



PANDEMİ SÜRECİNDE ŞEHİR İÇİ YOLCU TAŞIMA SAYILARININ VERİ MADENCİLİĞİ YÖNTEMİ İLE BELİRLENMESİ: KAYSERİ ÖRNEĞİ

Gülçin CANBULUT*

Nuh Naci Yazgan Üniversitesi, Mühendislik Fakültesi, Endüstri Mühendisliği Bölümü, Kayseri, Türkiye

Anahtar Kelimeler

Talep,
Pandemi,
Korelasyon,
Lineer Regresyon,
Yapay Sinir Ağları

Öz

Son aylarda tüm dünyayı kasıp kavuran pandemi; ülkemizi de oldukça etkilemektedir. Pandemi birçok sektörde krize yol açtığı gibi, toplu taşıma sektöründe de oldukça etkili olmaktadır. Toplu taşıma sistemlerinde taşınan yolcu sayıları, pandemi nedeniyle büyük miktarda azalış göstermektedir. Bu çalışmada, pandeminin devam etmesi durumunda, gerçekleşecek olan taşınacak günlük yolcu sayılarının tahmin edilmesi amaçlanmaktadır. Böylelikle taşıma sistemlerinin daha optimize edilmiş bir şekilde çalışmalarının sağlanacağı düşünülmektedir. Bu durumun da toplu taşıma sektörünün daha verimli sonuçlar elde etmesine olanak sağlaması beklenmektedir. Ülkemizde ilk vaka, diğer ülkelere nazaran daha ilerleyen tarihlerde görülmüştür. İlk vakanın daha önce zamanlarda görüldüğü bazı ülkelerdeki günlük vaka sayıları baz alınarak en fazla benzerlik gösteren ülke korelasyon katsayısı yardımıyla belirlenmeye çalışılmıştır. Korelasyon katsayısına göre belirlenmiş olan ülkenin vaka sayıları temel alınarak sonraki günler için ülkemizdeki vaka sayıları tahmin edilmiştir. Vaka sayılarının tahmin edilmesinde ise; WEKA yazılımı yardımıyla Lineer Regresyon ve Yapay Sinir Ağları yöntemi kullanılmıştır. Kullanılan bu yöntemlerle yapılan tahminlerin hata değerlerinin karşılaştırılması sonucunda Yapay Sinir Ağları ile elde edilen tahminlerin daha doğru sonuçlar verdiği belirlenmiştir. Bu yöntemle elde edilmiş vaka sayısı değerleri baz alınarak gelecek günlerde karşılaşılabilecek yolcu sayıları tahmin edilmiştir.

ESTIMATION URBAN TRANSPORT PASSENGER NUMBERS USING DATA MINING METHOD DURING THE PANDEMIA: THE SAMPLE OF KAYSERİ

Keywords

Demand,
Pandemia,
Correlation,
Linear Regression,
Artificial Neural Network

Abstract

The pandemic that has taken the whole world by storm in recent months; also affects our country considerably. The pandemic causes crises in many sectors, as well as in the public transportation sector. The number of passengers transported in public transport systems decreases significantly due to the pandemic. In this study, it is aimed to estimate the number of daily passengers to be transported if the pandemic continues. The first case in our country was seen in later dates compared to other countries. Based on the number of cases in the countries, the country with the most similarity will be tried to be determined. In order to calculate this similarity ratio, the correlation analysis method will be used. Based on the number of cases in the determined country, the number of cases in our country will be tried to be estimated for the next days. In estimating the number of cases; Linear Regression and Artificial Neural Networks method will be used with the help of WEKA software. Comparison of the errors of the estimates made by these methods will be made. The number of passengers to be encountered in the coming days will be estimated based on the values of the number of cases obtained by the method with fewer errors.

Ahntı / Cite

Canbulut, G. (2022). Pandemi Sürecinde Şehir İçi Yolcu Taşıma Sayılarının Veri Madenciliği Yöntemi İle Belirlenmesi: Kayseri Örneği, Mühendislik Bilimleri ve Tasarım Dergisi, 10(3), 1043-1053.

* İlgili yazar / Corresponding author: gcanbulut@nny.edu.tr, +90-352-324-0000

Yazar Kimliği / Author ID (ORCID Number)	Makale Süreci / Article Process	
G.Canbulut, 0000-0001-7106-4528	Başvuru Tarihi / Submission Date	21.04.2021
	Revizyon Tarihi / Revision Date	11.02.2022
	Kabul Tarihi / Accepted Date	14.04.2022
	Yayın Tarihi / Published Date	30.09.2022

1. Giriş (Introduction)

İnsanlık tarihinden dahi daha eski bir tarihe sahip olduğu iddia edilen mikroorganizmalar insanları; birçok alanda etkilemektedir. Bu küçük canlıların sebep olduğu hastalıklar insanlar arasında hızlı bir şekilde yayılarak, toplulukları birçok konuda değişiklikler yapmaya zorlamaktadır. Tarihte insanlar veba, çiçek, tifüs, tifo, kolera, influenza, sıtma gibi birçok bulaşıcı hastalıklara maruz kalmıştır.

Son aylarda ise tüm dünyayı etkileyen Covid19 adlı virüsün sebep olduğu hastalık, ülkemizi de birçok alanda olumsuz olarak etkilemiş ve etkilemeye de devam etmektedir. Pandemi olarak adlandırılan bu salgın birçok sektörde krize sebep olmaktadır. Şehir içi toplu taşıma sektörü de toplu taşıma araçlarında sosyal mesafenin sağlanmasının zorluğu nedeniyle oldukça fazla etkilenen sektörlerdendir.

Toplu taşıma şirket yöneticileri bu krizi yönetebilmek amacıyla; birtakım tedbirleri almak zorunda kalmaktadır. Bu tedbirleri alabilmeleri için ise; gelir ve giderlerini doğru bir şekilde tahmin edebilmeleri gerekmektedir. Dolayısıyla bu aşamada belirsizlik içeren taşınacak yolcu sayısı parametresinin belirlenmesi önem arz etmektedir. Literatürde toplu taşıma sektöründe yolcu sayısının tahmini için birçok yöntem kullanılmıştır [1-8]. Mevcut belirsizliklere ek olarak, yaşanan pandemi sürecinde gerekli veri sayısının azlığı geleneksel tahmin yöntemlerinin uygulanmasını daha da zorlaştırmaktadır. Ayrıca yapılan literatür taramasında şehir içi toplu taşıma sistemlerinin taşınacak yolcularının tahmin edilmesi ile ilgili uygulamalar, diğer toplu taşıma sistemlerine nazaran daha dar kapsamda kalmaktadır.

