNN modeli (0.763) ile elde edilmiştir. Bu, modelin eğitim verilerine oldukça iyi uyum sağladığını göstermektedir.

Test metriklerine göre:

- En düşük Test MSE değeri LSTM + GRU modelinde (587.428) görülmektedir. Bu, test verisindeki hata oranının en düşük seviyede olduğunu göstermektedir.
- Test MAE açısından en iyi performans yine LSTM + GRU modelinde (18.557) elde edilmiştir. Bu, modelin test verisindeki tahminlerinde daha az hata yaptığını göstermektedir.
- Test R^2 değeri bakımından en iyi performans LSTM + GRU modelinde (0.735) görülmektedir.

Heybe Kavşağı 37889-37887 istikameti (ham veri) genel değerlendirme:

- LSTM + GRU modeli, hem test MSE/MAE değerlerinde en düşük hata oranlarını hem de en yüksek test R^2 değerini vererek ham veri için en başarılı model olmuştur.
- LSTM + CNN modeli, eğitim sürecinde en düşük hata oranlarına ve en yüksek R^2 değerine ulaşmıştır, ancak test setinde LSTM + GRU kadar başarılı olamamıştır.

4.2. Türkay Kavşağı Veri Seti

Atatürk Bulvarı ile Gazi Mustafa Kemal Bulvarı kesişiminde yer alan sinyalizasyon kavşağına ait araç sayım verileri, 14 Şubat 2023 ile 3 Ağustos 2023 tarihleri arasında, toplam 170 günlük bir süreyi kapsamaktadır. Bu veriler, Antalya Trafik Kontrol Merkezi tarafından temin edilmiştir.


Analiz için kullanılan veri seti, kavşağına 5 saniye aralıklarla gelen araç sınıflarının (otomobil, motosiklet, minibüs ve kamyon) sayılarını içermektedir. Bu kapsamlı veri seti, toplamda 733.809 satırdan oluşmaktadır. Veri setinin detaylı analizi, araç sınıflarının trafik akışına etkisini anlamak ve kavşak performansını değerlendirmek amacıyla gerçekleştirilmiştir.

Çizelge 4.8’de Türkay Kavşağına ait oto sinyal verici grupları, geliş kolları ile yön bazlı eşleştirilmiştir.


Çizelge 4.8. Kavşak kontrol cihazına ait kimlik bilgileri ile yön isimlerinin eşleştirilmesi

ID	KkcId	Yön İsimleri
37860	9704	R1-Q6/Q8-Kemer Geliş
37861	9704	R2-Q9-Uncalı Geliş
37862	9704	R3-Q5/Q7-Merkez Geliş
37863	9704	R4-Q10-Sahil Geliş


Türkey Kavşağı'na ait trafik hacmi ve araç sınıflarına yönelik veriler analiz edilmiştir. Şekil 4.49'da görüldüğü üzere, otomobil sınıfı araçlar en yüksek orana sahipken, motosiklet sınıfındaki araçların da dikkate değer bir yoğunlukta olduğu gözlemlenmiştir. Bu durum, trafik akışının araç sınıfları açısından çeşitlilik gösterdiğini ve kavşağın farklı araç türleri açısından yoğun bir geçiş noktası olduğunu ortaya koymaktadır.



(a)



(b)




(c)

Şekil 4.49. Türkay Kavşağı trafik hacim verileri a) geliş istikameti; b) gidiş istikameti; c) dönüş istikameti

Analiz sonuçlarına göre Merkez İstikameti (Yön 3) ve Kemer İstikameti (Yön 1) ana arterlerinden gelen araç sayılarının diğer yönlerden daha fazla olduğu, dolayısıyla asıl trafik yoğunluğunun bu kollarda yaşandığı gözlemlenmiştir. Trafik hacim verilerine göre

büyükten küçüğe doğru bir sıralama yapıldığında Yön 3 (ID 37862), Yön 1 (ID 37860), Yön 2 (ID 37861), Yön 4 (ID 37863) olacak şekilde kavşağa geliş güzergahları sıralanmıştır. Ayrıca motosiklet sınıfından olan araçların yoğunluk olarak kavşağa ana arterlerden geldikleri ve bunların çoğunluğunun ana aks üzerinden kavşaktan ayrıldığı görülmüştür.


Şekil 4.50’de Türkay Kavşağı için güzergahlara göre gözlem sayılarının dağılımı gösterilmektedir. Grafik, veri setinde farklı güzergahlardan toplanan gözlem sayısını temsil etmektedir. Bazı güzergahlarda gözlem sayısının diğerlerine göre belirgin şekilde düşük olduğu görülmektedir. Bu durum, belirli güzergahlarda veri toplama yoğunluğunun veya sıklığının daha az olduğunu göstermekte olup, güzergahlar arasında veri setindeki temsiliyet farklılıklarını ortaya koymaktadır.




Şekil 4.50. Türkay Kavşağı’ndaki güzergahlara göre gözlem sayıları

4.2.1. Türkay Kavşağı 37860-37862 istikameti farklı zaman dilimlerine göre trafik hacimleri


Bu bölümde, 37860-37862 güzergahına ait trafik hacim verileri analiz edilmiştir. Veri seti, belirli bir zaman dilimi boyunca toplanan 5 dakikalık gözlemlerden oluşmaktadır. Şekil 4.51’de, farklı zaman dilimlerinde (15 dakika, saatlik, günlük, haftalık ve aylık) araç sınıflarına göre trafik akışındaki değişimler gösterilmektedir. Otomobil sınıfı araçlar, tüm zaman dilimlerinde en yoğun araç türü olarak dikkat çekerken, motosiklet ve diğer araç türlerinin hacmi nispeten daha düşük seviyelerde seyretmektedir. Özellikle haziran ayından itibaren minibüs araç sınıfının ani ve aşırı bir şekilde artmış olması sayım verilerinde sistemsal bir hata olduğunu göstermektedir.




(a)




(b)



(c)




(d)



(e)


Şekil 4.51. Türkay Kavşağı 37860-37862 güzergahı araç sayımları a) 15 dakikalık; b) saatlik; c) günlük; d) haftalık; e) aylık

Şekil 4.52’de, her bir araç sınıfının trafik hacmine yaptığı katkı ve toplam trafik yoğunluğu PCU cinsinden gösterilmiştir. Özellikle haziran ayı itibarıyla toplam trafik hacminde belirgin bir artış gözlemlenmiştir. Ancak, bu artışın minibüs araç sınıfındaki sistemsel hata nedeniyle gerçekleşmiş olabileceği değerlendirilmektedir. Araç sınıflarına yapılan dönüştürmeler ve veri setindeki sapmaların sistematik analiz edilmesi, bu tür anomalilerin daha iyi anlaşılmasına olanak sağlamıştır.



Şekil 4.52. Türkiye Kavşağı 37860-37862 güzergahındaki araç sınıflarına göre PCU cinsinden trafik hacim dağılımı

Trafik verileri arasındaki ilişkiler, korelasyon matrisi yardımıyla değerlendirilmiştir. Şekil 4.53'te yer alan korelasyon matrisi, araç sınıflarının birbirleriyle ve toplam araç sayısı ile olan ilişki derecelerini görselleştirmektedir. Özellikle otomobil, motosiklet ve minibüs sınıfının toplam trafik hacmiyle yüksek oranda pozitif korelasyona sahip olduğu, tır sınıfının ise diğer araç türlerine göre daha düşük bir korelasyon gösterdiği tespit edilmiştir. Bu durum, sistemsel hata kaynaklı anomalinin toplam trafik hacmi üzerindeki etkisini daha iyi açıklamaktadır.






Şekil 4.53. Türkiye Kavşağı 37860-37862 güzergahına ait araç sınıflarının korelasyon matrisi

4.2.2. Türkiye Kavşağı 37860-37862 istikameti aykırılık analizi ve temizleme yöntemlerinin karşılaştırılması

Bu bölümde, 37860-37862 güzergahına ait veri seti üzerinde Z-Score, Mahalanobis Mesafesi ve PCA yöntemleri aykırılık tespit etmek amacıyla uygulanmıştır.

Şekil 4.54'te, her bir aykırılık tespit yöntemi ile belirlenen aykırılıklar görselleştirilmiştir. Z-Score yöntemiyle 92, Mahalanobis Mesafesiyle 237 ve PCA yöntemiyle 119 aykırılık tespit edilmiştir.







(c)

Şekil 4.54. Türkay Kavşağı aykırılık tespit yöntemleri **a)** Z-Skoru; **b)** Mahalanobis mesafesiyle; **c)** PCA


Veri setinden aykırı değerler çıkarıldıktan sonra temizlenmiş veri setleri üzerinde çeşitli makine öğrenimi modelleri eğitilmiş ve performans metrikleri karşılaştırılmıştır. Şekil 4.55'te Mahalanobis, Şekil 4.56'da PCA ve Şekil 4.57'de Z-Score yöntemlerine göre modellenmiş verilerin performans metrikleri sunulmuştur.



(a)




(b)




(c)


Şekil 4.55. Mahalanobis modeli performans karşılaştırması a) MSE; b) MAE; c) R^2



(a)




(b)




(c)


Şekil 4.56. PCA modeli performans karşılaştırması a) MSE; b) MAE; c) R^2



(a)



(b)



(c)

Şekil 4.57. Z-Score modeli performans karşılaştırması a) MSE; b) MAE; c) R^2


Çizelge 4.9’da sırasıyla Z-Score, Mahalanobis ve PCA yöntemlerine ait performans metrikleri (MSE, MAE, R^2) özetlenmiştir. Mahalanobis yöntemi ile temizlenen veri seti, yüksek R^2 değeri ve düşük hata oranlarıyla en iyi performansı göstermiştir. PCA yöntemi ise dengeli bir performans sergilerken, Z-Score yöntemi belirli modellerde öne çıkmıştır.

Çizelge 4.9. Aykırılık tespit yöntemlerinin performans metrikleri bakımından karşılaştırılması


Model	MSE			MAE			R ²		
Doğrusal Regresyon	1072.120	1039.306	1077.904	26.790	26.545	26.831	0.368	0.380	0.370
Karar Ağaçları	537.400	513.318	526.095	17.363	17.092	17.189	0.683	0.694	0.693
KNN	672.348	581.686	656.913	19.287	18.210	18.898	0.603	0.653	0.616
MLP	560.301	1006.487	556.155	17.789	25.781	17.659	0.669	0.400	0.675
Rastgele Orman	537.369	513.350	526.128	17.362	17.094	17.190	0.683	0.694	0.693
Gradyan Artırma	537.325	513.346	526.187	17.367	17.094	17.193	0.683	0.694	0.693
Elastic Net	1072.094	1039.026	1077.903	26.792	26.547	26.834	0.368	0.380	0.370
AdaBoost	569.470	551.390	558.672	18.305	18.149	18.084	0.664	0.671	0.674
Bagging	537.204	513.381	526.082	17.366	17.093	17.187	0.683	0.694	0.693
Voting	672.065	646.887	670.859	20.617	20.367	20.595	0.604	0.614	0.608
Stacking	537.349	513.326	526.082	17.363	17.094	17.188	0.683	0.694	0.693

4.2.3. Türkay Kavşağı 37860-37862 istikameti aykırılık analizi sonrası derin öğrenme modellerinin eğitimi

Trafik verilerinin işlenmesi ve aykırılık analizinin ardından, Türkay Kavşağı 37860-37862 istikametine ait veri seti sekiz farklı derin öğrenme modeli (LSTM, BiLSTM, GRU, LSTM+CNN, RNN, Dikkat Mekanizması Tabanlı LSTM, Yığınlanmış LSTM ve LSTM+GRU) ile eğitilmiştir. Aykırılıklardan arındırılmış bileşenlerle oluşturulan bu veri seti, modellerin performanslarını değerlendirmek amacıyla analiz edilmiştir. Modellerin çıktıları aşağıda görselleştirmelerle birlikte sunulmuş olup, tahmin grafiklerinde mavi çizgi gerçek değerleri, turuncu çizgi ise model tarafından üretilen tahminleri göstermektedir. Kayıp grafiklerinde ise mavi çizgi eğitim kaybını, turuncu çizgi doğrulama kaybını temsil etmektedir. Bu görselleştirmeler, modellerin hem tahmin doğruluğunu hem de eğitim sürecindeki öğrenme davranışlarını değerlendirmek amacıyla kullanılmıştır.



(a)




(b)

Şekil 4.58. Türkay Kavşağı 37860-37862 istikameti (aykırılıklardan arındırılmış veri) için (a) LSTM modeli; (b) doğrulama grafiği


Şekil 4.58’de Türkay Kavşağı 37860-37862 istikameti (aykırılıklardan arındırılmış veri) için LSTM modeline ait çıktılar gösterilmiştir:

- Şekil 4.58(a) tahmin grafiğinde görüldüğü üzere, LSTM modeli genel trafik eğilimini yakalamış ve periyodik dalgalanmaları belirli bir düzeyde temsil edebilmiştir. Ancak ham veri kullanılması nedeniyle yüksek pik değerlerinde sapmalar daha belirginleşmiş, modelin ani yoğunluk artışlarını tam olarak yansıtmakta sınırlı kaldığı görülmüştür.

- Şekil 4.58(b) doğrulama grafiğinde ise eğitim kaybının düzenli olarak azaldığı, doğrulama kaybının ise başlangıçta dalgalı bir seyir izledikten sonra daha dengeli bir yapıya kavuştuğu gözlenmiştir. Bununla birlikte, eğitim ve doğrulama kayıpları arasındaki mesafenin giderek artması, modelin kısmi aşırı öğrenme eğilimi gösterdiğini ve genelleme kapasitesinin sınırlı kaldığını ortaya koymaktadır.



(a)




(b)

Şekil 4.59. Türkay Kavşağı 37860-37862 istikameti (aykırılıklardan arındırılmış veri) için (a) BiLSTM modeli; (b) doğrulama grafiği


Şekil 4.59’da Türkay Kavşağı 37860-37862 istikameti (aykırılıklardan

arındırılmış veri) için BiLSTM modeline ait çıktılar gösterilmiştir:

- Şekil 4.59(a) tahmin grafiğinde görüldüğü üzere BiLSTM modeli, gerçek değerlerle tahmin değerlerini genel eğilim açısından büyük ölçüde uyumlu şekilde yakalamıştır. Özellikle orta yoğunluk seviyelerinde başarılı tahminler üretilmiş, ancak yüksek pik değerlerinde kısmi sapmaların gözlemlendiği tespit edilmiştir. Bu durum, modelin ani trafik yoğunluklarını tam olarak temsil etmede sınırlı kaldığını göstermektedir.
- Şekil 4.59(b) doğrulama grafiğinde, eğitim kaybının düzenli biçimde azaldığı, doğrulama kaybının ise başlangıçta dalgalı bir seyir izledikten sonra belirli bir seviyede dengelendiği görülmektedir. Ancak süreç ilerledikçe doğrulama kaybı ile eğitim kaybı arasındaki farkın kısmen açıldığı dikkat çekmektedir. Bu durum, modelin genelleme kapasitesinin sınırlı olmakla birlikte belirli bir kararlılıkla sürdüğünü ortaya koymaktadır.



(a)




(b)


Şekil 4.60. Türkay Kavşağı 37860-37862 istikameti (aykırılıklardan arındırılmış veri) için (a) GRU modeli; (b) doğrulama grafiği

Şekil 4.60'ta Türkay Kavşağı 37860-37862 istikameti (aykırılıklardan arındırılmış veri) için GRU modeline ait çıktılar gösterilmiştir:

- Şekil 4.60(a) tahmin grafiğinde GRU modelinin, trafik akışındaki periyodik dalgalanmaları büyük ölçüde yakalayabildiği, orta yoğunluk seviyelerinde tahmin performansının güçlü olduğu görülmektedir. Ancak, yüksek pik değerlerinde tahminlerin gerçek değerlerden sapma eğiliminde olduğu ve modelin ani trafik artışlarını tam olarak yansıtmakta zorlandığı tespit edilmiştir.
- Şekil 4.60(b) doğrulama grafiğinde, eğitim kaybının düzenli şekilde azaldığı, doğrulama kaybının ise başlangıçta dalgalı bir seyir izlediği, daha sonra eğitim kaybıyla paralel ilerlediği görülmektedir. Ancak ilerleyen epoklarda eğitim ve doğrulama kaybı arasındaki farkın yavaş yavaş açıldığı gözlemlenmiştir. Bu durum, modelin kısmi aşırı öğrenme eğilimine girdiğini ve genelleme kapasitesinde sınırlılıklar bulunduğunu göstermektedir.



(a)



(b)


Şekil 4.61. Türkay Kavşağı 37860-37862 istikameti (aykırılıklardan arındırılmış veri) için **(a)** LSTM + CNN modeli; **(b)** doğrulama grafiği

Şekil 4.61’de Türkay Kavşağı 37860–37862 istikameti (aykırılıklardan arındırılmış veri) için LSTM + CNN modeline ait çıktılar gösterilmiştir:


- Şekil 4.61(a) tahmin grafiğinde görüldüğü üzere LSTM + CNN modeli, trafik akışındaki periyodik yapıları başarılı şekilde yakalamış ve tahmin değerleri genel eğilim açısından gerçek değerlere yakın bir seyir izlemiştir. Orta yoğunluk seviyelerinde güçlü bir uyum sağlanırken, yüksek pik değerlerinde belirgin

sapmalar görülmüş, bu da modelin ani trafik yoğunluklarını tam olarak yansıtmakta sınırlı kaldığını göstermektedir.

- Şekil 4.61(b) doğrulama grafiğinde eğitim kaybının düzenli bir azalma eğiliminde olduğu, doğrulama kaybının ise başlarda dalgalı bir yapı gösterdiği, sonrasında eğitim kaybına paralel şekilde ilerlediği ve daha sonraki dönemlerde iki eğri arasındaki farkın kademeli olarak artmaya başladığı gözlemlenmektedir. Bu durum, modelin genel eğilimleri öğrenebildiğini ancak kısmi düzeyde aşırı öğrenme eğilimi gösterdiğini ortaya koymaktadır.



