





# Düzce Üniversitesi Bilim ve Teknoloji Dergisi

*Araştırma Makalesi*

## Türkiye Demiryolu Yolcu Taşıma Talebinin Tahmini

 Fatma ÇAKIR <sup>a,\*</sup>,  Hümeysra BOLAKAR TOSUN <sup>b</sup>

<sup>a</sup> İnşaat Mühendisliği Bölümü, Mühendislik Fakültesi, Aksaray Üniversitesi, Aksaray, TÜRKİYE

<sup>b</sup> İnşaat Mühendisliği Bölümü, Mühendislik Fakültesi, Aksaray Üniversitesi, Aksaray, TÜRKİYE

\* Sorumlu yazarın e-posta adresi: [fatoskerse@gmail.com](mailto:fatoskerse@gmail.com)

DOI : 10.29130/dubited.769092

### ÖZET

Günümüzde yolcu taşımacılığında demiryollarının payı giderek artmaktadır. Yolcu talebinin karşılanması için uygun planlamaların belirlenmesi gereklidir. Kapasiteyi karşılayacak planlamaların oluşturulması hem talebi karşılayacak hem de yatırımlarda uygun kararların alınmasını sağlayacaktır. Bu çalışmada, demiryolu yolcu taşımacılığı üzerinde etkili olan değişkenler kullanılarak demiryolu yolcu sayısının tahmin edilmesi amaçlanmıştır. Yolcu talebinin belirlenmesi için Çok Değişkenli Regresyon (ÇDR) analizi ve Yapay Sinir Ağları (YSA) ile iki farklı model oluşturulmuştur. İki model içinde tahmin değerleri belirlenmiştir. Hata kareleri ortalaması (MSE) ve belirleme katsayısı ( $R^2$ ), performans kriterlerini, dikkate alarak en uygun tahmin YSA ile elde edilmiştir. Talep tahmininde YSA kaynak olarak kullanılabilmesi görüşüne varılmıştır.

**Anahtar Kelimeler:** Demiryolu yolcu taşıma, YSA, ÇDR, MSE,

## Forecasting of Turkey Railway Passenger Transport Demand

### ABSTRACT

Today, the share of railways in passenger transportation is increasing. Appropriate planning is required to meet passenger demand. The creation of plans to meet the capacity will both meet the demand and ensure that appropriate decisions are made in investments. In the study, it's aimed to estimate the number of rail passenger using variables that affect rail passenger transport. Two different models were created with Multivariate Regression (MR) analysis and Artificial Neural Networks (ANN) to determine passenger demand. Estimation values were determined in two models. Taking the mean of error squares (MSE) and coefficient of determination ( $R^2$ ), performance criteria, the most appropriate estimate was obtained with ANN: It's concluded that ANN can be used as a resource in demand forecasting.

**Keywords:** Railway passenger demand, ANN, MR, MSE

# I. GİRİŞ

Yolcu talep tahminini, ulařtırma sistemlerinin dzenli alıřması, iřletme planlaması, yolcu yoęunluęunun yonetilmesi ve gelir yonetiminin kontrol altında tutulmasını saęlamaktadır [1]. Demiryolu yolcu tařımacılıęında daha iyi hizmet sunmak iin hat planlama ve zamanlamanın tahmin edilmesi, yolcuların seyahat seme olutlerinin belirlenmesi ve uygun yolcu akıřını verecek modeller oluřturulmalıdır [2].

Talep tahmininin amacı belirlenen bir zaman diliminde oluřacak talebin, temsili olarak, gereęe yakın deęerlerin elde edilmesidir. Gncel veriler dāhilinde hata analizlerinden faydalanarak en az sapma yapan modellerin oluřturulması, gereki ve uygun sonulara ulařmayı etkilemektedir [3,6]. Talep tahmininde etkili olan deęiřkenlerin belirlenmesi ve bu deęiřkenlerin etkilerinin olulmesinde yapay zeka uygulamaları, nitel ve nicel yontemler kullanılmaktadır [6,4].

