

T.C.
BANDIRMA ONYEDİ EYLÜL ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

YÜKSEK LİSANS TEZİ

KENT İÇİ YOLCU TAŞIMACILIĞINDA AKILLI ULAŞIM SİSTEMLERİ
UYGULAMALARI

ECE SEMA KORKMAZ

Akıllı Ulaşım Sistemleri ve Teknolojileri Anabilim Dalı

ŞUBAT 2022

T.C.
BANDIRMA ONYEDİ EYLÜL ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

YÜKSEK LİSANS TEZİ

KENT İÇİ YOLCU TAŞIMACILIĞINDA AKILLI ULAŞIM SİSTEMLERİ
UYGULAMALARI

ECE SEMA KORKMAZ

DANIŞMAN
Dr. Öğr. Üyesi Serhat Berat Efe
II.DANIŞMAN
Dr. Öğr. Üyesi İlyas Özer

Akıllı Ulaşım Sistemleri ve Teknolojileri Anabilim Dalı

ŞUBAT 2022

ONAY

Ece Sema Korkmaz tarafından hazırlanan “**Kent İi Yolcu Taşımacılığında Akıllı Ulaşım Sistemleri Uygulamaları**” adlı tez çalışması .../.../...tarihinde yapılan sınavla aşığıdaki jüri tarafından oybirliğı/oyçokluğu ile Bandırma Onyedı Eylöl Üniversitesi Fen Bilimleri Enstitüsü Akıllı Ulaşım Sistemleri ve Teknolojileri Anabilim Dalı’nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Jüri Üyeleri

İmza

(Danışman)

(Üye)

(Üye)

Bu tezin kabulü, Fen Bilimleri Enstitüsü Yönetim Kurulu’nun .../.../...gün ve .../... sayılı kararı ile onaylanmıştır.

Enstitü Müdürü

BANDIRMA ONYEDİ EYLÜL ÜNİVERSİTESİ FEN BİLİMLERİ ENSTİTÜSÜ
YÜKSEK LİSANS TEZ ÇALIŞMASI
ETİK BEYANI

Bandırma Onyedi Eylül Üniversitesi Fen Bilimleri Enstitüsü tez yazım kılavuzuna göre hazırlamış olduğum “**Kent İçi Yolcu Taşımacılığında Akıllı Ulaşım Sistemleri Uygulamaları**” adlı tezimin özgün bir çalışma olduğunu, tez hazırlanırken tüm aşamalarda bilimsel etik ilkelerine uygun davrandığımı, tez kapsamında sunulan tüm verileri bilimsel etik ilkelerine uygun elde ettiğimi, tezde faydalandığım tüm eserlere atıf yaptığımı ve kaynaklar kısmında bu eserleri gösterdiğimi beyan ederim. 17/02/2022

Ece Sema KORKMAZ

ÖNSÖZ

Son yıllarda teknolojinin hızla gelişmesi ve dünyada nüfusun hızlı bir şekilde artmasıyla birlikte kentlerin değişim ve dönüşüme uğraması kaçınılmaz olmuştur. Yaşanan bu değişim ve dönüşümler ise kentlerde ekonomik, sosyal ve çevresel sorunların ortaya çıkmasına sebep olmaktadır. Özellikle kentsel alanlarda hızla artan nüfus başta ulaşım sektörü olmak üzere çeşitli alanlarda sorun olarak karşımıza çıkmaktadır. Ulaşım sisteminde yaşanan zaman kayıpları, yakıt tüketimi, karbon salınımı, trafik sıkışıklıkları vb. sorunların çözüm noktasında ise akıllı ulaşım sistemleri kullanılmaktadır. Akıllı Ulaşım Sistemleri gelişen bilgi ve iletişim teknolojileri aracılığıyla insanların kentsel alanlarda yaşadığı ulaşım sorunlarını minimize etmek ve hatta ileri zamanlarda ulaşımında yaşanacak sorunları önceden tahmin edip önlemler alma noktasında çözümler sunmaktadır. Akıllı Ulaşım Sistemleri bu sorunlara ilişkin çözümler sunarken elde edilen verilerin çok büyük boyutlarda ve karmaşık yapıya sahip olması ve klasik yöntemlerle çözüm sunulmasının zor olması nedeniyle yapay zekâ, makine öğrenmesi ve derin öğrenme yöntemlerinden faydalanmaktadır. Böylece elde edilen büyük verilerin analiz edilmesi sürecinde hem daha fazla hem de daha doğru çözüm alternatifleri sunmaktadır. Aynı zamanda verilerin işleme süreçleri de kısaltmaktadır.

Bu tez çalışması sırasında, tez konusunun belirlenmesinden başlayarak son aşamaya kadar her konuda benden yardımlarını esirgemeyen danışman hocalarım Sayın Dr. Öğr. Üyesi Serhat Berat EFE ve Dr. Öğr. Üyesi İlyas ÖZER'e şükranlarımı sunarım.

Yüksek lisans serüvenime başlamanın konusunda beni cesaretlendiren ve bu süreçte her daim yanımda olan eşim Muhammet Oğuz KORKMAZ'a, hayatım boyunca hep yanımda olan annem, babam ve kardeşime teşekkür ederim.

Tez çalışması kapsamında kullanılan verileri sağladıkları için Bursa Ulaşım Toplu Taşıım İşletmeciliği Turizm Sanayi ve Ticaret A.Ş.'ye teşekkür ederim.

Ayrıca bu tez çalışmasında BAP-20-1010-002 numaralı proje kapsamında verdikleri desteklerden dolayı Bandırma Onyedil Eylül Üniversitesi Bilimsel Araştırma Projeleri Birimi'ne teşekkür ederim.

ÖZET

YÜKSEK LİSANS TEZİ

KENT İÇİ YOLCU TAŞIMACILIĞINDA AKILLI ULAŞIM SİSTEMLERİ UYGULAMALARI

Ece Sema KORKMAZ

Bandırma Onyedi Eylül Üniversitesi

Fen Bilimleri Enstitüsü

Akıllı Ulaşım Sistemleri ve Teknolojileri Anabilim Dalı

Danışman: Dr. Öğr. Üyesi Serhat Berat EFE

İkinci Danışman: Dr. Öğr. Üyesi İlyas ÖZER

Şubat 2022, 78 sayfa

Bugün gelişmiş ülkeler başta olmak 1960'lı yıllardan beri birçok ülkede Akıllı Ulaşım Sistemleri konusunda hızla çalışmalar yapılmakta ve politikalar geliştirilmektedir. Akıllı Ulaşım Sistemleri Japonya, Amerika, Avustralya gibi gelişmiş ülkelerde başlamıştır ancak teknolojik gelişmelerin de etkisiyle günümüzde Hollanda, Singapur, Almanya, Güney Kore, İngiltere gibi ülkeler de Akıllı Ulaşım Sistemleri konusunda çalışmalar yürütmektedir. Tüm dünyada yaşanan teknolojik gelişmelerin etkisiyle Akıllı Ulaşım Sistemleri önemli bir pazar alanı oluşturmuştur ve bu da ülkeler arasında rekabet ortamı oluşmasına sebep olmuştur.

Bu çalışmada, toplu ulaşım araçlarıyla erişim konusunda yaşanan problemlerin minimize edilmesi amacıyla akıllı ulaşım sistemleri teknolojileri ve yapay zekâ teknolojileri birlikte kullanılmıştır. Bu kapsamda öncelikle BURULAŞ'tan alınan ve 2019 yılı ocak ve haziran ayları arasında gerçekleşen yolculukları kapsayan veriler büyük boyutlu veriler Microsoft SQL Server ve Spyder programları aracılığıyla analiz edilmiştir. Bu kapsamında 2019 yılı ocak ve haziran ayları içerisinde gerçekleşen Bursa Uludağ Üniversitesi varışlı yolculuklar bilet ve hat tiplerine göre belirli takvim günleri baz alınarak ay, gün, saat kriterlerine göre analiz edilmiştir. Analiz

sonucunda hangi hattı en çok hangi bilet tipinin hangi zamanda kullandığı bilgisi elde edilmiştir. Elde edilen bu farklı hat ve bilet tiplerine ait yolcu sayısı verileri, Spyder aracılığıyla yolcu sayısı tahmini (forecasting) yapmak için kullanılmıştır. Böylelikle Bursa Uludağ Üniversitesi varışlı istenilen otobüs hatlarına ait farklı zamanlardaki yolcu sayısı tahminleri elde edilmiştir.

Anahtar Kelimeler: Ulaşım, Trafik, Akıllı Ulaşım, Akıllı Ulaşım Sistemleri, Teknoloji, Yapay Zekâ, Makine Öğrenmesi



ABSTRACT

M.Sc. THESIS

APPLICATIONS OF INTELLIGENT TRANSPORTATION SYSTEMS IN URBAN PASSENGER TRANSPORTATION

Ece Sema KORKMAZ

**Bandırma Onyedi Eylül University
Graduate School of Natural and Applied Sciences
Department of Intelligent Transportation Systems and Technologies**

Supervisor: Asst. Prof. Dr. Serhat Berat EFE

Co-Supervisor: Asst. Prof. Dr. İlyas ÖZER

February 2022, 78 pages

Today, especially in developed countries, since the 1960s, studies have been carried out on Intelligent Transportation Systems and policies have been developed in many countries. Intelligent Transportation Systems started in developed countries such as Japan, America, Australia, but with the effect of technological developments, countries such as the Netherlands, Singapore, Germany, South Korea and England are also working on Intelligent Transportation Systems. With the effect of technological developments all over the world, Intelligent Transportation Systems has created an important market area and this has led to a competitive environment between countries.

In this study, smart transportation systems technologies and artificial intelligence technologies were used in order to minimize the problems experienced in accessing by public transportation vehicles. In this context, first of all, the data taken from BURULAŞ and covering the journeys between January and June 2019, were analyzed through Microsoft SQL Server and Spyder programs. In this context, the journeys arriving at Bursa Uludağ University in January and June 2019 were analyzed according to the criteria of month, day and hour, based on certain calendar days according to ticket and line types. As a result of the analysis, the information on

which line is used the most and which ticket type at which time was obtained. The passenger number data of these different lines and ticket types were used to forecast through Spyder. Thus, estimates of the number of passengers at different times of the desired bus lines arriving at Bursa Uludağ University were obtained.

Keywords: Transportation, Traffic, Intelligent Transportation, Intelligent Transportation Systems, Technology, Artificial Intelligence, Machine Learning



İÇİNDEKİLER

ÖZET	I
ABSTRACT	III
İÇİNDEKİLER.....	V
ŞEKİL LİSTESİ	VII
TABLO LİSTESİ.....	IX
SİMGE VE KISALTMA LİSTESİ.....	XI
1. GİRİŞ.....	1
2. BURSA KENT İÇİ TOPLU ULAŞIM ALTYAPISI.....	9
2.1. LASTİK TEKERLEKLİ TOPLU TAŞIMA SİSTEMLERİ.....	9
2.1.1. Belediye Otobüs Hatları.....	10
2.1.2. Özel Halk Otobüsü Hatları.....	11
2.1.3. Alt İşletme Hatları.....	11
2.1.4. İlçe Hatları	11
2.2. RAYLI TOPLU TAŞIMA SİSTEMLERİ.....	12
2.2.1. Hafif Raylı Sistem.....	12
2.2.2. Tramvay Hattı	14
2.3. ARA TOPLU TAŞIMA SİSTEMLERİ	15
2.3.1. Minibüs.....	15
2.3.2. Taksi Dolmuş	16
2.3.3. Servis.....	16
2.3.4. Taksi.....	16
3. AKILLI KART VERİLERİ İLE BURSA KENT İÇİ YOLCU TAŞIMACILIĞI ANALİZ VE YÖNTEMLERİ	17
3.1. AMAÇ VE KAPSAM	17
3.2. VERİLERİN ANALİZ EDİLMESİ VE MODEL KURGUSU.....	17
3.2.1. Derin Öğrenme-Yapay Sinir Ağları Tarihçesi.....	18

3.2.2. Derin Öğrenme-Yapay Sinir Ağlarının Yapısı, Özellikleri ve Kullanım Alanları.....	21
3.2.3. Derin Öğrenme Mimarisi.....	23
3.2.4. Verilerin Analiz Edilmesi ve Model Kurgusu.....	33
4. AKILLI KART VERİLERİ İLE TOPLU TAŞIMA SİSTEMİ YOLCU SAYISI TAHMİNİNE DAYALI MODELİN UYGULANMASI	46
4.1. UZUN-KISA DÖNEMLİ BELLEK (LSTM) VE KAPILI TEKRARLAYAN BİRİM (GRU) MODELLERİNİN UYGULANMASI	47
4.2. DEĞERLENDİRME	62
5. SONUÇ VE ÖNERİLER	66
6. KAYNAKLAR.....	68

ŞEKİL LİSTESİ

<u>Sekil</u>	<u>Sayfa</u>
Şekil 2-1: Bursa ili belediye otobüs hatları.....	11
Şekil 2-2: BursaRay yıllara göre etap gelişimi.....	13
Şekil 2-3: BursaRay hat-1 ve hat-2 güzergahları.....	13
Şekil 2-4: T1 hattı tramvay güzergâhı	14
Şekil 2-5: T3 hattı tramvay güzergâhı	14
Şekil 2-6: Merkez kent minibüs hatları	15
Şekil 2-7: İlçelere göre tescilli S plaka dağılımı	16
Şekil 3-1: Yapay sinir hücresi yapısı.....	22
Şekil 3-2: Biyolojik sinir ağı hücresi	22
Şekil 3-3: LeNet ağı	23
Şekil 3-4: İki boyutlu evrişim işlemi	24
Şekil 3-5: Geleneksel RNN mimarisi örneği-1	25
Şekil 3-6: Geleneksel RNN mimarisi örneği-2	26
Şekil 3-7: Uzun-kısa süreli bellek mimarisi yapısı.....	27
Şekil 3-8: Tam kapılı GRU mimarisi	29
Şekil 3-9: Minimum kapılı GRU mimarisi.....	29
Şekil 3-10: Sınırlı boltzmann makinesi.....	30
Şekil 3-11: Boltzmann makinesi	30
Şekil 3-12: Derin inanç ağı modeli	31
Şekil 3-13: Art arda eklenmiş kısıtlanmış boltzmann makineleri (RMB).....	31
Şekil 3-14: Oto kodlayıcıların yapısı.....	32
Şekil 3-15: Derin oto-kodlayıcı yapısı	32
Şekil 3-16: Otobüs hatları kriterleri	33
Şekil 3-17: Hatlara ait yolcu sayılarının hesaplanması.....	34
Şekil 3-18: Verilerin güncellenmesi.....	35
Şekil 3-19: (a) ve (b) Güncellenen BursaKART verileri	36
Şekil 3-20: Hatlara göre toplam yolcu sayısı dağılımı.....	36
Şekil 3-21: B/24 numaralı hat güzergahı	37
Şekil 3-22: B/24 hattı yolcu sayısının aylara göre dağılımı.....	38
Şekil 3-23: B/24 hattı yolcu sayısının günlere göre dağılımı.....	39

Şekil 3-24: B/24 numaralı hattın öğrenci sayısının günlere göre dağılımı	39
Şekil 3-25: 93 numaralı hat güzergahı.....	40
Şekil 3-26: 93 hattı yolcu sayısının aylara göre dağılımı.....	40
Şekil 3-27: B/44-B numaralı hat güzergahı	41
Şekil 3-28: B/44-B hattı yolcu sayısının aylara göre dağılımı.....	42
Şekil 3-29: 4/G numaralı hat güzergahı.....	43
Şekil 3-30: 4/G hattı yolcu sayısının aylara göre dağılımı	43
Şekil 3-31: 35/G numaralı hat güzergahı.....	44
Şekil 3-32: 35/G hattı yolcu sayısının aylara göre dağılımı	45
Şekil 4-1: B/24 tüm bilet tipleri için gerçek değerler ve tahmin değerleri	48
Şekil 4-2: B/24 tüm bilet tipleri eğitim ve test seti kayıpları.....	48
Şekil 4-3: B/24 tam bilet tipi için gerçek değerler ve tahmin değerleri	49
Şekil 4-4: B/24 tam bilet tipi eğitim ve test seti kayıpları	50
Şekil 4-5: B/24 öğrenci bilet tipi için gerçek değerler ve tahmin değerleri	51
Şekil 4-6: B/44-B tüm bilet tipleri için gerçek değerler ve tahmin değerleri	53
Şekil 4-7: B/44-B tüm bilet tipleri eğitim ve test seti kayıpları.....	53
Şekil 4-8: B/44-B tam bilet tipi için gerçek değerler ve tahmin değerleri	54
Şekil 4-9: B/44-B tam bilet tipi eğitim ve test seti kayıpları.....	55
Şekil 4-10: B/44-B öğrenci bilet tipi için gerçek değerler ve tahmin değerleri	56
Şekil 4-11: B/44-B öğrenci bilet tipi eğitim ve test seti kayıpları.....	56
Şekil 4-12: 4/G tüm bilet tipleri için gerçek değerler ve tahmin değerleri.....	57
Şekil 4-13: 4/G tüm bilet tipleri eğitim ve test seti kayıpları	58
Şekil 4-14: 4/G tam bilet tipi için gerçek değerler ve tahmin değerleri.....	60
Şekil 4-15: 4/G tam bilet tipi eğitim ve test seti kayıpları	60
Şekil 4-16: 4/G öğrenci bilet tipi için gerçek değerler ve tahmin değerleri.....	61
Şekil 4-17: 4/G öğrenci bilet tipi eğitim ve test seti kayıpları	62
Şekil 4-18: Çalışmanın aşamaları.....	63

TABLO LİSTESİ

<u>Tablo</u>	<u>Sayfa</u>
Tablo 2-1: Bursa ili Karayolları 14. Bölge Müdürlüğü sorumluluğundaki yollar	9
Tablo 2-2: Lastik tekerlekli toplu taşıma sistemleri hat ve araç sayısı	10
Tablo 2-3: İlçelere ait hat ve araç sayıları.....	12
Tablo 3-1: Biyolojik sinir ağı ve yapay sinir ağı benzerlikleri	22
Tablo 3-2: Farklı programlarda yolcu sayısı	35
Tablo 3-3: Aylara göre yolcu sayısı dağılımı.....	37
Tablo 3-4: B/24 numaralı hat bilet tiplerine ve aylara göre yolcu sayısı.....	38
Tablo 3-5: 93 numaralı hat bilet tiplerine ve aylara göre yolcu sayısı.....	41
Tablo 3-6: B/44-B numaralı hat bilet tiplerine ve aylara göre yolcu sayısı.....	42
Tablo 3-7: 4/G numaralı hat bilet tiplerine ve aylara göre yolcu sayısı	44
Tablo 3-8: 35/G numaralı hat bilet tiplerine ve aylara göre yolcu sayısı	45
Tablo 4-1: Metrik değerler ve formülleri	46
Tablo 4-2: Farklı başlangıç değerleriyle B/24 Hattı tüm bilet tiplerinin RMSE VE MAE değerleri.....	47
Tablo 4-3: Farklı başlangıç değerleriyle B/24 hattı tam bilet tipi RMSE VE MAE değerleri	49
Tablo 4-4: Farklı başlangıç değerleriyle B/24 hattı öğrenci bilet tipi RMSE VE MAE değerleri.....	51
Tablo 4-5: Farklı başlangıç değerleriyle B/44-B hattı tüm bilet tiplerinin RMSE VE MAE değerleri.....	52
Tablo 4-6: Farklı başlangıç değerleriyle B/44-B hattı tam bilet tipi RMSE VE MAE değerleri.....	54
Tablo 4-7: Farklı başlangıç değerleriyle B/44-B hattı öğrenci bilet tipi RMSE VE MAE değerleri.....	55
Tablo 4-8: Farklı başlangıç değerleriyle 4/G hattı tüm bilet tiplerinin RMSE VE MAE değerleri.....	57
Tablo 4-9: Farklı başlangıç değerleriyle 4/G hattı tam bilet tipi RMSE VE MAE değerleri	59
Tablo 4-10: Farklı başlangıç değerleriyle 4/G hattı öğrenci bilet tipi RMSE VE MAE değerleri.....	61

Tablo 4-11: Hatlara ve bilet tiplerine ait en iyi RMSE ve MAE deęerleri.....	64
---	-----------



SİMGE VE KISALTMA LİSTESİ

Simgeler

σ	:Sigmoid
Σ	:Toplam Formülü

Kısaltmalar

Açıklama

AUS	: Akıllı Ulaşım Sistemleri
APC	: Automatic Passenger Counting
AVL	: Automatic Vehicle Locating
BURULAŞ	: Bursa Ulaşım Toplu Taşıım İşletmeciliği Turizm Sanayi ve Ticaret A.Ş
CNN	: Convolutional Neural Networks
DBN	: Deep Belief Networks
DF	: Deficit Function
GA	: Genetic Algorithm
GB	: Gradyan Arttırma
GPS	: Küresel Konumlama Sistemi
GRU	: Gated Recurrent Unit
IEEE	: Institute of Electrical and Electronics Engineers
K-AUS	: Kooperatif Akıllı Ulaşım Sistemleri
LSTM	: Long Short-Term Memory
MIP	: Mixed Integer Program
MPC	: Model Predictive Control
NN	: Neural Network
NSGA	: Bastırılmamış Sınıflandırılmalı Genetik Algoritma
RMB	: Kısıtlanmış Boltzmann Makineleri
RNN	: Recurrent Neural Network
SAA	: Simulated Annealing Algorithm
SRN	: Simple Recurrent Network
TÜİK	: Türkiye İstatistik Kurumu
VNS	: Variable Neighborhood Search
XOR	: eXclusive OR

