



**T.C.
AKSARAY ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

İNŞAAT MÜHENDİSLİĞİ ANABİLİM DALI

**DEMİRYOLU YOLCU TAŞIMA TALEBİNİN
YAPAY SİNİR AĞLARI İLE TAHMİNİ**

YÜKSEK LİSANS TEZİ

Fatma ÇAKIR

DANIŞMAN

Dr. Öğr. Üyesi Hümeysra BOLAKAR TOSUN

AKSARAY, 2020

Aksaray Üniversitesi, Fen Bilimleri Enstitüsü'nün 182303411 numaralı Yüksek Lisans öğrencisi Fatma ÇAKIR tarafından hazırlanan “**DEMİRYOLU YOLCU TAŞIMA TALEBİNİN YAPAY SİNİR AĞLARI İLE TAHMİNİ**” adlı tez çalışması aşağıdaki jüri tarafından OY BİRLİĞİ ile İnşaat Mühendisliği Anabilim Dalında YÜKSEK LİSANS tezi olarak kabul edilmiştir.

Danışman: Dr. Öğr. Üyesi Hümeysra BOLAKAR TOSUN

Aksaray Üniversitesi

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum.

Üye: Dr. Öğr. Üyesi Salih BEKTAŞ

Aksaray Üniversitesi

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum.

Üye: Doç. Dr. Cahit GÜRER

Afyon Kocatepe Üniversitesi

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum.

Tez Savunma Tarihi: 15/01/2021

Jüri tarafından kabul edilen bu tezin Yüksek Lisans Tezi olması için gerekli şartları yerine getirdiğini onaylıyorum.

.....

Doç. Dr. Mehmet Ali HINIS

Fen Bilimleri Enstitüsü Müdürü

DOĞRULUK BEYANI

Yüksek lisans tezi olarak sunduğum bu çalışmayı, akademik kurallara ve bilimsel etik, ahlak ve geleneklere aykırı düşecek bir yol ve yardıma başvurmaksızın yazdığımı, yararlandığım eserlerin kaynakçada gösterilenlerden oluştuğunu, çalışmamda kullandığım verilerin orijinalliğini ve her türlü intihalden uzak olduğunu beyan ederim.

Enstitü tarafından belli bir zamana bağlı olmaksızın, tezimle ilgili yaptığım bu beyana aykırı bir durumun saptaması durumunda, ortaya çıkacak tüm ahlaki ve hukuki sonuçlara katlanacağımı bildiririm.

Fatma ÇAKIR

TEŞEKKÜR

Yüksek lisans eğitimim boyunca tecrübesini, desteğini ve gerekli olan tüm yönlendirmeleri yaparak çalışmamda yardımcı olan tez danışmanım Sn. Dr. Öğr. Üyesi Hümeysra BOLAKAR TOSUN'a,

Analiz çalışmasında resmi web kaynaklarından elde edemediğim gerekli olan bazı verilerin temin edilmesinde yardımcı olan TCDD çalışanlarına,

Eğitim hayatım boyunca hiçbir desteğini esirgemeyen, daima yanımda olan sevgili aileme ve değerli eşime teşekkürlerimi sunarım.

Fatma ÇAKIR

AKSARAY, 2020

İÇİNDEKİLER

TEŞEKKÜR	i
İÇİNDEKİLER	ii
ÖZET	iv
ABSTRACT	v
ŞEKİLLER DİZİNİ	vi
ÇİZELGELER DİZİNİ	vii
SİMGELER VE KISALTMALAR	viii
1. GİRİŞ	1
2. KAYNAK ÖZETLERİ	3
2.1 Demiryolu Yolcu Taşımacılığının Tarihi	3
2.2 Türkiye Demiryolu Yolcu Taşıma Tarihi	6
2.2.1 Osmanlı demiryolu tarihi	6
2.2.2 Türkiye demiryolu tarihi	7
2.2.3 Türkiye yüksek hızlı demiryolu yolcu taşımacılığı	10
2.2.4 Türkiye konvansiyonel hatlarla yolcu taşımacılığı	14
2.2.4.1 Anahat trenleri	14
2.2.4.2 Bölgesel trenler ile yolcu taşımacılığı	15
2.2.4.3 Uluslararası yolcu taşımacılığı	16
2.2.5 Kent içi demiryolu yolcu taşımacılığı	16
2.2.5.1 Marmaray	17
2.2.5.2 Başkentray	18
2.2.5.3 İzban	18
2.2.5.4 Gaziray	18
2.2.6 Demiryollarının yolcu taşımadaki avantajları ve dezavantajları	19
2.3 Literatür Özeti	21
3. MATERYAL VE YÖNTEM	25
3.1 Talep Tahmini	25
3.1.1 Talep tahmin verilerini belirleme	27
3.1.2 Talep tahmin yöntemleri	29
3.1.3 Talep tahmininde sayısal yöntemler	31
3.1.3.1 Regresyon analizi	32
3.1.3.2 Korelasyon analizi	34
3.1.3.3 Zaman serileri	36
3.1.3.4 Simülasyon yöntemi	39
3.1.4 Talep tahmininde duyarlılık	40