Suryani vd (2010) havayolu yolcu sayısını tahmin etmek ve gelecek talebi karşılayacak yolcu terminal kapasitesi ile alakalı bazı senaryoları değerlendirecek bir model geliştirmişlerdir. Sistem dinamikleri yapısı; modeli kurmak, sistem performansını artırmak amacıyla yeni senaryolar üretmek, analiz etmek amacıyla kullanılmıştır.

Wadud (2011) yapmış olduğu çalışmada yeni bir havalimanı kurulumu için yolcu tiplerini tahmin etmek üzere basit bir modelleme yaklaşımı sunmuştur. Modelde kısıtlı veri ile bütünleşik zaman serileri ve ağırlık merkezi tipinde talep modeli geliştirilmeye çalışılmıştır. Bu havalimanı için yapılan talep tahmini çalışması daha sonra modeldeki parametreler ve yolcu anketleri kullanılarak revize edilmiştir.

Jiang vd (2020) bass difüzyon modeli ile mevsimsel dalgalanma etkisinde tahminleme yöntemini birleştirerek Bass+BL+mevsimsellik adı altında yeni bir model önermiştir. Önermiş olduğu yöntemi bir havalimanında uygulayarak performansını değerlendirmek istemiş ve önerilen yöntemin diğer klasik yöntemlere nazaran daha kesin sonuçlar elde etmiş olduğunu göstermiştir.

Reddy (2019) çalışmasında aritmetik ve istatistiksel metotların her ikisini de destekleyen R yazılımı aracılığıyla raylı sistem yolcu taleplerinin tahminlerini yapmak üzere bir metot geliştirmiştir. Çalışma R yazılımı ile üstel düzeltme yöntemi kullanılarak nasıl tahmin yapılabileceğini göstermektedir.

Tsai vd (2009) demiryolu yolcu talep tahmini için kısa vadede iki yeni sinir ağı yapısı oluşturmuştur. Önerilen ilk ağ yapısı, ağda belirlenmiş bağlantılar aracılığıyla ayırt edici giriş bilgileriyle ilgilenen çoklu zamansal birim sinir ağıdır (MTUNN). Önerilen ikinci ağ yapısı, birkaç ayrı modelde farklı girdi bilgileri ile ilgilenen paralel topluluk sinir ağıdır (PENN). Ayrı modellerin çıktılarını daha sonra nihai tahminleri elde etmek için entegre edilir. Konvansiyonel çok katmanlı algılayıcı (MLP) de karşılaştırma amacıyla oluşturulmuştur. Sonuçlar hem MTUNN hem de PENN'in çalışmada geleneksel MLP'den daha iyi performans gösterdiğini ortaya koymuştur. Ortalama olarak, MTUNN, MLP'ye kıyasla MSE'de %8,1 ve MAPE'de %4,4 iyileştirme elde edebilir. PENN, MLP'ye kıyasla MSE'de %10,5 ve MAPE'de %3,3 oranında iyileşme sağlayabilir.

Zhao vd (2019) yakın zaman verilerinin alaka düzeyinin dikkate alan kısa vadeli demir yolu yolcu talep tahmini için bir hibrit model önermiştir. Model; birinci aşamada orijinal zaman serilerinin temel bileşene (PC) ve sinyal işleme prosedürü olarak benimsenen tekil spektrum analizi (SSA) yöntemiyle birkaç ayrıntılı bileşene (DC) ayrıştırılması; ikinci aşamada tek boyutlu zaman serilerinin haftalık çapraz korelasyon matrislerine dönüştürülmesiyle dalgacık paketi ayrışması (WPDCNN) ile tasarlanmış evrişimli sinir ağı aracılığıyla PC'nin tahmini; üçüncü aşamada ise destek vektörü regresyon (SVR) yöntemi ile DC'lerin tahmini olmak üzere üç aşamadan oluşmaktadır.

Çelebi vd (2019) demir yolu taşımacılığında kısa vadede yolcu talep tahmin modellerini geliştirme için yapay sinir ağlarının kullanımını önermiştir. Çok katmanlı algılayıcı (MLP) modeli, yalnızca basit mimarisi nedeniyle değil, aynı zamanda yaklaşım problemlerini çözmeye kanıtlanmış başarısı nedeniyle tercih edilmektedir. Zaman dilimindeki önemli mevsimselliği ortadan kaldırmak için her bir zaman dilimi diğerlerinden bağımsız olarak ele alınır ve her biri için günlük verilere dayalı yapay bir sinir ağı geliştirilir. 74 farklı zaman aralığı ile ilgili olarak, 74 farklı sinir ağı geçmiş verilerle eğitilir. Zaman aralıklarından birinde üç açıklayıcı örnek gösterilir ve tahmin modellerinin performansı, ortalama kare hatalarına (MSE) ve ortalama mutlak yüzde hatalarına (MAPE) dayalı olarak değerlendirilir.

Tsai vd (2005) demiryolu yolcu talebini tahmin etmek için iki ayrı dinamik yapay sinir ağı yapısı geliştirmiştir. İlk sinir ağı yapısı, zaman serisi tahmininde otoregresif model fikrini takip eder ve doğrusal olmayan bir otoregresif model oluşturur. Ek olarak, gereksiz girdileri ve eğitim örneklerini ortadan kaldırmak için iki deney test edilir. İkinci sinir ağı yapısı, birinci modeli genişletir. İlk modelin sonucu, önerilen doğrusal olmayan otoregresif modelin ümit verici performansa ulaşabileceğini ve çoğu durumda Ortalama Mutlak Yüzde Hatasının %20'den az olduğunu göstermektedir.