1. GİRİŞ

Günümüzde kentsel alanlardaki iş olanaklarının ve kentlerin sunduğu diğer imkanların fazla olması kentleri birer cazibe merkezi konumuna getirmektedir. Hem kentsel alanların sunduğu olanaklar hem de dünyada hızla artan nüfus kentsel alanlarda hızlı ve plansız bir büyüme gerçekleşmesine sebep olmaktadır. Bu alanlarda yaşanan hızlı ve plansız büyümenin çevresel, sosyal, ekonomik boyutlarda etkileri olmaktadır. Artan nüfusla birlikte bu boyutların neredeyse tamamını kapsayan ve en çok etkilenen yapılardan biri de ulaşım sistemleridir. Nüfusun artmasıyla birlikte kentlerdeki nüfus yoğunluğunun arttığı ve ulaşım ağları yetersiz kaldığı görülmektedir [1]. Kentlerde ulaşım sistemlerindeki etkiler başta araç ve yaya trafiği hareketliliği artışı olmak üzere pek çok şekilde karşımıza çıkmaktadır. Gerek toplu taşıma sistemlerinde meydana gelen yoğunluk artışı gerek özel araç sahipliğinde yaşanan artış miktarı trafik yoğunluğunun artmasına sebep olmaktadır. Bunun sonucunda yakıt tüketimi, karbon salınımı, trafik kazaları, araç bakım masrafları ve ulaşımında harcanan zaman miktarlarındaki artış vb. sorunlar ortaya çıkmaktadır. Kentlerde yaşanan bu vb. ulaşım sorunlarının önüne geçilmesi, akılcı ve kalıcı çözümler üreterek insanların yaşam standartlarının yükseltilmesi amacıyla bilgi ve iletişim alanında yaşanan teknolojik gelişmeler paralelinde akıllı ulaşım sistemlerinden faydalanılmaktadır. Akıllı Ulaşım Sistemleri (AUS); kentlerde artan hareketlilik sonucunda ortaya çıkan seyahat sürelerinin azaltılması, trafik güvenliğinin artırılması, mevcut yolların kapasitelerinin optimum kullanımı, mobilitenin artırılması, enerji verimliliğinin sağlanarak çevreye ve ülke ekonomisine zararın minimize edilmesi gibi amaçlar doğrultusunda kullanıcı-araç-altyapı ve yolcu arasında çok yönlü veri alışverişi ile gerçekleşen sistemler bütünüdür [2]. Akıllı Ulaşım Sistemleri olarak adlandırılan bu sistem halkın refah düzeyinin artırılması, verimli ve sürdürülebilir bir ulaşımın sağlanması için gerekli bir yapıdır. Akıllı Ulaşım Sistemleri mevcut kaynakların ve altyapının bilgi ve iletişim teknolojileri sayesinde en iyi şekilde kullanılarak yeni bir ulaşım planlaması yapılmasına olanak vermektedir [3]. AUS, bu anlamda zamanı ve enerjiyi verimli kullanarak ülke ekonomisine, çevreye ve toplum sağlığına vb. alanlara faydaları olan çok amaçlı bir sistemler bütünüdür [4]. Akıllı araçlar (akıllı navigasyon, sürücü destek sistemleri, otomatik park, otonom ve bağlantılı araçlar), akıllı yollar (akıllı kavşaklar, yeşil dalga, kameralar, algılayıcılar), akıllı şehirler (acil durum yönetimi, toplu ulaşım-filo yönetimi, akıllı otoparklar, güvenli erişilebilir ve kolay ulaşım), ekonomi ve çevre (akıllı enerji sistemleri, elektrikli araçlar, çevreye duyarlı ulaşım alt yapısı, insan faktörü), entegrasyon sistemleri (ulaşım kontrol merkezi, müşterek AUS yapısı, tüm ulaşım sistemleri için tek ödeme şekli, tüm ulaşım modlarının entegrasyonu), bilişim ve güvenlik (büyük

veri, veri güvenliği ve paylaşımı, siber güvenlik-blok zinciri, haberleşme sistemleri) bugün kullanılan ve gelecekte de kullanılacak Akıllı Ulaşım Sistemleri uygulamalarıdır [2]. Akıllı Ulaşım Sistemleri ile ilgili çalışmalar 1960'lı yıllarda başlayıp günümüzde hala devam etmektedir. Bu çalışmalar bugüne kadar ki tarihsel gelişimine göre 3 dönemde incelenmektedir. Birinci Dönem (1960-1974) akıllı ulaşım sistemlerine hazırlıkların yapıldığı, akıllı ulaşım sistemlerinin araştırma aşamasında olduğu dönemdir. Bu dönemde yapılan çalışmalarda verilerin toplanması ve işlenmesi için büyük işlem merkezleri gerektiği için bu sistemlerde hiçbir zaman pratik uygulama gerçekleştirememiştir [5]. İkinci Dönem (1980-1994) pratik uygulamaların kullanımı için araştırmaların hız kazandığı ve Avustralya, Japonya, Avrupa ve Amerika gibi ülkelerde Akıllı Ulaşım Sistemleri kapsamında çalışmaların yapılıp uygulamaya geçirildiği dönemdir. Bu dönemde aynı zamanda "Akıllı Ulaşım Sistemleri" kavramı ilk kez oluşmuştur [6], [7]. Üçüncü Dönem 1994 yılından günümüze kadar devam eden AUS'un halen sürdüğü dönemdir. Bu dönemde AUS'un araştırılması ve AUS'la ilgili çalışmalar yapmak amacıyla çeşitli kurumlar kurulup, topluluklar oluşturulmuştur. AUS'u daha ileriye taşımak için politikalar geliştirilmiştir ve uluslararası teknolojik gelişmelerin takip edilmesiyle AUS'ta gelişmeler devam etmektedir [7]. Tüm dünyada yaşanan bu gelişmeler ve teknolojinin de etkisiyle AUS önemli bir pazar alanı oluşturmuştur ve bu da ülkeler arasında rekabet ortamı oluşmasına sebep olmuştur. Ülkeler arası yaşanan bu rekabet AUS'a uluslararası bir boyut kazandırmıştır.

Bugün dünyada AUS'un ortak hedefleri arasında ulaşım sistemlerinde yaşanan sorunları önlemek amacıyla artış gösteren ulaşım hedefleri, ulaşım verimliliği ve enerji tasarrufları sağlanması, ulaşımın sebep olduğu çevresel etkilerin azaltılması noktasında mevcut altyapı ve arazi düzeninin dikkate alınarak orta ve uzun vadeli çözümler bulmak yer almaktadır [3]. Bunu yaparken de doğru tahminler yapan ve verimli çalışan bir trafik tahmin sistemine ihtiyaç duyulmaktadır. Bu trafik tahmin sistemi bünyesinde AUS, Haberleşme Teknolojileri, Algılama (Sensör) Teknolojileri ve K-AUS'dan (Kooperatif Akıllı Ulaşım Sistemleri) faydalanmaktadır. Teknolojinin gelişmesi ve akıllı telefon kullanımının yaygınlaşması sonucu geliştirilen mobil uygulamalar sayesinde paylaşımlı hareketlilik de AUS'ta popüler konular arasında yer almıştır. Paylaşımlı hareketlilik sayesinde trafik sıkışıklığı ve karbondioksit salınımında azalmalar olduğu ve şehir içi ulaşımın daha rahat gerçekleşeceği tespit edilmiştir [8]. AUS'un faydalandığı bu teknolojik yöntemler gelenekselden yöntemlerden farklı yöntemler ve bilgiler gerektirmektedir [9]. Çünkü algılayıcılardan, kameralardan, trafik yönetim merkezlerinden gelen veriler oldukça çeşitli, büyük hacimli ve karmaşık verilerdir. Bu büyük verilerin (Big Data) klasik yöntemlerle toplanması, saklanması ve analiz edilmesi oldukça güçtür. Bu nedenle en iyi trafik tahmin sistemini bulmak için Yapay Zekâ Teknolojilerinden (Artificial Intelligence) Makine Öğrenmesi

(Machine Learning) ve Derin Öğrenme (Deep Learning) teknikleri gibi farklı modeller kullanılmaktadır. Büyük verilerin bu teknikler ile işlenmesi sayesinde trafikte yaşanan problemlerinin çözülmesi, trafikteki davranışların önceden tahmin edilerek önlemler alınması mümkündür. Bu nedenle yapay zekâ teknolojilerinden makine öğrenmesi ve derin öğrenme teknikleri akıllı ulaşım sistemlerinin tasarlanmasında oldukça önemlidir.

Literatürde farklı trafik tahmin yöntemleri için yapılmış farklı çalışmalar bulunmaktadır. Bu çalışmalar, teknolojinin beraberinde getirmiş olduğu akıllı ulaşım sistemleri teknolojilerinden dolayısıyla akıllı sistemlerden ve yapay zekâ teknolojilerinden faydalanılarak tasarlanmıştır.

Örneğin; Nagy ve Simon çalışmalarında farklı veri kümelerine naive model, parametrik ve parametrik olmayan modeller uygulayarak farklı trafik tahmin sistemlerini denemişlerdir. Farklı veri kümeleriyle denenen her farklı modelin kendi içinde avantajları ve dezavantajları olduğunu belirlemişlerdir. Bu çalışmalar sonucunda mekân-zaman ilişkisi, dinamik trafik süreci ve çevresel faktörleri de içine aldığı için parametrik modellerin (Convolutional Neural Networks-CNN, Long Short-Term Memory-LSTM) en belirgin trafik tahmin sistemi modeli olduğunu tespit etmişlerdir [10].

Bir başka çalışmada Do vd. trafik tahmin sistemlerinin geliştirilmesi noktasında makine öğrenmesi yöntemlerinden biri olan NN (Neural Network) sistemine odaklanmışlardır. Trafik akışı içerisinde yer alan farklı değişkenleri NN modelleri ile deneyerek yüksek tahmin değerlerine ulaşmışlardır. NN modellerinin trafik tahmin sistemindeki avantajlarını ve dezavantajlarını ortaya koymuşlardır [11].

Diğer bir çalışmada Hindistan'ın Chennai kentinde GPS (küresel konumlama sistemi) cihazlarına sahip otobüslerden elde edilen seyahat süresi verileri analiz edilmiştir. Bu veriler üzerinden Derin öğrenme yaklaşımı, Uzun ve Kısa Dönemli Bellek (LSTM) ağları kullanılarak gerçek zamanlı bir otobüs seyahat süresi tahmin yöntemi geliştirilmiştir [12].

Bir başka çalışmada ise yine bir akıllı sistem yaklaşımı olan ve kısa vadeli seyahat süresi tahmin problemleri için yüksek başarımlı sonuçlar veren Gradyan Artırma (GB) yöntemi modifiye edilerek uzun vadeli tahmin için kullanılmıştır [13].

Toncharoen ve Piantanakulchai; Bangkok-Tayland otoyolunda sensörler aracılığıyla yolun belirli kısımlarına her 100 metre bir düğüm noktasına denk gelecek şekilde 40 düğüm noktası atayarak otoyol güzergahında yoğun saatlerde trafikten alınan verileri Evrişimli Sinir Ağı (CNN) modeli ile diğer trafik tahmin modellerini karşılaştırarak işlemişlerdir ve CNN modelinin diğer modellerden daha iyi bir performans elde ettiğini tespit etmişlerdir [14].

Pekin'de yapılan bir araştırmada Model Öngörülü Kontrol (MPC-Model Predictive Control) yöntemi ile gerçek zamanlı yolcu talepleri/beklentileri ve otobüs hattına ait gerçek

zamanlı veriler kullanılarak otobüs hareket saatlerini optimal düzeyde düzenleyerek yolcu varış oranı ve süresi, otobüs durma ve bekleme sürelerinde %33-%90 oranında iyileşme olduğu saptanmıştır [15].

Hollander ve Liu; seyahat süresi değişimlerinde rol oynayan hava durumu, sürücü davranışları, yolcu davranışları ve toplu taşıma sisteminden kaynaklanan belirsizlik vb. parametrelerin bir süre boyunca tekrarlandığı bir trafik simülasyon modelinin seyahat süresi dağılımına etkisini araştırıp ve aynı parametrelerle tekrarlanan bir trafik simülasyon modelinin çokta gerçekçi olmadığı ve parametre seçiminde kalibrasyon yapılması gerektiği sonucuna varmışlardır [16].

Fonzone vd.; duraklarda bekleyen yolcu sayısının farklı duraklar arasında ve farklı zamanlarda değişiklik gösterdiğini buna bağlı olarak da yolcu taleplerinin ve otobüslerin durağa varış sürelerinin değişebileceğini baz alarak “güvenilirliğe dayalı bir varış modeli” geliştirmişlerdir. Amaçları bekleme sürelerini en aza indirip yolcu ve otobüs demetlenmelerini engellemek olmuştur [17].

Watkins vd; toplu taşıma kullanan insanların toplu taşımadan duyulan memnuniyet düzeyini artırmak için yolculara durağa gelecek olan otobüsün varışıyla ilgili gerçek zamanlı bilgi vererek bekleme süresini azaltmayı amaçlamıştır. Seattle’da (ABD) yaptıkları çalışmayla gerçek zamanlı bilgilere sahip yolcuların geleneksel yöntemlerle ulaşmaya çalışan yolculara göre %30 daha az beklediklerini tespit etmişlerdir [18].

Gkiotsalitis ve Alesiani Singapur’da bir otobüs hattında yaptıkları çalışmada Otomatik Araç Yeri Belirleme (Automatic Vehicle Locating-AVL) ve Otomatik Yolcu Sayımı (Automatic Passenger Counting-APC) sistemlerini kullanarak seyahat süreleri ve yolcu talebi beklentilerine göre yaşanabilecek en kötü ulaşım senaryosunda olası zaman kayıplarını minimize etmeye çalışmışlardır. 5 aylık bir çalışma sonucu seyahat sürelerinde %6,87 oranında bir iyileşme yaşanmıştır [19].

Wang vd. farklı günlerde gerçekleşmiş olan seyahat verilerini (yolcu sayısı ve talepleri, otobüs sayısı ve hareket saatleri vb.) kullanarak farklı trafik simülasyon modelleri oluşturup buna bağlı olarak otobüs bekleme süresini büyük oranda azaltmaya yardımcı optimal bir model geliştirmişlerdir [20].

Qun Chen çalışmasında sefer sayıları bilinen bir otobüs hattını ele alarak yolcu yoğunluğunun önlenmesi ve yolcuların bekleme sürelerinin minimuma indirilmesi konusunda dinamik programlama algoritması tasarlayarak otobüs hareket saatlerini optimize edip yolcu bekleme sürelerinden tasarruf edileceğini ve bu algoritmanın küresel optimal çözüm sağladığını belirtmiştir [21].

Wihartiko ve arkadaşları tarafından Endonezya Bogor'da gerçekleştirilen bir çalışmada otobüs zaman çizelgesini optimize etmek amacıyla otobüs hareket saatleri, otobüs kapasitesi, yolcu sayısı, güzergah, yol durumu ve otobüs işletme maliyetlerini kriter olarak alan bir genetik algoritma modeli kullanarak %99,1 oranda doğruluk sağlayan bir model geliştirmişlerdir [22].

Tang ve arkadaşları otobüs hareket saatlerini optimize edip yolcuların toplam bekleme sürelerini azaltmak için Çin Pekin'de bir otobüs hattına ait verileri ve akıllı kart verilerini kullanarak Bastırılmamış Sınıflandırılmalı Genetik Algoritma (NSGA-II) yöntemi kullanarak gerçek zamanlı yolcu sayısını tahmin edip otobüs zaman çizelgelerini bu doğrultuda hazırlamışlardır [23].

Hongguang Ma ve arkadaşları Pekin'de Yuntong 128 otobüs hattı bilgileri, yolcuların konum ve akıllı kart verilerini kullanarak Tamsayı Doğrusal Programlama modeli aracılığıyla otobüs zaman çizelgesini optimize etmiştir ve yolcu talebinin ve otobüs yolcu yoğunluğunun karşılanması amacıyla 4 yeni hat daha eklenerek daha verimli bir hale getirmiştir [24].

Zhang ve arkadaşları otobüslere ait GPS (küresel konumlama sistemi) ve akıllı kart verileri ve yolcuların O-D yolculuk matrislerini iki aşamalı bir modelde girdi olarak kullanıp gerçek zamanlı yolcu akışını yüksek doğrulukla tahmin etmişlerdir [25].

Yang ve arkadaşları Çin Changsha kentinde gerçekleşen yolculuklara ait otobüs saati çizelgeleme problemi, otobüs kapasitesi, yolcu varış zamanı dağılımı ve gerçek seyahat süresi kriterlerini baz alarak Genetik Algoritma (GA-Genetic Algorithm) ve Tavlama Benzetimi Algoritmasının (SAA-Simulated Annealing Algorithm) birlikte kullanıldığı GASAA hibrit modeli oluşturarak otobüs zaman çizelgesini optimize etmiştir [26].

Wu ve arkadaşları mevcut yolcu sayısı ve mevcut otobüs hareket saatlerini kullanarak Bastırılmamış Sınıflandırılmalı Genetik Algoritma (NSGA-II) yöntemi ile otobüs hatlarına ait zaman çizelgesini optimize ederek yolcuların araç zamanlama sorunlarına çözüm getirmiştir [27].

Ceder ve arkadaşları, gereksiz araç kalkışlarını önlemek, sınırlı durma amacıyla hareket eden ve yolcu seyahat süresi değişikliklerini en aza indiren seyahat planlamak amacıyla Paris-Fransa'da Eksik Fonksiyon teorisini (DF-Deficit Function) kullanarak araç hareket planlaması çalışmasını optimize etmişlerdir. Bu sayede daha az araçla daha kısa süreli yolculuklar yapılarak yolculuk arz ve talepleri arasında uyum sağlanmıştır [28].

Liu ve Ceder Eksik Fonksiyon teorisi konusunda (DF-Deficit Function) geçen 50 yıl içerisindeki çalışmaları ele alarak toplu taşıma sistemleri planlamasında Eksik Fonksiyon teorisinin yolcu odaklı, sürdürülebilir ve toplu taşıma sistemleri planlaması için yeni gelişmeler vadettiğini belirtmişlerdir [29].

Mesa ve diğerleri, Kümeleme Algoritması (K-Means) ve P-Medyan Problemi (P-Median Problem) yöntemleriyle toplu taşıma hattı kullanıcıları odaklı otobüs hareket çizelgesi oluşturup, kullanıcı memnuniyetsizliklerini optimize etmişlerdir [30].

Varga ve diğerleri; toplu taşıma sistemlerinin trafikte yaşadığı etkileşimi dikkate alarak otobüs durağında bekleme ve varış sürelerini kısa zamanlı tahminler yaparak zaman-mekân kriterleri çerçevesinde Model Öngörülü Kontrol (MPC-Model Predictive Control) yöntemi ile optimal şekilde çözen çalışmalar yapmıştır [31].

Zuo ve diğerleri; Çin Nanjing’de toplu taşıma araç hareket zamanı düzenlemesi için bir dizi araç bloğu üreterek Bastırılmamış Sınıflandırılmalı Genetik Algoritma (NSGA-II) yöntemi ile Pareto Optimal çözüm yöntemleri geliştirmiştir [32].

Shui ve diğerleri; büyük kapasiteli otobüs zaman çizelgeleme problemlerini çözmek amacıyla Klonal Seçim Algoritması-KSA yöntemini kullanıp 1 dakika gibi bir sürede çok iyi zamanlama çözümleri sunan bir sistem oluşturmuştur [33].

Bie ve diğerleri; otobüslerin GPS verilerini kullanarak yolcu talepleri ve seyahat sürelerini Günü Saati Etkinlikleri (Time of Day- ToD) aralıklarında inceleyip otobüs zaman çizelgesi için eşik değerleri yani makul süreyi elde etmiştir [34].

Schöbel, iyi bir ulaşım sistemini tasarlamak için gerekli olan hat planlaması, zaman çizelgesi ve araç planlaması kriterlerinin birlikte ele alınıp optimizasyonu için yinelemeli bir algoritma modeli kullanılmasını önermiştir [35].

Herbon ve Hadas, Newsvendor Modeli (Gazete Satıcısı Problemi) ile toplu taşıma hareket saatleri, toplu taşıma maliyetleri ve yolcu bekleme sürelerinin daha verimli ve hızlı işlenmesini sağlayan bir sistem oluşturmuştur [36].

Fouilhoux ve diğerleri, yolcuların seyahat ve otobüs bekleme sürelerini azaltmak ve otobüs hareket çizelgesi senkronizasyon sorununu çözmek amacıyla Karma Tam Sayılı Programı (Mixed Integer Program-MIP) kullanmıştır [37].

Laporte ve diğerleri, yolcu kapasitelerini ve yolcu seyahat beklentilerini dikkate alarak her ulaşım hattı için en uygun zaman çizelgesi optimizasyonunu yapmıştır [38].

Owais ve diğerleri, toplu taşıma ağ tasarımı sırasında diğer araştırmacılardan farklı olarak sadece kullanıcı talepleri ve toplu taşıma maliyetlerini kriter olarak almak yerine en kısa seyahat güzergahı ve en az otobüs sayısını kriter olarak çalışma yapmıştır [39].

Chen ve diğerleri, toplu taşıma ağ tasarımı seyahat güzergahı tasarımı ve en kısa dönüşü baz alan yöntem kullanmıştır [40].

Dai ve diğerleri, otobüs-tutma (bus-holding) yöntemini kullanarak toplu taşıma ile gerçekleşen seyahatlerde yolcuların otobüs bekleme sürelerinin ve otobüs güzergah seçenek sayılarının önemli ölçüde azaldığını tespit etmiştir [41].

Yu ve diğerleri, farklı koşullarda gerçekleşen gerçek zamanlı yolcu taleplerini kriter olarak seçip otobüs güzergah ve kalkış saatlerini iki aşamalı optimizasyon modeli ile optimize etmiştir [42].

Liu ve diğerleri, Pekin’de Toplu Taşıma Şirketi için Eksik Fonksiyon (DF-Deficit Function) teorisini kullanarak otobüs hareket saatlerini optimize eden, yoğun saatlerde yolcu taleplerini karşılayan ve optimize edilen zaman çizelgesine göre araç sayısında azalmayı sağlayan bir model geliştirmiştir [43].

Ma ve diğerleri, Pekin Toplu Taşıma Şirketine ait otobüs hatlarında Değişken Mahalle Araması (Variable Neighborhood Search-VNS) algoritması ile yaptığı çalışmada hem otobüs hatlarına ait maliyeti %18,1 azaltmış hem de otobüs zaman çizelgesi optimizasyonunu sağlamıştır [44].

Liu ve Ceder’in Yeni Zelanda Auckland’da yaptığı çalışma İki Amaçlı Karmaşık Tam Sayı Doğrusal Programlama yöntemiyle yolcu bekleme süresini %68-%72, otobüste istenilen yolcu doluluk seviyesi yük farkını ise %59-%65 oranında azaltmıştır [45].

Nesheli ve diğerleri, Multinomial Lojistik Regresyon Analizi ve Karar Ağacı Yöntemiyle toplu taşıma sistemlerinde yaşanan gecikmelerin yolcuların seyahat kararlarını nasıl etkilediğine dair çalışma yapıp çalışma sonuçları neticesinde farklı toplu taşıma seyahat modelleri geliştirmiştir [46].

Nesheli ve diğerleri, Yeni Zelanda Auckland’da yaptığı çalışmada toplu taşıma modellerinin gerçek zamanlı olarak kontrol edilmesiyle seyahat süresinin en aza indirileceğini ve toplu taşımanın oluşturduğu olumsuz çevresel etkilerin azaltılacağını belirtmişlerdir [47].

Liu ve Ceder; toplu taşıma ulaşım planlaması konusunda sadece araç hareket çizelgesi ile yolcu talep atamasının birlikte değerlendirilmesinin daha doğru ve gerçekçi bir ulaşım planı olduğunu belirtmiştir [48].

Zhang ve diğerleri, Çin Pekin’de yaptıkları çalışmada toplu taşıma kullanan yolcuların otobüs bekleme sürelerini ve otobüslerin işletme maliyetinin birlikte senkronize edildiği bir algoritma önererek yolcu bekleme sürelerinin %54,2 - %70,4 ve toplam işletme maliyetinin %31,2 - %64,1 oranında azaltılabileceğini saptamıştır [49].

Cao, Ceder ve Zhang Yeni Zelanda Auckland’da otonom toplu taşıma araçları üzerinde yaptığı çalışmada gerçek zamanlı kontrol ile seyahat zaman çizelgesinde yaşanan sapmaların

%100 önüne geçilebildiğini ayrıca otonom araçların toplu taşımayı daha cazip hale getirebileceği sonucuna varmışlardır [50].

Cao ve diğerleri atla-dur taktiğini Eksik Fonksiyon (DF-Deficit Function) teorisi yöntemiyle kullanarak toplam yolcu seyahat süresinde ve toplu taşıma araç sayısında önemli ölçüde azalma sağlayarak seyahat zaman çizelgesini optimize etmişlerdir [51].

Çalışma kapsamında incelenen literatür araştırmaları neticesinde toplu taşıma yolculuklarında yolcu ve hizmet sağlayıcıları açısından yaşanan (seyahat ve bekleme süreleri, enerji kayıpları, işletme maliyetleri vb.) sorunların optimize edilmesi ve hatta tamamen çözülmesi noktasında farklı model ve çözüm yöntemleri önerildiği görülmektedir. Bu tez çalışmasında ise metropol şehirlerde giderek artan nüfus ve kentleşmeyle birlikte yerleşim alanı içerisinde yer alan ve sınırlı kentsel arazi sebebiyle genişletilemeyen yollar ve giderek artan özel araç sahipliği nedeniyle özellikle kent içi toplu taşıma sistemlerinde yaşanan sıkıntıların akıllı ulaşım sistemleri uygulamaları ile optimize edilmesi amaçlanmaktadır. Bu amaçla kara, deniz ve havayolu ile erişilebilen bir şehir olması, gelişen sanayisi ve ticaret merkezi konumunda olması sebebiyle çok fazla göç alan ve hızla büyüyen Bursa ilinde yoğun trafik hareketliliğinin olduğu bölgelerden biri olan Bursa Uludağ Üniversitesi varışlı yolculuklar incelenmiştir. Bu çalışma kapsamında literatür araştırmalarından farklı olarak yolcuların durakta bekleme süreleri, araçların doluluk oranları, araçların hareket çizelgeleri ve bunlara bağlı olarak ortaya çıkan işletme maliyetleri gibi hem yolcu hem hizmet sağlayıcısı kriterlerinin hepsi bir arada ele alınıp optimize edilecektir. Bu sayede seçilen bölgeye erişimde yaşanan ulaşım sorunlarına makro ve mikro ölçekli çözümler üretilirken daha konforlu ve sürdürülebilir seyahatler sağlanacaktır.