(a)




(b)


Şekil 4.62. Türkay Kavşağı 37860-37862 istikameti (aykırılıklardan arındırılmış veri) için (a) RNN modeli; (b) doğrulama grafiği

Şekil 4.62’de Türkay Kavşağı 37860-37862 istikameti (aykırılıklardan arındırılmış veri) için RNN modeline ait çıktılar gösterilmiştir:

- Şekil 4.62(a) tahmin grafiğinde RNN modeli, trafik akışındaki periyodik dalgalanmaları genel hatlarıyla yakalamış ve orta düzey yoğunluklarda tahminleriyle gerçek değerler arasında uyum sağlamıştır. Bununla birlikte, yüksek pik değerlerinde belirgin sapmalar gözlenmiş, modelin ani trafik artışlarını temsil etmede sınırlı kaldığı görülmüştür.
- Şekil 4.62(b) eğitim ve doğrulama kayıplarını göstermektedir. Başlangıçta doğrulama kaybında dalgalanmalar olsa da zamanla eğri daha istikrarlı bir yapıya kavuşmuştur. Ancak, eğitim ve doğrulama kayıpları arasında belirli bir farkın korunması modelin genelleme kapasitesinin kısmen sınırlı olduğunu göstermektedir.



(a)




(b)


Şekil 4.63. Türkay Kavşağı 37860-37862 istikameti (aykırılıklardan arındırılmış veri) için (a) Dikkat Mekanizması Tabanlı LSTM modeli; (b) doğrulama grafiği

Şekil 4.63'te Türkay Kavşağı 37860-37862 istikameti (aykırılıklardan arındırılmış veri) için Dikkat Mekanizması Tabanlı LSTM modeline ait çıktılar gösterilmiştir:

- Şekil 4.63(a): Tahmin grafiğinde modelin trafik akışındaki periyodik dalgalanmaları ve genel eğilimi başarılı şekilde yakaladığı, tahmin değerlerinin gerçek değerlere genel olarak uyum sağladığı görülmektedir. Bununla birlikte, belirli noktalarda sapmalar gözlenmiş ve model bu değerleri tam olarak yansıtmakta sınırlı kalmıştır.
- Şekil 4.63(b): Doğrulama grafiğinde eğitim kaybının düzenli bir biçimde azaldığı, doğrulama kaybının ise başlangıçta dalgalanmalar gösterdiği, ardından daha dengeli bir seyir izlediği görülmektedir. Eğitim ve doğrulama kayıpları arasındaki farkın süreç içerisinde kısmen açıldığı gözlenmiştir. Bu durum, modelin genelleme kapasitesinin sınırlı olduğunu ve kısmi aşırı öğrenme eğilimi gösterdiğini ortaya koymaktadır.



(a)




(b)

Şekil 4.64. Türkay Kavşağı 37860-37862 istikameti (aykırılıklardan arındırılmış veri) için (a) Yığınlanmış LSTM modeli; (b) doğrulama grafiği


Şekil 4.64'te Türkay Kavşağı 37860-37862 istikameti (aykırılıklardan arındırılmış veri) için Yığınlanmış LSTM modeline ait çıktılar gösterilmiştir:

- Şekil 4.64(a) tahmin grafiğinde görüldüğü üzere Yığınlanmış LSTM modeli, trafik akışının genel eğilimini başarılı bir şekilde yakalamış ve gerçek değerlerle tahmin değerleri arasında belirgin bir uyum sağlamıştır. Ancak ham veri kullanımı nedeniyle özellikle ani değişimlerde modelin sapmalar gösterdiği dikkati çekmektedir.

- Şekil 4.64(b) eğitim ve doğrulama kayıpları incelendiğinde, her iki eğrinin de genel olarak azalma eğiliminde olduğu görülmektedir. Başlangıçta doğrulama kaybı dalgalı bir seyir izlese de ilerleyen epoklarda daha kararlı bir yapıya ulaşmıştır. Bununla birlikte, eğitim ve doğrulama kayıpları arasındaki mesafenin zamanla açılması, modelde kısmi bir aşırı öğrenme eğilimi olabileceğini göstermektedir.



(a)



(b)

Şekil 4.65. Türkay Kavşağı 37860-37862 istikameti (aykırılıklardan arındırılmış veri) için (a) LSTM + GRU modeli; (b) doğrulama grafiği

Şekil 4.65'te Türkay Kavşağı 37860-37862 istikameti (aykırılıklardan

arındırılmış veri) için LSTM + GRU modeline ait çıktılar gösterilmiştir:

- Şekil 4.65(a) tahmin grafiğinde modelin trafik akışındaki periyodik dalgalanmaları yakalayabildiği ve gerçek değerlerle tahmin değerleri arasında genel olarak uyum sağladığı görülmektedir. Bununla birlikte, ani artışların yaşandığı noktalarda modelin tahminleri kısmi sapmalar göstermiştir.
- Şekil 4.65(b) eğitim ve doğrulama kayıpları grafiğinde ise başlangıçta doğrulama kaybının dalgalı bir seyir izlediği, ilerleyen epoklarda eğitim kaybı ile paralel bir azalış eğilimine girdiği gözlemlenmiştir. Ancak süreç ilerledikçe eğitim ve doğrulama kaybı arasındaki fark yavaş yavaş artmıştır. Bu durum, modelin genel öğrenme sürecinde aşırı öğrenme eğilimine kısmen yatkın olduğunu ve genelleme kapasitesinin sınırlı bir seviyede kaldığını göstermektedir.

Çizelge 4.10'da Türkay Kavşağı 37860-37862 güzergahı (aykırılıklardan arındırılmış veri) için derin öğrenme modellerinin eğitim ve test süreçlerindeki performans metrikleri kapsamlı bir şekilde sunulmuştur. Her model, eğitim ve test aşamalarındaki hata oranları (MSE, MAE) ve başarı oranları (R^2) ile karşılaştırılmıştır.

Çizelge 4.10. Türkay Kavşağı 37860-37862 güzergahı (aykırılıklardan arındırılmış veri) için derin öğrenme modellerinin performans metriklerinin karşılaştırılması

Model	Eğitim MSE	Test MSE	Eğitim MAE	Test MAE	Eğitim R^2	Test R^2
LSTM	342.399	432.66	14.027	15.519	0.779	0.787
BiLSTM	348.989	427.962	14.152	15.423	0.775	0.789
GRU	338.588	435.811	13.903	15.601	0.782	0.785
LSTM + CNN	340.341	445.574	13.936	15.687	0.78	0.78
RNN	344.123	450.428	14.053	15.696	0.778	0.778
Dikkat Mekanizması Tabanlı LSTM	362.61	471.008	14.451	16.057	0.766	0.768
Yığınlanmış LSTM	352.314	466.219	14.214	15.957	0.773	0.77
LSTM + GRU	342.32	453.53	13.948	15.752	0.779	0.776
Ortalama	346.460	447.899	14.086	15.712	0.776	0.779

Eğitim metriklerine göre:

- En düşük Eğitim MSE değerine GRU modeli (338.588) sahiptir. Bu, GRU modelinin eğitim verisindeki hata oranının diğer modellere göre daha düşük olduğunu göstermektedir.

- Eğitim MAE değerlerinde de GRU modeli (13.903) öne çıkmaktadır. Bu, modelin hata büyüklüğünün az olduğunu ifade etmektedir.
- Eğitim R^2 değeri açısından en iyi performans yine GRU modeli (0.782) ile elde edilmiştir. Bu, modelin eğitim verilerine oldukça iyi uyum sağladığını göstermektedir.

Test metriklerine göre:


- En düşük Test MSE değeri BiLSTM modelinde (427.962) görülmektedir. Bu, test verisindeki hata oranının diğer modellere göre düşük olduğunu göstermektedir.
- Test MAE açısından en iyi performans yine BiLSTM modelinde (15.423) elde edilmiştir. Bu, modelin test verisindeki tahminlerinde daha az hata yaptığını göstermektedir.
- Test R^2 değerinde en iyi performans BiLSTM modelinde (0.789) gözlenmiştir.

Türkay Kavşağı 37860-37862 istikameti (aykırılıklardan arındırılmış veri) genel değerlendirme:


- BiLSTM modeli, test metriklerinde (en düşük MSE ve MAE, en yüksek R^2) sağladığı başarı ile en iyi model olmuştur.
- GRU modeli, eğitim metriklerinde en başarılı sonuçları elde etmiş, ancak test performansı BiLSTM kadar güçlü olmamıştır.

4.2.4. Türkay Kavşağı 37860-37862 istikameti ham veri ile derin öğrenme modellerinin eğitimi

Türkay Kavşağı 37860-37862 istikametine ait ham veri seti, sekiz farklı derin öğrenme modeli (LSTM, BiLSTM, GRU, LSTM+CNN, RNN, Dikkat Mekanizması Tabanlı LSTM, Yığınlanmış LSTM ve LSTM+GRU) kullanılarak eğitilmiştir. Veri temizleme işlemleri uygulanmadan oluşturulan bu veri seti, modellerin performanslarını karşılaştırmak amacıyla analiz edilmiştir. Modellerin çıktıları aşağıda görselleştirmelerle birlikte sunulmuş olup, tahmin grafiklerinde mavi çizgi gerçek değerleri, turuncu çizgi ise model tarafından tahmin edilen değerleri göstermektedir. Kayıp grafiklerinde ise mavi çizgi eğitim kaybını, turuncu çizgi doğrulama kaybını temsil etmektedir. Bu görselleştirmeler, modellerin hem tahmin başarısını hem de eğitim sürecindeki öğrenme davranışlarını değerlendirmek amacıyla kullanılmıştır.



(a)




(b)

Şekil 4.66. Türkay Kavşağı 37860-37862 istikameti (ham veri) için (a) LSTM modeli; (b) doğrulama grafiği


Şekil 4.66’da 37860-37862 istikameti (ham veri) için LSTM modeline ait çıktılar gösterilmiştir:

- Şekil 4.66(a) tahmin grafiğinde, LSTM modelinin genel eğilimi başarılı şekilde yakaladığı ve periyodik trafik akışını temsil edebildiği görülmektedir. Ancak yüksek pik değerlerinde sapmalar belirginleşmiş, model bu ani değişimleri tam olarak yansıtmakta sınırlı kalmıştır.
- Şekil 4.66(b) doğrulama grafiğinde, eğitim kaybının düzenli olarak azaldığı, doğrulama kaybının ise başlangıçta dalgalı bir seyir izlediği, sonrasında eğitim

kaybı ile paralel ilerlediği görülmektedir. Sürecin ilerleyen aşamalarında eğitim ve doğrulama kaybı arasındaki farkın kademeli olarak artması, modelin kısmi aşırı öğrenme eğilimi gösterdiğini ortaya koymaktadır.



(a)




(b)


Şekil 4.67. Türkay Kavşağı 37860-37862 istikameti (ham veri) için (a) BiLSTM modeli; (b) doğrulama grafiği

Şekil 4.67’de 37860-37862 istikameti (ham veri) için BiLSTM modeline ait çıktılar gösterilmiştir:

- Şekil 4.67(a) tahmin grafiğinde görüldüğü üzere BiLSTM modeli, gerçek değerlerle tahmin değerlerini genel eğilim açısından uyumlu şekilde yakalamış ve periyodik trafik dalgalanmalarını başarılı biçimde temsil etmiştir. Ancak pik değerlerinde sapmalar gözlenmiş, model bu ani değişimleri tam olarak yansıtmakta sınırlı kalmıştır.
- Şekil 4.67(b) doğrulama grafiğinde, eğitim kaybının düzenli olarak azaldığı, doğrulama kaybının ise başlangıçta dalgalı bir seyir izledikten sonra daha istikrarlı bir yapıya ulaştığı görülmektedir. Ancak eğitim ve doğrulama eğrileri arasındaki farkın zamanla artması, modelin kısmi aşırı öğrenme eğilimi gösterdiğini ortaya koymaktadır.



(a)




(b)


Şekil 4.68. Türkiye Kavşağı 37860-37862 istikameti (ham veri) için (a) GRU modeli; (b) doğrulama grafiği

Şekil 4.68’de 37860-37862 istikameti (ham veri) için GRU modeline ait çıktılar gösterilmiştir:

- Şekil 4.68(a) tahmin grafiğinde görüldüğü üzere GRU modeli, gerçek değerlerle tahmin değerlerini genel eğilim açısından uyumlu şekilde yakalamış ve periyodik trafik dalgalanmalarını başarılı biçimde temsil etmiştir. Bununla birlikte, tahminlerde zaman zaman sapmalar görülmüş, bu durum modelin ani değişimleri tam olarak yansıtmakta sınırlı kaldığını göstermektedir.
- Şekil 4.68(b) doğrulama grafiğinde, eğitim kaybının düzenli olarak azaldığı, doğrulama kaybının ise genel olarak istikrarlı bir seyir izlediği görülmektedir. Sürecin ilerleyen aşamalarında eğitim ve doğrulama eğrileri arasındaki farkın kademeli olarak artması, modelin kısmi aşırı öğrenme eğilimi gösterdiğini ortaya koymaktadır.



(a)




(b)

Şekil 4.69. Türkay Kavşağı 37860-37862 istikameti (ham veri) için (a) LSTM + CNN modeli; (b) doğrulama grafiği


Şekil 4.69'da 37860-37862 istikameti (ham veri) için LSTM + CNN modeline ait çıktılar gösterilmiştir:

- Şekil 4.69(a) tahmin grafiğinde görüldüğü üzere LSTM + CNN modeli, trafik akışındaki periyodik dalgalanmaları başarılı biçimde öğrenmiş ve tahmin değerlerini gerçek değerlere yakın şekilde üretmiştir. Genel eğilim uyumlu olsa da pik seviyelerinde belirli sapmalar gözlenmiştir.

- Şekil 4.69(b) eğitim ve doğrulama kayıpları incelendiğinde, eğitim kaybının düzenli olarak azaldığı ve doğrulama kaybının da belirli bir seviyede dengeye oturduğu görülmektedir. Eğitim ve doğrulama eğrileri arasındaki farkın giderek açılması, modelin kısmi bir aşırı öğrenme eğilimi gösterdiğini işaret etmektedir.



(a)




(b)


Şekil 4.70. Türkay Kavşağı 37860-37862 istikameti (ham veri) için (a) RNN modeli; (b) doğrulama grafiği

Şekil 4.70’te 37860-37862 istikameti (ham veri) için RNN modeline ait çıktılar gösterilmiştir:

- Şekil 4.70(a) tahmin grafiğinde görüldüğü üzere RNN modeli, gerçek değerlerle tahmin değerlerini genel eğilim açısından uyumlu şekilde yakalamış ve trafik akışındaki periyodik tekrarları büyük ölçüde temsil etmiştir. Bununla birlikte, bazı ani değişimlerde tahminlerin gerçek değerlere göre daha yumuşak seyrettiği gözlemlenmektedir.
- Şekil 4.70(b) doğrulama grafiğinde, eğitim kaybının hızlı bir düşüş sonrası düzenli bir şekilde azaldığı ve düşük seviyelerde seyrettiği, doğrulama kaybının ise başlangıçta eğitim kaybına paralel ilerledikten sonra dalgalı fakat görece dengeli bir yapıda kaldığı görülmektedir. Eğitim ve doğrulama kayıplarının birbirine yakın olması, modelin aşırı öğrenme eğilimi göstermediğini ve genel genelleme kapasitesinin kabul edilebilir düzeyde olduğunu ortaya koymaktadır.



(a)




(b)


Şekil 4.71. Türkiye Kavşağı 37860-37862 istikameti (ham veri) için (a) Dikkat Mekanizması Tabanlı LSTM modeli; (b) doğrulama grafiği

Şekil 4.71’de 37860-37862 istikameti (ham veri) için Dikkat Mekanizması Tabanlı LSTM modeline ait çıktılar gösterilmiştir:

- Şekil 4.71(a) tahmin grafiğinde görüldüğü üzere Dikkat Mekanizması Tabanlı LSTM modeli, gerçek değerlerle tahmin değerlerini genel eğilim açısından başarılı şekilde yakalamış ve trafik akışındaki periyodik örüntüleri tatmin edici düzeyde temsil etmiştir. Zaman zaman sınırlı sapmalar görülmektedir.
- Şekil 4.71(b) doğrulama grafiğinde, eğitim ve doğrulama kayıpları ilk epoklarda birlikte düşüş eğilimi göstermekte, sonrasında doğrulama kaybı daha yatay bir yapıya oturmaktadır. İlerleyen epoklarda eğitim ve doğrulama eğrileri arasındaki farkın kademeli olarak artması, modelin kısmi bir aşırı öğrenme eğilimi sergilediğine işaret etmektedir.



(a)




(b)

Şekil 4.72. Türkay Kavşağı 37860-37862 istikameti (ham veri) için **(a)** Yığılanmış LSTM modeli; **(b)** doğrulama grafiği


Şekil 4.72’de 37860-37862 istikameti (ham veri) için Yığılanmış LSTM modeline ait çıktılar gösterilmiştir:

- Şekil 4.72(a) tahmin grafiğinde görüldüğü üzere Yığılanmış LSTM modeli, gerçek değerlerle tahmin edilen değerler arasında genel bir uyum sağlamış, trafik akışındaki periyodik yapıları başarılı şekilde temsil etmiştir. Ancak ani piklerde modelin sınırlı kaldığı ve sapmaların olduğu gözlenmektedir.

- Şekil 4.72(b) doğrulama grafiğinde, eğitim kaybının düzenli biçimde azaldığı, doğrulama kaybının ise başlangıçta hızlı bir düşüş gösterdikten sonra daha dengeli bir yapıya ulaştığı görülmektedir. Bununla birlikte, ilerleyen epoklarda eğitim ve doğrulama kaybı arasındaki farkın yavaş yavaş artması, modelin kısmi aşırı öğrenme eğilimine girdiğini göstermektedir.



