

Araştırma Makalesi

Şehir içi otobüs taşımacılığında kısa dönemli yolcu sayısı tahmini

Ece Sema Korkmaz¹, İlyas Özer², Serhat Berat Efe^{3,*}

¹ Graduate School of Natural and Applied Sci., Bandırma Onyedi Eylül University, Bandırma, Turkey

² Department of Computer Engineering, Faculty of Engineering and Natural Sciences, Bandırma Onyedi Eylül University, Bandırma, Turkey / AINTELIA Artificial Intelligence Technologies Company, Bursa, Turkey

³ Department of Electrical Engineering, Faculty of Engineering and Natural Sciences, Bandırma Onyedi Eylül University, Bandırma, Turkey

*Correspondence: sefe@bandirma.edu.tr

DOI: 10.51513/jitsa.1172352

Özet: 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 büyük boyutlu veri Microsoft SQL Server ve Python programlama dili 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 temel alınarak ay, gün, saat ölçütlerine 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, Python programlama dili 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

Short term passenger flow forecasting in urban bus transportation system with LSTM network

Abstract: 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 big-data that taken from BURULAŞ and covering the journeys between January and June 2019, were analyzed through Microsoft SQL Server and Python programming language. In this context, the journeys arriving at Bursa Uludağ University between 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 Python programming language. 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

* Corresponding author.

E-mail address: sefe@bandirma.edu.tr

ORCID: 0000-0002-6277-6926; 0000-0003-2112-5497; 0000-0001-6076-4166 (in hierarchical order)

Received 07.09.2022 ; accepted 30.09.2022

Peer review under responsibility of Bandırma Onyedi Eylül University.

1. Giriş

Kentsel alanların sunduğu olanaklar ve hızla artan nüfus, hızlı ve plansız bir büyümeye neden olmaktadır. Bu alanlarda yaşanan hızlı ve plansız büyümeden en çok etkilenen yapılardan biri de ulaşım sistemlerdir. Nüfusun artmasıyla birlikte kentlerdeki nüfus yoğunluğunun arttığı ve ulaşım ağları yetersiz kaldığı görülmektedir (Özkul, 2019). 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 üretmek 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 (Tektaş vd., 2019; Andersen vd., 2000; Tektaş vd., 2016).

Bugün dünyada AUS'un ortak hedefleri arasında ulaşım sistemlerinde yaşanan sorunları önlemek amacıyla artış gösteren ulaşım hedefleri, ulaşımında verimlilik 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 (Andersen vd., 2000). Bunu yaparken de doğru tahminler yapan ve verimli çalışan bir trafik tahmin sistemine ihtiyaç duyulmaktadır. AUS'un faydalandığı bu teknolojik yöntemler gelenekselden yöntemlerden farklı yöntemler ve bilgiler gerektirmektedir (T.C. Ulaştırma ve Altyapı Bakanlığı, 2020). 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 problemin aşılması amacıyla literatürde farklı yapay zekâ yaklaşımları mevcuttur (Gorur, vd. 2022). Yapay zekâ algoritmaları büyük veri içeren çalışmaların çoğunda büyük avantajlar sağlamaktadır (Ozbay, vd. 2021, Ozer, vd. 2021). Bu algoritmalar bilimin her alanında kullanılmaktadır (Ozer, vd. 2021).

Bu çalışma kapsamında özele indirgenecek olursa, en iyi trafik tahmin sistemini bulmak için de Yapay Zekâ Teknolojilerinden (Artificial Intelligence) Makine Öğrenmesi (Machine Learning) ve Derin Öğrenme (Deep Learning) teknikleri gibi farklı modeller kullanılmaktadır (Nagy, vd. 2018; Do, vd. 2019; Khadhir, vd. 2021). 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 (Chen, vd. 2020; Toncharoen vd. 2018).

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 (Ma, vd. 2021; Hollander, vd. 2008; Fonzone, vd. 2015).