2. BURSA KENT İÇİ TOPLU ULAŞIM ALTYAPISI

Bursa ili 2020 Adrese Dayalı Nüfus Kayıt Sistemi verilerine göre 3.101.833 kişi ile Türkiye'nin en fazla nüfusa sahip dördüncü büyükşehridir (TÜİK, 2020). Şehir göllerle birlikte 10.886 km² lik bir alana sahiptir ve Bursa Büyükşehir Belediyesi sınırları içerisinde 17 ilçe bulunmaktadır. Şehrin batısında Balıkesir-Bursa Yolu (D-200), doğusunda Bursa-Bilecik Yolu (D-160) ve Bursa-Eskişehir Yolu (D-200), kuzeyinde Bursa-Mudanya Yolu, Bursa-Yalova Yolu (D-575) ve Bursa-Gebze Otoyolu, şehir merkezinde ise şehir merkezinin çevresini saran otoyol Bursa ulaşım sisteminin en önemli yol ağıdır [52].

Tablo 2-1: Bursa ili Karayolları 14. Bölge Müdürlüğü sorumluluğundaki yollar

Bursa İli Yol Sınıflandırması	Km
Otoyol	131
Devlet Yolu	426
İl Yolu	609
Toplam	1166

Bursa'da Karayolları 14. Bölge Müdürlüğü sorumluluk sahası içerisinde 131 km Otoyol, 426 km Devlet Yolu, 609 km İl Yolu olmak üzere toplam 1166 km yol ağı bulunmaktadır [53].

Bursa'nın kent içi toplu ulaşım sistemi; lastik tekerlekli toplu taşıma sistemleri, raylı toplu taşıma sistemleri, ara toplu taşıma sistemleri ve deniz ulaşım sistemlerinden oluşmaktadır.

2.1. LASTİK TEKERLEKLİ TOPLU TAŞIMA SİSTEMLERİ

Lastik tekerlekli toplu taşıma sistemlerinin işletmesi şehirde BURULAŞ Bursa Ulaşım Toplu Taşıma İşletmeciliği Turizm Sanayi ve Ticaret A.Ş. sorumluluğundadır. Lastik tekerlekli toplu taşıma sistemlerine aşağıda belirtilen sektörler de dahil olmakla birlikte yolcu ücret ödeme sistemleri ve araç mülkiyet hakları farklılık göstermektedir [52].


- Belediye otobüsleri,
- Özel halk otobüsleri,
- Alt işletmeler
- İlçe hatları

Tablo 2-2: Lastik tekerlekli toplu taşıma sistemleri hat ve araç sayısı

	Hat Tipi	Hat Sayısı	Araç Sayısı
Şehir Merkezi Hatları	Belediye Otobüs Hatları	99	335
	Özel Halk Otobüsü Hatları (Batı)	60	325
	Özel Halk Otobüsü Hatları (Doğu)	14	55
	Alt İşletme Hatları	57	115
	İnegöl	25	172
İlçe Hatları	İznik	11	51
	Karacabey	29	48
	Mustafakemalpaşa	38	80
	Orhangazi	21	64
	Yenişehir	11	29
	Genel Toplam	365	1274

2.1.1. Belediye Otobüs Hatları

Bursa’da 99 adet belediye otobüs hattına ait 335 adet araç bulunmakta olup işletmesi BURULAŞ tarafından yapılmaktadır [54].



Şekil 2-1: Bursa ili belediye otobüs hatları

2.1.2. Özel Halk Otobüsü Hatları

2002 yılında Bursa'nın batısında hizmet veren 600 minibüsün iki minibüse bir otobüs olacak şekilde otobüse çevrilmesiyle 300 adet otobüs elde edilmiş ve Batı Özel Halk Otobüsü (Batı ÖHO) olarak adlandırılmıştır. Bursa Büyükşehir Belediyesi bu süreçte kiralık olarak çalışan 55 araç için de süre sınırlaması olmadan özel halk otobüsüne çevirmiştir ve bunlar da Doğu Özel Halk Otobüsü (Doğu ÖHO) olarak adlandırılmıştır.

2.1.3. Alt İşletme Hatları

Alt İşletme Hatları olarak adlandırılan otobüs sistemlerinde 57 hat 115 araç yer almakta olup sözleşme kapsamında BURULAŞ tarafından kiralanma işlemleri yapılmaktadır.

2.1.4. İlçe Hatları

Bursa ili 2004 yılında yürürlüğe giren “5216 sayılı Büyükşehir Belediyesi Kanunu” ve 2012 yılında yürürlüğe giren 6360 sayılı “On Dört İlde Büyükşehir ve Yirmi Yedi İlçe Kurulması

ile Bazı Kanun ve Kanun Hükmünde Kararnamelerde Değişiklik Yapılmasına Dair Kanun” ile büyükşehir sınırları genişletilmiştir ve bu kanunların yürürlüğe girdiği tarih itibarıyla Bursa Büyükşehir Belediyesi 17 ilçeden sorumlu olmuştur. Merkez ilçe olan Yıldırım, Osmangazi ve Nilüfer ilçelerine ek olarak Gemlik, Mudanya, Kestel ve Gürsu ilçeleri de merkez ilçeler olarak belirlenmiştir. Aynı zamanda bu yasalar sonrası Orhangazi, İznik, Yenişehir, İnegöl, Keles, Harmancık, Büyükorhan, Orhaneli, Mustafakemalpaşa, Karacabey ilçeleri de Büyükşehir Belediyesi sorumluluk alanı içine dahil olmuştur [52]. Bu ilçelere ait hat ve araç sayıları Tablo 2-3 de gösterilmiştir [54].

Tablo 2-3: İlçelere ait hat ve araç sayıları


İlçe Adı	Hat Sayısı	Araç Sayısı
İnegöl	25	172
İznik	11	51
Karacabey	29	48
Mustafakemalpaşa	38	80
Orhangazi	21	64
Yenişehir	11	29
Genel Toplam	135	444

2.2. RAYLI TOPLU TAŞIMA SİSTEMLERİ

Bursa şehrinde BURULAŞ bünyesinde raylı toplu taşıma sistemi olarak hizmet veren raylı sistem ve hafif raylı sistem kullanılmaktadır.


2.2.1. Hafif Raylı Sistem

Hafif raylı sistem güzergahı Bursa’da şehrin doğal gelişme aksına paralel olarak doğu-batı aksında konumlandırılıp BursaRay olarak adlandırılmıştır. İlk etapta Küçük Sanayi istasyonu ile Şhreküstü İstasyonu ve Mudanya Yolu üzerinde Organize Sanayi İstasyonu ile Şhreküstü İstasyonu arasında çalışan iki hat şeklinde hizmet vermiştir. Şekil 2-2 de gösterildiği gibi daha sonraki zamanlarda etaplar halinde uzatma projeleri hazırlanıp uygulanmıştır [55].



Şekil 2-2: BursaRay yıllara göre etap gelişimi


BursaRay Hat-1 güzergahı Emek İstasyonu ile Araba İstasyonu arasında, Hat-2 güzergahı ise Üniversite İstasyonu ile Kestel İstasyonu arasında hizmet vermektedir. Bu iki hattın uzunluğu toplam 39 km dir ve 7 si yeraltı olmak üzere toplam 38 istasyonu bulunmaktadır [52].




Şekil 2-3: BursaRay hat-1 ve hat-2 güzergahları [56]

2.2.2. Tramvay Hattı

Bursa Hafif Raylı Sistem ile birlikte T1 ve T3 tramvay hatları da bulunmaktadır. Bu hatların izlediği güzergahlar Şekil 2-4 ve Şekil 2-5 de verilmiştir [56]. 2011 yılında açılan T3 tramvay hattı Bursa'nın ilk tramvay hattı olup 2,2 km uzunluğundadır ve 9 istasyonu bulunmaktadır. T1 tramvay hattı ise 2012 yılında işletmeye açılan 6 km uzunluğunda ve 14 istasyonu olan güzergâh olarak Cemal Nadir Caddesi, Atatürk Caddesi, İnönü Caddesi, Kıbrıs Şehitleri Caddesi, İlkbahar Caddesi, Stadyum Caddesi ve Altıparmak Caddesini kullanan bir hattır. T2 Terminal hattı olarak bilinen tramvay hattı çalışmaları ise devam etmektedir [52].



Şekil 2-4: T1 hattı tramvay güzergâhı



Şekil 2-5: T3 hattı tramvay güzergâhı

2.3.2. Taksi Dolmuş

Bursa’da ara toplu taşıma sistemlerinden biri olan taksi dolmuşlar Bursa kent merkezi ve yakınında bulunmakta ve kent merkezinde ring yapmaktadır. Bursa’da 26 adet taksi dolmuş hattında toplam 303 araç çalışmaktadır ve Bursa Büyükşehir Belediyesi tarafından taksi, dolmuş, minibüs ve servis araçlarının işleyiş yapısını, yetki ve sorumluluk alanlarını belirlemek amacıyla Taksi-Dolmuş-Minibüs-Servis Araçları ve Özel Toplu Taşıma Araçları Yönetmeliğini yayınlamıştır [55].

2.3.3. Servis

Bursa ve ilçelerinde Şekil 2-7’de görüldüğü toplam 6025 adet servis bulunmaktadır ve bu araçlara Bursa İl Trafik Komisyonu’nda alınan gereği tahdit uygulanmaktadır [52], [56].

İLÇE	TESCİLLİ S PLAKA SAYISI
Osmangazi	2.915
Yıldırım	705
Nilüfer	334
Gürsu	Yıldırım Tescile kayıtlı
Kestel	Yıldırım Tescile kayıtlı
MERKEZ ILCELER	3.954
Mudanya	97
Gemlik	160
Karacabey	415
Mustafakemalpaşa	128
Orhangazi	131
İznik	158
Yenişehir	128
İnegöl	469
Keles	65
Orhaneli	320
Harmancık	Orhaneli Tescile kayıtlı
Büyükorhan	Orhaneli Tescile kayıtlı
MERKEZ DIŞI ILCELER	2.071
TOPLAM	6.025

Şekil 2-7: İlçelere göre tescilli S plaka dağılımı

2.3.4. Taksi

Bursa’da 1478 adet taksi ve 166 adet taksi durağı bulunmaktadır ve taksiler de Taksi-Dolmuş-Minibüs-Servis Araçları ve Özel Toplu Taşıma Araçları Yönetmeliğine bağlıdır.

3. AKILLI KART VERİLERİ İLE BURSA KENT İÇİ YOLCU TAŞIMACILIĞI ANALİZ VE YÖNTEMLERİ

3.1. AMAÇ VE KAPSAM

Bursa Büyükşehir Belediyesi sınırları içerisinde yer alan ve BURULAŞ Bursa Ulaşım Toplu Taşıım İşletmeciliği Turizm Sanayi ve Ticaret A.Ş. sorumluluğunda olan Bursa Uludağ Üniversitesi varışlı yolculuklara ait otobüs hatları incelenerek forecasting (tahmin) yapılması amaçlanmaktadır. Bu amaç doğrultusunda yolcu taşıma sistemlerinde elektronik bilet olarak kullanılan BursaKART verilerinden faydalanılmaktadır. Bir akıllı kart sistemi olan BursaKART elektronik bilet olma özelliği dışında her karta özel bir kart numarası bulundurması ve toplu taşıma araçlarında yer alan validatörlere okutulmasıyla kişilerin gün içinde gerçekleştirdikleri yolculuk rotaları ve yolculuk saatlerine ait bilgiler de vermektedir. BursaKART'a ait bu bilgiler aracılığıyla Bursa Uludağ Üniversitesi varışlı yolculuk analizleri yapılarak kişilerin yolculuk alışkanlıklarına bağlı alternatif ulaşım seçeceklerinin araştırılması, mevcut toplu taşıma hattına ait düzenlemeler, kullanılan toplu taşıma hattının diğer hatlarla entegrasyonu hedeflenmiştir.

3.2. VERİLERİN ANALİZ EDİLMESİ VE MODEL KURGUSU

BURULAŞ Bursa Ulaşım Toplu Taşıım İşletmeciliği Turizm Sanayi ve Ticaret A.Ş.'den alınan BursaKART verileri 2019 yılı Ocak-Haziran ayları arasında altı aylık bir süreci kapsamakta ve farklı kartlara ait 135.029.196 adet yolculuk gerçekleştiği tespit edilmiştir. BursaKART'a ait bu verilerin büyük hacimli olması ve veri çeşitliliği sebebiyle bu veriler Büyük Veri (Big Data) olarak nitelendirilmektedir. Bu büyük verilerin saklanması, analiz edilmesi ve işlenmesi geleneksel hesaplama yöntemleriyle zor ve maliyetli olduğu için tercih edilmemektedir. Büyük Veri (Big Data) değişken, karmaşık, büyük hacimli, çeşitliliği fazla ve belirli hız aralıklarıyla elde edilen verilerin bütünü anlamına gelmektedir. Büyük Veri (Big Data) kavramını tanımlamak için üç ana bileşen kullanılmaktadır: hacim, çeşitlilik ve hız. Hacim verilerin terebayt, petebayt vb. büyüklüğünü ifade ederken, çeşitlilik ise farklı kaynaklardan ve sensörlerden elde edilen veri çeşitliliği anlamına gelmektedir. Hız ise bu verilerin ne sıklıkla toplandığını ifade etmektedir. Örneğin verilerin saat, gün, ay vb. periyotlarla toplanması ve ayrıştırılması vb. gereksinimler olabilmektedir [57]. 1997 yılında gerçekleştirilen 8. IEEE Görüntüleme Konferansı'nda veri kümelerinin büyüklüğü sebebiyle bilgisayar belleklerine, yerel ve harici disklere sığmaması

sebebiyle ilk kez Büyük Veri (Big Data) kavramı kullanılmıştır [58]. Daha sonraları ise biyoloji, fizik veya sosyal bilimler başta olmak üzere bütün bilim dallarının Büyük Veri kavramıyla karşılaştığı ve kullanmak zorunda olmaları ortaya çıkmıştır. [59]. Bu çalışmada kullanılan veriler karmaşık ve büyük hacimli olduğu için Büyük Veri kapsamına dahil olmaktadır. Bu büyük verilerin işlenmesi konusunda en uygun ve en güvenilir karar metodunu bulmak için yaygın olarak Yapay Zekâ (Artificial Intelligence), Makine Öğrenmesi (Machine Learning) ve Derin Öğrenme (Deep Learning) teknikleri kullanılmaktadır. Büyük verilerin bu teknikler ile işlenmesi sayesinde trafikte yaşanan problemlerinin çözülmesi, trafikteki davranışların önceden tahmin edilerek önlemler alınması mümkündür. Bu nedenle yapay zekâ, makine öğrenmesi ve derin öğrenme teknikleri akıllı ulaşım sistemlerinin tasarlanmasında oldukça önemlidir. Bu çalışmada ise Derin Öğrenme Teknikleri tabanlı Uzun-Kısa Dönemli Bellek (Long Short-Term Memory-LSTM) ve Geçitli Tekrarlayan Birim (Gated Recurrent Unit-GRU) teknikleri kullanılmıştır.

3.2.1. Derin Öğrenme-Yapay Sinir Ağları Tarihçesi

Yapay sinir ağları bir çeşit makine öğrenmesi modelidir. İnsan beyninin sinir sistemi işleyişine benzer şekilde, öğrenirken tekrarlama, sınıflandırma ve anımsama yaparak topladığı bilgileri analiz edip yeni bilgi üretme yeteneğinin bilgisayar yazılımları aracılığıyla yapıldığı sistemlerdir yapay sinir ağları. İnsan beyninin çalışma mekanizması incelenerek tasarlanan ve yapay sinir ağlarının temelini oluşturan ilk yapay sinir ağı modellemesi 1943 yılında McCulloch ve Pitts tarafından yapılmıştır. Bu modelleme elektrik devreleri ve insan beyninin analiz yeteneğinden faydalanılarak ilk yapay sinir ağı hücresi elde etmişlerdir. Bu yapay sinir ağı hücreleri ile mantıksal her türlü ifadenin formülize etmenin mümkün olduğu ortaya çıkmıştır. Sonraki yıllarda tek bir hücre değil birden fazla hücrenin paralel şekilde çalışmasıyla farklı öğrenme teknikleri geliştirmişlerdir [60]. 1949 yılında sinir ağı sistemindeki yapay nöronların değerini değiştiren ve günümüzde birçok öğrenme kuralının temelini oluşturan ‘Hebbian Öğrenme Kuralı’ Hebb tarafından ortaya konmuştur [61]. 1954 yılında uyarlanabilir ve öğrenebilir sinir ağlarına ilişkin yeni bir optimizasyon tekniği geliştirilmiştir. Random (rastgele) sinir ağları ile adaptif tepki kavramı ortaya çıkmıştır [62]. ‘Yapay Zekâ’ kavramı ilk kez 1956 yılında Hanover, New Hampshire'da bulunan Dartmouth Koleji'ndeki bir konferansta kullanılmıştır ve konferans katılımcıları tarafından yapay zekâ çalışmaları oldukça ilgi çekmiştir. Yapay zekâ çalışmalarına olan ilgi yapay sinir ağlarını geride bırakmıştır ve bu dönemde yapay sinir ağları ve yapay zekâ çalışmaları birlikte yapılmamıştır. Yapay zekâ çalışmaları her ne kadar popüler olsa da yapay zekâ varlığını oluşturmak ve ona sahip olmak kolay değildi. 1974-1980 yılları arasını kapsayan ve

‘Yapay Zekâ Kışı’ olarak da bilinen bu dönemde yapay zekâ çalışmalarındaki ilerlemeyi eleştiren birkaç rapor nedeniyle bu alana hem ilgi hem de devlet desteği azalmıştır. Ancak yapay zekâ alanı 1980’li yıllarda İngilizlerin Japonlarla rekabet etmek için sağladığı finansal destekle yeniden canlanmıştır [63].

Rosenblatt tarafından 1957’de geliştirilen ‘perceptron’ adı verilen algılayıcılar önüne bir üçgen tutulduğu zaman görüntünün yanıt birimlerine iletilmesini sağlayan bir model geliştirmiştir ve ‘öğrenme’ yi sağlamıştır. Elektronik bir cihaz olan ‘perceptron’ ile gerçekleştirilen model deneme yanılma yolu ile yeni yetenekler öğrenen ilk bilgisayar niteliği taşımaktadır. Bu çalışma ilerleyen zamanlarda geliştirilerek çok katmanlı algılayıcıların öncüsü sayılarak yapay sinir ağları tarihinde ilerlemeler sağlamıştır [64]. 1959 yılında Widrow ve Hoff Stanford Üniversitesi’nde ADALINE (Adaptive Linear Neuron) ve MADALINE (Multiple Adaline) olarak adlandırılan bir yapay sinir ağı modeli oluşturmuşlardır. Bunlardan ADALINE Rosenblatt’ın perceptron (algılayıcı) modeliyle aynı özellikler taşıyan gelişmiş bir öğrenme modeliyken, MADALINE telefon hatlarında yaşanan ses yankısını ortadan kaldıran bir nevi süzgeç görevi gören bir algoritma özelliği taşımaktadır. Bu özelliği ile yapay sinir ağı gerçek bir probleme çözüm sunmuş olan ilk sinir ağıdır [65]. 1960’lı yıllarda Rosentblatt, Anderson, Kohonen, Hopfield, Widrow, Nilssons, Grossberg, Fukushima gibi bilim adamları 1956 yılında ortaya çıkan “yapay zekâ” kavramının yapay sinir ağları üzerindeki olumsuz etkisini kırmak amacıyla yapay sinir ağlarını tekrar tekrar gündeme getirmişlerdir. 1965 yılında yapay sinir ağları ile ilgili yapılan bütün çalışmalar Nilson tarafından yazılan “Öğrenen Makineler” isimli kitapta toplanmıştır [66]. Bu dönemde yapay sinir ağlarında yaşanan gelişmeleri yakından takip eden ve yapay zekayla ilgilenen bilim insanları Perceptrons (Algılayıcılar) isimli kitapla yapay sinir ağlarının lineer olmayan sorunlara bir çözüm bulmadığını ve bilimsel olarak bir faydası olmadığını ifade ederek yapay sinir ağı çalışmalarının duraklama dönemine girmesine sebep olmuştur. Minsky ve Papert yazdıkları bu kitapla tezlerini savunmak amacıyla yapay sinir ağlarının bilgisayar yazılımlarında sıklıkla kullanılan XOR (eXclusive OR) sorununa çözüm sunmadığını kanıtlamışlardır [67]. 1972 yılında Anderson ve Kohonen birbirinden habersiz şekilde ilişiksel bellek çalışması yaparak “Çağrışımli Bellek” isimli öğreticisi olmayan bir öğrenme modeli geliştirmişlerdir. Bu model öğreticisi olmayan öğrenme modelinin temeli sayılmaktadır [68]. 1979 yılında Fukushima karakter ve örüntü tanımaya yönelik çok katmanlı bir yapay sinir ağı modeli olan NEOCOGNITRON modelini bulmuştur. Bu model ile yapay sinir ağlarının her aşamasında hata payını tolere ederek deforme olmuş katmanların bile sonuç kısmında tanınmasına imkan vermiştir [69]. Bilim adamları tarafından geliştirilen bu modeller 1960’lı yıllarda yapay sinir ağları çalışmalarının duraklama dönemi olarak kabul edilen

dönemden çıkarak 1980’li yıllarda yapay sinir ağları çalışmalarının tekrar hız kazanmasını ve yapılan çalışmaların karşılıklarını almasını sağlamıştır.

