



T.C.
EGE ÜNİVERSİTESİ
Fen Bilimleri Enstitüsü



DERİN ÖĞRENME TEKNİKLERİ KULLANILARAK RAYLI SİSTEMLER İÇİN GÜNLÜK SEYAHAT TALEBİ TAHMİN MODELİ GELİŞTİRİLMESİ

Yüksek Lisans Tezi

Halil Uğur ERCAN

İnşaat Mühendisliği Anabilim Dalı

İzmir
2023

T.C.
EGE ÜNİVERSİTESİ
Fen Bilimleri Enstitüsü

**DERİN ÖĞRENME TEKNİKLERİ KULLANILARAK
RAYLI SİSTEMLER İÇİN GÜNLÜK SEYAHAT
TALEBİ TAHMİN MODELİ GELİŞTİRİLMESİ**

Halil Uğur ERCAN

Tez Danışmanı: Doç. Dr. Yalçın ALVER

İnşaat Mühendisliği Anabilim Dalı
İnşaat Mühendisliği Yüksek Lisans Programı

İzmir
2023

EGE ÜNİVERSİTESİ FEN BİLİMLERİ ENSTİTÜSÜ

ETİK KURALLARA UYGUNLUK BEYANI

EÜ Lisansüstü Eğitim ve Öğretim Yönetmeliğinin ilgili hükümleri uyarınca Yüksek Lisans Tezi / Doktora Tezi olarak sunduğum “Derin Öğrenme Teknikleri Kullanılarak Raylı Sistemler için Günlük Seyahat Talebi Tahmin Modeli Geliştirilmesi” başlıklı bu tezin kendi çalışmam olduğunu, sunduğum tüm sonuç, doküman, bilgi ve belgeleri bizzat ve bu tez çalışması kapsamında elde ettiğimi, bu tez çalışmasıyla elde edilmeyen bütün bilgi ve yorumlara atıf yaptığımı ve bunları kaynaklar listesinde usulüne uygun olarak verdiğimi, tez çalışması ve yazımı sırasında patent ve telif haklarını ihlal edici bir davranışımın olmadığını, bu tezin herhangi bir bölümünü bu üniversite veya diğer bir üniversitede başka bir tez çalışması içinde sunmadığımı, bu tezin planlanmasından yazımına kadar bütün safhalarda bilimsel etik kurallarına uygun olarak davrandığımı ve aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul edeceğimi beyan ederim.

19/09/2023

Halil Uğur ERCAN

ÖZET**DERİN ÖĞRENME TEKNİKLERİ KULLANILARAK RAYLI SİSTEMLER İÇİN GÜNLÜK SEYAHAT TALEBİ TAHMİN MODELİ GELİŞTİRİLMESİ**

ERCAN, Halil Uğur

Yüksek Lisans Tezi, İnşaat Mühendisliği Anabilim Dalı

Tez Danışmanı: Doç. Dr. Yalçın ALVER

Eylül 2023, 85 sayfa

Ulaşım sistemlerini etkin bir şekilde planlamak ve yönetmek için gelecekteki seyahat taleplerini tahmin etmek oldukça önemlidir. Toplu taşıma sistemlerindeki günlük seyahat talebinin tahmini; sefer sıklığı düzenleme, giriş çıkış turnike sayısı ve hizmet verecek personel sayısını belirleme gibi birçok operasyonel karar alınırken dikkate alınmalıdır. Bu tez çalışması, raylı sistemler özelinde, toplu taşıma sistemlerindeki talep tahminlerinde derin öğrenme tekniklerinin potansiyelini ortaya koymayı amaçlamaktadır. Çalışmada İstanbul'da hizmet veren M2 Yenikapı – Hacıosman Metro hattına ait 2019 yılı günlük seyahat verileri kullanılarak farklı derin öğrenme modelleri geliştirilmiş ve 2020 yılı günlük seyahat verileri ile model başarıları test edilmiştir. Tezde, dışsal faktör verilerinin (hava durumu, kentteki etkinlikler, tatiller, haftanın günü vb.) seyahat taleplerine etkisi sistematik bir şekilde incelenmiştir. Derin öğrenme teknikleri kullanılarak gerçek dünya koşullarında daha hassas tahminlerin elde edilebileceği gösterilmiştir. Aynı zamanda, geçmiş seyahat verileri ve dışsal faktör değişkenlerinin birleştirilmesiyle geliştirilen, Yapay Sinir Ağları (ANN), Uzun – Kısa Süreli Bellek Ağları (LSTM) ve Evrimsel Sinir Ağları (CNN) gibi tekniklerin bir arada kullanıldığı hibrit modellerin, tek tip veriye dayalı modellere göre daha iyi performans sergilediği ortaya koyulmuştur. Elde edilen sonuçlarının, operasyonel kararların alınmasında nasıl kullanılabileceğine dair öneriler sunulmuştur. Böylece toplu taşıma sistemlerinin daha etkin yönetilmesi ve hizmet kalitesinin artırılmasına katkı sağlamak hedeflenmektedir.

Anahtar sözcükler: seyahat talebi tahmini, raylı sistemler, derin öğrenme

ABSTRACT**DEVELOPMENT OF A DAILY PASSENGER DEMAND
PREDICTION MODEL FOR RAIL SYSTEMS USING DEEP
LEARNING TECHNIQUES**

ERCAN, Halil Uğur

MSc in Civil Engineering

Supervisor: Assoc. Prof. Dr. Yalçın ALVER

February 2023, 85 pages

Efficient planning and management of transportation systems require accurate forecasting of future travel demands. In public transportation systems, operational decisions such as estimating daily travel demand, setting service frequencies, determining the number of entrances and exit gates, and determining personnel numbers should be considered. This thesis aims to demonstrate the potential of deep learning techniques in demand forecasting for public transportation systems, especially in the context of rail systems. Various deep learning models were developed using the daily travel data of the 2019 Istanbul M2 Yenikapı – Hacıosman Metro line, and the model performances were tested using the daily travel data of 2020. The impact of various variables (weather conditions, local events, holidays, days of the week, etc.) on travel demands and how these variables can be integrated into travel demand forecast models were systematically examined. It has been shown that deep learning techniques can provide promising forecasts in real-world conditions. Furthermore, it has been revealed that hybrid models developed as a combination of historical travel data and various variables, utilizing techniques such as Artificial Neural Networks (ANN), Long – Short Term Memory Networks (LSTM), and Convolutional Neural Networks (CNN), outperform uni-modal data-based models. Recommendations were provided on how the resulting forecast outcomes can be utilized for operational decision-making, aiming to enhance the effective management and service quality of public transportation systems.

Keywords: travel demand forecast, rail systems, deep learning

ÖNSÖZ

Lisans öğrenimini Hacettepe Üniversitesi'nin Beytepe Kampüsü'nde almış bir kişi olarak, yıllarca birçok arkadaşım gibi en çok kampüsümüze olan ulaşım zorluğundan dert yanıyordum. Lisans hayatımda öğrenci değişim programıyla Polonya ve Avusturya'da yaşama şansı bulduğum süreçte beni en çok etkileyen şeylerden bir tanesi toplu taşıma sistemleri olmuştu. Ankara'ya yerleştikten sonra en önemli sorunlarımdan birisi olarak değerlendirdiğim bu toplu taşıma ulaşımının, Avrupa'nın birçok kentinde nasıl sorun olmaktan çıkarıldığını görmemle birlikte ulaşım sistemlerine olan ilgim başladı. Lisans eğitimimden sonra ulaşım planlama alanında çalışmaya karar verdim ve Ege Üniversitesi İnşaat Mühendisliği Anabilim Dalı'nda Ulaşım Planlama alanında yüksek lisansa başladım.

Danışman hocam Doç. Dr. Yalçın ALVER'in de cesaretlendirmesiyle zaten ilgim olan veri bilimi alanında kendimi geliştirip, toplu taşıma ve yapay zekâ alanlarını bir arada çalışabileceğim bir tez konusu belirledim. Tez çalışma sürecimde hem derin öğrenme alanında çok şey öğrendim, hem de toplu taşıma sistemlerindeki yapay zekâ uygulamalarını keşfetmiş oldum.

Ülkemizde veriye erişimin zor olmasından dolayı yurtdışındaki kentlerin açık kaynak olarak paylaşmış oldukları toplu taşıma verilerini kullanmayı düşünsem de İstanbul'un M2 metro hattının verilerini temin edebilmem ile birlikte ülkemizde bir çalışma yapabilecek olmanın sevincini yaşadım.

Başlığını "Derin Öğrenme Teknikleri Kullanılarak Raylı Sistemler için Günlük Seyahat Talebi Tahmin Modeli Geliştirilmesi" olarak belirlediğim bu tez çalışmamda geliştirmiş olduğum tahmin modellerinin oldukça tatmin edici sonuçlar vermiş olması beni oldukça mutlu etti. Çalışmamın çıktılarının bir gün gerçek dünyada toplu taşıma sistemlerinin planlanması ve yönetilmesinde kullanılmasını tüm kalbimle diliyorum.

İZMİR

19/09/2023

Halil Uğur ERCAN

İÇİNDEKİLER

	<u>Sayfa</u>
İÇ KAPAK	ii
KABUL ONAY SAYFASI	iii
ETİK KURALLARA UYGUNLUK BEYANI.....	v
ÖZET	vii
ABSTRACT	ix
ÖNSÖZ.....	xi
İÇİNDEKİLER.....	xiii
ŞEKİLLER DİZİNİ	xvii
TABLolar DİZİNİ.....	xix
SİMGELER VE KISALTMALAR DİZİNİ	xxi
1. GİRİŞ.....	1
2. GEÇMİŞ ÇALIŞMALAR	4
2.1 Ulaşım Sistemlerinde Derin Öğrenme Tekniklerinin Kullanılması	4
2.2 Derin Öğrenme Teknikleri ile Seyahat Talebinin Tahmin Edilmesi	6
3. YÖNTEM	13
3.1 Çalışmada Kullanılan Derin Öğrenme Yöntemleri	15
3.1.1 Yapay sinir ağları.....	15

İÇİNDEKİLER (devam)

	<u>Sayfa</u>
3.1.2 Yinelemeli sinir ağıları.....	16
3.1.3 Uzun-kısa süreli bellek ağıları	18
3.1.4 Evrimsel sinir ağıları	20
3.2 Çalışmada Kullanılan Veri.....	21
3.3 Veri Önleme	23
3.3.1 Nümerik verilerin normalizasyonu	23
3.3.2 Kategorik verilerin etiketlenmesi.....	24
3.3.3 LSTM dizilerinin oluşturulması.....	26
3.4 Değerlendirme Ölçütleri	26
3.4.1 Hata kareleri ortalamasının karekökü (RMSE).....	27
3.4.2 Ortalama mutlak hata (MAE)	27
3.4.3 Ortalama mutlak yüzde hata (MAPE).....	27
3.4.4 Belirleme katsayısı (R kare).....	28
3.5 Geliştirilen Modeller	29
3.5.1 ANN modeli.....	30
3.5.2 LSTM modeli.....	32
3.5.3 CNN modeli	34

İÇİNDEKİLER (devam)

	<u>Sayfa</u>
3.5.4 LSTM – ANN hibrit modeli	35
3.5.5 LSTM – CNN hibrit modeli	37
4. BULGULAR.....	41
4.1 Model Performansları	43
4.2 Değişkenlerin Tahmin Modeli Üzerindeki Etkisi.....	48
4.2.1 Ay değişkeninin model başarısına etkisi	49
4.2.2 Hava durumu değişkenlerinin model başarısına etkisi	50
4.2.3 Eğitim değişkenlerinin model başarısına etkisi	51
4.2.4 Tatil değişkenlerinin model başarısına etkisi	55
4.2.5 Etkinlik değişkenlerinin model başarısına etkisi	56
5. TARTIŞMA.....	61
5.1 Değerlendirme Ölçütlerinin Anlamlandırılması.....	61
5.1.1 R kare değeri ile uyum incelemesi.....	61
5.1.2 MAE ve RMSE değerleri ile hata analizi	62
5.1.3 MAPE değeri ile oransal hata analizi	62
5.2 Model Geliştirme Süreci.....	63
5.2.1 Model mimarisinin geliştirilmesi.....	64

İÇİNDEKİLER (devam)

	<u>Sayfa</u>
5.2.2 Eğitim sürecinin geliştirilmesi	66
5.3 Hibrit Modellerin Başarısı	67
5.4 Değişkenlerin Tahmin Başarısı Üzerindeki Etkileri	68
5.4.1 Ay değişkeni	68
5.4.2 Haftanın günü değişkeni	68
5.4.3 Hava durumu değişkenleri	69
5.4.4 Eğitim değişkenleri	69
5.4.5 Tatil değişkeni.....	70
5.4.6 Etkinlik değişkenleri	71
5.5 Çalışmanın Kısıtları	73
6. SONUÇ	74
KAYNAKLAR DİZİNİ	78
TEŞEKKÜR.....	84
ÖZGEÇMİŞ	85

ŞEKİLLER DİZİNİ

<u>Şekil</u>	<u>Sayfa</u>
3.1 Tek katmanlı algılayıcı (Güzel, 2020).....	13
3.2 Çok katmanlı algılayıcı (Birgül ve Bertan, 2009)	14
3.3 Basit bir ANN modelinin mimarisi (girdi katmanı, gizli katmanlar ve çıktı katmanı)	15
3.4 Basit bir RNN katmanının mimarisi.....	17
3.5 LSTM hücresi mimarisi.....	19
3.6 Tek boyutlu CNN modeli mimarisi.....	20
3.7 Geliştirilen ANN Modeli Mimarisi	31
3.8 Geliştirilen LSTM modeli mimarisi.	32
3.9 Geliştirilen CNN modeli mimarisi.	34
3.10 Geliştirilen LSTM – ANN hibrit modeli mimarisi.....	36
3.11 Geliştirilen LSTM – CNN hibrit modeli mimarisi.	39
4.1 LSTM – ANN Hibrit Modelinin Taksim istasyonu için yaptığı tahminler ile gerçek seyahat sayılarının karşılaştırılması.	48
4.2 “Haftanın Günü”, “Tatil”, “Eğitim” ve “Etkinlik” değişkenleri ile eğitilen LSTM – ANN hibrit modelinin Vezneciler istasyonu için yaptığı tahminler ile gerçek seyahat sayılarının karşılaştırılması.	53
4.3 “Haftanın Günü”, “Tatil” ve “Etkinlik” değişkenleri ile eğitilen LSTM – ANN hibrit modelinin Vezneciler istasyonu için yaptığı tahminler ile gerçek seyahat sayılarının karşılaştırılması.	53

ŞEKİLLER DİZİNİ (devam)

<u>Şekil</u>	<u>Sayfa</u>
4.4 “Haftanın Günü”, “Tatil”, “Eğitim” ve “Etkinlik” değişkenleri ile eğitilen LSTM – ANN hibrit modelinin İTÜ – Ayazağa istasyonu için yaptığı tahminler ile gerçek seyahat sayılarının karşılaştırılması.	54
4.5 “Haftanın Günü”, “Tatil” ve “Etkinlik” değişkenleri ile eğitilen LSTM – ANN hibrit modelinin İTÜ – Ayazağa istasyonu için yaptığı tahminler ile gerçek seyahat sayılarının karşılaştırılması.....	54
4.6 “Haftanın Günü” ve “Etkinlik” değişkenleri ile eğitilen LSTM – ANN hibrit modelinin Seyrantepe istasyonu için yaptığı tahminler ile gerçek seyahat sayılarının karşılaştırılması.	59
4.7 Sadece “Haftanın Günü” değişkenleri ile eğitilen LSTM – ANN hibrit modelinin Seyrantepe istasyonu için yaptığı tahminler ile gerçek seyahat sayılarının karşılaştırılması.	59

TABLolar DİZİNİ

<u>Tablo</u>	<u>Sayfa</u>
3.1 Etiket kodlama örneđi.....	24
3.2 İkili etiket kodlama örneđi.....	25
4.1 1 Ocak 2020 – 10 Mart 2020 tarihleri arasında M2 metro hattındaki seyahatlerin toplam sayıları, günlük ortalama sayıları, günlük standart sapmaları ve varyasyon katsayıları.....	42
4.2 Geliştirilen modellerin ve geçmiş yıl dönem ortalamasının gerçek değerler ile karşılaştırılması sonucu elde edilen değerlendirme ölçütlerinin sonuçları.....	45
4.3 LSTM – ANN ve LSTM – CNN Hibrit modellerinin değerlendirme ölçütleri.....	46
4.4 LSTM ve CNN modellerinin istasyon bazlı değerlendirme ölçütleri.....	46
4.5 ANN Modelinin ve 2020 yılına projekte edilmiş 2019 yılı dönem ortalamalarının istasyon bazlı değerlendirme ölçütleri.....	47
4.6 1 Ocak ve 8 Mart etkilerinden arındırılmış test veri seti ile yapılan tahminlerin değerlendirme ölçütleri.	48
4.7 “Hava Durumu”, “Haftanın Günü”, “Ay”, “Tatil”, “Eđitim” ve “Etkinlik” deđişkenleri kullanılarak geliştirilen LSTM - ANN hibrit modelinin değerlendirme ölçütleri.....	49
4.8 “Hava Durumu” deđişkenleri dahil edilerek ve edilmeyerek eğitilen modellerin test sonuçlarının değerlendirme ölçütleri.	50
4.9 “Eđitim” deđişkenleri dahil edilerek ve edilmeyerek geliştirilen modellerin test sonuçlarının değerlendirme ölçütleri.	51

TABLolar DİZİNİ (devam)

<u>Tablo</u>	<u>Sayfa</u>
4.10 “Tatil” deęiřkeni dahil edilerek ve edilmeyerek eęitilen modellerin test sonuçlarının deęerlendirme ölçütleri.	55
4.11 “Tatil” deęiřkeni dahil edilerek ve edilmeyerek eęitilen modellerin 1 Ocak 2020 tarihine ait verilerden arındırılmış olan test sonuçlarının deęerlendirme ölçütleri.	56
4.12 “Etkinlik” deęiřkeni dahil edilerek ve edilmeyerek eęitilen modellerin test sonuçlarının deęerlendirme ölçütleri.	58
4.13 Taksim ve Seyrantepe istasyonları çıkarılarak, “Etkinlik” deęiřkeni dahil edilerek ve edilmeyerek eęitilen modellerin test sonuçlarının deęerlendirme ölçütleri.	58

SİMGELER VE KISALTMALAR DİZİNİ

<u>Kısaltmalar</u>	<u>Açıklama</u>
ANN	Yapay Sinir Ağı (Artificial Neural Network)
CNN	Evrişimsel Sinir Ağı (Convolutional Neural Network)
CPU	Merkezi İşlem Birimi (Central Processing Unit)
DNN	Derin Sinir Ağı (Deep Neural Network)
GCN	Graf Evrişimsel Ağı (Graph Convolutional Network)
GPU	Grafik İşlem Birimi (Graphics Processing Unit)
LSTM	Uzun-Kısa Süreli Bellek Ağı (Long – Sort Term Memory)
RNN	Yinelemeli Sinir Ağı (Recurrent Neural Network)

1. GİRİŞ

Ulaşım her insan için temel bir ihtiyaçtır ve günlük yaşamımızın vazgeçilmez bir parçasıdır. Kentlerimiz geliştikçe ve büyüdükçe ulaşım sistemlerinin iyileştirilmesine olan ihtiyaç artmaktadır. İnsanoğlu tarih boyunca yaşadığı coğrafyanın da elverdiği ölçüde ulaşım ihtiyacını karşılamak için çeşitli yöntemler geliştirmiştir. Teknolojinin ve mühendisliğin gelişimi ile insanoğlu; kara yolu, demir yolu, su yolu ve hava yolu gibi birçok farklı yöntemle ulaşım ihtiyacını sağlamaya çalışmıştır. Zamanla, ulaşım türlerinin mevcut kapasitelerinin en yüksek verimlilikle kullanılmasının, en az kapasite artırımı kadar önemli olduğu anlaşılmıştır. Ulaşımda verimliliği artırmak için hem ulaşım sistemini hem de operasyonu iyi planlamak kritik öneme sahiptir.

Kentlerimizin ulaşım sistemlerindeki temel sorunlardan dolayı kent içi ulaşımında özel taşıt kullanımı oldukça yaygındır. Bu durum fazla yakıt tüketimi, doğaya çok fazla CO₂ salınması ve trafik sıkışıklığı gibi sonuçlar doğurmaktadır. Toplu taşıma ise; yürüme, bisiklet, e-skuter ve diğer mikro hareketlilik araçlarından sonra gelen sürdürülebilir ulaşım türlerinden birisidir. İyi bir toplu taşıma sistemi; daha az trafik kazasına sebep olarak trafik kazası sonucu meydana gelen ölüm ve yaralanmaların sayısının azalmasına, hareketliliği artırarak toplumun fiziksel ve ruhsal sağlığının artmasına fayda sağlar ve uygun maliyetli olmasından dolayı kullanıcıların aile ekonomisine katkıda bulunur (Litman, 2011). Özel taşıt odaklı ulaşım planlarının yol açtığı bu olumsuzluklardan dolayı Avrupa Birliği Komisyonu özel taşıt öncelikli geleneksel ulaşım planları yerine yaya öncelikli olan Sürdürülebilir Kent Hareketliliği Planları (SKHP) yapmaları konusunda kentlere teşviklerde bulunmaktadır (Kiba-Janiak and Witkowski, 2019). SKHP'ler sürdürülebilir ulaşım türlerinin kullanımını teşvik ederken, özel taşıt gibi sürdürülebilir olmayan ulaşım türlerinin kullanımını caydırmayı amaçlamaktadır.

Kent içi toplu taşıma sistemlerinin planlanması, operasyonel kararların alınması ve yönetilebilmesi için gelecekteki seyahat taleplerinin gerçeğe yakın bir şekilde tahmin edilebilmesi gerekmektedir. Toplu taşıma sistemlerindeki günlük seyahat talebinin tahmini; sefer sıklığı düzenleme, giriş – çıkış turnike sayısı ve hizmet verecek personel sayısını belirleme gibi birçok operasyonel karar alınırken

dikkate alınmalıdır. Seyahat talebinin doğru tahmini, günlük operasyon güvenliği yönetimi ve acil durum önleme çalışmaları için de büyük önem taşımaktadır (Xiong et al., 2019). Bunun için ulaşım sistemlerinden elde edilen verilere dayanan iyi bir tahmin modeli oluşturmak gerekmektedir. Oluşturulan modelin geleceği öngörme başarısı, yapılacak olan planlamanın başarısını doğrudan etkileyecektir.

Geleneksel olarak, toplu taşıma sistemlerinde seyahat talebi tahmini, haftanın farklı günleri ve günün farklı saatlerindeki geçmiş seyahat verileri ile geliştirilen istatistiksel yöntemlere dayanmaktadır. Bu şekilde yapılan seyahat talebi tahminleri ulaşım sistemlerinde sadece hafta içi ve hafta sonu için değişen statik sefer planları oluşturmaya olanak tanımaktadır. Ancak, toplu taşıma sistemlerindeki talep, haftanın günü ve günün saati dışında birçok değişkenden etkilenmektedir. Haftanın günü, hava sıcaklığı, yağış durumu, kentte büyük bir organizasyon olup olmaması, okulların açık olup olmaması gibi birçok faktör kent içi toplu taşıma kullanım talebini etkilemektedir. Geleneksel yöntemler ile bu değişkenler arasındaki karmaşık ilişkiyi ifade eden bir tahmin modeli geliştirmek oldukça güçtür.

Derin öğrenme yöntemleri karmaşık ilişkileri doğru bir şekilde modelleme ve oldukça yüksek bir doğrulukla tahmin yapabilme konusunda oldukça başarılıdır. Bu yöntemler, yapay sinir ağları olarak temsil edilen çok katmanlı ve karmaşık yapılarıyla veriler arasındaki sebep – sonuç ilişkilerini örüntüleri öğrenirler. Bu sayede, derin öğrenme yöntemleri görüntü işleme, doğal dil işleme, tıbbi teşhis, finansal analiz, otonom sürüş gibi birçok uygulama alanında başarıyla kullanılabilir. Derin öğrenme yöntemlerinin karmaşık ilişkileri modelleyebilme başarısı, bu yöntemleri toplu taşıma sistemlerinde seyahat talep tahmini modeli geliştirme konusunda elverişli hale getirmektedir.

Raylı sistemlerin kent içi toplu taşıma içerisindeki payı yıllar geçtikçe artmaktadır. Raylı toplu taşıma sistemlerinde, diğer toplu taşıma sistemlerine göre faydalı bir şekilde optimize edilebilecek daha fazla parametre bulunmaktadır. Sefer sıklığının, seferlerde kullanılacak vagon sayısının, giriş – çıkış turnike sayısının, istasyonlarda çalışan personel sayısının belirlenmesi, yürüyen merdivenlerin ve asansörlerin optimize edilmesi hem kaynak hem de zaman tasarrufu açısından önemlidir. Ayrıca raylı toplu taşıma sistemlerinin genellikle kapalı sistem olmaları ve trafik, yağış gibi dış faktörlerden dolayı operasyonlarının minimum düzeyde

etkilenmesi yapılacak optimizasyonun başarısını artırarak diğer sistemlere göre daha belirgin bir fayda ortaya koyacaktır.

Bu tez çalışmasında kent içi raylı toplu taşıma sistemlerinde seyahat talebini tahmin eden bir derin öğrenme modeli geliştirilmiştir. Geliştirilen modelin operasyonel faaliyetlerin iyileştirilmesine katkıda bulunarak raylı sistemlerdeki kaynak yönetimini iyileştirmesi, hizmet kalitesini artırması ve bu sistemlerin kullanılmasını daha cazip hale getirmesi hedeflemektedir. Böylece bu çalışma; daha çevreci, insan odaklı ve sürdürülebilir kentler planlama noktasında otoritelere katkıda bulunacak ve ulaşım sistemlerindeki talep tahmin modellerinde derin öğrenme yöntemlerinin potansiyelini daha iyi anlamamızı sağlayacaktır.

Bu çalışmada ülkemizin İstanbul kentinde hizmet veren Yenikapı ve Hacıosman istasyonları arasında çalışan M2 Metro hattına ait 2019 ve 2020 yılı günlük seyahat verileri kullanılmıştır. M2 metrosunun günlük kullanım verileri haftanın günü, içinde bulunulan ay, okul ve üniversitelerin eğitim döneminde olup olmaması, hava durumu, kentte büyük organizasyon olup olmaması gibi farklı veriler ile desteklenmiştir. Çalışma kapsamında kullanılan değişkenlerin seyahat talebine ve talep tahmin modeline olan etkileri ayrı ayrı incelenmiştir.

Tezin ikinci bölümünde, “Ulaştırma Sistemlerinde Derin Öğrenme Tekniklerinin Kullanılması” ve “Derin Öğrenme Teknikleri ile Seyahat Talebinin Tahmin Edilmesi” başlıkları altında literatür taramasının özeti sunulmaktadır. Üçüncü bölümde, bu çalışmada kullanılan derin öğrenme yöntemlerine genel bir bakış sunulmuş, kullanılan veri ve veri kaynakları açıklanmış, veri ön işleme süreci ve değerlendirme ölçütleri anlatılmış, geliştirilen modellerin mimarileri detaylıca ele alınmıştır. Dördüncü bölümde ise geliştirilen modellerin ve değişkenlerin tahmin başarısı üzerindeki etkilerine ait bulgular paylaşılmıştır. Beşinci bölümde model geliştirme süreci, değişkenlerin model başarısı üzerindeki etkileri ve çalışmanın kısıtları ayrıntılı bir şekilde tartışılmıştır. Sonuç bölümünde ise çalışmanın amaçları ve önemli bulguları tekrar vurgulanmış, gerçek hayat uygulama önerileri sunulmuş ve gelecek çalışmalar için tavsiyelerde bulunulmuştur.

2. GEÇMİŞ ÇALIŞMALAR

Etkili bir toplu taşıma sistemi özellikle büyük kentlerde insanların ulaşım ihtiyaçlarını karşılama noktasında çok önemli bir yere sahiptir. Metro gibi raylı toplu taşıma sistemleri büyük kentlerde ulaşım talebinin çok büyük bir kısmını karşılamaktadır. Bu sistemlerdeki seyahat talebini doğru bir şekilde tahmin etmek, bu sistemlerin sorunsuz çalışmasını sağlamak ve kaynak kullanımını optimize etmek için oldukça önemlidir. Seyahat talebini tahmin etmenin bir diğer önemli faydası da trenlerdeki ve istasyonlardaki sıkışıklığın azaltılmasına yardımcı olabilmesidir. Aşırı kalabalık trenler ve istasyonlar konforsuz bir seyahate, gecikmelere ve potansiyel güvenlik tehlikelerine yol açabilir. Seyahat talebi tahmin edilerek istasyonlardaki ve trenlerdeki aşırı yoğunluğu önlemek için sefer sıklıkları ve vagon sayıları düzenlenebilir, böylece yolcuların hızlı, rahat ve güvenli bir seyahat geçirmesi sağlanır. Özellikle zirve saatlerdeki aşırı yoğunluğun yönetilmesi için talep tahmin çalışmaları oldukça önemlidir.

Seyahat talebini tahmin etmek, uzak bir projeksiyon için de planlama yapmaya olanak tanır. Bir kentin geleceğindeki ulaşım sistemlerini planlamak ve tasarlamak için seyahat talebi tahmini oldukça önemlidir. Doğru talep ve talep artışı tahmini, gelecekte ihtiyaç duyulacak hizmet düzeyi hakkında önemli bilgiler vererek otoritelerin altyapı yatırımları ve kapasite planlaması hakkında bilinçli kararlar almasına olanak tanır.

Son yıllarda derin öğrenme teknikleri kent içi ulaşım dahil olmak üzere birçok alanda sorunlara çözüm bulmak için kullanılmaktadır. Bu bölümde ilk olarak derin öğrenme tekniklerinin ulaşım alanında kullanımı ile ilgili çeşitli çalışmalara yer verilecektir. Daha sonrasında ise derin öğrenme tekniklerinin ulaşım sistemlerindeki talep tahmin çalışmalarında kullanımı ile ilgili literatür incelenecek, raylı toplu taşıma sistemleri özelindeki talep tahmin çalışmaları ise daha kapsamlı olarak ele alınacaktır.

2.1 Ulaşım Sistemlerinde Derin Öğrenme Tekniklerinin Kullanılması

Son zamanlarda birçok alanda olduğu gibi ulaştırma alanındaki sorunlara da derin öğrenme teknikleriyle çözüm aramak oldukça yaygın hale gelmiştir.