3.1.5 Talep tahmininde yapay sinir ağıları	41
3.2 Yapay Sinir Ağları	42
3.2.1 Yapay sinir ağlarının genel tanımı ve tarihi	42
3.2.2 YSA yapısı	44
3.2.2.1 Biyolojik sinir hücresi ve yapay sinir ağlarının yapısı.....	44
3.2.3 Yapay sinir ağlarının özellikleri.....	49
3.2.4 Yapay sinir ağlarının türleri	50
3.2.5 Yapay sinir ağlarında öğrenme	53
3.2.5.1 Geri yayımlı öğrenme	54
3.2.5.2 Levenberg-Marquardt algoritması	58
3.2.6 Yapay sinir ağlarının eğitilmesi	62
3.2.7 Yapay sinir ağlarının uygulama alanları	62
3.2.8 Yapay sinir ağlarının avantajları ve dezavantajları.....	63
4. ARAŞTIRMA BULGULARI	65
4.1 Model Girdileri.....	65
4.2 Talep Tahmin Analizi	68
4.2.1 Korelasyon analizi.....	68
4.2.2 Çoklu regresyon analizi.....	69
4.2.3 Yapay sinir ağları	72
5. SONUÇ VE ÖNERİLER	80
KAYNAKLAR	82
EKLER	88
Ek A. t Tablosu	89
EK B. F Tablosu (0,05)	90
ÖZGEÇMİŞ	91

YÜKSEK LİSANS TEZİ

DEMİRYOLU YOLCU TAŞIMA TALEBİNİN YAPAY SİNİR AĞLARI İLE TAHMİNİ

Fatma ÇAKIR

Aksaray Üniversitesi
Fen Bilimleri Enstitüsü
İnşaat Mühendisliği Anabilim Dalı

Danışman: Dr. Öğr. Üyesi Hümeysra BOLAKAR TOSUN

ÖZET

Demiryolu yolcu planlamaları ve gerekli noktalara yapılması düşünülen projelerin taşıma oranını belirlemek mali olarak uygun yöntemlerin seçilmesinde etkilidir. Yolcu talebi üzerinde etkili olan faktörlerin göz önünde bulundurularak tahminlerinin oluşturulması doğru tercihlerin ve kararların alınmasında önemli bir etkiye sahiptir.

Bu çalışmada demiryolu yolcu taşıma talebinin belirlenmesi için etkili olan 9 bağımsız değişken ile demiryolu yolcu sayısı regresyon analizi ve yapay sinir ağları ile modellenmiştir. Modellerin performansını değerlendirebilmek için belirleme katsayısı ve hata kareleri ortalaması (MSE) dikkate alınmıştır. Korelasyon analizi ile önce değişkenler arasındaki ilişki incelenmiş ve bağımsız değişkenlerin bağımlı değişkeni açıklama oranı yeterli bulunmuştur. Regresyon analizi sonucunda nüfus ve demiryolu hat uzunluğunun bağımlı değişken üzerinde daha anlamlı olduğu belirlenmiştir.

Yapay sinir ağları ile analizde ağı eğitilmesi için Levenberg-Marquardt algoritması kullanılarak uygun ağ yapısı tespit edilmiştir. Bağımsız değişkenlerin etkisi duyarlılık analizi ile incelenmiş ve en önemli değişkenin GSYH olduğu belirlenmiştir. İki model içinde belirleme katsayıları, modellerin açıklanması için yeterlidir ve MSE düşük değerlere sahiptir. Ancak yapay sinir ağlarının demiryolu yolcu sayısını belirlemede daha iyi performans gösterdiği anlaşılmıştır. Bunun üzerine gerçeğe yakın değerler oluşturduğu için YSA yolcu talebine ait tahminde daha iyi sonuçlar oluşturmaktadır.

Anahtar Kelimeler: Demiryolu Yolcu Taşıma, YSA, Regresyon, MSE, Levenberg-Marquardt.

Temmuz, 2020; 91 sayfa

M.Sc. THESIS

FORECASTING OF RAILWAY PASSENGER TRANSPORT DEMAND WITH ARTIFICIAL NEURAL NETWORK

Fatma ÇAKIR

**Aksaray University
Graduate School of Natural and Applied Sciences
Department of Civil Engineering**

Supervisor: Dr. Öğr. Üyesi Hümeysra BOLAKAR TOSUN

ABSTRACT

Railway passenger planning and determining the transportation rate of the projects that are planned to be made to the required points are effective in choosing financially appropriate methods. Considering the factors affecting the passenger demand, the creation of forecasts has an important effect on making the right choices and decisions.

In the study, 9 independent variables that are effective for determining the demand for railway passengers by regression analysis and artificial neural networks. In order to evaluate the performance of the models, determination coefficient and mean square error (MSE) were taken into consideration. With correlation analysis, the relationship between variables was examined first and the explanation rate of the independent variables for the dependent variables was found to be sufficient. As a result of the regression analysis, it was determined that population and railway line length were more significant on the dependent variable.