1982 yılında Kohonen basit fiziksel bir durum sonucu beyinde sinyal alan kısmın aynı sinyal gösterim yanıtlarının sonucu olarak aynı topolojik sırayı oluşturarak bir dizi çıktı oluşturarak otomatik olarak kendini eşleştiren kendi kendine öğrenen haritalar modelini oluşturmuştur [70]. Hopfield ise aynı sene insan beyinde yer alan nöronların benzersiz işleyişini örnek alarak yaptığı çalışmada yapay sinir ağlarını bilgisayar yazılımları aracılığıyla matematiksel olarak modelleyerek çözülmesi güç problemleri çözebileceğini göstermiştir. Hatta 1985 yılında Hopfield’in kendi adıyla anılan “Hopfield Ağı” sayesinde gezgin satıcı problemlerine çözüm bulunmuştur [71][72]. 1986 yılında Rumelhart ve arkadaşları tarafından ağda beklenen ve üretilen çıktı arasındaki hatayı en aza indiren günümüzde de kullanılan “Geri Yayılım Algoritması” olarak adlandırılan modeli geliştirmişlerdir [73]. Carpenter ve Grossberg 1987 yılında Adaptif Rezonans Teorisi (ART) adlı “denetimli ve denetimsiz öğrenme modellerini kullanarak tahmin ve örüntü tanıma problemlerinde kullanılan sinir ağı modelini geliştirmiştir [74]. 1988 yılında Broomhead ve Lowe insan sinir sisteminde yer alan nöronların etki-tepki sistemini baz alarak Radyal Tabanlı Fonksiyonlara dayalı sinir ağı sistemini tasarlamıştır. Broomhead Andrew Webb ile Radyal Tabanlı Fonksiyonları kullanarak yaptıkları çalışmalar sayesinde 1989 da John Benjamin Memorial Ödülü’ne layık görülmüştür [75]. Specht ise Broomhead ve Lowe’ın çalışmasını illeterek “Probabilistik Ağlar” ve “Genel Regrasyon Ağlarını” geliştirmiştir [76]. 1995 yılında Hinton ve arkadaşları tarafından uyanıklık-uyku (wake-sleep) algoritmasını geliştirerek binlerce gizli katmanlardan oluşan ağın eğitilmesinin süreç uzunda olsa mümkün olduğunu gösterdiler [77]. Hochreiter ve Schmidhuber ise 1997 yılında Uzun-Kısa Süreli Bellek (Long Short-Term Memory) öğrenme modelini geliştirmişlerdir [78]. 2000’li yıllarda Yapay Sinir Ağları ile yapılan çalışmalarda artan katman ve düğüm sayıları sebebiyle donanımsal yetersizlikler yaşanmıştır ve yapay zekâ teknikleri bir süre kullanılmamıştır. Ancak daha sonra Grafik İşlemci Ünitesi (GPU) ve donanım ürünlerinde yaşanan teknolojik gelişmeler ve maliyet düşüklüğü sayesinde yapay sinir ağları yeniden kullanılmaya başlanmıştır [79]. Yine aynı yıllarda Aizenberg ve arkadaşları tarafından “Derin Öğrenme (Deep Learning)” kavramı yapay sinir ağları bağlamında ilk kez tanıtılmıştır [80]. 2007 yılında Geoffrey Hinton’un yayınlanan bir makalesinde çok katmanlı sinir ağına öğrenmeyi kolaylaştırmak adına geri yayılım modeliyle birlikte ince ayarlar yapılabileceğinden bahsetmiştir [81]. Derin ağlarda ön eğitim süreci olmadan ağın eğitilebilmesi GPU hızlarının artmasıyla çözüme kavuşmuştur. 2012 yılında Hinton ve arkadaşları GPU kullanarak yaptıkları ImageNet derin öğrenme çalışmalarında en iyi performansı elde etmek için model öğrenirken ezberlemeyi azaltıp seyreltme (dropout) yani normalleştirme yöntemini

kullanmışlardır [82]. Ayrıca 2012 ve 2014 yıllarında nesneleri sınıflandırmak için düzenlenen ImageNet yani görsel tanıma yarışması ile Derin Öğrenme yönteminin başarısı kanıtlanmış oldu ve popüler olmaya başladı [83].

3.2.2. Derin Öğrenme-Yapay Sinir Ağlarının Yapısı, Özellikleri ve Kullanım Alanları

Eğitim için kullanılan verilerin yüksek boyutlu ve karmaşık olması ve bilgi/sinyal işleme, makine öğrenmesi alanlarında yaşanan gelişmeler neticesinde günümüzde derin öğrenme bir makine öğrenmesi tekniği olarak karşımıza çıkmaktadır. Makine öğrenmesi ve Yapay Sinir Ağları kullanılarak geliştirilen derin öğrenme tekniği geleneksel ve yeni ayrımı olmaksızın bütün sinyal işleme ve bilgi teknolojileri alanlarında kullanılmaktadır. Derin öğrenme çok özellikli ve karmaşık veriler arasındaki ilişkiyi katmanlarına ayırarak alt düzeyde tanımlanmasına imkân vermektedir. Derin öğrenme mimarisinin ortak özellikleri arasında çok katmanlı veya doğrusal olmayan bilgi işleme modelleri oluşturulup denetimli veya denetimsiz şekilde verilerin özneteliğini ortaya çıkaran soyut katmanlar elde edilmesi bulunmaktadır [84].


Yapay sinir ağlarının insan beyninin sinir sistemi işleyişine benzemesi yani öğrenmesi daha sonra sınıflandırması ve anımsaması özellikleri ve son yıllarda yaşanan teknolojik gelişmeler yapay sinir ağlarını oldukça popüler bir hale getirmiştir. Yapay sinir ağları uygulamaları geçmişten bugüne gelinceye kadar birçok alanda kullanılmıştır. Tıp (kanserli hücre ve tıbbi sinyal analizleri), finans (kredi skorları, döviz kuru, risk analizi), ulaşım (trafik yoğunluk, araç ve yolcu sayısı tespiti, alternatif güzergahlar), mühendislik (ürün analizi, otomotiv, enerji üretim-tüketim hesaplaması), ticaret (kar-zarar marjı tahmini), iklim (hava tahmini) vb. alanlarda ayrıca robotik sistemlerde, el yazısı, karakter tanıma, doğal dil işleme, görüntü işleme vb. veri madenciliği alanlarında da kullanılmaktadır.

Biyolojik sinir sisteminde bir sinir hücresinin yapısı çoğunlukla hücre gövdesi, dendrit ve aksonlardan meydana gelirken yapay sinir ağları da yapay sinir hücresi olarak görev yaptıkları için onların da girdiler, ağırlıklar, toplama fonksiyonu, aktivasyon fonksiyonu ve hücre çıktısı gibi elemanları vardır. 1943 yılında yapay sinir ağlarının temelini oluşturan ilk yapay sinir ağı modellemesini yapan McCulloch ve Pitts'ten başka yapay sinir ağları ile biyolojik sinir sistemi elemanları ve işleyişinden esinlenerek yapılan başka çalışmalarda literatür oldukça fazladır. Örneğin 1995 yılında Braspenning, Muller ve arkadaşları biyolojik sinir sistemi yapısını yapay sinir ağı yapısıyla karşılaştırmışlardır. Biyolojik sinir sisteminde uyarının yapay sinir sistemlerinde girdiye, reseptörlerin girdi katmanına, sinir ağının işlem katmanına, nöronların işlem elemanına,


efektörlerin çıktı katmanına cevapların ise çıktıya benzer olduğu Tablo 3-1 ve Şekil 3-1’de görüldüğü şekilde ifade etmişlerdir [85].

Tablo 3-1: Biyolojik sinir ağı ve yapay sinir ağı benzerlikleri

Biyolojik Sinir Ağları	Yapay Sinir Ağları
Uyarı	Girdi
Reseptörler	Girdi Katmanı
Sinir ağı	İşlem Katmanı
Nöron	İşlem Elemanı
Efektörler	Çıktı Katmanı
Cevap	Çıktı



Şekil 3-1: Biyolojik sinir ağı hücresi



Şekil 3-2: Yapay sinir hücresi yapısı

Bir yapay sinir ağı hücresi Giriş Katmanı, Ara (Gizli) Katman ve Çıktı Katmanı olmak üzere 3 katmandan oluşmaktadır. Şekil 3-2 de görüldüğü gibi m değerleri girdi katmanını y değeri ise çıktı katmanını oluşturmaktadır [86]. Şekildeki yapay sinir ağı hücresinde m tane girdi değerinin w ağırlık değerleriyle çarpıldıktan sonra toplanma işlemi sonrasında aktivasyon fonksiyonu ile işleme tabi tutulduktan sonra y yani bir çıktı değeri elde edilmektedir. Bu işlem istenilen sonuç elde edilene kadar tekrarlanmaktadır. Yani yapay sinir ağı öğrenmesi için öncelikle farklı girdi setleri ile eğitilmekte sonrasında ise ağı karar vererek ve genelleme yaparak sonuç yani çıktı değerleri elde edilmektedir.

Sınıflandırma, tahmin, veri ilişkilendirme, veri yorumlama ve veri filtreleme özellikleri yapay sinir ağlarının farklı alanlarda en çok kullanılan özellikleri arasında yer almakla birlikte yapay sinir ağı hücrelerinin yaygın olarak bilinen ortak özellikleri de bulunmaktadır [87].

- Doğrusal olmayan paralel bir yapıya sahip olması
- Hata toleransı ve esneklik


- Eksik verilerle çalışma
- Öğrenme kabiliyeti
- Genelleme kabiliyeti
- Çok fazla değişken ve parametre kullanması
- Farklı problemlere uyarlanabilir olması

3.2.3. Derin Öğrenme Mimarisi

Yapay sinir ağları her problem için farklı çözüm yöntemleri sunmaktadır. Her probleme aynı yapay sinir ağı modeli uygulanmamaktadır. Problemin türüne göre uygulanacak olan yapay sinir ağı modeli farklılık göstermektedir. Tahmin ve teşhis etme, tanıma, sınıflandırma vb. amaçlara yönelik sonuç elde etmek için farklı yapay sinir ağı modelleri kullanılmaktadır. Bu farklı yapay sinir ağı modellerinde ağ içinde yer alan katman sayılarının artırılmasıyla da farklı derin öğrenme mimarileri oluşmaktadır. Derin öğrenme yöntemlerinde kullanılan mimariler şunlardır: Konvolüsyonel Sinir Ağları (Convolutional Neural Networks), Tekrarlayan Sinir Ağları (Recurrent Neural Networks), Uzun Kısa Dönemli Bellek (Long-Short Term Memory), Kısıtlanmış Boltzmann Makineleri (Restricted Boltzmann Machines), Derin İnanç Ağları (Deep Belief Networks), Derin Oto Kodlayıcılar (Denoising Autoencoders).


Konvolüsyonel Sinir Ağları (Convolutional Neural Networks-CNN)

Konvolüsyonel Sinir Ağları yani Evrişimli Sinir Ağları (Convolution Neural Networks), insanın görme duyusundan faydalanılarak geliştirilen ve çok katmanlı bir yapıya sahip olan bir derin öğrenme sistemidir. İlk CNN ağı Yann LeCun'un 1988 yılında ortaya attığı ve LeNet olarak adlandırılan bir mimari modeldir [88]. LeNet ağı mimari modeli Şekil 3-3'teki gibidir [89].



Şekil 3-1: LeNet ağı

Bilgisayar aracılığıyla geliştirdiği modellerin başarı oranlarının yüksek olması sebebiyle oldukça tercih edilen bir modeldir. Görüntüsü sınıflandırılması, nesne tanıma, nesne takibi, doğal dil işleme ve anlam çıkarımı ve tahmin problemlerinde Evrişimli Sinir Ağlarından faydalanılmaktadır. Evrişim işleminde iki boyutlu bilgilere uygulanacak olan filtrenin x ve y verilerine göre simetriği alınmaktadır. Matriste tüm değerler eleman elemana çarpılır ve elden edilen tüm değerlerin toplamı çıkış matrisinin ilgili elemanı olarak Şekil 3-4'te görüldüğü gibi kaydedilir. Giriş verisi tek kanallı olduğu zamanlarda bu işlem kolaylıkla yapılmaktadır. Giriş verisi farklı kanal sayısında ve formatlarda olabilmektedir [90].



Şekil 3-2: İki boyutlu evrişim işlemi

Evrişimli Sinir Ağları modellemesi yapılırken kenar bulma, piksel ekleme (padding), kaydırma adımı (stride), ortalama (pooling) yöntemlerinden faydalanılmaktadır. Yapılan hesaplamalarda giriş ve çıkış veri boyutları arasında farklılıklar olmaktadır. Örneğin, $(n \times n) = 5 \times 5$, kenar bulma filtresi $(f \times f) = 3 \times 3$ boyutlarına evrişim işlemi uygulandığında elde edilen çıkış matrisinin boyutları $(n - f + 1) \times (n - f + 1) = 3 \times 3$ olmaktadır. Eğer çıkış matrisinin boyutlarının değişmesi istenmiyorsa; piksel ekleme (padding) işlemi uygulanmaktadır ve Denklem (1) de ifade edilmektedir [90].

$$[(n + 2p - f)/s + 1] \times [(n + 2p - f)/s + 1] \quad (1)$$

Burada eklenen piksel ise Denklem (2) de gösterilmektedir:

$$p = (f - 1)/2 \quad (2)$$


Evrişimli Sinir Ağları (CNN) modelini matematiksel olarak; girdi boyutunu W , evrişimsel katman nöronlarının boyutlarını F , sıfır ekleme miktarını P , adım sayısını S şeklinde ifade ederek belirlenmiş bir boyuta sığacak nöron sayısını N Denklem (3) de şeklinde gösterebiliriz [91].

$$N = \frac{W-F+2P}{S} + 1 \quad (3)$$

Dan Cireşan 2012 yılında görüntü işleme alanında CNN modelini kullanarak MNIST veri kümesiyle yaptığı çalışmada hata payını %2'ye kadar düşürmeyi başarmıştır [92]. 2012-2014 yıllarında ImageNet'in gerçekleştirdiği nesne tanıma yarışmasında Evrişimli Sinir Ağları sayesinde büyük başarılar elde edilmiştir [83]. 2015 yılında Evrişimli Sinir Ağları ile ters yüzlerde dahil olmak üzere farklı açı aralıklarında olan yüzlerin yer aldığı 200.000 görüntü ve yüzleri olmayan 20 milyon görüntünün yer aldığı bir veritabanı eğitilmiştir [93]. Aynı yıl Evrişimli Sinir Ağları ilk kez ilaç keşif uygulamaları için kullanılarak AtomNet adıyla tasarlanmıştır [94].

Tekrarlayan Sinir Ağı (Recurrent Neural Network-RNN)

Tekrarlayan Sinir Ağları (RNN) yapay sinir ağlarının bir çeşidi olup çıktı verilerinin girdi verileri olarak kullanılmasına imkân veren bir sinir ağıdır. İlk Basit Tekrarlayan Ağ (Simple Recurrent Network-SRN) Elman tarafından tasarlanmıştır. Elman yaptığı simülasyon çalışmasında cümle yapısını meydana getiren isimler ve fiillerin ayrıştırılmasını hatta isimler içerisinde canlı-cansız varlıkların ve canlı varlıklar içerisinde insan-hayvan ayrımı yapılmasının ayırt edilmesini sağlamıştır ve bu dil bilimi alanında oldukça kaydedir bir gelişme niteliği taşımaktadır [95]. Tekrarlayan Sinir Ağı konuşma tanıma, dil modelleri ve metin üretimi, video işleme vb. alanlarda kullanılan bir derin öğrenme yöntemidir. Bu modelin, herhangi bir uzunluktaki girdilerin işlenmesi, girdi boyutları artsa bile model boyutunda artış olmaması, girdi verileri hatırlayabilmesi ve zaman içinde ağırlıkları paylaşabilmesi vb. avantajları bulunmaktadır. Farklı geleneksel RNN mimari yapıları Şekil 3-5 ve 3-6'da verilmiştir [96].




Şekil 3-3: Geleneksel RNN mimarisi örneği-1

Bir t zamanında, $a^{<t>}$ aktivasyonu ve $y^{<t>}$ çıktısı Denklem (4) deki gibi ifade edilmektedir:

$$a^{<t>} = g_1(W_{aa}a^{<t-1>} + W_{ax}x^{<t>} + b_a) \text{ ve } y^{<t>} = g_2(W_{ya}a^{<t>} + b_y) \quad (4)$$

Denklem (4) te W_{ax} , W_{aa} , W_{ya} , b_a , b_y geçici olarak paylaşılan kat sayıları, g_1 , g_2 ise aktivasyon fonksiyonlarını ifade etmektedir.

Tekrarlayan Sinir Ağları (RNN) modeli matematiksel olarak aşağıdaki şekilde tanımlanır.




Şekil 3-4: Geleneksel RNN mimarisi örneği-2

Tekrarlayan Sinir Ağı genellikle dil modellerinde arka arkaya gelen sıralı bir dizi içerisinde sıradaki yapıyı tahmin eder. Bir cümlede kullanılan kelimelerin devamında hangi kelime veya kelime gruplarının geleceğinin tahmin edilerek cümlelerin tamamlanması işlemi örnek olarak verilebilir. Bu işlemi yaparken bir önceki kelimelere yani önceki çıktılara bağlı hareket etmesi de “tekrarlayan” olarak adlandırılmasının ana sebebidir. Alex Graves ve arkadaşları 2014 yılında yaptığı çalışmada RNN modelini kullanarak konuşma seslerini fonetik sunuma gerek kalmadan metine çeviren bir sistem tasarlamışlardır [97].

Uzun-Kısa Dönemli Bellek (Long-Short Term Memory-LSTM)

Uzun-Kısa Dönemli Bellek (LSTM) sıralı verilerin modellenmesi için kullanılan bir RNN türüdür. Tekrarlayan Sinir Ağları (RNN) yapısı çıktı verilerinin girdi verileri olarak kullanılmasına imkân veren bir yapıydı. Uzun-Kısa Dönemli Bellek (LSTM) yapısı ise; gradyan kaybolması/patlama sebebiyle önceki çıktı verilerinin girdi verisi olarak kullanılmasının mümkün olmadığı ifade etmektedir [98]. Bu soruna çözüm bulmak için Hochreiter ve Schmidhuber 1997 yılında yapmış oldukları çalışmayla Uzun-Kısa Süreli Bellek (LSTM) modelini geliştirmişlerdir [78]. Şekil 3-7’de Uzun-Kısa Bellek mimari yapısı gösterilmiştir [98].

LSTM ağlarının RNN ağlarından farkı RNN ağında hafızada tutulamayan önceki çıktı ve girdi verilerinin tutulduğu hafıza birimlerinin yer almasıdır. Böylelikle hafıza hücreleri gerekli olan verileri ağda tutarak önceki bellek bilgileri ile girdi verilerini birleştirip ağın çalışmasının devamlılığını sağlamış olurlar.



Şekil 3-5: Uzun-kısa süreli bellek mimarisi yapısı

Uzun-Kısa Süreli Bellek (LSTM) mimarisi birbirini tekrar eden sıralı bloklardan ve unut, girdi ve katman olmak üç katmandan oluşmaktadır. LSTM mimarisi tasarlanırken X_t ve h_{t-1} değerleri girdi olarak kullanılarak hangi bilgilerin silineceği belirlenmektedir. Unut katmanı üzerinde (f_t) Denklem (5) kullanılarak bu işlemler yapılır ve aktivasyon fonksiyonu olarak sigmoid tercih edilmektedir.

$$f_t = \sigma(W_{f,x} * X_t + W_{f,h} * h_{t-1} + b_f) \quad (5)$$

İkinci aşamada Denklem (6) kullanılarak sigmoid fonksiyonu ile bilgiler güncellenmektedir. Ardından Denklem (7) ile tanh fonksiyonu ile aday bilgiler belirlenir ve Denklem (8) ile yeni bilgiler oluşturulur.

$$i_t = \sigma(W_{i,x} * X_t + W_{i,h} * h_{t-1} + b_i) \quad (6)$$

$$\tilde{c}_t = \tanh(W_{c,x} * X_t + W_{c,h} * h_{t-1} + b_c) \quad (7)$$

$$c_t = c_{t-1} * f_t + i_t * \tilde{c}_t \quad (8)$$

Denklem (9) ve Denklem (10) kullanılarak çıktı verileri elde edilir.

$$o_t = \sigma(W_{o,x} * X_t + W_{o,h} * h_{t-1} + b_o) \quad (9)$$

$$h_t = o_t * \tanh(c_t) \quad (10)$$

Denklemlerde belirtilen W (ağırlık parametresi) ve b (bias parametresi) değerleri model tarafından öğrenilmektedir [98].

LSTM modeli konuşma ve metin işleme, müzik bestesi oluşturma, çevrimdışı el yazısı karakteri tanıma, robotik kalp ameliyatlarında düğümleri bağlama becerisi ve düzensiz farklı dillerde öğrenme vb. alanlarda kullanılmaktadır [99]–[103].

Kapılı Tekrarlayan Birim (Gated Recurrent Unit-GRU)

Kapılı tekrarlayan birim olan sinir ağıları LSTM'nin en çok tercih edilen çeşitlerindendir. Cho ve arkadaşları tarafından standart tekrarlayan sinir ağı modeliyle oluşan ve kaybolan gradyan problemini çözmek amacıyla 2014 yılında ortaya atılan GRU, bir çıkış kapısı olmaması ve daha az parametreye sahip olması özellikleriyle LSTM'den ayrılmaktadır [104], [105]. Bu özellikleriyle klasik LSTM yapısından daha az karmaşıktır [106]. GRU yapısı daha küçük veri setlerinde daha iyi performansla çalıştığı saptanmıştır [107]. GRU'da modeldeki geçmiş bilgilerinin (önceki adımların) ne kadarının geleceğe aktarılacağını sağlayan “güncelleme kapısı” ve modeldeki geçmiş bilgilerin ne kadarının unutulacağına karar veren “sıfırlama kapısı” bulunmaktadır.

GRU'lar doğal dil işleme, konuşma sinyali ve polifonik müzik modelleri üretmede LSTM kadar iyi performansla çalışmaktadır [108], [109].

GRU'nun tam kapılı ve minimum kapılı birim olmak üzere çeşitleri bulunmaktadır. Bunlardan tam kapılı birim Denklem 11, 12, 13 ve 14 ile ifade edilmiştir [110].

$$z_t = \sigma(W_z x_t + U_z h_{t-1} + b_z) \quad (11)$$


$$r_t = \sigma(W_r x_t + U_r h_{t-1} + b_r) \quad (12)$$

$$\tilde{h}_t = g(W_h x_t + U_h (r_t \odot h_{t-1}) + b_h) \quad (13)$$


$$h_t = (1 - z_t) \odot h_{t-1} + z_t \odot \tilde{h}_t \quad (14)$$

Kısıtlanmış Boltzmann Makineleri (Restricted Boltzmann Machines-RBM)

Boltzmann Makineleri ile ilgili ilk çalışma 1986 yılında Smolensky tarafından “Harmonium” adlı çalışma ile yapılmıştır [113]. Daha sonra Hinton ve Salakhutdinov tarafından hızlı öğrenme algoritmalarını keşfetmesiyle daha fazla ön plana çıkmıştır [114]. Kısıtlanmış Boltzmann Makineleri, Boltzmann Makinelerinin bir türüdür. Görünür ve gizli olmak üzere iki nöron grafiğinin simetrik bağlantı aracılığıyla birbirine bir düğümle bağlanmasıyla oluşmaktadır. Ancak düğümler arasında bağlantı bulunmamaktadır. Kısıtlanmış Boltzmann Makineleri boyut indirgeme, işbirlikçi filtreleme, özellik öğrenimi, sınıflandırma ve konu modelleme gibi birçok alanda kullanılmaktadır [114]–[118].



Şekil 3-10: Boltzmann makinesi



Şekil 3-11: Sınırlı boltzmann makinesi


Standart Kısıtlanmış Boltzmann Makineleri (RBM) görünür ve gizli birimlerden oluşmaktadır. RBM yapısı $m \times n$ boyutta ve W olarak gösterilen bir ağırlık matrisinden meydana gelmektedir ve Şekil 3-10’da mimari yapısı görülmektedir [119]. Ağırlık elemanlarının her biri (w_{ij}) matrisinin görünür birimi yani giriş birimi ile ilişkilidir. Görünür i adet ve gizli j adet birimlerin enerji fonksiyonu Denklem (11) ile ifade edilmiştir [120].

$$Enerji(v, h\theta) = - \sum_{i=1}^{görünür} \sum_{j=1}^{gizli} w_{ij} v_i h_j - \sum_{i=1}^{görünür} a_i v_i - \sum_{j=1}^{gizli} b_j h_j \quad (11)$$

$v_i \in \{0,1\}$ görünür elemanı, $h_j \in \{0,1\}$ gizli elemanı, θ ise model parametre değerini, a_i görünür bias ağırlığını ve b_j gizli bias ağırlığını ifade etmektedir.


Derin İnanç Ağları (Deep Belief Networks-DBN)

Derin İnanç Ağları Hinton tarafından Kısıtlı Boltzmann Makineleri katmanlarının bir araya getirilerek oluşturduğu bir sinir ağı modelidir. Kısıtlı Boltzmann Makineleri katmanlarının her birinin sırayla eğitilerek öğrenme modeliyle çalışmaktadır [114]. Şekil 3-12’de direnç inan ağları mimari yapısı gösterilmiştir [121].