Nguyen et al. (2018) hazırladığı derlemesinde; ulaşım ağı gösterimi, trafik hacmi tahmini, seyahat talebi tahmini, otomatik taşıt tespiti, trafik sinyal kontrolü, trafik kaza verileri işlenmesi, otonom sürüş ve sürücü davranışlarının işlenmesi olmak üzere derin öğrenmenin ulaştırma alanındaki uygulamalarına sekiz ayrı başlıkta değinmiştir. Ma et al. (2015) karayolu linklerindeki trafik durumunu gösteren yinelemeli sinir ağı (Recurrent Neural Network, RNN) ve kısıtlı boltzmann makinesi (Restricted Boltzmann Machines, RBM) tekniklerinin birleşiminden oluşan bir model oluşturmuştur. Bu çalışmada modelin mekânsal ilişkileri tarihsel verilerden çıkarım yaparak kendi kendine öğrenmesi gerektiği için model başarısı düşük görülmüştür. Bu sorunu gidermek için Fouladgar et al. (2017) evrimsel sinir ağı (Convolutional Neural Network, CNN) modeli ve uzun – kısa süreli bellek hücresi (Long – Short Term Memory, LSTM) içeren yinelemeli sinir ağı modeli olmak üzere iki farklı model önermiştir. Literatürde kısa vadeli trafik hacmini derin öğrenme teknikleri ile tahmin etmeye yönelik çalışmalar da yer almaktadır (Chen et al., 2021; Gokasar and Timurogullari, 2021; Huang et al., 2014; Nur YİĞİT ve Haldenbilen, 2021; Polson & Sokolov, 2017; Zhao et al., 2017; Zheng et al., 2020). Zhao et al. (2017) kentin üç farklı bölgesindeki trafik hacmini 15, 30, 45 ve 60 dakika ilerisi için tahmin eden RNN, LSTM, otoresif entegre hareketli ortalama (Autoregressive Integrated Moving Average, ARIMA), destek vektör makinesi (Support Vector Machine, SVM), radyal tabanlı fonksiyon ve yığınlı oto-kodlayıcı (stacked autoencoder) yöntemlerini kullanarak altı farklı model oluşturmuştur. Üç farklı bölge ve dört farklı zaman aralığı için yapılan toplam 12 tahminin sekizinde LSTM modelinin en başarılı sonucu verdiği görülmüştür. Genders and Razavi (2016) ve Van Der Pol (2016) teorik bir çalışma olarak derin öğrenme teknikleri ile trafik sinyal kontrol sistemi önermişlerdir. İki çalışmada da bilgisayar ortamında üretilen veriler ile modeller eğitilmiştir. Yapılan simülasyonlar sonucunda önerilen sistemin trafikteki gecikmeyi, ortalama seyahat süresini ve kavşaklardaki kuyruklanmayı azalttığı görülmüştür. Chen et al. (2016) geçmiş trafik ve trafik kazası verilerini kullanarak derin öğrenme teknikleri ile bir model geliştirmiştir. Bu modele anlık trafik verileri girdi olarak verilerek anlık trafik kazası risk haritası elde edilmiştir. Derin öğrenme tekniklerinin kullanılmasıyla görüntü işleme teknolojisi de gelişmiş ve bu teknoloji; plaka tanıma, taşıt sayımı ve taşıt tipi tespiti gibi uygulamalar ile ulaştırma alanına katkıda bulunmuştur (Adu-Gyamfi et al., 2017; Moussa, 2014; Zhou and Cheung, 2016). Benzer şekilde video işleme tekniklerinin

gelişmesiyle birlikte anlık araç ve şerit tespiti yapılabilmesi otonom sürüş teknolojisinin gelişimine katkıda bulunmaktadır (Nguyen et al., 2018). Dong et al. (2016) sürücülerin GPS verilerini kullanarak CNN ve RNN teknikleriyle sürüş karakteristiklerini sınıflandıran bir model geliştirmiştir. Dwivedi et al. (2014) ise sürücülerin yüz ifadelerini kullanarak uyuklu sürücülerini %92'lik bir doğrulukla tespit eden bir CNN modeli oluşturmuştur.

2.2 Derin Öğrenme Teknikleri ile Seyahat Talebinin Tahmin Edilmesi

Literatürde derin öğrenme teknikleri ile seyahat talebi tahmini farklı şekillerde ele alınmıştır. Bai and Jiao (2021) Austin, Teksas'taki 2019 yılı akıllı telefon GPS verilerini kullanarak şehrin altı farklı bölgesine yapılan günlük seyahatleri incelemişlerdir. Bu çalışmada hava sıcaklığı, yağış miktarı, geçmiş günlük seyahat sayıları gibi değişkenler kullanılarak gelecekteki günlük seyahat talebini tahmin eden LSTM modeli önerilmiştir. Yao et al. (2018) Çin'in Guangzhou kentindeki taksi talebini uzamsal ve zamansal değişkenler ile tahmin etmek için "Derin Çoklu Görünüm Uzay – Zamansal Ağ (DMVST-Net)" adını verdikleri bir yöntem geliştirmişlerdir. Bu çalışmada CNN tekniğinin uzamsal, LSTM tekniğinin ise zamansal değişkenlerdeki başarısı kullanılarak bir hibrit model önerilmiştir. Önerilen model farklı yöntemlerle oluşturulan sekiz modelle karşılaştırılmış ve bu çalışmadaki modelin en iyi başarıyı gösterdiği belirtilmiştir. Yang et al. (2018) New York'taki bisiklet paylaşım sistemi için istasyon bazında günlük talep tahmini yapan bir CNN modeli önermişlerdir. Hava durumu, haftanın günü, geçmiş kiralama verileri, komşu istasyon kiralama verileri gibi değişkenler ile günlük talep tahmini yapan CNN modeli, yapay sinir ağı (Artificial Neural Network, ANN) ve ARIMA modelleri ile karşılaştırılmış ve CNN modelinin en tutarlı sonuçları verdiği belirtilmiştir.

Literatürde raylı sistem hatlarındaki seyahat talebini tahmin etmeye yönelik bazı çalışmalar bulunmaktadır. Bu çalışmalar, tahmin detayı ve tahmin projeksiyonu anlamında birbirinden ayrılmaktadır. Tahmin detayı bakımından hat bazında, istasyon bazında ve başlangıç – varış bazında olmak üzere seyahat talebi tahmini yapan çalışmalar bulunmaktadır. Ayrıca, metro istasyonlarındaki turnikelerden elde edilen istasyona giriş hem de istasyondan çıkış verileriyle istasyon bazında biniş ve iniş tahmini yapan çalışmalar da literatürde yer

almaktadır. Tahmin projeksiyonu bazında ise 5, 10, 15, 30 ve 60 dakikalık yakın gelecek için veya günlük olarak seyahat sayısı tahmini yapan çalışmalar bulunmaktadır.

Bu tez çalışmasında olduğu gibi günlük ve istasyon bazında seyahat talebi tahmini yapan çalışmalardan birisi Liu and Chen (2017) tarafından yapılmıştır. Bu çalışmada Tayvan'ın Taipei kentindeki raylı sisteminde istasyon bazındaki seyahat talebini; içinde bulunulan ay, ay içerisinde bulunulan gün, haftanın günü, o günün tatil olup olmaması gibi değişkenlere bağlı tahmin eden ANN modelleri önerilmiştir. Bu çalışmada oluşturulan modelleri birbirinden ayıran nokta ise modellerin hepsinde bütün değişkenlere yer verilmemiş olmasıdır. Bütün değişkenlerin bulunduğu modelin en yüksek doğrulukla tahmin üreten model olduğu belirtilmiştir. Benzer şekilde Zhu et al. (2018) tarafından Çin'in Şangay kentinin metro hattından elde edilen istasyon giriş – çıkış verileriyle birlikte, hava sıcaklığı, yağış durumu, günün iş günü olup olmaması, istasyonun yakınındaki yolun ve istasyona en yakın kesintisiz yolun trafik durumu verileri kullanılarak istasyondaki günlük giriş ve çıkış sayısını tahmin eden bir ANN modeli önerilmiştir. Önerilen tahmin modelinin lineer regresyon modeline göre çok daha başarılı tahminler yapabildiği ortaya koyulmuştur. Xiong et al. (2019), Çin'in Pekin şehrindeki 15 hat 47 istasyondan oluşan metro sisteminin 2015 yılı seyahat verileri ile günlük ve gün içerisinde kısa vadeli (10 dakika sonrası için) seyahat talebi tahmini yapan LSTM ve CNN modellerini önermişlerdir. Ayrıca ARIMA, mevsimsel otoregresif entegre hareketli ortalama (Seasonal Auto-Regressive Integrated Moving Average, SARIMA) ve uzay – zamansal otoregresif entegre hareketli ortalama (Space-Time Autoregressive Integrated Moving Average, STARIMA) olmak üzere üç farklı geleneksel yöntemle oluşturulan modeller ile LSTM ve CNN modellerinin başarısı karşılaştırılmıştır. LSTM ve CNN modellerinin geleneksel yöntemlerden çok daha iyi sonuç verdiği belirtilmiştir. Bu çalışmada sadece metro sistemi içerisindeki uzamsal ve zamansal değişkenler kullanılmıştır. Günlük bazdaki en güncel çalışmalardan birisi ülkemizde Nar and Arslankaya (2022) tarafından yapılmıştır. Bu çalışmada, İstanbul'un M1 Yenikapı – Kirazlı metro hattına ait 2019 ve 2020 yılı ücret toplama sistemi verileri kullanılmıştır. Çalışmanın ilk aşamasında regresyon analizi ve ortalama seyahat sayıları gibi basit istatistiksel yöntemler kullanılarak hat bazında günlük seyahat

sayısı tahmini yapılmıştır. İkinci aşamada ise makine öğrenmesi algoritmaları ve ANN yöntemi kullanılarak istasyon bazında günlük seyahat sayısı tahmini yapan modeller geliştirilmiştir. Bu çalışmada geliştirilen modeller sadece geçmiş seyahat verilerini kullanarak tahmin üretmektedir. ANN ve makine öğrenmesi algoritmaları ile geliştirilen modeller günlük istasyon bazında tahmin üretse de çalışmadaki model performansları istasyon bazında günlük olarak tahmin edilen seyahat sayılarına göre değil, istasyon bazında tahmin edilen toplam seyahat sayılarına göre yapılmıştır. Çalışmada sadece Yenikapı istasyonu için günlük seyahat sayısı tahminleri ile gerçekleşen seyahat sayılarının karşılaştırmalı grafiği verilmiş ve bu grafikte tahminlerin belirli zamanlarda gerçek değerlere yaklaştığı ancak genellikle gerçek değerlerden daha fazla sayıda tahmin yaptığı görülmektedir.

Literatürde hava durumu, haftanın günü, okulların açık olması gibi dışsal faktörleri kullanarak günlük seyahat talebini tahmin eden çalışma sayısı kısıtlıdır. Öte yandan, son zamanlarda yakın gelecek için seyahat talebi tahmini yapan çalışmaların sayısında artış gözlemlenmektedir. Bu çalışmalardan birisi Çin'in Chongqing kentinde gerçekleştirilmiş, metro istasyonundan çıkan yolcu sayısını yine metro sistemi içerisindeki uzay – zamansal değişkenlere göre sadece 10'ar dakikalık yakın gelecek için tahmin eden bir model önerilmiş ve modele ST-LSTM (Uzay – Zamansal LSTM, Spatio-Temporal LSTM) adı verilmiştir (Tang et al., 2019). Geliştirilen bu model SARIMA, PSO-SVR, LSTM teknikleriyle oluşturulan modellerle kıyaslanmış ve en başarılı sonuçların önerilen model ile elde edildiği belirtilmiştir.

Literatürdeki daha güncel çalışmalara bakıldıkça farklı derin öğrenme tekniklerinin bir arada kullanıldığı çalışmalarda artış olduğu görülmektedir. Zhang et al. (2021), artık ağlar, (residual network, ResNet), graf evrimsel ağ (Graph Convolutional Network, GCN) ve LSTM yöntemlerini birleştirerek ağ ölçeğinde 10, 15, 30 dakikalık gelecek için seyahat talebi tahmini yapan “ResLSTM” adını verdikleri hibrit bir model önermiştir. Pekin metrosu verileri kullanılarak geliştirilen bu hibrit modelde ResNet yönteminin metro istasyonları arasındaki soyut zamansal korelasyonları yakalaması, GCN yönteminin metro ağı yapısından faydalanarak anlamlı bilgi çıkarması ve LSTM yönteminin de veriler arasındaki zamansal ilişkileri yakalaması amaçlanmıştır. Çalışmada geliştirilen ResLSTM

modelinin performansı LSTM, geçitli tekrarlayan birim (Gated Recurrent Unit, GRU) yöntemleri kullanılarak geliştirilen modeller ile karşılaştırılmış ve önerilen hibrit modelin başarısının diğer modellere göre daha yüksek olduğu belirtilmiştir. Bu alandaki en güncel çalışmalardan birisi X. Zhang et al. (2023) tarafından Çin'in Pekin ve Xiamen metro hatlarına ait ücret toplama sistemi verileri kullanılarak gerçekleştirilmiştir. Bu çalışmada, 10 dakikalık yakın gelecek için istasyonlara giren ve çıkan yolcu sayıları tahmin edilmek istenmiştir. GCN ve üç boyutlu CNN yöntemleri kullanılarak geliştirilen model anlık yolcu sayısı, günlük yolcu sayısı ve haftalık yolcu sayısı olmak üzere üç farklı geçmiş seyahat sayısı verisini işleyerek tahmin üretmektedir. ARConv-GCN adı verilen modelin başarısını değerlendirmek için ARIMA, LSTM, iki boyutlu CNN, evrimsel LSTM, üç boyutlu LSTM, GCN gibi yöntemlerle birçok model geliştirilmiş ve en başarılı tahmin üreten modelin ARConv-GCN modeli olduğu belirtilmiştir. Bu çalışmada sadece beş haftalık hafta içi günlere ait verilerin ilk dört haftasının model eğitimi için, son bir haftasının da test için kullanıldığı ifade edilmiş ve çalışmanın daha büyük veri setleri üzerinde test edilmemesi en büyük kısıtı olarak belirtilmiştir. Han et al. (2019) Çin'in Şangay metrosunun verilerini kullanarak yakın gelecekte istasyona yapılacak olan giriş ve çıkış sayılarını tahmin edebilmek için "STGCNNmetro" adını verdikleri uzay – zamansal bir graf evrimsel sinir ağı modeli önermiştir. 10 dakikalık yakın gelecek talebini tahmin etmek için geliştirilen model anlık, günlük ve haftalık istasyona giriş – çıkış yapan yolcu sayılarını zamansal girdi olarak kullanmaktadır. Lai et al. (2022) LSTM ve CNN tekniklerini kullanarak geliştirdikleri üç farklı hibrit model ile 10 dakikalık yakın gelecek için Çin'in Fuzhou kentine ait bir metro hattının istasyonlarındaki seyahat hacmini tahmin etmeye çalışmışlardır. Yazarlar, bu çalışmada hem kendi geliştirdikleri hibrit modellerin başarısını geleneksel yöntemler ile karşılaştırmışlar hem de LSTM ve CNN tekniklerinin karışımı olarak geliştirilen hibrit modellerin daha doğru tahminler ürettiğini ortaya koymuşlardır. Bir başka çalışmada Fu et al. (2023) Delhi metrosuna ait 2012 – 2017 yılları arasındaki seyahat verileriyle yakın gelecekteki seyahat talebini tahmin etmek için LSTM ve GCN yöntemlerini kullanarak geliştirdiği tahmin modeline hava kirliliği indeksi, nem oranı, rüzgâr hızı, rüzgâr yönü, görüş mesafesi, çiy noktası, sıcaklık, yağmur yağış miktarı, kar yağış miktarı, bulutluluk oranı gibi meteorolojik verileri de girdi olarak eklemiştir. GCMN adı verilen bu tahmin modelinin birçok yenilikçi yöntemden daha başarılı olduğu belirtilmiştir.

Literatürde derin öğrenme yöntemleri kullanarak yakın gelecekte gerçekleşecek olan seyahatlerin başlangıç – varış matrislerini tahmin etmeye yönelik çalışmalar da bulunmaktadır (Toqué et al., 2016; J. Zhang et al., 2021; Jiang et al., 2022; Noursalehi et al., 2022; Y. Zhang et al., 2023; Zheng et al., 2022). Toqué et al. (2016) geliştirdiği LSTM modeli ile Fransa'nın Rennes kentindeki metro sisteminde 15 dakika gelecek için dinamik başlangıç – varış matrisi tahmini yapan bir model önermişler ve bu modeli geleneksel yöntemler ile geliştirilen iki model ile karşılaştırmışlardır. Bu çalışmada ücret toplama sistemi verilerinden sadece seyahat başlangıcı verisi elde edilebilmiştir ve seyahat sonu verisi kullanıcının bir sonraki seyahatin başladığı konum dikkate alınarak kestirilmiştir. Geliştirilen LSTM modeli sadece geçmiş kullanım verilerine göre 15 dakika ilerisi için tahmin yapmaktadır. LSTM modeline ayrıca otobüs başlangıç – varış verileri de eklenerek bir model daha geliştirilmiş ve otobüs kullanım verilerinin metro için geliştirilen tahmin modeline etkisi incelenmiştir. Bu çalışma sonucunda LSTM modelinin geleneksel yöntemlere göre çok daha iyi bir sonuç ortaya koyduğu gösterilmiş ve otobüs kullanım verilerinin modelde kullanılmasının da model başarısına olumlu yönde etki ettiği belirtilmiştir. Benzer bir başka çalışma J. Zhang et al. (2021) tarafından yapılmış ve bu çalışmada Çin'in Pekin şehrinin raylı sistemlerindeki başlangıç – varış matrisini dinamik olarak 30 dakika ilerisi için tahmin eden bir CAS-CNN (Channel-Wise Attentive Split – CNN) modeli önerilmiştir. Bu çalışma kapsamında iki boyutlu CNN, üç boyutlu CNN, ConvLSTM (evrişimsel LSTM, Convolutional LSTM), ConvGRU (evrişimsel GRU), TrajGRU (Trajectory GRU), STResNet (Uzay – Zamansal ResNet) ve CAS-CNN'in çeşitli varyasyonları ile birçok model geliştirilmiştir. Geliştirilen CAS-CNN modeli ile en iyi tahmin sonuçları elde edilmiştir. Diğer modellere kıyasla en önemli farkın zirve saatlerde görüldüğü belirtilmiştir. Noursalehi et al. (2022) LSTM tekniğinin zaman serisi problemlerindeki başarısından, CNN tekniğinin ise geçici bağımlılıkları modelleyebilmesi özelliğinden faydalanarak LSTM ve CNN tekniklerinin birlikte kullanıldığı bir dinamik başlangıç – varış matrisi tahmini modeli geliştirmişlerdir. Bu çalışmada geliştirilen model; Hong Kong raylı sistem hattı kullanım verileri ile birlikte, hava durumu ve günün zamanı gibi değişkenlerden de faydalanarak 15, 30, 45 ve 60 dakika ilerisi için dinamik bir başlangıç – matrisi tahmini yapmaktadır. Geliştirilen model; ARIMA, SVR, CNN, LSTM, ConvLSTM, STResNet ve ayrık dalgacık dönüşümü (Discrete Wavelet

Transform, DWT) yöntemleri ile geliştirilen modellerle kıyaslanmış ve bu çalışmada geliştirilen modelin tahmin başarısının en yüksek olduğu belirtilmiştir. Başlangıç – varış matrisi tahmin çalışmalarının en güncellerinden birisi Y. Zhang et al. (2023) tarafından Çin'in Chengdu şehri metrosunun altı hattındaki 136 istasyona ait 1 Nisan 2018 – 30 Temmuz 2018 tarihleri arasındaki ücret toplama sistemi verileri kullanılarak gerçekleştirilmiştir. Bu çalışmada 5, 10, 15 dakikalık yakın gelecek için seyahatlerin başlangıçlarını ve varışlarını tahmin eden bir uzay – zamansal CNN modeli (Spatio – Temporal CNN) geliştirilmiştir. Çalışmada metro hattındaki yüksek düzensizliğe sahip (fazla başlangıç – varış çifti üreten) ve yüksek kapasite kullanım oranına sahip kısımların tahmininin daha önemli olduğu belirtilmiş ve bu kısımlar için daha yüksek doğrulukta tahmin yapılması hedeflenmiştir. Geliştirilen STCNN modelinin tahmin başarısı ARIMA, SVR, GRU, T-GCN, STGCN, Graph WaveNet, TCN, L-TCN ve NL-STCNN gibi birçok farklı model ile karşılaştırılmıştır. Bu çalışmada geliştirilen STCNN modeli diğer modellere kıyasla biraz daha iyi performans gösterdiği, metro hattının önemli kısımları olarak adlandırılan yüksek kapasite kullanım oranına sahip kısımlarda ise diğer modellere kıyasla çok daha iyi performans gösterdiği (%27,4 oranında daha başarılı) belirtilmiştir.

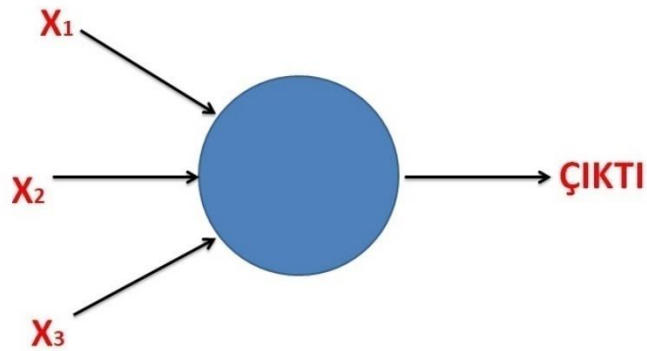
Literatür incelemesinde görüldüğü gibi derin öğrenme teknikleri, raylı sistemlerde seyahat talebini doğru bir şekilde tahmin etme konusunda umut vadetmektedir. Bu modeller, ulaşım planlamacılarının ve operatörlerinin kaynaklarını optimize etmelerine, yolcu hizmetlerini iyileştirmelerine ve maliyetleri azaltmalarına yardımcı olabilir. Literatüre bakıldığında 5, 10, 15, 30, 60 dakikalık yakın gelecek için seyahat sayısı tahmini yapan birçok çalışma olduğu görülmüştür. Öte yandan, derin öğrenme tekniklerini kullanarak günlük bazda yapılan çalışmaların sayısı görece daha azdır. Ancak bu tez çalışmasının literatüre sağladığı en önemli katkı oldukça fazla sayıda değişken kullanarak günlük seyahat sayısı talebi tahmini yapıyor olması ve bu değişkenlerin tahmin başarısı üzerindeki etkilerini incelemesidir. Bu çalışmada hava sıcaklığı, yağış miktarı, rüzgâr hızı, haftanın günü, içinde bulunulan ay, günün resmî tatil olup olmaması, Millî Eğitim Bakanlığı'na (MEB) bağlı okulların açık olup olmaması, metro hattı kullanılarak ulaşılabilen üç üniversitenin ayrı ayrı eğitim döneminde olup olmaması ve metro hattı kullanılarak ulaşılabilen iki futbol stadyumunda (Galatasaray'ın ve Beşiktaş'ın

stadyumları) ayrı ayrı futbol maçı olup olmaması dahil olmak üzere toplam 12 farklı dıřsal faktörü dikkate alarak seyahat talebi tahmini yapan derin öğrenme modelleri geliştirilmiştir. Bu 12 farklı deęişken “hava durumu, haftanın günü, ay, eğitim, tatil ve etkinlik” başlıkları altında gruplanmış ve her deęişken grubunun tahmin başarısı üzerindeki etkisi incelenmiştir. Yapılan literatür incelemesinde bu kadar fazla sayıda dıřsal faktörü göz önüne alarak derin öğrenme teknikleri ile seyahat talebi tahmini yapan bir çalışmaya rastlanmamıştır.




3. YÖNTEM

Büyük verinin ortaya çıkması ve bilgisayarların gelişmesi ile yapay zekâ oldukça popüler hale gelmiştir. Yapay zekâ kısaca insanların yapabildiği işi bilgisayara yaptırmak olarak tanımlanabilir. Makine öğrenmesi ise veriden bilgiyi çıkaran yapay zekanın alt disiplini (Yılmaz ve Kaya, 2021). Makine öğrenmesi tekniklerinin büyük veriyi işlemekte yetersiz kalmasından dolayı bu yetersizliği gidermek için derin öğrenme teknikleri ortaya çıkmıştır. Derin öğrenme çok katmanlı yapay sinir ağlarını kullanan bir yapay zekâ yöntemidir ve makine öğrenmesinin alt dalıdır (Yılmaz ve Kaya, 2021). Makine öğrenmesinde öğretilmek istenen olgunun özelliklerinin önceden belirlenerek modele verilmesi gerekirken derin öğrenme çok daha karmaşık ve büyük veri setinden kendi kendine özellikler çıkarabilmektedir. Derin öğrenme değişkenler arasındaki lineer olmayan ilişkileri modelleme konusunda oldukça başarılıdır. Yapay sinir ağları (Artificial Neural Network, ANN) derin öğrenmenin en temel bileşenidir. Biyolojik sinir ağlarını taklit eden yapısıyla sistemin öğrenmesini sağlar. ANN'ler basitçe; nöron, ağırlık, sapma (bias) ve aktivasyon fonksiyonu kavramlarından oluşur. ANN'lerde en az bir girdi ve bir çıktı katmanı bulunur. Bir girdi ve bir çıktı katmanından oluşan ANN'lere tek katmanlı algılayıcı adı verilir. Şekil 3.1'de üç farklı girdi verisini bir nörona ileten ve bir çıktı üreten tek katmanlı algılayıcı örneği gösterilmiştir.



Şekil 3.1 Tek katmanlı algılayıcı (Güzel, 2020)

Girdi ve çıktı katmanları arasında gizli katmanlar var ise bu yapıya çok katmanlı algılayıcı adı verilir. Şekil 3.2’de iki gizli katmanı olan çok katmanlı algılayıcı örneği verilmiştir.



Şekil 3.2 Çok katmanlı algılayıcı (Birgül ve Bertan, 2009)

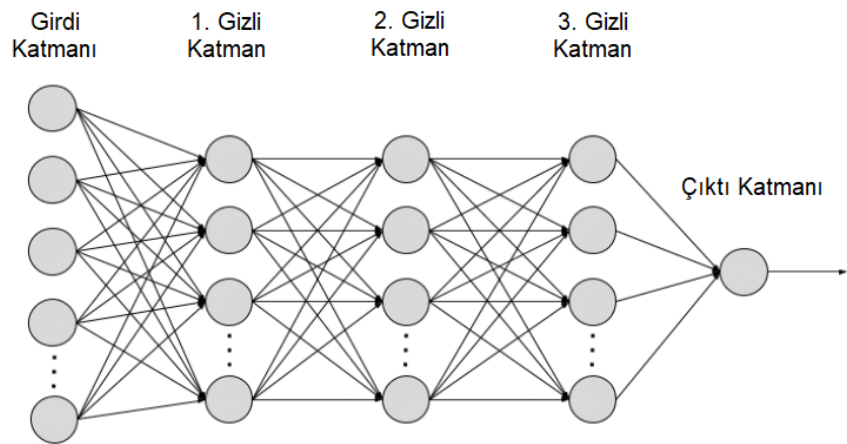
ANN’lerin geçmişi 1940’lı yıllara dayanmaktadır (McCulloch and Pitts, 1943). Ancak o yıllarda gerekli hesaplamaları hızlı bir şekilde yapabilecek bilgisayarlar olmadığından dolayı en fazla üç, dört katmanlı ANN’ler kullanılmıştır. İşlemcilerin (CPU) gelişmesiyle daha fazla katmanlı ve her katmanda daha fazla nöron bulunan ANN modelleri oluşturulmaya başlanmış ve derin sinir ağı (Deep Neural Network, DNN) kavramı ortaya çıkmıştır. Ancak yine de CPU’lar mimarilerinden dolayı karmaşık matematiksel işlemlerde yetersiz kalabilmekte ve derin sinir ağı modellerinin eğitilmesi uzun sürebilmektedir. Görüntü işleme birimlerinin (GPU) gelişmeye başlamasıyla birlikte bilgisayarlar GPU’ları kullanarak vektörel hesaplamaları ve matris işlemlerini çok daha hızlı yapmaya başlamış ve derin sinir ağlarının kullanılması yaygınlaşmıştır (Goodfellow et al., 2016). Ayrıca evrimsel sinir ağları (CNN) ve yinelemeli sinir ağları (RNN) gibi daha karmaşık işlemler gerektiren derin öğrenme teknikleri ortaya çıkmış ve bu tekniklerin kullanılması son zamanlarda oldukça yaygınlaşmıştır.

3.1 Çalışmada Kullanılan Derin Öğrenme Yöntemleri

3.1.1 Yapay sinir ağları

ANN'ler tahmin modellerinde en çok kullanılan derin öğrenme yöntemlerinden birisidir. Ayrıca ANN'ler ile bir tahmin modeli geliştirmek CNN, RNN, LSTM gibi karmaşık algoritmalara göre daha kolaydır. ANN'ler, biyolojik nöronların yapısını ve işlevini taklit eder. Veriler arasındaki kompleks ilişkileri tanımlayabilir, büyük miktarda veriyi işleyebilir ve analiz edebilir.

ANN kullanarak bir tahmin modeli geliştirmek için öncelikle girdi verilerinin bir takım işlemden geçmesi gerekmektedir. Örneğin seyahat talebi tahmin eden bir ANN modeli geliştirmek için geçmiş seyahat verileri, hava durumu verileri ve takvim verileri gibi verilerin benzer ölçekte olmasını sağlamak için verilerin normalize edilmesi gerekir. Daha sonra veriler, birbirine bağlı yapay nöron katmanlarından oluşan ANN modelinde eğitilir. Basit bir ANN modelinde girdi katmanı, gizli katmanlar ve çıktı katmanı bulunur. Girdi katmanı, önceden işlenmiş verileri alır ve sonraki gizli katmanlara iletir. Katmanlar arasında belirlenen ağırlık ve sapma değerleri ile veriler bir dizi matematiksel işlemden geçer. Ayrıca verilere katmanlar içerisindeki nöronlarda bulunan aktivasyon fonksiyonları uygulanır. Son olarak, çıktı katmanı tahmin değerleri üretir. Bu çalışmadaki tahmin değerleri ise istasyonlar için tahmin edilen seyahat talebidir. Basit bir ANN modelinin mimarisi Şekil 3.3'te gösterilmiştir.



Şekil 3.3 Basit bir ANN modelinin mimarisi (girdi katmanı, gizli katmanlar ve çıktı katmanı)

Seyahat talebi tahmininde ANN kullanımının bazı avantajları ve dezavantajları vardır. Başlıca avantajlarından biri, ANN'ler girdi verileri ile çıktı verileri arasındaki karmaşık ve doğrusal olmayan ilişkileri başarılı olarak ele alabilir. ANN'ler, önceden herhangi bir varsayım veya bilgi gerektirmeden, seyahat talebini etkileyen değişkenlerin seyahat talebine olan etkisini otomatik olarak öğrenebilir ve tanımlayabilir. Ek olarak, ANN'ler hem istasyon bazında hem de sistem bazında eğitilerek farklı ayrıntı düzeylerinde seyahat talebini tahmin etmek için eğitilebilir.

Bununla birlikte, ANN'leri seyahat talebi tahmini için kullanmanın dezavantajları da vardır. Ana zorluklardan biri, bir ANN modeli oluştururken uygun sinir ağı mimarisini seçmek ve gizli katman sayısı, katmanlardaki nöron sayısı, aktivasyon fonksiyonları, iterasyon sayısı gibi hiperparametreleri belirlemektir. Veri kalitesinden sonra ANN'lerin performansı büyük ölçüde mimari seçimine ve hiperparametrelere bağlıdır. Kötü tasarlanmış bir model yanlış tahminlere neden olabilir. Bir ANN modeli geliştirmek için büyük miktarda ve yüksek kalitede veri gerekir.

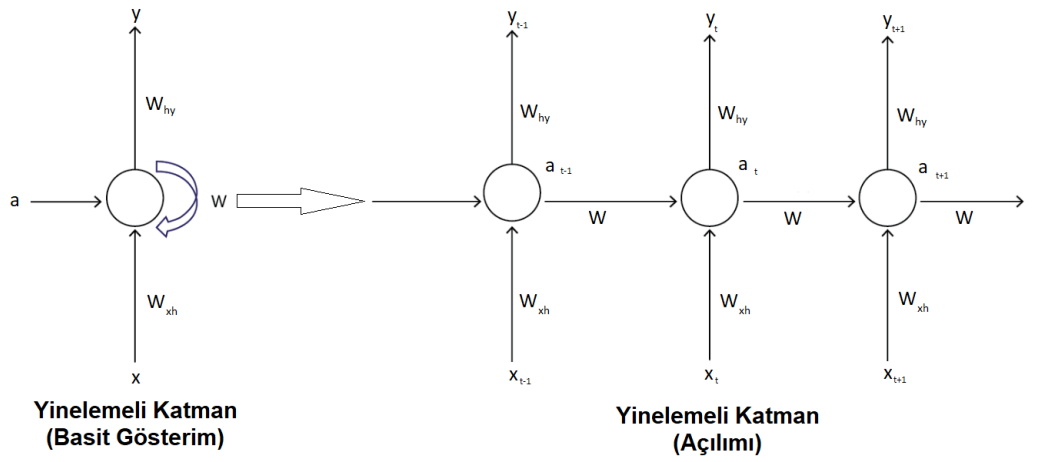
Özetle, ANN'ler girdiler arasındaki karmaşık ilişkileri yakalayabilmesi ve yüksek doğrulukta tahminler üretebilmesi yönleriyle raylı sistemlerde seyahat talebi tahmini için kullanılabilecek önemli yöntemlerden biri olarak karşımıza çıkmaktadır. Bu durum ANN'leri ulaşım planlaması ve seyahat talep tahmini için önemli bir araç haline getirmektedir.