Bu çalışmanın temel motivasyonunu oluşturan yolcu sayısı tahminleme algoritmaları da literatürde oldukça geniş yer bulmaktadır (Watkins, vd. 2011; Gkiotsalitis, vd. 2019; Wang, vd. 2017).

Çalışma kapsamında incelenen literatür 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 (Chen, 2014; Kane, vd. 2016; Tang, vd. 2021). Bu çalışmada, anakent 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. Akıllı kart verileri ile bursa kent içi yolcu taşımacılığı analizi

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 dâhil olmakla birlikte yolcu ücret ödeme sistemleri ve araç mülkiyet hakları farklılık göstermektedir (B.P.AŞ., 2018)

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

Tablo 1. 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

Bu çalışmanın temel amacını Bursa Büyükşehir Belediyesi sınırları içerisinde yer alan ve BURULAŞ Bursa Ulaşım Toplu Taşıma İşletmeciliği Turizm Sanayi ve Ticaret A.Ş sorumluluğunda olan Bursa Uludağ Üniversitesi varışlı yolculuklara ait otobüs hatları incelenerek forecasting (tahmin) yapılması oluşturmaktadır. 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. Verilerin analizi ve model kurgusu

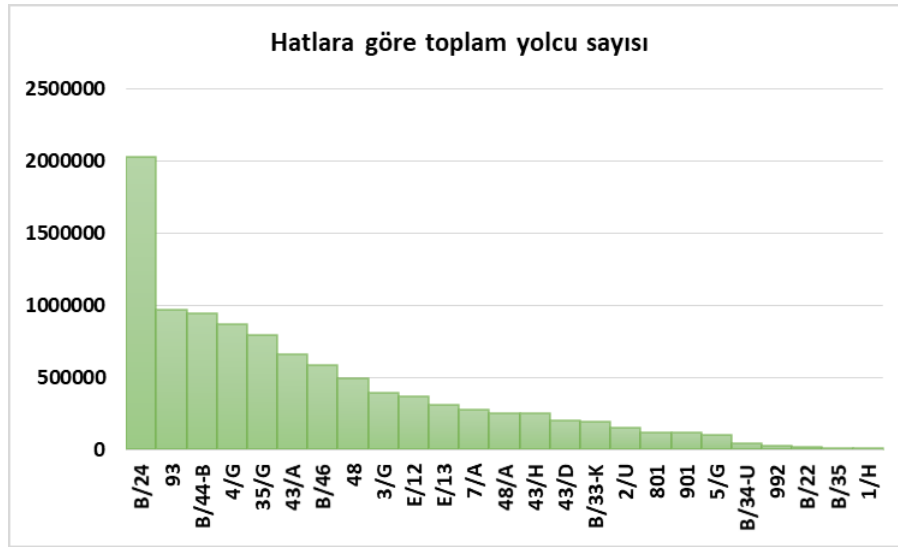
BURULAŞ Bursa Ulaşım Toplu Taşıma İşletmeciliği Turizm Sanayi ve Ticaret A.Ş'den alınan BursaKART verileri 2019 yılı Ocak-Haziran ayları arasında altı aylık bir süreci kapsamakta ve farklı kartlara ait 135.029.196 adet yolculuk gerçekleştiği tespit edilmiştir. BursaKART'a ait bu verilerin büyük hacimli 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. 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 (Ozer, vd. 2018, Ozer, vd. 2017, Ozer, vd. 2018). 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.

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 Üniversitesinin ve Uludağ Üniversitesi Tıp Fakültesi Hastanesinin bulunduğu ve yolculuk çekim merkezi olarak nitelendirilebileceğimiz 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 yolculukların bilet tipi, kart numarası, tarihi ve saati, hangi hat üzerinde gerçekleştiği, coğrafi koordinat bilgileri vb. veriler yer almaktadır.

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 güzergâhında 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.