Şekil 3-8: Derin inanç ağı modeli

Derin İnanç Ağları görüntü ve konuşma tanıma ve videolardan hareket yakalama gibi çalışmalarda kullanılmaktadır. Şekil 3-13’te art arda eklenmiş Kısıtlanmış Boltzmann Makineleri (RMB) katmanlarından oluşan Derin İnanç Ağları görülmektedir. Bu yapıda her alt ağı gizli katmanı, bir sonraki için katman için görünür katman görevi üstlenmektedir [114].




Şekil 3-9: Art arda eklenmiş kısıtlanmış boltzmann makineleri (RMB)

Derin Oto-Kodlayıcılar (Denoising Autoencoders-DAE)


Derin Oto Kodlayıcılar denetimsiz öğrenme tekniğine sahip bir yapay sinir ağı modelidir. Diablo ağı olarak da adlandırılmaktadır [120]. Genellikle bir veri kümesi içerisinde boyutsallık azaltarak öğrenme modeli gerçekleştirmek için kullanılmaktadır. Derin oto kodlayıcıların giriş veri kümesini en az kayıpla sıkıştırıp boyut azaltarak en iyi öğrenme şeklini amaçlaması stratejisiyle

çalışmaktadır [122]. Girdi katmanı, gizli katman ve çıkış katmanı olmak üzere üç temel bölümden oluşmaktadır. Oto Kodlayıcılar şifreleme-şifre çözme işlemi bittikten sonra çıktı verisi olarak yine aynı girdi verisini elde edene kadar ağırlıklarını değiştirmektedir. Yani Oto Kodlayıcılar girdi ve çıktı verileri Şekil 3-14 teki gibi aynı olana kadar ağırlıklarını değiştirmeye devam etmektedir.



Şekil 3-10: Oto kodlayıcıların yapısı

Derin Oto Kodlayıcılar ise katmanlarda yer alan her bir çıktının ardışık katmanların girişine bağlandığı bir sinir ağı modelidir.



Şekil 3-11: Derin oto-kodlayıcı yapısı

Şekil 3-15' te girdi verisi gizli katmanda şifrelenmiş bir veri kümesinden elde edilmiştir. Sonraki katman ise 2.katmandaki verilerin şifrelenmesi sonucu elde edilmiştir. Bu işlemlerin tekrarlanıp bitmesi sonucunda kodlama işlemi bitip şifrenin çözülmesi aşaması gerçekleşmiştir.

3.2.4. Verilerin Analiz Edilmesi ve Model Kurgusu

Çalışmanın bu kısmında BURULAŞ Bursa Ulaşım Toplu Taşıım İşletmeciliği Turizm Sanayi ve Ticaret A.Ş.'den alınan 2019 yılı Ocak-Haziran ayları arasında altı aylık bir süreci kapsayan ve farklı BursaKARTlara ait 135.029.196 adet yolculuk verisi bulunmaktadır. Bu veriler amaçlanan hedefler doğrultusunda derin öğrenme modellerinde kullanılmadan önce ön analiz işlemlerine ihtiyaç duyulmaktadır. Bu amaçla ilk olarak kentin yaya ve araç trafiğinde hareketliliğin ve yoğunluğun fazla olduğu bölgelerden biri olan, Bursa Uludağ Üniversitenin ve Uludağ Üniversitesi Tıp Fakültesi Hastanesinin bulunduğu ve yolculuk çekim merkezi olarak nitelendirebileceğimiz Bursa Uludağ Üniversitesi varışlı yolculuklara ait BURULAŞ'tan alınan ve .mdf (birincil veri dosyaları) dosya formatında olan verilerin Microsoft SQL Server üzerinde incelenerek çalışma bölgesi varışlı tüm hat ve bilet tiplerine (tam kart, öğrenci, indirimli kart, engelli kart ve diğer kartlar) ait otobüs hatları analiz edilmiştir. Alınan BursaKART verilerinde Şekil 3-16'da gösterildiği üzere yolculukların bilet tipi, kart numarası, tarihi ve saati, hangi hat üzerinde gerçekleştiği, coğrafi koordinat bilgileri vb. veriler yer almaktadır.

```
SELECT TOP (1000) [RECNO]
, [SIRA]
, [ISLEM]
, [BILETTIPI]
, [KARTNO]
, [TARSAAT]
, [CIHAZ]
, [ARAC]
, [HATADI]
, [LAT]
, [LONG]
, [GEOG]
, [MAHALLE]
, [ILCE]
, [BILETTUR_1]
, [BILETTUR_2]
, [BILETTUR_3]
FROM [TTAKTIVITE_2019].[dbo].[BINISLER_19]
```

Şekil 3-12: Otobüs hatları kriterleri

Analiz sonucunda 4/G, 48/A, 992, B/35, E/13, 3/G, 801, 93, B/34-U, B/46, B/44-B,43/H, E/12, 43/D, 5/G, 1/H, 1/T, 901, 35/G, 43/A, 7/A, B/22, B/24, 2/U, 48, B/33-K numaralı hatların Bursa Uludağ Üniversitesi güzergahında olan otobüs hatları olduğu tespit edilmiştir. Bursa Uludağ Üniversitesi'ne giden hatların tespiti hususunda ise kamuya açık olan www.burulas.com.tr internet sitesinde yer alan otobüs sefer bilgisi ve güzergâh haritalarından yararlanılmıştır.

```

, [GEOG]
, [MAHALLE]
, [ILCE]
, [BILETTUR_1]
, [BILETTUR_2]
, [BILETTUR_3]
FROM [TTAKTIVITE_2019].[dbo].[BINISLER_19]

select COUNT(KARTNO) from BINISLER_19 Where HATADI='4/G'
select COUNT(KARTNO) from BINISLER_19 Where HATADI='3/G'
select COUNT(KARTNO) from BINISLER_19 Where HATADI='48/A'
select COUNT(KARTNO) from BINISLER_19 Where HATADI='992'
select COUNT(KARTNO) from BINISLER_19 Where HATADI='B/35'
select COUNT(KARTNO) from BINISLER_19 Where HATADI='E/13'
select COUNT(KARTNO) from BINISLER_19 Where HATADI='801'
select COUNT(KARTNO) from BINISLER_19 Where HATADI='93'
select COUNT(KARTNO) from BINISLER_19 Where HATADI='B/34-U'
select COUNT(KARTNO) from BINISLER_19 Where HATADI='B/46'

100 %
Results Spatial results Messages
<
1 (No column name) 874705
1 (No column name) 392737
1 (No column name) 256572
1 (No column name) 26634
1 (No column name) 3862
1 (No column name) 309296
1 (No column name) 120753
Query executed successfully.
```

Şekil 3-13: Hatlara ait yolcu sayılarının hesaplanması

Toplam 135.029.196 adet yolculuktan 10.402.560 adedi Bursa Uludağ Üniversitesi güzergâhında gerçekleşen hatlara ait yolculuk sayısı olup bunlardan hangilerinin yolcular tarafından ne sıklıkla kullanıldığının tespit edilmesi amacıyla Ocak ve Haziran ayları içerisinde hat bazında gerçekleşen toplam yolcu sayıları Şekil 3-17’de gösterdiği gibi Microsoft SQL Server’da hesaplanmıştır. Hesaplamalar doğrultusunda Ocak-Haziran aylarını kapsayan sürede en fazla yolcu taşınan hattın en az yolcu taşınan hat ismine göre B/24, 93, B/44-B, 4/G, 35/G, 43A, B/46, 48, 3/G, E/12, E/13, 7/A, 48/A, 43/H, 43/D, B/33-K, 2/U, 801, 901, 5/G, B/34-U, 992, B/22, B/35, 1/H şeklindedir.

Hesaplamalar doğrultusunda ocak-haziran aylarını kapsayan sürede en fazla yolcu taşınan hattın en az yolcu taşınan hat ismine göre B/24, 93, B/44-B, 4/G, 35/G, 43/A, B/46, 48, 3/G, E/12, E/13, 7/A, 48/A, 43/H, 43/D, B/33-K, 2/U, 801, 901, 5/G, B/34-U, 992, B/22, B/35, 1/H şeklindedir. Bu hatlardan en çok tercih edilenleri Şekil 3-18 grafiğinde görülen 2.033.953 yolcu sayısı ile Yunuseli başlangıç ve Uludağ Üniversitesi bitişli B/24 numaralı hat, 970.527 yolcu sayısı ile Terminal başlangıç ve Uludağ Üniversitesi bitişli 93 numaralı hat, 948.780 yolcu sayısı ile Uludağ Üniversitesi başlangıç ve Çiftehavuzlar bitişli B/44-B hat, 874.705 yolcu sayısı ile Üniversite başlangıç ve Görükle Kızılırmak Caddesi bitişli 4/G hattıdır.

Bu hatlardan en çok tercih edilen hatlara ait yolcu sayıları Microsoft SQL Server ve Spyder programlarında hesaplandığında Tablo 3-2’de görüldüğü üzere farklı sonuçlar elde edilmektedir. Bu farklılığın sebebi hat bazında gerçekleşen toplam yolcu sayıları Microsoft SQL Server’da tespit edildikten sonra boş (null) verilerin, metro ve tramvay hatlarının ve Bursa Uludağ Üniversitesine gitmeyen otobüs hatlarının listeden çıkarılmış olmasıdır. Bu analizin amacı ise gereksiz verilerin kaldırılıp eksik verilerin tespitinin yapılarak derin öğrenme modelinin sağlıklı verilerle eğitilerek en doğru sonuçları vermesidir.

Tablo 3-2: Farklı programlarda yolcu sayısı

Hat Adı	Microsoft SQL Server	Spyder
B/24	2.033.953	1.656.413
93	970.527	755.401
B/44-B	948.780	754.736
4/G	874.705	747.213
35/G	796.076	675.323

Analiz ve ayıklama işlemlerinin ardından veritabanı paylaşımı yapılarak BursaKART ham verilerinin okunabilir hale getirilmesi için “Spyder” programı kullanılmıştır. Bu sayede Şekil 3-18’deki düzenlemeler ile veriler güncellenerek farklı tarihlere ve farklı bilet tiplerine ait yolculukların hangi saat diliminde kaç adet yolculuk gerçekleştirdiği bilgisine erişilmiştir.

```
#query_hat = 'SELECT [RECNO], [LAT], [LONG], [TARSAAT] FROM BINISLER_19 where HATADI = \'4/G\' '
query_hat = 'SELECT [RECNO], [LAT], [LONG], [TARSAAT] FROM BINISLER_19 where HATADI = \'B/44-B\' and BILETTUR_3 = \'TAM\' '
df = sql_query_command(query_hat)
df = df.dropna()
df = df.sort_values(by='TARSAAT')
df["TARSAAT"] = pd.to_datetime(df["TARSAAT"])

dfNew = DataFrame()
#startDate = df.iloc[0:1,3:4].TARSAAT.values
startDate = datetime.datetime(2019,1,1, 0,5,6)
finalDate = datetime.datetime(2019,6,30, 23,48,57)

counts15Minutes = []
while finalDate > startDate:
    endDate = startDate + datetime.timedelta(minutes = 15)
    if endDate > finalDate:
        endDate = finalDate

    after_start_date = df["TARSAAT"] >= startDate
    before_end_date = df["TARSAAT"] <= endDate
    between_two_dates = after_start_date & before_end_date
    filtered_dates = df.loc[between_two_dates]
    counts15Minutes.append([startDate,len(filtered_dates.index)])
    startDate = startDate + datetime.timedelta(minutes = 15)
```

Şekil 3-14: Verilerin güncellenmesi

Güncellenen veriler ile bu çalışmada kullanılacak olan otobüs hatlarındaki farklı bilet tiplerine ait yolcu sayıları 15'er dakikalık periyotlarla hesaplanmıştır ve Şekil 3-19'da görülen tablolar elde edilmiştir. Böylelikle hangi hattın hangi zaman diliminde daha çok yolcu taşıdığı ve bu yolcu sayılarının hangi bilet tipine ait olduğu verilerine de erişilmiştir.

Tarih Saat	Yolcu Sayısı
1.01.2019 06:05	0
1.01.2019 06:20	0
1.01.2019 06:35	8
1.01.2019 06:50	25
1.01.2019 07:05	28
1.01.2019 07:20	21
1.01.2019 07:35	44
1.01.2019 07:50	27
1.01.2019 08:05	41
1.01.2019 08:20	31
1.01.2019 08:35	30
1.01.2019 08:50	35
1.01.2019 09:05	35
1.01.2019 09:20	33
1.01.2019 09:35	34
1.01.2019 09:50	21
1.01.2019 10:05	30
1.01.2019 10:20	34
1.01.2019 10:35	35
1.01.2019 10:50	42
1.01.2019 11:05	60
1.01.2019 11:20	36
1.01.2019 11:35	44
1.01.2019 11:50	39
1.01.2019 12:05	58
1.01.2019 12:20	39
1.01.2019 12:35	67


(a)

Tarih Saat	Yolcu Sayısı
1.01.2019 06:05	0
1.01.2019 06:20	0
1.01.2019 06:35	20
1.01.2019 06:50	1
1.01.2019 07:05	11
1.01.2019 07:20	0
1.01.2019 07:35	9
1.01.2019 07:50	3
1.01.2019 08:05	5
1.01.2019 08:20	3
1.01.2019 08:35	6
1.01.2019 08:50	1
1.01.2019 09:05	3
1.01.2019 09:20	7
1.01.2019 09:35	11
1.01.2019 09:50	6
1.01.2019 10:05	5
1.01.2019 10:20	9
1.01.2019 10:35	12
1.01.2019 10:50	7
1.01.2019 11:05	12
1.01.2019 11:20	5
1.01.2019 11:35	16
1.01.2019 11:50	19
1.01.2019 12:05	14
1.01.2019 12:20	11
1.01.2019 12:35	20

(b)

Şekil 3-15: (a) ve (b) Güncellenen BursaKART verileri

Şekil 3-19'da belirtilen ve çalışmada kullanılan diğer hatlar için de aynı şekilde uygulanan hesaplamalar sonrası en yoğun otobüs hatlarının yolcu sayısı dağılımı ve aylara göre nasıl değişkenlik gösterdiği çıkarılmıştır Şekil 3-20 ve Tablo 3-3'te verilmiştir.



Şekil 3-16: Hatlara göre toplam yolcu sayısı dağılımı

Aylara göre farklı dağılım gösteren bu yolculukları tam, öğrenci, öğretmen, 65 yaş, engelli-refakatçi ve diğer olmak üzere 6 tip bilet profiliyle gerçekleştirmiştir. Bu bilet tipleri Spyder programında analiz edildiğinde hangi bilet tipinin hangi hattı hangi ay, hangi gün (hafta içi-hafta sonu) hatta hangi saatte kullandığı bilgilerine ulaşılmıştır.


Tablo 3-3: Aylara göre yolcu sayısı dağılımı

	OCAK	ŞUBAT	MART	NİSAN	MAYIS	HAZİRAN	TOPLAM
B/24	298.760	257.567	305.216	260.694	308.596	225.580	1.656.413
93	126.370	114.659	148.537	144.334	124.236	97.265	755.401
B/44-B	134.099	120.209	128.011	139.504	129.570	103.343	754.736
4/G	145.773	84.728	141.812	129.166	150.836	94.898	747.213
35/G	133.789	86.438	120.500	117.830	128.276	88.490	675.323


Çalışmanın bu kısmında yoğun olarak kullanılan bu hatların güzergâh ve bilet tiplerine göre taşınan toplam yolcu sayısı detaylı şekilde analiz edilmiştir.

B/24 numaralı hat Şekil 3-21’de gösterildiği şekilde Yunuseli Mahallesinden hareket ederek sırasıyla Hamidiye Caddesi, 1. Kavaklı Caddesi, Hancı Caddesi, Sanayi Caddesi, Fatih Sultan Mehmet Bulvarı, Bilginler Caddesi, Ahıska Caddesi ve ardından İzmir Yolu Caddesinden Uludağ Üniversitesine varmaktadır.

B/24 numaralı hat ocak ve haziran ayları arasında gerçekleşen 6 aylık süreçte toplam 1.656.413 adet yolcu taşınmıştır. En fazla yolcu 308.596 adet ile mayıs ayında taşınmıştır.



Şekil 3-17: B/24 numaralı hat güzergahı




Şekil 3-18: B/24 hattı yolcu sayısının aylara göre dağılımı

Taşınan yolcu sayısını bilet tiplerine göre analiz edildiğinde haziran ayında öğrenci yolcu sayısında azalma olduğu Tablo 3-4'te görülmektedir bu azalmanın sebebiyse üniversitelerin yaz tatili tarihlerine denk gelmiş olmasıdır.

Tablo 3-4: B/24 numaralı hat bilet tiplerine ve aylara göre yolcu sayısı


	Tam	Yüzde	Öğrenci	Yüzde	Diğer	Yüzde
Ocak	165.710	%55	94.784	%32	38.266	%13
Şubat	141.056	%55	81.388	%31	35.123	%14
Mart	159.051	%52	104.897	%34	41.268	%14
Nisan	138.396	%53	87.489	%34	34.809	%13
Mayıs	160.773	%52	107.482	%35	40.341	%13
Haziran	134.485	%60	59.825	%26	31.270	%14

B/24 numaralı hattın bütün bilet tipleri için işe gidiş (07:00-09:00) ve işten dönüş (17:00-19:00) saatlerinin hafta içi ve hafta sonu değişimini gösteren yolcu sayısı grafiği Bursa Uludağ Üniversitesi'nin de akademik takvimde açık olduğu 2019 yılı 14 Ocak Pazartesi-20 Ocak Pazar tarihleri analiz edilip Şekil 3-23'te gösterilmiştir. Grafiğe göre hafta içi işe gidiş saatlerindeki yolcu sayısı hafta sonu işe gidiş saatlerindeki yolcu sayısının yaklaşık iki katıdır.




Şekil 3-19: B/24 hattı yolcu sayısının günlere göre dağılımı

Bursa Uludağ Üniversitesi'nin akademik takviminde yarıyıl sonu sınavları olan 14-25 Ocak 2019 tarihleri içerisinde 14-20 Ocak 2019 tarihlerini kapsayan öğrenci yolcu sayısı dağılımında hafta içi 20.096 adet, hafta sonu ise 3883 adet öğrencinin yolculuk yaptığı analiz edilmiştir. Hafta içi günlük yolcu sayısı yaklaşık aynı değerlerdeyken hafta sonu günlük yolcu sayısının yarı yarıya azaldığı Şekil 3-24'te görülmektedir.




Şekil 3-20: B/24 numaralı hattın öğrenci sayısının günlere göre dağılımı

93 numaralı hat Şekil 3-25'te gösterildiği gibi Yeni Yalova Yolu Caddesinden yani Bursa Terminalden hareket ederek sırasıyla İstanbul Caddesi, Avrupa Konseyi Bulvarı, Mudanya Caddesi ve ardından İzmir Yolu Caddesinden Uludağ Üniversiteye varmaktadır.



Şekil 3-21: 93 numaralı hat güzergahı

93 numaralı hat ocak ve haziran ayları arasında gerçekleşen 6 aylık süreçte toplam 755.401 adet yolcu taşınmıştır. En fazla yolcu 148.537 adet ile mart ayında taşınmıştır.




Şekil 3-22: 93 hattı yolcu sayısının aylara göre dağılımı

Taşınan yolcu sayısını bilet tiplerine göre analiz edildiğinde tam bilet tipine sahip yolcu sayısında azalmanın en fazla haziran ayında olduğu görülmektedir. Şubat ve haziran aylarında ise üniversitelerin ara tatil ve yaz tatili tarihlerine denk gelmesi sebebiyle öğrenci yolcu sayısında azalma olduğu Tablo 3-5'te görülmektedir.

Tablo 3-5: 93 numaralı hat bilet tiplerine ve aylara göre yolcu sayısı


	Tam	Yüzde	Öğrenci	Yüzde	Diğer	Yüzde
Ocak	71.871	%57	44.964	%36	9535	%7
Şubat	65.704	%57	39.605	%35	9350	%8
Mart	77.980	%52	59.001	%40	11.556	%8
Nisan	77.841	%54	55.483	%38	11.010	%8
Mayıs	62.154	%50	47.899	%39	14.183	%11
Haziran	55.358	%57	29.646	%30	12.261	%13

B/44-B numaralı hat ring şeklinde çalışmakta olup Şekil 3-27’de gösterildiği şekilde Uludağ Üniversitesinden hareket ederek sırasıyla İzmir Yolu Caddesi, Nilüfer Caddesi, Ertuğrul Caddesi, Beşevler Caddesi, Mıhraplı Caddesi, Dikkaldırım Caddesi, Değirmen Caddesi, Zübeyde Hanım Caddesi, Mudanya Caddesi, 1.Nilüfer Caddesi, 2. Kanal Caddesi, Avrupa Konseyi Bulvarı ve ardından Zübeyde Hanım Caddesi üzerinden aynı yolu izleyerek ringi tamamlamaktadır.



Şekil 3-23: B/44-B numaralı hat güzergahı

B/44-B numaralı hat ocak ve haziran ayları arasında gerçekleşen 6 aylık süreçte toplam 754.736 adet yolcu taşınmıştır. En fazla yolcu 139.504 adet ile nisan ayında taşınmıştır.



Şekil 3-24: B/44-B hattı yolcu sayısının aylara göre dağılımı

Taşınan yolcu sayı aylara ve bilet tiplerine göre analiz edildiğinde tam bilet tipine sahip yolcu sayısının en az haziran ayında olduğu görülmektedir. Şubat ve haziran aylarında ise üniversitelerin ara tatil ve yaz tatili tarihlerine denk gelmesi sebebiyle öğrenci yolcu sayısında belirgin bir azalma olduğu Tablo 3-6’da görülmektedir.

Tablo 3-6: B/44-B numaralı hat bilet tiplerine ve aylara göre yolcu sayısı


	Tam	Yüzde	Öğrenci	Yüzde	Diğer	Yüzde
Ocak	76.533	%57	36.697	%27	20.869	%16
Şubat	67.603	%56	32.482	%27	20.124	%17
Mart	66.699	%52	40.910	%32	20.402	%16
Nisan	74.551	%53	42.639	%31	22.314	%16
Mayıs	66.922	%52	41.910	%32	20.738	%16
Haziran	62.871	%61	23.347	%23	17.125	%16

4/G numaralı hat Şekil 3-29’da görüldüğü gibi ring şeklinde çalışmakta olup Uludağ Üniversitesi’nden hareketine başlayarak sırayla Bahriye Üçok Caddesi, Atatürk Caddesi, Zafer Caddesi, Fevzi Çakmak Caddesi, Çağdaş Caddesi, Akdeniz Caddesi, Tüter Caddesi, Kızıllırmak Caddesi, Üçoluk Caddesi ve ardından Bahriye Üçok Caddesi üzerinden aynı yolu izleyerek ringi tamamlamaktadır.



Şekil 3-25: 4/G numaralı hat güzergahı

4/G numaralı hat ocak ve haziran ayları arasında gerçekleşen 6 aylık süreçte toplam 747.213 adet yolcu taşınmıştır. En fazla yolcu 150.836 adet ile mayıs ayında taşınmıştır.



Şekil 3-26: 4/G hattı yolcu sayısının aylara göre dağılımı

Taşınan yolcu sayı aylara ve bilet tiplerine göre analiz edildiğinde tam ve öğrenci bilet tipine sahip yolcu sayısının en az şubat ayında olduğu görülmektedir. Ayrıca şubat ve haziran aylarında ise üniversitelerin ara tatil ve yaz tatili tarihlerine denk gelmesi sebebiyle öğrenci yolcu sayısında belirgin bir azalma olduğu Tablo 3-7’de görülmektedir.