Wardman [5] alıřmasında, yolcu talebi zerinde etkili olan dıř etkenler, GSYH, ara sahiplilięi, yolculuk sresi, yakıt maliyetleri, nfus ve hatlar zerindeki zelleřtirmelerin talebi etkiledięini belirtmiřtir. Topuz [7] alıřmasında, toplu tařıma sistemlerini kullanan yolcuların yolculuk taleplerini belirlemek iin gnlk yolculuk sayılarını baz alarak yapay sinir aęları modellemeler oluřturmuř ve deęiřkenlerin %80'ini eęitim, %20'sini test ařamasında kullanmıřtır. Bu modellerden en iyi sonuların tarihlendirilmiř verileri kullanarak ileri beslemeli aę yapısının verdięini belirlemiřtir. Xie vd. [1] alıřmalarında, bir gzergāh zerinde numaralandırdıęı istasyonlara gelen ve ayrılan yolcu sayısına ait gemiř verileri kullanarak kısa vadeli planlamada yapay sinir aęlarından faydalanmıřlardır. nerdikleri DC (Divide and Conquer) yontemi ile kısa vadeli yksek hızlı tren yolcu akıřının tahmininde bařarılı sonular oluřturduęunu belirlemiřlerdir. Bayata vd. [8] alıřmalarında, yolcuların tercih, tutum ve memnuniyetlerine gre seyahat sıklıęı talebinin belirlenmesinde Yapay Sinir Aęları (YSA), ok Deęiřkenli Regresyon (DR) ve Bulanık Mantık (BM) yontemlerini kullanarak elde ettikleri sonuları kıyaslamıřlardır. YSA ve DR ile analizde ankete verilen cevapların tahmin edilmesinde yapay sinir aęlarının daha iyi sonular oluřturduęunu belirlemiřlerdir. Gallo vd. [9] yaptıkları alıřmada, Napoli metro hattının yolcu akıřını tahmin etmek iin hat zerindeki kapasitenin belirlenmesinde yapay sinir aęlarının performansının olumlu sonular oluřturduęu belirlemiřlerdir.

## II. MATERYAL VE YONTEM

### **A. REGRESYON ANALİZİ**

Regresyon analizi, iki ya da daha fazla baęımsız deęiřken kombinasyonunun etkilerini deęerlendirerek baęımlı deęiřkenin alacaęı deęerlerin belirlenmesini saęlar. Regresyon analizinde ncelikli olarak aęırlık ya da katsayılar belirlenir. Modellemede tanımlanan baęımsız deęiřkenler baęımlı deęiřken deęerlerine daha yakın sonular elde etmeye ve deęiřkenlerin nemlerini belirlemeye yardımcı olur [10].

Korelasyon analizinde baęımlı deęiřken zerindeki etkili olan baęımsız deęiřkenlerin iliřkisi incelenir. Baęımsız deęiřkenlere ait deęerler artarken baęımlı deęiřken deęerleri azalıyorsa korelasyon negatif deęerler alır. Baęımlı deęiřken artarken baęımlı deęiřken de artıyorsa deęiřkenler arasında pozitif iliřkiyi ifade eder. Deęer 1'e yaklařtıķa iliřki gclenir, -1'e yaklařtıķa iliřki zayıflar. Hatanın belirlenmesinde tahmin ve gerek deęerler arasındaki fark hatanın kareleri toplamının en kk deęeri alacaęı en kk kareler yontemi kullanılarak yeni bir doęrunun oluřturulması ile belirlenir. Oluřturulan bu doęru tm dřey tahmin hatalarının sıfır olduęunu ve hata karelerinin toplamının en kk deęeri alacak biimde oluřturulduęunu ifade eder. Eęer deęiřkenlere ait deęerler uygun aralıklar iinde kalacak bir doęrunun oluřturulması iin uygun deęilse eęri uydurma yontemi ile hata karelerinin toplamının minimum aralıkta kalacaęı bir doęru oluřturulabilir [11].

## B. YAPAY SİNİR AĞLARI

İnsan beyni fonksiyonlarının bilgisayarlara uyarlanmasıyla elde edilen YSA biyolojik sinir sistemlerinin davranışlarını makinalar üzerinde gerçekleştirir. Ağın temel elemanlarını girdi, toplam fonksiyonu, aktivasyon fonksiyonu ve çıktı oluşturmaktadır. Sinir hücrelerinden meydana gelen YSA nöronlar arasındaki bağlantılarla sinyaller ileterek girdi katmanından aldığı bilgileri işleyip çıktı katmanına iletir. Öğrenme, ilişkilendirme ve özellik belirleme gibi yöntemlerden faydalanarak değişkenlerden tahmin yapma, sınıflandırma, modelleme gibi farklı amaçlar için kullanılmaktadır [12,13].

Günlük olayların çoğu doğrusal olmayan bir ilişki ile gerçekleşmektedir. Doğrusal olmayan modellerin çözülmesi için çok katmanlı ve ileri beslemeli ağlar geliştirilmiştir [12]. İleri beslemeli ağlarda girdi katmanından alınan bilgi akışı daima tek doğrultuda çıktı katmanına doğru ilerler. Toplanan bilginin ağa ilk sunulduğu yer girdi katmanıdır. Bağlantılar yoluyla ara katmana gelen bilgiyi karıştırır ve değişkenlerin yeni özelliklerini belirler. Çıktı katmanı tahminleri oluşturur ve hatayı yayar [14-15,1].

İleri beslemeli geri yayımlı öğrenmede girdi, gizli ve çıktı katman arasındaki bağlantı ağırlıklarına hatanın dağıtılması ile hata karelerinin uygun değerler almasında yardımcı olur [6]. Gerçek değerler ( $y(k)$ ) ve ağ işlemlerinden sonra elde edilen çıktı değerleri ( $o(k)$ ) arasındaki fark hata değerini oluşturur [16].

$$e(k) = y(k) - o(k) \quad (1)$$

Ağın eğitilmesi, uygun ağırlık değerlerinin belirlenmesi ve doğruluğunu etkiler. Ağ eğitilmesindeki amaç bağımlı değişken değerinin gerçek değerlere en yakın değerlerin elde edilmesidir. Hata değerini minimum değerlere sahip olması için ağ içinde işleme devam edilir. Ancak ağ uzun süre eğitime devam ederse genelleme özelliğini kaybeder [17].