Bu çalışmanın amacı; Türkiye'den daha önceki günlerde koronavirüs vakası görülmüş olan ülkelerdeki vaka sayıları dikkate alınarak Türkiye'de ilerleyen günlerde görülmesi muhtemel vaka sayısının tespit edilmesi ve belirlenmiş olan bu vaka sayılarına uygun olarak toplu taşıma sistemi yolcu sayısının tahmin edilmesidir. İlk olarak Dünya genelinden beş ülke seçilmiştir. Ülke seçiminde Amerika Birleşik Devletleri ve İtalya; tüm dünyada neredeyse en fazla vaka sayısına sahip olan ülkeler olması sebebiyle seçilmiştir. Belçika, Fransa ve Şili ise Türkiye ile yaklaşık olarak aynı toplam vaka sayısına sahip olması sebebiyle seçilmek istenmiştir. Seçilen bu beş ülke ile Türkiye'nin benzerlikleri günlük görülen koronavirüs vaka sayıları açısından karşılaştırılmıştır. En fazla benzerlik oranına sahip ülkedeki vaka sayıları ile Türkiye'deki günlük vaka sayıları dikkate alınarak Türkiye'de ilerleyen günlerde görülmesi muhtemel vaka sayılarının tahmin edilmesi amaçlanmıştır. Günlük vaka sayısı ile şehir içi toplu taşıma sisteminde taşınacak yolcu sayısı arasında bir ilişkinin var olduğu düşünülmektedir. Ardından yapılan günlük vaka sayısı tahminlerine göre; yine belirtilen günler için Kayseri ilindeki şehir içi toplu taşıma yolcu sayısı tahmin edilmeye çalışılmıştır.

Çalışmanın bundan sonraki bölümleri şu şekilde organize edilmiştir; ikinci bölümde, kullanılan yöntemlerle ilgili genel bilgiler verilmiştir. Üçüncü bölümde problemle ilgili verilere ile problemin çözümü için planlanan yöntemler kullanılarak elde edilen sonuçlara ve karşılaştırmalara yer verilmiştir. Son bölümde ise; çalışma sonuçları ve gelecek çalışma önerileri sunulmuştur.

2. Materyal ve Yöntem (Material and Method)

Türkiye'de ilk koronavirüs vakası 11 Mart 2020 tarihinde görülmüş ve bu vakaya birçok ülkeden oldukça ilerleyen bir tarihte rastlanılmıştır. Çalışmanın amacı; diğer ülkelerde rastlanılan vaka sayılarından yararlanılarak tahminlemeler yapılmasıdır. İlk olarak Dünya genelinden beş ülke rassal olarak seçilmiştir: Amerika Birleşik Devletleri, Fransa, İtalya, Belçika ve Şili. Koronavirüs vaka sayıları açısından; seçilen bu beş ülke ile Türkiye arasındaki korelasyon katsayıları belirlenerek benzerlikleri karşılaştırılmıştır.

Daha sonra elde edilen benzerlik oranlarına göre en fazla benzerlik içeren ülke ele alınmış ve ele alınan bu ülkenin günlük vaka sayıları ile Türkiye'de günlük görülen vaka sayılarına göre yapay sinir ağları ve lineer regresyon yöntemlerinden yararlanılarak tahmin modeli oluşturulmaya çalışılmıştır. Oluşturulmuş tahmin modelleri ortalama mutlak hata (mean absolute error-MAE) değerlerine göre; hangi yöntemin daha doğru sonuçlar vermiş olduğu belirlenmiştir. Türkiye'de ilerleyen günlerde görülmesi muhtemel vaka sayıları daha kesin sonuçlar vermiş olduğu tespit edilen tahmin modeli sayesinde tespit edilmeye çalışılmıştır.


Ardından Türkiye'de ilerleyen günlerde görülecek vaka sayısı tahmini baz alınarak şehir içi toplu taşıma sistemi yolcu sayısının tahmin edilmesi amaçlanmıştır. Bu aşamada yapay sinir ağları ve lineer regresyon olmak üzere iki yöntem kullanılmış ve sonuçlar ortalama hata kareleri (mean square error-MSE) değerlerine göre karşılaştırılmıştır.

2.1. Yapay Sinir Ağları-YSA (Artificial Neural Network- ANN)

Yapay sinir ağları metodolojisi insan beyninin örnek alınması ile oluşturulmuş ve güncelliğini kaybetmemiş yöntemlerden birisidir. Dijital ortamda; insan beyninin yapabildiği faaliyetleri yapabilen, yeterli verinin olmadığı durumlarda dahi; eldeki verilerden yola çıkarak yorum yapabilen, sonuca ulaşan; kendi ortamına veri girişini kabul ederek sürekli öğrenme faaliyetine devam eden ve öğrenme faaliyeti neticesinde elde etmiş olduğu sonuçları hatırlayıp kullanıcıya sunan algoritmalara kısaca "Yapay Sinir Ağları" adı verilir (Civalek ,1999; Sözen vd,2005;

Sözen vd,2004). Yapay sinir ağları yardımıyla; klasik yöntemlerle çözülemeyen problemler insan beyninin faaliyetlerinden yararlanılarak kolaylıkla sonuca ulaştırılabilir (Kalogirou,2000; Dorvlo vd., 2002).


Yapay sinir ağları algoritmasına ait bir yapının temelini; biyolojik sinir ağlarını ve insan beyninin de en temel yapısı olan sinir hücreleri oluşturmaktadır. İnsan beyninde yer alan sinir hücrelerinin hatırlama, düşünme ve her durumda daha önceki deneyimleri sayesinde sonucu güncelleme yetenekleri bu yöntem tarafından da örnek alınmıştır. Şekil 1'de basitleştirilmiş biyolojik bir beyin sinir hücresi ve bileşenleri ile ilişkisi görülmektedir.



Şekil 1. Biyolojik bir sinir hücresi ve bileşenleri (A Biological Nerve Cell and Its Components)

Yapay sinir ağları, insan beyninde yer alan bu nöronlara benzer şekilde değişik bağlantı türleri ile bağlanması sonucu oluşan sistemlerdir. Dolayısıyla yapay sinir ağlarında da biyolojik bir beyin sinir hücresinde yer alan bileşenler var olmaktadır. Biyolojik bir nöronun yapısı incelendiğinde, bir gövde, bir çekirdek ve birisi kısa, diğeri uzun olmak üzere iki tür uzantıdan oluşmaktadır. Bu uzantılardan kısa ve dallanmış olana dendrit ismi verilir ve hücredeki görevi hücreye gelen bilgileri toplamaktır. Uzun ve tek olan uzantı ise akson olarak adlandırılır ve çıktı bilgilerini nöronlara taşımakla görevlendirilmiştir. Bir sinir hücresinin aksonu ile diğer bir sinir hücresinin dendritinin birleşim noktasına sinaps denir. Sinapslar ise nöronlardan almış oldukları bilgileri değerlendirmektedirler (Kalogirou, 2000; Kalogirou, 1999).