Tablo 3-7: 4/G numaralı hat bilet tiplerine ve aylara göre yolcu sayısı

	Tam	Yüzde	Öğrenci	Yüzde	Diğer	Yüzde
Ocak	47.351	%33	82.184	%56	16.238	%11
Şubat	29.629	%35	44.210	%52	10.889	%13
Mart	39.469	%28	87.305	%61	15.038	%11
Nisan	38.569	%30	76.143	%59	14.454	%11
Mayıs	42.924	%28	91.250	%61	16.662	%11
Haziran	33.827	%36	49.422	%52	11.649	%12

35/G numaralı hat Şekil 3-31’de görüldüğü gibi ring şeklinde çalışmakta olup Uludağ Üniversitesi’nden hareketine başlayarak sırayla Bahriye Üçok Caddesi, Atatürk Caddesi, Gülveren Caddesi, Koza Caddesi, Selvi Caddesi, Fevzi Çakmak Caddesi, Zafer Caddesi, Muaammer Aksoy Caddesi, Atatürk Bulvarı, Cevizlik Caddesi, Kızılırmak Caddesi, Üçoluk Caddesi ve ardından tekrar Bahriye Üçok Caddesi üzerinden aynı yolu izleyerek ringi tamamlamaktadır.



Şekil 3-27: 35/G numaralı hat güzergahı



Şekil 3-28: 35/G hattı yolcu sayısının aylara göre dağılımı

35/G numaralı hat ocak ve haziran ayları arasında gerçekleşen 6 aylık süreçte toplam 675.323 adet yolcu taşınmıştır. En fazla yolcu 133.789 adet ile ocak ayında taşınmıştır.

Tablo 3-8: 35/G numaralı hat bilet tiplerine ve aylara göre yolcu sayısı

	Tam	Yüzde	Öğrenci	Yüzde	Diğer	Yüzde
Ocak	40.834	%31	80.777	%60	12.178	%9
Şubat	28.871	%33	48.456	%56	9111	%11
Mart	33.380	%28	76.641	%63	10.479	%9
Nisan	32.364	%28	74.670	%63	10.796	%9
Mayıs	34.254	%27	82.242	%64	11.780	%9
Haziran	30.411	%35	48.954	%55	9125	%10

Taşınan yolcu sayı aylara ve bilet tiplerine göre analiz edildiğinde tam ve öğrenci bilet tipine sahip yolcu sayısının en az şubat ayında olduğu görülmektedir. Ayrıca şubat ve haziran aylarında ise üniversitelerin ara tatil ve yaz tatili tarihlerine denk gelmesi sebebiyle öğrenci yolcu sayısında belirgin bir azalma olduğu Tablo 3-8’de görülmektedir.

4. AKILLI KART VERİLERİ İLE TOPLU TAŞIMA SİSTEMİ YOLCU SAYISI TAHMİNİNE DAYALI MODELİN UYGULANMASI

Çalışmanın bu bölümünde, tezin üçüncü bölümde detaylı olarak anlatılan ve literatürde benzer çalışmalarda yaygın olarak tercih edilen yapay sinir ağı modellerinden Uzun-Kısa Dönemli Bellek (Long-Short Term Memory-LSTM) ve Kapılı Tekrarlayan Birim (Gated Recurrent Unit-GRU) modelleri kullanılarak, Bursa Uludağ Üniversitesi varışlı otobüs hatlarında yolcu sayısı tahmini uygulaması anlatılmıştır. Çalışma modeli uygulanırken, farklı yapay sinir ağı modelleriyle farklı düğüm ve katman sayısı değerleri rastgele seçilerek uygulanmıştır. Bu rastgele seçimin sebebi yapay sinir ağı tabanlı sinir ağı modellerinin genellikle sezgisel olması yani başlangıçta seçilen değerlerin her seferinde farklı sonuç değerleri oluşturmasıdır. Bu amaçla çalışma alanı kapsamındaki otobüs hatlarına farklı modeller, farklı düğüm ve katman sayılarıyla uygulanmış ve elde edilen farklı sonuç değerleri tablolar ve grafiklerle karşılaştırılmıştır. Çalışmada girdi verisi olarak 1 Ocak 2019 ve 30 Haziran 2019 tarihlerini arasını kapsayan ve giriş katmanına uygulanan yolcu sayısı verilerinin %90'ı eğitim seti, %10'u test seti olarak kullanılmıştır. Modelin uygulanması aşamasında zamanı ve bellek depolama alanlarını optimize etmek için son zamanlarda makinesi öğrenmesi alanında sıklıkla kullanılan gradyan tabanlı Adam optimizasyonu kullanılmıştır [123]. Bu sayede geleneksel gradyan algoritmalarına göre yüksek boyutlu veri kümesi olan otobüs hat verileri modelde çalışırken zaman ve bellek daha optimum düzeyde kullanılmıştır. Model sonucu çıktı katmanında oluşan tahminleri değerlendirmek için Kök Ortalama Kare Hata (Root Mean Square Error-RMSE) ve Ortalama Mutlak Hata (Mean Absolute Error-MAE) metrik değerleri kullanılmıştır.

Tablo 4-1: Metrik değerler ve formülleri

Açıklaması	Hata Ölçüt Formülü
RMSE	$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n e_t^2}$
MAE	$MAE = \frac{1}{n} \sum_{t=1}^n e_t $

$$e_t = r_t - p_t \quad (12)$$

Tablo 4-1’de t belirli bir zamanını, r_t zaman aralığını, p_t tahmin edilen zamanı ifade ederken hata Denklem (12) ile ifade edilmektedir [124].

4.1. UZUN-KISA DÖNEMLİ BELLEK (LSTM) VE KAPILI TEKRARLAYAN BİRİM (GRU) MODELLERİNİN UYGULANMASI


BursaKART verileri kullanılarak uygulanacak yapay sinir ağı modellerinde model; girdi katmanı, LSTM veya GRU algoritmaları ve çıktı katmanı olmak üzere üç kısımdan oluşmaktadır. Burada girdi katmanına farklı hatlara ait farklı zamanlarda gerçekleşen yolcu sayıları uygulanmaktadır. Model uygulanırken düğüm sayıları 100 ve 200 olmak üzere iki değer, eğitimin kaç iterasyonda çalışacağını gösteren “epoch” değeri ise 100, 150 ve 200 olmak üzere üç farklı değer, LSTM ve GRU ağlarında tek katmanlı ve üç katmanlı olarak kullanılmıştır. Ayrıca otobüs hatlarına ait yolcu sayısı verileri 15’er dakikalık periyotlarla giriş katmanına uygulanmaktadır. Çıktı katmanında ise modelin tahmin sonuçları ve gerçek değerlerin karşılaştırıldığı grafik, RMSE ve MAE değerleri elde edilmektedir.

Analizler sonucu ilk olarak yolcu sayısı en fazla olan B/24 numaralı hatta ait tüm bilet tipleri, tam bilet ve öğrenci bilet tipleri için farklı başlangıç değerleri ile LSTM ve GRU ağ modeli uygulanmıştır.

B/24 numaralı hatta tüm bilet tipleri için uygulanan modellere ait elde edilen hata ölçüt değerleri Tablo 4-2’de verilmiştir. RMSE ve MAE değerleri sırasıyla 27,749 ve 21,934 olarak en iyi sonuç olup, GRU ağı ile elde edilmiştir.


Tablo 4-2: Farklı başlangıç değerleriyle B/24 Hattı tüm bilet tiplerinin RMSE VE MAE değerleri

B/24 Hattı Tüm Bilet Tipleri Yolcu Sayısı Tahmini Hata Ölçüt Değerleri						
	1.TEST (LSTM)	2.TEST (LSTM)	3.TEST (LSTM)	4.TEST (GRU)	5.TEST (GRU)	6.TEST (GRU)
RMSE	27,767	27,889	27,916	27,831	27,749	27,863
MAE	21,932	22,023	22,064	22,047	21,934	22,022



Şekil 4-1: B/24 tüm bilet tipleri için gerçek değerler ve tahmin değerleri

Tablo 4-2’de verilen RMSE ve MAE değerleri ile elde edilen gerçek ve tahmin edilen yolcu sayısı grafiği Şekil 4-1’de gösterilmektedir.



Şekil 4-2: B/24 tüm bilet tipleri eğitim ve test seti kayıpları


Aynı tahmin değerlerine ilişkin eğitim ve test seti kaybı değerleri ise Şekil 4-2’de gösterilmiştir. Bu şekle göre eğitim seti kaybı mavi renk ile ifade edilmiştir ve ilk iterasyon adımlarında 0,11 seviyesinden 0,0544 seviyesine önemli ölçüde azalırken, test seti kaybı turuncu renk ile ifade edilmiş olup 0,058 seviyesinden 0,0466 seviyesine kadar düşüş göstermiştir. Bu değerler 100 düğüm sayısı, 200 epoch değeri ve tek katmanlı GRU sinir ağı ile gerçekleştirilmiştir. 5.test denemesi sonucu elde edilen en iyi RMSE ve MAE değerleri sırasıyla 27,749 ve 21,934 iken en kötü RMSE ve MAE değerleri 3.test denemesi sonucu sırasıyla 27,916 ve 22,064 olarak LSTM

ağı ile elde edilmiştir. Bu durum için, rastgele başlangıç değerleriyle elde edilen sonuçlarda en iyi RMSE ve MAE değerlerinin, en kötü RMSE ve MAE değerlerine göre sırasıyla %0,60 ve %0,59 iyileştiği tespit edilmiştir.


B/24 numaralı hatta tam bilet tipi için rastgele başlangıç ağırlıkları seçilerek uygulanan LSTM ve GRU ağ modelleri sonucu elde edilen hata ölçüt değerleri Tablo 4-3'te verilmiştir. RMSE ve MAE sırasıyla 18,517 ve 14,569 ile en iyi sonuç olup GRU ağı ile elde edilmiştir.

Tablo 4-3: Farklı başlangıç değerleriyle B/24 hattı tam bilet tipi RMSE VE MAE değerleri

B/24 Hattı Tam Bilet Tipi Yolcu Sayısı Tahmini Hata Ölçüt Değerleri						
	1.TEST (LSTM)	2.TEST (LSTM)	3.TEST (LSTM)	4.TEST (GRU)	5.TEST (GRU)	6.TEST (GRU)
RMSE	18,531	18,724	18,644	18,602	18,517	18,652
MAE	14,555	14,652	14,609	14,591	14,569	14,613



Şekil 4-3: B/24 tam bilet tipi için gerçek değerler ve tahmin değerleri




Şekil 4-4: B/24 tam bilet tipi eğitim ve test seti kayıpları

Tablo 4-3'te verilen RMSE ve MAE değerleri ile elde edilen gerçek ve tahmin edilen yolcu sayısı grafiği Şekil 4-3'te gösterilmektedir. Aynı tahmin değerlerine ilişkin eğitim ve test seti kayıp değerleri ise Şekil 4-4'te verilmiştir. Şekil 4-4'te görüldüğü üzere ilk iterasyon adımlarında eğitim seti kaybı 0,12 seviyesinden 0,0713 seviyesine önemli derecede azalırken, test seti kaybı ise 0,0796 seviyesinden 0,0691 seviyesine kadar düşüş göstermiştir. Bu değerler 100 düğüm sayısı, 200 epoch değeri ve tek katmanlı GRU sinir ağı ile gerçekleştirilmiştir. 5.test denemesi sonucu elde edilen en iyi RMSE ve MAE değerleri sırasıyla 18,517 ve 14,569 iken en kötü RMSE ve MAE değerleri 2.test denemesi sonucu sırasıyla 18,724 ve 14,652 olarak LSTM ile elde edilmiştir. Bu durum için, rastgele başlangıç değerleriyle elde edilen sonuçlarda en iyi RMSE ve MAE değerlerinin, en kötü RMSE ve MAE değerlerine göre sırasıyla %1,10 ve %0,56 iyileştiği tespit edilmiştir.


B/24 numaralı hatta öğrenci bilet tipi için rastgele başlangıç ağırlıkları seçilerek uygulanan LSTM ve GRU ağ modelleri sonucu elde edilen hata ölçüt değerleri Tablo 4-4'te verilmiştir. RMSE ve MAE sırasıyla 11,418 ve 8,701 olarak en iyi sonuç LSTM ağı ile elde edilmiştir.

Tablo 4-4: Farklı başlangıç değerleriyle B/24 hattı öğrenci bilet tipi RMSE VE MAE değerleri

B/24 Hattı Öğrenci Bilet Tipi Yolcu Sayısı Tahmini Hata Ölçüt Değerleri						
	1.TEST (LSTM)	2.TEST (LSTM)	3.TEST (LSTM)	4.TEST (GRU)	5.TEST (GRU)	6.TEST (GRU)
RMSE	11,418	11,619	11,628	11,744	11,452	11,631
MAE	8,701	8,844	8,853	8,968	8,713	8,863



Şekil 4-5: B/24 öğrenci bilet tipi için gerçek değerler ve tahmin değerleri



Şekil 4-6: B/24 öğrenci bilet tipi eğitim ve test seti kayıpları

Tablo 4-4'te verilen RMSE ve MAE değerleri ile elde edilen gerçek ve tahmin edilen yolcu sayısı grafiği Şekil 4-5'te gösterilmektedir. Aynı tahmin değerlerine ilişkin eğitim ve test seti kayıp değerleri ise Şekil 4-6'da verilmiştir. Şekil 4-6'da görüldüğü üzere ilk iterasyon adımlarında eğitim seti kaybı 0,09 seviyesinden 0,0498 seviyesine önemli derecede azalırken, test seti kaybı ise 0,048 seviyesinden 0,0351 seviyesine kadar düşüş göstermiştir. Bu değerler 100 düğüm sayısı, 200 epoch değeri ve tek katmanlı LSTM sinir ağı ile gerçekleştirilmiştir. 1.test denemesi sonucu elde edilen en iyi RMSE ve MAE değerleri sırasıyla 11,418 ve 8,701 iken en kötü RMSE ve MAE değerleri 4.test denemesi sonucu sırasıyla 11,744 ve 8,968 olarak GRU ile elde edilmiştir. Bu durum için, rastgele başlangıç değerleriyle elde edilen sonuçlarda en iyi RMSE ve MAE değerlerinin, en kötü RMSE ve MAE değerlerine göre sırasıyla %2,77 ve %2,97 iyileştiği tespit edilmiştir.


B/24 hattına ait model kayıp grafikleri olan Şekil 4-2, Şekil 4-4 ve Şekil 4-6 karşılaştırıldığında zaman-model kaybının en fazla öğrenci bileti tipine ait Şekil 4-6 grafiğinde olduğu görülürken en az kaybın Şekil 4-4'te yer alan tam bileti tipine ait olduğu görülmektedir.

B/44-B numaralı hatta ait tüm bileti tipleri için rastgele başlangıç ağırlıkları seçilerek uygulanan LSTM ve GRU ağı modelleri sonucu elde edilen hata ölçüt değerleri Tablo 4-5'te verilmiştir. RMSE ve MAE değerleri sırasıyla 21,450 ve 15,649 olarak en iyi sonuç LSTM ağı ile elde edilmiştir.


Tablo 4-5'te verilen RMSE ve MAE değerleri ile elde edilen gerçek ve tahmin edilen yolcu sayısı grafiği Şekil 4-7'de gösterilmektedir. Aynı tahmin değerlerine ilişkin eğitim ve test seti kayıp değerleri ise Şekil 4-8'de verilmiştir.

Tablo 4-5: Farklı başlangıç değerleriyle B/44-B hattı tüm bileti tiplerinin RMSE VE MAE değerleri

	B/44-B Hattı Tüm Bileti Tipleri Yolcu Sayısı Tahmini Hata Ölçüt Değerleri					
	1.TEST (LSTM)	2.TEST (LSTM)	3.TEST (LSTM)	4.TEST (GRU)	5.TEST (GRU)	6.TEST (GRU)
RMSE	21,556	21,450	21,495	21,655	21,558	21,571
MAE	15,614	15,649	15,577	15,570	15,652	15,536



Şekil 4-6: B/44-B tüm bilet tipleri için gerçek değerler ve tahmin değerleri




Şekil 4-7: B/44-B tüm bilet tipleri eğitim ve test seti kayıpları

Şekil 4-8'de görüldüğü üzere ilk iterasyon adımlarında eğitim seti kaybı 0,1 seviyesinden 0,0527 seviyesine önemli ölçüde azalırken, test seti kaybı ise 0,0720 seviyesinden 0,0481 seviyesine kadar düşüş göstermiştir. Bu değerler 100 düğüm sayısı, 200 epoch değeri ve tek katmanlı LSTM sinir ağı ile gerçekleştirilmiştir. 2.test denemesi sonucu elde edilen en iyi RMSE ve MAE değerleri sırasıyla 21,450 ve 15,649 iken en kötü RMSE ve MAE değerleri 4.test denemesi sonucu sırasıyla 21,655 ve 15,570 olarak GRU ile elde edilmiştir. Bu durum için, rastgele başlangıç değerleriyle elde edilen sonuçlarda en iyi RMSE değerinin, en kötü RMSE değerine göre %0,95 iyileştiği tespit edilmiştir.

B/44-B numaralı hatta ait tam bilet tipi için rastgele başlangıç ağırlıkları seçilerek uygulanan LSTM ve GRU ağ modelleri sonucu elde edilen hata ölçüt değerleri Tablo 4-6’da verilmiştir. RMSE ve MAE değerleri sırasıyla 14,305 ve 10,186 olarak en iyi sonuç GRU ağı ile elde edilmiştir.

Tablo 4-6: Farklı başlangıç değerleriyle B/44-B hattı tam bilet tipi RMSE VE MAE değerleri


B/44-B Hattı Tam Bilet Tipi Yolcu Sayısı Tahmini Hata Ölçüt Değerleri						
	1.TEST (LSTM)	2.TEST (LSTM)	3.TEST (LSTM)	4.TEST (GRU)	5.TEST (GRU)	6.TEST (GRU)
RMSE	14,468	14,467	14,467	14,439	14,484	14,305
MAE	10,307	10,328	10,315	10,229	10,353	10,186



Şekil 4-8: B/44-B tam bilet tipi için gerçek değerler ve tahmin değerleri

Tablo 4-6’da verilen RMSE ve MAE değerleri ile elde edilen gerçek ve tahmin edilen yolcu sayısı grafiği Şekil 4-9’da gösterilmektedir. Aynı tahmin değerlerine ilişkin eğitim ve test seti kayıp değerleri ise Şekil 4-10’da verilmiştir. Şekil 4-10’da görüldüğü üzere ilk iterasyon adımlarında eğitim seti kaybı 0,098 seviyesinden 0,0673 seviyesine önemli derecede azalırken, test seti kaybı ise 0,078 seviyesinden 0,0703 seviyesine kadar düşüş göstermiştir. Bununla birlikte, test seti kaybı 80 iterasyon adımından itibaren artış göstermektedir. Bu değerler 200 düğüm sayısı, 150 epoch değeri ve 3 katmanlı GRU sinir ağı ile gerçekleştirilmiştir. 6.test denemesi sonucu elde

edilen en iyi RMSE ve MAE değerleri sırasıyla 14,305 ve 10,186 iken en kötü RMSE ve MAE değerleri 5.test denemesi sonucu sırasıyla 14,484 ve 10,353 olarak GRU ile elde edilmiştir. Bu durum için, rastgele başlangıç değerleriyle elde edilen sonuçlarda en iyi RMSE ve MAE değerlerinin, en kötü RMSE ve MAE değerlerine göre sırasıyla %1,26 ve %1,61 iyileştiği tespit edilmiştir.




Şekil 4-9: B/44-B tam bilet tipi eğitim ve test seti kayıpları

B/44-B numaralı hatta öğrenci bilet tipi için rastgele başlangıç ağırlıkları seçilerek uygulanan LSTM ve GRU ağ modelleri sonucu elde edilen hata ölçüt değerleri Tablo 4-7’de verilmiştir. RMSE ve MAE değerleri sırasıyla 8,066 ve 5,427 olarak en iyi sonuç LSTM ağı ile elde edilmiştir.


Tablo 4-7: Farklı başlangıç değerleriyle B/44-B hattı öğrenci bilet tipi RMSE VE MAE değerleri

	B/44-B Hattı Öğrenci Bilet Tipi Yolcu Sayısı Tahmini Hata Ölçüt Değerleri					
	1.TEST (LSTM)	2.TEST (LSTM)	3.TEST (LSTM)	4.TEST (GRU)	5.TEST (GRU)	6.TEST (GRU)
RMSE	8,166	8,066	8,169	8,152	8,148	8,098
MAE	5,389	5,427	5,378	5,388	5,480	5,360

Tablo 4-7’de verilen RMSE ve MAE değerleri ile elde edilen gerçek ve tahmin edilen yolcu sayısı grafiği Şekil 4-11’de gösterilmektedir. Aynı tahmin değerlerine ilişkin eğitim ve test seti kayıp değerleri ise Şekil 4-12’de verilmiştir.



Şekil 4-10: B/44-B öğrenci bilet tipi için gerçek değerler ve tahmin değerleri



Şekil 4-11: B/44-B öğrenci bilet tipi eğitim ve test seti kayıpları

Şekil 4-12’de görüldüğü üzere ilk iterasyon adımlarında eğitim seti kaybı 0,078 seviyesinden 0,0527 seviyesine önemli derecede azalırken, test seti kaybı ise 0,053 seviyesinden 0,0368 seviyesine kadar düşüş göstermiştir. Bu değerler 100 düğüm sayısı, 200 epoch değeri ve tek katmanlı LSTM sinir ağı ile gerçekleştirmiştir. 2.test denemesi sonucu elde edilen en iyi RMSE


ve MAE değerleri sırasıyla 8,066 ve 5,427 iken en kötü RMSE ve MAE değerleri 3.test denemesi sonucu sırasıyla 8,169 ve MAE 5,378 olarak LSTM ile elde edilmiştir. Bu durum için, rastgele başlangıç değerleriyle elde edilen sonuçlarda en iyi RMSE değerinin, en kötü RMSE değerine göre %1,26 iyileştiği tespit edilmiştir.

B/44-B hattına ait model kayıp grafikleri olan Şekil 4-8, Şekil 4-10 ve Şekil 4-12 karşılaştırıldığında model kaybının en fazla öğrenci bileti tipine ait Şekil 4-12 grafiğinde olduğu görülürken en az kaybın Şekil 4-10’da yer alan tam bileti tipine ait olduğu görülmektedir.

4/G numaralı hatta tüm bileti tipleri için rastgele başlangıç ağırlıkları seçilerek uygulanan LSTM ve GRU ağı modelleri sonucu elde edilen hata ölçüt değerleri Tablo 4-8’de verilmiştir. RMSE ve MAE değerleri sırasıyla 29,957 ve 23,644 olarak en iyi sonuç LSTM ağı ile elde edilmiştir.


Tablo 4-8: Farklı başlangıç değerleriyle 4/G hattı tüm bileti tiplerinin RMSE VE MAE değerleri

	4/G Hattı Tüm Bileti Tipleri Yolcu Sayısı Tahmini Hata Ölçüt Değerleri					
	1.TEST (LSTM)	2.TEST (LSTM)	3.TEST (LSTM)	4.TEST (GRU)	5.TEST (GRU)	6.TEST (GRU)
RMSE	30,502	30,110	29,957	30,727	30,081	30,495
MAE	23,821	23,749	23,644	24,032	23,736	23,436



Şekil 4-12: 4/G tüm bileti tipleri için gerçek değerler ve tahmin değerleri

Tablo 4-8’de verilen RMSE ve MAE değerleri ile elde edilen gerçek ve tahmin edilen yolcu sayısı grafiği Şekil 4-13’te gösterilmektedir. Şekil 4-13’te görüldüğü üzere 1000-1200 zaman aralığında gerçek yolcu sayısı 0-10 aralığında iken, tahmin edilen yolcu sayısı 20-40 aralığında olduğu gözlemlenmektedir. Bu durum, modelin hata oranının artmasına sebep olmaktadır. Aynı tahmin değerlerine ilişkin eğitim ve test seti kayıp değerleri ise Şekil 4-14’te verilmiştir. Şekil 4-14’te görüldüğü üzere ilk iterasyon adımlarında eğitim seti kaybı 0,125 seviyesinden 0,1050 seviyesine önemli derecede azalırken, test seti kaybı ise 0,145 seviyesinden 0,1044 seviyesine kadar düşüş göstermiştir. Bu değerler 200 düğüm sayısı, 150 epoch değeri ve 3 katmanlı LSTM sinir ağı ile gerçekleştirilen 3.test denemesi sonucu elde edilmiştir. En kötü RMSE 30,727 ve MAE 24,032 değerlerine karşılık RMSE 29,957 ve MAE 23,644 değerleri elde edilmiştir. Bu durum için, rastgele başlangıç değerleriyle elde edilen sonuçlarda en iyi RMSE ve MAE değerlerinin, en kötü RMSE ve MAE değerlerine göre sırasıyla %2,50 ve %1,61 iyileştiği tespit edilmiştir.