(a)



(b)

Şekil 4.73. Türkay Kavşağı 37860-37862 istikameti (ham veri) için (a) LSTM + GRU modeli; (b) doğrulama grafiği

Şekil 4.73'te 37860-37862 istikameti (ham veri) için LSTM + GRU modeline ait çıktılar gösterilmiştir:

- Şekil 4.73(a) tahmin grafiğinde görüldüğü üzere LSTM + GRU modeli, gerçek değerlerle tahmin edilen değerler arasında genel eğilim açısından güçlü bir uyum sağlamış ve trafik akışındaki periyodik yapıyı başarıyla temsil etmiştir. Ancak ani yükseliş ve düşüşlerde modelin belirli sınırlılıklar gösterdiği dikkati çekmektedir.
- Şekil 4.73(b) doğrulama grafiğinde, eğitim kaybının düzenli olarak azaldığı, doğrulama kaybının ise başlangıçta dalgalı bir seyir izledikten sonra daha istikrarlı bir seviyede ilerlediği görülmektedir. İlerleyen epoklarda eğitim ve doğrulama kayıpları arasındaki farkın açılmaya başlaması, modelin kısmi aşırı öğrenme eğilimine işaret etmektedir.

Çizelge 4.11'de Türkay Kavşağı 37860-37862 güzergahı (ham veri) için derin öğrenme modellerinin eğitim ve test süreçlerindeki performans metrikleri kapsamlı bir şekilde sunulmuştur. Her model, eğitim ve test aşamalarındaki hata oranları (MSE, MAE) ve başarı oranları (R^2) ile karşılaştırılmıştır.

Çizelge 4.11. Türkay Kavşağı 37860-37862 güzergahı (ham veri) için derin öğrenme modellerinin performans metriklerinin karşılaştırılması

Model	Eğitim MSE	Test MSE	Eğitim MAE	Test MAE	Eğitim R^2	Test R^2
LSTM	351.425	431.898	14.034	15.531	0.791	0.787
BiLSTM	355.982	433.816	14.096	15.544	0.788	0.786
GRU	339.566	428.158	13.761	15.443	0.798	0.789
LSTM + CNN	340.565	431.396	13.74	15.453	0.797	0.787
RNN	360.565	452.841	14.166	15.82	0.785	0.776
Dikkat Mekanizması Tabanlı LSTM	363.234	462.041	14.179	15.855	0.784	0.772
Yığınlanmış LSTM	355.847	451.482	13.985	15.69	0.788	0.777
LSTM + GRU	345.759	432.824	13.86	15.507	0.794	0.786
Ortalama	351.618	440.557	13.978	15.605	0.791	0.782

Eğitim metriklerine göre:

- En düşük Eğitim MSE değeri GRU modelinde (339.566) elde edilmiştir. Bu, GRU modelinin eğitim verisindeki hata oranının diğer modellere göre daha düşük olduğunu göstermektedir.

- Eğitim MAE açısından da en iyi performans yine GRU modeline (13.761) aittir. Bu, modelin hata büyüklüğünün düşük olduğunu göstermektedir.
- Eğitim R^2 değeri bakımından en yüksek performans yine GRU modeli (0.798) ile elde edilmiştir.

Test metriklerine göre:


- En düşük Test MSE değeri GRU modelinde (428.158) görülmektedir. Bu, test verisindeki hata oranının en düşük seviyede olduğunu göstermektedir.
- Test MAE açısından en iyi performans yine GRU modelinde (15.443) elde edilmiştir. Bu, modelin test verisindeki tahminlerinde hata büyüklüğünün daha az olduğunu göstermektedir.
- Test R^2 değeri bakımından en iyi performans GRU modelinde (0.789) gözlenmiştir.

Türkay Kavşağı 37860-37862 istikameti (ham veri) genel değerlendirme:


- GRU modeli, hem eğitim hem de test metriklerinde (düşük MSE ve MAE, yüksek R^2) en iyi sonuçları elde ederek en başarılı model olmuştur.
- LSTM + CNN modeli, eğitim sürecinde görece güçlü performans göstermiştir, ancak test metrikleri GRU'ya kıyasla daha zayıf kalmıştır.

4.2.5. Türkay Kavşağı 37862-37860 istikameti farklı zaman dilimlerine göre trafik hacimleri


Bu bölümde, 37862-37860 güzergahına ait trafik hacmi verileri analiz edilmiştir. Veri seti, belirli bir zaman dilimi boyunca toplanan 5 dakikalık gözlemlerden oluşmaktadır. Şekil 4.74'te, farklı zaman dilimlerinde (15 dakika, saatlik, günlük, haftalık ve aylık) araç sınıflarına göre trafik akışındaki değişimler görselleştirilmiştir. Otomobil sınıfı araçlar, tüm zaman dilimlerinde en yüksek yoğunluğu oluştururken, motosiklet ve diğer araç türlerinin hacmi görece daha düşük seviyelerde seyretmiştir. Bununla birlikte, haziran ayından itibaren otomobil araç sınıfının sayısında ani ve aşırı bir azalma gözlemlenmiş, aynı dönemde minibüs araç sınıfında dikkat çekici bir artış yaşanmıştır. Bu durum, sistemsal bir hata nedeniyle otomobil araç sınıfının minibüs olarak algılanmış olabileceğini göstermektedir.




(a)




(b)



(c)




(d)



(e)


Şekil 4.74. Türkiye Kavşağı 37862-37860 güzergahı araç sayımları a) 15 dakikalık; b) saatlik; c) günlük; d) haftalık; e) aylık

Şekil 4.75'te, her bir araç sınıfının trafik hacmine yaptığı katkı ve toplam trafik yoğunluğu PCU cinsinden gösterilmiştir. Özellikle haziran ayı itibarıyla toplam trafik hacminde belirgin bir artış gözlemlenmiştir. Ancak, bu artışın minibüs araç sınıfındaki sistemsel hata nedeniyle gerçekleşmiş olabileceği değerlendirilmektedir. Araç sınıflarına yapılan dönüştürmeler ve veri setindeki sapmaların sistematik analiz edilmesi, bu tür anomalilerin daha iyi anlaşılmasına olanak sağlamıştır.



Şekil 4.75. Türkiye Kavşağı 37862-37860 güzergahındaki araç sınıflarına göre PCU cinsinden trafik hacim dağılımı

Trafik verileri arasındaki ilişkiler, korelasyon matrisi yardımıyla değerlendirilmiştir. Şekil 4.76'da yer alan korelasyon matrisi, araç sınıflarının birbirleriyle ve toplam trafik hacmiyle olan ilişkilerini görselleştirmektedir. Bu analiz, tüm araç sınıflarının toplam trafik hacmine etkisinin benzer olduğunu ortaya koymaktadır. Özellikle otomobil ve minibüs araç sınıfları arasında yüksek bir korelasyon olduğu dikkat çekmektedir. Bu durum, sistemsal hata kaynaklı anomalinin toplam trafik hacmi üzerindeki etkisini daha iyi açıklamaktadır.






Şekil 4.76. Türkiye Kavşağı 37862-37860 güzergahındaki araç sınıflarının korelasyon matrisi

4.2.6. Türkiye Kavşağı 37862-37860 istikameti aykırılık analizi ve temizleme yöntemlerinin karşılaştırılması

Bu bölümde, 37862-37860 güzergahına ait veri seti üzerinde Z-Score, Mahalanobis Mesafesi ve PCA yöntemleri aykırılık tespit etmek amacıyla uygulanmıştır.

Şekil 4.77’de her bir aykırılık tespit yöntemi ile belirlenen aykırılıklar görselleştirilmiştir. Z-Score yöntemiyle 296, Mahalanobis Mesafesiyle 448 ve PCA yöntemiyle 538 aykırılık tespit edilmiştir.







(c)

Şekil 4.77. Türkay Kavşağı aykırılık tespit yöntemleri **a)** Z-Skoru; **b)** Mahalanobis mesafesiyle; **c)** PCA


Aykırı değerler temizlendikten sonra oluşturulan veri setleri, çeşitli makine öğrenimi modelleri üzerinde test edilmiştir. Şekil 4.78’de Mahalanobis, Şekil 4.79’da PCA ve Şekil 4.80’de Z-Score yöntemlerine göre modellenmiş verilerin performans metrikleri sunulmuştur.



(a)




(b)



(c)


Şekil 4.78. Mahalanobis modeli performans karşılaştırması a) MSE; b) MAE; c) R^2

Güzergah: 37862-37860 - PCA - Model Performans Karşılaştırması




(a)


Güzergah: 37862-37860 - PCA - Model Performans Karşılaştırması




(b)




(c)

Şekil 4.79. PCA modeli performans karşılaştırması a) MSE; b) MAE; c) R^2 

(a)



(b)



(c)

Şekil 4.80. Z-Score modeli performans karşılaştırması **a)** MSE; **b)** MAE; **c)** R^2


Çizelge 4.12’de sırasıyla Z-Score, Mahalanobis ve PCA yöntemlerine performans metrikleri (MSE, MAE, R^2) özetlenmiştir. Mahalanobis yöntemiyle temizlenen veri seti, yüksek R^2 değeri ve düşük hata oranlarıyla öne çıkmıştır. PCA yöntemi ise dengeli bir performans sergilerken, Z-Score yöntemi bazı modellerde avantaj sağlamıştır.

Çizelge 4.12. Aykırılık tespit yöntemlerinin performans metrikleri bakımından karşılaştırılması


Model	MSE			MAE			R ²		
Doğrusal Regresyon	1000.688	968.696	971.210	25.022	24.776	24.668	0.417	0.440	0.408
Karar Ağaçları	713.655	711.131	682.440	20.028	20.062	19.808	0.584	0.589	0.584
KNN	863.680	912.208	789.840	22.015	22.602	21.158	0.497	0.473	0.518
MLP	779.395	769.370	744.912	20.830	20.869	20.592	0.546	0.555	0.546
Rastgele Orman	713.678	711.118	682.542	20.027	20.064	19.809	0.584	0.589	0.584
Gradyan Artırma	713.626	711.099	682.403	20.028	20.062	19.807	0.584	0.589	0.584
Elastic Net	1000.691	968.706	971.192	25.024	24.778	24.670	0.417	0.440	0.408
AdaBoost	765.975	751.200	724.006	21.266	21.116	20.941	0.554	0.566	0.558
Bagging	713.697	711.088	682.607	20.026	20.057	19.808	0.584	0.589	0.584
Voting	785.703	773.775	755.811	21.687	21.630	21.401	0.542	0.553	0.539
Stacking	713.767	711.197	682.457	20.032	20.064	19.807	0.584	0.589	0.584

4.2.7. Türkay Kavşağı 37862-37860 istikameti aykırılık analizi sonrası derin öğrenme modellerinin eğitimi

Trafik verilerinin işlenmesi ve aykırılık analizinin ardından, Türkay Kavşağı 37862-37860 istikametine ait veri seti sekiz farklı derin öğrenme modeli (LSTM, BiLSTM, GRU, LSTM+CNN, RNN, Dikkat Mekanizması Tabanlı LSTM, Yığınlanmış LSTM ve LSTM+GRU) ile eğitilmiştir. Aykırılıklardan arındırılmış bileşenlerle oluşturulan bu veri seti, modellerin performanslarını değerlendirmek amacıyla analiz edilmiştir. Modellerin çıktıları aşağıda görselleştirmelerle birlikte sunulmuş olup, tahmin grafiklerinde mavi çizgi gerçek değerleri, turuncu çizgi ise model tarafından üretilen tahminleri göstermektedir. Kayıp grafiklerinde ise mavi çizgi eğitim kaybını, turuncu çizgi doğrulama kaybını temsil etmektedir. Bu görselleştirmeler, modellerin hem tahmin doğruluğunu hem de eğitim sürecindeki öğrenme davranışlarını değerlendirmek amacıyla kullanılmıştır.



(a)



(b)


Şekil 4.81. Türkay Kavşağı 37862-37860 istikameti (aykırılıklardan arındırılmış veri) için (a) LSTM modeli; (b) doğrulama grafiği

Şekil 81’de 37862-37860 istikameti (aykırılıklardan arındırılmış veri) için LSTM modeline ait çıktılar gösterilmiştir:


- Şekil 4.81(a) tahmin grafiğinde görüldüğü üzere LSTM modeli, gerçek değerler ile tahmin değerlerini genel eğilim açısından oldukça uyumlu biçimde yakalamıştır. Trafik akışındaki periyodik dalgalanmalar başarıyla temsil edilmiş, tahmin edilen değerler ile gerçek değerler arasında benzer bir ritim

gözlemlenmiştir. Ancak bazı pik noktalarda sapmalar oluşmuş, bu da modelin ani değişimlere duyarlılığının sınırlı olduğunu göstermektedir.

- Şekil 4.81(b) eğitim ve doğrulama kayıplarını göstermektedir. Eğitim kaybı düzenli şekilde azalırken doğrulama kaybı başlangıçta dalgalı bir seyir izlemiş, daha sonra belirli bir istikrara kavuşmuştur. Bununla birlikte, ilerleyen epoklarda eğitim ve doğrulama kayıpları arasındaki farkın artmaya başlaması, modelin kısmen aşırı öğrenme eğilimi gösterdiğini ortaya koymaktadır.



(a)




(b)


Şekil 4.82. Türkay Kavşağı 37862-37860 istikameti (aykırılıklardan arındırılmış veri) için (a) BiLSTM modeli; (b) doğrulama grafiği

Şekil 4.82’de 37862-37860 istikameti (aykırılıklardan arındırılmış veri) için BiLSTM modeline ait çıktılar gösterilmiştir:

- Şekil 4.82(a) tahmin grafiğinde görüldüğü üzere BiLSTM modeli, gerçek değerlerle tahmin değerlerini genel eğilim açısından tutarlı şekilde yakalamış ve periyodik dalgalanmaları başarılı biçimde temsil etmiştir. Ancak pik değerlerinde kısmi sapmalar gözlenmiştir.
- Şekil 4.82(b) doğrulama grafiğinde, eğitim kaybının düzenli bir azalma eğilimi gösterdiği, doğrulama kaybının ise başlangıçta dalgalı bir seyir izledikten sonra daha dengeli bir yapıya kavuştuğu görülmektedir. Eğitim ve doğrulama kaybı arasındaki farkın epoklar ilerledikçe belirginleşmeye başlaması, modelin kısmi aşırı öğrenme eğilimi gösterdiğini işaret etmektedir.



(a)




(b)


Şekil 4.83. Türkey Kavşağı 37862-37860 istikameti (aykırılıklardan arındırılmış veri) için (a) GRU modeli; (b) doğrulama grafiği

Şekil 4.83'te 37862-37860 istikameti (aykırılıklardan arındırılmış veri) için GRU modeline ait çıktılar gösterilmiştir:

- Şekil 4.83(a) tahmin grafiğinde, GRU modelinin genel trafik eğilimlerini başarılı şekilde yakaladığı, özellikle periyodik dalgalanmaları tatmin edici biçimde yansıttığı görülmektedir. Ancak tahmin değerlerinin bazı pik noktalarda gerçek değerlerin altında kaldığı gözlemlenmiştir.
- Şekil 4.83(b) doğrulama grafiğinde, eğitim kaybı düzenli olarak azalırken doğrulama kaybının başlangıçta dalgalı bir seyir izlediği, ilerleyen epoklarda ise daha istikrarlı hale geldiği görülmektedir. Eğitim ve doğrulama kaybı arasındaki farkın kısmen açılması, modelin sınırlı düzeyde aşırı öğrenme eğilimi sergilediğini göstermektedir.



(a)




(b)

Şekil 4.84. Türkay Kavşağı 37862-37860 istikameti (aykırılıklardan arındırılmış veri) için **(a)** LSTM + CNN modeli; **(b)** doğrulama grafiği


Şekil 4.84'te 37862-37860 istikameti (aykırılıklardan arındırılmış veri) için LSTM + CNN modeline ait çıktılar gösterilmiştir:

- Şekil 4.84(a) tahmin grafiğinde, LSTM + CNN modeli gerçek değerlerin genel eğilimini yakalamış ve periyodik trafik dalgalanmalarını büyük ölçüde temsil etmiştir. Ancak ani artış ve düşüşlerde tahminlerin gerçek değerlere göre daha yumuşatılmış kaldığı görülmektedir.

- Şekil 4.84(b) doğrulama grafiğinde, eğitim kaybının düzenli şekilde azaldığı, doğrulama kaybının ise başlangıçta dalgalı bir seyir izlediği ve ardından daha dengeli bir yapıya ulaştığı gözlemlenmektedir. İlerleyen epoklarda eğitim ve doğrulama kayıpları arasındaki farkın kademeli olarak artması, modelde kısmi bir aşırı öğrenme eğiliminin ortaya çıktığını göstermektedir.



(a)




(b)


Şekil 4.85. Türkay Kavşağı 37862-37860 istikameti (aykırılıklardan arındırılmış veri) için (a) RNN modeli; (b) doğrulama grafiği

Şekil 4.85'te 37862-37860 istikameti (aykırılıklardan arındırılmış veri) için RNN modeline ait çıktılar gösterilmiştir:

- Şekil 4.85(a) tahmin grafiğinde görüldüğü üzere RNN modeli, genel eğilimi yakalamakta başarılı olmuş, gerçek değerlerle tahminler arasında uyumlu bir paralellik sağlamıştır. Ancak ani yükseliş ve düşüşlerde (pik değerlerde) modelin tahmin performansında sapmaların devam ettiği gözlenmektedir.
- Şekil 4.85(b) doğrulama grafiğinde, eğitim kaybının düzenli olarak azaldığı, doğrulama kaybının ise başta dalgalı bir seyir izledikten sonra daha istikrarlı hale geldiği görülmektedir. Bununla birlikte eğitim ve doğrulama kayıpları arasındaki farkın ilerleyen epoklarda belirginleşmeye başladığı, modelin kısmi aşırı öğrenme eğilimi gösterdiğini ortaya koymaktadır.