3.1.2 Yinelemeli sinir ağları

RNN, sıralı verileri işlemek için tasarlanmış bir sinir ağı türüdür. RNN'ler, veriler arasındaki zamansal ilişkileri yakalayabildikleri için geçmiş seyahat verileri gibi zaman serisi verileri için oldukça uygundur. Seyahat talebi tahmininde, yolcu akışlarının zamana bağlı değişimini modellemek ve gelecekteki talebi tahmin etmek için RNN'ler kullanılarak başarılı tahmin modelleri geliştirilebilir.

ANN'lerde olduğu gibi RNN'lerde de girdi verilerinin benzer ölçekte olmasını sağlamak için verilerin normalize edilmesi gerekir. Veriler daha sonra, her dizi sabit bir zaman aralığına (örneğin, bir saat, bir gün, bir hafta) karşılık gelecek şekilde dizilere bölünür. Daha sonra normalize edilen veriler, yinelenen bir

katmandan ve bir veya daha fazla gizli katmandan (ANN'deki gizli katmanlara benzer şekilde gibi) oluşan RNN modelinde eğitilir. Tekrarlayan katman, sıralı verileri işler ve önceki girdilere dayalı olarak ilgili nöronun durumunu günceller. Bu durum RNN'nin veriler arasındaki zamansal bağımlılıkları yakalamasına ve seyahat talebinin zaman içerisinde değişen talep verisine göre modellenmesine olanak tanır. Son olarak, çıktı katmanı her istasyon veya rota için tahmin edilen seyahat talebini üretir. Basit bir RNN katmanının mimarisi Şekil 3.4'te gösterilmiştir.



Şekil 3.4 Basit bir RNN katmanının mimarisi

Seyahat talebi tahmini için RNN algoritmasını kullanmanın en önemli avantajı RNN modellerinin seyahat talep verilerindeki zamansal ilişkiyi başarılı bir şekilde yakalayabilmesidir. RNN'ler ile günlük ve haftalık döngüler, tatil etkileri ve hava durumuyla ilgili etkiler dahil olmak üzere seyahat talebinin zaman içerisindeki çeşitli sebeplere dayanan değişimi modellenebilir. Ek olarak, RNN'ler, kısa dönemden (örneğin sonraki saat veya sonraki gün) uzun döneme (örneğin gelecek hafta veya gelecek ay) kadar farklı projeksiyonlardaki seyahat talebini tahmin etmek üzere eğitilebilir.

Seyahat talebi tahmini için RNN'leri kullanmanın en önemli dezavantajı RNN modelini eğitirken ortaya çıkabilen kaybolan gradyan sorunudur (Zhao et al., 2017). Kaybolan gradyan sorunu, RNN modellerinin eğitim sürecinde ortaya çıkabilecek yaygın bir sorundur. Eğitim sürecindeki ağırlıklı güncellemek için kullanılan gradyanlar zaman etkisiyle küçülmektedir. Örnek vermek gerekirse, yarınki seyahat talebini etkileyebilecek olan uzak zamandaki bir değişkenin tahmin

üzerindeki etkisi kaybolan gradyan sorunu nedeniyle oldukça az olacaktır. Bu durum model eğitiminin başarısız olmasına sebep olabilir veya modelin bir çözüme yakınsaması için gereken süreyi oldukça artırabilir.

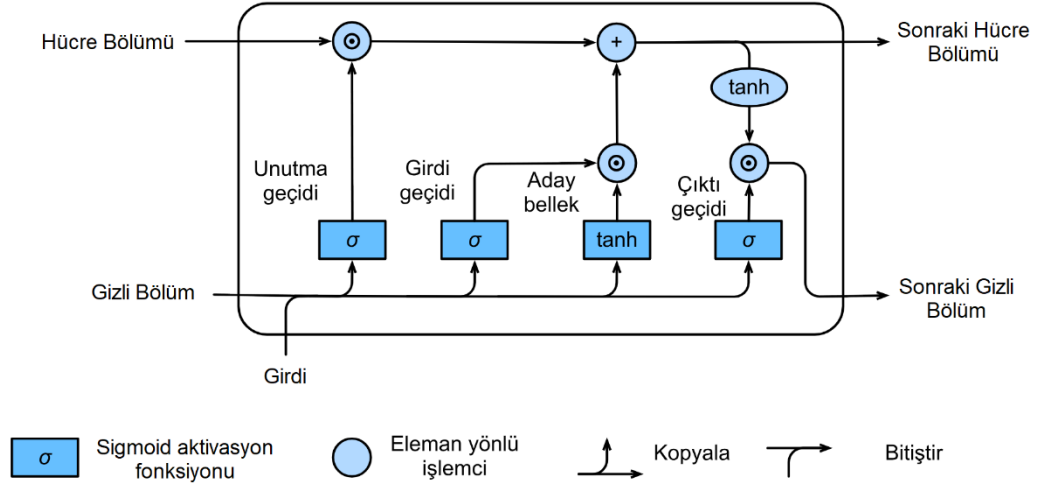
Sonuç olarak, seyahat talebi verilerindeki zamansal ilişkileri öğrenerek başarılı tahminler üretebilen RNN modelleri ulaşım planlaması için geliştirilmek istenen talep tahmin modellerinde kullanılabilir. Bununla birlikte, bir RNN modelinin geliştirilmesi ve optimizasyonu, büyük miktarda ve yüksek kaliteli veri gerektirir. Ayrıca, dizi uzunluğunun ve mimarisinin dikkatli bir şekilde seçilmesi model başarısı için çok büyük önem arz etmektedir. RNN yönteminin en önemli dezavantajı olan kaybolan gradyan sorunu bir sonraki bölümde açıklanacak olan uzun-kısa süreli bellek ağları (LSTM) yöntemi ile aşılmaktadır. Bundan dolayı, bu tez çalışmasında RNN yöntemi yerine, daha gelişmiş bir RNN modeli olan LSTM yöntemi kullanılarak bir model geliştirilmiştir.

3.1.3 Uzun-kısa süreli bellek ağları

LSTM ağları, RNN'lerdeki kaybolan gradyan problemini çözmek için tasarlanmış bir tür yinelemeli sinir ağıdır. LSTM'ler zaman serisi verilerindeki uzun vadeli bağımlılıkları yakalayabilir. LSTM ağı, zaman serisi verilerindeki uzun vadeli bağımlılıkları yakalamak ve doğru tahminler yapmak için tasarlanmıştır.

LSTM'ler, bilgileri uzun süre depolayabilen bir dizi bellek hücresi kullanarak çalışır. Her bellek hücresinin bir giriş kapısı, bir unutma kapısı ve bir çıkış kapısı olmak üzere üç kapısı vardır. Giriş kapısı, bellek hücresine bilgi girişini kontrol eder. Unutma kapısı, bellek hücresine gelen hangi bilginin unutulacağını (sonraki katmanlara aktarılmayacağını) kontrol eder. Çıkış kapısı, bilgi akışı sürecinde bilginin ağıdaki bir sonraki katmana aktarılmasını kontrol eder. Kapılar, "0" ile "1" arasında değerler veren ve ne kadar bilginin geçeceğini belirleyen sigmoid aktivasyon fonksiyonları tarafından kontrol edilir. Bir LSTM hücresinin mimarisi Şekil 3.5'te gösterilmiştir.

LSTM'leri kullanarak tahmin modeli geliştirmek için ilk adım öncelikle girdi verilerini ANN ve RNN modellerinde olduğu gibi normalize etmektir. Veriler daha sonra birden çok bellek hücresinden ve gizli katmanlardan oluşan LSTM ağında eğitilir.



Şekil 3.5 LSTM hücresi mimarisi.

LSTM'lerin en büyük avantajı kaybolan gradyan problemini çözdüğü için zaman serisi verilerinde daha uzun vadeli ilişkileri yakalayabilmesidir. Bu durum veriler arasında zamana bağlı olarak değişen karmaşık ilişkiler olduğunda bile daha tutarlı tahmin modeli oluşturulmasına olanak tanır. LSTM modeli geliştirirken bellek hücrelerinin sayısı ve öğrenme hızı gibi hiperparametrelerin seçimi çok önemlidir. Bu hiperparametreler, modelin performansı üzerinde önemli bir etkiye sahiptir. Ancak, hiperparametreler için optimum değeri bulmak hem çok fazla parametre bulunduğu hem de genellikle deneme – yanılma yöntemi kullanıldığı için kolay değildir.

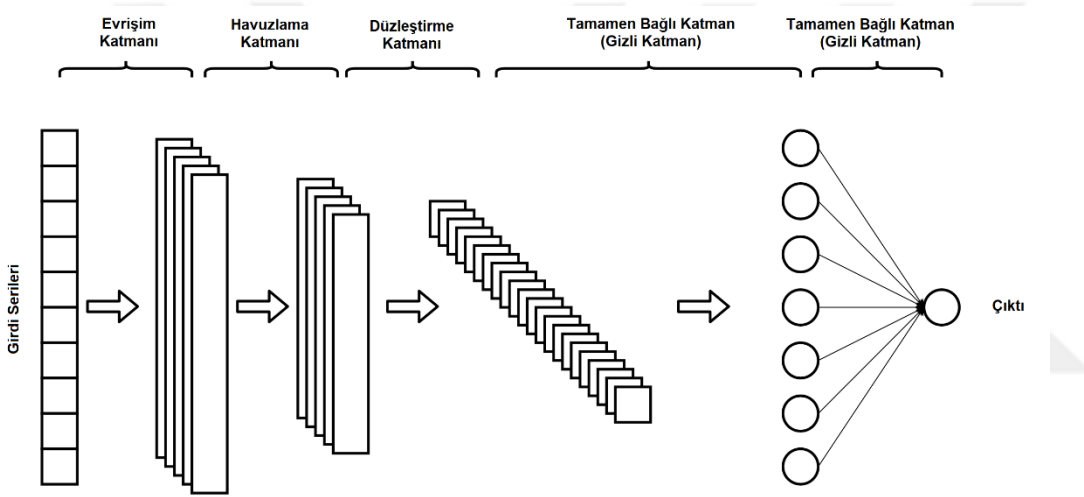
Geleneksel ANN'ler ile karşılaştırıldığında hem RNN'ler hem de LSTM'ler, verilerdeki zamansal bağımlılıkları modelleyebilme avantajına sahiptir. Bununla birlikte, RNN modelleri kaybolan gradyan problemi yaşarken, LSTM'ler bu sorunu çözmek için tasarlanmıştır. Performans açısından, LSTM'ler birçok zaman serisi tahmin modelinde geleneksel RNN'lerden ve diğer makine öğrenimi algoritmalarından daha iyi performans göstermektedir (Zhao et al., 2017).

Özetle, LSTM'ler ulaşım sistemlerinde seyahat talebi tahmini için kullanılacak tahmin modellerinde kullanılabilir. Zaman serisi verilerindeki uzun vadeli bağımlılıkları yakalaması ve doğru tahminler üretebilmesi bakımından ulaşım planlaması için tahmin modeli oluşturmak için tercih edilebilir.

3.1.4 Evrişimsel sinir ağıları

CNN, görüntü işleme çalışmaları için yaygın olarak kullanılan bir tür sinir ağıdır. Bununla birlikte, zaman serisi analiz çalışmalarında da başarılı sonuçlar ortaya koymaktadır (Xiong et al., 2019).

CNN'leri seyahat talebi tahminde kullanabilmek için verileri belirli bir zaman aralığında (örneğin her 15 dakikada bir) bir boyutlu bir zaman serisine dönüştürmek gerekir. Bu zaman serisi verileri daha sonra bir CNN modeline girdi olarak kullanılabilir. Basit bir tek boyutlu CNN modeli mimarisi Şekil 4.6'da gösterilmiştir.



Şekil 3.6 Tek boyutlu CNN modeli mimarisi.

CNN'ler zaman serisi verilerinden ilgili ilişkileri otomatik olarak öğrenme ve çıkarma konusunda avantajlıdır. Bu durum CNN'i girdiler ve çıktılar arasındaki doğrusal olmayan ilişkileri yakalama konusunda geleneksel ANN modellerinden daha etkili hale getirmektedir. Ek olarak, havuzlama katmanlarının kullanılması, verilerin boyutsallığını azaltarak modeli eğitim açısından daha verimli hale getirmektedir. Ancak CNN'ler verilerdeki uzun vadeli bağımlılıkları modelleyememektedir. Bu durum uzun süreli hafıza gerektiren görevlerde iyi performans gösteremeyebilecekleri anlamına gelir. CNN'ler, veriler arasındaki ilişkiyi etkili bir şekilde öğrenmek ve çıkarmak için büyük miktarda eğitim verisine ihtiyaç duyar.

Özetle, CNN'ler, ulaşım sistemlerinde seyahat talebi tahmini dahil olmak üzere zaman serisi analiz görevleri için kullanılabilecek bir derin öğrenme yöntemidir. Verilerden ilgili örüntüleri ve özellikleri otomatik olarak öğrenme ve çıkarma konusunda etkilidirler. Ancak bu gibi zaman serisi verilerinin işlenmesi için RNN veya LSTM gibi yöntemlerin kullanılması başarıyı artırabilir. Seyahat talebi tahmini için bir sinir ağı mimarisi seçerken, ilgili çalışmanın gereksinimlerini ve kullanılabilecek mimarilerin güçlü ve zayıf yanlarını dikkate almak önemlidir.

3.2 Çalışmada Kullanılan Veri

Bu tez çalışmasında seyahat talebi tahmin modellerini geliştirmek için Metro İstanbul'dan M2 Yenikapı – Hacıosman metro hattına ait 2019 ve 2020 yıllarında gerçekleşen seyahatlere ilişkin ücret toplama sistemi verileri talep edilmiştir. Belirtilen yıllara ait saatlik bazda ücret toplama sistemi verileri temin edilmiştir. Gerekli veri düzenlemeleri yapılarak seyahat verileri model geliştirme sürecinde kullanılabilecek şekilde günlük seyahat verilerine dönüştürülmüştür. Yapılan düzenlemeler sonucunda 2019 ve 2020 yıllarında gerçekleşmiş olan seyahatlere ilişkin günlük veriler elde edilmiştir.

Model geliştirmek için kullanılan diğer bir veri türü ise meteorolojik verilerdir. 2019 ve 2020 yıllarına ait meteorolojik veriler için açık kaynaklardan günlük ortalama sıcaklıklar, yağış miktarı ve rüzgâr hızı verileri elde edilmiştir.

Millî Eğitim Bakanlığı'na bağlı okulların (ilkokul, ortaokul ve liseler) ve M2 metro hattı güzergahında bulunan üniversitelerin eğitim döneminde olup olmaması da metro hattında oluşan talebi etkileyen önemli olaylardır. Bu veri setini oluşturmak için açık kaynaklar kullanılmıştır. Millî Eğitim Bakanlığı'nın duyurduğu eğitim – öğretim takvimi incelenmiştir. Yaz tatilli dönemi, yarıyıl tatil dönemi ve her iki dönem içerisindeki verilen birer haftalık ara tatiller veri setinde ifade edilmiştir. M2 metro güzergahı kullanılarak Boğaziçi Üniversitesi, İstanbul Üniversitesi ve İstanbul Teknik Üniversitesi'ne ulaşım sağlanmaktadır. Bu üniversitelerin akademik takvimleri incelenmiş ve ders dönemleri ayrı ayrı veri setine eklenmiştir.

Seyahat talebini etkileyen en önemli değişkenlerden birisi de haftanın günüdür. Bazı çalışmalar bu veriyi hafta içi ve hafta sonu olarak etiketlemiş olsa da

bu çalışmada haftanın her bir günü ayrı ayrı veri setine dahil edilerek seyahat talebindeki haftanın günü etkisi değerlendirilmiştir. 2019 ve 2020 yıllarındaki her bir günün, haftanın hangi günü olduğu (pazartesi, çarşamba, pazar vs.) veri seti içerisine kaydedilmiştir. İçinde bulunulan ay (ocak, şubat, mart vs.) değişkeninin de seyahat talebini etkileyebileceği düşünülmüş ve veri setine ay değişkeni eklenmiştir. Seyahat talebini etkilediği düşünülen bir diğer değişken de günün resmî tatil olup olmamasıdır. İş günlerinde diğer günlere göre çok daha fazla seyahat talebi olduğu bir gerçektir. Dolayısıyla 2019 ve 2020 yıllarındaki resmî tatiller (dini bayramlar, millî bayramlar, özel günler) açık kaynaklar kullanılarak veri setine eklenmiştir. İstanbul'da bu gibi özel günlerde genellikle toplu taşıma hizmeti ücretsiz sunulmaktadır. Bu değişken sayesinde bu durumun da seyahat talebi üzerindeki etkisi incelenmiş olacaktır.

Kentlerde yüksek katılım ile gerçekleşen organizasyonlar yapısına ve konumuna bağlı olarak toplu taşıma sistemlerinde beklenenden fazla bir talep oluşmasına sebep olabilmektedir. Galatasaray Spor Kulübü'nün futbol maçlarını oynadığı Ali Sami Yen Spor Kompleksi'ne M2 metro hattı kullanılarak Seyrantepe istasyonundan kolaylıkla ulaşılabilir. Ayrıca Beşiktaş Jimnastik Kulübü'nün futbol maçlarını oynadığı Beşiktaş Stadyumu Taksim istasyonuna 1,3 km uzaklıktadır. Geçmiş seyahat verileri incelendiğinde bu stadyumlarda futbol maçı oynanan günlerde M2 metro hattına diğer günlerden daha yoğun bir talep olduğu görülmüştür. 2019 ve 2020 yıllarında Ali Sami Yen Spor Kompleksi'nde ve Beşiktaş Stadyumunda Galatasaray Spor Kulübü'nün, Beşiktaş Jimnastik Kulübü'nün ve Türkiye A Millî Futbol Takımı'nın futbol maçlarını oynadığı tarihler bulunmaktadır. Bu nedenle bu stadyumlarda futbol maçı oynanan günler veri setine ayrı ayrı eklenmiştir.

2020 yılında toplu taşıma sistemlerindeki seyahat talebini çok büyük oranda düşüren bir olay olan Covid-19 pandemisi ülkemizde de etkisini önemli düzeyde hissettirmiştir. Bu nedenle 2020 yılında ülkemizde ilk Covid-19 vakasının görüldüğü tarih olan 11 Mart 2020 gününden itibaren 2020 yılına ait olan veriler bu çalışmada kullanılmamıştır. 2019 yılına ait veriler seyahat tahmin modelini geliştirmek için, 2020 yılına ait 10 Mart 2020 tarihine kadar olan veriler de geliştirilen modeli test etmek için kullanılmıştır. Böylece geliştirilen modelin

gelecekteki bir tarihi tahmin etme başarısı test edilmiştir. Final veri setinde; M2 metro güzergâhındaki 16 istasyonun günlük kullanım verisi, her güne ait ortalama hava sıcaklıkları, yağış miktarı, rüzgâr hızı verisi, Millî Eğitim Bakanlığı'na bağlı okulların eğitim döneminde olup olmadığı, Boğaziçi Üniversitesi, İstanbul Üniversitesi ve İstanbul Teknik Üniversitesi'nin ayrı ayrı eğitim döneminde olup olmadıkları, haftanın günü, içinde bulunulan ay, resmî tatil günleri, Ali Sami Yen Spor Kompleksi'nde ve Beşiktaş Stadyumu'nda ayrı ayrı futbol maçı olup olmaması gibi veriler yer almaktadır. Sonuç olarak, eğitim veri setinde 2019 yılına ait 365 günlük veri, test veri setinde 2020 yılının 10 Mart tarihine kadar olan 70 günlük veri yer almaktadır.

3.3 Veri Önleme

Veri önleme aşaması, kullanılacak veri setinin hazırlanması için yapılan önemli bir adımdır. Bu aşamada, nümerik verilerin “0” ile “1” arasında ölçeklendirilerek normalize edilmesi ve kategorik verilerin uluslararası literatürde “one-hot-encoding” olarak geçen, bu tez çalışmasında “ikili etiket kodlama” olarak ifade edilecek olan işleme tabi tutulması gerçekleştirilmiştir. Ayrıca, geliştirilecek olan LSTM ve CNN modelleri için belirli uzunluklarda zaman serisi dizileri oluşturulmuştur. Bu işlemler modelin daha hızlı ve stabil bir şekilde eğitilmesine, daha iyi sonuçlar vermesine ve yanlış öğrenmeyi önlemesine katkı sağlar.

3.3.1 Nümerik verilerin normalizasyonu

Çalışmada hava sıcaklığı, yağış miktarı, rüzgâr hızı ve her bir istasyondaki seyahat sayısı gibi farklı ölçeklere sahip nümerik veriler kullanılmıştır. Farklı ölçeklerdeki veriler modelin başarısını olumsuz etkileyebilir ve eğitim sürecini yavaşlatabilir. Bu nedenle bu çalışmada normalize etme işlemi uygulanarak veriler aynı ölçeğe getirilmiştir.

Normalize etme işlemi, veri setindeki tüm değerleri belirli bir aralığa dönüştürmek amacıyla uygulanır. Bu çalışmada veriler “0” ile “1” arasında ölçeklendirilmiştir. Bu işlem her bir verinin, veri seti içerisindeki kendi maksimum ve minimum değerleri arasındaki oransal pozisyonunu ifade eden bir ölçeğe dönüşmesini sağlar. Bu sayede, verilerin farklı ölçeklerde olması engellenir, eğitim

sürecinde gradyanların aşırı büyümesi önlenir ve modelin eğitimi daha başarılı bir şekilde gerçekleştirilir.

3.3.2 Kategorik verilerin etiketlenmesi

Modelde kullanılan veriler arasında kategorik değişkenler de bulunmaktadır. Örneğin, okulların ve üniversitelerin açık olup olmaması, haftanın günleri, ay, Ali Sami Yen Spor Kompleksi'nde ve Beşiktaş Stadyumu'nda futbol maçı olup olmaması ve günün resmî tatil olup olmaması bu tez çalışmasında kullanılan kategorik değişkenlerdir. Kategorik değişkenler, makine öğrenmesi ve derin öğrenme algoritmalarının doğrudan işleyemeyeceği metinsel veya sembolik değerler içerir. Bu nedenle, bu kategorik değişkenler sayısal formata dönüştürülmelidir. Bu işlem için genellikle etiket kodlama (label encoding) ve ikili etiket kodlama (one-hot encoding) olmak üzere iki farklı yöntem kullanılır.

Etiket kodlama kategorik değişkenleri sıralı bir sayı dizisine dönüştürmenin en basit yöntemidir. Her bir kategori değeri için sırasıyla sıfırdan başlayarak birer artan sayılar atanır. Örneğin, resmî tatil olma durumu için "1" değeri atanırken, resmî tatil olmayan günler için "0" değeri atanır. Aynı şekilde, haftanın günü değişkeni için pazartesiye "1", salıya "2" gibi sıralı değerler atanır (Tablo 3.1).

Tablo 3.1 Etiket kodlama örneği.

Etiket Kodlama	
Haftanın Günü	Kategori
Pazartesi	0
Salı	1
Çarşamba	2
Perşembe	3
Cuma	4
Cumartesi	5
Pazar	6

İkili etiket kodlama kategorik değişkenlerin sayısal verilere dönüştürülmesi için yaygın olarak kullanılan başka bir yöntemdir. Bu işlemde, kategorik değişkenin her bir kategori değeri ayrı bir sütun olarak temsil edilir. Bu sütunlardan sadece gerçek olan kategoriye karşılık gelen hücrelere "1" değeri atanırken, diğer hücrelere "0" değeri atanır. Örneğin, resmî tatil olma durumu için resmî tatil olduğunu ifade eden kolon ve resmî tatil olmadığını ifade eden kolon olmak üzere iki farklı kolon

bulunur. O gün resmî tatil ise, resmî tatil olduğunu ifade eden kolona “1”, resmî tatil olmadığını ifade eden kolona “0” değeri atanır. Aynı şekilde, haftanın günü değişkeni için her bir gün ayrı bir sütunda temsil edilir ve bu durum haftanın günü değişkeni için veri seti içerisinde yedi sütun olduğu anlamına gelir. Örneğin, pazartesi günü için birinci kolona “1” diğer altı kolona “0” değeri atanırken, haftanın üçüncü günü olan çarşamba günü için üçüncü kolona “1” diğer altı kolona “0” değeri atanır (Tablo 3.2).

Tablo 3.2 İkili etiket kodlama örneği.

İkili Etiket Kodlama							
Etiket	Pazartesi	Salı	Çarşamba	Perşembe	Cuma	Cumartesi	Pazar
Pazartesi	1	0	0	0	0	0	0
Salı	0	1	0	0	0	0	0
Çarşamba	0	0	1	0	0	0	0
Perşembe	0	0	0	1	0	0	0
Cuma	0	0	0	0	1	0	0
Cumartesi	0	0	0	0	0	1	0
Pazar	0	0	0	0	0	0	1

Bu işlemler sonucunda kategorik değişkenler sayısal bir formata dönüştürülmüş olur ve model tarafından işlenebilir hale gelir. Kategorik değişkenlerin kategorileri arasında hiyerarşik bir sıralama olmadığı için bu çalışmada ikili etiket kodlama yöntemi tercih edilmiştir.

İkili etiket kodlama yöntemi kullanıldığından dolayı; haftanın günü değişkeni yedi, ay değişkeni 12, Ali Sami Yen Spor Kompleksi’nde ve Beşiktaş Stadyumu’nda futbol maçı olup olmaması değişkenleri dört (her biri için iki), günün resmî tatil olup olmaması değişkeni iki, okulların ve üniversitelerin açık olup olmaması değişkenleri sekiz (MEB’e bağlı okullar için iki değişken, üç üniversitenin her biri için ikişer değişken) değişken ile ifade edilmektedir. Dolayısıyla kategorik değişkenlerin girdi uzunluğu 33’tür. Hava sıcaklığı, yağış miktarı ve rüzgâr hızı değişkenlerinden oluşan nümerik değişkenlerin sayısı da üçtür. Dolayısıyla, dışsal faktör değişkenlerinin tamamının tahmin modelinde kullanılması durumunda dışsal faktörler 36 elemanlı bir vektör ile ifade edilir.

3.3.3 LSTM dizilerinin oluşturulması

LSTM ve CNN yöntemleri ile geliştirilen modellerde girdi olarak kullanmak için belirli bir dizi uzunluğunda geçmiş seyahat verileri oluşturulmuştur. Bu çalışmada dizi uzunlukları model başarılarına göre deneme yanılma yöntemiyle belirlenmiştir. Çalışmada geliştirilen farklı modeller farklı dizi uzunluklarında en iyi başarılarına ulaşmışlardır. Geliştirilmiş olan LSTM ve CNN modellerinde 14 günlük, LSTM – ANN ve LSTM – CNN hibrit modellerde ise beş günlük dizilerin seyahat talebi tahminlerinde daha başarılı olduğu değerlendirilmiş ve bu dizi uzunlukları kullanılmıştır.

Veri setindeki zaman serisi verileri kullanılarak belirlenen uzunluklarda diziler oluşturulurken her bir tahmin edilmek istenen hedef gün için, o günden önceki beş veya 14 günün normalize edilmiş seyahat verileri alınmıştır. Örneğin, hibrit modellerde belirli bir tarihi tahmin etmek için kullanılan girdi verileri arasında, tahmin edilmek istenen günün öncesindeki beş günlük geçmiş seyahat verileri bulunmaktadır.

Dizilerin oluşturulmasında dikkat edilen önemli bir faktör dizilerin zaman sırasına uygun bir şekilde düzenlenmesidir. Bu durum modelin zaman serisi içerisindeki örüntüyü öğrenmesi için önemlidir. Uygun dizi uzunluğu modelin yeterli miktarda veriyle eğitilmesini ve zaman serilerindeki önemli örüntüleri keşfetmesini sağlar. Bu çalışmada geliştirilen modellerin tahmin başarısını artırmak amacıyla deneme yanılma yöntemiyle en uygun dizi uzunlukları belirlenmiştir.

3.4 Değerlendirme Ölçütleri

Geliştirilen modellerin başarılarını ve performanslarını değerlendirmek için birçok değerlendirme ölçütü kullanılabilir. Bu değerlendirme ölçütleri, tahmin modellerinin sonuçlarını gerçek değerler ile karşılaştırarak doğruluk, hata miktarı ve korelasyon açılarından model başarısı ile ilgili bilgi verir. Bu çalışmada değerlendirme ölçütleri olarak hata kareleri ortalamasının karekökü (RMSE), ortalama mutlak hata (MAE), ortalama mutlak yüzde hata (MAPE) ve belirleme katsayısı (R kare) kullanılmıştır.