İleri beslemeli yapay sinir ağlarının eğitilmesinde kullanılan en etkili yöntem olan Levenberg-Marquardt yöntemidir. Levenberg-Marquardt algoritması minimum ortalama hata karelerini hesaplamak için kullanılmaktadır [18]. Newton algoritmasının performans indeksinin ikinci türevi ile oluşturulan Levenberg Marquardt, Jacobian tarafından Hessian matrisine yaklaşır. Ağ performansı hata kareleri toplamı (MSE) ile belirlenir [19]. MSE denklemi, Eş. 2'de verilmiştir.

$$MSE = \frac{1}{N} \sum_{i=1}^n (A_i - F_i)^2 \quad (2)$$

Levenberg Marquardt algoritmasının performans indeksinin optimizasyonu; [16,18]

$$x_{k+1} = x_k - A_k^{-1} g_k \quad (3)$$

Burada  $A_k$  ve  $g_k$ :

$$A_k = \nabla^2 F(x)|_{x=x_k} \quad (4)$$

$$g_k = \nabla F(x)|_{x=x_k} \quad (5)$$

Eş. (4), (5), (6)'da  $x$  değişkeni ağın ağırlıklarını,  $\nabla^2 F(x)$  Hessian matrisini,  $\nabla F(x)$  eğimi,  $F(x)$  hata kareleri toplamını ifade etmektedir. Ağın eğitiminde ağın öğrenmesi için başlangıçta ağırlıklar değerleri küçük ve rastgele seçilir. Hata değeri minimum olana kadar  $x$  ağırlık değerleri değiştirilerek uygun ağ modellemesi oluşturulur. İşlem devamındaki bilginin detayları Daniel et al. [18] çalışmasından ulaşılabilir.

### **III. BULGULAR VE TARTIŞMA**

#### **A. DEMİRYOLU YOLCU TAŞIMA TALEBİNE AİT BULGULAR**

Demiryolu yolcu talebini etkileyen ana faktör GSYH olduğu gibi ayrıca araç sahipliği, nüfus, yakıt maliyetleri ve araba ile yolculuk süreleri gibi faktörlerde etkilidir [5]. Çalışma da demiryolu yolcu taşımacılığında etkili faktörler Statistica 12.0 paket programı kullanılarak regresyon analizi ve YSA ile iki farklı şekilde modellenmiştir. Değişkenler 1998-2018 zaman aralığındaki veriler kullanılarak oluşturulmuştur. Veriler TÜİK, KGM, TCDD resmi sitelerinden temin edilmiştir. Performans kriteri olarak determinasyon katsayısı ve hata kareleri ortalamasından faydalanılmıştır. Verilerin ve elde edilen değerlerin yorumlanması için değişkenlerin anlamlılık testi ve genel model anlamlılığı F testi %5 önem aralığında tutularak modellenmiştir.

Bağımlı değişkeni, Demiryolu Yolcu Sayısı (DYS); bağımsız değişken olarak kişi başına düşen Gayri Safi Yurtiçi Hasıla (GSYH), Nüfus (N), Karayolu Yolcu Sayısı (KYS), Otomobil Sayısı (OS), Motorlu Taşıt Sayısı (KMTS), Demiryolu Hat Uzunluğu (DHU), Demiryolu Yolcu Vagon Sayısı (DYVS), Demiryolu Yolcu Vagon Kapasitesi (DYVK), Demiryolu Yolcu Taşıma Giderleri (DYTG) oluşturmaktadır. Model verileri Çizelge 7.'den incelenebilir.

#### **B. ÇOKLU REGRESYON ANALİZİ**

Çoklu regresyon analizinin amacı bağımsız değişkenlerdeki değişimin bağımlı değişken üzerindeki etkisini açıklamak ve tahmin etmektir. Açıklama ve tahmin ayrı ayrı çözümler için kullanıldığı gibi aynı problemde ikisi de uygulanabilir. Esnek ve uyarlanabilir olduğu içinde neredeyse bütün bağımlı değişken ile ilgili işlemlerde kullanılır [20].

Korelasyon analizinde bağımlı değişken üzerinde etkili olan bağımsız değişkenlerin ilişkisi [-1, 1] aralığın da değerler alır. Değişkenler arasındaki ilişki 1'e yaklaştıkça ilişki güçlenir, -1'e yaklaştıkça zayıflar. Buna bağlı olarak korelasyon katsayısı 0,968 olarak hesaplanmış olup değişkenler arasında ilişki güçlüdür. Tablo 1.'de korelasyon analizi tablosuna göre demiryolu yolcu vagon sayısı hariç diğer değişkenler ile bağımlı değişken arasında pozitif bir ilişki mevcuttur.