Bu hatlardan en çok tercih edilen hatlara ait yolcu sayılarının analiz ve ayıklama işlemlerinin ardından en yoğun otobüs hatlarının yolcu sayısı dağılımı ve aylara göre gösterdiği değişkenlik çıkarılmıştır Şekil 1'de verilmiştir.



Şekil 1. Hatlar göre toplam yolcu sayısı dağılımı

4. Akıllı kart verileri ile toplu taşıma sistemi yolcu sayısı tahmini

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. 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.

Modelin uygulanması aşamasında zamanı ve bellek depolama alanlarını optimize etmek için son zamanlarda makinesi öğrenmesi alanında sıklıkla kullanılan gradyan tabanlı Adam optimizasyonu kullanılmıştır (Kingma, vd. 2015). 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.

$$MAE = \frac{1}{n} \sum_{t=1}^n |e_t| \quad (1)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n e_t^2} \quad (2)$$

$$e_t = r_t - p_t \quad (3)$$


Denklem (1) ve Denklem (2)'de t belirli bir zamanı, r_t zaman aralığını, p_t tahmin edilen zamanı ifade ederken, hata Denklem (3) ile ifade edilmektedir (Gültepe, 2019).

Tahminleme çalışmalarına yolcu sayısı en fazla olan B/24 numaralı hat ile başlanmıştır. Bu 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 2'de verilmiştir. RMSE ve MAE değerleri sırasıyla 27,749 ve 21,934 olarak en iyi sonuç olup, GRU ağı ile elde edilmiştir.

Tablo 2. Farklı başlangıç koşullarında B/24 Hattı 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

Tablo 2'de verilen RMSE ve MAE değerleri ile elde edilen gerçek ve tahmin edilen yolcu sayısı grafiği Şekil 2'de gösterilmektedir.



Şekil 2. B/24 tüm bilet tipleri için gerçek değerler ve tahmin değerleri


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 3'te verilmiştir. RMSE ve MAE sırasıyla 18,517 ve 14,569 ile en iyi sonuç olup GRU ağı ile elde edilmiştir.

Tablo 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

Tablo 3'te verilen RMSE ve MAE değerleri ile elde edilen gerçek ve tahmin edilen yolcu sayısı grafiği Şekil 3'te gösterilmektedir.



Şekil 3. B/24 tam bilet tipi için gerçek değerler ve tahmin değerleri


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 ağı modelleri sonucu elde edilen hata ölçüt değerleri Tablo 4'te verilmiştir. RMSE ve MAE sırasıyla 11,418 ve 8,701 olarak en iyi sonuç LSTM ağı ile elde edilmiştir.

Tablo 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	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

Tablo 4'te verilen RMSE ve MAE değerleri ile elde edilen gerçek ve tahmin edilen yolcu sayısı grafiği Şekil 4'te gösterilmektedir.



Şekil 4. B/24 öğrenci bilet tipi için gerçek değerler ve tahmin değerleri


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

Tablo 5. Farklı başlangıç değerleriyle B/44-B hattı tüm bilet tiplerinin RMSE VE MAE değerleri

B/44-B 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	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

Tablo 5’te verilen RMSE ve MAE değerleri ile elde edilen gerçek ve tahmin edilen yolcu sayısı grafiği Şekil 5’de gösterilmektedir.

**Şekil 5.** B/44-B tüm bilet tipleri için gerçek değerler ve tahmin değerleri


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 6’da verilmiştir. RMSE ve MAE değerleri sırasıyla 14,305 ve 10,186 olarak en iyi sonuç GRU ağı ile elde edilmiştir.