Şekil 4-13: 4/G tüm bilet tipleri eğitim ve test seti kayıpları

4/G numaralı hatta ait tam bilet tipi için rastgele başlangıç ağırlıkları seçilerek uygulanan LSTM ve GRU ağ modelleri sonucu elde edilen hata ölçüt değerleri Tablo 4-9’da verilmiştir. RMSE ve MAE değerleri sırasıyla 11,573 ve 9,031 olarak en iyi sonuç LSTM ağı ile elde edilmiştir. Şekil 4-15’te görüldüğü üzere 1000-1200 zaman aralığında gerçek yolcu sayısı 0-5 aralığında iken, tahmin edilen yolcu sayısı 8-15 aralığında olduğu gözlemlenmektedir. Bu durum, modelin hata oranının artmasına sebep olmaktadır.


Tablo 4-9’da verilen RMSE ve MAE değerleri ile elde edilen gerçek ve tahmin edilen yolcu sayısı grafiği Şekil 4-15’te gösterilmektedir. Aynı tahmin değerlerine ilişkin eğitim ve test seti kayıp değerleri ise Şekil 4-16’da verilmiştir. Şekil 4-16’da görüldüğü üzere ilk iterasyon adımlarında eğitim seti kaybı 0,0998 seviyesinden 0,0891 seviyesine önemli derecede azalırken, test seti kaybı ise 0,1079 seviyesinden 0,0977 seviyesine kadar düşüş göstermiştir. Bu değerler 200 düğüm sayısı, 150 epoch değeri ve 3 katmanlı LSTM sinir ağı ile gerçekleştirilmiştir. 3.test denemesi sonucu elde edilen en iyi RMSE ve MAE değerleri sırasıyla 11,573 ve 9,031 iken en kötü RMSE ve MAE değerleri 4.test denemesi sonucu sırasıyla 11,819 ve 9,225 olarak GRU ile elde edilmiştir. Bu durum için, rastgele başlangıç değerleriyle elde edilen sonuçlardan en kötü RMSE ve MAE değerlerinin, en iyi RMSE ve MAE değerlerine göre sırasıyla %2,08 ve %2,10 iyileştiği saptanmıştır. Test sayısı belirli bir değere kadar arttıkça RMSE ve MAE değerlerinin azaldığı gözlemlenirken 4.test verilerinde ise değerlerin tekrar arttığı belirlenmiştir. Test sayısının belirli bir orana kadar artmasının test başarımlarını etkilediği öngörülmüştür.

Tablo 4-9: Farklı başlangıç değerleriyle 4/G hattı tam bilet tipi RMSE VE MAE değerleri

	4/G Hattı Tam Bilet Tipi Yolcu Sayısı Tahmini Hata Ölçüt Değerleri					
	1.TEST (LSTM)	2.TEST (LSTM)	3.TEST (LSTM)	4.TEST (GRU)	5.TEST (GRU)	6.TEST (GRU)
RMSE	11,812	11,698	11,573	11,819	11,692	11,737
MAE	9,163	9,145	9,031	9,225	9,171	9,056



Şekil 4-14: 4/G tam bilet tipi için gerçek değerler ve tahmin değerleri




Şekil 4-15: 4/G tam bilet tipi eğitim ve test seti kayıpları

4/G numaralı hatta ait öğrenci bilet tipi için rastgele başlangıç ağırlıkları seçilerek uygulanan LSTM ve GRU ağ modelleri sonucu elde edilen hata ölçüt değerleri Tablo 4-10'da verilmiştir. RMSE ve MAE değerleri sırasıyla 18,015 ve 13,441 olarak en iyi sonuç GRU ağı ile elde edilmiştir.


Tablo 4-10: Farklı başlangıç değerleriyle 4/G hattı öğrenci bilet tipi RMSE VE MAE değerleri

4/G Hattı Öğrenci Bilet Tipi Yolcu Sayısı Tahmini Hata Ölçüt Değerleri						
	1.TEST (LSTM)	2.TEST (LSTM)	3.TEST (LSTM)	4.TEST (GRU)	5.TEST (GRU)	6.TEST (GRU)
RMSE	18,348	18,058	18,260	18,674	18,015	18,370
MAE	13,518	13,455	13,524	13,647	13,441	13,498

**Şekil 4-16:** 4/G öğrenci bilet tipi için gerçek değerler ve tahmin değerleri

Tablo 4-10’da verilen RMSE ve MAE değerleri ile elde edilen gerçek ve tahmin edilen yolcu sayısı grafiği Şekil 4-17’de gösterilmektedir. Şekil 4-17’de görüldüğü üzere 1000-1200 zaman aralığında gerçek yolcu sayısı 0-10 aralığında iken, tahmin edilen yolcu sayısı 10-20 aralığında olduğu gözlemlenmektedir. Bu durum, modelin hata oranının artmasına sebep olmaktadır. Aynı tahmin değerlerine ilişkin eğitim ve test seti kayıp değerleri ise Şekil 4-18’de verilmiştir. Şekil 4-18’de görüldüğü üzere ilk iterasyon adımlarında eğitim seti kaybı 0,103 seviyesinden 0,0897 seviyesine azalırken, test seti kaybı ise 0,107 seviyesinden 0,0809 seviyesine kadar düşüş göstermiştir. Bu değerler 100 düğüm sayısı, 200 epoch değeri ve tek katmanlı GRU sinir ağı ile gerçekleştirilmiştir. 5.test denemesi sonucu elde edilen en iyi RMSE ve MAE değerleri sırasıyla 18,015 ve 13,441 iken en kötü RMSE ve MAE değerleri 4.test denemesi sonucu sırasıyla 18,674 ve 13,647 olarak GRU ile elde edilmiştir. Bu durum için, rastgele başlangıç değerleriyle elde edilen

sonuçlardan en kötü RMSE ve MAE değerlerinin, en iyi RMSE ve MAE değerlerine göre sırasıyla %3,53 ve %1,51 iyileştiği saptanmıştır. Test sayısı belirli bir değere kadar arttıkça RMSE ve MAE değerlerinin azaldığı gözlemlenirken son test olan 6.test verilerinde ise değerlerin tekrar arttığı belirlenmiştir. Test sayısının belirli bir orana kadar artmasının test başarımlarını etkilediği öngörülmüştür.




Şekil 4-17: 4/G öğrenci bilet tipi eğitim ve test seti kayıpları

4/G hattına ait model kayıp grafikleri, diğer hat model-kayıp grafikleri ile karşılaştırıldığında eğitim ve test seti kaybının yüksek olduğu ve başarımlarının düşük olduğu gözlemlenmiştir. 4/G hattında 6 aylık süreçte gerçekleşen toplam 747.213 adet yolculuktan 430.514 adet yolculuğun öğrenci bilet tipinde olması ve öğrenci yolculuk davranışlarının belirsiz ve tahmin edilemez olması (istenilen zamanda okula gidilmesi, sınavlar dışında okula gidilmemesi, sabah derslerine genelde katılım sağlanmaması vb.) bu hatta ait modelin başarımlarının düşmesine ve bu veri setinde çok yüksek başarı oranı göstermemesine sebep olmaktadır.

4.2. DEĞERLENDİRME

Çalışma kapsamında Akıllı Ulaşım Sistemleri ve Yapay Zekâ Teknolojilerinden faydalanılarak, Bursa Uludağ Üniversitesi'ne yapılan yolculuklara ait veriler ile gerçekleştirilen modeller ile yolcu sayısının tahmin (forecasting) edilmesi amaçlanmaktadır. Bu amaçla öncelikle BURULAŞ'tan elde edilen 2019 yılı ocak ve haziran ayları arasında gerçekleşen 135.029.196 ham yolculuk verisi işlenmeye hazır hale getirilmiştir ve çalışma adımları Şekil 4-18'de gösterilmiştir.



Şekil 4-18: Çalışmanın aşamaları

Durak verileri (durak adı, durak koordinat bilgisi) ve biniş verileri (bilet tipi, hat adı, araç adı, tarih ve saat) olmak üzere iki ana .mdf dosyasından oluşmaktadır. Bu veriler büyük veri kapsamında olup, analiz edilmesi oldukça zor olduğundan bu aşamada Microsoft SQL Server ve Spyder programları kullanılmıştır. Durak ve yolcu biniş koordinat bilgileri aracılığıyla duraklar arasındaki mesafeler hesaplanarak biniş verileriyle eşleştirilmiştir. Daha sonra bu veriler kullanılarak 15'er dakikalık periyotlarla farklı otobüs hatlarına kaçar adet yolcu bindiği belirlenmiştir. Elde edilen bu yolcu sayıları çalışmanın analiz kısmında grafikleştirilerek farklı otobüs hatları ve bilet tiplerine ait farklı zaman dilimlerindeki değişim ortaya konulmuştur. Bu veriler aynı zamanda tahmin (forecasting) ana verilerini oluşturmakla birlikte tahmin modellerimizi yaparken de kullanılmıştır. Tahmin modellerimiz sonucu grafiklerde gerçek yolcu sayısı (mavi renk) ve tahmin edilen yolcu sayısı (kırmızı renk) değerleri yorumlanırken tahminler sonucu elde edilen RMSE ve MAE değerleri ise modelin başarı oranlarını yorumlamaya olanak vermektedir.

RMSE ve MAE değerleri 0 ile ∞ arasında değişmekle birlikte düşük değerlere sahip tahminleyiciler modelin daha başarılı olduğunu ifade etmektedir. Bu çalışmada farklı hatlara ve farklı bilet tiplerine ait elde edilen RMSE ve MAE değerleri yolcu sayısı tahmin grafikleri ile birlikte ele alınarak değerlendirilmiştir ve en iyi RMSE ve MAE değerleri Tablo verilmiştir.

Tablo 4-11: Hatlara ve bilet tiplerine ait en iyi RMSE ve MAE değerleri

Hat Adı	Bilet Tipi	RMSE	MAE
B/24	Bütün	27,749	21,934
	Tam	18,517	14,569
	Öğrenci	11,418	8,701
B/44-B	Bütün	21,450	15,649
	Tam	14,305	10,186
	Öğrenci	8,066	5,427
4/G	Bütün	29,957	23,644
	Tam	11,573	9,031
	Öğrenci	18,015	13,441

Bu tezin giriş bölümünde ele aldığımız literatür çalışmalarında çoğunlukla optimizasyon az da olsa tahmin (forecasting) tekniklerinin kullanıldığı görülmektedir. Literatür çalışmalarında bahsi geçen tahmin modellerinde aylık ve yıllık gibi uzun vadeli (long-term) tahminler yapılırken bu çalışmada ise günlük, haftalık gibi kısa vadeli (short-term) tahminler gerçekleştirilmiştir. Bu kısa vadeli tahminler farklı otobüs hatları ve farklı bilet tipleriyle gerçekleştirilen yolculuklardaki

yolcu sayısı tahminleri yaparak otobüs sayılarının ve otobüs hatlarının sefer saatlerinin ihtiyaçlar doğrultusunda yeniden düzenlenmesine olanak vermektedir.



5. SONUÇ VE ÖNERİLER

Bu tez çalışmasında, 1 Ocak 2019 ve 30 Haziran 2019 tarihleri arasında BursaKART verilerine ait B/24, B/44-B ve 4/G numaralı otobüs hatlarından elde edilen yolcu sayısı veri seti kullanılmıştır. Bu veri setleri, RNN teknikleri arasında bulunan LSTM ve GRU sinir ağıları ile oluşturulmuş 6 farklı model kullanılarak yolcu sayısı tahmini gerçekleştirilmiş ve elde edilen sonuçlar karşılaştırılmıştır.

Önerilen LSTM ve GRU sinir ağıları modeli, rastgele seçilen farklı düğüm, katman sayısı ve epoch sayısı ile oluşturulmuştur. Bu rastgele seçimin sebebi RNN tabanlı modellerin genellikle sezgisel olması yani başlangıçta seçilen değerlerin her seferinde farklı sonuç değerleri oluşturmasıdır. Modelin uygulanması aşamasında zamanı ve bellek depolama alanlarını optimize etmek için makine öğrenmesi alanında kullanılan gradyan tabanlı Adam optimizasyonu tercih edilmiştir. Bu sayede geleneksel gradyan algoritmalarına göre yüksek boyutlu veri kümesi olan otobüs hat verileri modelde çalışırken zaman ve bellek daha optimum düzeyde kullanılmıştır. LSTM ve GRU modellerine ait elde edilen sonuçlar incelendiğinde ilk iterasyon adımlarında veri ve test setinde öğrenme kaybının hızlı gerçekleştiği ancak belirli bir adım sonrasında öğrenme kaybının aynı seviyede devam ettiği ve öğrenmenin başarılı bir şekilde gerçekleştiği gözlemlenmiştir. Model-kayıp grafiğinde iterasyon adımı arttığında başarı oranı yükselirken, eğitim süresinin de arttığı dolayısıyla zamandan kayıp yaşandığı saptanmıştır. Sonuç olarak iterasyon adımı belirli bir değerde tutulmalıdır.

B/24 hattına ait tahmin sonuçları bilet tiplerine göre tüm, tam ve öğrenci olmak üzere 3 ayrı sınıfta incelenmiştir. Bu veri setinde tüm bilet tiplerine ait yolcu sayısı toplam 1.656.413, tam bilet tipi yolcu sayısı 899.471 iken, toplam öğrenci bilet tipi sayısı 535.865'tir. Modellerden elde edilen tüm, tam ve öğrenci bilet tiplerine ait en iyi RMSE değerleri sırasıyla 27,749, 18,517 ve 11,418 olarak sonuçlanmıştır. Aynı zamanda bu bilet tiplerine ait MAE değerleri sırasıyla 21,934, 14,569 ve 8,701 olarak elde edilmiştir. Bu değerler, 100 düğüm sayısı, 200 epoch ve bir katmandan oluşturulan LSTM ve GRU sinir ağı modelleri ile tahmin edilmiştir. Buna göre en iyi tahmin sonucunun LSTM modeli ile öğrenci bilet tipinde gerçekleştiği gözlemlenmiştir. Ancak yüksek yolcu sayısına sahip tüm bilet tipinde katman sayısı artırılırsa GRU modelinin başarı oranının artacağı öngörülmektedir.

B/44-B hattına ait tahmin sonuçları bilet tiplerine göre tüm, tam ve öğrenci olmak üzere 3 ayrı sınıfta incelenmiştir. Bu veri setinde tüm bilet tiplerine ait yolcu sayısı toplam 754.736, tam bilet tipi yolcu sayısı 415.179 iken, toplam öğrenci bilet tipi sayısı 217.985'tir. Modellerden elde

edilen tüm, tam ve öğrenci bilet tiplerine ait en iyi RMSE değerleri sırasıyla 21,450, 14,305 ve 8,066 olarak sonuçlanmıştır. Aynı zamanda bu bilet tiplerine ait MAE değerleri sırasıyla 15,649, 10,186 ve 5,427 olarak elde edilmiştir. Buna göre en iyi tahmin sonucunun LSTM modeli, 100 düğüm sayısı, 200 epoch değeri ve tek katman ile öğrenci bilet tipinde gerçekleştiği gözlemlenmiştir. LSTM ağında girdi katmanına bir defada eğitim için verilen verinin büyüklüğünün artırılması eğitimin başarımlarına olumsuz etki gösterirken, eğitim süresinden önemli ölçüde kazanç sağlamaktadır. Aynı zamanda, ikinci en iyi değer olan tam bilet tipine ait RMSE değeri GRU modeli ile 200 düğüm, 150 epoch ve üç katman ile elde edilmiştir. Buna göre GRU modelinin tahmin başarımlarının artması için eğitim iterasyon ve yolcu sayısı büyüklüğünün artırılması gerektiği sonucu öngörülmüştür.

4/G hattına ait tahmin sonuçları bilet tiplerine göre tüm, tam ve öğrenci olmak üzere 3 ayrı sınıfta incelenmiştir. Bu veri setinde tüm bilet tiplerine ait yolcu sayısı toplam 747.213, tam bilet tipi yolcu sayısı 231.769 iken, toplam öğrenci bilet tipi sayısı 430.514'tür. Modellerden elde edilen tüm, tam ve öğrenci bilet tiplerine ait en iyi RMSE değerleri sırasıyla 29,957, 11,573 ve 18,015 olarak sonuçlanmıştır. Aynı zamanda bu bilet tiplerine ait MAE değerleri sırasıyla 23,644, 9,031 ve 13,441 olarak elde edilmiştir. Buna göre en iyi tahmin sonucunun LSTM modeli, 200 düğüm sayısı, 150 epoch değeri ve üç katman ile tam bilet tipinde gerçekleştiği gözlemlenmiştir.

B/24 ve B/44-B hatlarına ait modeller ile yapılan yolcu sayısı tahminlerinde yolcu sayısının arttığı ve azaldığı zamanlardaki tahmin başarımları elde edilen şekillerde görülmektedir. Ancak, 4/G hattında bulunan bilet tiplerine ait yolcu sayısı tahmin başarımları diğer hatlarla karşılaştırıldığında düşük olduğu gözlemlenmiştir. Bunun sebebi ise 4/G hattında 6 aylık süreçte gerçekleşen toplam 747.213 adet yolculuktan 430.514 adet yolculuğun öğrenci bilet tipinde olması ve öğrenci yolculuk davranışlarının belirsiz ve tahmin edilemez olmasıdır. Dolayısıyla önerilen modelin bir dezavantajı ise, bu çalışmada kullanılan her veri seti üzerinde başarımlarının değişkenlik gösterebildiği ve her test sonucunun yüksek başarımları göstermediği olarak elde edilmiştir.

Bu tez çalışmasının devamında 4/G hattına ait veri setinde öğrenci davranışları incelenip anketler yapılarak gerekirse ders günlerine ve saatlerine göre veriler analiz edilerek test başarımlarının iyileştirilmesi hedeflenmektedir.

6. KAYNAKLAR

- [1] M. Özkul, “Metin Madenciliği Yöntemi ile Akıllı Ulaşım Sistemleri Algısının Duygu Analizi ile Ölçülmesi, Yüksek Lisans Tezi,” *Bandırma Onyediy Eylül Üniversitesi*, 2019.
- [2] M. Tektaş and N. Tektaş, “Akıllı Ulaşım Sistemleri(AUS) Uygulamalarının Sektörlere Göre Dağılımı,” *Akıllı Ulaşım Sist. ve Uygulamaları Dergisi*, vol. 2, no. 1, p. 2, 2019.
- [3] J. Andersen and S. Sutcliffe, “Intelligent Transport Systems (ITS) - An Overview,” *IFAC Proc. Vol.*, vol. 33, no. 18, pp. 99–106, 2000, doi: 10.1016/s1474-6670(17)37129-x.
- [4] M. Tektaş, K. Korkmaz, and H. Erdal, “Akıllı Ulaşım Sistemlerinin Geleceği (Ekonomik ve Çevresel Faydaları),” in *ICOMEPE, International Congress of Management Economy and Policy*, 2016, pp. 1–16.
- [5] H. Tokuyama, “Intelligent Transportation Systems in Japan,” *Public Roads*, no. Vol.60 No.2, pp. 1–6, 1996.
- [6] X. Yan, H. Zhang, and C. Wu, “Research and Development of Intelligent Transportation Systems,” *Proc. - 11th Int. Symp. Distrib. Comput. Appl. to Business, Eng. Sci. DCABES 2012*, pp. 321–327, 2012, doi: 10.1109/DCABES.2012.107.
- [7] G. Nowacki, “Development and Standardization of Intelligent Transport Systems,” *Transp. Syst. Process.*, vol. 6, no. 3, pp. 41–48, 2011, doi: 10.1201/b11347-9.
- [8] S. Turan and S. B. Efe, “Elektrikli Bisiklet Paylaşımı : Çanakkale Onsekiz Mart Üniversitesi Terzioğlu Yerleşkesi Örneği,” *Akıllı Ulaşım Sistemleri ve Uygulamaları Dergisi*, 3(2), 112–122.
- [9] T.C. Ulaştırma ve Altyapı Bakanlığı, *Ulusal Akıllı Ulaşım Sistemleri Strateji Belgesi ve 2020-2023 Eylem Planı*. Türkiye, 2020, pp. 15–18.
- [10] A. M. Nagy and V. Simon, “Survey on Traffic Prediction in Smart Cities,” *Pervasive Mob. Comput.*, vol. 50, pp. 148–163, 2018, doi: 10.1016/j.pmcj.2018.07.004.
- [11] L. N. N. Do, N. Taherifar, and H. L. Vu, “Survey of Neural Network-Based Models for Short-Term Traffic State Prediction,” *Wiley Interdiscip. Rev. Data Min. Knowl. Discov.*, vol. 9, no. 1, pp. 1–24, 2019, doi: 10.1002/widm.1285.
- [12] A. Khadhir, B. Anil Kumar, and L. D. Vanajakshi, “Analysis of Global Positioning System Used Bus Travel Time Data and Its Use for Advanced Public Transportation System Applications,” *J. Intell. Transp. Syst. Technol. Planning, Oper.*, vol. 25, no. 1, pp. 58–76, 2021, doi: 10.1080/15472450.2020.1754818.
- [13] C. M. Chen, C. C. Liang, and C. P. Chu, “Long-Term Travel Time Prediction Using

- Gradient Boosting,” *J. Intell. Transp. Syst. Technol. Planning, Oper.*, vol. 24, no. 2, pp. 109–124, 2020, doi: 10.1080/15472450.2018.1542304.
- [14] R. Toncharoen and M. Piantanakulchai, “Traffic State Prediction Using Convolutional Neural Network,” *Proceeding 2018 15th Int. Jt. Conf. Comput. Sci. Softw. Eng. JCSSE 2018*, pp. 2–7, 2018, doi: 10.1109/JCSSE.2018.8457359.
- [15] Q. Ma, S. Li, H. Zhang, Y. Yuan, and L. Yang, “Robust Optimal Predictive Control for Real-Time Bus Regulation Strategy with Passenger Demand Uncertainties in Urban Rapid Transit,” *Transp. Res. Part C Emerg. Technol.*, vol. 127, no. October 2020, p. 103086, 2021, doi: 10.1016/j.trc.2021.103086.
- [16] Y. Hollander and R. Liu, “Estimation of the Distribution of Travel Times by Repeated Simulation,” *Transp. Res. Part C Emerg. Technol.*, vol. 16, no. 2, pp. 212–231, 2008, doi: 10.1016/j.trc.2007.07.005.
- [17] A. Fonzone, J. D. Schmöcker, and R. Liu, “A Model of Bus Bunching under Reliability-based Passenger Arrival Patterns,” *Transp. Res. Procedia*, vol. 7, pp. 276–299, 2015, doi: 10.1016/j.trpro.2015.06.015.
- [18] K. E. Watkins, B. Ferris, A. Borning, G. S. Rutherford, and D. Layton, “Where Is My Bus? Impact of Mobile Real-Time Information on the Perceived and Actual Wait Time of Transit Riders,” *Transp. Res. Part A Policy Pract.*, vol. 45, no. 8, pp. 839–848, 2011, doi: 10.1016/j.tra.2011.06.010.
- [19] K. Gkiotsalitis and F. Alesiani, “Robust Timetable Optimization for Bus Lines Subject to Resource and Regulatory Constraints,” *Transp. Res. Part E Logist. Transp. Rev.*, vol. 128, no. June, pp. 30–51, 2019, doi: 10.1016/j.tre.2019.05.016.
- [20] Y. Wang, D. Zhang, L. Hu, Y. Yang, and L. H. Lee, “A Data-Driven and Optimal Bus Scheduling Model with Time-Dependent Traffic and Demand,” *IEEE Trans. Intell. Transp. Syst.*, vol. 18, no. 9, pp. 2443–2452, 2017, doi: 10.1109/TITS.2016.2644725.
- [21] Q. Chen, “Global Optimization for Bus Line Timetable Setting Problem,” *Discret. Dyn. Nat. Soc.*, vol. 2014, no. 1991, 2014, doi: 10.1155/2014/636937.
- [22] S. N. Kane, A. Mishra, and A. K. Dutta, “Preface: International Conference on Recent Trends in Physics (ICRTP 2016),” *J. Phys. Conf. Ser.*, vol. 755, no. 1, 2016, doi: 10.1088/1742-6596/755/1/011001.
- [23] J. Tang, Y. Yang, W. Hao, F. Liu, and Y. Wang, “A Data-Driven Timetable Optimization of Urban Bus Line Based on Multi-Objective Genetic Algorithm,” *IEEE Trans. Intell. Transp. Syst.*, vol. 22, no. 4, pp. 2417–2429, 2021, doi: 10.1109/TITS.2020.3025031.
- [24] H. Ma, X. Li, and H. Yu, “Single Bus Line Timetable Optimization with Big Data: A Case