3.4.2 Ortalama mutlak hata (MAE)

MAE, tahmin edilen değerler ile gerçek değerler arasındaki ortalama mutlak farkı ölçen yaygın olarak kullanılan bir metriktir. RMSE'den farklı olarak MAE, hataların karesini almaz ve bu da MAE ölçütünü çok büyük hatalara ve aykırı değerlere karşı RMSE'ye göre daha az duyarlı hale getirir. MAE, hata yönü ne olursa olsun hataların mutlak değerlerini alarak ortalama hata büyüklüğünü değerlendirir. RMSE'ye benzer şekilde, daha düşük bir MAE değeri, modelin tahmin başarısının daha iyi olduğunu gösterir. “n” yapılan tahmin sayısı olmak üzere, MAE ölçütünün matematiksel formülü aşağıda verilmiştir.

$$MAE = \frac{1}{n} \sum_{i=1}^n |tahmin_i - gercekleşen_i|$$

3.4.1 Hata kareleri ortalamasının karekökü (RMSE)

RMSE, tahmin edilen değerler ile gerçek değerler arasındaki hataların ortalama büyüklüğünü ölçmek için kullanılan bir ölçüttür. Tahmin edilen ve gözlemlenen değerler arasındaki farkların karelerinin ortalamasının karekökü alınarak hesaplanır. Hata miktarı arttıkça hatanın karesinin çok daha fazla artacağından dolayı, RMSE ölçütü büyük hatalara karşı oldukça duyarlıdır. Tahmin edilen değer ile gerçek değerler arasındaki önemli sapmaları belirlemek için kullanılabilir. Düşük RMSE değerleri, daha iyi tahmin performansını gösterir. “n” yapılan tahmin sayısı olmak üzere, RMSE ölçütünün matematiksel formülü aşağıda verilmiştir.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (tahmin_i - gercekleşen_i)^2}{n}}$$

3.4.3 Ortalama mutlak yüzde hata (MAPE)

MAPE, tahmin edilen değerler ile gerçek değerler arasındaki ortalama yüzdesel farkı gösteren yüzde tabanlı bir ölçüttür. Her bir tahmin değeri için hatanın yüzdesel değerinin mutlak değerinin ortalaması alınarak hesaplanır. MAPE, özellikle göreceli doğruluğun tahmin edilen ve gerçek değerler arasındaki mutlak farktan daha kritik olduğu durumlarda, tahmin senaryolarında yaygın olarak

kullanılır. Bu tez çalışmasında da MAPE değerinin tahmin başarısı ölçütü olarak daha çok dikkate alınması gerektiği düşünülmektedir. Zira, metro hattının her bir istasyonundaki günlük talep birbirinden farklı olabilir. Çalışılan metro hattında günlük ortalama 50.000 seyahatin yapıldığı bir metro istasyonu varken, ortalama 5.000 seyahatin yapıldığı farklı bir istasyon da bulunmaktadır. Örneğin, tahmin değerinde yapılan 1.000 seyahatlik bir hata günlük 50.000 seyahatin yapıldığı istasyonda %2'lik bir hataya karşılık gelirken, aynı hata miktarı günlük 5.000 seyahatin yapıldığı istasyonda gerçekleşirse %20'lik bir hataya karşılık gelmektedir. Yani, her iki senaryoda da MAE değerleri aynı olmasına karşın, MAPE değerleri oldukça farklıdır ve düşük olan MAPE değeri modelin tahmin performansının yüzdesel anlamda daha başarılı olduğunu gösterir. “n” yapılan tahmin sayısı olmak üzere, MAPE ölçütünün matematiksel formülü aşağıda verilmiştir.

$$MAPE = \frac{\%100}{n} \sum_{i=1}^n \frac{|tahmin_i - gerçekteşen_i|}{gerçekteşen_i}$$

3.4.4 Belirleme katsayısı (R kare)

R kare değeri bağımsız değişkenler tarafından açıklanan bağımlı değişkendeki varyansın oranını temsil eden istatistiksel bir ölçüttür. Yani, farklı girdi değerleri ile model tarafından tahmin edilen değerlerin gerçek değerler ile ne kadar uyumlu değiştiğini gösterir. “0” ile “1” arasında değişir; bire yakın bir R kare değeri, modelin verilere iyi uyan bir model olduğunu gösterirken, sıfıra yakın bir değer modelin verilere uymadığını, bu modelle yapılan tahmin değerinin veri setinin ortalama değeri kullanılarak yapılan tahminden daha iyi olmadığını ifade eder. Negatif bir R kare değeri de mümkündür. Bu, modelin gerçek değer ve ortalamasının çok uzağında olduğunu, gerçeğe kıyasla oldukça uyumsuz tahmin yaptığını gösterir. R kare değeri modelin tahminlerinin ne kadar gerçeğe yakın olduğu ile ilgili bilgi vermez. Ancak, bağımsız değişkenler ve tahmin edilmek istenen gerçek değer arasındaki uyumu modelin ne kadar başarılı olarak yakaladığının bir ölçütüdür. “n” yapılan tahmin sayısı olmak üzere, R kare ölçütünün matematiksel formülü aşağıda verilmiştir.

$$MAE = 1 - \frac{\sum_{i=1}^n (gerçekteşen_i - tahmin_i)^2}{\sum_{i=1}^n (gerçekteşen_i - gerçekteşen_ortalama)^2}$$

3.5 Geliştirilen Modeller

Bu tez çalışmasının öncelikli amacı başarılı bir seyahat talebi tahmin modeli geliştirmektir. Bu çalışmanın diğer çıktısı da farklı değişkenlerin ve derin öğrenme yöntemlerinin tahmin başarısı üzerindeki etkilerini incelemektir. Dolayısıyla, farklı teknikler ve farklı veri kombinasyonları kullanılarak birden fazla model geliştirilmiş, bu modellerin başarıları bulgular ve tartışma bölümlerinde değerlendirilmiştir. Veri kombinasyonlarını daha kolay değerlendirebilmek için girdi olarak verilen değişkenler temsil ettikleri olguya göre gruplandırılmıştır. Ortalama hava sıcaklığı, yağış miktarı, ortalama rüzgâr hızı gibi değişkenler “Hava Durumu”, haftanın günleri “Haftanın Günü”, içinde bulunulan ay “Ay”, günün resmî tatil olup olmaması “Tatil”, Millî Eğitim Bakanlığı’na bağlı okulların ve bölgede bulunan üniversitelerin (İstanbul Üniversitesi, İstanbul Teknik Üniversitesi ve Boğaziçi Üniversitesi) eğitim döneminde olup olmaması “Eğitim”, Ali Sami Yen Spor Kompleksi’nde ve Beşiktaş Stadyumu’nda futbol maçı olup olmaması değişkeni de “Etkinlik” başlığı altında gruplandırılmıştır. Bu belirtilen değişkenlere de bütüncül bir isim olarak “Dışsal Faktör Verileri” adı verilmiştir. LSTM ve CNN tekniklerinin kullanıldığı modellere girdi olarak verilen geçmiş seyahat verileri de “Geçmiş Seyahat Verileri” olarak adlandırılmıştır. Bu çalışma kapsamında geliştirilen modeller aşağıda sıralanmıştır:

- Dışsal faktör verileri ve geçmiş seyahat verileri kullanılarak geliştirilen ANN modeli.
- Sadece geçmiş seyahat verileri kullanılarak geliştirilen LSTM modeli.
- Sadece geçmiş seyahat verileri kullanılarak geliştirilen CNN modeli.
- Dışsal faktör verileri ve geçmiş seyahat verileri kullanılarak geliştirilen LSTM – ANN hibrit modeli.
- Dışsal faktör verileri ve geçmiş seyahat verileri kullanılarak geliştirilen LSTM – CNN hibrit modeli.

Bu çalışmada verilerin düzenlemesi için Numpy ve Pandas kütüphaneleri, veri normalizasyonu için Scikit-learn kütüphanesi, veri görselleştirme ve grafik çizimleri için Matplotlib kütüphanesi ve derin öğrenme modellerinin geliştirilmesi için TensorFlow kütüphanesinden yararlanılmıştır. Tüm bu işlemler Python programlama dili kullanılarak Google Colaboratory ortamında gerçekleştirilmiştir.

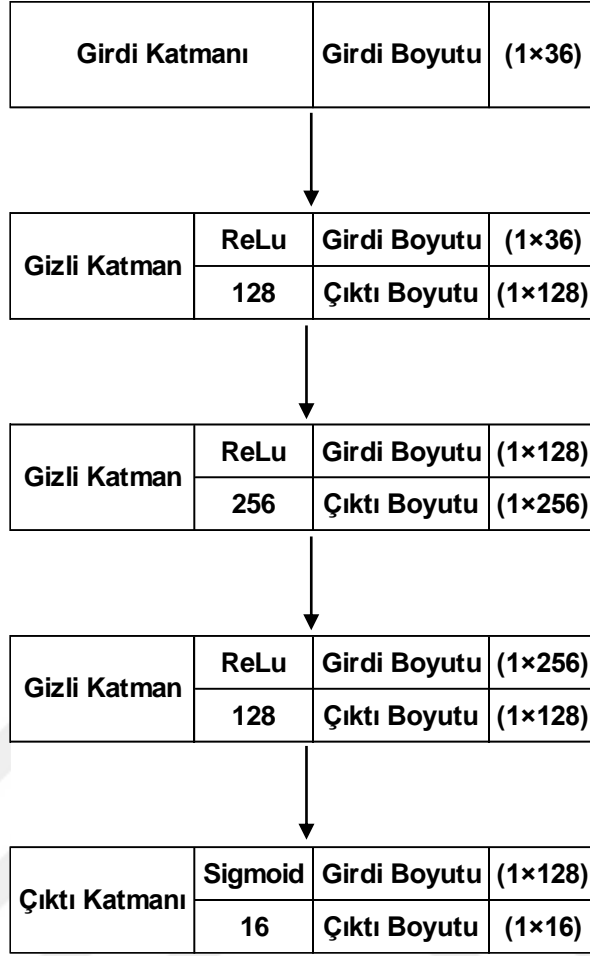
3.5.1 ANN modeli

Bu çalışmada ilk olarak metro hattındaki günlük seyahat talebini tahmin etmek için ANN modeli geliştirilmiştir. Model, 2019 yılına ait tüm verilerle eğitilmiş ve 2020 yılındaki pandemi öncesi döneme kadar olan veri ile test edilmiştir.

Girdi katmanında dışsal faktör verileri kullanılmıştır. Yani bu model, geçmiş seyahat verilerini girdi olarak kullanmamaktadır. Çıktı katmanında ise 16 istasyonun her biri için ilgili güne ait seyahat sayısı verisi yer almaktadır. Dışsal faktör verileri içerisinde nümerik olarak yer alan hava sıcaklığı, yağış miktarı, rüzgâr hızı ve çıktı katmanında yer alan her bir istasyondaki seyahat sayısı gibi veriler normalize edilmiştir. Kategorik veriler ise ikili etiket kodlama yöntemi ile derin öğrenme modelinin anlayabileceği sayısal bir formata dönüştürülmüştür.

ANN modeli, çok katmanlı bir yapısı olan yapay sinir ağları kullanılarak tasarlanmıştır. Girdi katmanı, üç gizli katman ve çıktı katmanı içermektedir. Girdi katmanında her bir özelliğe karşılık gelen düğümler bulunmaktadır. Dışsal faktör verilerini oluşturan tüm veriler girdi olarak kullanıldığında girdi sayısı veri ön işleme bölümünde ifade edildiği gibi 36 olmaktadır. İlk gizli katmanda 128, ikinci gizli katmanda 256, üçüncü gizli katmanda da 128 düğüm kullanılmıştır. Gizli katmanlardaki tüm nöronlarda ReLU aktivasyon fonksiyonu tercih edilmiştir.

Çıktı katmanında 16 adet nöron bulunmaktadır, her bir nöron bir istasyondaki günlük seyahat sayısını tahmin etmektedir. Çıktı katmanındaki her nöron için sigmoid aktivasyon fonksiyonu kullanılmıştır. Sigmoid aktivasyon fonksiyonu tahmin modellerinde sıklıkla kullanılır ve çıktıları “0” ile “1” arasında bir olasılık değeri olarak üreterek tahminlerin olasılık dağılımına uygun bir şekilde ifade edilmesini sağlamaktadır. Çıktı verilerinin zaten “0” ile “1” arasında normalize edildiği düşünüldüğünde sigmoid fonksiyonu uygun bir tercih olarak değerlendirilmiştir. Açıklanan bu modelin mimarisi Şekil 3.7’de gösterilmiştir.



Şekil 3.7 Geliştirilen ANN Modeli Mimarisi

Model eğitimi, eğitim veri setindeki verilerin kullanılarak ağırlık ve sapma değerlerinin ayarlanması sürecini ifade eder. Model geliştirme sürecinde aşırı uyum sorunundan (overfitting) kaçınmak için dropout ve L2 regülarizasyon teknikleri kullanılmış, ancak bu tekniklerin modelin tahmin başarısına olumlu bir etkisi olmadığı değerlendirilerek sonuç modelde bu tekniklere yer verilmemiştir. Eğitim süresince hata fonksiyonunun ürettiği hata değerlerini azaltan optimizasyon algoritması olarak tahmin modellerinde sıklıkla kullanılan “Adam (Adaptif Moment Kestirimi)” algoritması kullanılmıştır. Modelin hiperparametreleri olan; gizli katman sayısı, gizli katmanlardaki nöron sayısı, iterasyon sayısı ve aktivasyon fonksiyonları bu eğitim sürecinde deneme-yanılma yöntemleriyle belirlenmiştir.

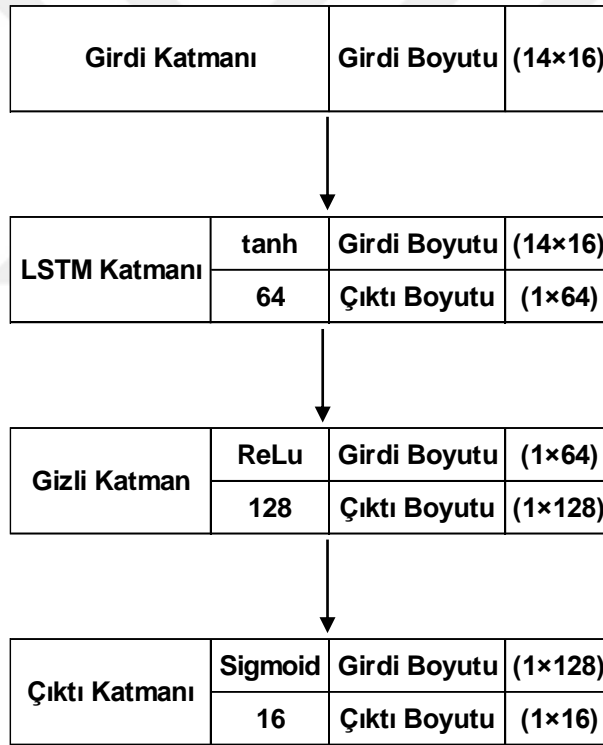
Geliştirilen model, 2020 yılındaki pandemi öncesi dönem verileriyle test edilmiş, test aşamasında modelin tahminleri gerçek verilerle karşılaştırılmış ve tahmin başarısı değerlendirilmiştir. Modelin performansını değerlendirmek için RMSE, MAE, MAPE ve R kare ölçütleri kullanılmıştır. Bu ölçütlerin sonuçlarına

göre, model eğitimi sürecindeki parametreler uygun bir şekilde düzenlenerek iyileştirilmiştir.

3.5.2 LSTM modeli

Bu çalışmada geliştirilen diğer model, metro hattındaki günlük seyahat talebini tahmin etmek için sadece geçmiş seyahat verilerini kullanarak geliştirilen LSTM modelidir. Model, 2019 yılına ait seyahat verileri ile eğitilmiş ve 2020 yılındaki pandemi öncesi döneme kadar olan seyahat verileri ile test edilmiştir.

Modelin mimarisi, girdi katmanı, bir adet LSTM katmanı, bir adet gizli katman ve çıktı katmanı olmak üzere dört temel katmandan oluşmaktadır. Model mimarisi Şekil 3.8’de gösterilmiştir.



Şekil 3.8 Geliştirilen LSTM modeli mimarisi.

Girdi katmanında, tahmin edilmek istenen gün öncesindeki son 14 güne ait normalize edilmiş seyahat verileri kullanılmıştır. Metro hattındaki toplam 16 istasyon için her bir istasyonun geçmiş seyahat verileri, girdi katmanından modele verilmiştir. Girdi katmanının boyutu 16 istasyon için geçmiş 14 günlük veri olmak üzere 14×16 olarak ifade edilebilir.

Geliştirilen modelde girdi katmanından sonra LSTM katmanı gelmektedir. Bu katmanda 64 adet LSTM hücresi kullanılmıştır. LSTM hücreleri geçmiş 14 günlük seyahat verileri ile bir sonraki gün gerçekleşecek olan seyahat sayısı arasındaki ilişkiyi öğrenerek gelecekteki seyahat talebini tahmin etmek için tasarlanmıştır. Her bir LSTM hücresinde hiperbolik tanjant (tanh) aktivasyon fonksiyonu kullanılmıştır. Bu fonksiyon giriş değerinin “-1” ile “1” arasında bir değere dönüştürülmesini sağlar. Böylece giriş değerlerinin çok büyük veya çok küçük değerlerde olmasını önleyerek, LSTM'in daha kararlı ve doğru bir şekilde çalışmasını sağlar.

LSTM katmanından sonra, bir adet gizli katman gelmektedir. Tasarlanan gizli katman 128 adet nörondan oluşmaktadır. Bu katman, LSTM katmanından elde edilen 64 elemanlı tek boyutlu vektörü alır ve katmandaki her bir nöronda yer alan ReLU aktivasyon fonksiyonundan geçirerek 128 elemanlı tek boyutlu bir vektöre dönüştürür. ReLU, doğrusal olmayan bir fonksiyon olup, ağın lineer olmayan ilişkileri öğrenmesine yardımcı olur ve modelin daha esnek bir şekilde öğrenmesini sağlar.

Gizli katmandan sonra, çıktı katmanı gelmektedir. Çıktı katmanında, her biri metro hattının bir istasyonuna karşılık gelen 16 adet nöron yer alır. Bir önceki gizli katmandan gelen 128 elemanlı tek boyutlu vektör bu katmanda sigmoid fonksiyonundan geçirilir. Sigmoid aktivasyon fonksiyonu, çıktıları “0” ile “1” arasında bir olasılık değeri olarak döndürür ve bu sayede tahminlerin olasılık dağılımına uygun bir şekilde ifade edilmesini sağlar.

Modelin eğitim sürecinde, hata değerini azaltan optimizasyon algoritması olarak yine Adam algoritması kullanılmıştır. Modelin performansını değerlendirmek için RMSE, MAE, MAPE ve R kare ölçütleri kullanılmıştır. Bu ölçütler, modelin tahmin başarısını değerlendirmede kullanılarak modelin performansının iyileştirilmesine yönelik deneme – yanılma yöntemleriyle modelin mimarisinin ve hiperparametrelerinin belirlenmesine de katkı sağlamıştır.

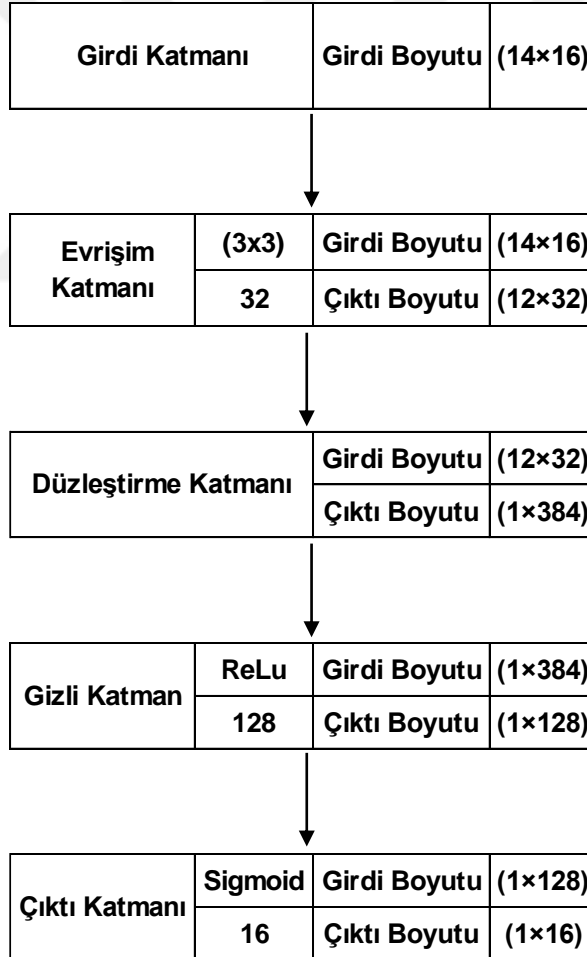
Bu şekilde geliştirilen LSTM modeli, sadece geçmiş seyahat verilerini kullanarak gelecekteki seyahat talebini tahmin etmeyi amaçlamaktadır. Bu tez

çalışmasında geçmiş seyahat verilerini LSTM katmanında, dışsal faktör verilerini ise farklı katmanlarda değerlendiren hibrit modeller de geliştirilmiştir.

3.5.3 CNN modeli

Bu çalışmada geliştirilen modellerden bir tanesi de sadece geçmiş seyahat verileri kullanılarak geliştirilen bir CNN modelidir. Diğer modellerde olduğu gibi 2019 yılına ait tüm verilerle eğitilmiş ve 2020 yılındaki pandemi öncesi döneme kadar olan veriler ile test edilmiştir.

Model, girdi katmanı, evrişim katmanı, düzleştirme katmanı, gizli katman ve çıktı katmanı olmak üzere beş katmandan oluşmaktadır. Geliştirilen modelin mimarisi Şekil 3.9'da gösterilmiştir.



Şekil 3.9 Geliştirilen CNN modeli mimarisi.

Girdi katmanında, her bir istasyon için tahmin edilmek istenen günden önceki 14 günlük normalize edilmiş seyahat verileri kullanılmıştır. Girdi katmanı 16

istasyon için geçmiş 14 günlük verileri iki boyutlu bir matris olarak kabul etmektedir.

Girdi katmanından sonra gelen evrişim katmanında, 32 adet 3×3 'lük bir filtre (tensor) kullanılarak çok boyutlu verilerden öznitelik çıkarma işlemi gerçekleştirilmiştir. Bu filtre ile evrişim katmanı çıktı olarak 12×32 'lik iki boyutlu bir matris oluşturur.

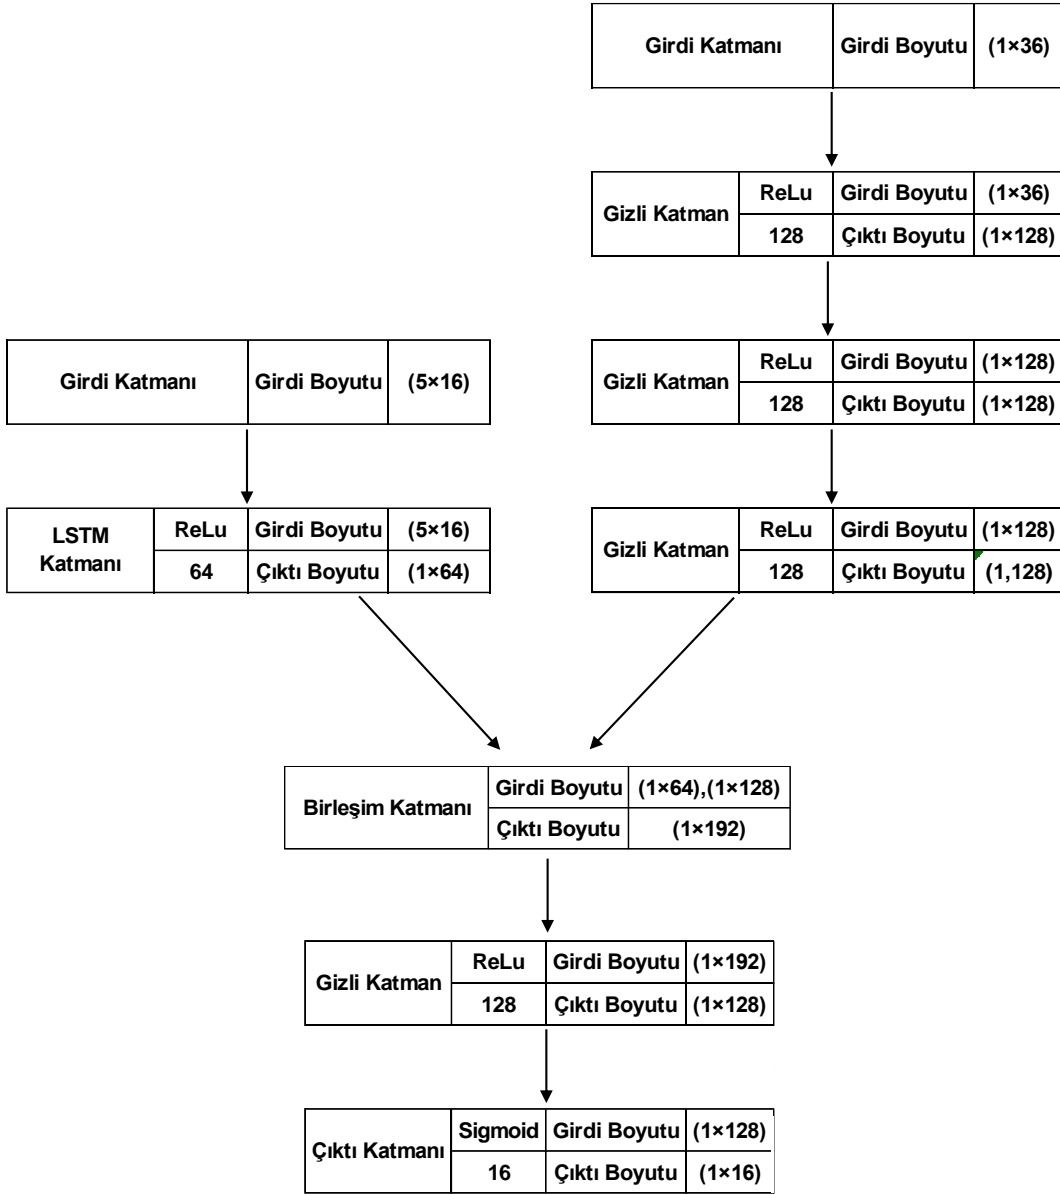
Evrişim katmanından sonra, elde edilen iki boyutlu matrisi tek boyuta indirebilmek için düzleştirme katmanı (flattening layer) kullanılmıştır. Düzleştirme katmanı sayesinde 14×32 boyutundaki veriler 384 elemanlı tek boyutlu bir vektöre dönüştürülmüştür. Daha sonra 384 elemanlı vektör gizli katmana aktarılmıştır. Gizli katmanda her birinde ReLu aktivasyon fonksiyonu olan 128 adet nöron kullanılmıştır. Çıktı katmanında diğer modellerde olduğu gibi her bir istasyon için bir adet olmak üzere, sigmoid aktivasyon fonksiyonu içeren toplam 16 nöron bulunmaktadır.

Optimizasyon algoritması yine olarak “Adam” algoritması, değerlendirme ölçütleri olarak da RMSE, MAE, MAPE ve R kare değerleri kullanılmıştır. Değerlendirme ölçütlerinin sonuçlarına göre model mimarisi ve hiperparametreleri iyileştirilmiştir.

3.5.4 LSTM – ANN hibrit modeli

Bu bölümde metro hattındaki günlük seyahat talebini tahmin etmek için tüm veri seti kullanılarak, yani hem dışsal faktör verileri hem de geçmiş seyahat verileri kullanılarak geliştirilen LSTM – ANN hibrit modeli anlatılmaktadır. Diğer modellerde olduğu gibi 2019 yılına ait tüm verilerle model eğitilmiş ve 2020 yılındaki pandemi öncesi döneme kadar olan veri ile test edilmiştir.

Model, LSTM kolu ve ANN kolu olarak adlandırılan iki ayrı koldan veri alacak şekilde yapılandırılmıştır. Bu sayede, iki farklı veri akışından elde edilen bilgilerin birleştirilerek modelin daha güçlü bir öğrenme performansı elde etmesi hedeflenmiştir. Dolayısıyla model LSTM ve ANN kollarında birer adet girdi katmanı ile başlamaktadır. Geliştirilen modelin mimarisi Şekil 3.10'da gösterilmiştir.



Şekil 3.10 Geliştirilen LSTM – ANN hibrit modeli mimarisi.

LSTM kolunda girdi katmanı ve sonrasında 64 adet LSTM hücresi içeren ve her bir LSTM hücresinde “tanh” aktivasyon fonksiyonu bulunan bir LSTM katmanı bulunmaktadır. LSTM kolu her bir istasyon için tahmin edilmek istenen günden önceki beş günlük normalize edilmiş seyahat verilerini alarak bu verileri 64 elemanlı bir vektöre dönüştürmektedir. Dolayısıyla bu kol girdi olarak 5×16 ’lık iki boyutlu bir matris alırken çıktı olarak 64 elemanlı tek boyutlu bir vektör oluşturmaktadır.

ANN kolu ilk geliştirilen ANN modelinde olduğu gibi dışsal faktör verilerini farklı bir koldan girdi olarak almaktadır. Bu bölümde açıklanan ilk model olan ANN modelinde olduğu gibi nümerik veriler normalize edilerek, kategorik veriler

ise ikili etiket kodlama işleminden geçirilerek bu kola girdi olarak verilmiştir. ANN kolunda girdi katmanından sonra üç adet gizli katman yer almaktadır. 128 nörona sahip olan ilk gizli katman 36 elemanlı girdi vektörünü ReLu aktivasyon fonksiyonu ile işleyerek 128 elemanlı bir vektör üretmektedir. Ardından yine 128 nöron içeren ikinci ve üçüncü gizli katmanlar bir önceki katmanlardan gelen verileri ReLu aktivasyon fonksiyonundan geçirir ve ANN kolu sonunda 128 elemanlı bir vektör oluşturur.

LSTM kolunda işlenen veriler bu kol sonunda 64 elemanlı, ANN kolunda işlenen veriler bu kol sonunda 128 elemanlı vektörler oluşturmaktadır. Bu iki vektör birleşim katmanında 192 elemanlı tek bir vektöre dönüştürülür. Birleşim katmanından sonra, veriler bir gizli katmana aktarılır. Burada yer alan gizli katman modelin lineer olmayan ilişkileri daha iyi öğrenmesine yardımcı olur ve tahmin performansını artırır. Her birinde ReLu aktivasyon fonksiyonu bulunan 128 nöronlu gizli katmanda oluşturulan 128 elemanlı vektör çıktı katmanına iletilir. Metro hattı üzerindeki her bir istasyonu ifade eden 16 nörondan oluşan çıktı katmanı sigmoid aktivasyon fonksiyonu ile tahmin değerlerini üretir.

Diğer modellerde olduğu gibi optimizasyon algoritması olarak “Adam” algoritması, değerlendirme ölçütleri olarak da RMSE, MAE, MAPE ve R kare değerleri kullanılmıştır. Değerlendirme ölçütlerinin sonuçlarına göre model mimarisi ve hiperparametreleri güncellenmiş ve bu bölümde anlatıldığı şekliyle sonuçlandırılmıştır.

Bu hibrit modelde ANN ve LSTM teknikleri bir araya getirilmiştir. LSTM'nin zaman serisi verilerindeki örüntüleri dikkate alarak daha doğru tahminler yapma kabiliyetinden, ANN'nin ise geniş veri işleme kapasitesi ve lineer olmayan ilişkileri öğrenme yeteneğinden aynı anda faydalanılmak istenmiştir. Bu hibrit modelde, ANN ve LSTM'nin avantajları birlikte kullanılarak daha güçlü ve etkili bir tahmin modeli oluşturmak hedeflenmiştir.

3.5.5 LSTM – CNN hibrit modeli

Bu çalışmada geliştirilen son model, metro hattındaki günlük seyahat talebini tahmin etmek amacıyla geçmiş seyahat verileri ve dışsal faktör verileri kullanılarak geliştirilen LSTM – CNN hibrit modelidir. Bu model, geçmiş seyahat verilerini

işlemek için LSTM katmanının, dışsal faktör verilerini işlemek için CNN katmanının kullanıldığı hibrit bir yapıya sahiptir. Modelin eğitim sürecinde, 2019 yılına ait tüm veriler kullanılarak model eğitilmiş ve 2020 yılındaki pandemi öncesi dönem verileri ile test edilmiştir.

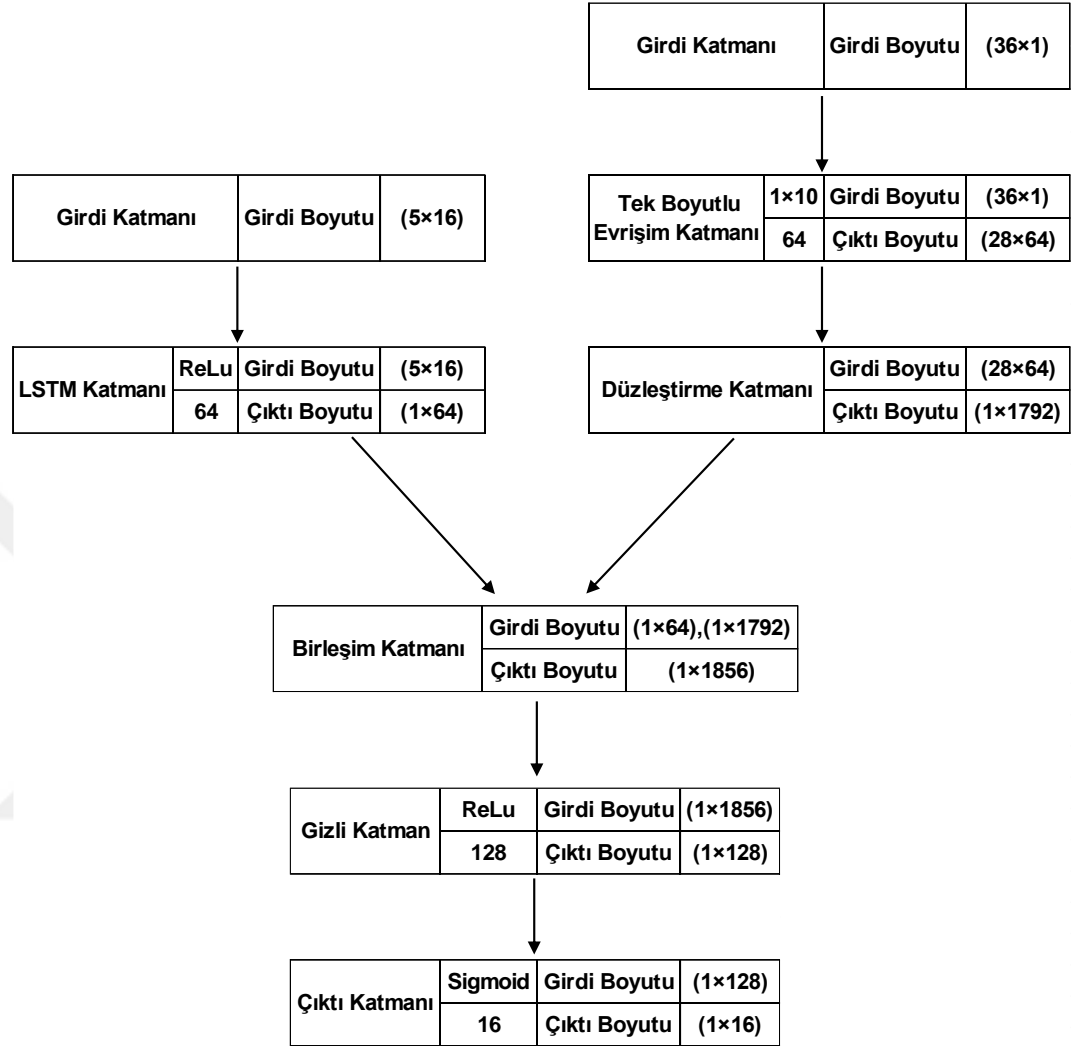
Modelin mimarisi LSTM – ANN hibrit modelinde olduğu gibi iki ayrı koldan oluşmaktadır ve bu kollar LSTM kolu ve CNN kolu olarak adlandırılmıştır. Bu nedenle, modelde iki adet girdi katmanı bulunmaktadır. LSTM kolu, girdi katmanı ile başlamaktadır ve girdi katmanını bir LSTM katmanı takip etmektedir. CNN kolunda ise girdi katmanından sonra tek boyutlu bir evrişim katmanı bulunur. LSTM katmanı girdi olarak bir önceki modelde olduğu gibi her bir istasyon için tahmin edilmek istenen günden önceki beş günlük normalize edilmiş seyahat verilerini alır ve bu koldaki girdi 5×16 'lık bir matristir. CNN katmanı bir önceki modelin ANN kolu ile aynı girdileri alır. Tüm dışsal faktör verilerinin kullanıldığı durumda bu katmandaki girdi 36 elemanlı bir vektördür. Evrişim katmanındaki filtre sayısı 64, filtre boyu ise 10 olarak belirlenmiştir. Geliştirilen modelin mimarisi Şekil 3.11'de verilmiştir.