Tablo 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

Tablo 6’da verilen RMSE ve MAE değerleri ile elde edilen gerçek ve tahmin edilen yolcu sayısı grafiği Şekil 6’da gösterilmektedir



Şekil 6. B/44-B tam bilet tipi için gerçek değerler ve tahmin değerleri

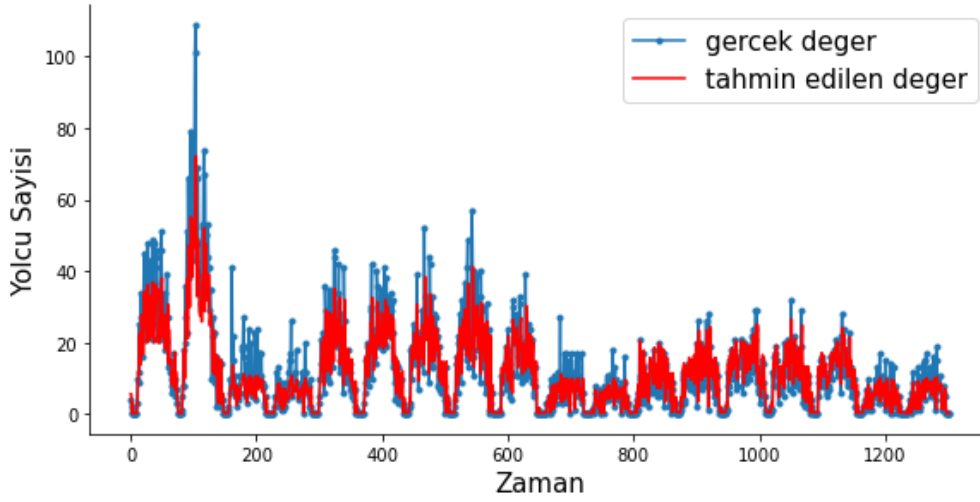
Bu değerler 200 düğüm sayısı, 150 epoch değeri ve 3 katmanlı GRU sinir ağı ile gerçekleştirilmiştir. 6.test denemesi sonucu elde edilen en iyi RMSE ve MAE değerleri sırasıyla 14,305 ve 10,186 iken en kötü RMSE ve MAE değerleri 5.test denemesi sonucu sırasıyla 14,484 ve 10,353 olarak GRU ile elde edilmiştir. 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.

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

Tablo 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 7’de verilen RMSE ve MAE değerleri ile elde edilen gerçek ve tahmin edilen yolcu sayısı grafiği Şekil 7’de gösterilmektedir.



Şekil 7. B/44-B öğrenci bilet tipi için gerçek değerler ve tahmin değerleri

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.

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 8'de verilmiştir.

Tablo 8. 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

Literatür çalışmalarındaki 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 öneriler

Bu çalışmada, 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 ağları ile oluşturulmuş 6 farklı model kullanılarak yolcu sayısı tahmini gerçekleştirilmiş ve elde edilen sonuçlar karşılaştırılmıştır.

Önerilen LSTM ve GRU sinir ağları 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 başarı oranına 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 başarı oranının 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 başarı oranı elde edilen şekillerde görülmektedir. Ancak, 4/G hattında bulunan bilet tiplerine ait yolcu sayısı tahmin başarı oranı 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. Bu durum, tahminleme çalışmalarında yolcu statüsünün önemli olduğu sonucunu ortaya çıkarmaktadır.

Araştırmacıların Katkı Oranı Beyanı

Bu çalışma Ece Sema Korkmaz'a ait "Kent İçi Yolcu Taşımacılığında Akıllı Ulaşım Sistemleri Uygulamaları" isimli tezden türetilmiştir. Serhat Berat Efe ve İlyas Özer öğrencinin tez danışmanları olup tüm yazarların çalışmadaki katkı oranları eşittir.

Destek ve Teşekkür Beyanı

Bu çalışma Bandırma Onyedü Eylül Üniversitesi Bilimsel Araştırma Projeleri Koordinasyon Birimi tarafından desteklenmiştir. Proje Numarası: BAP-20-1010-002.

Çalışma kapsamında kullanılan verileri sağladıkları için Bursa Ulaşım Toplu Taşıma İşletmeciliği Turizm Sanayi ve Ticaret A.Ş.'ye teşekkür ederiz.