*Tablo 1. Korelasyon analizi*

	GSYH	N	KYS	KMTS	OS	DHU	DYVS	DYVK	DYTG	DYS
GSYH	1,00									
N	0,97	1,00								
KYS	0,92	0,89	1,00							
MTS	0,98	0,99	0,92	1,00						
OS	0,99	0,98	0,93	0,99	1,00					
DHU	0,93	0,94	0,9	0,95	0,95	1,00				
DYVS	0,22	0,39	0,16	0,34	0,29	0,21	1,00			
DYVK	0,9	0,92	0,84	0,92	0,93	0,95	0,20	1,00		
DYTG	0,89	0,96	0,8	0,95	0,93	0,89	0,51	0,89	1,00	
DYS	0,84	0,76	0,79	0,8	0,82	0,87	-0,09	0,8	0,67	1,00

Regresyon analizi sonucunda sadece nüfus ve demiryolu hat uzunluğu değişkenlerinin bağımlı değişken üzerinde daha önemli olduğu ve bazı değişken değerlerinin pozitif olması gerekirken negatif değerler aldığı belirlenmiştir. Regresyon analizi sonucu Tablo 2'de belirtilmiştir. Regresyon analizinin t testi, kritik t değerinden ve genel anlamlılık değerinin F kritik büyük olması  $H_0$  yani sıfır hipotezini reddetmekte ve anlamlı bir ilişkinin var olduğunu bildirmektedir. Genel anlamlılığın belirlenmesi için varyans analizi kullanılmaktadır [21].

**Tablo 2.** Çoklu doğrusal regresyon analizi sonuçları

N=21	b*	Std. hata b*	B	Std. hata b	t-değeri	p-değeri
<b>Sabitler</b>			21498,99	13318,25	1,61425	0,134768
<b>GSYH</b>	1,675	1,292	0,16	0,13	1,296	0,221
<b>N</b>	-2,680	1,111	-0,59	0,24	-2,411	0,0035
<b>KYS</b>	-0,252	0,252	-0,01	0,01	-0,998	0,339
<b>KMTS</b>	-1,136	1,882	-0,00	-0,00	-0,604	0,558
<b>OS</b>	1,934	2,677	0,00	0,00	0,722	0,485
<b>DHU</b>	1,201	0,325	2,24	0,61	3,692	0,0035
<b>DYVS</b>	0,098	0,171	2,83	4,94	0,572	0,578
<b>DYVK</b>	-0,185	0,39	-0,01	0,02	-0,474	0,645
<b>DYTG</b>	0,266	0,477	0,00	0,00	0,558	0,587


(b\*: Standardize edilmemiş beta, B: standardize edilmiş beta)

**Tablo 3.** Varyans analizi


	Kareler Top.	Serbestlik D.	Ort. Kareler	F	p-değeri
<b>Regresyon</b>	27964235	9	3107137	18,11109	0,000023
<b>Hatalar</b>	1887159	11	1715560		
<b>Toplam</b>	29851394				

Değişkenlerin t testi değeri 1,614 olarak belirlenmiştir. Kritik t değeri t tablosundan  $t_{\alpha,(n-2)}$  kuralıyla 1,729 değeri bulunmuştur. Ancak tablo değeri t testi değerinden büyüktür. Bunun için genel anlamlılık değeri incelenmiştir. F tablosundan önem düzeyi 0,05 olan F kritik değeri 3,11 olarak bulunmuştur. F hesap değeri (18,11) kritik değerden büyük olduğu için de sıfır hipotezi reddedilmiş ve modelin anlamlı olduğu kanıtlanmıştır.

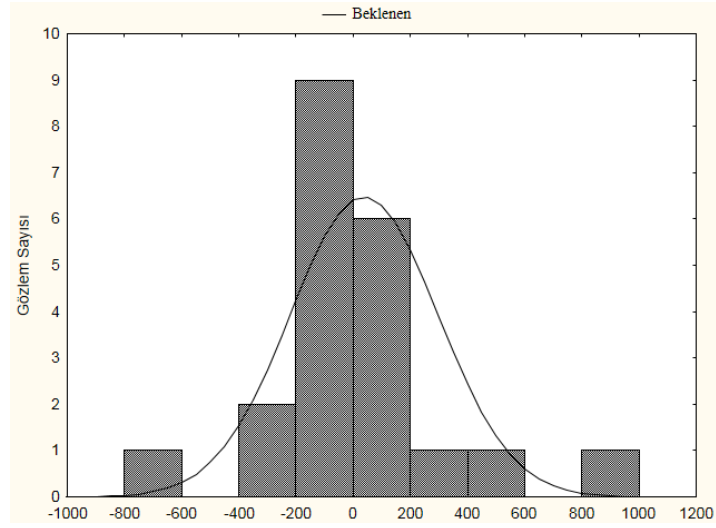
Regresyon analizi sonucunda elde edilen grafikler ile de değişkenler arasındaki bağıntılar kolay biçimde yorumlanabilir. Tahmin değerleri ile gerçek değerlerin ve hata dağılımlarının sıfır çizgisine yakın olduğu, hata histogramında iki ucu kapalı ve simetrik bir dağılım göstermektedir.