- Study in Beijing,” *Inf. Sci. (Ny)*, vol. 536, pp. 53–66, 2020, doi: 10.1016/j.ins.2020.03.108.
- [25] J. Zhang *et al.*, “A Real-Time Passenger Flow Estimation and Prediction Method for Urban Bus Transit Systems,” *IEEE Trans. Intell. Transp. Syst.*, vol. 18, no. 11, pp. 3168–3178, 2017, doi: 10.1109/TITS.2017.2686877.
- [26] J. Tang, Y. Yang, and Y. Qi, “A Hybrid Algorithm for Urban Transit Schedule Optimization,” *Phys. A Stat. Mech. its Appl.*, vol. 512, pp. 745–755, 2018, doi: 10.1016/j.physa.2018.08.017.
- [27] Y. Wu, H. Yang, J. Tang, and Y. Yu, “Multi-Objective Re-Synchronizing of Bus Timetable: Model, Complexity and Solution,” *Transp. Res. Part C Emerg. Technol.*, vol. 67, no. 2, pp. 149–168, 2016, doi: 10.1016/j.trc.2016.02.007.
- [28] C. Tang, A. Ceder, S. Zhao, and Y. E. Ge, “Vehicle Scheduling of Single-Line Bus Service Using Operational Strategies,” *IEEE Trans. Intell. Transp. Syst.*, vol. 20, no. 3, pp. 1149–1159, 2019, doi: 10.1109/TITS.2018.2841061.
- [29] T. Liu and A. (Avi) Ceder, “Deficit Function Related to Public Transport: 50 Year Retrospective, New Developments, and Prospects,” *Transp. Res. Part B Methodol.*, vol. 100, pp. 1–19, 2017, doi: 10.1016/j.trb.2017.01.015.
- [30] J. A. Mesa, F. A. Ortega, and M. A. Pozo, “Locating Optimal Timetables and Vehicle Schedules in a Transit Line,” *Ann. Oper. Res.*, vol. 222, no. 1, pp. 439–455, 2014, doi: 10.1007/s10479-013-1393-5.
- [31] B. Varga, T. Tettamanti, and B. Kulcsár, “Optimally Combined Headway and Timetable Reliable Public Transport System,” *Transp. Res. Part C Emerg. Technol.*, vol. 92, no. July 2017, pp. 1–26, 2018, doi: 10.1016/j.trc.2018.04.016.
- [32] X. Zuo, C. Chen, W. Tan, and M. Zhou, “Vehicle Scheduling of an Urban Bus Line via an Improved Multiobjective Genetic Algorithm,” *IEEE Trans. Intell. Transp. Syst.*, vol. 16, no. 2, pp. 1030–1041, 2015, doi: 10.1109/TITS.2014.2352599.
- [33] X. Shui, X. Zuo, C. Chen, and A. E. Smith, “A Clonal Selection Algorithm for Urban Bus Vehicle Scheduling,” *Appl. Soft Comput. J.*, vol. 36, pp. 36–44, 2015, doi: 10.1016/j.asoc.2015.07.001.
- [34] Y. Bie, X. Gong, and Z. Liu, “Time of Day Intervals Partition for Bus Schedule Using GPS Data,” *Transp. Res. Part C Emerg. Technol.*, vol. 60, pp. 443–456, 2015, doi: 10.1016/j.trc.2015.09.016.
- [35] A. Schöbel, “An Eigenmodel for Iterative Line Planning, Timetabling and Vehicle Scheduling in Public Transportation,” *Transp. Res. Part C Emerg. Technol.*, vol. 74, pp. 348–365, 2017, doi: 10.1016/j.trc.2016.11.018.

- [36] A. Herbon and Y. Hadas, “Determining Optimal Frequency and Vehicle Capacity for Public Transit Routes: A Generalized Newsvendor Model,” *Transp. Res. Part B Methodol.*, vol. 71, pp. 85–99, 2015, doi: 10.1016/j.trb.2014.10.007.
- [37] P. Fouilhoux, O. J. Ibarra-Rojas, S. Kedad-Sidhoum, and Y. A. Rios-Solis, “Valid Inequalities for the Synchronization Bus Timetabling Problem,” *Eur. J. Oper. Res.*, vol. 251, no. 2, pp. 442–450, 2016, doi: 10.1016/j.ejor.2015.12.006.
- [38] G. Laporte, F. A. Ortega, M. A. Pozo, and J. Puerto, “Multi-Objective Integration of Timetables, Vehicle Schedules and User Routings in a Transit Network,” *Transp. Res. Part B Methodol.*, vol. 98, pp. 94–112, 2017, doi: 10.1016/j.trb.2016.12.018.
- [39] M. Owais, M. K. Osman, and G. Moussa, “Multi-Objective Transit Route Network Design as Set Covering Problem,” *IEEE Trans. Intell. Transp. Syst.*, vol. 17, no. 3, pp. 670–679, 2016, doi: 10.1109/TITS.2015.2480885.
- [40] J. Chen, Z. Liu, S. Wang, and X. Chen, “Continuum Approximation Modeling of Transit Network Design Considering Local Route Service and Short-Turn Strategy,” *Transp. Res. Part E Logist. Transp. Rev.*, vol. 119, no. January, pp. 165–188, 2018, doi: 10.1016/j.tre.2018.10.001.
- [41] Z. Dai, X. C. Liu, Z. Chen, R. Guo, and X. Ma, “A Predictive Headway-Based Bus-Holding Strategy With Dynamic Control Point Selection: A Cooperative Game Theory Approach,” *Transp. Res. Part B Methodol.*, vol. 125, no. 37, pp. 29–51, 2019, doi: 10.1016/j.trb.2019.05.001.
- [42] Z. Wang *et al.*, “Two-Step Coordinated Optimization Model of Mixed Demand Responsive Feeder Transit,” *J. Transp. Eng. Part A Syst.*, vol. 146, no. 3, p. 04019082, 2020, doi: 10.1061/jtepbs.0000317.
- [43] T. Liu, A. Ceder, J. Ma, W. Guan, and L. Zhou, “Graphical Human-Machine Interactive Approach for Integrated Bus Transit Scheduling: Lessons Gained From a Large Bus Company,” *IEEE Trans. Intell. Transp. Syst.*, vol. 18, no. 4, pp. 1023–1028, 2017, doi: 10.1109/TITS.2016.2604392.
- [44] J. Ma, A. A. Ceder, Y. Yang, T. Liu, and W. Guan, “A Case Study of Beijing Bus Crew Scheduling: A Variable Neighborhood-Based Approach,” *J. Adv. Transp.*, vol. 50, no. 4, pp. 434–445, Jun. 2016, doi: 10.1002/atr.1333.
- [45] T. Liu and A. Ceder, “Synchronization of Public Transport Timetabling with Multiple Vehicle Types,” *Transp. Res. Rec.*, vol. 2539, pp. 84–93, 2016, doi: 10.3141/2539-10.
- [46] M. M. Nesheli, A. A. Ceder, and S. Estines, “Public Transport User’s Perception and Decision Assessment Using Tactic-Based Guidelines,” *Transp. Policy*, vol. 49, pp. 125–

- [60] W. S. McCulloch and W. Pitts, “A Logical Calculus Of The Ideas Immanent In Nervous Activity,” *Bull. Math. Biol.*, vol. 52, no. 1, pp. 99–115, 1990.
- [61] F. Attneave, M. B., and D. O. Hebb, “The Organization of Behavior; A Neuropsychological Theory,” *Am. J. Psychol.*, vol. 63, no. 4, p. 633, 1950, doi: 10.2307/1418888.
- [62] L. I. Burke and J. P. Ignizio, “Neural Networks and Operations Research: An Overview,” *Comput. Oper. Res.*, vol. 19, no. 3–4, pp. 179–189, 1992, doi: 10.1016/0305-0548(92)90043-5.
- [63] Lewis Tanya, “A Brief History of Artificial Intelligence Live Science,” 2014. <https://www.livescience.com/49007-history-of-artificial-intelligence.html>.
- [64] F. Rosenblatt, “The Perceptron: A Probabilistic Model for Information Storage and Organization in the Brain,” *Psychol. Rev.*, vol. 65, no. 6, pp. 386–408, 1958, doi: 10.1037/h0042519.
- [65] B. Widrow and M. E. Hoff, “Adaptive Switching Circuits,” in *Wescon Conference Record*, 1989, pp. 709–717.
- [66] N. Nilsson, *The Mathematical Foundations Of Learning Machines*. 1965.
- [67] S. Minsky, L., Marvin Papert, A., *Perceptrons.pdf*. 1969.
- [68] T. Kohonen, “Correlation Matrix Memories,” *IEEE Trans. Comput.*, vol. C–21, no. 4, pp. 353–359, 1972, doi: 10.1109/TC.1972.5008975.
- [69] K. Fukushima, “Biological Cybernetics,” vol. 15, pp. 5–15, 1986.
- [70] T. Kohonen, “Self-Organized Formation of Topologically Correct Feature Maps,” *Biol. Cybern.*, vol. 43, no. 1, pp. 59–69, 1982, doi: 10.1007/BF00337288.
- [71] J. J. Hopfield, “Neural Networks and Physical Systems with Emergent Collective Computational Abilities,” *Proc. Natl. Acad. Sci. U. S. A.*, vol. 79, no. 8, pp. 2554–2558, 1982, doi: 10.1073/pnas.79.8.2554.
- [72] J. J. Hopfield, “Neurons with Graded Response Have Collective,” *Biophysics (Oxf)*, vol. 81, no. May, pp. 3088–3092, 1984.
- [73] I. Goodfellow, Y. Bengio, and A. Courville, “Deep Learning,” p. 800, 2017.
- [74] G. A. Carpenter and S. Grossberg, “Art 2: Self-Organization of Stable Category Recognition Codes for Analog Input Patterns,” *Appl. Opt.*, vol. 26, no. 23, pp. 4919–4930, 1987.
- [75] L. D. Broomhead D.S., “Radial Basis Functions Multi-Variable Functional Interpolation and Adaptive Networks,” *Emerg. Technol. Situ Process.*, vol. 139, no. 4148, p. 221, 2012.
- [76] D. F. Specht, “A General Regression Neural Network,” *IEEE Trans. Neural Networks*, vol. 2, no. 6, pp. 568–576, 1991, doi: 10.1109/IJCNN.2007.4371258.

- [77] N. M. R. Hinton E. Geoffrey, Dayan Peter, Frey J. Brendan, “The Wake Sleep Algorithm for Unsupervised Neural Networks,” *Dep. of Computer Sci. Univ. Toronto*, 1995, [Online]. Available: <https://www.cs.toronto.edu/~hinton/csc2535/readings/ws.pdf>.
- [78] S. J. Hochreiter Sepp, “Long Short-Term Memory,” *Massachusetts Inst. Technol.*, 1997, doi: 10.17582/journal.pjz/2018.50.6.2199.2207.
- [79] J. Schmidhuber, “Deep Learning in Neural Networks: An Overview,” *Neural Networks*, vol. 61, pp. 85–117, 2015, doi: 10.1016/j.neunet.2014.09.003.
- [80] I. N. Aizenberg, N. N. Aizenberg, and J. Vandewalle, “Multiple-Valued Threshold Logic and Multi-Valued Neurons,” *Multi-Valued Univers. Bin. Neurons*, no. 1971, pp. 25–80, 2000, doi: 10.1007/978-1-4757-3115-6_2.
- [81] G. E. Hinton, “Learning Multiple Layers of Representation,” *Trends Cogn. Sci.*, vol. 11, no. 10, pp. 428–434, 2007, doi: 10.1016/j.tics.2007.09.004.
- [82] S. R. R. Hinton, G. E., Srivastava N. , Krizhevsky A., Sutskever I., “Improving Neural Networks by Preventing Co-Adaptation of Feature Detectors,” no. July, 2012.
- [83] R. Girshick, J. Donahue, T. Darrell, and J. Malik, “Rich Feature Hierarchies for Accurate Object Detection and Semantic Segmentation,” *Proc. IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit.*, pp. 580–587, 2014, doi: 10.1109/CVPR.2014.81.
- [84] L. Deng and D. Yu, “Deep Learning: Methods and Applications,” *Found. Trends Signal Process.*, vol. 7, no. 3–4, pp. 197–387, 2013, doi: 10.1561/20000000039.
- [85] G. Erkan, “Dinamik Yapay Sinir Ağları Sistemi Önerisi,” *İstanbul Tek. Üniversitesi*, 2014.
- [86] “Yapay Sinir Ağları - Veri Bilimi Okulu - Veri Bilimi Okulu.”
- [87] Z. Ağyar, “Yapay Sinir Ağlarının Kullanım Alanları ve Bir Uygulama,” *Mühendis ve Makina*, p. 662, 2015.
- [88] Y. Le Cun *et al.*, “Handwritten Digit Recognition: Applications of Neural Network Chips and Automatic Learning,” *IEEE Commun. Mag.*, vol. 27, no. 11, pp. 41–46, 1989, doi: 10.1109/35.41400.
- [89] M. LeCun, Y., Jackel. L.D., Bottou. L., Cortes. C., Denker. J.S., Drucker. H., Guyon. I., “Learning Algorithms for Classification: A Comparison On Handwritten Digit Recognition,” 1995.
- [90] M. A. Kızrak and B. Bolat, “Derin Öğrenme ile Kalabalık Analizi Üzerine Detaylı Bir Araştırma,” *Bilişim Teknol. Derg.*, pp. 263–286, 2018, doi: 10.17671/gazibtd.419205.
- [91] L. Relu, “Derin Öğrenme El Kitabı,” pp. 1–2, 2019.
- [92] D. Cireşan, “Multi-Column Deep Neural Networks for Image Classification,” *Proc. IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit.*, pp. 3642–3649, 2012, doi:

10.1109/CVPR.2012.6248110.

- [93] S. S. Farfade, M. Saberian, and L. J. Li, “Multi-View Face Detection Using Deep Convolutional Neural Networks,” *ICMR 2015 - Proc. 2015 ACM Int. Conf. Multimed. Retr.*, pp. 643–650, 2015, doi: 10.1145/2671188.2749408.
- [94] I. Wallach, M. Dzamba, and A. Heifets, “AtomNet: A Deep Convolutional Neural Network for Bioactivity Prediction in Structure-based Drug Discovery,” pp. 1–11, 2015, [Online]. Available: <http://arxiv.org/abs/1510.02855>.
- [95] J. L. Elman, “Finding Structure in Time,” *Cogn. Sci.*, vol. 14, no. 2, pp. 179–211, 1990, doi: 10.1207/s15516709cog1402_1.
- [96] A. Amidi, “Tekrarlayan Yapay Sinir Ağları El Kitabı,” pp. 1–5, 2019.
- [97] A. Graves and N. Jaitly, “Towards end-to-End Speech Recognition with Recurrent Neural Networks,” *31st Int. Conf. Mach. Learn. ICML 2014*, vol. 5, pp. 3771–3779, 2014.
- [98] A. Kara, “Uzun-Kısa Süreli Bellek Ağı Kullanarak Global Güneş Işınımı Zaman Serileri Tahmini,” *Gazi Üniversitesi Fen Bilim. Derg. Part C Tasarım ve Teknol.*, vol. 7, no. 4, pp. 882–892, 2019, doi: 10.29109/gujsc.571831.
- [99] A. Graves and J. Schmidhuber, “Framewise Phoneme Classification with Bidirectional LSTM and Other Neural Network Architectures,” *Neural Networks*, vol. 18, no. 5–6, pp. 602–610, 2005, doi: 10.1016/j.neunet.2005.06.042.
- [100] D. Eck and J. Schmidhuber, “Learning the Long-Term Structure of the Blues,” *Lect. Notes Comput. Sci. (including Subser. Lect. Notes Artif. Intell. Lect. Notes Bioinformatics)*, vol. 2415 LNCS, pp. 284–289, 2002, doi: 10.1007/3-540-46084-5_47.
- [101] H. Mayer, F. Gomez, D. Wierstra, I. Nagy, A. Knoll, and J. Schmidhuber, “A System for Robotic Heart Surgery That Learns to Tie Knots Using Recurrent Neural Networks,” *Adv. Robot.*, vol. 22, no. 13–14, pp. 1521–1537, 2008, doi: 10.1163/156855308X360604.
- [102] J. Schmidhuber, F. Gers, and D. Eck, “Learning Nonregular Languages: A Comparison of Simple Recurrent Networks and LSTM,” *Neural Comput.*, vol. 14, no. 9, pp. 2039–2041, 2002, doi: 10.1162/089976602320263980.
- [103] A. Graves and J. Schmidhuber, “Offline Handwriting Recognition with Multidimensional Recurrent Neural Networks,” *Adv. Neural Inf. Process. Syst. 21 - Proc. 2008 Conf.*, pp. 545–552, 2009.
- [104] K. Cho *et al.*, “Learning Phrase Representations Using RNN Encoder-Decoder for Statistical Machine Translation,” *EMNLP 2014 - 2014 Conf. Empir. Methods Nat. Lang. Process. Proc. Conf.*, no. November, pp. 1724–1734, 2014, doi: 10.3115/v1/d14-1179.
- [105] F. A. Gers, J. Schmidhuber, and F. Cummins, “Learning to Forget: Continual prediction

- with LSTM,” *IEE Conf. Publ.*, vol. 2, no. 470, pp. 850–855, 1999, doi: 10.1049/cp:19991218.
- [106] J. Chung, C. Gulcehre, K. Cho, and Y. Bengio, “Empirical Evaluation of Gated Recurrent Neural Networks on Sequence Modeling,” no. December, 2014, [Online]. Available: <http://arxiv.org/abs/1412.3555>.
- [107] P. Goyal, S. Pandey, and K. Jain, *Deep Learning for Natural Language Processing: Creating Neural Networks with Python*. 2018.
- [108] M. Ravanelli, P. Brakel, M. Omologo, and Y. Bengio, “Light Gated Recurrent Units for Speech Recognition,” *IEEE Trans. Emerg. Top. Comput. Intell.*, vol. 2, no. 2, pp. 92–102, 2018, doi: 10.1109/TETCI.2017.2762739.
- [109] Y. Su and C. C. J. Kuo, “On Extended Long Short-Term Memory and Dependent Bidirectional Recurrent Neural Network,” *Neurocomputing*, vol. 356, pp. 151–161, 2019, doi: 10.1016/j.neucom.2019.04.044.
- [110] R. Dey and F. M. Salemt, “Gate-Variants of Gated Recurrent Unit (GRU) Neural Networks,” *Midwest Symp. Circuits Syst.*, vol. 2017-Augus, no. 2, pp. 1597–1600, 2017, doi: 10.1109/MWSCAS.2017.8053243.
- [111] “Gated recurrent unit - Wikipedia,” *Wikipedia*. https://en.wikipedia.org/wiki/Gated_recurrent_unit.
- [112] J. C. Heck and F. M. Salem, “Simplified Minimal Gated Unit Variations for Recurrent Neural Networks,” *Midwest Symp. Circuits Syst.*, vol. 2017-Augus, pp. 1593–1596, 2017, doi: 10.1109/MWSCAS.2017.8053242.
- [113] Smolensky Paul, “Information Processing in Dynamical Systems: Foundations of Harmony Theory,” *J. Japan Soc. Fuzzy Theory Syst.*, vol. 4, no. 2, pp. 220–228, 1986, [Online]. Available: https://books.google.co.id/books?hl=id&lr=&id=5Y5MyjbU87oC&oi=fnd&pg=PA1&dq=harmony+theory&ots=HggkOeHYYc&sig=xPDnfVYMXaiwF_rGCcJuobJNejc&redir_esc=y#v=onepage&q=harmony theory&f=false.
- [114] S. R. . Hinton G.E., “Reducing the Dimensionality of Data with Neural Networks,” *Science (80-.)*, vol. 313, no. July, pp. 504–507, 2006, doi: 10.1016/B978-0-08-044894-7.00081-6.
- [115] H. Larochelle and Y. Bengio, “Classification Using Discriminative Restricted Boltzmann Machines,” *Proc. 25th Int. Conf. Mach. Learn.*, pp. 536–543, 2008, doi: 10.1145/1390156.1390224.
- [116] H. G. Salakhutdinov Ruslan, Mnih Andriy, “Restricted Boltzmann Machines for Collaborative Filtering Ruslan,” *Univ. Toronto*, pp. 791–798, doi:

10.1016/j.nonrwa.2008.07.008.

- [117] A. Coates, L. Honglak, and A. Y. Ng, “An Analysis of Single-Layer Networks in Unsupervised Feature Learning.”
- [118] R. Salakhutdinov and G. Hinton, “Replicated Softmax: an Undirected Topic Model Ruslan,” pp. 1–8.
- [119] “Boltzman Makinesi(Boltzmann Machines)(BM) ve Kısıtlanmış Boltzmann Makineleri(Restricted Boltzmann Machines) (RBM) _ by F.” .
- [120] Y. Bengio, *Learning Deep Architectures for AI*, vol. 2, no. 1. 2009.
- [121] “Derin Öğrenme Mimarileri (Deep Learning Architectures) _ by F.” .
- [122] A. Krizhevsky and G. E. Hinton, “Using Very Deep Autoencoders for Content-Based Image Retrieval,” *ESANN 2011 - 19th Eur. Symp. Artif. Neural Networks*, pp. 489–494, 2011.
- [123] D. P. Kingma and J. L. Ba, “Adam: A Method for Stochastic Optimization,” *3rd Int. Conf. Learn. Represent. ICLR 2015 - Conf. Track Proc.*, pp. 1–15, 2015.
- [124] Y. Gültepe, “Makine Öğrenmesi Algoritmaları ile Hava Kirliliği Tahmini Üzerine Karşılaştırmalı Bir Değerlendirme,” *Eur. J. Sci. Technol.*, no. 16, pp. 8–15, 2019, doi: 10.31590/ejosat.530347.

ÖZGEÇMİŞ

Kişisel Bilgiler		
Adı Soyadı	Ece Sema Korkmaz	
Doğum Yeri		
Doğum Tarihi		
Uyruğu		
Telefon		
E-Posta Adresi		
Web Adresi		

	Eğitim Bilgileri
	Lisans
Üniversite	
Fakülte	
Bölümü	
Mezuniyet Yılı	

Yüksek Lisans	
Üniversite	
Enstitü Adı	
Anabilim Dalı	
Programı	

Makale ve Bildiriler