(a)




(b)


Şekil 4.86. Türkiye Kavşağı 37862-37860 istikameti (aykırılıklardan arındırılmış veri) için (a) Dikkat Mekanizması Tabanlı LSTM modeli; (b) doğrulama grafiği

Şekil 4.86'da 37862-37860 istikameti (aykırılıklardan arındırılmış veri) için Dikkat Mekanizması Tabanlı LSTM modeline ait çıktılar gösterilmiştir:

- Şekil 4.86(a) tahmin grafiğinde, Dikkat Mekanizması Tabanlı LSTM modeli gerçek değerlerle tahmin değerlerini büyük ölçüde uyumlu yakalamış ve trafik akışındaki periyodik dalgalanmaları temsil etmede başarılı olmuştur. Ancak, ani pik noktalarında kısmi sapmalar gözlenmiş ve model bu keskin değişimlerde tam doğruluk sağlayamamıştır.
- Şekil 4.86(b) doğrulama grafiğinde, eğitim kaybının düzenli olarak azaldığı ve doğrulama kaybının başlangıçta dalgalı bir seyir izledikten sonra daha istikrarlı hale geldiği görülmektedir. Bununla birlikte, eğitim ve doğrulama kayıpları arasındaki fark ilerleyen epoklarda yavaşça artmaya başlamış, bu durum modelin sınırlı da olsa aşırı öğrenme eğilimi gösterebileceğini düşündürmektedir.



(a)




(b)

Şekil 4.87. Türkay Kavşağı 37862-37860 istikameti (aykırılıklardan arındırılmış veri) için **(a)** Yığılanmış LSTM modeli; **(b)** doğrulama grafiği


Şekil 4.87’de 37862-37860 istikameti (aykırılıklardan arındırılmış veri) için Yığılanmış LSTM modeline ait çıktılar gösterilmiştir:

- Şekil 4.87(a) tahmin grafiğinde görüldüğü üzere, Yığılanmış LSTM modeli genel eğilimleri başarılı biçimde yakalamış, trafik yoğunluğundaki periyodik dalgalanmaları temsil edebilmiştir. Ancak yüksek değerlerde tahminlerin gerçek değerlere kıyasla bir miktar aşağıda kaldığı gözlemlenmektedir.

- Şekil 4.87(b) doğrulama grafiğinde, eğitim kaybının düzenli olarak azaldığı, doğrulama kaybının ise başlangıçta dalgali bir seyir izledikten sonra daha istikrarlı bir yapıya ulaştığı görülmektedir. Bununla birlikte, eğitim ve doğrulama eğrileri arasındaki farkın epoklar ilerledikçe açılmaya başlaması, modelin kısmi aşırı öğrenme eğilimi gösterdiğine işaret etmektedir.



(a)



(b)

Şekil 4.88. Türkay Kavşağı 37862-37860 istikameti (aykırılıklardan arındırılmış veri) için (a) LSTM + GRU modeli; (b) doğrulama grafiği

Şekil 4.88’de 37862-37860 istikameti (aykırılıklardan arındırılmış veri) için LSTM + GRU modeline ait çıktılar gösterilmiştir:

- Şekil 4.88(a) tahmin grafiğinde görüldüğü üzere LSTM + GRU modeli, gerçek değerlerin genel eğilimini başarılı biçimde yakalamış ve trafik hacmindeki periyodik yapıyı temsil etmiştir. Özellikle orta seviyelerdeki dalgalanmalar iyi bir şekilde modellenmiş, ancak ani artışların tamamı aynı doğrulukla yakalanamamıştır.
- Şekil 4.88(b) doğrulama grafiğinde, eğitim kaybı düzenli bir azalış eğilimi sergilemiştir. Doğrulama kaybı başlangıçta dalgalı bir yapı izlese de ilerleyen epoklarda daha istikrarlı bir seviyeye oturmuştur. Eğitim ve doğrulama eğrileri arasındaki farkın zamanla açılması, modelin kısmi aşırı öğrenme eğilimine işaret etmektedir.

Çizelge 4.13’te Türkay Kavşağı 37862-37860 güzergahı (aykırılıklardan arındırılmış veri) için derin öğrenme modellerinin eğitim ve test süreçlerindeki performans metrikleri kapsamlı bir şekilde sunulmuştur. Her model, eğitim ve test aşamalarındaki hata oranları (MSE, MAE) ve başarı oranları (R^2) ile karşılaştırılmıştır.

Çizelge 4.13. Türkay Kavşağı 37862-37860 güzergahı (aykırılıklardan arındırılmış veri) için derin öğrenme modellerinin performans metriklerinin karşılaştırılması

Model	Eğitim MSE	Test MSE	Eğitim MAE	Test MAE	Eğitim R^2	Test R^2
LSTM	397.328	639.56	14.915	18.682	0.721	0.729
BiLSTM	404.652	637.67	14.944	18.653	0.716	0.73
GRU	383.168	649.9	14.688	18.786	0.731	0.725
LSTM + CNN	411.252	668.945	15.224	18.973	0.711	0.717
RNN	410.099	688.166	15.283	19.424	0.712	0.708
Dikkat Mekanizması Tabanlı LSTM	408.744	623.053	15.025	18.522	0.713	0.736
Yığınlanmış LSTM	393.245	627.24	14.907	18.469	0.724	0.734
LSTM + GRU	392.081	643.685	14.826	18.72	0.725	0.727
Ortalama	400.071	647.277	14.976	18.779	0.719	0.726

Eğitim metriklerine göre:

- En düşük Eğitim MSE değeri GRU modelinde (383.168) elde edilmiştir. Bu, GRU modelinin eğitim verisindeki hata oranının diğer modellere göre daha düşük olduğunu göstermektedir.

- Eđitim MAE aısından da en iyi performans yine GRU modeline (14.688) aittir. Bu, modelin hata büyüklüğünün görece daha az olduğunu göstermektedir.
- Eđitim R^2 değeri bakımından en yüksek performans GRU modeli (0.731) ile elde edilmiştir.

Test metriklerine göre:


- En düşük Test MSE değeri Dikkat Mekanizması Tabanlı LSTM modelinde (623.053) görölmektedir. Bu, test verisindeki hata oranının diđer modellere göre daha düşük olduğunu göstermektedir.
- Test MAE aısından en iyi performans yine Dikkat Mekanizması Tabanlı LSTM modelinde (18.522) elde edilmiştir. Bu, modelin test verisindeki hata büyüklüğünün daha az olduğunu göstermektedir.
- Test R^2 değeri bakımından en yüksek performans Dikkat Mekanizması Tabanlı LSTM modelinde (0.736) gözlenmiştir.

Türkay Kavşacı 37862-37860 istikameti (aykırılıklardan arındırılmış veri) genel değeriendirme:


- Dikkat Mekanizması Tabanlı LSTM modeli, test metriklerinde (en düşük MSE ve MAE, en yüksek R^2) elde ettiđi sonuçlarla en başarılı model olmuştur.
- GRU modeli, eğitim sürecinde en düşük hata oranları ve en yüksek R^2 değeri ile öne çıkmıştır, ancak test performansında Dikkat Mekanizması Tabanlı LSTM'in gerisinde kalmıştır.

4.2.8. Türkay Kavşacı 37862-37860 istikameti ham veri ile derin öğrenme modellerinin eğitimi

Türkay Kavşacı 37862-37860 istikametine ait ham veri seti, sekiz farklı derin öğrenme modeli (LSTM, BiLSTM, GRU, LSTM+CNN, RNN, Dikkat Mekanizması Tabanlı LSTM, Yığınlanmış LSTM ve LSTM+GRU) kullanılarak eğitilmiştir. Veri temizleme işlemleri uygulanmadan oluşturulan bu veri seti, modellerin performanslarını karşılaştırmak amacıyla analiz edilmiştir. Modellerin çıktıları aşağıda görselleştirmelerle birlikte sunulmuş olup, tahmin grafiklerinde mavi çizgi gerçek değerleri, turuncu çizgi ise model tarafından tahmin edilen değerleri göstermektedir. Kayıp grafiklerinde ise mavi çizgi eğitim kaybını, turuncu çizgi doğrulama kaybını temsil etmektedir. Bu görselleştirmeler, modellerin hem tahmin başarısını hem de eğitim sürecindeki öğrenme davranışlarını değeriendirmek amacıyla kullanılmıştır.



(a)




(b)

Şekil 4.89. Türkay Kavşağı 37862-37860 istikameti (ham veri) için (a) LSTM modeli; (b) doğrulama grafiği


Şekil 4.89’da 37862-37860 istikameti (ham veri) için LSTM modeline ait çıktılar gösterilmiştir:

- Şekil 4.89(a) tahmin grafiğinde görüldüğü üzere, LSTM modeli genel eğilimi başarılı bir biçimde yakalamış ve trafik akışındaki periyodik dalgalanmaları belirgin şekilde temsil etmiştir. Bununla birlikte, bazı pik değerlerinde modelin sapmalar gösterdiği ve ani değişimlere duyarlılığının sınırlı olduğu dikkat çekmektedir.

- Şekil 4.89(b) doğrulama grafiğinde, eğitim kaybının düzenli olarak azaldığı, doğrulama kaybının ise başlangıçtan itibaren dalgalı bir seyir izlediği görülmektedir. İlerleyen epoklarda doğrulama kaybı görece stabil hale gelmekle birlikte, eğitim ve doğrulama eğrileri arasındaki farkın zamanla açıldığı gözlenmiştir. Bu durum, modelin kısmi bir aşırı öğrenme eğilimi sergilediğini göstermektedir.



(a)




(b)

Şekil 4.90. Türkay Kavşağı 37862-37860 istikameti (ham veri) için (a) BiLSTM modeli; (b) doğrulama grafiği


Şekil 4.90'da 37862-37860 istikameti (ham veri) için BiLSTM modeline ait

çktılar gösterilmiştir:

- Şekil 4.90(a) tahmin grafiğinde, BiLSTM modelinin gerçek değerlerle tahmin değerlerini genel eğilim açısından uyumlu şekilde yakaladığı görülmektedir. Trafik akışındaki periyodik dalgalanmalar başarılı biçimde temsil edilmiştir. Ancak, bazı pik değerlerinde modelin tahminlerinin gerçek değerlerden ayrıştığı gözlemlenmektedir.
- Şekil 4.90(b) doğrulama grafiğinde, eğitim kaybı düzenli bir şekilde azalırken doğrulama kaybının daha yüksek seviyelerde seyrettiği ve zamanla nispeten yatay bir eğilim gösterdiği görülmektedir. Eğitim ve doğrulama kayıpları arasındaki farkın belirginleşmesi, modelin kısmi aşırı öğrenme eğilimi gösterdiğine işaret etmektedir.



(a)




(b)


Şekil 4.91. Türkiye Kavşağı 37862-37860 istikameti (ham veri) için (a) GRU modeli; (b) doğrulama grafiği

Şekil 4.91’de 37862-37860 istikameti (ham veri) için GRU modeline ait çıktılar gösterilmiştir:

- Şekil 4.91(a) tahmin grafiğinde görüldüğü üzere GRU modeli, gerçek değerler ile tahmin değerlerini genel eğilim açısından uyumlu şekilde yakalamış ve periyodik trafik dalgalanmalarını temsil etmede başarılı olmuştur. Ancak pik değerlerde belirli sapmalar gözlenmiş, model bu ani değişimleri sınırlı ölçüde yansıtmıştır.
- Şekil 4.91(b) doğrulama grafiğinde, eğitim kaybının düzenli olarak azaldığı görülmektedir. Doğrulama kaybı ise başlangıçta dalgalı bir seyir izledikten sonra daha istikrarlı bir yapıya kavuşmuştur. Bununla birlikte, eğitim ve doğrulama kayıpları arasındaki farkın epoklar ilerledikçe kademeli biçimde açıldığı gözlenmiş, bu durum modelin kısmi aşırı öğrenme eğilimi gösterdiğini ortaya koymaktadır.



(a)




(b)

Şekil 4.92. Türkay Kavşağı 37862-37860 istikameti (ham veri) için (a) LSTM + CNN modeli; (b) doğrulama grafiği


Şekil 4.92’de 37862-37860 istikameti (ham veri) için LSTM + CNN modeline ait çıktılar gösterilmiştir:

- Şekil 4.92(a) tahmin grafiğinde görüldüğü üzere LSTM + CNN modeli, gerçek değerlerle tahmin değerlerini genel eğilim açısından başarılı bir şekilde yakalamış, trafik hacmindeki periyodik dalgalanmaları tatmin edici düzeyde temsil etmiştir. Ancak ani pik değerlerinde belirgin sapmalar gözlenmiş, bu durum modelin ani trafik değişimlerine sınırlı tepki verdiğini göstermektedir.

- Şekil 4.92(b) doğrulama grafiğinde eğitim kaybının düzenli bir azalma eğiliminde olduğu, doğrulama kaybının ise ilk epoklarda dalgalanmalar yaşadıktan sonra daha kararlı bir seviyede seyrettiği görülmektedir. Eğitim ve doğrulama kayıpları arasındaki mesafenin epoklar ilerledikçe belirginleşmesi, modelin kısmi aşırı öğrenme eğilimi sergilediğini göstermektedir.



(a)




(b)


Şekil 4.93. Türkay Kavşağı 37862-37860 istikameti (ham veri) için (a) RNN modeli; (b) doğrulama grafiği

Şekil 4.93'te 37862-37860 istikameti (ham veri) için RNN modeline ait çıktılar gösterilmiştir:

- Şekil 4.93(a) tahmin grafiğinde görüldüğü üzere RNN modeli, gerçek değerlerle tahmin değerlerini genel eğilim açısından belirli ölçüde yakalamış ve trafik verisinin periyodik dalgalanmalarını kısmen temsil edebilmiştir. Ancak özellikle ani değişimlerin yaşandığı pik bölgelerde modelin tahminlerinde sapmalar gözlenmiştir.
- Şekil 4.93(b) doğrulama grafiğinde eğitim kaybının hızlı bir şekilde azaldığı, doğrulama kaybının ise ilk epoklardan sonra dalgalı bir seyir izlediği görülmektedir. Eğitim ve doğrulama kayıpları arasında belirgin farkın oluşması, modelin genelleme performansında sınırlılık yaşadığını ve aşırı öğrenmeye eğilim gösterdiğini ortaya koymaktadır.



(a)




(b)


Şekil 4.94. Türkyay Kavşağı 37862-37860 istikameti (ham veri) için (a) Dikkat Mekanizması Tabanlı LSTM modeli; (b) doğrulama grafiği

Şekil 4.94'te 37862-37860 istikameti (ham veri) için Dikkat Mekanizması Tabanlı LSTM modeline ait çıktılar gösterilmiştir:

- Şekil 4.94(a) tahmin grafiğinde, Dikkat Mekanizması Tabanlı LSTM modelinin gerçek değerlerle tahmin değerleri arasında genel eğilim açısından başarılı bir uyum yakaladığı görülmektedir. Model, trafik serisinin periyodik dalgalanmalarını büyük ölçüde temsil etmiş, ancak pik değerlerde belirli sapmalar gözlenmiştir. Bu durum, modelin ani artışları takip etmekte kısmen sınırlı kaldığını ortaya koymaktadır.
- Şekil 4.94(b) doğrulama grafiğinde, eğitim kaybının düzenli bir şekilde azaldığı, doğrulama kaybının ise ilk epoklarda dalgalı bir seyir izledikten sonra giderek daha istikrarlı bir yapıya ulaştığı görülmektedir. İlerleyen epoklarda eğitim ve doğrulama eğrileri arasındaki farkın belirginleşmeye başlaması, modelin kısmi aşırı öğrenme eğilimi gösterdiğini işaret etmektedir.



(a)




(b)

Şekil 4.95. Türkay Kavşağı 37862-37860 istikameti (ham veri) için **(a)** Yığılanmış LSTM modeli; **(b)** doğrulama grafiği


Şekil 4.95'te 37862-37860 istikameti (ham veri) için Yığılanmış LSTM modeline ait çıktılar gösterilmiştir:

- Şekil 4.95(a) tahmin grafiğinde, Yığılanmış LSTM modeli gerçek değerlerle tahmin değerlerini genel eğilim açısından uyumlu şekilde yakalamış, trafik serisinin periyodik dalgalanmalarını başarıyla temsil etmiştir. Ancak, özellikle pik değerlerde tahminlerin gerçek değerlere göre daha düşük seviyede kaldığı ve modelin ani değişimlerde sınırlı performans gösterdiği gözlemlenmektedir.

- Şekil 4.95(b) doğrulama grafiğinde, eğitim kaybının düzenli şekilde azaldığı, doğrulama kaybının ise başlangıçta dalgalı bir seyir izledikten sonra belirli bir dengeye oturduğu görülmektedir. Eğitim ve doğrulama kayıpları arasındaki farkın ilerleyen epoklarda kademeli olarak artması, modelin kısmi aşırı öğrenme eğilimi gösterdiğini ortaya koymaktadır.



(a)



(b)

Şekil 4.96. Türkay Kavşağı 37862-37860 istikameti (ham veri) için (a) LSTM + GRU modeli; (b) doğrulama grafiği

Şekil 4.96’da 37862-37860 istikameti (ham veri) için LSTM + GRU modeline ait çıktılar gösterilmiştir:

- Şekil 4.96(a) tahmin grafiğinde görüldüğü üzere LSTM + GRU modeli, gerçek değerlerle tahmin değerlerini genel eğilim açısından uyumlu şekilde yakalamıştır. Trafik serisinin periyodik tekrarlarını öğrenmede başarılı olmuş, ancak ani pik noktalarında sapmalar gözlemlenmiştir.
- Şekil 4.96(b) doğrulama grafiğinde eğitim kaybının düzenli şekilde azaldığı görülmektedir. Doğrulama kaybı ise başlangıçta dalgalı bir seyir izledikten sonra daha dengeli bir yapıya ulaşmıştır. Eğitim ve doğrulama eğrileri arasındaki mesafe epoklar ilerledikçe hafif artmakta olup, bu durum modelin sınırlı düzeyde aşırı öğrenme eğilimine işaret etmektedir.

Çizelge 4.14’te Türkay Kavşağı 37862-37860 güzergahı (ham veri) için derin öğrenme modellerinin eğitim ve test süreçlerindeki performans metrikleri kapsamlı bir şekilde sunulmuştur. Her model, eğitim ve test aşamalarındaki hata oranları (MSE, MAE) ve başarı oranları (R^2) ile karşılaştırılmıştır.