Modelde LSTM kolu ve CNN kolu çıktılarını birleştiren bir birleşim katmanı bulunur. LSTM kolu çıktısı 64 elemanlı bir vektörken, CNN kolu çıktısı 28×64 elemanlı bir matristir. Bu vektör ve matris birleşim katmanında 1856 elemanlı tek bir vektöre dönüştürülür.

Birleşim katmanından sonra, veriler bir gizli katmana aktarılır. Bu gizli katman modelin doğrusal olmayan ilişkileri daha iyi öğrenmesine yardımcı olur ve tahmin performansını artırır. Gizli katmanın her birinde ReLu aktivasyon fonksiyonu bulunan 128 nöron yer almaktadır ve bu nöronlar 128 elemanlı bir vektörü çıktı katmanına iletir.

Çıktı katmanı, her bir istasyona karşılık gelen 16 adet nöron içerir ve sigmoid aktivasyon fonksiyonu kullanılarak tahmin değerleri üretilir. Modelin eğitimi sırasında, optimizasyon algoritması olarak diğer modellerde olduğu gibi "Adam" algoritması, modelin performans değerlendirmesi için RMSE, MAE, MAPE ve R kare gibi ölçütler kullanılmıştır. Bu ölçütlerin sonuçları modelin tahmin

yeteneğini ve performansını değerlendirmek, model mimarisini ve hiperparametreleri ayarlamak için değerlendirilmiştir.



Şekil 3.11 Geliştirilen LSTM – CNN hibrit modeli mimarisi.

Önerilen modelde geçmiş seyahatlerin verileri LSTM katmanında işlenmiştir. LSTM katmanı, zaman serisi verilerindeki uzun vadeli bağımlılıkları yakalamak ve doğru tahminler yapmak için tasarlanmıştır. LSTM katmanı, seyahat talebi verileri gibi zaman serisi verilerindeki örüntüleri etkili bir şekilde işleyebilmektedir. Zaman serisi verileri işlenerek zaman içinde uzun ve kısa vadeli ilişkilerden anlamlı bilgiler çıkarılabilir. LSTM katmanı, modelin seyahat talebinin tarihsel eğilimlerini ve dinamiklerini anlamasına olanak tanıyarak modeli desteklemiştir.

Önerilen modelde “Ay”, “Hava Durumu”, “Eğitim”, “Tatil” ve “Etkinlik” değişken gruplarından oluşan dışsal faktör verileri CNN katmanında işlenmiştir. CNN tekniği, veriler arasındaki ilişkileri otomatik olarak öğrenme ve çıkarma

konusunda oldukça başarılı olması nedeniyle yukarıda ifade edilen veriler arasındaki ilişkiyi yakalaması amacıyla kullanılmıştır. Bu değişkenlerin seyahat talebini kendi aralarındaki ilişkilere (korelasyona) göre farklı etkileyebilecek olma ihtimali düşünülerek CNN tekniği kullanılmıştır. Örneğin, daha yüksek veya daha düşük seyahat talebiyle ilişkilendirilen haftanın günü değişkeninin talep üzerindeki etkisi, üniversitelerin açık olması durumu ve hava durumu değişkenleri ile ilişkili olarak değişiyor olabilir. CNN katmanının, bu ilişki kombinasyonlarını ve bunların seyahat talebiyle olan ilişkilerini öğrenmesi hedeflenmiştir.

Özetle, CNN katmanının dışsal faktör değişkenlerinin birbirleri ile ilişkilerini dikkate alarak modelin bu değişkenlerin gelecekteki seyahat talebi üzerindeki etkilerini tanımasına yardımcı olması hedeflenmiştir. LSTM katmanının ise zaman serisi verilerinin örüntülerini yakalayıp gelecekteki seyahat talebini tahmin etmek için modelin geçmiş eğilimleri ve dinamikleri anlamasına yardımcı olması planlanmıştır. Bu iki katmanın birleşimiyle, modelin geçmiş seyahat verilerini ve dışsal faktör değişkenlerini etkin bir şekilde kullanarak hedeflenen zamandaki talebi en doğru şekilde tahmin etmesi amaçlanmaktadır.

4. BULGULAR

Bu bölümde, geliştirilen modellerin performanslarının ayrıntılı bir analizine yer verilmiştir. Geliştirilen modeller kullanılarak yapılan talep tahminleri gerçek veriler ile karşılaştırılarak modellerin başarıları değerlendirilmiştir. Bu karşılaştırmada eğitim sürecinde kullanılmayan veriler test verisi olarak kullanılmıştır. Geliştirilen modellerin performansını değerlendirmek için yöntem bölümünde belirtilen değerlendirme ölçütleri kullanılmıştır. Değerlendirme ölçütlerini yorumlarken göz önünde bulundurulması gereken noktalardan birisi de modellerin her eğitimden sonra ağırlıklarının yeniden hesaplanıyor olmasıdır. Bu durumda, hiçbir parametre veya hiperparametre değiştirilmeden, aynı verilerle ve aynı koşullarda eğitilen iki modelin test sonuçları birbirinden farklılık gösterebilmektedir. Ancak, bu farklılığın model performanslarını kıyaslarken herhangi bir yanılgıya sebep olmaması için modeller çok kez eğitilmiş, test edilmiş ve ortalamayı en iyi temsil ettiği düşünülen modellerin değerlendirme ölçütleri bu bölümde sunulmuştur.

Geliştirilen modellerin tahmin başarısını daha iyi yorumlayabilmek adına dikkate alınması gereken bazı önemli noktalar bulunmaktadır. Öncelikle çalışılan M2 metro hattının her bir istasyonundaki günlük ortalama seyahat sayıları birbirinden farklıdır. Bu nedenle, istasyonlar arası tahmin başarısını değerlendirirken MAE ve RMSE ölçütlerinin kullanımı yanılgıya sebep olacaktır. Bu sebepten ötürü istasyonlar arasındaki tahmin başarısını daha doğru bir şekilde değerlendirebilmek adına MAPE ve R kare gibi ölçütlerin kullanılması daha doğru olacaktır. MAPE yüzdesel hatayı ölçtüğü, R kare ise model tahminlerindeki varyansın gerçek değerlerin varyansına ne kadar uyumlu olduğunu ifade ettiği için bu ölçütler daha sağlıklı değerlendirme yapılmasını sağlayacaktır.

Modeller arasındaki tahmin performansını karşılaştırmak amacıyla tüm ölçütler dikkate alınabilir. Ancak, model performansının anlamlandırılması ve yorumlanması için MAPE ve R kare ölçütlerine özellikle odaklanması daha doğru sonuç verecektir.

Model başarısını test etmek için kullanılan 1 Ocak 2020 – 10 Mart 2020 tarihleri arasındaki seyahatlerin istasyon bazında toplam sayıları, günlük ortalama sayıları, standart sapmaları ve varyasyon katsayıları Tablo 4.1’de verilmiştir.

Tablo 4.1 1 Ocak 2020 – 10 Mart 2020 tarihleri arasında M2 metro hattındaki seyahatlerin toplam sayıları, günlük ortalama sayıları, günlük standart sapmaları ve varyasyon katsayıları.

İstasyon	Yenikapı	Vezneciler	Haliç	Şişhane
Toplam Seyahat	4.878.312	1.473.911	849.595	1.752.434
Günlük Ortalama	69.690	21.056	12.137	25.035
Standart Sapma	10.736	5.389	2.038	3.261
Varyasyon Katsayısı	15,4%	25,6%	16,8%	13,0%
İstasyon	Taksim	Osmanbey	Şişli-Mecidiyeköy	Gayrettepe
Toplam Seyahat	2.852.833	3.418.970	4.019.709	2.732.359
Günlük Ortalama	40.755	48.842	57.424	39.034
Standart Sapma	5.188	11.835	8.633	11.553
Varyasyon Katsayısı	12,7%	24,2%	15,0%	29,6%
İstasyon	Levent	4. Levent	Sanayi Mahallesi	İTÜ Ayazağa
Toplam Seyahat	3.086.504	2.269.285	862.081	2.144.409
Günlük Ortalama	44.093	32.418	12.315	30.634
Standart Sapma	10.080	6.608	3.881	13.369
Varyasyon Katsayısı	22,9%	20,4%	31,5%	43,6%
İstasyon	Atatürk Oto Sanayi	Darıüşşafaka	Haciosman	Seyrantepe
Toplam Seyahat	601.360	375.378	1.265.111	530.013
Günlük Ortalama	8.591	5.363	18.073	7.572
Standart Sapma	3.379	1.418	3.605	3.053
Varyasyon Katsayısı	39,3%	26,4%	19,9%	40,3%

Geliştirilen modellerin performanslarını kıyaslamamanın yanı sıra, modellerin performanslarının ortalamalardan ne kadar ayrıştığını incelemek için, seyahat talebinin bir önceki yılın aynı döneminin ortalamalarından ne kadar farklılık gösterdiği incelenmiştir. Ayrıca bahsedilen ortalama seyahat sayısı yöntemi geleneksel toplu taşıma planlamasında sefer sıklıklarını belirlemek için de kullanılmaktadır. Bu amaçla, bir önceki yılın aynı tarih aralığında gerçekleşen seyahatlerin haftanın günlerine göre ortalama değerleri hesaplanmıştır. Seyahat sayılarının bir önceki yıla göre arttığı göz önünde bulundurularak test veri setinde yer alan tarih aralığındaki seyahat sayılarının artış oranı hesaplanmış ve 2019 yılının aynı dönemine ait olan seyahat sayıları 2020 yılına dönüştürülmüştür. Bu adım, geliştirilen modelin, geçmiş yılın ortalama değerlerinin test dönemine dönüştürülmüş haline göre başarısını değerlendirmek için gerçekleştirilmiştir.

Farklı deęişkenlerin model performansına olan etkisini anlamak amacıyla, en başarılı bulunan model, dışsal faktör deęişkenleri arasından belirlenen farklı deęişken kombinasyonları kullanılarak tekrar eğitilip test edilmiştir. Bu adımdaki analizler, hangi deęişkenlerin seyahat talebini ve dolayısıyla modelin tahmin yeteneğini en çok etkilediğini belirlemek için gerçekleştirilmiştir.

Bu bölümde ayrıca, elde edilen sonuçları daha anlaşılır hale getirmek amacıyla bazı istasyonlar için gerçek deęerler ile modellerin tahminlerinin karşılaştırıldığı grafikler sunulmuş ve bu grafikler incelenmiştir. Bu grafikler, modellerin performansının ve gerçekleşen seyahat örüntülerini yakalama başarısının daha kolay bir şekilde deęerlendirilmesine olanak sağlamaktadır.

Özetle bu bölümde, geliştirilen modellerin performansı detaylı olarak incelenmiştir. 1 Ocak 2020 – 10 Mart 2020 tarihleri arasındaki test verileri kullanılarak modellere seyahat sayısı tahmini yaptırılmış, elde edilen tahmin verileri gerçek verilerle karşılaştırılmıştır. Yöntem bölümünde açıklanan deęerlendirme ölçütleri kullanılarak modellerin başarısı analiz edilmiştir. Modellerin performansını kıyaslayan bu analizlere ek olarak, tahmin sonuçlarının geçmiş yılın aynı dönemine ait olan ortalama deęerlere göre ne kadar farklılaştığını gözlemlemek amacıyla geçmiş yılın aynı dönemindeki haftanın günlerine göre seyahat ortalama deęerleri ile kıyaslama yapılmıştır. Ayrıca, farklı deęişken gruplarının model performansı üzerindeki etkilerini anlamak için en başarılı model farklı deęişken kombinasyonları ile tekrar eğitilmiş ve test edilmiştir. Bu bölüm farklı yöntemlerle geliştirilen modellerin performanslarının sunulduğu “Model Performansları” ve deęişkenlerin tahmin başarısındaki etkilerinin incelendiği “Deęişkenlerin Tahmin Modeli Üzerindeki Etkisi” alt başlıkları ile devam etmektedir.

4.1 Model Performansları

Bu bölümde, geliştirilen beş derin öğrenme modelinin tahmin başarıları incelenmiştir. Test veri setinde 1 Ocak 2020 – 10 Mart 2020 tarihleri arasındaki veriler kullanılmıştır. Model tahminlerinin ortalamalardan ne kadar ayrıştığını deęerlendirmek amacıyla, bir önceki senenin aynı dönemine karşılık gelen 1 Ocak 2019 – 10 Mart 2019 tarihleri arasındaki seyahatlerin haftanın günlerine göre

ortalamları bulunmuştur. Çalışılan metro hattında 1 Ocak 2019 – 10 Mart 2019 tarihleri arasında toplam 30.323.516 seyahat, 1 Ocak 2020 – 10 Mart 2020 tarihleri arasında toplam 33.112.264 seyahat gerçekleşmiştir. Belirtilen dönemler arasındaki seyahat artış oranı %9,2'dir. Hesaplanan seyahat artış oranı ile, belirtilen dönem için 2019 yılındaki haftanın günlerine göre hesaplanan ortalama seyahat sayılarının 2020 yılındaki projeksiyonu elde edilmiştir. Bu yöntem ile yapılan tahminler de geliştirilen modellerin tahminleri ile karşılaştırılarak seyahat sayılarının ortalamadan ne kadar farklılaştığı ve modellerin seyahat sayılarını ortalama göre ne kadar iyi tahmin edildiği incelenmiştir.

Bu bölümde sonuçları paylaşılmış olan modellerde “Ay” değişkeni kullanılmamıştır. “Ay” değişkeni modele eklendiğinde model başarısının belirgin ölçüde düştüğü görülmüştür. “Ay” değişkeninin dahil edildiği modellerin sonuçları “Değişkenlerin Tahmin Modeli Üzerindeki Etkisi” bölümünde paylaşılmış, “Ay” değişkeninin modele olan olumsuz etkisi ise “Tartışma” bölümünde detaylıca ele alınmıştır.

Bu bölümde aşağıda belirtilen modellerin değerlendirme ölçütleri Tablo 4.2’de paylaşılmıştır.

- “Hava Durumu”, “Haftanın Günü”, “Tatil”, “Eğitim” ve “Etkinlik” değişkenleri kullanılarak geliştirilen ANN modeli,
- Geçmiş 14 günlük seyahat verileri kullanılarak geliştirilen LSTM modeli.
- Geçmiş 14 günlük seyahat verileri kullanılarak geliştirilen CNN modeli.
- “Hava Durumu”, “Haftanın Günü”, “Tatil”, “Eğitim” ve “Etkinlik” değişkenleri ve geçmiş beş günlük seyahat verileri kullanılarak geliştirilen LSTM-ANN hibrit modeli,
- “Hava Durumu”, “Haftanın Günü”, “Tatil”, “Eğitim” ve “Etkinlik” değişkenleri ve geçmiş beş günlük seyahat verileri kullanılarak geliştirilen LSTM-CNN hibrit modeli.

Sadece geçmiş seyahat verileri veya sadece “Hava Durumu”, “Haftanın Günü”, “Tatil”, “Eğitim” ve “Etkinlik” değişkenleri kullanılarak geliştirilen modellerin, ortalama değerler kullanılarak geliştirilen modellere kıyasla belirgin derecede başarılı olamadığı gözlemlenmektedir. “Hava Durumu”,

“Haftanın Günü”, “Tatil”, “Eğitim” ve “Etkinlik” değişkenleri, geçmiş beş günlük seyahat verileri ile birleştirildiğinde ise modellerin performanslarının belirgin derecede arttığı ve geliştirilen LSTM – CNN ve LSTM – ANN hibrit modellerinin en iyi performansı sergilediği görülmüştür.

Tablo 4.2 Geliştirilen modellerin ve geçmiş yıl dönem ortalamasının gerçek değerler ile karşılaştırılması sonucu elde edilen değerlendirme ölçütlerinin sonuçları.

Model Adı	MAE	RMSE	MAPE	R kare
2019 Yılı Dönem Ortalaması	3345	5222	%12,5	0,47
2020 Yılına Projekte Edilmiş 2019 Yılı Dönem Ortalaması	2493	4218	%10,6	0,63
LSTM Modeli	1886	3600	%9,4	0,64
ANN Modeli	2525	4223	%8,9	0,62
CNN Modeli	1737	3431	%8,8	0,66
LSTM – CNN Hibrit Modeli	1476	2350	%6,4	0,85
LSTM – ANN Hibrit Modeli	1225	2076	%5,3	0,86

Tablo 4.2’de verilen değerler M2 metro hattının tüm istasyonları için ayrı ayrı günlük olarak yapılan tahminler ve gerçek seyahat sayıları kullanılarak hesaplanmıştır. Metro hattının her bir istasyonu için yapılan günlük tahminlerin genel başarısını ifade ettiği için, bu ölçütler modellerin metro hattının geneli üzerindeki ortalama başarısını göstermektedir. Ancak, modeller bazı istasyonlarda genele kıyasla çok daha iyi, bazı istasyonlarda ise daha kötü sonuçlar ortaya koymuştur. Geliştirilen beş modelin ve 2020 yılına projekte edilmiş 2019 yılı aynı dönem verilerinin gerçek seyahat sayıları karşısındaki istasyon bazındaki değerlendirme ölçütleri LSTM – ANN ve LSTM – CNN hibrit modelleri için Tablo 4.3’te, LSTM ve CNN modelleri için Tablo 4.4’te, ANN modeli için Tablo 4.5’te verilmiştir.

Daha derinlemesine yapılan bir değerlendirme sonucunda özellikle Taksim istasyonunda gerçekleşen seyahat sayılarının test seti içerisinde yer alan 1 Ocak 2020 ve 8 Mart 2020 tarihlerinde modellerin tahmin ettiği değerden çok fazla farklılaştığı görülmüştür. 1 Ocak 2020 günü resmî tatil olduğu için bu tarihte gerçekleşen seyahatleri etkileyen değişkenlerden birisi “Tatil” değişkenidir. Ancak, yılbaşı tatili dışındaki diğer tatiller genellikle seyahat talebini düşürürken, yılbaşı tatilinin İstanbul’un en önemli cazibe merkezlerinden olan İstiklal Caddesi’ne olan ulaşım talebini artırdığı, dolayısıyla bu caddeye ulaşım için kullanılan iki istasyon olan Şişhane ve Taksim istasyonlarındaki talebin arttığı, ancak geliştirilen

modellerin bu ayrımı yapma konusunda başarısız olduğu görülmüştür. Bu durumun olası sebeplerine tartışma bölümünde değinilmiştir.

Tablo 4.3 LSTM – ANN ve LSTM – CNN Hibrit modellerinin değerlendirme ölçütleri.

İstasyon	LSTM – ANN Hibrit Modeli				LSTM – CNN Hibrit Modeli			
	MAE	RMSE	MAPE	R kare	MAE	RMSE	MAPE	R kare
Yenikapı	2782	3683	%4,1	0,88	4280	5080	%6,3	0,78
Vezneciler	1155	1479	%5,8	0,92	1146	1402	%6,1	0,93
Haliç	880	1210	%7,7	0,65	1002	1340	%9,1	0,57
Şişhane	1283	1628	%5,3	0,75	1066	1294	%4,4	0,84
Taksim	2842	5127	%9,9	0,02	2621	4691	%9,6	0,18
Osmanbey	1366	1856	%3,5	0,98	1633	2149	%4,3	0,97
Şişli-Mecidiyeköy	1317	1619	%2,4	0,96	2216	2689	%4,1	0,90
Gayrettepe	1335	1743	%4,0	0,98	1776	2179	%5,3	0,96
Levent	1522	1980	%3,6	0,96	1769	2278	%4,3	0,95
4. Levent	894	1162	%3,0	0,97	1073	1381	%3,7	0,96
Sanayi Mahallesi	477	614	%4,3	0,97	498	657	%4,3	0,97
İTÜ-Ayazağa	1890	2412	%9,5	0,97	2316	2912	%11,0	0,95
Atatürk Oto Sanayi	589	743	%7,7	0,95	632	797	%8,1	0,94
Darüşşafaka	245	304	%5,4	0,95	379	482	%9,3	0,88
Hacıosman	477	620	%3,0	0,97	690	1111	%4,7	0,91
Seyrantepe	552	1088	%6,3	0,87	520	665	%7,3	0,95
Tüm Hat	1225	2076	%5,3	0,86	1476	2350	%6,4	0,85

Tablo 4.4 LSTM ve CNN modellerinin istasyon bazlı değerlendirme ölçütleri.

İstasyon	LSTM Modeli				CNN Modeli			
	MAE	RMSE	MAPE	R kare	MAE	RMSE	MAPE	R kare
Yenikapı	4368	6285	%6,8	0,66	2982	5159	%4,7	0,77
Vezneciler	2125	2972	%11,3	0,70	1390	2326	%7,1	0,81
Haliç	1408	1850	%13,1	0,18	1405	1872	%13,0	0,16
Şişhane	1486	1908	%6,2	0,66	1390	1783	%5,8	0,70
Taksim	2726	4681	%10,0	0,19	2548	4487	%9,4	0,25
Osmanbey	2074	4319	%5,7	0,87	2122	4435	%5,8	0,86
Şişli-Mecidiyeköy	1908	3522	%3,7	0,83	1827	3529	%3,6	0,83
Gayrettepe	2143	4395	%7,6	0,86	2274	4486	%8,1	0,85
Levent	2331	4061	%5,8	0,84	2617	4183	%6,7	0,83
4. Levent	1525	2738	%5,3	0,83	1728	2820	%6,1	0,82
Sanayi Mahallesi	759	1505	%8,8	0,85	687	1442	%8,3	0,86
İTÜ-Ayazağa	3384	5936	%18,0	0,80	3036	5616	%16,7	0,82
Atatürk Oto Sanayi	1025	1547	%17,2	0,79	786	1344	%14,4	0,84
Darüşşafaka	500	747	%11,7	0,72	411	702	%9,3	0,76
Hacıosman	1065	1797	%7,1	0,75	920	1664	%6,1	0,79
Seyrantepe	1356	3465	%11,9	-0,29	1660	3624	%15,8	-0,41
Tüm Hat	1886	3600	%9,4	0,64	1737	3431	%8,8	0,66


Tablo 4.5 ANN Modelinin ve 2020 yılına projekte edilmiş 2019 yılı dönem ortalamalarının istasyon bazlı değerlendirme ölçütleri.

İstasyon	ANN Modeli				2020 Yılına Projekte Edilmiş 2019 Yılı Dönem Ortalamaları			
	MAE	RMSE	MAPE	R kare	MAE	RMSE	MAPE	R kare
Yenikapı	11367	12494	%16,5	-0,35	9287	10004	%13,2	0,13
Vezneciler	1863	2521	%8,7	0,78	2581	3193	%12,1	0,65
Haliç	1210	1595	%10,3	0,39	1287	1690	%11,6	0,31
Şişhane	2845	3403	%12,0	-0,09	1417	1840	%6,1	0,68
Taksim	4204	6668	%13,0	-0,65	3152	4526	%10,4	0,24
Osmanbey	3160	3859	%7,7	0,89	2476	4685	%6,3	0,84
Şişli-Mecidiyeköy	2139	2743	%3,9	0,90	3199	4643	%5,9	0,71
Gayrettepe	2057	2593	%6,0	0,95	2840	4965	%9,1	0,82
Levent	2795	3308	%6,5	0,89	2174	3695	%5,5	0,87
4. Levent	1888	2203	%6,3	0,89	1717	2860	%5,9	0,81
Sanayi Mahallesi	976	1116	%8,7	0,92	729	1397	%8,3	0,87
İTÜ-Ayazağa	3121	3679	%12,5	0,92	4853	6427	%21,9	0,77
Atatürk Oto Sanayi	838	1059	%11,0	0,90	681	1205	%12,3	0,87
Darüşşafaka	246	319	%5,4	0,95	474	775	%11,0	0,70
Hacıosman	916	1122	%5,6	0,90	1138	1740	%7,3	0,77
Seyrantepe	774	1442	%8,4	0,78	1882	3048	%23,5	0,00
Tüm Hat	2525	4223	%8,9	0,62	2493	4218	%10,6	0,63

8 Mart 2020 tarihinde ise geliştirilen tüm modellerde Taksim istasyonu için yapılan tahminlerin gerçekleşen seyahat sayısının oldukça üzerinde olduğu görülmüştür. Bunun sebebi araştırıldığında ise İstanbul Valiliği'nin kararı ile M2 metro hattının Taksim istasyonunun tamamının, Şişhane istasyonunun İstiklal caddesi giriş – çıkışlarının ve F1 Taksim-Kabataş Füniküler hattının yolcu alımına kapatıldığı haberine ulaşılmıştır (Euronews, 2020). Değerlendirme ölçütlerine göre M2 metro hattının bütünü için en iyi sonuçları veren LSTM – ANN Hibrit modelinin Taksim istasyonu için yapmış olduğu tahminler ve gerçekleşen seyahat sayılarının karşılaştırıldığı grafik Şekil 4.1'de gösterilmiştir. Bu grafikte 1 Ocak 2020 ve 8 Mart 2020 tarihlerindeki sapmalar açıkça görülmektedir. Aykırı değer olarak nitelendirilebilecek bu iki tarih test veri setinden çıkarılarak değerlendirme ölçütleri yeniden hesaplanmıştır (Tablo 4.6).

Tablo 4.6 1 Ocak ve 8 Mart etkilerinden arındırılmış test veri seti ile yapılan tahminlerin değerlendirme ölçütleri.

Model Adı	1 Ocak etkisinden arındırılmış test veri seti				1 Ocak ve 8 Mart etkilerinden arındırılmış test veri seti			
	MAE	RMSE	MAPE	R kare	MAE	RMSE	MAPE	R kare
2019 Yılı Dönem Ortalaması	3205	4905	%10,9	0.50	3170	4843	%10,7	0.47
2020 yılına Projekte Edilmiş 2019 Yılı Dönem Ortalaması	2307	3625	%8,8	0.69	2288	3548	%8,6	0.67
ANN Modeli	2492	4094	%8,6	0,66	2517	4085	%8,5	0,58
LSTM Modeli	1662	2631	%7,3	0,72	1652	2514	%7,1	0,72
CNN Modeli	1512	2395	%6,8	0,74	1507	2275	%6,5	0,74
LSTM-CNN Hibrit Modeli	1436	2259	%6,0	0,86	1412	2101	%5,7	0,87
LSTM-ANN Hibrit Modeli	1198	1935	%5,2	0,88	1176	1767	%4,9	0,88



Şekil 4.1 LSTM – ANN Hibrit Modelinin Taksim istasyonu için yaptığı tahminler ile gerçek seyahat sayılarının karşılaştırılması.

4.2 Değişkenlerin Tahmin Modeli Üzerindeki Etkisi

Bir önceki bölümde gösterilen değerlendirme ölçütlerine göre LSTM – ANN hibrit modelinin en başarılı tahmin sonuçlarını ürettiği görülmüştür. Bundan dolayı, değişkenlerin model üzerindeki etkisi LSTM – ANN hibrit modeli üzerinden incelenecektir. Bu bölümde “Ay”, “Hava Durumu”, “Eğitim”, “Tatil” ve “Etkinlik” değişkenleri teker teker geliştirilen modelden çıkarılarak bu değişkenlerin modelin tahmin performansı üzerindeki etkisi ayrı ayrı incelenmiştir. “Haftanın Günü”

değişkeninin seyahat talebi üzerinde doğrudan etkisi olduğu bilindiği için bu değişken tahmin modelinden çıkarılarak bir değerlendirme yapılmamıştır.

4.2.1 Ay değişkeninin model başarısına etkisi

Bu bölümde "Ay" değişkeninin model başarısına etkisi incelenmiştir. Daha önce belirtildiği üzere, bu değişkenin kullanıldığı modellerin tahmin performansının oldukça düşük olduğu gözlemlenmiştir. “Hava Durumu”, “Haftanın Günü”, “Ay”, “Tatil”, “Eğitim” ve “Etkinlik” değişkenleri kullanılarak geliştirilen LSTM – ANN hibrit modeli, test veri setindeki verilerle değerlendirildiğinde zayıf bir performans sergilerken, eğitim verileri ile değerlendirildiğinde oldukça başarılı sonuçlar sunmaktadır (Tablo 4.7).

Tablo 4.7 “Hava Durumu”, “Haftanın Günü”, “Ay”, “Tatil”, “Eğitim” ve “Etkinlik” değişkenleri kullanılarak geliştirilen LSTM - ANN hibrit modelinin değerlendirme ölçütleri.

İstasyon	MAE	RMSE	MAPE	R kare
Yenikapı	13023	13781	%18,5	-0,65
Vezneciler	2694	3240	%12,2	0,64
Haliç	1129	1363	%9,5	0,55
Şişhane	2736	2989	%11,4	0,16
Taksim	3235	5313	%10,6	-0,05
Osmanbey	3301	3759	%8,1	0,90
Şişli-Mecidiyeköy	3164	3480	%5,5	0,84
Gayrettepe	2068	2486	%6,2	0,95
Levent	3816	4232	%8,6	0,82
4. Levent	2255	2482	%7,2	0,86
Sanayi Mahallesi	1148	1233	%9,9	0,90
İTÜ-Ayazağa	3585	4152	%13,4	0,90
Atatürk Oto Sanayi	1114	1315	%13,3	0,85
Darüşşafaka	266	329	%5,9	0,95
Haciosman	1121	1259	%6,5	0,88
Seyrantepe	766	993	%9,9	0,89
Tüm Hat (Test Verisi)	2839	4466	%9,8	0,65
Tüm Hat (Eğitim Verisi)	693	1236	%6,9	0,97

Bu durum, ay değişkeninin modeli aşırı uyum (overfitting) sorununa sürüklediğinin bir işareti olarak yorumlanabilir. Aşırı uyum sorunu, modelin eğitim verilerine aşırı derecede uyum sağlaması sonucu yeni verilere genelleme yapma yeteneğini kaybetmesine neden olur. Bu durum, modelin daha önce hiç görmediği, gelecek zaman verileri üzerindeki tahmin yeteneğini olumsuz yönde etkilemektedir.