İnsan beyin hücresini örnek olarak oluşturulan yapay bir sinir ağı ise Şekil 2'de gösterildiği gibidir.



Şekil 2. Yapay bir sinir ağı ve bileşenleri (An Artificial Neural Network and Its Components)

Yapay bir sinir hücresi oluşturulurken genellikle şu beş ana birimden yararlanır:

- Girdiler
- Ağırlıklar
- Toplama fonksiyonu
- Aktivasyon fonksiyonu
- Çıktılar

Yapay bir ağda işlemler şu şekilde yürümektedir:

1. İlk olarak girdiler, sinir hücresinde ilgili bağlantı ağırlıkları ile çarpma işlemine tabi tutulurlar, ardından bu değerler bir birleştirme fonksiyonu yardımıyla birleştirilirler.
2. Birleştirme işlemi neticesinde elde edilen değer nöronun net girdisi olarak belirlenir.
3. Net girdinin belirlenmesinin ardından, bu net girdi bir aktivasyon fonksiyonu ile işlenerek; bu fonksiyona ait çıktı sayesinde de nöronların net çıktı değerleri elde edilmiş olur (Hamzaçebi, 2011).

Literatürde yapay sinir ağlarına ait birçok sınıflandırma ile karşılaşmaktadır. Buna göre yapay sinir ağlarını yapılarına ve öğrenme algoritmalarına göre Şekil 3'teki gibi sınıflandırmak mümkündür (Rojas, 1996; Sağiroğlu vd. 2003; Alpaydın, 2004;Alataş, 2006; Şen, 2004):



Şekil 3. Yapay sinir ağlarının sınıflandırılması (The Classification of The Artificial Neural Network)

Yapay sinir ağları; yapılarında bulunan sinirler arasındaki bilgi akışının yönüne göre ileri ve geri beslemeli yapay sinir ağları olarak sınıflandırılırken; ağın öğrenme yapısına göre danışmanlı ve danışmansız yapay sinir ağları olarak sınıflandırılmaktadır.

İleri beslemeli yapay sinir ağlarında birisi girdi katmanı, birisi çıktı katmanı; diğerleri ise gizli katmanlar olmak üzere çok katmanlı yapılar söz konusudur. Bu yapay sinir ağı yapısında bilgi akışı, girdi katmanından gizli katmana doğru iletildikten sonra, gizli katmandan da çıkış katmanına iletilerek ileri yönlü olmaktadır. Bu tür ağlara; çok katmanlı algılayıcılar (multilayer perceptron) ve öğrenme vektör nicelendirmesi (LVQ) örnek olarak verilebilir.

Geri beslemeli yapay sinir ağlarında da ileri beslemeli ağlarda olduğu gibi çok katmanlı bir yapı söz konusudur. Ancak ileri beslemeli ağ yapısından farklı olarak, bu ağ yapısında bilgi akışı geriye doğru olabilmektedir. Hücrelerin çıktıları; yine kendisine ya da ağda bulunan başka bir hücreye girdi olarak kullanılabilir.

Çalışmada ileri beslemeli ağ yapılarının kullanışlı olması sebebiyle çok katmanlı algılayıcılar (multilayer perceptron) kullanılmıştır.

2.2. Lineer Regresyon (Linear Regression)

Lineer regresyon; bağımlı ve bağımsız değişkenler olarak tanımlanan iki veya daha fazla değişken arasındaki ilişkinin matematiksel modelini oluşturmakta kullanılan bir yöntemdir. Elde edilmiş olan matematiksel modele göre, bağımsız değişkenlerin değerlerine bağlı olan bağımlı değişken değeri ile bağımlı değişkenin gerçek değeri arasındaki hataların karesinin minimum olması amaçlanmaktadır.

Çok değişkenin yer aldığı, bağımsız değişkenler ile bağımlı değişken arasındaki doğrusal ilişki Eş.1'de gösterildiği gibidir:

$$Y = \alpha + \beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3 + \dots + \beta_n x_n \quad (1)$$

3. Şehir İçi Toplu Taşıma Yolcu Sayısı Tahminine Yönelik Bir Uygulama (An Application For Estimating The Number of Passengers in Urban Public Transport)

Son aylarda tüm dünyayı kasıp kavuran pandemi; ülkemizi de etkilemektedir. Pandemi sebebiyle birçok sektörde ortaya çıkan krizin toplu taşıma sektöründe de olumsuz etkileri görülmektedir. Şehir içi toplu taşıma sistemlerinde taşınan yolcu sayıları, pandemi nedeniyle büyük miktarda azalış göstermektedir. Şehir içi toplu taşıma şirket yöneticileri de gerçekleşecek yolcu sayılarına bağlı olarak kapasite yönetimini gerçekleştirmeyi planlamaktadır. Bu çalışmada, pandeminin devam etmesi durumunda, kapasite yönetiminin sorunsuz bir şekilde gerçekleştirilmesi amacıyla taşınacak günlük yolcu sayılarının tahmin edilmesi amaçlanmaktadır.

3.1. Örnek Alınacak Ülke Seçimi (Selection of The Country)

Ülkemizde ilk vaka, diğer ülkelere nazaran daha ilerleyen tarihlerde görülmüştür. İlk olarak ilk vakanın daha önceki zamanlarda görüldüğü bazı ülkelerdeki günlük vaka sayıları baz alınarak en fazla benzerlik gösteren ülke korelasyon katsayısı yardımıyla belirlenmiştir. Dikkate alınan ülkeler; Amerika Birleşik Devletleri, Fransa, İtalya, Belçika ve Şili'dir. Bu ülkelerdeki ilk vakanın görüldüğü günden itibaren günlük vaka sayıları değişkenine göre; Türkiye'de görülen değerler arasındaki ilişki incelenmiştir. Korelasyon analizi yapılması amacıyla SPSS programından yararlanılmıştır. Analiz için 245 veri kullanılmış ve korelasyon katsayısı hesaplanmasında; kullanılan

verilerin normal dağılım göstermemiş olmalarının saptanması sebebiyle parametrik olmayan testlerden Spearmann korelasyon katsayısı tekniğinden yararlanılmıştır. Karşılaştırma yapılan her bir ülke için elde edilen korelasyon analizi sonuçları Şekil 4'te gösterildiği gibidir.