**Şekil 1.** ÇDR tahmin ve gerçek değerler arasındaki bağlantı



Şekil 2. ÇDR hata-tahmin dağılımı



Şekil 3. ÇDR hata histogramı



Şekil 4. ÇDR Hata normal olasılığı

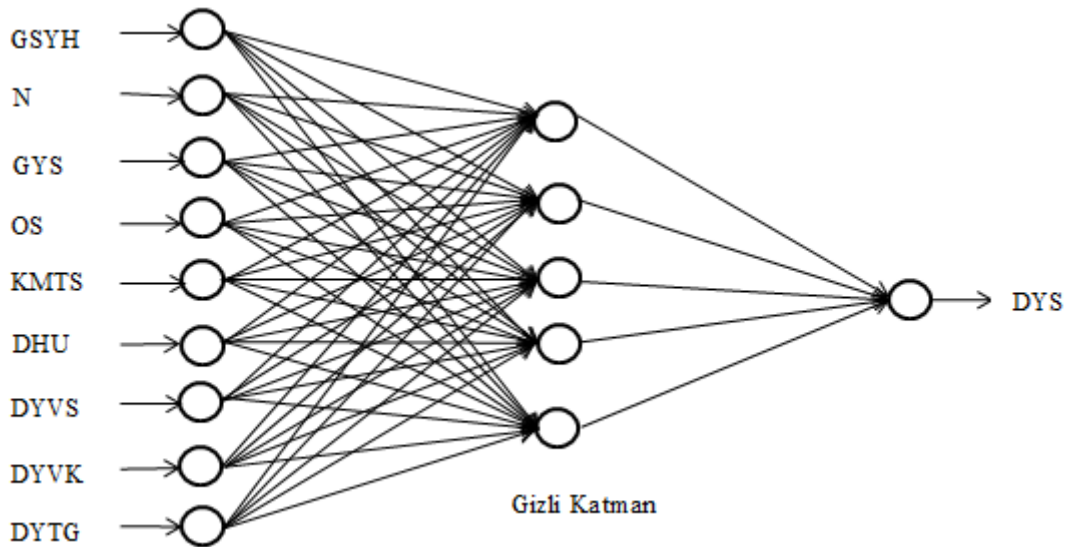
### C. YAPAY SİNİR AĞLARI

Yapay sinir ağlarının tercih edilmesinde ki asıl sebep daha önceki çalışmalardan da yola çıkarak analiz sonucunda tutarlı gerçeğe daha yakın değerler oluşturmalarıdır. Yapay sinir ağlarıyla analizde ağın başlangıçta eğitilmesi deneme-yanılma yoluyla belirlenerek istenilen çıktıya ait uygun koşulu sağlayana kadar ağırlık değerleri değiştirilerek model tespit edilmeye çalışılır [12].

Çalışmada, hata değerlerini ağırlıklara yayarak işlem yaptığı için ileri beslemeli geri yayılmalı ağ yapısı kullanılmıştır. Girdi katmanında 9 bağımsız değişken ve bu değişkenlerin etkilediği 1 bağımlı değişken bulunmaktadır. Değişkenlerin %80 eğitim, %20 test için Levenberg- Marquardt algoritması kullanılarak 1000 iterasyonla eğitilmiştir. Ağda gizli katmanda hiperbolik tanjant çıktı katmanında log-sigma aktivasyon fonksiyonu kullanılmıştır. Ağ eğitildikten sonra uygun ağ yapısının 5 nöronlu gizli katmandan oluştuğu belirlenmiştir. Hiperbolik tanjant ve sigmoid denklemleri [12] sırasıyla Eş. 6 ve 7’de verilmiştir.

$$F(\text{Net}) = \left( \frac{e^{\text{Net}} + e^{-\text{Net}}}{e^{\text{Net}} - e^{-\text{Net}}} \right) \quad (6)$$

$$F(\text{Net}) = \frac{1}{1 + e^{-\text{Net}}} \quad (7)$$



Şekil 5. Modelin yapay sinir ağı mimarisi

Modelin genel denklemi:

$$DYS = f_2 [w_2] f_1 \left\{ w_1 \begin{bmatrix} GSYH \\ N \\ KYS \\ KMTS \\ OS \\ DHU \\ DYVS \\ DYVK \\ DYTG \end{bmatrix} + [b_1] \right\} + [b_2] \quad (8)$$

Ağırlık ve bias değerleri Tablo 4.’de verilmiştir.