Çizelge 4.14. Türkay Kavşağı 37862-37860 güzergahı (ham veri) için derin öğrenme modellerinin performans metriklerinin karşılaştırılması

Model	Eğitim MSE	Test MSE	Eğitim MAE	Test MAE	Eğitim R^2	Test R^2
LSTM	444.609	684.253	15.759	19.506	0.714	0.71
BiLSTM	427.626	625.821	15.262	18.669	0.725	0.734
GRU	414.459	660.029	15.109	19.08	0.734	0.72
LSTM + CNN	442.744	658.182	15.597	19.004	0.716	0.721
RNN	480.59	716.686	16.171	19.923	0.691	0.696
Dikkat Mekanizması Tabanlı LSTM	458.471	665.342	15.844	19.142	0.706	0.718
Yığınlanmış LSTM	441.978	627.422	15.583	18.661	0.716	0.734
LSTM + GRU	441.959	669.492	15.678	19.232	0.716	0.716
Ortalama	444.054	663.403	15.625	19.152	0.715	0.719

Eğitim metriklerine göre:

- En düşük Eğitim MSE değeri GRU modelinde (414.459) elde edilmiştir. Bu, GRU modelinin eğitim verisindeki hata oranının diğer modellere göre daha düşük olduğunu göstermektedir.

- Eğitim MAE açısından da en iyi performans yine GRU modeline (15.109) aittir. Bu, modelin hata büyüklüğünün görece daha az olduğunu göstermektedir.
- Eğitim R^2 değeri bakımından en yüksek performans yine GRU modeli (0.734) ile elde edilmiştir.

Test metriklerine göre:


- En düşük Test MSE değeri BiLSTM (625.821) modelinde görülmektedir. Bu, test verisindeki hata oranının diğer modellere göre daha düşük olduğunu göstermektedir.
- Test MAE açısından en iyi performans BiLSTM modelinde (18.669) ve Yığınlanmış LSTM (18.661) modelinde elde edilmiştir. Bu, modellerin test verisindeki tahminlerinde hata büyüklüğünün daha az olduğunu göstermektedir.
- Test R^2 değeri bakımından en yüksek performans BiLSTM (0.734) ve Yığınlanmış LSTM (0.734) modellerinde gözlenmiştir.

Türkay Kavşacı 37862-37860 istikameti (ham veri) genel değerlendirme:


- BiLSTM ve Yığınlanmış LSTM modelleri, test metriklerinde düşük hata değerleri ve yüksek R^2 ile en başarılı sonuçları vermiştir.
- GRU modeli, eğitim sürecinde en iyi performansı göstermiştir, ancak test sonuçları BiLSTM ve Yığınlanmış LSTM kadar güçlü olmamıştır.

4.3. Benzetim Doğrulama Sonuçları


Şekil 4.97 kalibrasyon süreçlerinde GEH kriterinin uygulanışını göstermekte ve bu kriterlerin benzetim sonuçlarının doğruluğunu artırmaya olan katkısını vurgulamaktadır.



(a)



(b)



(c)

Şekil 4.97. Trafik hacmi tahmini için kalibrasyon süreçlerinde GEH kriterinin uygulandığı (a) Heybe Kavşağı; (b) Ardeşık Kavşaklar (c); Işıktepe Kavşağı

Şekil 4.97’de görüldüğü üzere, tüm değerler beşin altındadır ve GEH kriterine uygundur. Bu bağlamda benzetim sonuçları ve gerçek hayat arasındaki farklar sürücü ve yaya davranışları gibi etkenler sebebiyle açıklanabilir.

4.4. Heybe Kavşağı SUMO analiz sonuçları

Çizelge 4.15 akıllı bir kavşağın arıza durumunda sabit moda geçtiğinde performansını, adaptif süreli mod ile karşılaştırmaktadır. Arıza durumunda akıllı kavşağın sabit moda geçmesi, trafik yönetimini performans açısından önemli kayıplara yol açmıştır. Bu durum, akıllı sistemlerin adaptif kontrol mekanizmalarının sürdürülebilir olmasının önemini vurgulamaktadır.


Çizelge 4.15. Adaptif ve sabit süreli sinyalizasyon sistemlerinin trafik parametreleri açısından performans karşılaştırması

Metrik	Sabit Süreli	Adaptif Süreli
Ortalama Kuyruk Uzunluğu (Araç)	26.38	12.39
Ortalama Gecikme Süresi (s)	50.67	24.83
Ortalama Hız (km/sa)	7.60	14.97
Ortalama Karbon Emisyonu (g)	84.40	42.78
Ortalama Yakıt Tüketimi (L)	26.92	13.65
Hizmet Seviyesi (LOS)	E	C


4.4.1. Derin Q-Öğrenme uygulaması sonuçları

Şekil 4.98 eğitim bölümleri boyunca kümülatif negatif ödüllerin ilerlemesini göstermektedir. Grafik, kümülatif negatif ödüllerin ilk bölümler sırasında nispeten yüksek başladığını ve eğitim ilerledikçe kademeli olarak azaldığını göstermektedir. Bu azalma, aracının bilgi edindikçe en uygun eylemler seçtiğini ve bunun da trafik yönetiminde daha iyi karar almaya yol açtığını göstermektedir. Negatif ödüllerdeki azalma, aracının bekleme sürelerini etkili bir şekilde azalttığını ve trafik sıkışıklığını hafiflettiğini göstermektedir. Sonraki bölümlerde, negatif ödül değerlerinin sabitlenmesi, öğrenme sürecinin birleştiğini ve aracının performansının sabitlendiğini göstermektedir.

Şekil 4.99 kümülatif gecikme süresinin bölümlere göre nasıl değiştiğini göstermektedir. Grafikte, ilk bölümlerde gecikme süresi oldukça yüksekken, bölümler ilerledikçe belirgin bir azalma eğilimi göstermektedir. Bu, ajan tarafından öğrenilen trafik kontrol stratejilerinin daha etkili hale geldiğini ve trafik akışını en iyileyerek toplam gecikmeyi düşürdüğünü göstermektedir. Eğitim sürecinin son bölümlerinde kümülatif gecikme değerlerinin düşük ve nispeten sabit olduğu gözlemlenmektedir. Bu durum, öğrenilen stratejilerin kalıcı bir iyileştirme sağladığını ve trafik yönetim sisteminin hedeflenen performans seviyesine ulaştığını ifade etmektedir.



Şekil 4.98. Kümülatif negatif ödülün bölümlere göre değişimi



Şekil 4.99. Kümülatif gecikmenin bölümlere göre değişimi

Bu iki grafik birlikte incelendiğinde, eğitim sürecinin hem ödül hem de trafik yönetimi açısından etkili bir şekilde sonuç verdiği açıkça görülmektedir.

Çizelge 4.16'da sabit süreli, adaptif süreli ve DQL kontrollü trafik yönetim sistemlerinin performansını karşılaştırılmaktadır. DQL kontrollü sistem, tüm metriklerde en iyi performansı sergileyerek trafik yönetimi açısından en etkili çözüm olduğunu göstermektedir.

Kuyruk uzunluğu açısından incelendiğinde, sabit süreli sistemde 26.38 araç olarak ölçülen ortalama kuyruk uzunluğu, adaptif süreli sistem ile %53 azalarak 12.39 araca düşmüştür. DQL kontrollü sistem ise bu değeri %67 azaltarak 8.73 araca kadar düşürerek en iyi sonucu elde etmiştir.

Ortalama gecikme süresi açısından bakıldığında, sabit süreli sistemin trafik akışındaki verimsizliği nedeniyle ortalama gecikme süresi 50.67 saniye olarak ölçülmüştür. Adaptif süreli sistem, dinamik sinyal en iyilemesi sayesinde bu süreyi %51

azaltarak 24.83 saniyeye düşürmüştür. DQL kontrollü sistem ise gecikme süresini %61.3 oranında iyileştirerek 19.63 saniyeye kadar azaltarak trafiğin en verimli şekilde yönetildiğini göstermektedir. Ortalama hız metriği, trafik akışının etkinliğini değerlendirmek için kritik bir göstergedir. Sabit süreli sistemde ortalama hız 7.60 km/sa olarak ölçülmüşken, adaptif süreli sistem ile %97 artış göstererek 14.97 km/sa seviyesine yükselmiştir. DQL kontrollü sistem ise %134.6 iyileşme sağlayarak 17.83 km/sa hıza ulaşarak trafik akışını en verimli hale getirmiştir.

Çizelge 4.16. Heybe Kavşağı farklı trafik yönetim sistemlerinin performans karşılaştırması

Metrik	Sabit Süreli	Adaptif Süreli	DQL Kontrollü
Ortalama Kuyruk Uzunluğu (Araç)	26.38	12.39	8.73
Ortalama Gecikme Süresi (s)	50.67	24.83	19.63
Ortalama Hız (km/sa)	7.60	14.97	17.83
Ortalama Karbon Emisyonu (g)	84.40	40.78	30.17
Ortalama Yakıt Tüketimi (L)	26.92	13.65	10.8
Hizmet Seviyesi (LOS)	E	C	B

Çevresel etkiler açısından değerlendirildiğinde, karbon emisyonu ve yakıt tüketimi, sabit süreli sistemde sırasıyla 84.40 gram ve 26.92 litre olarak hesaplanmıştır. Adaptif süreli sistem, daha akıllı sinyalizasyon yönetimi sayesinde bu değerleri sırasıyla 40.78 gram ve 13.65 litreye düşürerek çevresel sürdürülebilirlik açısından önemli bir iyileşme sunmuştur. DQL kontrollü sistem ise 30.17 gram karbon emisyonu ve 10.8 litre yakıt tüketimi ile en düşük seviyeye ulaşarak çevresel etkilerin en aza indirildiğini ortaya koymaktadır.

Son olarak, hizmet seviyesi (LOS) açısından değerlendirildiğinde, sabit süreli sistemde trafik sıkışıklığının yüksek olması nedeniyle E seviyesi gözlemlenmiştir. Adaptif süreli sistem, trafik akışını en iyileyerek hizmet seviyesini C seviyesine yükseltmiştir. DQL kontrollü sistem ise B seviyesine ulaşarak, kavşakta daha konforlu ve verimli bir trafik akışı sağlandığını göstermektedir.

4.5. Ardışık kavşaklar SUMO analiz sonuçları

Çizelge 4.17 Ardışık sinyalize kavşaklara farklı senaryoların uygulanması durumunda elde edilen SUMO analiz sonuçlarını göstermektedir. Senaryo 1, her iki kavşağın adaptif süreli sinyalizasyonla çalıştığı durumu; Referans Senaryo (Senaryo 2), her iki kavşağın sabit süreli sinyalizasyon modunda çalıştığı arıza durumunu; Senaryo 3 ise Türkay Kavşağı'nın veri analizine dayalı olarak adaptif biçimde çalışmaya devam ettiği, ancak Heybe Kavşağı'nın arıza nedeniyle sabit süreli moda geçtiği durumu ifade

etmektedir.

Çizelge 4.17. Ardışık Kavşaklar farklı trafik yönetim sistemlerinin performans karşılaştırması

Metrik	Senaryo 1	Senaryo 2 (Referans)	Senaryo 3
Ortalama Yolculuk Süresi (s)	179.21	234.97	200.52
Ortalama Hız (km/sa)	4.75	3.77	4.25
Toplam CO ₂ Emisyonu (kg)	3918.98	4246.99	4064.67
Toplam CO Emisyonu (kg)	150.85	179.84	165.09
Toplam HC Emisyonu (kg)	0.78	0.92	0.85
Toplam NO _x Emisyonu (kg)	1.73	1.89	1.80
Toplam PM _x Emisyonu (kg)	0.094	0.102	0.097

Çizelge 4.18 referans senaryoya kıyasla farklı senaryoların uygulanması durumunda elde edilen yüzdelik performans iyileşme oranlarını göstermektedir.

Çizelge 4.18. Akıllı sinyalizasyon senaryolarının yüzdelik iyileşme oranları

Senaryolar	Ortalama Yolculuk Süresi (%)	Ortalama Hız (%)	CO ₂ (%)	CO (%)	NO _x (%)	PM _x (%)	HC (%)	Yakıt Tüketimi (%)
Senaryo 3	14.66	12.73	4.29	8.20	4.56	4.74	7.76	4.29
Senaryo 1	23.73	25.99	7.72	16.12	8.15	8.11	15.15	7.72

Ortalama yolculuk süresi, trafik yönetim performansını doğrudan etkileyen önemli bir göstergedir. Adaptif sistemin uygulandığı Senaryo 1’de ortalama 179.21 saniye olan yolculuk süresi, sabit modda çalışan Senaryo 2’de 234.97 saniyeye çıkmıştır. Bu artış, adaptif sistemlerin zaman optimizasyonundaki gerekliliğini vurgulamaktadır. Senaryo 3’te ise bu süre 200.52 saniyeye inmiş, böylece %14.66 oranında bir iyileşme sağlanmıştır. Benzer şekilde ortalama hız, adaptif sistemde 4.75 km/sa iken sabit süreli modda azalarak 3.77 km/sa olarak ölçülmüştür. Türkay kavşağının adaptif kalmaya devam ettiği durumda ise ortalama hız 4.25 km/sa değerini almıştır.

Emisyon değerleri ve yakıt tüketimi incelendiğinde ise adaptif sistemlerin çevresel açıdan da daha sürdürülebilir olduğu gözlemlenmiştir. CO₂ emisyonları açısından bakıldığında, tam adaptif kontrolün uygulandığı Senaryo 1, 3918.98 kg ile en düşük değeri göstermektedir. Sabit süreli sinyalizasyonun devrede olduğu Senaryo 2’de CO₂ emisyonu yaklaşık 4246.99 kg’a yükselmiş ve bu durum çevresel etkilerin belirgin

şekilde arttığını ortaya koymuştur. Senaryo 3, yani kısmi adaptif kontrol durumunda ise CO₂ emisyonu 4064.67 kg seviyesinde kalmış, böylece sabit süreli moda kıyasla çevresel etkilerde bir miktar iyileşme sağlanmıştır. Bu sonuçlar, adaptif sistemlerin karbon salımını azaltmada kritik rol oynadığını göstermektedir.

Karbonmonoksit (CO) emisyonlarında da benzer bir eğilim gözlemlenmektedir. Adaptif süreli çalışmada (Senaryo 1), toplam CO emisyonu 150.85 kg seviyesindeyken, sabit süreli sistemde (Senaryo 2) bu değer 179.84 kg'a çıkarak artış göstermiştir. Senaryo 3'te ise CO emisyonu 165.09 kg olarak ölçülmüş, sabit süreli sisteme göre daha düşük olmakla birlikte tam adaptif modun gerisinde kalmıştır. Bu sonuç, adaptif sistemlerin hava kalitesinin korunmasında da önemli katkı sağladığını göstermektedir.

Hidrokarbon (HC) emisyonları bakımından tam adaptif sistem (Senaryo 1) 0.78 kg ile en düşük değeri kaydetmiştir. Sabit süreli sinyalizasyonun uygulandığı Senaryo 2'de bu değer 0.92 kg'a çıkarak artmıştır. Senaryo 3'te ise HC emisyonu 0.85 kg seviyesinde ölçülmüştür. Özellikle hidrokarbon emisyonlarının artışı, hava kirliliği ve ozon oluşumu açısından önemli bir risk faktörü olduğundan, adaptif sistemlerin bu konuda da önemli çevresel faydalar sunduğu görülmektedir.

Azot oksit (NO_x) emisyonları incelendiğinde, adaptif sistemde (Senaryo 1) toplam NO_x emisyonu 1.73 kg olarak gerçekleşmiştir. Sabit süreli sistemde (Senaryo 2) NO_x emisyonları 1.89 kg'a yükselmiş ve bu artış, özellikle şehir içi hava kirliliği ve asit yağmurları açısından olumsuz bir durum yaratmıştır. Senaryo 3'te NO_x emisyonu 1.80 kg olarak gözlemlenmiştir. Bu değer, sabit süreli sisteme göre daha düşük olmakla birlikte tam adaptif sisteme göre daha yüksek kalmıştır. Bu bulgu, adaptif kontrolün NO_x salımını azaltmada da etkili olduğunu göstermektedir.

Partikül madde (PM_x) emisyonları açısından, adaptif sistemin kullanıldığı Senaryo 1'de toplam PM_x değeri 0.094 kg ile en düşük seviyededir. Sabit sinyal süreli Senaryo 2'de bu değer 0.102 kg'a yükselmiştir. Senaryo 3'te ise PM_x emisyonu 0.097 kg olarak ölçülmüştür. Özellikle partikül madde emisyonları, insan sağlığı açısından doğrudan risk oluşturduğundan, adaptif sistemlerin bu konuda da olumlu etkileri olduğu net biçimde görülmektedir.

Toplam yakıt tüketimi, Senaryo 1'de 1250 kg iken sabit süreli sistemde artarak 1354 kg seviyesine yükselmiştir. Senaryo 3'te ise 1296 kg olarak ölçülmüştür. Bu durum, sabit modun sadece trafik performansı açısından değil, enerji tüketimi bakımından da dezavantajlı olduğunu göstermektedir.

Bu bulgular, adaptif sistemlerin sinyal süresi en iyilemesindeki etkinliğini ortaya koymuştur. Tüm emisyon türlerinde adaptif kontrol mekanizmalarının devrede olduğu Senaryo 1 çevresel performans açısından en iyi sonuçları vermiştir. Senaryo 3, Senaryo 2'ye kıyasla her emisyon parametresinde iyileşme sağlamış olsa da Senaryo 3'ün performans seviyesine ulaşamamıştır. Senaryo 3, arıza durumunda bile adaptif kontrolün kısmen sürdürülmesinin sistem performansını kayda değer ölçüde koruyabildiğini ortaya koymuştur.

4.5.1. Sinyalizasyon senaryoları için LCA analizi


Çalışma kapsamında ilk olarak, farklı senaryoların uygulanması sonucu GWP'lerde sağlanan iyileştirmeler değerlendirilmiştir. Referans senaryo ve diğer senaryolar için ReCiPe orta noktası (H) metodolojisi uygulanarak elde edilen GWP'ler Çizelge 4.19'da görülmektedir.