Ayrıca, bu durumun nedenleri ve olası çözüm önerileri tartışma bölümünde daha detaylı bir şekilde ele alınmıştır.

4.2.2 Hava durumu değişkenlerinin model başarısına etkisi

Ortalama hava sıcaklığı, yağış miktarı ve rüzgâr hızı verilerinden oluşan “Hava Durumu” değişkenlerinin model performansına olan etkisini değerlendirmek için LSTM – ANN hibrit hodel “Hava Durumu” değişkenlerinin etkisi olmaksızın “Haftanın Günü”, “Tatil”, “Eğitim” ve “Etkinlik” değişkenleri kullanılarak tekrar eğitilmiş ve test edilmiştir. “Hava Durumu” değişkenleri dahil edilerek ve edilmeyerek eğitilen modellerin tahminlerinin değerlendirme ölçütleri Tablo 4.8’de verilmiştir.

Tablo 4.8 “Hava Durumu” değişkenleri dahil edilerek ve edilmeyerek eğitilen modellerin test sonuçlarının değerlendirme ölçütleri.

İstasyon	Hava Durumu, Haftanın Günü, Tatil, Eğitim ve Etkinlik Değişkenleri ile Eğitilen Model				Haftanın Günü, Tatil, Eğitim ve Etkinlik Değişkenleri ile Eğitilen Model			
	MAE	RMSE	MAPE	R kare	MAE	RMSE	MAPE	R kare
Yenikapı	2782	3683	%4,1	0,88	3280	4205	%4,8	0,85
Vezneciler	1155	1479	%5,8	0,92	1217	1516	%6,1	0,92
Haliç	880	1210	%7,7	0,65	1384	1889	%12,3	0,14
Şişhane	1283	1628	%5,3	0,75	1253	1583	%5,2	0,76
Taksim	2842	5127	%9,9	0,02	3248	5430	%11,2	-0,10
Osmanbey	1366	1856	%3,5	0,98	1525	1929	%4,0	0,97
Şişli-Mecidiyeköy	1317	1619	%2,4	0,96	1428	1909	%2,6	0,95
Gayrettepe	1335	1743	%4,0	0,98	1388	1867	%4,2	0,97
Levent	1522	1980	%3,6	0,96	1755	2264	%4,0	0,95
4. Levent	894	1162	%3,0	0,97	970	1276	%3,1	0,96
Sanayi Mahallesi	477	614	%4,3	0,97	453	576	%4,1	0,98
İTÜ-Ayazağa	1890	2412	%9,5	0,97	1844	2364	%7,7	0,97
Atatürk Oto Sanayi	589	743	%7,7	0,95	646	817	%7,8	0,94
Darıüşşafaka	245	304	%5,4	0,95	262	315	%5,6	0,95
Haciosman	477	620	%3,0	0,97	808	1152	%5,4	0,90
Seyrantepe	552	1088	%6,3	0,87	560	890	%6,6	0,91
Tüm Hat	1225	2076	%5,3	0,86	1376	2263	%5,9	0,81

Yukarıda verilen değerlendirme ölçütleri incelendiğinde “Hava Durumu” değişkeninin hemen hemen bütün istasyonlarda modelin tahmin performansını iyileştirdiği görülmüştür. Tüm hat değerlendirmesinde ise R kare değerinin

0,81'den 0,86'ya arttığı, MAPE değerini %5,9'dan %5,3'e indiği, MAE ve RMSE değerlerini azaldığı görülmüştür.

4.2.3 Eğitim değişkenlerinin model başarısına etkisi

Millî Eğitim Bakanlığı'na bağlı okulların ve bölgede bulunan üniversitelerin (İstanbul Üniversitesi, İstanbul Teknik Üniversitesi ve Boğaziçi Üniversitesi) eğitim döneminde olup olmamasını ifade eden "Eğitim" değişkenlerinin model tahmin başarısına olan etkisi, "Haftanın Günü", "Tatil", "Eğitim" ve "Etkinlik" değişkenleri ile eğitilen modelden "Eğitim" değişkenlerinin çıkarılması ile geliştirilen model ile test edilmiştir. Sadece "Haftanın Günü", "Tatil" ve "Etkinlik" değişkenleri ile eğitilen modelin istasyon bazlı değerlendirme ölçütleri Tablo 4.9'da gösterilmiş ve "Eğitim" değişkenlerinin dahil olduğu modelin sonuçları ile kıyaslanmıştır.

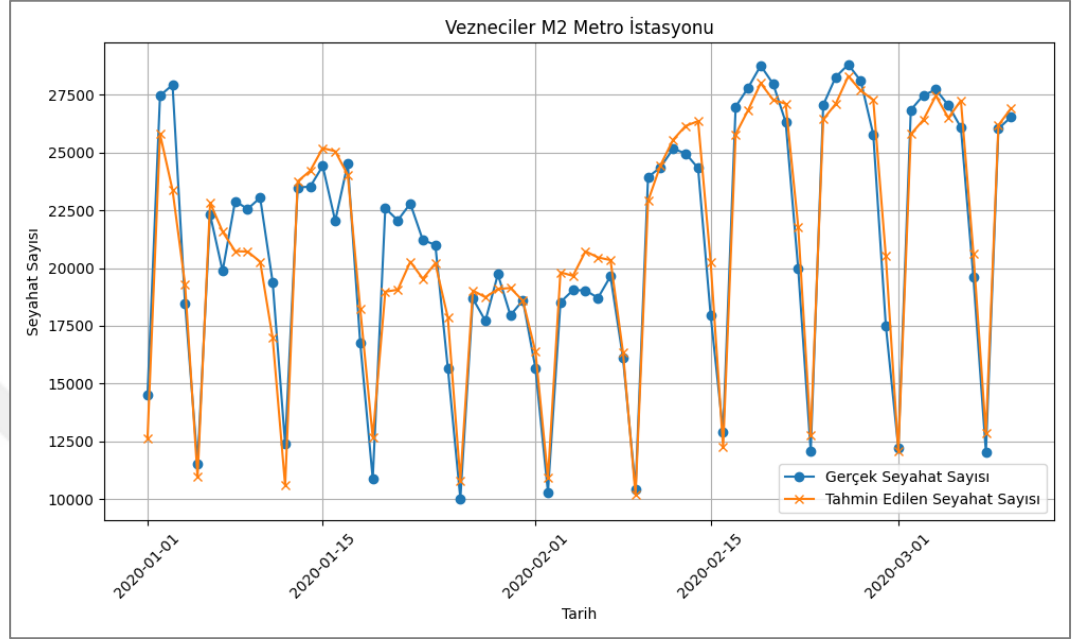
Tablo 4.9 "Eğitim" değişkenleri dahil edilerek ve edilmeyerek geliştirilen modellerin test sonuçlarının değerlendirme ölçütleri.

İstasyon	Haftanın Günü, Tatil, Eğitim, Etkinlik Değişkenleri ile Eğitilen Model				Haftanın Günü, Tatil, Etkinlik Değişkenleri ile Eğitilen Model			
	MAE	RMS E	MAP E	R kare	MAE	RMS E	MAP E	R kare
Yenikapı	3280	4205	%4,8	0,85	3328	4422	%5,3	0,83
Vezneciler	1217	1516	%6,1	0,92	2161	2623	%11,7	0,76
Haliç	1384	1889	%12,3	0,14	1546	2101	%14,7	-0,06
Şişhane	1253	1583	%5,2	0,76	1327	1831	%5,7	0,68
Taksim	3248	5430	%11,2	-0,10	2951	5314	%10,6	-0,05
Osmanbey	1525	1929	%4,0	0,97	2134	2823	%5,7	0,94
Şişli-Mecidiyeköy	1428	1909	%2,6	0,95	1770	2306	%3,3	0,93
Gayrettepe	1388	1867	%4,2	0,97	1804	2297	%5,6	0,96
Levent	1755	2264	%4,0	0,95	1994	2496	%4,8	0,94
4. Levent	970	1276	%3,1	0,96	1363	1697	%4,5	0,93
Sanayi Mahallesi	453	576	%4,1	0,98	566	722	%5,1	0,97
İTÜ-Ayazağa	1844	2364	%7,7	0,97	3067	4050	%15,7	0,91
Atatürk Oto Sanayi	646	817	%7,8	0,94	674	819	%9,3	0,94
Darüşşafaka	262	315	%5,6	0,95	385	476	%8,3	0,89
Haciosman	808	1152	%5,4	0,90	1087	1485	%7,4	0,83
Seyrantepe	560	890	%6,6	0,91	511	1116	%5,2	0,87
Tüm Hat	1376	2263	%5,9	0,81	1667	2639	%7,7	0,77


Tablo 4.9’da görüldüğü gibi “Eğitim” değişkenlerinin dahil olduğu model istasyonların genelinde ve tüm hat değerlendirmesinde “Eğitim” değişkenlerinin dahil olmadığı modele göre oldukça başarılı sonuçlar ortaya koymuştur. “Eğitim” değişkenlerinin modele eklenmesi ile gözlemlenen en belirgin iyileşmeler İstanbul Üniversitesi Beyazıt Yerleşkesi’ne ulaşımın sağlandığı Vezneciler istasyonunda ve İstanbul Teknik Üniversitesi Ayazağa Kampüsü’ne ulaşımın sağlandığı İTÜ – Ayazağa istasyonunda olmuştur. Vezneciler istasyonu için yapılan tahminlerin R kare değeri 0,76’dan 0,92’ye çıkarken, MAPE değeri %11,7’den %6,1’e gerileyerek kayda değer bir iyileşme göstermiştir. Öte yandan, İTÜ – Ayazağa istasyonunun değerlendirme ölçütlerine bakıldığında R kare değeri 0,91’den 0,97’ye çıkarken MAPE değeri %15,7’den %7,7’ye gerilemiştir. “Eğitim” değişkenleri dahil edilerek ve edilmeden geliştirilen modeller ile Vezneciler istasyonu için yapılan tahminlerin gerçek seyahat sayıları ile ilişkilerinin grafikleri Şekil 4.2 ve 4.3’te gösterilmiştir. Aynı şekilde İTÜ – Ayazağa istasyonu için yapılan tahminlerin gerçek seyahat sayıları ile ilişkilerinin grafikleri de Şekil 4.4 ve 4.5’te gösterilmiştir.

İstanbul Üniversitesi 2019 – 2020 akademik takvimine göre güz dönemi yarıyıl sonu bütünleme sınavları bitiş tarihi 24 Ocak 2020’dir. İstanbul Teknik Üniversitesi’nin 2019 – 2020 akademik takvimine göre de bu tarih 17 Ocak 2020’dir. Her iki üniversitenin akademik takvimlerine göre de bahar yarıyılı 10 Şubat 2020 tarihinde başlamıştır. Dolayısıyla eğitim veri setindeki tarih aralığı içerisindeki iki haftada İstanbul Üniversitesi, üç haftada ise İstanbul Teknik Üniversitesi aktif eğitim döneminde değildir. Şekil 4.2 ve 4.3’e bakıldığında, “Eğitim” değişkenlerinin dahil edildiği modelin Vezneciler istasyonu için tahminlerini gösteren Şekil 4.2’deki tahmin edilen seyahat sayısı örüntüsünün Şekil 4.3’teki örüntüye göre gerçek seyahat sayılarına çok daha uyumlu olduğu görülmektedir. Benzer şekilde İTÜ – Ayazağa istasyonu için de Şekil 4.4’te görülen tahmin edilen seyahat sayısı örüntüsü, Şekil 4.5’tekine göre gerçek değerlere daha çok uyumludur. Özellikle bu üniversitelerin eğitim döneminde olmadıkları aralıklara bakıldığında, “Eğitim” değişkenleri dahil edilerek eğitilen modelin bu dönem aralığında daha düşük seyreden seyahat sayılarını çok daha başarılı bir şekilde tahmin ettiği gözlemlenmiştir. Şekil 4.3 ve Şekil 4.5’e bakıldığında, “Eğitim” değişkenleri dahil edilmeden eğitilen modellerden elde edilen

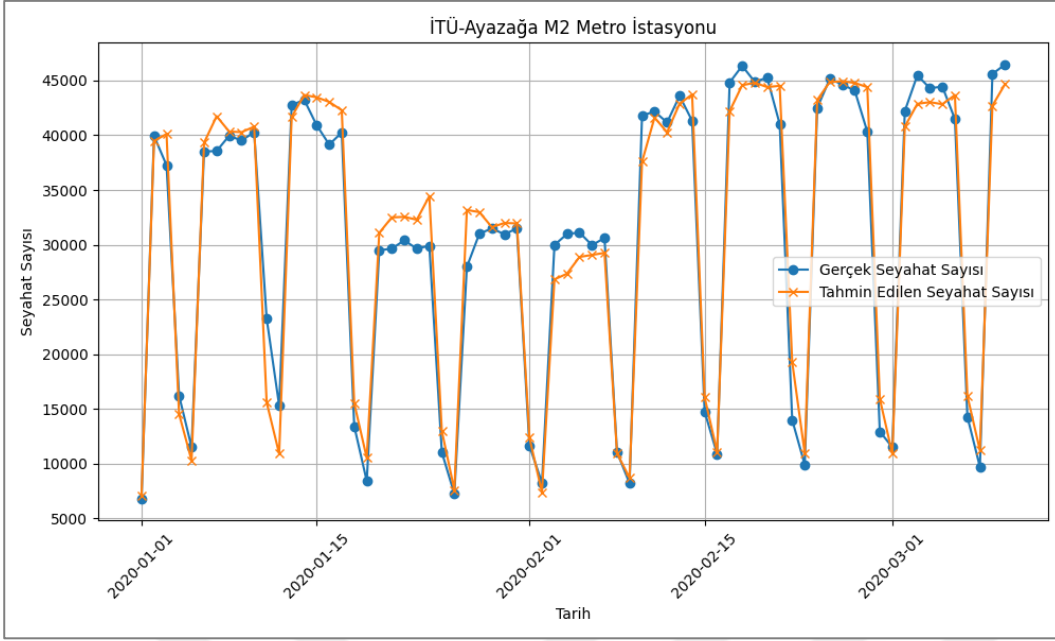
tahminlerin, üniversite tatilinin ikinci haftasından itibaren gerçeğe yaklaştığı görülmektedir. Bunun sebebi olarak LSTM modelinin geçmiş seyahat sayıları arasındaki örüntüleri yakalamasıyla ilk tatil haftasının sonunda düşük seyahat sayısı örüntüsünü öğrenerek tatilin ikinci haftasını daha doğru tahmin ettiği söylenebilir.



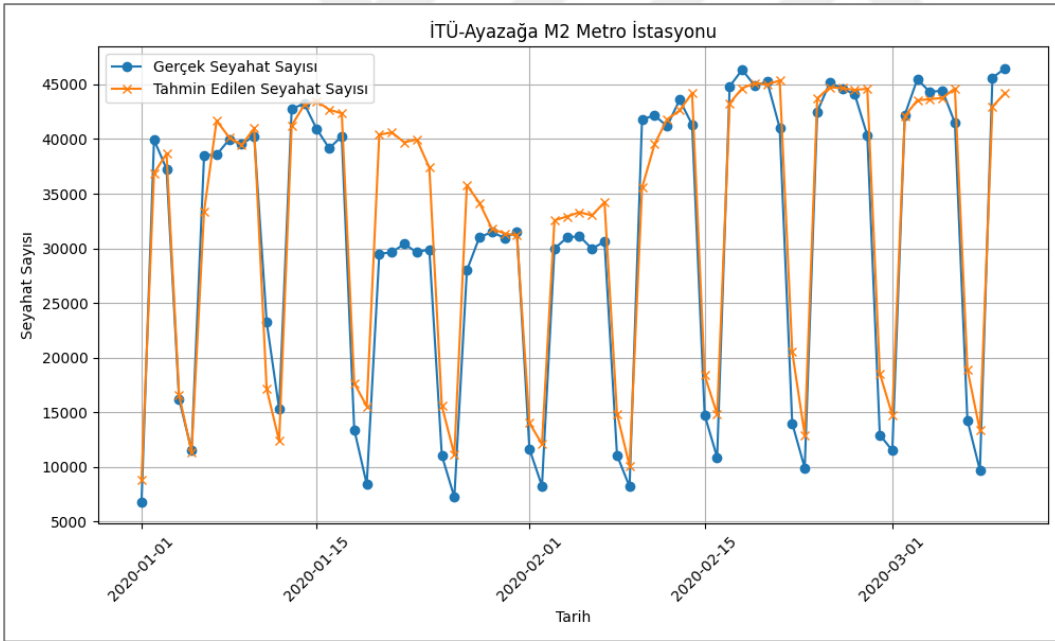
Şekil 4.2 “Haftanın Günü”, “Tatil”, “Eğitim” ve “Etkinlik” değişkenleri ile eğitilen LSTM – ANN hibrit modelinin Vezneciler istasyonu için yaptığı tahminler ile gerçek seyahat sayılarının karşılaştırılması.



Şekil 4.3 “Haftanın Günü”, “Tatil” ve “Etkinlik” değişkenleri ile eğitilen LSTM – ANN hibrit modelinin Vezneciler istasyonu için yaptığı tahminler ile gerçek seyahat sayılarının karşılaştırılması.



Şekil 4.4 “Haftanın Günü”, “Tatil”, “Eğitim” ve “Etkinlik” değişkenleri ile eğitilen LSTM – ANN hibrit modelinin İTÜ – Ayazağa istasyonu için yaptığı tahminler ile gerçek seyahat sayılarının karşılaştırılması.



Şekil 4.5 “Haftanın Günü”, “Tatil” ve “Etkinlik” değişkenleri ile eğitilen LSTM – ANN hibrit modelinin İTÜ – Ayazağa istasyonu için yaptığı tahminler ile gerçek seyahat sayılarının karşılaştırılması.

Daha önce belirtildiği gibi, “Eğitim” değişkenleri arasında Boğaziçi Üniversitesi’nin eğitim döneminde olup olmaması da yer almaktadır. M2 metro hattı güzergâhındaki Levent istasyonundan M6 metro hattına aktarma yapılarak Boğaziçi Üniversitesi’ne ulaşılmaktadır. Ancak model tahminleri incelendiğinde ne

değerlendirme ölçütlerinde ne de Levent istasyonunun seyahat örüntüsünde dikkate değer bir iyileşme gözlenmemiştir.

4.2.4 Tatil değişkenlerinin model başarısına etkisi

Ülkemizde yıl boyunca bayramlar ve çeşitli özel günler nedeniyle bazı günler resmî tatil ilan edilmektedir. Bu gibi resmî tatil günlerinin iş günü olmaması, bu günlerde gerçekleştirilen kutlamaların ve ritüellerin bulunması insanların seyahat alışkanlıklarını etkilemektedir. Pandemi kısıtı sebebiyle sadece 1 Ocak 2020 ile 10 Mart 2020 günleri arasındaki tarihlerin test edilebilmesi nedeniyle, bu çalışmada etkisi gözlemlenebilen tek resmî tatil 1 Ocak 2020 tarihindeki yılbaşı günü olmuştur. Resmî tatil değişkeninin model başarısına etkisini gözlemek adına “Haftanın Günü”, “Tatil” ve “Etkinlik” değişkenleri kullanılarak geliştirilen model ile “Haftanın Günü” ve “Etkinlik” değişkenleri kullanılarak geliştirilen modelin değerlendirme ölçütleri karşılaştırılmış ve Tablo 4.10’da verilmiştir.

Tablo 4.10 “Tatil” değişkeni dahil edilerek ve edilmeyerek eğitilen modellerin test sonuçlarının değerlendirme ölçütleri.

İstasyon	Haftanın Günü, Tatil, Etkinlik Değişkenleri ile Eğitilen Model				Haftanın Günü, Etkinlik Değişkenleri ile Eğitilen Model			
	MAE	RMSE	MAPE	R kare	MAE	RMSE	MAPE	R kare
Yenikapı	3328	4422	%5,3	0,83	2972	5165	%4,9	0,77
Vezneciler	2161	2623	%11,7	0,76	2072	2865	%10,9	0,72
Haliç	1546	2101	%14,7	-0,06	1559	2087	%14,6	-0,05
Şişhane	1327	1831	%5,7	0,68	1423	1890	%5,8	0,66
Taksim	2951	5314	%10,6	-0,05	2467	4273	%9,1	0,32
Osmanbey	2134	2823	%5,7	0,94	2421	4396	%6,5	0,86
Şişli-Mecidiyeköy	1770	2306	%3,3	0,93	1848	3482	%3,6	0,84
Gayrettepe	1804	2297	%5,6	0,96	2538	4494	%8,2	0,85
Levent	1994	2496	%4,8	0,94	3106	4387	%7,8	0,81
4. Levent	1363	1697	%4,5	0,93	1440	2639	%5,0	0,84
Sanayi Mahallesi	566	722	%5,1	0,97	946	1509	%10,1	0,85
İTÜ-Ayazağa	3067	4050	%15,7	0,91	2975	5439	%16,8	0,83
Atatürk Oto Sanayi	674	819	%9,3	0,94	757	1296	%13,8	0,85
Darüşşafaka	385	476	%8,3	0,89	397	644	%9,2	0,79
Haciosman	1087	1485	%7,4	0,83	941	1682	%6,5	0,78
Seyrantepe	511	1116	%5,2	0,87	622	1289	%7,4	0,82
Tüm Hat	1667	2639	%7,7	0,77	1780	3330	%8,8	0,72

Bu tabloda verilen değerlendirme ölçütlerine göre, test veri seti içerisinde yer alan tek resmî tatil günü 1 Ocak 2020 olmasına rağmen “Tatil” değişkeninin modelin tahmin performansına belirgin ölçüde etki ettiği söylenebilir. Tablo 4.10’da değerlendirme ölçütleri verilen modellerin başarıları arasındaki fark 1 Ocak 2020 gününü tahmin etme başarısından gelmektedir. Test veri setinden 1 Ocak 2020 tarihi çıkartılarak tekrar hesaplanan değerlendirme ölçütleri de bu düşüncüyü desteklemektedir (Tablo 4.11). Bu ölçütlere göre, test seti içerisindeki tek resmî tatil olan 1 Ocak 2020 tarihine ait olan veri ve bu güne ait olan tahmin hesaba katılmadığında, bu iki modelin tahmin başarıları arasında belirgin bir fark olmadığı söylenebilir. Dolayısıyla, test setinde sadece bir adet resmî tatil olsa da, “Tatil” değişkeninin model başarısını etkilediği söylenebilir.

Tablo 4.11 “Tatil” değişkeni dahil edilerek ve edilmeyerek eğitilen modellerin 1 Ocak 2020 tarihine ait verilerden arındırılmış olan test sonuçlarının değerlendirme ölçütleri.

İstasyon	Haftanın Günü, Tatil, Etkinlik Değişkenleri ile Eğitilen Model				Haftanın Günü, Etkinlik Değişkenleri ile Eğitilen Model			
	MAE	RMSE	MAPE	R kare	MAE	RMSE	MAPE	R kare
Yenikapı	3339	4443	%5,3	0,82	2545	3442	%3,9	0,89
Vezneciler	2172	2637	%11,7	0,76	1912	2414	%9,7	0,80
Haliç	1485	2000	%14,2	0,05	1537	2069	%14,4	-0,02
Şişhane	1229	1563	%5,2	0,77	1367	1793	%5,5	0,70
Taksim	2662	4591	%10,2	0,08	2318	4020	%8,9	0,30
Osmanbey	2121	2820	%5,6	0,94	2034	2704	%5,0	0,95
Şişli-Mecidiyeköy	1786	2322	%3,4	0,92	1545	2188	%2,8	0,93
Gayrettepe	1799	2299	%5,5	0,96	2157	2905	%5,8	0,93
Levent	1984	2492	%4,7	0,94	2813	3417	%6,6	0,88
4. Levent	1375	1708	%4,6	0,93	1213	1676	%3,8	0,93
Sanayi Mahallesi	570	726	%5,1	0,96	818	964	%7,1	0,94
İTÜ-Ayazağa	3082	4072	%15,5	0,90	2528	3660	%9,8	0,92
Atatürk Oto Sanayi	674	821	%8,9	0,94	646	825	%8,1	0,94
Darıüşşafaka	385	477	%8,2	0,88	344	433	%6,8	0,90
Hacıosman	1035	1386	%6,8	0,84	797	1071	%5,0	0,91
Seyrantepe	516	1124	%5,2	0,86	576	1215	%6,1	0,84
Tüm Hat	1639	2539	%7,5	0,79	1572	2426	%6,8	0,80

4.2.5 Etkinlik değişkenlerinin model başarısına etkisi

Galatasaray Spor Kulübü’nün futbol maçlarını oynadığı Ali Sami Yen Spor Kompleksi’ne ve Beşiktaş Jimnastik Kulübü’nün futbol maçlarını oynadığı Beşiktaş

Stadyumu'na M2 metro hattı üzerinden ulaşım sağlanabilmektedir. Ali Sami Yen Spor Kompleksi'ne Seyrantepe istasyonundan kolaylıkla ulaşım sağlanabiliyorken, Beşiktaş Stadyumu Taksim istasyonuna 1,3 km uzaklıktadır. Dolayısıyla, bu iki stadyumda bir organizasyon olması durumunun M2 metro hattındaki talebi artıracığı değerlendirilerek her iki stadyumda da futbol maçı olup olmama durumu (varsa millî maçlar dahil) iki farklı değişken halinde modelde kullanılmış ve bu değişkenler “Etkinlik” değişkenleri olarak adlandırılmıştır. “Etkinlik” değişkenlerinin modelin tahmin performansı üzerindeki etkisini incelemek için, bir önceki bölümde “Haftanın Günü” ve “Etkinlik” değişkenleri kullanılarak geliştirilmiş olan modelden elde edilen tahminler ile sadece “Haftanın Günü” değişkeni kullanılarak geliştirilen modelden elde edilen tahminlerin başarı ölçütleri Tablo 4.12’de karşılaştırılmıştır. Bu tablodaki başarı ölçütlerine göre, modelin genel başarısı değerlendirildiğinde R kare değerinin arttığı görülmekle birlikte MAE, RMSE, MAPE gibi hata ölçütlerinde iyileşme gözlemlenmemiştir. Ancak, Seyrantepe istasyonunda belirgin düzeyde iyileşme gözlemlenmiştir. Seyrantepe istasyonunda gerçekleşen gerçek seyahat sayıları ile bu iki modelin tahmin ettiği seyahat sayılarını gösteren grafikler Şekil 4.6 ve 4.7’de verilmiştir. Ali Sami Yen Spor Kompleksi’nde futbol maçı olan günler gerçekleşen yoğun seyahat talebi bu grafiklerde anlaşılabilir. Şekil 4.6’da gösterilen etkinlik değişkeninin dahil edildiği model, futbol maçı olan günlerde beklenen sıçramayı yapmış, ancak bazı günlerde artışı tahmin etmesine rağmen doğru seyahat sayısı tahminini yapma konusunda eksik kalmıştır.


“Etkinlik” değişkenlerinin sadece Taksim ve Seyrantepe istasyonlarını değil, tüm metro hattındaki talebi etkileyeceği düşünülmektedir. Bu hipotezi test etmek için Seyrantepe ve Taksim istasyonları eğitim veri setinden çıkarılarak geriye kalan 14 istasyonda oluşacak talebi tahmin etmek için “Hava Durumu”, “Haftanın Günü”, “Tatil”, “Eğitim” ve “Etkinlik” değişkenleri kullanılarak bir LSTM – ANN Hibrit Modeli daha geliştirilmiştir. Aynı model bir de etkinlik değişkenleri dahil edilmeden geliştirilmiş ve bu modellerin tahminlerinin başarı ölçütleri karşılaştırılmıştır. Buradaki amaç, etkinlik değişkeninin sadece Taksim ve Seyrantepe istasyonlarını değil, tüm metro hattındaki talebi etkileyeceği hipotezini test etmektir. Geliştirilen modeller ile üretilen seyahat tahminlerinin değerlendirme ölçütleri Tablo 4.13’te verilmiştir.

Tablo 4.12 “Etkinlik” değişkeni dahil edilerek ve edilmeyerek eğitilen modellerin test sonuçlarının değerlendirme ölçütleri.


İstasyon	Haftanın Günü, Etkinlik Değişkenleri ile Eğitilen Model				Sadece Haftanın Günü Değişkenleri ile Eğitilen Model			
	MAE	RMSE	MAPE	R kare	MAE	RMSE	MAPE	R kare
Yenikapı	2972	5165	%4,9	0,77	3305	5328	%5,3	0,75
Vezneciler	2072	2865	%10,9	0,72	1402	2231	%7,3	0,83
Haliç	1559	2087	%14,6	-0,05	1377	1709	%12,3	0,30
Şişhane	1423	1890	%5,8	0,66	1436	1835	%6,1	0,68
Taksim	2467	4273	%9,1	0,32	2524	4372	%9,2	0,29
Osmanbey	2421	4396	%6,5	0,86	1731	4163	%4,8	0,88
Şişli-Mecidiyeköy	1848	3482	%3,6	0,84	1819	3438	%3,5	0,84
Gayrettepe	2538	4494	%8,2	0,85	1826	4113	%6,6	0,87
Levent	3106	4387	%7,8	0,81	2293	3865	%5,6	0,85
4. Levent	1440	2639	%5,0	0,84	1299	2496	%4,6	0,86
Sanayi Mahallesi	946	1509	%10,1	0,85	795	1450	%8,6	0,86
İTÜ-Ayazağa	2975	5439	%16,8	0,83	3040	5322	%17,5	0,84
Atatürk Oto Sanayi	757	1296	%13,8	0,85	862	1377	%14,1	0,83
Darüşşafaka	397	644	%9,2	0,79	368	635	%8,5	0,80
Hacıosman	941	1682	%6,5	0,78	935	1686	%6,5	0,78
Seyrantepe	622	1289	%7,4	0,82	1319	3459	%11,1	-0,28
Tüm Hat	1780	3330	%8,8	0,72	1646	3293	%8,2	0,69

Tablo 4.13 Taksim ve Seyrantepe istasyonları çıkarılarak, “Etkinlik” değişkeni dahil edilerek ve edilmeyerek eğitilen modellerin test sonuçlarının değerlendirme ölçütleri.

İstasyon	Hava Durumu, Haftanın Günü, Tatil, Eğitim, Etkinlik Değişkenleri ile Eğitilen Model				Hava Durumu, Haftanın Günü, Tatil, Eğitim Değişkenleri ile Eğitilen Model			
	MAE	RMSE	MAPE	R kare	MAE	RMSE	MAPE	R kare
Yenikapı	2545	3292	%3,7	0,91	2621	3541	%4,0	0,89
Vezneciler	942	1323	%4,7	0,94	1231	1507	%6,6	0,92
Haliç	888	1136	%7,6	0,69	956	1327	%8,2	0,58
Şişhane	978	1312	%4,1	0,84	1038	1584	%4,4	0,76
Osmanbey	1621	2061	%3,8	0,97	1599	1931	%4,0	0,97
Şişli-Mecidiyeköy	1399	1763	%2,6	0,96	2061	2664	%3,9	0,90
Gayrettepe	1265	1571	%3,6	0,98	1739	2331	%5,5	0,96
Levent	1441	1921	%3,3	0,96	1683	2123	%4,3	0,96
4. Levent	715	927	%2,3	0,98	1156	1491	%4,1	0,95
Sanayi Mahallesi	386	506	%3,9	0,98	476	606	%4,7	0,98
İTÜ-Ayazağa	1631	2272	%8,1	0,97	1950	2562	%10,9	0,96
Atatürk Oto Sanayi	664	793	%8,5	0,94	582	748	%7,3	0,95
Darüşşafaka	197	255	%4,0	0,97	498	575	%11,6	0,84
Hacıosman	576	716	%3,6	0,96	662	818	%4,2	0,95
Tüm Hat	1089	1617	%4,6	0,93	1304	1900	%6,0	0,90



Şekil 4.6 “Haftanın Günü” ve “Etkinlik” değişkenleri ile eğitilen LSTM – ANN hibrit modelinin Seyrantepe istasyonu için yaptığı tahminler ile gerçek seyahat sayılarının karşılaştırılması.