**Tablo 4.** Ağırlık ve bias değerleri

	2.1	2.2	2.3	2.4	2.5	3.1
<b>Bias</b>			b1			b2
	3,3799	6,5265	-5,9584	-7,0501	-3,5902	2,5046
<b>Ağırlıklar</b>			w1			w2
<b>1.1</b>	-3,0549	-7,5441	-2,7439	7,1031	-3,7086	
<b>1.2</b>	-2,8612	-1,989	-3,1354	-1,9574	3,8157	
<b>1.3</b>	-2,2259	18,0586	-2,8815	-5,3261	-0,5144	
<b>1.4</b>	-3,0234	-4,2367	-3,2471	2,2257	-0,6555	
<b>1.5</b>	-3,1253	-4,7918	-3,1277	3,8394	-2,4799	
<b>1.6</b>	-4,4021	-11,31	-4,7547	2,9535	0,2609	
<b>1.7</b>	1,3429	6,964	-4,019	4,9553	0,9279	
<b>1.8</b>	-2,9446	8,1304	-1,7576	-3,7249	1,5453	
<b>1.9</b>	-2,8045	-0,5274	-3,2545	1,6393	2,5413	
<b>2.1</b>						2,9522
<b>2.2</b>						-10,3417
<b>2.3</b>						-3,2518
<b>2.4</b>						5,2848
<b>2.5</b>						-6,059

Ağın girdi katmanını oluşturan değişkenlerin bağımlı değişken üzerindeki etkisi duyarlılık analizi ile belirlenmiştir. Duyarlılık analizi sonucunda en önemli değişkenin gayrisafi yurtiçi hasıla olduğu tespit edilmiştir. Diğer değişkenlerin de önem derecesi sırayla karayolu yolcu sayısı, nüfus, motorlu taşıt sayısı, demiryolu yolcu vagon sayısı, otomobil sayısı, demiryolu hat uzunluğu, demiryolu yolcu vagon kapasitesi ve demiryolu yolcu taşıma giderleri olarak belirlenmiştir.


**Tablo 5.** Duyarlılık analizi

	GSYH	N	KYS	KMTS	OS	DHU	DYVS	DYVK	DYTG
<b>Oran</b>	208,88	178,66	175,71	129,58	49,63	46,90	46,85	33,88	24,49
<b>Derece</b>	1	2	3	4	5	6	7	8	9




**Şekil 6.** YSA tahmin ve gerçek değerler arasındaki bağlantı






Şekil 7. YSA hata histogramı



Şekil 8. YSA hata dağılımı



Şekil 9. Hata olasılığı

YSA ait hata dağılımının sıfır çizgisi üzerine yakın, hata histogramının sola doğru açık olduğu görülmüştür. Ancak sıfır hata frekansının yüksek ve tahmin değerlerinin uyumlu sonuçlar oluşturduğu belirlenmiştir.

*Tablo 6. ÇDR ve YSA tahmin değerleri*

Yıllar	Gözlem Değerleri	Tahmin (ÇDR)	Tahmin (YSA)
1998	6161	6288,886	6222,649
1999	6146	6187,531	6211,235
2000	5833	5663,119	5815,466
2001	5568	5497,821	5604,949
2002	5204	5338,458	5285,887
2003	5878	5455,364	5555,863
2004	5237	5489,750	5244,929
2005	5036	5223,142	5142,698
2006	5277	5251,882	5137,734
2007	5553	5448,3541	5237,726
2008	5097	5130,449	5109,968
2009	5374	5380,101	5452,331
2010	5491	6258,757	5507,757
2011	7300	6455,157	7298,056
2012	6612	6400,106	6741,509
2013	6225	6558,769	6258,591
2014	7401	7429,261	7351,248
2015	8326	8278,461	8385,498
2016	7829	7858,814	7781,125
2017	8465	8274,562	8539,276
2018	8938	9092,175	8766,929

İki modellemeye ait kıyaslamanın yapılabilmesi için hata kareleri ortalaması MSE ve belirleme katsayısı kullanılmıştır. Regresyon ve yapay sinir ağlarına ait hata kareleri toplamı ve belirleme katsayısı değerleri incelendiğinde modelin açıklanması için oldukça yeterlidir. Bağımlı değişkenin gerçek değerleri ile tahmin değerleri arasındaki hata değerleri düşük değerli ve model performansı iyi bir değere sahiptir. Ancak modelde yapay sinir ağlarının performansı, bağımlı değişkeni açıklama oranı ve hata kareleri ortalaması, regresyon analizine göre daha iyi performans gösterdiği açık bir şekilde görülmektedir.