Çizelge 4.19. Sinyalizasyon senaryolarının GWP açısından karşılaştırılması


Senaryolar	Benzin (kgCO ₂ e/fu)	CO ₂ (kgCO ₂ e/fu)	CH ₄ (kgCO ₂ e/fu)	Toplam GWP (kgCO ₂ e/fu)	GWP Azalma Oranı (%)
Senaryo 2	0.004130636	4529.61	0.811	4530.43	-
Senaryo 3	0.003953292	4324.09	0.748	4324.84	4.54
Senaryo 1	0.003811593	4156.02	0.688	4156.71	8.25

Çizelge 4.19'da görüleceği üzere, sera gazı emisyonları büyük oranda CO₂ emisyonlarından kaynaklanmış, yakıt tüketimi ve CH₄ emisyonlarının katkısı sınırlı olmuştur. Elde edilen sonuçlar, S3'in uygulanmasıyla GWP'de %4.54, S1 uygulanması ile ise %8.25 azalma sağlanabileceğini ortaya koymuştur.

Referans senaryo ve diğer senaryolara göre, sistem sınırlarından bir saatte geçen bir araç için ReCiPe uç nokta (H) yöntemiyle belirlenen yaşam döngüsü etkileri Şekil 4.102'de sunulmuştur. İnsan sağlığı hasar kategorisinde ulaşımdan kaynaklanan en yüksek etkiler (%99, 70) beklendiği gibi GWP etki kategorisinden kaynaklanmıştır. İnsan sağlığı hasar kategorisinde diğer etkileri gösterebilmek için Şekil 4.100(a)'da GWP etki kategorisi gösterilmemiştir. GWP etkisi hariç tutulduğunda, insan sağlığı hasar kategorisinde en yüksek üç etkinin sırasıyla ince partikül madde oluşumu (%0.29), ozon oluşumu ve insan kanserojen toksisitesi etki kategorilerinden kaynaklandığı gözlemlenmiştir. İnsan sağlığı hasar kategorisinde başlıca etken GWP olduğu için Senaryo 3'ün ve Senaryo 1'in uygulanması ile bu kategoride GWP'ye benzer şekilde sırasıyla %4.54 ve %8.25 azaltım sağlanmıştır. İnsan sağlığı hasar kategorisinde GWP etki kategorisi hariç tutulduğunda Senaryo 3'ün ve Senaryo 1'in uygulanmasıyla sırasıyla %4.62 ve %8.14 etki azaltımı gerçekleştirilebilmektedir.



(a)



(b)

Şekil 4.100. ReCiPe Uç Nokta (H) metodolojisine göre sinyalizasyon yaklaşımlarının yaşam döngüsü etkileri (zarar kategorileri kapsamında) **a)** insan sağlığı; **b)** ekosistem kalitesi

Ekosistem kalitesi hasar kategorisinde en yüksek etki beklendiği gibi yaklaşık %99.79 oranında karasal ekosistemlerde küresel ısınma etkisinden kaynaklandığı belirlenmiştir. Bu nedenle, ekosistem kalitesi hasar kategorisinde ulaşımdan kaynaklanan

diğer kategorilerin görülebilir olması için Karasal ekosistemlerde küresel ısınma etki kategorisi Şekil 4.100(b)'de gösterilmemiştir. Ekosistem kalitesi hasar kategorisinde ulaşımdan kaynaklanan diğer etkiler karasal ekosistemlerde ozon üretimi (%0.13) ve karasal asitlenme (%0.07) etki kategorilerinde gerçekleşmiştir. Ekosistem kalitesi hasar kategorisinde karasal ekosistemlerde küresel ısınma haricindeki etki kategorilerine senaryoların uygulanmasının etkisi incelendiğinde; Senaryo 3'ün ve Senaryo 1'in uygulanmasıyla yaklaşık %4.71 ve %8.49 etki azaltımı sağlandığı hesaplanmıştır.

Kaynak tüketimi hasar kategorisinde ise yakıt tüketiminden kaynaklı olarak %99,99 oranında baskın etki fosil kaynak kısıtlılığı etki kategorisinden kaynaklanmıştır. Senaryo 3'e göre tek kavşakta akıllı sinyalizasyon uygulanması kaynak tüketimi hasar kategorisinde yaklaşık %4.29 azaltım sağlarken, Senaryo 1'e göre 2 kavşakta akıllı sinyalizasyon uygulanması yaklaşık %7.72 azaltım sağlamıştır.

Elde edilen çevresel etki azaltımları trafik yönetiminde adaptif sistemlerin yalnızca trafik akışını değil, çevresel sürdürülebilirliği de önemli ölçüde iyileştirdiğini net bir şekilde ortaya koymaktadır.

4.6. Işıktepe Kavşağı SUMO analiz sonuçları

Çizelge 4.20'da sistemin performansını 2 farklı senaryo çerçevesinde karşılaştırılmaktadır. Senaryo 1, Işıktepe Kavşağının arıza nedeniyle sabit süreli moda geçtiği durumu yansıtmaktadır. Senaryo 2, kavşağın adaptif sinyal süreli modda çalıştığı durumu temsil etmektedir.

Arıza nedeniyle adaptif kontrol mekanizmasının devre dışı kalması, sistem performansında önemli bozulmalara yol açmıştır. Senaryo 1'de hem trafik akışındaki verimlilik düşmüş hem de çevresel etkiler artmıştır. Bu durum, adaptif sistemlerin sürdürülebilirliğinin önemini vurgulamaktadır.

Çizelge 4.20. Işıktepe Kavşağı farklı trafik yönetim sistemlerinin performans karşılaştırması

Performans Ölçütü	Metrik	Senaryo 1 (Sabit Süreli)	Senaryo 2 (Adaptif Süreli)
Ortalama Yolculuk Süresi	s	43.04	34.51
Ortalama Hız	km/sa	19.66	25.09
Toplam CO ₂ Emisyonu	kg	777.22	673.84
Toplam CO Emisyonu	kg	26.83	22.17
Toplam HC Emisyonu	kg	0.14076	0.11719
Toplam NO _x Emisyonu	kg	0.34023	0.29300
Toplam PM _x Emisyonu	kg	0.01786	0.01576

Ortalama yolculuk süresi, trafik yönetim performansını doğrudan etkileyen önemli bir göstergedir. Sabit süreli sistemin uygulandığı Senaryo 1’de ortalama 43.04 saniye olan yolculuk süresi, adaptif modda çalışan Senaryo 2’de %19.8 oranında azalarak 34.51 saniyeye düşmüştür. Bu azalma, trafik akışının daha verimli yönetildiğini ve araçların kavşakta daha az zaman kaybettiğini göstermektedir.

Benzer şekilde ortalama hız, sabit süreli sistemin uygulandığı Senaryo 1’de 19.66 km/sa iken adaptif modda çalışan Senaryo 2’de %27.6 artarak 25.09 km/sa olarak ölçülmüştür. Ayrıca ortalama gecikme süresi bakımından Senaryo 1 48.37 saniye olarak, Senaryo 2 46.16 olarak ölçülmüştür.

Emisyon değerleri incelendiğinde, adaptif sistemin çevresel performans açısından daha başarılı olduğu görülmüştür. Karbondioksit (CO₂) emisyonlarında, sabit süreli sistemde toplam 777.22 kg CO₂ salımı gerçekleşirken, adaptif sistemde bu değer 673.84 kg’a düşmüş ve %13.3 oranında bir azalma sağlanmıştır. Benzer şekilde, karbonmonoksit (CO) emisyonları sabit sistemde 26.83 kg, adaptif sistemde ise 22.17 kg olarak ölçülmüş, bu da %17.3’lük bir iyileşmeye işaret etmektedir. Hidrokarbon (HC) emisyonları açısından da adaptif sistem avantajlıdır; sabit sistemde 0.14076 kg olan HC değeri, adaptif sistemde 0.11719 kg seviyesine inmiş ve %16.8 oranında azalma sağlanmıştır. Azot oksit (NO_x) emisyonlarında ise sabit sistem 0.34023 kg, adaptif sistem 0.29300 kg değerine ulaşmış, bu da %13.9’luk bir düşüş anlamına gelmektedir. Partikül madde (PM_x) emisyonları sabit sürede 0.01786 kg, adaptif sürede ise 0.01576 kg olarak hesaplanmış ve %11.8 oranında azaltılmıştır.

Bu analizler, trafik yönetiminde adaptif sistemlerin yalnızca trafik akışını değil,

evresel srdrlebilirlięi de nemli lde iyileřtirdięi grlmřtr. Ayrıca Adaptif ynetimin gerekleřtięi Senaryo 2, sabit sreli sistemin alıřtıęı Senaryo 1'e kıyasla daha verimli performans gstermesi arıza durumunda adaptif kontroln srdrlmesinin nemini ortaya koyulmuřtur.





5. SONUÇLAR

Bu Tez kapsamında, adaptif trafik sinyalizasyon sistemlerinin modellenmesi, analizi ve en iyilemesi için geçmiş zamanlı verilerle beslenip geleceği tahmin eden bir dijital ikiz mimarisi geliştirilmiştir. Çalışma Antalya ili Heybe Kavşağı, Ardıışık Kavşaklar (Heybe Kavşağı ve Türkay Kavşağı) ile Bursa ili Işıktepe Kavşağı için gerçekleştirilmiştir. Bu kapsamda gerçek trafik koşullarını yansıtan dijital ortamda mevcut trafik yönetimi yaklaşımlarını iyileştirmenin yanı sıra gelecekteki trafik senaryolarını öngörerek akıllı kavşak sistemlerine yenilikçi ve sürdürülebilir çözümler sunmuştur.

Tez çalışmasında geliştirilen derin öğrenme tabanlı trafik hacmi tahmin modelleri ile kavşaklardaki sensör arızası gibi beklenmedik durumlarda adaptif sinyal kontrolünün sürekliliği sağlanmış ve sabit zaman planına geçiş gerekliliği ortadan kaldırılmıştır. Bu modellerin etkinliği, SUMO Türkiye Uyarlaması kullanılarak oluşturulan benzetim ortamında doğrulanmıştır. Literatürde benzeri olmayan bir yaklaşımla tahmin modelleri doğrudan ulaşım ağına entegre edilmiş; böylece sanal operatörlerin farklı saatlerdeki trafik yoğunluğunu öngörüp sinyal sürelerini proaktif olarak ayarlayabileceği çoklu planlama stratejileri geliştirilmiştir.

Çalışma sonuçları, yerel yönetimlerin akıllı kavşak projelerinde kapasite geliştirilmesine rehberlik edecek şekilde tasarlanmıştır. Akıllı kavşak sistemlerinin deprem, fırtına gibi afetlere dirençli hale getirilmesi gerekliliği vurgulanmıştır. Araçların gereksiz bekleme sürelerinin azaltılması sayesinde sera gazı salımını ve enerji tüketimini en aza indirerek, iklim değişikliğiyle mücadeleyle ve ülke ekonomisine önemli katkılar sağlayan sürdürülebilir bir kavşak yönetim sistemi oluşturulması hedeflenmiştir. Bu kapsamda yapılan analizler şunlardır:

Tahmin Modelleri ve Performans Analizi: Tüm araç sınıfları (otomobil, motosiklet, minibüs, kamyon) için PCU dönüşümleri yapılarak tahmin modelleri oluşturulmuştur. Modellerin gerçek verilerle uyumlu kalibrasyonu sonucunda, eğitim ve test aşamalarında LSTM ve GRU tabanlı algoritmalarının daha dengeli ve başarılı sonuçlara ulaştığı gözlemlenmiştir. Bununla birlikte, veri kalitesinin model başarısına etkisini incelemek amacıyla ham veri ve aykırılıklardan arındırılmış veri ayrı ayrı değerlendirilmiştir.

Bu kapsamda, her kavşak ve istikamet için en başarılı modelin test metrikleri (MSE, MAE, R^2) ile sekiz farklı modelin ortalama performans değerleri karşılaştırmalı olarak sunulmuştur. Çizelge 5.1, Heybe ve Türkay Kavşakları özelinde elde edilen sonuçları özetlemekte olup, veri türleri arasındaki performans farklılıklarını açıkça göstermektedir.

Çizelge 5.1. Tahmin Modelleri Performans Sonuçları

	En Başarılı Model	En Başarılı Model Metrikleri			8 Model Metriğinin Ortalaması		
		MSE	MAE	R ²	MSE	MAE	R ²
Heybe Kavşağı 37887-37889 Aykırılıklardan Arındırılmış Veri	LSTM + GRU	281.567	12.462	0.845	306.841	12.930	0.832
Heybe Kavşağı 37887-37889 Ham Veri	LSTM + GRU	276.672	12.366	0.848	288.464	12.601	0.842
Heybe Kavşağı 37889-37887 Aykırılıklardan Arındırılmış Veri	LSTM + GRU	597.047	18.687	0.730	624.038	18.948	0.721
Heybe Kavşağı 37889-37887 Ham Veri	LSTM + GRU	587.428	18.557	0.735	609.818	18.858	0.724
Türkay Kavşağı 37860-37862 Aykırılıklardan Arındırılmış Veri	BiLSTM	427.962	15.423	0.789	447.521	15.716	0.780
Türkay Kavşağı 37860-37862 Ham Veri	BiLSTM	428.158	15.443	0.789	440.557	15.605	0.782
Türkay Kavşağı 37862-37860 Aykırılıklardan Arındırılmış Veri	Dikkat Mekanizması Tabanlı LSTM	623.053	18.522	0.736	647.277	18.779	0.726
Türkay Kavşağı 37862-37860 Aykırılıklardan Ham Veri	BiLSTM	625.821	18.669	0.734	655.287	19.028	0.720

Heybe Kavşağı 37887-37889 istikameti ham veri ve arındırılmış veri karşılaştırması:

- Aykırılıklardan arındırılmış veride LSTM + GRU modeli test performansında diğer modellere göre daha düşük MSE (281.567), MAE (12.462) ve daha yüksek R² (0.845) değerlerini alarak en başarılı sonuçları vermiştir.
- Ham veride ise LSTM + GRU modeli test performansında diğer modellere göre daha düşük MSE (276.672), MAE (12.366) ve daha yüksek R² (0.848) değerlerini alarak ön plana çıkmıştır.

- Ortalama test metriklerinin analiz sonuçları incelendiğinde, ham veri için Test MSE 288.464, Test MAE 12.601 ve Test R^2 0.842; arındırılmış veri için ise Test MSE 306.841, Test MAE 12.930 ve Test R^2 0.832 olarak elde edilmiştir. Sonuçlar karşılaştırıldığında, ham verinin daha düşük hata değerleri ve daha yüksek R^2 ile daha başarılı bir performans gösterdiği görülmüştür.

Heybe Kavşağı 37889-37887 istikameti ham veri ve arındırılmış veri karşılaştırması:

- Aykırılıklardan arındırılmış veride LSTM + GRU modeli test metriklerinde diğer modellere göre daha düşük MSE (597.047), MAE (18.687) ve daha yüksek R^2 (0.730) değerlerini alarak daha güçlü performans göstermiştir.
- Ham veride ise LSTM + GRU modeli test performansında diğer modellere göre daha düşük MSE (587.428), MAE (18.557) ve daha yüksek R^2 (0.735) değerlerini alarak ön plana çıkmıştır.
- Ortalama test metriklerinin analiz sonuçları incelendiğinde, ham veri için Test MSE 609.818, Test MAE 18.858 ve Test R^2 0.724; arındırılmış veri için ise Test MSE 624.038, Test MAE 18.948 ve Test R^2 0.721 olarak elde edilmiştir. Karşılaştırma sonucunda ham verinin daha düşük hata değerleri ve daha yüksek R^2 sağlamasıyla daha iyi performans sunduğu görülmüştür.

Türkay Kavşağı 37860-37862 istikameti ham veri ve arındırılmış veri karşılaştırması:

- Aykırılıklardan arındırılmış veride test performansında öne çıkan model BiLSTM olmuştur. BiLSTM modeli, test MSE değeri (427.962), test MAE değeri (15.423) ve test R^2 değeri (0.789) ile en başarılı sonuçları vermiştir. GRU modeli de benzer şekilde test R^2 değerinde (0.785) yüksek bir uyum sağlamıştır.
- Ham veride ise en başarılı model GRU olarak öne çıkmıştır. GRU modeli, test MSE değeri (428.158), test MAE değeri (15.443) ve test R^2 değeri (0.789) ile diğer modellerden daha iyi performans göstermiştir.
- Ortalama test metriklerinin analiz sonuçları incelendiğinde, ham veri için Test MSE 440.557, Test MAE 15.605 ve Test R^2 0.782; arındırılmış veri için ise Test MSE 447.521, Test MAE 15.716 ve Test R^2 0.780 olarak elde edilmiştir. Karşılaştırma sonucunda ham verinin daha düşük hata değerleri ve daha yüksek R^2 sağlamasıyla daha iyi performans sunduğu görülmüştür.

Türkay Kavşağı 37862-37860 istikameti ham veri ve arındırılmış veri karşılaştırması:

- Aykırılıklardan arındırılmış veride en başarılı sonuçları Dikkat Mekanizması Tabanlı LSTM ve Yığınlanmış LSTM modelleri vermiştir. Dikkat Mekanizması Tabanlı LSTM modeli test R^2 değeri (0.736) ile en yüksek doğruluk oranına ulaşırken, test MSE değeri (623.053) ve test MAE değeri (18.522) ile güçlü bir performans sergilemiştir. Yığınlanmış LSTM modeli ise test R^2 değeri (0.734) ve test MSE değeri (627.240) ile benzer şekilde yüksek uyum göstermiştir.
- Ham veride ise en başarılı model BiLSTM olmuştur. BiLSTM modeli test MSE değeri (625.821), test MAE değeri (18.669) ve test R^2 değeri (0.734) ile öne

çıkmiştir. Yığılanmış LSTM modeli de test R^2 değeri (0.734) ile benzer bir doğruluk sağlamıştır.