Çıkar Çatışması Beyanı

Çalışma kapsamında herhangi bir kurum veya kişi ile çıkar çatışması bulunmamaktadır.

Kaynaklar

Andersen J., and Sutcliffe S. (2000). Intelligent Transport Systems (ITS) - An Overview. *IFAC Proc.* 33(18), 99–106, doi: 10.1016/s1474-6670(17)37129-x.

B. P. A.Ş. (2018). *Bursa Ulaşım Ana Planı Final Raporu 2035*.

Chen, C. M., Liang, C. C., and Chu, C. P. (2020). Long-Term Travel Time Prediction Using Gradient Boosting. *J. Intell. Transp. Syst. Technol. Planning, Oper.*, 24(2), 109–124, doi: 10.1080/15472450.2018.1542304.

Chen, Q. (2014) Global Optimization for Bus Line Timetable Setting Problem. *Discret. Dyn. Nat. Soc.*, 2014, 1-9, doi: 10.1155/2014/636937.

Do, L. N. N., Taherifar, N., and Vu H. L. (2019). Survey of Neural Network-Based Models for Short-Term Traffic State Prediction. *Wiley Interdiscip. Rev. Data Min. Knowl. Discov.*, 9(1), 1–24, doi: 10.1002/widm.1285.

Fonzone, A., Schmöcker, J. D., and Liu, R. (2015). A Model of Bus Bunching under Reliability-based Passenger Arrival Patterns. *Transp. Res. Procedia*, 7, 276–299, doi: 10.1016/j.trpro.2015.06.015.

Gkiotsalitis, K., and Alesiani, F. (2019). Robust Timetable Optimization for Bus Lines Subject to Resource and Regulatory Constraints. *Transp. Res. Part E Logist. Transp. Rev.*, 128, 30–51, doi: 10.1016/j.tre.2019.05.016.

Gorur, K., Ozer, C.K., Ozer, I., Karaca, A.C., Çetin, O., and Koçak, İ. (2022). Species-Level Microfossil Prediction for Globotruncana genus Using Machine Learning Models. *Arab J Sci Eng.*, <https://doi.org/10.1007/s13369-022-06822-5>

Gültepe, Y. (2019). Makine Öğrenmesi Algoritmaları ile Hava Kirliliği Tahmini Üzerine Karşılaştırmalı Bir Değerlendirme. *Eur. J. Sci. Technol.*, 16, 8–15, doi: 10.31590/ejosat.530347.

Hollander, Y. and Liu, R. (2008). Estimation of the Distribution of Travel Times by Repeated Simulation. *Transp. Res. Part C Emerg. Technol.*, 16(2), 212–231, doi: 10.1016/j.trc.2007.07.005.

Kane, S. N., Mishra, A., and Dutta, A. K. (2016). Preface: International Conference on Recent Trends in Physics (ICRTP 2016). *J. Phys. Conf. Ser.*, 755(1), doi: 10.1088/1742-6596/755/1/011001.

Khadhir, A., Anil Kumar, B., and Vanajakshi, L. D. (2021). 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.*, 25(1), 58–76, doi: 10.1080/15472450.2020.1754818.