*Tablo 6. Model kıyaslama*

Model	R <sup>2</sup> (%)	MSE
Regresyon	93,7	199,727
YSA	98,9	87,149

**Tablo 7. Analiz verileri**

Yıllar	GSYH	N	GYS	OS	KMTS	DHU	DYVS	DYVK	DYTG	DYS
1998	1151	63391	186159	3838288	116	8607	1046	96534	69505	6161
1999	1697	64337	175236	4072326	120	8682	1040	94461	113437	6146
2000	2656	65293	185681	4422180	129	8671	1038	121049	176457	5833
2001	3766	66249	168211	4534803	130	8671	1031	119652	278520	5568
2002	5445	67205	163327	4600140	130	8671	1013	115591	388287	5204
2003	7007	68161	164311	4700343	133	8697	1102	111372	444806	5878
2004	8536	69117	174312	5400440	151	8697	1129	112094	539658	5237
2005	9844	70063	182152	5772745	162	8697	1131	111375	570470	5036
2006	11389	70500	187593	6140992	175	8697	1123	108199	618934	5277
2007	12550	70586	209115	6472156	184	8697	1137	108330	702571	5553
2008	14001	71517	206098	6796629	192	8699	1122	118824	729204	5097
2009	13870	72561	212464	7093964	197	9080	1132	122203	823217	5374
2010	15860	73722	226913	7544871	205	9594	1131	136552	835343	5491
2011	18788	74724	242265	8113111	215	9642	1134	137860	926599	7300
2012	20880	75627	258874	8648875	225	9642	1125	138769	1004647	6612
2013	23766	76667	268178	9283923	234	9718	1135	159171	1076685	6225
2014	26489	77696	276073	9857915	242	10087	1125	165864	1197772	7401
2015	29899	78741	290734	10589337	254	10131	1124	167765	1360063	8326
2016	32904	79815	300852	11317998	264	10131	1089	170105	1436476	7829
2017	38732	80811	314734	12035978	275	10207	1080	172015	1068884	8465
2018	45750	82004	329363	12398190	279	10315	1047	158650	1144294	8938

## **IV. SONUÇ**

Çalışma da demiryolu yolu taşıma talebine ait değerler üzerinde etkili olduğu tespit edilen demiryolu hat uzunluğu, nüfus, gayrisafi yurtiçi hasıla, karayolu yolcu taşımacılığında kullanılan motorlu taşıt sayısı, otomobil sayısı, demiryolu yolcu taşımada kullanılan vagon sayısı ve kapasitesi, demiryolu yolcu taşıma giderleri ve karayolu yolcu sayısından oluşan bağımsız değişkenlerden oluşmaktadır. Analiz için çok değişkenli regresyon analizi ve yapay sinir ağlarından faydalanılmıştır. İki model içinde performans kriteri olarak hata kareleri ortalaması (MSE) kullanılmıştır.

Analiz sonucunda;

1. Regresyon analizinde nüfus ve demiryolu hat uzunluğu değişkenlerinin bağımlı değişken üzerindeki ilişkilerinin anlamlı olduğu, bazı değişkenlerin pozitif değerler alması beklenirken negatif değerler aldığı belirlenmiştir.
2. Regresyon analizi belirleme katsayısı ( $R^2$ ) ve korelasyon katsayısı değerleri sırasıyla %93,7 ve %96,8'dir. Bu durumdan da regresyon analizinin modeli açıklamada yeterli olduğu görülmektedir.
3. Değişkenler arasında demiryolu yolcu vagon sayısı hariç pozitif bir mevcuttur. Demiryolu yolcu vagon sayısının belirlenen yıllar içinde veri değerlerinde azalmalardan kaynaklı negatif bir ilişki olduğu düşünülmektedir.
4. Analizde hesaplanan t testi değeri tablo değerinden küçüktür. Bu yüzden F testi de -genel anlamlılık- incelenmiştir.
5. F testi %95 güven aralığında test edildiğinde, hesaplanan F değeri kritik F tablo değerinden büyük olduğu belirlenmiştir. Böylece sıfır hipotezi reddedilmiş ve modelin anlamlı olduğu kanıtlanmıştır.

6. Regresyon analizinde elde edilen tahmin değerlerinde gerçek değere yakın değerlerin olduğu ve hata kareleri ortalaması (MSE) 199,727 olarak belirlenmiştir.
7. Duyarlılık analizi sonucunda bağımlı değişken üzerinde etkili olan en önemli değişkenin Wardman'ın [5], çalışmasında belirttiği gibi gayrisafi yurtiçi hasıla olduğu görülmüştür. Diğer değişkenler de önem derecesine göre sırasıyla karayolu yolcu sayısı, nüfus, motorlu taşıt sayısı, demiryolu yolcu vagon sayısı, otomobil sayısı, demiryolu hat uzunluğu, demiryolu yolcu vagon kapasitesi ve demiryolu yolcu taşıma giderleri olduğu gözlemlenmiştir.
8. Modellere ait hata dağılımının her iki analiz içinde sıfır çizgisi üzerine yakın olduğu, hata histogramının regresyon analizinde sağ ve sol yönünde açık olmadığı, yapay sinir ağlarında ise sola doğru açık olduğu görülmüştür. Ancak sıfır hata frekansının yüksek olduğu ve tahmin değerlerinin uyumlu sonuçlar oluşturduğu belirlenmiştir.
9. YSA ile oluşturulan tahmin değerlerine ait hata kareleri ortalaması 87,149 olarak hesaplanmıştır.
10. İki modelde performans kriterlerine ait değerler kıyaslandığında yapay sinir ağlarının belirleme katsayısı değeri daha yüksek ve hata kareleri ortalamasının daha düşük değerlere sahip olduğu belirlenmiştir.