- Ortalama test metriklerinin analiz sonuçları incelendiğinde, ham veri için Test MSE 655.287, Test MAE 19.028 ve Test R^2 0.720; arındırılmış veri için ise Test MSE 647.277, Test MAE 18.779 ve Test R^2 0.726 olarak elde edilmiştir. Karşılaştırma sonucunda arındırılmış verinin R^2 açısından daha başarılı olduğu, hata metriklerinde ise küçük farklarla daha avantajlı sonuçlar verdiği görülmüştür.

SUMO Analiz Sonuçları: Heybe Kavşağı üzerinde gerçekleştirilen (DQL Uygulaması) sensör arızası senaryosunda, kavşak önceden belirlenmiş sabit zamanlı plana geçmeden DQL tabanlı adaptif kontrol modeliyle yönetilmiştir. Bu sayede hizmet seviyesi E seviyesinden B seviyesine yükselmiş; ortalama gecikme süresi %61.3 oranında azalmış ve ortalama araç hızı %134.6 oranında artmıştır. Sonuçlar sensör arızasının yaşandığı durumda önerilen alternatif yöntem senaryosunun sabit zamanlı kontrole göre çok daha yüksek performans sağladığını göstermiştir.

Ardışık Kavşak uygulamasında, sonuçlara göre uygulanan sinyalizasyon yaklaşımlarının emisyonlara ve çevreye etkileri LCA ile incelenmiştir. LCA çalışmaları sonucunda, ulaşımdan kaynaklanan emisyonların yalnızca GWP açısından değil; ince partikül madde oluşumu, karasal ekosistemlerde ozon üretimi, karasal asitlenme ve fosil kaynak kıtlığı gibi çevresel etki kategorileri açısından da önemli etkiler yarattığı belirlenmiştir. Son olarak önerilen sinyalizasyon yaklaşımlarının uygulanması ile bu etkilerde %4 ile %8 azaltım sağlanabileceği belirlenmiştir. Yapılan analizlerde adaptif sistemlerin yalnızca trafik akışını değil, aynı zamanda çevresel etkileri azaltmakta da etkili olduğunu göstermiştir.

Işıktepe Kavşağı üzerinde yapılan karşılaştırmalı analizde, adaptif sinyal süreleriyle çalışan sistem, sabit süreli sinyal planına kıyasla üstün performans göstermiştir. Adaptif mod, ortalama yolculuk süresini %19.8 oranında azaltırken ortalama hızı %27.6 oranında artırmıştır. Buna paralel olarak çevresel göstergelerde de iyileşme gözlenmiş; CO₂ emisyonları %13.3, CO %17.3, HC %16.8, NO_x %13.9 ve PM_x %11.8 oranında düşmüştür. Elde edilen bu kazanımlar, adaptif trafik kontrolünün hem verimlilik hem de çevresel etkiler açısından sabit zamanlı kontrol stratejisine göre belirgin avantajlar sağladığını kanıtlamaktadır.

Bu bağlamda, önerilen DQL ve veri analizi tabanlı adaptif kavşak kontrol stratejilerinin, sensör arızası gibi zorlu koşullarda da başarılı sonuçlar verdiği ve elde edilen nicel bulguların, akıllı şehir ekosistemlerinde dayanıklı ve sürdürülebilir bir çözüm olarak önerilen yaklaşımın değerini doğruladığı görülmüştür.

Gelecek Çalışmalar: Bu çalışma, akıllı kavşakların dijital ikiz altyapısı ve adaptif trafik yönetim sistemlerinin verimliliğini artırmaya yönelik önemli bir adım atmıştır. Ancak, önerilen modelin daha geniş bir uygulama alanına taşınabilmesi ve gerçek dünya koşullarında daha etkin hale gelmesi için bazı geliştirmelere ve ek araştırmalara ihtiyaç duyulmaktadır. Gelecekteki çalışmalar, mevcut modellerin ölçeklenebilirliğini ve pratik uygulanabilirliğini değerlendirmeye yönelik daha kapsamlı araştırmalar ve uygulama testleri gerçekleştirmeyi hedeflemektedir. Aşağıda, bu alanda gelecekte yapılması planlanan önemli araştırma ve geliştirme konuları belirtilmiştir:

- Ağ Ölçeğine Yayılım ve MARL: Çalışmanın geleceğinde, önerilen çerçevenin yalnızca tekil kavşaklarla sınırlı kalmayıp çoklu kavşak ağları ya da şehir ölçeğindeki sistemlere uyarlanması planlanmaktadır. Bu doğrultuda, birden fazla kavşak arasındaki etkileşimleri gerçekçi bir şekilde modellemek için Çok Ajanlı Pekiştirmeli Öğrenme (MARL) yöntemlerinin araştırılması gerekmektedir. Böyle bir genişleme, farklı kavşakların koordineli adaptif kontrolüyle trafik en iyilemesini şehir genelinde ele almayı mümkün kılacaktır.
- Gerçek Zamanlı Veri ve Saha Uygulamaları: Önerilen modelin güvenilirliğini ve dayanıklılığını pekiştirmek adına gerçek zamanlı trafik uygulamasıyla doğrulama çalışmalarına ihtiyaç vardır. Canlı saha uygulamalarının hayata geçirilmesi, düzensiz sürücü davranışları, iletişim gecikmeleri ve beklenmedik donanım arızaları gibi gerçek dünya belirsizlikleri altında sistem performansının sınanmasına imkan tanıyacaktır. Bu sayede modelin pratik uygulanabilirliği ve gerçek zamanlı uyarlanabilirliği değerlendirilebilecektir.
- Genelleme ve Ölçeklenebilirlik Analizleri: Geliştirilen yaklaşımın farklı şehir ortamlarında da test edilerek genelleme yeteneğinin incelenmesi önerilmektedir. Farklı coğrafi ve demografik özelliklere sahip şehirlerden elde edilecek veriler üzerinde yapılacak çalışmalar, modelin ölçeklenebilirliğini değerlendirmeye yardımcı olacaktır. Böylelikle yaklaşımın geniş ölçekli akıllı ulaşım sistemlerine uyarlanabilirliği ve farklı koşullara adaptasyonu konusunda önemli bulgular elde edilebilecektir.
- Kıyaslamalı Performans Değerlendirmeleri: Adaptif kontrolün faydalarını bütüncül şekilde değerlendirebilmek için sensör arızası senaryolarında en iyilenmiş sabit zamanlı sinyal planları ile detaylı karşılaştırmalar yapılmalıdır. Bu kıyaslamalar, önerilen yöntemin geleneksel yöntemlere göre sağladığı avantajları nicel olarak ortaya koyarak hangi koşullarda ne kadar iyileşme sağlandığını netleştirecektir.
- Yaya Entegrasyonu: Gelecekteki çalışmalarda adaptif trafik kontrol modeline yaya fazlarının entegre edilmesi önemli görülmektedir. Yaya geçişlerine sistemde açık biçimde yer verilmesi, tüm yol kullanıcıları için güvenlik ve verimlilik değerlendirmesi yapmaya olanak tanıyacaktır. Böylece adaptif sistemlerin yayalar üzerindeki etkileri de analiz edilerek şehir içi ulaşımın bütüncül en iyilemesi hedeflenebilecektir.
- Gelişmiş Yapay Zekâ Modelleri: Mevcut çalışmada kullanılan LSTM, GRU, RNN gibi tekrarlayan sinir ağı temelli modellerin ötesinde, ileriki araştırmalarda Transformer ve Grafik Sinir Ağları (GNN) gibi ileri düzey yapay zekâ mimarilerinin incelenmesi hedeflenmektedir. Bu sayede, trafik akışındaki uzun dönemli zamansal ve mekânsal bağımlılıkların daha etkin bir biçimde modellenmesi mümkün olacak ve adaptif trafik yönetiminde daha yüksek doğrulukla tahmin ve kontrol sağlanabilecektir.
- Öz Niteliklerin Genişletilmesi: Tahmin modellerinin başarısını artırmak amacıyla hava durumu koşulları ve özel günler gibi öz nitelikler sisteme dahil edilecektir. Böylece, adaptif trafik yönetim sistemlerinin daha esnek ve güvenilir sonuçlar üreteceği öngörülmektedir.



6. KAYNAKLAR

- Aimsun. 2023. Real-time transportation management. <https://www.aimsun.com/real-time-transportation-management/> [Son erişim tarihi: 27.03.2023].
- Akgül, O. 2021. Türkiye Paris İklim Anlaşması'nı onayladı. Peki şimdi ne olacak? <https://www.greenpeace.org/turkey/blog/turkiye-paris-iklim-anlasmasini-onayladi-peki-simdi-ne-olacak/> [Son erişim tarihi: 21.02.2024].
- Akıllı Şehirler Portalı. 2024a. Bursa Kentsel Trafik Yönetim Merkezi Projesi. <https://www.akillisehirler.gov.tr/proje-envanteri/bursa-kentsel-trafik-yonetim-merkezi-projesi/> [Son erişim tarihi: 10.03.2024].
- Akıllı Şehirler Portalı. 2024b. Yalova Dinamik Akıllı Kavşaklar Projesi. <https://www.akillisehirler.gov.tr/proje-envanteri/yalova-dinamik-akilli-kavsaklar-projesi/> [Son erişim tarihi: 10.03.2024].
- Akıllı Şehirler Portalı. 2024c. Sakarya Acil Durum Sinyalizasyon Sisteminin Kurulması. <https://www.akillisehirler.gov.tr/proje-envanteri/sakarya-acil-durum-sinyalizasyon-sisteminin-kurulmasi/> [Son erişim tarihi: 10.03.2024].
- Akıllı Şehirler Portalı. 2024d. Balıkesir Trafik Yönetim Sistemi. <https://www.akillisehirler.gov.tr/proje-envanteri/balikesir-trafik-yonetim-sistemi/> [Son erişim tarihi: 10.03.2024].
- Akıllı Şehirler Portalı. 2024e. Sakarya Adaptif Trafik Uyarmalı Trafik Yönetim Sistemi. <https://www.akillisehirler.gov.tr/proje-envanteri/sakarya-adaptif-trafik-uyarmali-trafik-yonetim-sistemi/> [Son erişim tarihi: 10.03.2024].
- Alajali, W., Zhou, W., and Wen, S. 2018. Traffic Flow Prediction for Road Intersection Safety. 2018 IEEE SmartWorld, Ubiquitous Intelligence and Computing, Advanced and Trusted Computing, Scalable Computing and Communications, Cloud and Big Data Computing, Internet of People and Smart City Innovation. ss 812-820, Guangzhou, China.
- Ali, F.M.N. and Hamed, A.A.M. 2018. Usage Apriori and clustering algorithms in WEKA tools to mining dataset of traffic accidents. *Journal of Information and Telecommunication*, 2 (3): 231–245.
- Alshayeb, S., Stevanovic, A., Mitrovic, N. and Espino, E. 2022. Traffic signal optimization to improve sustainability: A literature review. *Energies*, 15: 8452.
- Anonim 1: <https://www.cnnturk.com/video/turkiye/deprem-bolgesinde-trafik-sorunu> [Son erişim tarihi: 10.03.2024].
- Anonim 2: <https://www.trthaber.com/haber/gundem/deprem-bolgesinde-yol-durumu-3-ile-arac-girisi-durduruldu-744493.html> [Son erişim tarihi: 15.05.2024].
- Aydın, M.M. ve Kekeş, M.A. 2024. Trafikte Acil Durum Müdahale Araçlarının Geçiş Esnasındaki Karmaşa Problemleri İçin AUS Tabanlı Bir Çözüm Önerisi Geliştirilmesi. *Iğdır Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 14 (1): 294–311.
- Aynacı, İ. 2020. Dijital İkiz ve Sağlık Uygulamaları. *İzmir Kâtip Çelebi Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 3 (1): 70–79.

- Bare, J.C., Hofstetter, P., Pennington, D.W. and Udo de Haes, H.A. 2000. Midpoints versus endpoints: the sacrifices and benefits. *International Journal of Life Cycle Assessment*, 5: 319–326.
- Balta, M. and Özçelik, İ. 2019. Şehir içi kavşak yönetim sistemleri için SDN temelli bir VANET mimari önerisi. *Journal of the Faculty of Engineering and Architecture of Gazi University*, 34 (3): 1451–1468.
- Boz, C. 2019. Yol Ağı Kavşaklarında Trafik Akışının Simülasyonu ve Konfigürasyondaki Değişim Etkilerinin Araştırılması. Yüksek Lisans Tezi, Yıldız Teknik Üniversitesi, İstanbul, 62 s.
- Bursa Trafik Kontrol Merkezi. 2023. Bursa kent genelinde sinyalizasyon kavşakları ve yaya geçitleri kapsamında yürütülen sinyalizasyon sistemleri ve Akıllı Ulaşım Sistemleri kontrol altyapısına ilişkin teknik bilgi raporu. Bursa, Türkiye.
- Bratsas, C., Koupidis, K., Salanova, J.M., Giannakopoulos, K., Kaloudis, A., and Aifadopoulou, G. 2020. A comparison of machine learning methods for the prediction of traffic speed in Urban places. *Sustainability (Switzerland)*: 12 (1).
- Çeltek, S.A. 2021. Şehir içi trafik sinyal ağının takviyeli öğrenme algoritmaları ve nesnelerin interneti tabanlı kontrolü. Doktora Tezi, Konya Teknik Üniversitesi, Konya, 100 s.
- Çevre Şehircilik ve İklim Değişikliği Bakanlığı. 2016. Paris Anlaşması imzalandı. <https://www.csb.gov.tr/paris-anlasmasi-imzalandi-bakanlik-faaliyetleri-1510> [Son erişim tarihi: 05.12.2023].
- Coğrafi Bilgi Sistemleri Müdürlüğü, 2022. Şehirlerin Dijital İkizlerini Güncelliyoruz. <https://cbs.csb.gov.tr/sehirlerin-dijital-ikizlerini-guncelliyoruz-haber-278818> [Son erişim tarihi: 01.01.2025].
- Dasgupta, S., Rahman, M., Lidbe, A.D., Lu, W. and Jones, S. 2021. A transportation digital-twin approach for adaptive traffic control systems. *arXiv (Cornell University)*
- Ding, A., Zhang, R., Ngo, H.H., He, X., Ma, J., Nan, J. and Li, G. 2021. Life cycle assessment of sewage sludge treatment and disposal based on nutrient and energy recovery: a review. *Science of the Total Environment*, 769: 144451.
- Dönmezçelik, O., Koçak, E., ve Örkücü, H.H., 2023. Net Sıfır Emisyon Hedefine Doğru Türkiye Kara Yolu ve Demir Yolu Taşımacılığının Enerji Modellemesi (2025-2050). *Politeknik Dergisi*, 27(3): 931-946.
- European Commission, 2023. Causes of climate change. https://climate.ec.europa.eu/climate-change/causes-climate-change_en [Son erişim tarihi: 06.02.2024].
- Faliagka, E., Christopoulou, E., Ringas, D., Politi, T., Kostis, N., Leonardos, D., Tranoris, C., Antonopoulos, C.P., Denazis, S., and Voros, N. 2024. Trends in Digital Twin Framework Architectures for Smart Cities: A Case Study in Smart Mobility. *Sensors*, 24 (5): 1665.
- Fazio, S., Garráin, D., Mathieux, F., De la Rúa, C., Recchioni, M. and Lechón, Y. 2015. Method applied to the background analysis of energy data to be considered for the European Reference Life Cycle Database (ELCD). *SpringerPlus*, 4: 150.

- Fujii, T.Y., Hayashi, V.T., Arakaki, R., Ruggiero, W.V., Bulla, R., Hayashi, F.H. and Khalil, K.A. 2022. A Digital Twin Architecture Model Applied with MLOps Techniques to Improve Short-Term Energy Consumption Prediction. *Machines*: 10 (1).
- Fuller, A., Fan, Z., Day, C. and Barlow, C. 2020. Digital twin: Enabling technologies, challenges and open research. *IEEE access*, 8, 108952–108971.
- Gao, J., Chen, H., Dave, K., Chen, J., and Jia, D. 2020. Fuel economy and exhaust emissions of a diesel vehicle under real traffic conditions. *Energy Science and Engineering*, 8 (5): 1781–1792.
- Goedkoop, M., Heijungs, R., Huijbregts, M., De Schryver, A., Struijs, J. ve van Zelm, R. 2013. ReCiPe 2008: a life cycle impact assessment method which comprises harmonised category indicators at the midpoint and the endpoint level. First edition (version 1.08), Report I: Characterisation. PRE Consultants, Amersfoort; CML University of Leiden; RUN Radboud University Nijmegen; RIVM, Bilthoven, Netherlands.
- Guo, Q., Li, L. ve Ban, X.J. 2019. Urban traffic signal control with connected and automated vehicles: A survey. *Transportation Research Part C: Emerging Technologies*, 101: 313–334.
- Hou, Y., Deng, Z., and Cui, H. 2021. Short-Term Traffic Flow Prediction with Weather Conditions: Based on Deep Learning Algorithms and Data Fusion. *Complexity*, 2021 (1): 1-14.
- Huijbregts, M.A.J., Steinmann, Z.J.N., Elshout, P.M.F., Stam, G., Verones, F., Vieira, M., Zijp, M., Hollander, A. and van Zelm, R. 2017. ReCiPe2016: a harmonized life cycle impact assessment method at midpoint and endpoint level. *International Journal of Life Cycle Assessment*, 22: 138–147.
- Hu, T.Y. and Li, Z.Y. 2024. A multi-agent deep reinforcement learning approach for traffic signal coordination. *IET Intelligent Transport Systems*: 18 (8), 1428–1444.
- T.C. Çevre Şehircilik ve İklim Değişikliği Bakanlığı. 2023a. 2053 yılı itibarıyla net sıfır emisyon hedefini gerçekleştirmeyi öngörüyoruz. <https://iklim.gov.tr/2053-yili-itibariyla-net-sifir-emisyon-hedefini-gerceklestirmeyi-ongoruyoruz-haber-4173> [Son erişim tarihi: 05.12.2024].
- T.C. Çevre Şehircilik ve İklim Değişikliği Bakanlığı. 2023b. Kent İçi Hareketlilik Analiz Sistemi (SUMO Türkiye Uyarlaması). <https://akillisehirekosistem.csb.gov.tr/DataBank/Detail?mId=310035003800&databankDataTypeId=3900360030003600> [Son erişim tarihi: 18.12.2023].
- İlyas, S. ve Albayrak, Y. 2023. Akıllı kavşaklarda trafik hacmi tahmini için makine öğrenmesi modellerinin karşılaştırılması. *Gazi Journal of Engineering Sciences*, 9 (4): 141–150.
- İlyas, S., Ulusoy, B.E., Köfteci, S. and Albayrak, Y. 2024. Association of vehicle count data obtained via image processing techniques compared with microsimulation program analysis results. *Networks and Spatial Economics*, 24 (3): 655–680.
- Irfan, M.S., Dasgupta, S., and Rahman, M. 2022. Towards Transportation Digital Twin Systems for Traffic Safety and Mobility Applications: A Review. *arXiv preprint*

arXiv:2212.12242.