Şekil 4.7 Sadece “Haftanın Günü” değişkenleri ile eğitilen LSTM – ANN hibrit modelinin Seyrantepe istasyonu için yaptığı tahminler ile gerçek seyahat sayılarının karşılaştırılması.

Bu bölümde görüldüğü üzere etkinlik değişkenlerinin modele eklenmesi modelin tahmin başarısını her ölçüte göre belirgin düzeyde artırmaktadır. “Etkinlik” değişkenlerinin sadece Taksim ve Seyrantepe istasyonlarındaki seyahat talebini değil, tüm hattaki seyahat talebini etkilediği görülmüş, bu değişkenlerin modele eklenmesi halinde tüm hattaki genel tahmin başarısının arttığı ortaya koyulmuştur. Bu tablodan yapılabilecek diğer önemli çıkarım ise, tablodaki

değerlendirme ölçütlerinin değerlerinin bu çalışmada şimdiye kadar görülmüş olan en iyi tüm hat değerleri olduğudur. Bu beklenen bir durumdur. Zira, Taksim istasyonu hat üzerindeki tahmin performansı en düşük olan istasyondur. Bu istasyonun modelden çıkarılmasıyla, genel tahmin başarısında gözlemlenen artış normal karşılanabilir.



5. TARTIŞMA

Tahmin modelleri, karmaşık veri setlerinden gelecekteki olayların tahmin edilmesinde yaygın olarak kullanılan araçlardır. Bu çalışmada, İstanbul'daki M2 metro hattının seyahat taleplerini tahmin etmek için beş farklı derin öğrenme modeli geliştirilmiş, modellerin değerlendirme ölçütleri sonuçları ve elde edilen bulgular bir önceki bölümde paylaşılmıştır. Ayrıca, en iyi tahmin başarısını sergilediği gözlemlenen LSTM – ANN hibrit modeline odaklanılmış, değişkenlerin modellerin tahmin başarısı üzerindeki etkisi bu hibrit model üzerinden incelenmiştir. Bulgular, bu modelin genel olarak tatmin edici sonuçlar ürettiğini göstermektedir. Ancak, modelin tahmin performansını etkileyen çeşitli değişkenlerin rolünü anlamak ve değerlendirmek de önemlidir. Bu nedenle, çalışmada kullanılan değerlendirme ölçütleri, model geliştirme süreci, hibrit modellerin başarısı, değişkenlerin tahmin başarısı üzerindeki etkileri ve bu çalışmanın kısıtları detaylı bir şekilde tartışılmıştır, bazı noktalarda önerilerde bulunulmuş ve gelecek potansiyel çalışmalara önerilerde bulunulmuştur. Tahmin modellerinin potansiyelinin ve sınırlamalarının daha iyi anlaşılmasına katkıda bulunulmuştur. Elde edilen sonuçların gerçek dünyadaki potansiyel uygulamalarına ve gelecekteki araştırmalara yönelik daha detaylı önerilere sonuç bölümünde yer verilmiştir.

5.1 Değerlendirme Ölçütlerinin Anlamlandırılması

Tahmin modellerinin performansını objektif bir şekilde değerlendirmek ve sonuçlarını anlamak, modelin gerçek dünyadaki uygulanabilirliğini belirlemek açısından kritik öneme sahiptir. Bu bağlamda, çalışmada kullanılan değerlendirme ölçütlerinin nasıl yorumlanması gerektiği bu bölümde incelenmiştir.

5.1.1 R kare değeri ile uyum incelemesi

R kare değeri, modelin tahminlerinin gerçek değerlere ne kadar uyumlu olduğunu gösterir. Bu değer, gerçek değerdeki değişim örüntülerini modelin tahminlerinin yakalayıp yakalayamadığını yansıtır. Ancak yüksek bir R kare değeri her zaman hatanın minimum olduğu anlamına gelmediği için diğer ölçütlerle birlikte değerlendirilmelidir. R kare değerinin sıfıra yaklaşması, modelin ortalama değerlerden daha iyi bir sonuç üretilmediğini, negatif olması ise modelin ortalama

değerlerden bile kötü sonuç verdiğini gösterir. Bu çalışmada geliştirilen hibrit modellerin tahminlerine bakıldığında, birçok istasyonun R kare değerinin oldukça yüksek olduğu gözlemlenmiş, dolayısıyla geliştirilen modellerin tahminlerinin test veri setine oldukça uyumlu olduğu görülmüştür. Ancak, özellikle Taksim, Haliç ve Şişhane istasyonları için yapılan tahminlerin R kare değerlerinin diğer istasyonlara göre düşük olduğu gözlemlenmiştir. Bu durum, sonraki bölümlerde daha detaylı bir şekilde tartışılacaktır.

5.1.2 MAE ve RMSE değerleri ile hata analizi

MAE ve RMSE değerleri, modelin tahminlerindeki hataları değerlendirmek için kullanılır. Ancak istasyonlar arasındaki talep seviyeleri farklı olduğundan, istasyon tahmin başarılarını karşılaştırmak için uygun değildir. Örneğin, modelin aynı oranda hatalı tahmin ettiği iki istasyondan, daha yüksek talep görenin MAE ve RMSE değerleri daha yüksek çıkacaktır. Bu nedenle, istasyon tahmin başarılarını değerlendirmek için ideal olmasa da modelin genel başarısını değerlendirmek ve modeller arası değerlendirme yapmak için uygundur. Çalışılan metro hattında test için kullanılan 1 Ocak 2020 – 10 Mart 2020 tarihleri arasında günlük yaklaşık ortalama 473.000 seyahat gerçekleşmiştir. Geliştirilen LSTM – ANN hibrit modelinin tahminleri için hesaplanan MAE ve RMSE değerleri sırasıyla 1225 ve 2076'dır. Bazı istasyonlar için bu değerler daha yüksek veya daha düşüktür. Ancak tüm hat için tahmin performansına bakıldığında, bu MAE ve RMSE değerleri oldukça tatmin edicidir.

5.1.3 MAPE değeri ile oransal hata analizi

MAPE değeri, modelin ortalama olarak hangi oranda hata yaptığını belirtir. Hem istasyonlar arası hem de modeller arası tahmin başarılarını karşılaştırmak için daha anlamlı bir ölçüttür. Yüzdesele hatalara odaklandığı için, istasyonlar arasındaki talep farklılıkları göz önünde bulundurulur ve yapılan tahminin ortalama olarak ne kadar hata içerdiğinin bilgisini verir.

R kare, MAE, RMSE ve MAPE gibi ölçütler, farklı yönleriyle modelin tahmin yeteneklerini ele alırken, istasyonlar arası ve modeller arası karşılaştırmaların sağlıklı yapılabilmesine katkı sağlar. Bu değerlendirme ölçütleri, tahmin modelinin gerçek dünyadaki performansını değerlendirmek ve iyileştirmek

için önemlidir. Bu çalışmada yapılan değerlendirmelerde talep hacminden etkilenmedikleri için ağırlıklı olarak R kare ve MAPE değerleri dikkate alınmıştır. Geliştirilen en başarılı model olan LSTM – ANN hibrit modelinin yaptığı tahminlerin MAPE değerleri incelendiğinde, en yüksek MAPE değeri iki tane aykırı değer bulunan ve ölçütlere göre en başarısız olarak tahmin edilen Taksim istasyonunda %9,9 olarak tespit edilmiştir. En düşük MAPE değeri hat üzerindeki en yoğun istasyonlardan biri olan Şişli – Mecidiyeköy istasyonunda %2,4 olarak kaydedilmiştir. Modelin genel tahmin performansına bakıldığında ise, tüm hattın MAPE değeri %5,3 olmuştur. Ortalama olarak tespit edilen %5,3'lük MAPE değeri modelin başarılı tahminler yaptığını göstermektedir.

5.2 Model Geliştirme Süreci

Bir derin öğrenme modeli geliştirirken hem model mimarisine hem de eğitim süreci için belirlenmesi gereken parametrelere karar vermek gerekir. Model mimarisi tarafında; katman sayısı, katman genişlikleri, regülarizasyon tekniklerinin kullanılıp kullanılmaması, aktivasyon fonksiyonları, LSTM modelleri için hücre sayısı ve dizi uzunluğu, CNN modelleri için kernel (filtre) sayısı ve boyutları gibi parametrelerin seçilmesi gerekmektedir. Eğitim tarafında ise; iterasyon sayısı, hata fonksiyonu, optimizasyon algoritması gibi seçimlerin yapılması gerekmektedir. Bu parametreler veriye ve duruma özel olarak belirlenmelidir. Ancak bu parametrelere karar vermek için bir nicel yöntem bulunmamaktadır. Bundan dolayı, bazı genel kabuller yapılarak, her bir parametrenin amacı ve modele etkisi düşünülüp başlangıç parametrelerine karar vermek, model geliştirme sürecinde ise deneme yanılma yöntemiyle bu parametrelerin iyileştirilmesi gerekmektedir. Deneme yanılma sürecine tabi olan parametre sayısı da oldukça fazla olduğu için optimum parametre kombinasyonunun tespit edilmesi oldukça güçtür.

Model geliştirme sürecinde önem verilen noktalardan birisi de modellerin her eğitimden sonra ağırlıklarının yeniden hesaplanıyor olmasıdır. Bu durum, her eğitim adımında modelin optimize edildiği ve geliştirilen bir model tekrar eğitildiğinde tahmin performansının farklılık gösterebileceği anlamına gelir. Ancak bu farklılığın model geliştirme sürecinde hataya sebep olmaması için, aynı koşullar altında defalarca eğitilen ve test edilen modellerin sonuçları incelenerek gerekli kararlar verilmiştir.

5.2.1 Model mimarisinin geliştirilmesi

ANN yöntemi kullanılan modellerde az sayıda gizli katman ve düşük nöron sayıları kullanılarak geliştirme sürecine başlanmıştır. Model başarıları düşük bulununca hem ANN modelinde hem LSTM – ANN hibrit modelinde, dar ve kısa olarak oluşturulan ANN katmanlarındaki nöron sayıları ve gizli katman sayıları artırılmıştır. Modellerin çok fazla sayıda girdi aldığı ve 16 istasyon için tahmin ürettiği düşünüldüğünde, az sayıdaki gizli katmanın ve düşük nöron sayısının modeldeki karmaşıklığı öğrenemediği değerlendirilmiştir. Nöron ve katman sayılarının çok artırılması modelde aşırı uyum sorunu gözlemlenmesine sebep olmuştur. Bundan dolayı optimum sayıdaki nöron ve katman sayıları belirlenmiş ve “Geliştirilen Modeller” bölümünde belirtilmiştir. Aktivasyon fonksiyonu olarak derin öğrenme modellerinde sıklıkla kullanılan ve başarılı olduğu bilinen “ReLU” ve “Sigmoid” fonksiyonları tercih edilmiştir. ANN katmanlarında aşırı uyumu önlemek ve tahmin başarısını artırmak için bazı regülarizasyon teknikleri denenmiş, ancak tahmin başarısını artıran model yakalanmadığı için bu teknikler kullanılmamıştır.

Yakın geçmişteki seyahat sayılarını girdi olarak kullanan LSTM ve CNN modelleri için yakın geçmişteki gün sayısını ifade eden dizi uzunluğu önemli bir parametredir. Sadece CNN yöntemi kullanılarak geliştirilen CNN modeli, “Geçmiş Gün Sayısı \times İstasyon Sayısı” boyutlarında olan iki boyutlu bir veriyi girdi olarak almaktadır. LSTM modelinin, LSTM – ANN hibrit modelinin ve LSTM – CNN hibrit modelinin LSTM katmanı geçmiş gün sayısı kadar tek boyutlu istasyon sayısı uzunluğunda vektörleri girdi olarak almaktadır. Burada istasyon sayısı sabit olduğuna göre, geçmiş gün sayısını belirlemek önemlidir. Yapılan testler sonucunda, sadece LSTM ve CNN yöntemlerinin kullanıldığı modellerde modele girdi olarak verilen geçmiş gün sayısı arttıkça, bir yere kadar model başarısı da artmaktadır. Bunun sebebi, bu iki modelin geçmiş günlerde gerçekleşen seyahat sayılarından başka bir girdi kullanmıyor olmasıdır. Dolayısıyla veri sayısı arttıkça model başarısının da bir yere kadar arttığı gözlemlenmiştir. Bu iki model için, modele girdi olarak verilen geçmiş gün verisi sayısı 14 olarak belirlenmiştir. Hibrit modellerde ise, geçmiş gün verisi sayısının artmasıyla model başarısının düştüğü gözlemlenmiştir. Bu durumdan dolayı, hibrit modellerin geçmiş seyahat verileri

dışında girdi olarak aldığı dışsal faktör verilerinin, uzak geçmişteki seyahat verilerine kıyasla yakın gelecekteki bir günü tahmin etme konusunda daha önemli olduğu yorumu yapılabilir. Hibrit modellerin ikisinde de dizi uzunlukları beş günlük geçmiş seyahat verisi olarak belirlenmiştir. Özetle, sadece geçmiş seyahat verilerini kullanarak tahmin yapan LSTM ve CNN modellerinde uzun dizilerin başarıyı artırdığı, geçmiş seyahat verileri dışında farklı değişkenlerin etkisini dahil eden hibrit modellerde ise kısa dizilerin daha etkili olduğu söylenebilir.

LSTM – CNN hibrit modelinde dışsal faktör değişkenleri CNN kolundan modele girdi olarak verilmiştir. Bu uygulamanın amacı, tek boyutlu olan CNN katmanında kullanılan filtrelerin bu değişkenler arasındaki ilişkiyi de ortaya çıkararak bir tahmin yapmasıdır. Bu amaca ulaşmak için filtre boyutunun uygun bir biçimde belirlenmesi önemlidir. Buradaki filtre boyutu, CNN katmanının yan yana kaç değişken arasındaki ilişkiyi ortaya çıkarmaya çalışacağını göstermektedir. Örneğin, boyutu beş birim olarak belirlenen bir filtre, yan yana dizilen beş girdi üzerinde işlem yapmakta ve girdi verileri üzerinde sırayla gezmektedir. Ancak, bu çalışmada filtre boyutu ile model başarısı arasında bir ilişki kurulamamıştır. CNN katmanının arzu edildiği gibi çalışmadığı ve beklenenin aksine LSTM – CNN hibrit modelinin LSTM – ANN hibrit modeline üstünlük sağlamadığı gözlemlenmiştir. Bunun sebebi olarak, LSTM – CNN hibrit modelinde CNN koluna girilen verilerin çoğunluğunun ikili etiket kodlama ile oluşturulan kategorik veriler olduğu söylenebilir. Kategorik veriler ikili etiket olarak kodlandıklarında girdi boyutları oldukça uzun olmaktadır. Örneğin, sadece ay değişkeni girdi setinde 12 değişkenle ifade edilmektedir. Böyle olunca, CNN katmanı farklı veriler arasındaki ilişkiyi ortaya koyma noktasında başarı gösterememiş olabilir. Gelecekteki çalışmalar için, kategorik değişkenlerin etiket kodlama gibi daha farklı bir yöntemle kodlanarak ve aralarındaki ilişki dikkate alınarak bir sıralama yapılarak modele verilmesi önerilebilir. Bu durumda, girdi vektörünün uzunluğunun kısılacağı, değişkenlerin konumları birbirlerine daha yakın olacağı ve değişkenler daha anlamlı bir şekilde kendi aralarında sıralanacağı için CNN katmanının değişkenler arasındaki ilişkiyi daha iyi ortaya koyması beklenebilir.

5.2.2 Eğitim sürecinin geliştirilmesi

Eğitim sürecinde geliştirilebilecek parametrelerin en başında iterasyon sayısı gelmektedir. İterasyon sayısı arttıkça, modelin eğitim setindeki hatası azalsa da belirli bir sayıdan sonra test setindeki hata artmakta ve model aşırı uyum sorunu ile karşılaşmaktadır. Aşırı uyum sorunu yaşandığında modelin eğitim seti içerisindeki verileri ezberlediği yorumu yapılabilir. En uygun iterasyon sayısı, farklı iterasyon sayılarıyla eğitilen modellerin başarıları karşılaştırılarak bulunabilir. Modelleri en uygun iterasyon sayısı ile eğitmenin bir diğer yolu da validasyon veri seti kullanmaktır. Validasyon veri seti, aşırı uyumdan kaçınmak için erken durdurma tekniğinden faydalanmak amacıyla kullanılır ve test veri setinden farklı olması istenir. Erken durdurma, eğitim sürecinde validasyon setindeki hata lokal minimuma veya belirli bir eşiğin altına indiğinde eğitimin durdurulmasıdır. Böylece en uygun iterasyon sayısında model eğitilmiş olur ve aşırı uyumdan kaçınılır. Bu çalışmadaki veri sayısı kısıtından dolayı validasyon seti test setinden farklı olarak oluşturulamamıştır. Yine de iterasyon sayısı ile modelin test verilerinin başarısı arasındaki ilişkileri incelemek için test verileri eğitim süresince modele validasyon verisi olarak verilmiştir. Ancak, validasyon seti olarak kullanılan test setinin hata verileri üzerinden eğitim sürecine erken durdurma gibi bir uygulama yapılmamıştır. Sadece, iterasyonlar boyunca eğitim sürecinin test seti hatası üzerindeki etkisi incelenmiştir ve en uygun iterasyon sayısı kestirilmeye çalışılmıştır. Bu kestirimi yapabilmek için, geliştirme sürecinde defalarca eğitilen modellerin validasyon hatası – iterasyon sayısı grafikleri incelenmiştir. Her bir model için validasyon hatasının en az olduğu iterasyon aralıkları gözlenmiştir. Hibrit modellerde bu sayı 37 iterasyon, LSTM ve CNN modellerinde 40 iterasyon, ANN modelinde ise 50 iterasyon olarak belirlenmiştir.

Belirlenmesi gereken bir diğer parametre ise hata fonksiyonudur. Hata fonksiyonu modelin tahminlerinin gerçek değerlerden ne kadar sapma gösterdiğini ölçerek modelin tahmin hatasını değerlendirir. Model eğitimi süresince model parametrelerini güncellemek için gerçek değerlerle tahminler arasındaki farkları hesaplayarak optimizasyon algoritması tarafından minimize edilir. Tahmin modelleri geliştirilme sürecinde en çok kullanılan hata fonksiyonlarından birkaçı MSE, MAE, Huber Kaybı ve Logaritmik Kayıp (Log Loss) olarak sıralanabilir. Bu

çalışmada geliştirilen bütün modellerde veri setinde aykırı değerler bulunduğu göz önüne alınarak, aykırı değerlerden en az etkilenen hata fonksiyonu olan MAE seçilmiştir.

Eğitim süresince hata değerlerini minimize edecek olan optimizasyon algoritması olarak “Adam” algoritması seçilmiştir. Bu algoritma, gradiyent bazlı optimizasyon algoritmalarından biridir ve derin öğrenme modellerinin eğitiminde sıklıkla tercih edilir. Aykırı değerlere karşı oldukça dayanıklıdır ve hızlı bir şekilde öğrenme sağlamak amacıyla tasarlanmıştır. "Adam" algoritması öğrenme oranını her parametre için ayrı ayrı adaptif olarak ayarladığı için aykırı değerlerin modele olumsuz etkisi daha az olur.

5.3 Hibrit Modellerin Başarısı

Bu çalışma kapsamında geliştirilen beş modelden bir tanesi sadece “Hava Durumu”, “Haftanın Günü”, “Eğitim”, “Tatil” ve “Etkinlik” verilerini girdi olarak alan ANN modeli, iki tanesi sadece yakın geçmiş seyahat verilerini girdi olarak alan ANN ve CNN modelleri, iki tanesi de hem “Hava Durumu”, “Haftanın Günü”, “Eğitim”, “Tatil” ve “Etkinlik” verilerini hem de yakın geçmiş seyahat verilerini girdi olarak alan LSTM – ANN ve LSTM – CNN hibrit modelleridir. Bulgular bölümünde verilen değerlendirme ölçütlerinden açıkça görüldüğü üzere, sadece geçmiş seyahat verileri veya sadece “Hava Durumu”, “Haftanın Günü”, “Eğitim”, “Tatil” ve “Etkinlik” verileri ile tahmin yapan modellerin başarıları, 2019 yılı verilerinin haftanın günlerine göre ortalamalarının seyahat artış oranı ile 2020 yılına projekte edilmiş haline kıyasla belirgin derecede daha iyi değildir. Model performansının sadece geçmiş seyahat verilerine dayalı veya sadece dışsal faktörlere dayalı modellerde düşük olduğu gözlemlenirken, bu iki veri türünün birleştirilmesiyle elde edilen modellerin başarısının önemli ölçüde arttığı görülmüştür.

Yakın geçmiş seyahat verilerinin sistemin dinamiklerini ve geçmiş seyahat taleplerinin örüntüsünü yakalama konusunda önemli bir rol oynadığı söylenebilir. Öte yandan, “Hava Durumu”, “Haftanın Günü”, “Eğitim”, “Tatil” ve “Etkinlik” gibi faktörlerin, günlük seyahat taleplerini etkileyen önemli değişkenler olduğu görülmüştür. Bu çalışmada elde edilen sonuçlar, farklı veri türlerinin birleştirilerek

hibrit modellerin oluşturulmasının, tahmin performansını önemli ölçüde artırabileceğini göstermektedir. Bu sonuçlar, model geliştirme sürecindeki veri seçiminin önemini vurgularken, farklı veri türlerinin birbirini tamamlayıcı bir şekilde kullanılma potansiyelini açık bir şekilde ortaya koymaktadır.

5.4 Değişkenlerin Tahmin Başarısı Üzerindeki Etkileri

Bu çalışmada kullanılan değişkenlerin tamamının model performansı üzerinde olumlu veya olumsuz olarak etkili olduğu “Değişkenlerin Tahmin Modeli Üzerindeki Etkisi” bölümündeki bulgularla ortaya koyulmuştur. Bu bölümde “Hava Durumu”, “Haftanın Günü”, “Ay”, “Eğitim”, “Tatil” ve “Etkinlik” değişkenlerinin model performansı üzerindeki etkileri tartışılacaktır.

5.4.1 Ay değişkeni

Ay değişkeninin modele girdi olarak eklenmesi model başarısını belirgin ölçüde olumsuz olarak etkilemiştir. Tablo 4.7’de görüldüğü üzere, ay değişkeninin dahil edildiği modelin eğitim setindeki başarısı oldukça yüksekken, test setindeki başarısı oldukça düşüktür. Bu durumun aşırı uyum sorunu olarak değerlendirilebilir ve aşırı uyumun sebebi modelin, aylar içerisinde gerçekleşen olaylardan kaynaklı olarak değişen seyahat talebini ay değişkeni ile açıklamaya çalışıyor olması olabilir. Örnek vermek gerekirse, normalde tatil veya eğitim değişkenleri ile açıklanması gereken seyahat sayılarındaki düşüşler model tarafından ay değişkeni ile ilişkilendirilmiş olabilir. Böylece model, sebep – sonuç ilişkilerini yanlış öğrenmiş ve farklı bir değişken ile açıklaması gereken seyahat taleplerini ay değişkeni ile açıklamaya çalışmıştır. Eğitim veri setinin bir yıldan daha uzun süreler olarak belirlenmesi ve modelin bu veri seti ile eğitilmesi durumunda, modelin ay değişkeninin etkisini daha iyi öğrenmesi beklenmektedir.

5.4.2 Haftanın günü değişkeni

Haftanın günü değişkeni, seyahat talebine ve modelin tahmin başarısına belirgin bir biçimde etki eden en önemli değişkendir. Herhangi bir istasyon için seyahat sayılarının günlere göre değişimi grafiğine bakıldığında bu açıkça görülmektedir. Seyahat talebinin haftanın günleri arasındaki dağılımını sadece hafta içi – hafta sonu ayrımıyla açıklamak eksik kalmaktadır. Her günün farklı

istasyonlar üzerinde farklı etkileri vardır. Örneğin, cuma günleri insanlar iş çıkışı eğlence ve sosyalleşme aktivitelerinin yapılabileceği yerlere hafta içi diğer günlere göre daha sık giderler. Dolayısıyla, eğlence ve sosyalleşme aktivitelerinin yapılabildiği konumlara ulaşımın sağlandığı istasyonlara daha yoğun bir talep oluşmaktadır. Bu nedenle, bu çalışmada modellerin geliştirilmesinde, haftanın her günü ayrı bir değişken olarak tanımlanmıştır.

5.4.3 Hava durumu değişkenleri

“Ortalama Hava Sıcaklığı”, “Yağış Miktarı” ve “Rüzgâr Hızı” değişkenlerinden oluşan “Hava Durumu” değişken grubunun tahmin modelinin performansını olumlu olarak etkilediği Tablo 4.8’de verilmiş olan değerlendirme ölçütlerine bakarak söylenebilir. Sıcaklık değişkeninin insanların dışarıda hareket etme eğilimini etkileyeceği, aşırı sıcak ve aşırı soğuk havalarda insanların yürümek yerine toplu taşıma araçlarını veya kişisel araçlarını tercih edebilecekleri söylenebilir. Öte yandan, yağış miktarı yürüyüş veya bisiklet gibi açık alan aktivitelerini olumsuz etkilemekte, bu da insanları toplu taşıma araçlarına yönlendirebilmektedir. Ayrıca yağışlı hava trafik sıkışıklığına neden olabilmekte, bu da kişisel araç yerine toplu taşımayı tercih etme eğilimini artırabilmektedir. Rüzgâr hızı da dışarıda hareket etmeyi etkileyen diğer bir faktördür. Şiddetli rüzgârlar, fırtınalı havalar yürüyüş veya bisiklet gibi aktiviteleri zorlaştırabilir ve insanları toplu taşıma araçlarına yönlendirebilir. Bu nedenlerle, “Hava Durumu” değişkenlerinin tahmin modellerine eklenmesi doğru bir karar olarak değerlendirilmiştir.

5.4.4 Eğitim değişkenleri

İstanbul Teknik Üniversitesi, İstanbul Üniversitesi, Boğaziçi Üniversitesi ve MEB’e bağlı okulların eğitim döneminde olup olmadığını ifade eden “Eğitim” değişkenleri bu çalışmada geliştirilen modellerde etkisi en belirgin şekilde gözlemlenen değişkenler olarak gösterilebilir. İstanbul Üniversitesi ve İstanbul Teknik Üniversitesi’nin yarı yıl tatiline girmesiyle 17 Ocak 2020 – 10 Şubat 2020 tarihleri arasında İTÜ – Ayazağa istasyonundaki, 24 Ocak 2020 – 10 Şubat 2020 tarihleri arasında da Vezneciler istasyonundaki seyahat talebinin belirgin bir şekilde düştüğü gözlemlenmiştir. Eğitim değişkenlerinin kullanıldığı tahmin modellerinin

bu seyahat sayılarındaki belirgin düşüğe uyumlu bir şekilde tahminler ürettiği Şekil 4.2, Şekil 4.3, Şekil 4.4 ve Şekil 4.5'te görülmektedir. “Eğitim” değişkenleri kullanılmadan geliştirilen LSTM – ANN hibrit modelinin tahminleri ile gerçek değerlerin karşılaştırılmasını gösteren Şekil 4.5 incelendiğinde, İTÜ – Ayazağa istasyonunda ikinci tatil haftasından itibaren model tahminlerinin gerçek değerlere yaklaştığı görülmektedir. Bunun sebebi olarak geliştirilen modelin LSTM kolunun başarısı gösterilebilir. LSTM kolu bu örnekte, tahmin edilmek istenen günden beş gün önceye kadar olan geçmiş seyahat verilerini kullanarak modelin tatil dönemindeki talep düşüklüğünü öğrenmesini sağlamış ve yarıyıl tatilinin ikinci haftasından itibaren model tahminlerinde bunun etkisi olmuştur.

5.4.5 Tatil değişkeni

Bu çalışmada etkisi en az gözlemlenebilen değişken günün resmî tatil olup olmadığını ifade eden “Tatil” değişkenidir. Test veri setinde "Tatil" değişkeninin etkisinin gözlemlenebileceği tek gün yılbaşı günüdür. Yılbaşı gününün istasyonlardaki seyahat talebi üzerindeki etkisinin diğer tatil günlerinden farklı olabileceği düşünülmeye karşın, yılda sadece bir kere tekrarlanan bir gün olması nedeniyle bu güne özel bir değişken tanımlamanın modelin tahmin performansına katkı sunmayacağı düşünülmektedir. Ayrıca, ANN modeli dışındaki geliştirilen modellerde yakın geçmiş seyahat verileri modellerde girdi olarak kullanılmaktadır. Örneğin, LSTM – ANN hibrit modelinde tahmin edilecek günün öncesindeki sıralı beş günlük geçmiş seyahat verileri modele girdi olarak verilmiştir. Dolayısıyla, bu model için kullanılan eğitim setinin ilk öğrendiği tarih 6 Ocak 2019 tarihidir. Başka bir deyişle 1 – 5 Ocak 2019 tarihleri arasındaki veri 6 Ocak 2019 tarihini tahmin etmek için girdi olarak kullanılmıştır. 2018 yılına ait herhangi bir veri bulunmaması nedeniyle bu model için 1 – 5 Ocak 2019 tarihlerini arasındaki seyahatleri tahmin edebilecek geçmiş beş günlük veri oluşturulamamaktadır. Dolayısıyla, yakın geçmiş seyahat verilerini girdi olarak kullanmayan ANN modeli haricindeki modellere yılbaşı tatili etkisini öğrenebilecekleri herhangi bir veri sunulamamıştır. Ancak, eğitim veri seti içerisinde diğer tatil günlerinin verileri bulunmaktadır. Bunun sonucu olarak 1 Ocak 2020 tarihini tahmin etmek için tatil değişkeni kullanıldığında, sonuçların istasyonların genelinde olumlu olarak değiştiği gözlemlenmiştir. Geliştirilen modeller eğitim veri setinden resmî tatil günlerinde

daha düşük seyahat talebi üretildiğini öğrenmiştir. Çalışılan metro hattı üzerinde de bazı istasyonlarda yılbaşı tatili günü seyahat talebi azalmış ve bu değişken sayesinde model bu istasyonlarda daha başarılı tahminler ortaya koymuştur. Ancak yılbaşı günü İstanbul'daki İstiklal Caddesi gibi cazibe merkezlerine olan ulaşım talebini artırmaktadır. Ancak, geliştirilen modeller, öğrenmiş oldukları “tatil günü talebi düşürür” olgusundan dolayı tüm istasyonlarda olduğu gibi Taksim istasyonunda da o gün için gerçekleşenden çok daha düşük bir talep tahmini yapmıştır. Bu durum da hataya sebebiyet vermiştir (Bkz. Şekil 4.1). Bu durumu çözmek için, haftanın her günü birbiriyle aynı olmadığı gibi her resmî tatili de birbiri ile aynı değerlendirmemek ve resmî tatilleri gruplandırarak değerlendirmek gerekebilir. Ancak, bu farklı tatil verilerini kullanarak geliştirilen modelin her tatilin etkisini öğrenebilmesi için çok daha uzun süreli veriye ihtiyacı olacaktır. Örneğin, bir yıl içerisinde bir tane yılbaşı tatili olması nedeniyle bir yıllık veri yılbaşı tatilinin istasyonlardaki talep üzerindeki etkisinin öğrenilmesi için yeterli değildir.

5.4.6 Etkinlik değişkenleri

Kentteki büyük konserler, spor etkinlikleri veya festival gibi yüksek katılımlı etkinlikler, metro hattının kullanımını belirgin bir şekilde artırabilmekte ve bu tür etkinliklerin gerçekleştiği günlerde, metro hatlarında daha yoğun bir seyahat talebi gözlemlenebilmektedir. Bu çalışmanın odaklandığı M2 metro hattı kullanılarak Galatasaray Spor Kulübü'nün futbol maçlarını oynadığı Ali Sami Yen Spor Kompleksi'ne ve Beşiktaş Jimnastik Kulübü'nün futbol maçlarını oynadığı Beşiktaş Stadyumu'na Seyrantepe ve Taksim istasyonları kullanılarak ulaşılabilir. Ayrıca, normal şartlarda M2 hattı seferleri Yenikapı – Hacıosman arasında 15 istasyonla yapılmaktadır. Seyrantepe istasyonuna ulaşım ise “Sanayi” istasyonundan yapılan aktarma ile gerçekleşmektedir. Ancak, Ali Sami Yen Spor Kompleksi'nde futbol maçı oynanan günlerin belli saatlerinde Yenikapı – Seyrantepe istasyonları arasında kesintisiz seferler yapılmaktadır.