Correlations				
			TÜRKİYE	ABD
Spearman's rho	TÜRKİYE	Correlation Coefficient	1,000	,053
		Sig. (2-tailed)	.	,410
		N	246	246
	ABD	Correlation Coefficient	,053	1,000
		Sig. (2-tailed)	,410	.
		N	246	246

Correlations					Correlations						
			TÜRKİYE	FRANSA				TÜRKİYE	İTALYA		
Spearman's rho	TÜRKİYE	Correlation Coefficient	1,000	,680**	Spearman's rho	TÜRKİYE	Correlation Coefficient	1,000	,303**		
		Sig. (2-tailed)	.	,000			Spearman's rho	TÜRKİYE	Sig. (2-tailed)	.	,000
		N	246	246					Spearman's rho	İTALYA	Correlation Coefficient
FRANSA	Correlation Coefficient	,680**	1,000	Spearman's rho	İTALYA	Sig. (2-tailed)					,000
	Sig. (2-tailed)	,000	.			Spearman's rho	İTALYA	N			246
	N	246	246					Spearman's rho	İTALYA	N	246

Correlations					Correlations						
			TÜRKİYE	BELÇİKA				TÜRKİYE	ŞİLİ		
Spearman's rho	TÜRKİYE	Correlation Coefficient	1,000	,761**	Spearman's rho	TÜRKİYE	Correlation Coefficient	1,000	-,429**		
		Sig. (2-tailed)	.	,000			Spearman's rho	TÜRKİYE	Sig. (2-tailed)	.	,000
		N	246	246					Spearman's rho	ŞİLİ	Correlation Coefficient
BELÇİKA	Correlation Coefficient	,761**	1,000	Spearman's rho	ŞİLİ	Sig. (2-tailed)					,000
	Sig. (2-tailed)	,000	.			Spearman's rho	ŞİLİ	N			246
	N	246	246					Spearman's rho	ŞİLİ	N	246

** Correlation is significant at the 0.01 level (2-tailed).

** Correlation is significant at the 0.01 level (2-tailed).

** Correlation is significant at the 0.01 level (2-tailed).

** Correlation is significant at the 0.01 level (2-tailed).

Şekil 4. Günlük vaka sayıları arasındaki korelasyon analizi (The Correlation Analysis Between The Daily Cases Number)

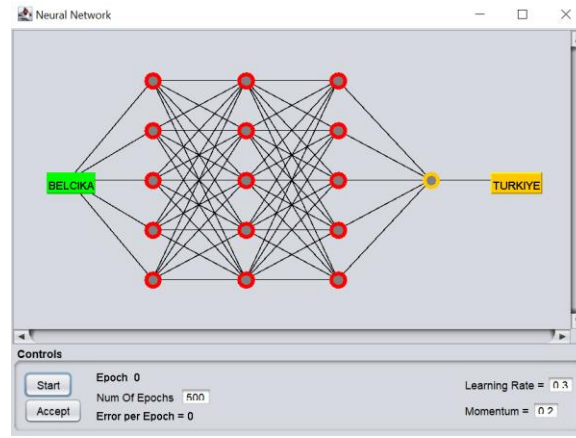
Korelasyon katsayıları incelendiğinde en yüksek benzerlik oranına Belçika-Türkiye arasında rastlanmış olduğu görülmektedir. Dolayısıyla ülkemizdeki ilerleyen günler için gerçekleşmesi muhtemel olan vaka sayılarının tahmininde Belçika'da görülen vaka sayılarından yararlanılmıştır.

3.2. Vaka Sayılarının Tespit Edilmesi (Determining The Number of Cases)

Türkiye ile vaka sayıları açısından en fazla ilişki olan ülkenin saptanmasının ardından; bu ülkedeki vaka sayıları baz alınarak, Türkiye'de gerçekleşmesi muhtemel vaka sayıları tahmin edilmeye çalışılmıştır. Vaka sayılarının tahmin edilmesi aşamasında; WEKA yazılımı yardımıyla Yapay Sinir Ağları ve Lineer Regresyon yöntemlerinden yararlanılmıştır.

WEKA yazılımı yapay zekâ tekniklerini uygulamak amacıyla oluşturulmuş ve hemen hemen bu alandaki tüm algoritmaları içerisinde barındıran bir yazılımdır. Program içerisinde yer alan araçlar sayesinde; sınıflandırma, kümeleme ve birliktelik gibi temel işlemleri yerine getirebilmektedir.

Yapılacak olan tahmin analizinde kullanılacak yapay sinir ağı yapısı; ağ yapısında birden fazla katmanın bulunması halinde ağı daha iyi öğrenme yeteneğine sahip olması sebebiyle; çok katmanlı olarak belirlenmiş ve oluşturulan ağ yapısı Şekil 5'te gösterilmiştir.



Şekil 5. Belçika'yı örnek alarak Türkiye vaka sayısı tahmini için yapay sinir ağ yapısı (The Artificial Neural Network Structure for The Cases Number Estimation in Turkey According to Belçika)

Şekil 5'te de görüldüğü üzere; oluşturulan yapay sinir ağında bir girdi parametresi ve bir çıktı parametresi bulunmaktadır. Yani Belçika'da gerçekleşen vaka sayılarına (girdi parametresi) bağlı olarak Türkiye'de gerçekleşecek vaka sayıları (çıkı parametresi) tahmin edilmeye çalışılmıştır.

Çalışma için her iki ülkeye ait toplamda 262 gün için günlük vaka sayısı verisi bulunmaktadır. Bu verilerin %66'sı ağı eğitimi için kullanılmış olup; geri kalan veriler ise ağı test edilmesi amacıyla kullanılmaktadır. Bu özellikleri ile oluşturulmuş olan ağ yapısı çalıştırıldığında; elde edilen sonuçlar Şekil 6'da görüldüğü gibidir:

```

=== Summary ===

Correlation coefficient           0.6493
Mean absolute error              766.2773
Root mean squared error          1272.974
Relative absolute error          85.056 %
Root relative squared error      87.1375 %
Total Number of Instances       89

```

Şekil 6. Yapay Sinir Ağı yöntemi ile elde edilen sonuçlar (The Results According to Artificial Neural Network)

Sonuçlar incelendiğinde hata değeri (MAE) 766.2773 olarak elde edilmiştir. Yapay sinir ağ yapısının güncellenmesi durumunda elde edilen sonuçlar Tablo 1'de gösterilmiştir.