- ISO 14040, 2006. International Standard. Environmental Management - Life cycle assessment - Principles and Framework. International Organisation for Standardisation, Geneva.
- ISO 14044, 2006. International Standard. Environmental management - Life cycle assessment - Requirements and Guidelines. International Organisation for Standardisation, Geneva.
- ISSD. 2024. Solutions are Now Integrated with Digital Twins. https://www.youtube.com/watch?v=JxCFqMR5uE8&ab_channel=ISSDBili%C5%9FimElektronik [Son erişim tarihi: 24.06.2024].
- Janković, S., Uzelac, A., Zdravković, S., Mladenović, D., Mladenović, S., and Andrijanić, I. 2021. Traffic Volumes Prediction Using Big Data Analytics Methods. *International Journal for Traffic and Transport Engineering*, 2 (0): 184–198.
- Jaramillo, P., Kahn Ribeiro, S., Newman, P., Dhar, S., Diemuodeke, O.E., Kajino, T., Lee, D.S., Nugroho, S.B., Ou, X., Hammer Strømman, A. ve Whitehead, J. 2022. Transport. In: IPCC. Climate Change 2022: Mitigation of Climate Change. Contribution of Working Group III to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change. Cambridge University Press, Cambridge, UK.
- Krajzewicz, D., Behrisch, M., Wagner, P., Luz, R. and Krumnow, M. 2015. Second generation of pollutant emission models for SUMO. 2nd SUMO Conference, pp. 203–221, May 15–16, Berlin, Germany.
- Kemeç, A. ve Gül, H. 2021. Antalya Büyükşehir Belediyesi Örneğinde Akıllı Kent Uygulamaları. *Journal of Public Administration and Policy*, 2 (3): 355–382.
- Kim, H., Park, J., Kim, D., and Jun, C. 2025. Cooperative control of intersection traffic signals based on multi-agent reinforcement learning for carbon dioxide emission reduction. *IEEE Access*, 13: 33485-33495.
- Kumarasamy, V.K., Saroj, A.J., Liang, Y., Wu, D., Hunter, M.P., Guin, A., and Sartipi, M. 2024a. Integration of Decentralized Graph-Based Multi-Agent Reinforcement Learning with Digital Twin for Traffic Signal Optimization. *Symmetry*: 16 (4), 448.
- Li, H., Li, H., Hu, Y., Xia, T., Miao, Q., and Chu, J. 2023. Evaluation of fuel consumption and emissions benefits of connected and automated vehicles in mixed traffic flow. *Frontiers in Energy Research*, 11: 1207449.
- Liu, Q., Sun, S., Liang, Y., Xu, X., Liu, M., Bilal, M., Wang, Y., Li, X., and Zheng, Y. 2025. REFOL: Resource-Efficient Federated Online Learning for Traffic Flow Forecasting. *IEEE Transactions on Intelligent Transportation Systems*, 26 (2): 2777–2792.
- Lv, J., Wang, Z. and Ma, J. 2025. Carbon Emission Reduction in Traffic Control: A Signal Timing Optimization Method Based on Rainbow DQN. *Applied Science*, 15 (3): 1101.
- Navarro-Espinoza, A., López-Bonilla, O.R., García-Guerrero, E.E., Tlelo-Cuautle, E., López-Mancilla, D., Hernández-Mejía, C., and Inzunza-González, E. 2022.

- Traffic flow prediction for smart traffic lights using machine learning algorithms. *Technologies*, 10 (1): 5.
- Pachauri, R.K., Allen, M.R., Barros, V.R., Broome, J., Cramer, W., Christ, R., Church, J.A., Clarke, L., Dahe, Q., and Dasgupta, P. 2014. *Climate Change 2014: Synthesis Report*.
- Patel, K. and Singh, S.K. 2022. A life cycle approach to environmental assessment of wastewater and sludge treatment processes. *Water and Environment Journal*, 36 (3): 412–424.
- Politi, R.R. and Tanyel, S. 2025. Developing a Sustainable Traffic Management Framework Using Machine Learning Models for Fuel Consumption Minimization at Closely Spaced Intersections. *Sustainability*, 17 (3): 1267.
- Rezaei, Z., Vahidnia, M.H., Aghamohammadi, H., Azizi, Z., and Behzadi, S. 2023. Digital twins and 3D information modeling in a smart city for traffic controlling: A review. *Journal of Geography and Cartography*, 6 (1): 1-27.
- Rou, Y., Liang, C., and Lu, Z. 2024. Application of Ensemble Learning and VISSIM in Intersection Traffic Flow Prediction and Signal Timing Optimization. *IEEE Access*, 12 : 194891-194898.
- Santos, O., Ribeiro, F., Metrôlho, J., and Dionísio, R. 2023. Using Smart Traffic Lights to Reduce CO2 Emissions and Improve Traffic Flow at Intersections: Simulation of an Intersection in a Small Portuguese City. *Applied System Innovation*, 7 (1): 3.
- Shamlitsky, Y., Aleksey, O., Morozov, E., and Strekaleva, T. 2024. Using digital twins to manage traffic flows. *E3S Web of Conferences*, pp 1-6.
- Shao, Q., Piao, X., Yao, X., Kong, Y., Hu, Y., Yin, B., and Zhang, Y. 2024. An adaptive composite time series forecasting model for short-term traffic flow. *Journal of Big Data*, 11 (1): 1–22.
- Shen, J., Hu, J., Zhao, Q., and Rao, W. 2023. Heterogeneous traffic intersections control design based on reinforcement learning. *IET Intelligent Transport Systems*, 18 (10): 1760-1776.
- Shin, H., Oh, S., Isah, A., Aliyu, I., Park, J., and Kim, J. 2023. Network Traffic Prediction Model in a Data-Driven Digital Twin Network Architecture. *Electronics*, 12 (18): 1-15.
- Mahmood, T. A. M. 2019. Akıllı şehirler için adaptif trafik sinyalizasyon kontrolü. Yüksek Lisans Tezi, Selçuk Üniversitesi, Konya, 73 s.
- Notter, B., Keller, M., Althaus, H. J., Cox, B., Knörr, W., Heidt, C., Biemann, K., Räder, D. and Jamet. M. 2019. HBEFA 4.1 Development Report, INFRAS. https://www.hbefa.net/e/ documents/HBEFA41_Development_Report.pdf [Son erişim tarihi: 10.02.2023].
- Tomanik, E., Jimenez-Reyes, A.J., Tomanik, V. and Tormos, B. 2023. Machine-Learning-Based Digital Twins for Transient Vehicle Cycles and Their Potential for Predicting Fuel Consumption. *Vehicles*, 5 (2): 583–604.
- Topal, E. 2022. Sezgisel algoritma tabanlı trafik ışıkları optimizasyonu ve benzetimi.

- Yüksek Lisans Tezi, Şeyh Edebalı Üniversitesi, Bilecik, 52 s.
- Tuğaç, Ç. 2022. İklim Değişikliği ve Kentsel Dirençlilik Bağlamında Yeşil Ulaşım. *İdealkent*, 13 (36): 545–575.
- Türkiye İstatistik Kurumu (TÜİK). 2024. “Motorlu Kara Taşıtları, Ekim 2024”. <https://data.tuik.gov.tr/Bulten/Index?p=Motorlu-Kara-Tasitlari-Ekim-2024-53461> [Son Erişim Tarihi: 26.02.2025].
- Türk Standartları Enstitüsü (Türk Standartları TS6407). 2013 Şehir içi ulaşım hesaplamalarında kullanılan araç tiplerine göre otomobil eşdeğeri katsayıları.
- Tunc, I., Yesilyurt, A.Y., Gumus, Z., Sert, K., Koroglu, A.O. and Soylemez, M.T. 2024. A platoon ordering algorithm on reservation based intersection management systems. *Alexandria Engineering Journal*, 88, 36–44.
- UKOME (Ulaşım Koordinasyon Merkezi). 2023. Antalya Büyükşehir Belediyesi sorumluluğu kapsamındaki yolların trafik kesitlerine göre yıllık ortalama trafik değerleri ve ulaşım bilgileri. Antalya, Türkiye.
- Uzer, O. ve Özaslan, A. 2023. Bursa ve Antalya’nın akıllı kentiçi ulaşım denemeleri. *Journal of Intelligent Transportation Systems and Applications*, 6 (2): 238–252.
- Vidali, A., Crociani, L., Vizzari, G. and Bandini, S. 2019. A Deep Reinforcement Learning Approach to Adaptive Traffic Lights Management. Proceedings of the 20th Workshop “From Objects to Agents”, 26-28 June, Parma, Italy.
- Wang, Z., Gupta, R., Han, K., Wang, H., Ganlath, A., Ammar, N., and Tiwari, P. 2022. Mobility Digital Twin: Concept, Architecture, Case Study, and Future Challenges. *IEEE Internet of Things Journal*, 9 (18): 17452–17467.
- Wang, Z., Han, K. and Tiwari, P. 2022. Digital Twin-Assisted Cooperative Driving at Non-Signalized Intersections. *IEEE Transactions on Intelligent Vehicles*, 7 (2): 198–209.
- Wang, Z., Xu, L. and Ma, J. 2023. Carbon Dioxide Emission Reduction-Oriented Optimal Control of Traffic Signals in Mixed Traffic Flow Based on Deep Reinforcement Learning. *Sustainability*, 15 (24): 16564.
- Wu, K., Ding, J., Lin, J., Zheng, G., Sun, Y., Fang, J., Xu, T., Zhu, Y. and Gu, B. 2025. Big-data empowered traffic signal control could reduce urban carbon emission. *Nature Communications*, 16 (1): 1–12.
- Ye, B.L., Zhang, M., Li, L., Liu, C., and Wu, W. 2024. A Survey of Traffic Flow Prediction Methods Based on Long Short-Term Memory Networks. *IEEE Intelligent Transportation Systems Magazine*, 16 (5): 87-112.
- Zhao, B., Lin, Y., Hao, H., and Yao, Z. 2022. Fuel Consumption and Traffic Emissions Evaluation of Mixed Traffic Flow with Connected Automated Vehicles at Multiple Traffic Scenarios. *Journal of Advanced Transportation*, 2022 (1): 14
- Zhang, Z., Zhang, W., Liu, Y., and Xiong, G. 2023. Mean Field Multi-Agent Reinforcement Learning Method for Area Traffic Signal Control. *Electronics*, 12 (22): 4686.
- Xu, B., Ban, X.J., Bian, Y., Li, W., Wang, J., Li, S.E., Li, K. 2018. Cooperative method of traffic signal optimization and speed control of connected


vehicles at isolated intersections. *IEEE Trans. Intelligent Transportation System*, 20: 1390–1403.





7. EKLER

EK-1: LSTM + GRU için eğitim ve doğrulama kayıpları (500 epokluk örnek çalışma).





ÖZGEÇMİŞ

Seyitali İLYAS

ÖĞRENİM BİLGİLERİ

Doktora	Akdeniz Üniversitesi
2019-2025	Fen Bilimleri Enstitüsü, Elektrik Elektronik Mühendisliği Anabilim Dalı, Antalya, Türkiye
Yüksek Lisans	Akdeniz Üniversitesi
2015-2019	Fen Bilimleri Enstitüsü, Elektrik Elektronik Mühendisliği Anabilim Dalı, Antalya, Türkiye
Lisans	Pamukkale Üniversitesi
2009-2013	Fen Bilimleri Enstitüsü, Elektrik Elektronik Mühendisliği Anabilim Dalı, Denizli, Türkiye

MESLEKİ VE İDARİ GÖREVLER

Elektrik Elektronik Mühendisi	Antalya Büyük Şehir Belediyesi,
2014-2024	Ulaşım Dairesi Başkanlığına bağlı Trafik Şube Müdürlüğü, Sinyalizasyon Biriminde

ESERLER

Uluslararası hakemli dergilerde yayımlanan makaleler

- User, Y., İlyas, S., & Tinaztepe, G. (2021). Performance Evaluation Of A Hybrid Roundabout Using A Microscopic Simulation. Baltic Journal of Road & Bridge Engineering (RTU Publishing House), 16(3).
- İlyas, S., Ulusoy, B.E., Köfteci, S. Albayrak, Y. (2024). Association of Vehicle Count Data Obtained Via Image Processing Techniques Compared with Microsimulation Program Analysis Results. Netw Spat Econ. <https://doi.org/10.1007/s11067-024->

Ulusal ve uluslararası bilimsel toplantılarda sunulan ve bildiri kitaplarında basılan bildiriler

1. İlyas S., User Y. (2015). Transition To Urban İts; The Case Of Antalya, Road Traffic Safety – Congress (ROTRASA)
2. İlyas S., User Y. (2017). Determination of Traffic Intensity with Optimum Detection of Vehicle Count Using Virtual Zone. International Conference On Engineering Technologies (ICENTE'17).
3. İlyas S., User Y. (2017). Optimum Desing Of A Rotary Intersection With Aimsun Programme. International Conference On Engineering Technologies (ICENTE'17).
4. İlyas S., User Y. (2017). Transit Pass Application For Signalized Traffic Roundabouts And Evaluation By Using Aimsun Simulation, International Advanced Researches & Engineering Congress (IAREC2017).
5. İlyas S., User Y. (2018). Impact Of The Sıgnal Plan Attangement At The Pedestrian Crossing With Button Application In Antalya And Aimsun Simulation Program To The System Performance, Umteb 4. Uluslararası Mesleki Ve Teknik Bilimler Kongresi (UMTEB).
6. İlyas S., Üser Y., "Antalya Konyaaltı Caddesinde Yeşil Dalga Koridoru üzerindeki Eş Periyotlu Statik Koordinasyonlu Sinyalizasyon Sistemlerinde Faz Farkının Modüler Aritmetik Yöntemiyle Hesaplanması", IMASCON 2019, KOCAELİ, TÜRKİYE, 1-3 Kasım 2019, pp.330-334
7. İlyas S., Üser Y., Köfteci S., (2023) "Antalyada Sinyalize Kavşaklarda Flaş Modunun Farklı Senaryolu Mikrosimilasyon Modellerinde Değerlendirilmesi", IMASCON 2019, KOCAELİ, TÜRKİYE, 1-3 Kasım 2019, pp.335-340
8. İlyas S., Albayrak Y., (2023) Tam Adaptif Trafik Yönetim Sistemi Performans Değerlendirmesi Conference: Karayolları 5. Ulusal Kongresi ve Sergisi Yer : ANKARA, TÜRKİYE
9. İlyas S., Albayrak Y., (2023) Sürdürülebilir Kent İçi Ulaşım: Antalya'da Akıllı Sinyalizasyonun Geleceği TMMOB (Türk Mühendis ve Mimar Odaları Birliği) Antalya İKK (İl Koordinasyon Kurulu) KENT SEMPOZYUMU, ANTALYA, TÜRKİYE
10. İlyas S., Albayrak Y., (2023) Akıllı Kavşaklarda Yeni Trafik Yönetim Teknolojisi Konferans Adı : The 2nd Innovation Management And Triz Conference Yer : BAKÜ, AZERBAIJAN Basım Tarihi : 13 Şubat 2024
11. İlyas S., Albayrak Y., Kentsel meknda e-skuter kullanıma ilikin Türkiye ve dünyada yapılan yasal düzenleme örnekleri Akıllı Ulaşım Sistemleri ve Uygulamalar Dergisi (2024) Cilt : 7 Sayı : 1 Sayfa : 3142
12. S. İlyas, Y. Albayrak & T. E. Türkoğlu, "Veri Bilimi Tabanlı Kapasite Geliştirme - Sürdürülebilir Akıllı Ulaşım Sistemi", 25. Otomatik Kontrol Ulusal Konferansı (TOK-2024), Konya, Türkiye, 24 Ekim 2024.

Akademik destek ve ödüller

1. Antalya Trafik Kontrol Merkezi projesi hazırladığım rapor sonucunda Türkiye Akıllı Ulaşım Sistemleri Derneği tarafından 2023 Akıl Yolu Ödülleri'nde jüri özel ödülüne

- layık görölmüştür.
2. 2024 Havacılık, Uzay ve Teknoloji Festivali kapsamında bu yıl Antalya'da Akıllı Ulaşım kategorisinde 104.971 takım arasından final aşamasına kalınmıştır (TEKNOFEST 2024 FİNAL).
 3. 1002-b TÜBİTAK projesi yürütücülüğü gerçekleştirilmiştir. Bu kapsamda bir öğrenciye araştırma bursu sağlanmış olup ayrıca konferans desteğinden yararlanılmıştır.
 4. TÜBİTAK tarafından başarıya verilen ödöl niteliğı taşıyan 2211-C Yurt İçi Öncelikli Alanlar Doktora Burs Programı kapsamında Doktora çalışmam desteklenmiştir.
 5. Bursa Büyükşehir Belediyesi Lisansüstü Tez Destek Programı kapsamında tez çalışmam, Akıllı Şehirler, Dirençli Şehirler ve Sürdürülebilir Şehirler çerçevesinde kent ihtiyaçlarına yönelik sunduğı önemli katkılar neticesinde desteklenmeye değeri bulunmuştur (2024).