- Kingma, D. P. and Ba, J. L.** (2015). Adam: A method for stochastic optimization. *3rd International Conference on Learning Representations, ICLR 2015 - Conference Track Proceedings*, pp. 1–15.
- Ma Q., Li S., Zhang H., Yuan Y., and Yang L.** (2021). Robust Optimal Predictive Control for Real-Time Bus Regulation Strategy with Passenger Demand Uncertainties in Urban Rapid Transit. *Transp. Res. Part C Emerg. Technol.*, 127, 103086, doi: 10.1016/j.trc.2021.103086.
- Nagy, A. M. and Simon, V.** (2018) Survey on Traffic Prediction in Smart Cities. *Pervasive Mob. Comput.*, 50, 148–163, doi: 10.1016/j.pmcj.2018.07.004.
- Ozbay, H., and Dalcali, A.** (2021). Effects of COVID-19 on electric energy consumption in Turkey and ANN-based short-term forecasting. *Turkish Journal of Electrical Engineering and Computer Sciences*, 29(1), 78–97. <https://doi.org/10.3906/ELK-2006-29>
- Ozer, I., Efe, S. B., and Ozbay, H.** (2021). CNN / Bi-LSTM-based deep learning algorithm for classification of power quality disturbances by using spectrogram images. *International Transactions on Electrical Energy Systems*, 31(12), 1–16. <https://doi.org/10.1002/2050-7038.13204>
- Ozer, I., Efe, S. B., and Ozbay, H.** (2021). A combined deep learning application for short term load forecasting. *Alexandria Engineering Journal*, 60(4), 3807–3818. <https://doi.org/10.1016/j.aej.2021.02.050>
- Ozer, I., Ozer, Z., and Findik, O.** (2017). Lanczos kernel based spectrogram image features for sound classification. *Procedia Computer Science*, 111(2015), 137–144, <https://doi.org/10.1016/j.procs.2017.06.020>
- Ozer, I., Ozer, Z., and Findik, O.** (2018). Noise robust sound event classification with convolutional neural network. *Neurocomputing*, 272, 505–512.
- Ozer, Z., Ozer, I., and Findik, O.** (2018). Diacritic restoration of Turkish tweets with word2vec. *Engineering Science and Technology, an International Journal*, 21(6), 1120–1127. <https://doi.org/10.1016/j.jestch.2018.09.002>
- Özkul, M.** (2019). Metin Madenciliği Yöntemi ile Akıllı Ulaşım Sistemleri Algısının Duygu Analizi ile Ölçülmesi. *Bandırma Onyedü Eylül Üniversitesi Sosyal Bilimler Enstitüsü*, YL Tezi.
- Tang, J., Yang, Y., Hao, W., Liu, F., and Wang, Y.** (2021). A Data-Driven Timetable Optimization of Urban Bus Line Based on Multi-Objective Genetic Algorithm. *IEEE Trans. Intell. Transp. Syst.*, 22(4), 2417–2429, doi: 10.1109/TITS.2020.3025031.
- T.C. Ulaştırma ve Altyapı Bakanlığı.** (2020). *Ulusal Akıllı Ulaşım Sistemleri Strateji Belgesi ve 2020-2023 Eylem Planı*, 15–18.
- Tektaş, M., Korkmaz K., and Erdal H.** (2016). Akıllı Ulaşım Sistemlerinin Geleceği (Ekonomik ve Çevresel Faydaları). *ICOMEPE, International Congress of Management Economy and Policy*, 1–16.
- Tektaş, M., and Tektaş N.** (2019). Akıllı Ulaşım Sistemleri (AUS) Uygulamalarının Sektörlere Göre Dağılımı. *Akıllı Ulaşım Sist. ve Uygulamaları Dergisi*, 2(1), 32-41.
- Toncharoen, R. and Piantanakulchai, M.** (2018). Traffic State Prediction Using Convolutional Neural Network. *Proceeding 15th Int. Jt. Conf. Comput. Sci. Softw. Eng. JCSSE*, 2–7, doi: 10.1109/JCSSE.2018.8457359.
- Wang, Y., Zhang, D., Hu, L., Yang, Y., and Lee, L. H.** (2017). A Data-Driven and Optimal Bus Scheduling Model with Time-Dependent Traffic and Demand. *IEEE Trans. Intell. Transp. Syst.*, 18(9), 2443–2452, doi: 10.1109/TITS.2016.2644725.
- Watkins, K. E., Ferris, B., Borning, A., Rutherford, G. S., and Layton, D.** (2011). 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.*, 45(8), 839–848, doi: 10.1016/j.tra.2011.06.010.