Tablo 1.Yapay Sinir Ağ yapısının farklı kombinasyonları için sonuç değerleri (The Results According to Different Combinations of Artificial Neural Networks)

Model No	Ağ Yapısı	Eğitime Ayrılan Veri Yüzdeleri	Öğrenme Oranı	MAE	RMSE	Modelin Sonuca Ulaşması için Geçen Süre
1	a	%66	0.5	766	1272	0,02 sn.
2	a	%85	0.5	941	1610	0,02 sn.
3	a	%66	0.4	722	1211	0,02 sn.
4	a	%85	0.4	971	1650	0,02 sn.
5	a	%66	0.3	724	1206	0,02 sn.
6	a	%85	0.3	897	1426	0,02 sn.
7	5,5,5	%66	0.3	819	1481	0,16 sn.
8	5,5,5	%66	0.4	800	1457	0,16 sn.
9	5,5,5	%66	0.5	803	1355	0,17 sn.

Buna göre yapay sinir ağ yapısında ara katmanlarda yer alan nöron sayılarının, eğitime ayrılan veri yüzdelerinin ve öğrenme oranlarının değişimi sonucu; hata göstergelerinin değerlerinin ve modelin sonuca ulaşma sürelerinin de değişmiş olduğu görülmektedir. İlk 6 model zaman performansı açısından diğer modellere üstünlük sağlamaktadır; buna ek olarak 3. model; MAE (Mean absolute error) ve RMSE (Relative mean squared error) hata değerleri açısından en iyi değerlere sahiptir.

Yapay sinir ağı ile Türkiye’de görülecek vaka sayıları tahmin edildikten sonra; lineer regresyon yöntemi kullanılarak vaka sayıları tahmin edilmeye çalışılmıştır. Yine lineer regresyon yöntemi için WEKA yazılımından yararlanılmıştır ve elde edilen sonuçlar Şekil 7’de görüldüğü gibidir:

```

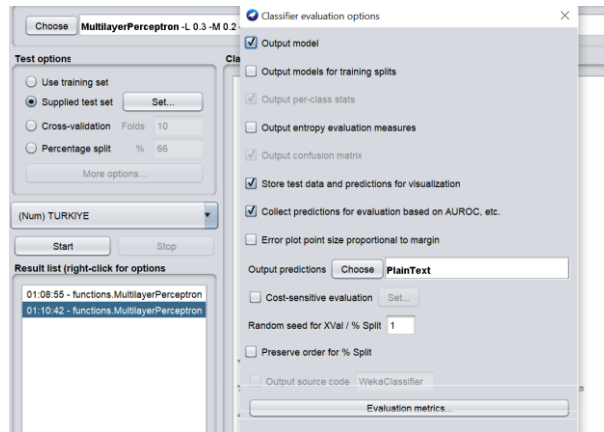
=== Summary ===

Correlation coefficient           0.3541
Mean absolute error              804.2774
Root mean squared error         1369.9163
Relative absolute error          89.274 %
Root relative squared error      93.7733 %
Total Number of Instances       89
  
```

Şekil 7. Lineer Regresyon yöntemi ile elde edilen sonuçlar (The Results According to Linear Regression)

Kullanılan bu yöntemlerle yapılan tahminlerin hata gösterge değerlerinin karşılaştırılması sonucunda hangi yöntemin daha doğru sonuçlar vereceği belirlenmiştir. Bu yöntemler hata gösterge değerlerine (MAE) göre incelendiğinde; yapay sinir ağı yöntemi (722), lineer regresyon yöntemine (804) göre daha doğru sonuç vermiş olduğu görülmektedir. Yapay sinir ağı ile daha kesin sonuçlar elde edilmesi sebebiyle ilerleyen günlerde görülecek vaka sayılarının tahmin edilmesinde; yapay sinir ağı yöntemi kullanılmaya karar verilmiştir.

Her iki ülkeye ait 262 adet veri üzerinden ağı eğitimi tamamlandıktan sonra; sadece Belçika’da gerçekleşmiş olan günlük vaka sayılarından yararlanarak; Türkiye için de tahminde bulunulmuştur. WEKA yazılımında; ilgili veriler tahmin amacıyla aktarılması için gerekli olan bilgiler Şekil 8’de gösterildiği gibidir.



Şekil 8. Tahmin değerlerinin WEKA yazılımı aracılığı ile elde edilmesi (Obtaining the Estimations Using WEKA)

Belçika’da ilk vaka 01.03.2020 tarihinde görülürken; Türkiye’de ilk vaka 11.03.2020 tarihinde görülmüştür. Dolayısıyla Belçika’da gün olarak 10 günlük daha fazla veri bulunmakta ve bu da Türkiye’de 10 gün için görülecek vaka sayısının tespiti için imkân sağlamaktadır. Belçika’ya ait 10 günlük vaka değerlerine göre; ülkemizde gerçekleşecek vaka sayılarının tahmin değerleri Tablo 2’de görüldüğü gibi elde edilmiştir.


Tablo 2. Yapay sinir ağı yöntemi kullanılarak elde edilmiş Türkiye’de görülecek vaka sayısı tahminleri (The Cases Number Estimations in Turkey According to Artificial Neural Networks)

Gün	Belçika’da Görülen Vaka Sayısı	Türkiye’de Görülecek Vaka Sayısı Tahmini
1	2734	3254
2	5182	3510
3	4477	3494
4	3416	3411
5	3224	3379
6	1875	2815
7	1123	2227
8	1901	2833
9	3164	3367
10	2565	3192

Türkiye için ilerleyen günlerde görülmesi beklenen vaka sayısı tahminlerinin yapılmasının ardından; Kayseri şehri için toplu taşıma yolcu sayılarının tahmin edilmesine çalışılmıştır. Vaka sayıları ile yolcu sayıları arasında bir

ilişki olduğu kabul edilmiş ve bu ilişki için yeniden bir yapay sinir ağı modellenmiştir. Modellenmiş olan yapay sinir ağı Şekil 9'da gösterildiği gibidir.

Şekil 9'da da görüldüğü üzere; oluşturulan yapay sinir ağında iki girdi parametresi ve bir çıktı parametresi bulunmaktadır. Yani Türkiye'de gerçekleşen günlük vaka sayılarına (girdi parametresi-Date ve Vakasayısı) bağlı olarak toplu taşıma sistemi yolcu sayıları (çıkı parametresi-yolcusayısı) tahmin edilmeye çalışılmıştır. Date girdi parametreleri pazartesi gününden itibaren haftanın günleri için 1-7 arasında sayılar kullanılarak değerlendirilmiştir. Ayrıca girdi ve çıkı katmanları arasında üç adet ara katman ve her ara katmanda ise onar adet nöron bulunmaktadır.