Bu stadyumlarda yüksek katılımı gerçekleştirecek olan futbol maçlarına bu metro hattı üzerinden ulaşım sağlanması beklenmektedir. Modelin tahmin performansını desteklemek için bu stadyumlarda futbol maçı olan günler (kulüp veya millî takım maçı olabilir) belirlenerek modelin eğitiminde ve test edilmesinde

kullanılan veri setlerine eklenmiştir. Tablo 4.12’de verilmiş olan bulgular incelendiğinde, etkinlik değişkenleri kullanılarak eğitilen modelin genel tahmin performansının arttığı gözlemlenmiştir. Özellikle Seyrantepe istasyonunda R kare değerinin negatif değerden 0,82 gibi oldukça iyi bir seviyeye çıkması, bu değişkenlerin Seyrantepe istasyonundaki seyahat talebi üzerinde oldukça etkili olduğunu göstermektedir. Bunun yanında, Şekil 4.6 ve Şekil 4.7’de verilmiş olan grafikler incelendiğinde Ali Sami Yen Stadyumu’nda futbol maçı olduğu günlerde Seyrantepe istasyonuna olan aşırı talebe modelin uyum sağladığı söylenebilir.

Modele girdi olarak sadece bu stadyumda futbol maçı olup olmadığı bilgisi verilmiştir. Ancak her futbol maçına olan katılım birbirinden farklıdır. Yaklaşık 52.000 seyirci kapasitesi olan Ali Sami Yen Spor Kompleksi’nde 10.000 kişinin katılımı ile de futbol maçı oynandığı günler olmuştur. Dolayısıyla, modelin bu günlerdeki başarısını artırmak için modele girdi olarak futbol maçı olup olmadığı bilgisinin yanında satılan bilet bilgisi veya tahmini seyirci bilgisi verilebilir. Böylelikle model, etkinliğe katılacak olan seyirci sayısına göre değerlendirme yaparak daha başarılı seyahat sayısı tahmininde bulunabilir.

Beşiktaş Stadyumu’na M2 metro hattının Taksim istasyonundan ulaşım sağlanabilmektedir. Ancak Tablo 4.12 incelendiğinde etkinlik değişkeninin eklenmesiyle modelin Taksim istasyonundaki tahmininde belirgin bir iyileşme görülememiştir. Şekil 4.1 incelendiğinde, Beşiktaş Stadyumu’nda futbol maçı olan günlerde Taksim istasyonuna olan seyahat talebinde Seyrantepe istasyonundakine benzer düzeyde bir artış görülmemiştir. Bu durumun sebepleri olarak şu yorumlar yapılabilir. Yolcular indikleri değil bindikleri istasyonlarda ücret toplama sistemi için ulaşım kartlarını kullanmaktadır. Dolayısıyla seyahatin bittiği değil başladığı istasyonlar ile ilgili veriler bulunmaktadır. Beşiktaş Stadyumu ile Taksim istasyonu arasındaki mesafe yaklaşık 1,3 km, rakım farkı ise yaklaşık 83 m’dir. Dolayısıyla futbol maçı sonrası seyirciler yokuş yukarıya yürümeyi tercih etmeyip farklı ulaşım türlerini kullanmaya eğilimli olabilir. Ancak, Seyrantepe istasyonu için böyle bir seçenek söz konusu değildir. Seyircilerin futbol maçı sonrasında ağırlıklı olarak Seyrantepe istasyonundan M2 metro hattını kullanarak ulaşımını sağladıkları görülmektedir.

5.5 Çalışmanın Kısıtları

Bu çalışmanın en büyük kısıtı bütünüyle tam bir yıllık test seti ile test edilememiş olması olarak değerlendirilebilir. Bu çalışmaya başlanmadan önce 2018 yılı verileri kullanılarak modeli eğitmek, 2019 yılı verilerinin tamamını kullanarak modeli test etmek hedeflenmiştir. Böylece, bir yıllık veri tümüyle tahmin modellerini test etmek için kullanılabilmesi için tüm değişkenlerin model performanslarına olan etkilerini çok daha iyi bir şekilde ortaya koymak hedeflenmiştir. Ancak, 2018 yılının verilerine ulaşamaması ve 2020 yılının büyük bir kısmının Covid – 19 pandemisi etkisinde geçmesinden dolayı 2019 yılı verileri ile model eğitilip 2020 yılının ilk 70 gününün verileri ile test edilmiştir. Eğitim ve test veri setlerinin ayrılmasında yaygın uygulama %80 eğitim – %20 test şeklinde kullanılmasıdır. Bu çalışmada 2020 yılı içerisinde 10 Mart tarihine kadar olan veri test için kullanılabilmiş ve böylece eğitim verilerinin tüm veri seti içerisindeki oranı %84, test verilerinin tüm veri seti içerisindeki oranı ise %16 olmuştur. M2 metro hattı üzerinde 16 istasyon olduğu, her bir istasyon için 70 günlük tahmin yapıldığı değerlendirildiğinde, modellerin genel başarısı, yapılan 1120 tahmin üzerinden değerlendirilmiştir. %16'lık test seti verisi oranı ve yapılan tahmin sayısı model başarısını değerlendirmek için yeterlidir. Ancak, tahmin modelinin bir yıllık verinin bütünü ile test edilemiyor olması bazı değişkenlerin etkisinin açıkça gözlemlenememesi ve modelin farklı mevsimlerde nasıl performans gösterdiğinin incelenememesi gibi kısıtlara sebep olmuştur.

6. SONUÇ

Bu tez çalışması kent içi toplu taşıma sistemlerinin dinamik bir şekilde yönetilmesi, planlanması ve operasyonel kararların alınması için çıktılar sunmaktadır. Bu çalışma, metro hatlarına olan talebi etkileyen çeşitli faktörlerin anlaşılmasına fayda sağlamakta, bu faktörlerin seyahat talebi tahmini için nasıl kullanılabileceğini ortaya koymaktadır. Ayrıca, derin öğrenme yöntemlerinin kapsamlı değişkenlerle birlikte oldukça başarılı seyahat talebi tahmini yapma konusundaki potansiyelinin ortaya koyulmasına olanak sağlamıştır. Çalışmanın sonuçları, hangi faktörlerin raylı sistemlerdeki talebi nasıl etkilediğini ve hangi yöntemlerin daha doğru tahminler yapabildiğini ortaya koyarak, başarılı seyahat tahmin modeli geliştirme konusunda literatüre katkı sunmuştur. Çalışma çıktılarının bu bölümde yapılacak olan uygulama ve iyileştirme önerileri çerçevesinde, gerçek hayat uygulamalarında kullanılması durumunda, kaynakların daha etkili kullanılmasına ve hizmet kalitesinin artırılmasına yardımcı olacağı düşünülmektedir.

Bu çalışmadan elde edilen başlıca bulgular şunlardır:

- Seyahat talebini etkileyen anlamlı değişkenler kullanılarak, haftanın günlerine göre hesaplanan ortalama seyahat sayılarından çok daha iyi seyahat talep tahmini yapan modeller geliştirmek mümkündür.
- Yakın geçmişte gerçekleşen seyahat talebi ile yakın gelecekte gerçekleşecek olan seyahat talebi arasında bir ilişki bulunmaktadır.
- “Hava durumu, haftanın günü, okulların ve üniversitelerin ders döneminde olup olmaması, günün bayram veya farklı bir özel durum sebebi ile resmî tatil olup olmaması, kentte yüksek katılımı gerçekleştirecek olan bir etkinliğin olup olmaması gibi değişkenler toplu taşıma sistemlerine olan (bu örnekte metro sistemi) talebi etkilemektedir.
- Sadece geçmiş seyahat talebi verileri veya sadece “Hava Durumu”, “Haftanın Günü”, “Eğitim”, “Tatil” ve “Etkinlik” gibi dışsal faktör verileri kullanılarak geliştirilen seyahat talebi tahmin modellerinin başarıları yüksek olmamıştır.

- Geçmiş seyahat talebi verileri ve dışsal faktör verilerinin bir arada kullanılmasıyla geliştirilen hibrit modellerin seyahat talebi tahmin başarılarının diğer modellere göre belirgin derecede daha başarılı olduğu görülmüştür.
- Geliştirilen modeller arasında LSTM – ANN ve LSTM – CNN hibrit modellerinin tahmin başarılarının birbirlerine oldukça yakın olduğu görülmüştür. LSTM – CNN hibrit modelindeki CNN katmanının istenen etkiyi yaratamadığı belirtilmiştir. Değişkenlerin modellerin tahmin başarıları üzerindeki etkileri LSTM – ANN hibrit modeli üzerinden test edilmiştir.
- İçinde bulunan ay değişkeninin geliştirilen modelin tahmin başarısına olumsuz etki yaptığı görülmüş ve modelin aşırı uyum sorunuyla karşılaşmış olabileceği değerlendirilmiştir. Bunun sebebi olarak, eğitim sürecinde modelin farklı değişkenlerin etkilerini ay değişkeni üzerinden yorumluyor olabilmesi gösterilmiştir.
- Dışsal faktör değişkenlerinin tahmin modellerine dahil edilmesinin tahmin başarısına olumlu etki yaptığı tespit edilmiştir.
- “Eğitim” değişkenlerinin tahmin modellerine dahil edilmesinin Vezneciler ve İTÜ – Ayazağa istasyonlarındaki tahmin başarılarını belirgin biçimde olumlu etkilediği gösterilmiş ve açıklanmıştır.
- “Etkinlik” değişkenlerinin modele dahil edilmesinin Seyrantepe istasyonundaki tahmin başarılarını belirgin biçimde olumlu etkilediği gösterilmiş ve açıklanmıştır.
- “Tatil” değişkeninin etkisinin her istasyon için farklı olduğu Taksim istasyonundaki 1 Ocak 2020 tarihi için tahmin edilen seyahat talebi ile gerçekleşen seyahat talebi verileri üzerinden örnek verilerek açıklanmıştır.

Bu çalışmadan elde edilen çıktılar gerçek dünyada dinamik olarak bazı operasyonel kararların alınmasına katkıda bulunabilir. Bu çalışmanın amacı istasyonlardaki günlük toplam gerçekleşecek seyahat sayısını tahmin eden bir model geliştirmektedir. Tahmin edilen günlük talep gün içerisindeki saatlere göre ağırlıklandırılarak saatlik bazda talep kestiriminde bulunulabilir. Böylece bu çalışmanın çıktıları statik sefer tablolarını kullanmak yerine her gün için talebe göre değişen dinamik sefer tablolarının oluşturulmasına olanak tanıyabilir. İstanbul’da

bazı metro hatlarında dört vagonlu trenler ve sekiz vagonlu trenler karma olarak kullanılmaktadır. Geliştirilen talep tahmin modelinden faydalanılması durumunda, dört ve sekiz vagonlu trenlerin hizmet sıklıkları ve saatleri beklenen talebe göre güncellenebilecektir. Ayrıca, yoğun talep olacağı tahmin edilen iki istasyon arasına ek seferler eklenerek seyahat talebi karşılanmaya çalışılabilir. Bu gibi gerçek hayat uygulamaları ile toplu taşıma sistemleri daha etkin bir şekilde yönetilebilir, kaynaklardan tasarruf sağlanabilir ve yolcu memnuniyeti artırılabilir.

Bu çalışmada belirtildiği üzere günlük bazda her istasyon için bir seyahat talebi tahmini yapılmaktadır. Literatürde saatlik bazda seyahat talebi tahmini yapan bazı çalışmalar da bulunmaktadır. Gelecek çalışma olarak hem günlük hem de saatlik seyahat talebi tahmini yapan bir çalışma yapılması önerilebilir. Tahmin edilen günlük seyahat sayılarının gün içerisindeki dağılımı da başarılı bir şekilde tahmin edilebilirse kaynakların verimli kullanılmasını ve yolcu memnuniyetinin artmasını sağlayacak olan operasyonel kararların etkileri daha başarılı olacaktır.

Hem günlük hem de saatlik tahmin yapan bir model geliştirildikten sonra, tahmin edilen gün içerisindeki operasyonel kararları alan bir algoritma geliştirilebilir. Bu algoritma, metro hattı içindeki tüm istasyonların seyahat taleplerini günlük ve gün içindeki dağılımı şeklinde girdi olarak alarak dinamik sefer tabloları, ek sefer önerileri gibi bazı çıktılar sunarak operasyonel kararlara destek olabilir. Bu algoritma yeterince geliştirilir ve sınırları belirlenirse bazı operasyonel kararlar dinamik ve otomatik hale getirilebilir.

Bu çalışmada geliştirilen beş modelden dördü mimarileri gereği en yakın günlük gelecek olan yarın için tahminler üretmektedir. Sadece ANN modeli daha uzun vadeli tahminler üretebilmektedir. ANN modelinin başarısı CNN ve LSTM modellerine oldukça benzer olsa da LSTM – ANN ve LSTM – CNN hibrit modellerinin başarılarına kıyasla daha geride kalmıştır. Hibrit modellerle de benzer değişkenler ve yöntemler kullanılarak daha uzak gelecek için tahmin üreten modellerin geliştirildiği bir çalışma daha uzun vadeli kararlar alma noktasında otoritelere yardımcı olabilir.

Bu çalışmada geliştirilen modellerden M2 metro hattının 16 istasyonunun tamamı için seyahat talebi tahmini yapılması istenmektedir. Ancak, her bir istasyon

için farklı modeller geliştirilmesi, belki farklı parametreler, farklı değişkenler hatta farklı teknikler kullanılması istasyon bazındaki tahmin başarısını artırabilir. Çünkü her istasyonun diğerlerinden farklı karakteristikleri bulunmaktadır ve istasyonlar özelinde geliştirilen tahmin modellerinin istasyonların karakteristik özelliklerini öğrenmesi tahmin başarısını olumlu etkileyebilir.

Toplu taşıma sistemlerini her gün yüz binlerce insan kullanmaktadır. Otomatik ücret toplama sistemi verileri bu sistemlere anlık olarak kaydedilmektedir. Dolayısıyla iyi kurgulanmış sistemlerden her an veri çekilebilir ve bu veri işlenebilir. Bir toplu taşıma sistemi için bir kere geliştirilen seyahat talebi tahmin modelini uzun süreler boyunca kullanmak da tahmin başarısını olumsuz etkileyebilir. Günümüz teknolojisinde güncel seyahat verilerine ulaşmanın oldukça kolay olması, ertesi günü tahmin etmek için kullanılacak olan tahmin modelinin her gün güncel verilerle yeniden eğitilebilmesine veya bir diğer deyişle kalibre edilebilmesine olanak tanır. Böylelikle tahmin modelinin sürekli güncel olması ve her zaman en iyi tahmin başarısını göstermesini sağlanabilir.

Bu tez çalışması, raylı sistemler özelinde, toplu taşıma sistemlerindeki talep tahminlerinde derin öğrenme tekniklerinin etkili kullanımını vurgulayarak literatüre katkılarda bulunmaktadır. Çeşitli değişkenlerin (hava durumu, kentteki etkinlikler, tatiller, haftanın günü vb.) tahmin modellerine etkisini ve tahmin modellerine nasıl entegre edilebileceğini sistematik bir şekilde inceleyerek, gerçek dünya koşullarında daha hassas tahminlerin elde edilebileceğini göstermektedir. Aynı zamanda, farklı veri türlerinin birleştirilmesiyle oluşturulan hibrit modellerin, tek tip veriye dayalı modellere göre daha iyi performans sergilediğini ortaya koymaktadır. Elde edilen tahmin sonuçlarının, operasyonel kararların alınmasında nasıl kullanılabileceğine dair öneriler sunmakta ve toplu taşıma sistemlerinin daha etkin yönetilmesi ve hizmet kalitesinin artırılmasına katkı sağlamaktadır. Sonuç olarak, bu çalışma literatüre toplu taşıma talebi tahmininde derin öğrenme modellerinin pratik uygulamaları konusunda rehberlik eden kapsamlı bir yaklaşım sunarak, gelecekteki benzer araştırmalara destek olacaktır.

KAYNAKLAR DİZİNİ

- Adu-Gyamfi, Y. O., Asare, S. K., Sharma, A., & Titus, T.** (2017). Automated vehicle recognition with deep convolutional neural networks. *Transportation Research Record*, 2645(1), 113-122. <https://doi.org/10.3141/2645-13>
- Bai, S., & Jiao, J.** (2021). Using Deep Learning to Understand Travel Demands in Different Urban Districts. *Transportation Research Record: Journal of the Transportation Research Board*, 2675(7), 117–128. <https://doi.org/10.1177/0361198121994582>
- Birgül, K., & Bertan, B.** (2009). Yapay Sinir Ağları İle Borsa Endeksi Tahmini. *İstanbul Üniversitesi İşletme Fakültesi İşletme İktisadı Enstitüsü Dergisi*, 63, 25–40.
- Chen, C., Liu, Z., Wan, S., Luan, J., & Pei, Q.** (2021). Traffic Flow Prediction Based on Deep Learning in Internet of Vehicles. *IEEE Transactions on Intelligent Transportation Systems*, 22(6), 3776–3789. <https://doi.org/10.1109/TITS.2020.3025856>
- Chen, Q., Song, X., Yamada, H., & Shibasaki, R.** (2016). Learning deep representation from big and heterogeneous data for traffic accident inference. *30th AAAI Conference on Artificial Intelligence, AAAI 2016*, 338–344.
- Dong, W., Li, J., Yao, R., Li, C., Yuan, T., & Wang, L.** (2016). Characterizing Driving Styles with Deep Learning. *ArXiv*.
- Dwivedi, K., Biswaranjan, K., & Sethi, A.** (2014). Drowsy driver detection using representation learning. *Souvenir of the 2014 IEEE International Advance Computing Conference, IACC 2014*, 995–999. <https://doi.org/10.1109/IADCC.2014.6779459>
- Euronews** (2020). *İstanbul Valiliği'nden 8 Mart kararı: Taksim'e çıkan yollar kapatıldı* | Euronews. <https://tr.euronews.com/2020/03/08/istanbul-valiliginden-8-mart-karar-taksime-cikan-yollar-kapatildi>

KAYNAKLAR DİZİNİ (devam)

- Fouladgar, M., Parchami, M., Elmasri, R., & Ghaderi, A.** (2017). Scalable deep traffic flow neural networks for urban traffic congestion prediction. *Proceedings of the International Joint Conference on Neural Networks, 2017-May*, 2251–2258. <https://doi.org/10.1109/IJCNN.2017.7966128>
- Fu, X., Wu, M., Ponnarasu, S., & Zhang, L.** (2023). A Hybrid Deep Learning Approach for Real-Time Estimation of Passenger Traffic Flow in Urban Railway Systems. *Buildings*, 13(6), 1514. <https://doi.org/10.3390/buildings13061514>
- Genders, W., & Razavi, S.** (2016). *Using a Deep Reinforcement Learning Agent for Traffic Signal Control*. 1–9. <http://arxiv.org/abs/1611.01142>
- Gokasar, I., & Timurogullari, A.** (2021). Real-Time Prediction of Traffic Density with Deep Learning Using Computer Vision and Traffic Event Information. *2021 International Conference on INnovations in Intelligent SysTems and Applications (INISTA)*, 1–5. <https://doi.org/10.1109/INISTA52262.2021.9548434>
- Goodfellow, I., Bengio, Y., & Courville, A.** (2016). *Deep Learning*. MIT Press.
- Güzel, H.** (2020). *R ve Python ile Sıfırdan Sinir Ağlarını (NNs) Anlama ve Kodlama*. <https://www.datascienceearth.com/r-ve-python-ile-sifirdan-sinir-aglarini-nns-anlama-ve-kodlama/>
- Han, Y., Wang, S., Ren, Y., Wang, C., Gao, P., & Chen, G.** (2019). Predicting station-level short-term passenger flow in a citywide metro network using spatiotemporal graph convolutional neural networks. *ISPRS International Journal of Geo-Information*, 8(6). <https://doi.org/10.3390/ijgi8060243>
- Huang, W., Song, G., Hong, H., & Xie, K.** (2014). Deep architecture for traffic flow prediction: Deep belief networks with multitask learning. *IEEE Transactions on Intelligent Transportation Systems*, 15(5), 2191–2201. <https://doi.org/10.1109/TITS.2014.2311123>

KAYNAKLAR DİZİNİ (devam)

- Jiang, W., Ma, Z., & Koutsopoulos, H. N.** (2022). Deep learning for short-term origin–destination passenger flow prediction under partial observability in urban railway systems. *Neural Computing and Applications*, 34(6), 4813–4830. <https://doi.org/10.1007/s00521-021-06669-1>
- Kiba-Janiak, M., & Witkowski, J.** (2019). Sustainable Urban Mobility Plans: How Do They Work? *Sustainability 2019, Vol. 11, Page 4605, 11(17)*, 4605. <https://doi.org/10.3390/SU11174605>
- Lai, Y. Wen, Wang, Y., Xu, X. Ying, Easa, S. M., & Zhou, X. Wei.** (2022). Hybrid models of subway passenger flow prediction based on convolutional neural network. *IET Intelligent Transport Systems*, 17(4), 716–729. <https://doi.org/10.1049/itr2.12298>
- Litman, T.** (2011). *Evaluating Public Transportation Health Benefits*. undefined-undefined. https://www.mendeley.com/catalogue/314a29e0-7875-3b57-b2c6-61f7afa742d5/?utm_source=desktop&utm_medium=1.19.8&utm_campaign=open_catalog&userDocumentId=%7B0815b7c0-6a7f-3aa2-b3ce-bc05994b3e8f%7D
- Liu, L., & Chen, R. C.** (2017). A Mrt daily passenger flow prediction model with different combinations of influential factors. *Proceedings - 31st IEEE International Conference on Advanced Information Networking and Applications Workshops, WAINA 2017*, 601–605. <https://doi.org/10.1109/WAINA.2017.19>
- Ma, X., Yu, H., Wang, Y., & Wang, Y.** (2015). Large-Scale Transportation Network Congestion Evolution Prediction Using Deep Learning Theory. *PLOS ONE*, 10(3), e0119044. <https://doi.org/10.1371/JOURNAL.PONE.0119044>
- McCulloch, W. S., & Pitts, W.** (1943). A logical calculus of the ideas immanent in nervous activity. *The Bulletin of Mathematical Biophysics 1943 5:4*, 5(4), 115–133. <https://doi.org/10.1007/BF02478259>

KAYNAKLAR DİZİNİ (devam)

- Moussa, G. S.** (2014). Vehicle Type Classification with Geometric and Appearance Attributes. *International Journal of Civil, Environmental, Structural, Construction and Architectural Engineering*.
- Nar, M. and Arslankaya, S.** (2022). Passenger demand forecasting for railway systems. *Open Chemistry*, 20(1), 105–119. <https://doi.org/10.1515/chem-2022-0124>
- Nguyen, H., Kieu, L. M., Wen, T., & Cai, C.** (2018). Deep learning methods in transportation domain: A review. *IET Intelligent Transport Systems*, 12(9), 998–1004. <https://doi.org/10.1049/iet-its.2018.0064>
- Noursalehi, P., Koutsopoulos, H. N., & Zhao, J.** (2022). Dynamic Origin-Destination Prediction in Urban Rail Systems: A Multi-Resolution Spatio-Temporal Deep Learning Approach. *IEEE Transactions on Intelligent Transportation Systems*, 23(6), 5106–5115. <https://doi.org/10.1109/TITS.2020.3047047>
- Nur YİĞİT, R. ve Haldenbilen, S.** (2021). *Kısa Zamanlı Trafik Tahmini ile Devre Süresi Optimizasyonu ve Gecikme Analizi* *. 627. <https://doi.org/10.18400/tekderg.713080>
- Polson, N. G., & Sokolov, V. O.** (2017). Deep learning for short-term traffic flow prediction. *Transportation Research Part C: Emerging Technologies*, 79, 1–17. <https://doi.org/10.1016/J.TRC.2017.02.024>
- Tang, Q., Yang, M., & Yang, Y.** (2019). ST-LSTM: A Deep Learning Approach Combined Spatio-Temporal Features for Short-Term Forecast in Rail Transit. *Journal of Advanced Transportation*, 2019. <https://doi.org/10.1155/2019/8392592>

KAYNAKLAR DİZİNİ (devam)

- Toqué, F., Côme, E., Mahrsi, M. K. El, & Oukhellou, L.** (2016). Forecasting dynamic public transport origin-destination matrices with long-short term memory recurrent neural networks. *IEEE Conference on Intelligent Transportation Systems, Proceedings, ITSC*, 1071–1076. <https://doi.org/10.1109/ITSC.2016.7795689>
- Van Der Pol, E.** (2016). *Deep Reinforcement Learning for Coordination in Traffic Light Control*. <https://www.researchgate.net/publication/315810688>
- Xiong, Z., Zheng, J., Song, D., Zhong, S., & Huang, Q.** (2019). Passenger Flow Prediction of Urban Rail Transit Based on Deep Learning Methods. *Smart Cities*, 2(3), 371–387. <https://doi.org/10.3390/smartcities2030023>
- Yang, H., Xie, K., Ozbay, K., Ma, Y., & Wang, Z.** (2018). Use of Deep Learning to Predict Daily Usage of Bike Sharing Systems. *Article Transportation Research Record*, 2672(36), 92–102. <https://doi.org/10.1177/0361198118801354>
- Yao, H., Wu, F., Ke, J., Tang, X., Jia, Y., Lu, S., Gong, P., Ye, J., & Li, Z.** (2018). Deep Multi-View Spatial-Temporal Network for Taxi Demand Prediction. *32nd AAAI Conference on Artificial Intelligence, AAAI 2018*, 2588–2595. <https://arxiv.org/abs/1802.08714v2>
- Yılmaz, A., & Kaya, U.** (2021). *Derin Öğrenme* (3rd ed.). Kodlab Yayın Dağıtım.
- Zhang, J., Che, H., Chen, F., Ma, W., & He, Z.** (2021). Short-term origin-destination demand prediction in urban rail transit systems: A channel-wise attentive split-convolutional neural network method. *Transportation Research Part C: Emerging Technologies*, 124. <https://doi.org/10.1016/j.trc.2020.102928>
- Zhang, J., Chen, F., Cui, Z., Guo, Y., & Zhu, Y.** (2021). Deep Learning Architecture for Short-Term Passenger Flow Forecasting in Urban Rail Transit. *IEEE Transactions on Intelligent Transportation Systems*, 22(11), 7004–7014. <https://doi.org/10.1109/TITS.2020.3000761>

KAYNAKLAR DİZİNİ (devam)

- Zhang, X., Wang, C., Chen, J., & Chen, D.** (2023). A deep neural network model with GCN and 3D convolutional network for short-term metro passenger flow forecasting. *IET Intelligent Transport Systems*. <https://doi.org/10.1049/itr2.12352>
- Zhang, Y., Sun, K., Wen, D., Chen, D., Lv, H., & Zhang, Q.** (2023). Deep Learning for Metro Short-Term Origin-Destination Passenger Flow Forecasting Considering Section Capacity Utilization Ratio. *IEEE Transactions on Intelligent Transportation Systems*. <https://doi.org/10.1109/TITS.2023.3266371>
- Zhao, Z., Chen, W., Wu, X., Chen, P. C. Y., & Liu, J.** (2017). LSTM network: a deep learning approach for short-term traffic forecast. *IET Intelligent Transport Systems*, 11(2), 68–75. <https://doi.org/10.1049/IET-ITS.2016.0208>
- Zheng, H., Chen, J., Huang, Z., Yang, K., & Zhu, J.** (2022). Short-Term Online Forecasting for Passenger Origin–Destination (OD) Flows of Urban Rail Transit: A Graph–Temporal Fused Deep Learning Method. *Mathematics*, 10(19). <https://doi.org/10.3390/math10193664>
- Zheng, H., Lin, F., Feng, X., & Chen, Y.** (2020). A Hybrid Deep Learning Model With Attention-Based Conv-LSTM Networks for Short-Term Traffic Flow Prediction. *IEEE Transactions on Intelligent Transportation Systems*, 1–11. <https://doi.org/10.1109/TITS.2020.2997352>
- Zhou, Y., & Cheung, N.-M.** (2016). Vehicle Classification using Transferable Deep Neural Network Features. *ArXiv*.
- Zhu, H., Yang, X., & Wang, Y.** (2018). Prediction of Daily Entrance and Exit Passenger Flow of Rail Transit Stations by Deep Learning Method. *Journal of Advanced Transportation*, 2018. <https://doi.org/10.1155/2018/6142724>

TEŞEKKÜR

Tez çalışmam süresince desteklerini esirgemeyen, samimi ilgi, rehberlik ve değerli görüşleri ile bana yol gösteren tez danışmanım Doç. Dr. Yalçın ALVER'e, çalışmamı detaylıca inceleyen ve önerileriyle destekleyen Dr. Öğr. Üyesi Mehmet Metin MUTLU'ya, tezimi metinsel anlamda kontrol eden ve tez sürecimde bana hep destek olan Fulya ÜNALP'e, tezin basımı ve diğer prosedürler konusunda bana yardımcı olan Burak GÜLŞEN'e, İnşaat Mühendisliği Anabilim Dalı'ndaki yüksek lisans eğitimim süresince aldığım derslerde değerli bilgi birikimlerini paylaşan ve rehberlik eden hocalarıma, eğitimim boyunca beraber çalışmaktan ve zaman geçirmekten çok keyif aldığım çalışma grubu arkadaşlarıma, öğrenim gördüğüm süre boyunca bana sunduğu akademik ve sosyal imkanları için Ege Üniversitesi'ne gönülden teşekkür ederim.

Tez çalışmamda kullandığım verileri sağlayarak bu çalışmaya katkıda bulunan İstanbul Büyükşehir Belediyesi Ulaşım Daire Başkanlığı'na, Metro İstanbul'a ve çalışanlarına teşekkürü borç bilirim.

Bu süreçteki zorlu yolculuğumda yanımda olan, desteklerini hiçbir zaman esirgemeyen aileme ve sevdiklerime de en derin şükranlarımı sunarım.

19/09/2023

Halil Uğur ERCAN

ÖZGEÇMİŞ

Halil Uğur ERCAN ilk ve orta öğrenim eğitimlerini ülkemizin küçük turizm kentlerinin birisi olan Didim'de aldı. 2014 yılında yüksek öğrenimine başlamak amacıyla büyüdüğü kentten ayrılarak ülkemizin başkenti Ankara'ya yerleşti. Beş buçuk senesini geçirdiği Hacettepe Üniversitesi'nden İnşaat Mühendisliği lisans derecesinin yanında birçok farklı tecrübeyle ayrıldı. Üniversite yaşamı süresince çok sevdiği üniversitesinin sunduğu imkanlardan sonuna kadar faydalanmak isteyen ERCAN, üniversitesinin iletişim koordinatörlüğünde bir buçuk sene yarı zamanlı olarak çalıştı, üniversitesindeki en büyük öğrenci etkinliklerinin organizasyon süreçleri içerisinde bulundu, birisi Polonya'da diğeri ise Avusturya'da olmak üzere Erasmus+ Öğrenim ve Staj hareketliliklerinden birer kere faydalanarak ilk yurt dışı deneyimlerini kazandı. 2020 yılında uzmanlaşmak istediği Ulaştırma Mühendisliği alanında Ege Üniversitesi'nde yüksek lisans eğitimine başladı ve 2022 yılına kadar Ege Üniversitesi Ulaşım Planlama Laboratuvarı'nda yürütülen akademik çalışmalara katkıda bulundu. Yüksek lisans eğitimini 2023 yılında tamamlayan ERCAN, bugün itibariyle 2022 yılında profesyonel iş hayatına ilk adımını attığı Haritaevi Havacılık şirketinin İstanbul ofisinde Havacılık Emniyeti Uzman Yardımcısı pozisyonunda çalışmalarını sürdürmektedir.