Yapay sinir ağlarının hatayı yayararak minimum seviyede tutması ve doğrusal olmayan problemlerin çözümündeki performansına dayanarak bağımsız değişkenlerin bağımlı değişkeni açıklamada daha iyi olduğu ve gerçek değerlere yakın değerleri elde etmede daha iyi sonuçlar oluşturduğu görülmüştür. Böylece demiryolu yolcu planlamada gerçeği yansıtan değerler elde ettiği için kaynak olarak kullanılması önerilmektedir.

## **V. KAYNAKLAR**

- [1] M. Xie, X. Li, W. Zhou and Y. Fu., "Forecasting the Short-Term Passenger Flow on High Speed Railway with Neural Networks," *Computational Intelligence and Neuroscience*, c. 2014, ss. 1-8, 2014.
- [2] G. Hu, W. Liu, and H. Yang, "A reliability-based Assignment Method for Railway Networks with Heterogeneous Passenger," *Transportation Research Part C: Emerging Technologies*, c. 93, ss. 501-524, 2018.
- [3] M. Karahan, "İstatistiksel Tahmin Yöntemleri: Yapay Sinir Ağları Metodu ile Ürün Talep Tahmini Uygulaması," Doktora Tezi, Selçuk Üniversitesi, 2011.
- [4] B. Kobu, *Üretim Yönetimi*, 17. Baskı, İstanbul, 2014.
- [5] M. R. Wardman, "Demand for Rail Travel and The Effects of External Factors," *Transportation Research Part E: Logistics and Transportation Review*, c. 42, s. 3, ss. 129-148, 2006.
- [6] S. P. Yalçın, "Talep Yönetimi, Dağıtımı ve Tedarik Zinciri Performansı Yönetim Uygulamalarının Tedarik Zinciri Performansı Üzerindeki Etkileri," Yüksek Lisans Tezi, Başkent Üniversitesi, 2013.
- [7] S. Topuz, "İstanbul İlindeki Toplu Taşıma Yolculuk Taleplerinin Yapay Sinir Ağlarıyla Modellenmesi," Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi, 2008.

- [8] H. F. Bayata, H. N. Saęlamyürek ve O. Ü. Bayrak, “Demiryolu Yolcularının Tutum ve Davranışlarının Farklı İstatistiksel Yöntemler ile Modellenmesi,” *Iğdır Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, c. 8, s. 2, ss. 141-151, 2018.
- [9] M. Gallo, G.D. Luca, L. D’acierno and M. Botte, “Artificial Neural Networks for Forecasting Passenger Flows on Metro Lines,” *Sensors*, c. 19, s. 15, ss. 1-14, 2019.
- [10] T.J. Archdeacon, *Correlation and regression analysis: a historian’s guide*, 1. Edition, America, 1994.
- [11] S. Üreten, *Üretim/İşlemler Yönetimi*, 5. Baskı, Gazi Kitabevi, Ankara, 2006.
- [12] E. Öztemel, *Yapay Sinir Ağları*, 1. Baskı, Papatya Yayıncılık, İstanbul, 2003.
- [13] Ç. Elmas, *Yapay Zeka Uygulamaları*, 1. Baskı, Seçkin Yayıncılık, Ankara, 2007.
- [14] T. Tsai, C. Lee and C. Wei, “Neural Network Based Temporal Feature Models for Short-Term Railway Passenger Demand Forecasting,” *Expert Systems with Applications*, c. 36, ss. 3728-3736, 2009.
- [15] M. Dougherty, “A Review of Neural Networks Applied to Transport,” *Transportation Research Part C: Emerging Technologies*, c. 3, s. 4, ss. 247-260, 1995.
- [16] M. Yaşar, “Günlük Akışlardaki Boşlukların Yapay Sinir Ağları Kullanılarak Tamamlanması,” Yüksek Lisans Tezi, Pamukkale Üniversitesi, 2004.
- [17] S. Agatonovic-Kustrin and R. Beresford, “Basic Concept of Artificial Neural Network Modeling and Its Application in Pharmaceutical Research,” *Journal of Pharmaceutical and Biomedical Analysis*, c. 22, ss. 717-727, 2000.
- [18] L. Daniel, T. K. Chaturvedi and L. M. Kolhe, “Dynamic Economic Load Dispatch Using Levenberg Marquardt Algorithm,” *Energy Procedia*, c. 144, ss. 95-103, 2018.
- [19] S. Mammadli, “Financial Time Series Prediction Using Artificial Neural Network Based on Levenberg- Marquardt Algorithm,” *Procedia Computer Science*, c. 120, ss. 602-607, 2017.
- [20] R. E. Anderson, B. J. Babin, W. C. Black and J. F. Hair Jr., *Multivariate Data Analysis*, 7. Edition, Pearson Prentice Hall, America, 2010.
- [21] S. Yavuz, “Regresyon Analizinde Doğrusala Dönüştürme Yöntemleri ve Bir Uygulama,” *Atatürk Üniversitesi İktisadi ve İdari Bilimler Dergisi*, c. 23, s. 1, ss. 165-179, 2009.