Şekil 9. Vaka sayıları-yolcu sayısı yapay sinir ağı yapısı(Case Number-Passenger Number Artificial Neural Network)

Çalışma için toplamda 262 gün için günlük vaka sayısı ve günlük toplu taşıma sistemi yolcu sayısı verisi bulunmaktadır. Bu verilerin %66'sı ağı eğitimi için kullanılacak olup; geri kalan veriler ise ağı test edilmesi amacıyla kullanılacaktır. Bu özellikleri ile oluşturulmuş olan ağı çalıştırıldığında; elde edilen sonuçlar Şekil 10'da görüldüğü gibi elde edilmiştir:

```

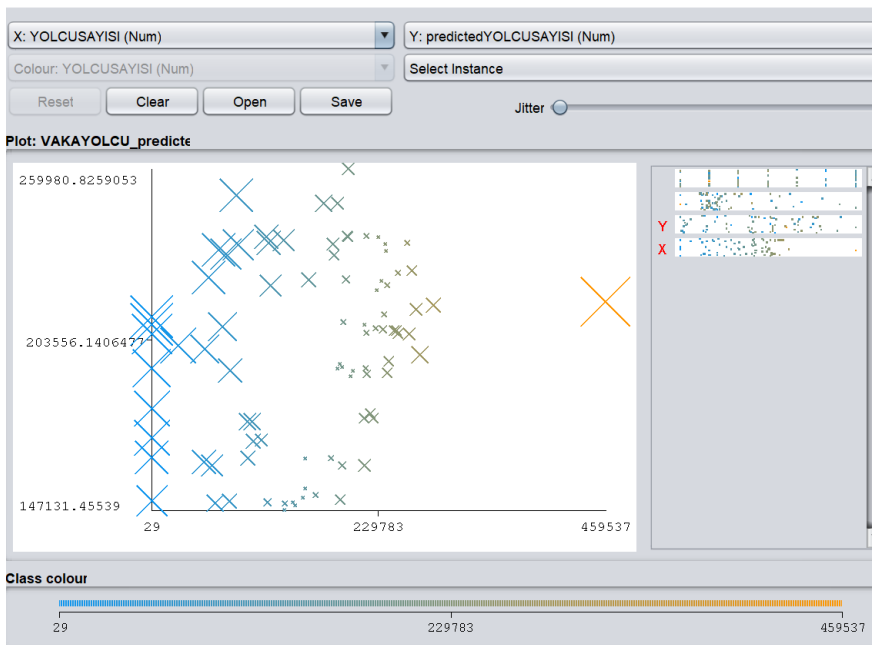
=== Summary ===

Mean absolute error           66907.2684
Root mean squared error      90628.8014
Total Number of Instances    89

```

Şekil 10. Yolcu sayısı tahmini için oluşturulan modele ait yapay sinir ağı yöntemi ile elde edilen sonuçlar (The Results of Passenger Number Estimation According to Artificial Neural Network)

Ayrıca gerçekleşen ve tahmin edilen yolcu sayılarına ait grafik Şekil 11'de gösterildiği gibidir.



Şekil 11. Gerçekleşen ve Tahmin Edilen Yolcu Sayıları (The Estimated and Obtained Passenger Numbers)

Bu sonuçlara göre Belçika örnek alınarak elde edilmiş vaka sayıları tahminine göre gelecek on gün için toplu taşıma yolcu sayıları Tablo 3'teki gibidir.

Tablo 3. Yapay sinir ağı yöntemi kullanılarak elde edilmiş toplu taşıma sistemi sayısı tahminleri (The Passenger Number Estimations in Turkey According to Artificial Neural Networks)

Gün	Toplu Taşıma Sistemi Yolcu Sayısı
1	162669
2	148746
3	229845
4	216466
5	203005
6	190398
7	177830
8	163345
9	148976
10	230330

4. Sonuç ve Tartışma (Result and Discussion)

Son aylarda tüm dünyayı kasıp kavuran pandemi; ülkemizi de etkilemektedir. Pandemi sebebiyle birçok sektörde ortaya çıkan krizin toplu taşıma sektöründe de olumsuz etkileri görülmektedir. Şehir içi toplu taşıma sistemlerinde taşınan yolcu sayıları, pandemi nedeniyle büyük miktarda azalış göstermektedir. Şehir içi toplu taşıma şirket yöneticileri de gerçekleşecek yolcu sayılarına bağlı olarak kapasite yönetimini gerçekleştirmeyi planlamaktadır. Bu çalışmada, pandeminin devam etmesi durumunda, kapasite yönetiminin sorunsuz bir şekilde gerçekleştirilmesi amacıyla taşınacak günlük yolcu sayılarının tahmin edilmesi amaçlanmıştır.

Ülkemizde ilk vaka, diğer ülkelere nazaran daha ilerleyen tarihlerde görülmesi ülkemizi avantajlı hale getirmekte ve ilerleyen günlerde görülebilecek vaka sayılarını tahmin etmekte fayda sağlamaktadır. İlk olarak ilk vakanın daha önceki zamanlarda görüldüğü bazı ülkelerdeki günlük vaka sayıları baz alınarak en fazla benzerlik gösteren ülke korelasyon katsayısı yardımıyla belirlenmeye çalışılmış ve seçilen ülkeler arasından Türkiye ile en fazla benzerliği sahip olan ülkenin Belçika olduğu sonucuna ulaşılmıştır.

Türkiye ile vaka sayıları açısından en fazla ilişki olan ülkenin saptanmasının ardından; Belçika'daki vaka sayıları baz alınarak, Türkiye'de gerçekleşmesi muhtemel vaka sayıları tahmin edilmeye çalışılmıştır. Vaka sayılarının tahmin edilmesi aşamasında; Yapay Sinir Ağları ve Lineer Regresyon yöntemlerinden yararlanılacaktır.

Kullanılan bu yöntemlerle yapılan tahminlerin doğruluk değerlerinin karşılaştırılması sonucunda yapay sinir ağları yönteminin lineer regresyon yöntemine göre daha doğru sonuç vermiş olduğu görülmüş ve yapay sinir ağları ile daha kesin sonuçlar elde edileceğinin anlaşılması üzerine ilerleyen günlerde görülecek vaka sayılarının tahmin edilmesinde; yapay sinir ağları yöntemi kullanılmaya karar verilmiştir. Belçika'ya ait veri setinde Türkiye'ye nazaran daha fazla günlük vaka değeri bulunmaktadır; bu değerler ülkemizde gerçekleşecek vaka sayılarının tahmin edilmesinde kullanılmıştır.

Türkiye için ilerleyen günlerde görülmesi beklenen vaka sayısı tahminlerinin yapılmasının ardından; Kayseri şehri için toplu taşıma yolcu sayılarının tahmin edilmesine çalışılmıştır. Vaka sayıları ile yolcu sayıları arasında bir ilişki olduğu kabul edilmiş ve bu ilişki için yeniden bir yapay sinir ağı modellenmiştir. Belçika örnek alınarak elde edilmiş vaka sayıları tahminine göre gelecek için toplu taşıma yolcu sayıları tahmin edilmiştir.

Çalışmada, yapay sinir ağları ve lineer regresyon gibi literatürde oldukça fazla kullanılan iki yonteme yer verilmiştir. Gelecek çalışmalarda bu yöntemlerden farklı yöntemler ile de şehir içi toplu yolcu sayılarının tahmin edilmesi uygun olacaktır. Ayrıca çalışmada görülen doğruluk oranlarının artması için veri setinde daha verinin bulunması gerektiği aşikârdır. İlerleyen zamanlarda çalışma güncellenen verilerle yeniden yapılması durumunda daha fazla doğruluk oranına ulaşabileceği öngörülmektedir. Yine çalışmada günlük vaka sayılarına ek olarak günlük ölü sayısı, kümülatif vaka sayısı, kümülatif ölü sayısı, iyileşen hasta sayısı gibi farklı değişkenler de kullanılması mümkündür.

Teşekkür (Acknowledgement)

Bu çalışmada kullanılan günlük yolcu sayılarına ait veriler Kayseri Büyükşehir Belediyesi iştiraki olan Kayseri Ulaşım A.Ş. tarafından sağlanmıştır. İşletmeye katkılarından dolayı teşekkür ederim.

Çıkar Çatışması (Conflict of Interest)

Yazar tarafından herhangi bir çıkar çatışması beyan edilmemiştir. No conflict of interest was declared by the author.

Kaynaklar (References)

- Alpaydın, E., *Introduction To Machine Learning*. England: The MIT Press Cambridge, 2004.
- Alataş, B., Sinirsel Ağlar, (www.firat.edu.tr/akademik/fakulteler/muhendislik/bilgisayar/balatas/SinirselAglar.pdf), [16.09.2006].
- Civalek, Ö., Dairesel Plakların Nöro-Fuzzy Tekniği İle Analizi, *Dokuz Eylül Üniversitesi Fen ve Mühendislik Dergisi*, 1(2), 13-31, 1999.
- Celebi, D., Bolat, B., Bayraktar, D., Light rail passenger demand forecasting by artificial neural networks, 2009 International Conference on Computers & Industrial Engineering, Troyes, 239-243, 2009, doi: 10.1109/ICCIE.2009.5223851.
- Dorvlo, S.S., Jervase, J.A., Al-Lawati, A., Solar Radiation Estimation Using Artificial Neural Network, *Applied Energy*, 71, 307-319, 2002.
- Hamzaçebi, C., Yapay Sinir Ağları: Tahmin Amaçlı Kullanımı Matlab ve Neurosolutions Uygulamalı, Ekin Yayınevi, Bursa, 1-105, 2011.
- Jiang, Y., Gao, S., Guan, W., Yin, X., Bass+BL+seasonality forecasting method for demand trends in air rail integrated service, *Journal Transportmetrica A: Transport Science*, <https://doi.org/10.1080/23249935.2020.1799111>.
- Kalogirou, S.A., Artificial Neural Networks in Renewable Energy Systems Applications: A Review, *Renewable and Sustainable Energy Reviews*, 5, 373-401, 2000.
- Kalogirou, S. A., Long-Term Performance Prediction of Forced Circulation Solar Domestic Water Heating Systems Using Artificial Neural Networks, *Applied Energy*, 66, 63-74, 2000.
- Kalogirou, S.A., Applications of Artificial Neural Networks in Energy Systems: A Review, *Energy Conversion&Management*, 40: 1073-1087, 1999.
- Reddy, M.R., Forecasting railway passengers demand using holt-winter method with R statistical tool, *International Journal of Advanced Multidisciplinary Scientific Research (IJAMSR)*, 2(7), 1-8, 2019.
- Rojas, R., *Neural Networks-A Systematic Introduction*. Berlin: Springer-Verlag, 1996.
- Sağiroğlu, Ş.; Beşdok E. & Erler, M., *Mühendislikte Yapay Zeka Uygulamaları I: Yapay Sinir Ağları*. Kayseri: Ufuk Kitap Kıratsiyeye Yayıncılık, 2003.
- Sözen, A., Arcaklıoğlu, E., Özalp, M., Formulation based on Artificial Neural Network of Thermodynamic Properties of Ozone Friendly Refrigerant/Absorbent Couples, *Applied Thermal Engineering*, 25(11-12): 1808-1820, 2005.
- Sözen, A., Akçayol, M.A., Modelling (Using Artificial Neural-Networks) the Performance Parameters of a Solar-Driven Ejector-Absorption Cycle, *Applied Energy*, 79(3): 309-325, 2004.
- Suryani, E., Chou, S-Y, Chen, C-H., Air passenger demand forecasting and passenger terminal capacity expansion: A system Dynamics framework, *Expert Systems with Applications*, 37, 2324-2339, 2010.
- Şen, Z., *Yapay Sinir Ağları İlkeleri*. İstanbul: Su Vakfı Yayınları, 2004.
- Tsai, T-H., Lee, C-K., Wei, C-H., Design of dynamic neural networks to forecast short term railway passenger demand, *Journal of Eastern Asia Society for Transportation Studies*, 6, 1651-1666, 2005.
- Tsai, T-H., Lee, C-K., Wei, C-H., Neural network based temporal feature models for short-term railway passenger demand forecasting, *Expert Systems with Applications*, 36(2), 3728-3736, 2009.
- Wadud, Z., Modeling and forecasting passenger demand for a new domestic airport with limited data, 2214(2214), 59-68, 2011.
- Zhao, S. Mi, X., A novel Hybrid model for short-term high-speed railway passenger demand forecasting, *IEEE Access*, 7, 175681-175692, 2019.