The appropriate network structure was determined by using Levenberg-Marquardt algorithm to train the network in analysis with artificial neural network. The effect of independent variables was analyzed with sensitivity analysis and it was determined that the most important variable was GDP. The determination coefficient within the two models is sufficient to explain the models and MSE has low values. However, it has been understood that artificial neural networks perform better in determining the number of rail passengers. Therefore, ANN creates better results in the forecast of passenger demand as it creates realistic values.

Keywords: Rail Passenger Transport, ANN, Regression, MSE, Levenberg-Marquardt.

July, 2020; 91 pages

ŞEKİLLER DİZİNİ

Şekil 2.1. Yalpalı tren yolcu konforu.....	5
Şekil 2.2. Yapımı planlanan, inşaat sürecinde ve işletimdeki YHD ağı.....	11
Şekil 2.3. Türkiye YHT yolcu sayısı.....	12
Şekil 2.4. Anahat tren haritası.....	15
Şekil 2.5. Bölgesel tren haritası.....	15
Şekil 2.6. Uluslararası tren haritası.....	16
Şekil 3.1. Regresyon doğrusu ve en küçük kareler yöntemi.....	33
Şekil 3.2. Korelasyon katsayısı değerleri ve anlamları.....	35
Şekil 3.3. Zaman serilerine göre talep değişimi.....	37
Şekil 3.4. Biyolojik hücre yapısı.....	45
Şekil 3.5. Yapay sinir ağının yapısı.....	46
Şekil 3.6. Yapay sinir ağı hücre yapısı.....	46
Şekil 3.7. Yapay sinir ağlarının türleri.....	50
Şekil 3.8. Geri yayılım algoritması akış diyagramı.....	57
Şekil 4.1. Regresyon analizi tahmin ve gerçek değerler.....	71
Şekil 4.2. Regresyon analizi tahmin değerleri ve dağılımı.....	71
Şekil 4.3. Regresyon analizi hata histogramı.....	72
Şekil 4.4. Regresyon analizi hata normal olasılığı.....	72
Şekil 4.5. Yapay sinir ağı tahmin ve gerçek değerleri.....	76
Şekil 4.6. Yapay sinir ağı tahmin değerleri ve dağılımı.....	76
Şekil 4.7. Yapay sinir ağı hata histogramı.....	77
Şekil 4.8. Yapay sinir ağı hata normal olasılığı.....	77

ÇİZELGELER DİZİNİ

Çizelge 2.1. Karayolu ve demiryolu hat uzunluğu.	8
Çizelge 2.2. Yapım aşamasındaki yüksek hızlı demiryolu hatları.	12
Çizelge 2.3. Projesi onaylanmış yüksek hızlı demiryolları.	13
Çizelge 2.4. Uzun vadede yapımı planlanan yüksek hızlı demiryolları.	13
Çizelge 2.5. Anahat trenleri.	14
Çizelge 3.1. Talep yöntemleri.	31
Çizelge 4.1. Analizde kullanılan veri değerleri.	67
Çizelge 4.2. Korelasyon analizi.	68
Çizelge 4.3. Çoklu doğrusal regresyon analizi sonuçları.	69
Çizelge 4.4. Varyans analizi.	70
Çizelge 4.5. Regresyon analizi gerçek değerler ve tahmin değerleri.	70
Çizelge 4.6. Uygun değerleri oluşturan ağ yapısı.	73
Çizelge 4.7. Duyarlılık analizi.	73
Çizelge 4.8. Ağa ait bias ve ağırlık değerleri.	74
Çizelge 4.9. Yapay sinir ağları gerçek değerler ve tahmin değerleri.	78
Çizelge 4.10. Performans kriterleri.	79

ŞİMGELER VE KISALTMALAR

ÇDR	Çok Değişkenli Regresyon
DHU	Demiryolu Hat Uzunluğu
DYTG	Demiryolu Yolcu Taşıma Giderleri
DYVK	Demiryolu Yolcu Vagon Kapasitesi
DYVS	Demiryolu Yolcu Vagon Sayısı
ESS	Explained Sum of Squares
KGM	Karayolları Genel Müdürlüğü
KMTS	Karayolları Motorlu Taşıt Sayısı
KYS	Karayolları Yolcu Sayısı
MLP	Multi Layer Perceptron
MSE	Mean Squares Error
N	Nüfus
OS	Otomobil Sayısı
r	Korelasyon Katsayısı
R²	Belirleme Katsayısı
RSS	Residual Sum of Squares
TCDD	Türkiye Cumhuriyeti Devlet Demiryolları
TSS	Total Sum of Square
TÜİK	Türkiye İstatistik Kurumu
Yolcu-km	Bir Kilometrede Taşınan Yolcu Sayısı

1. GİRİŞ

Ulaşımın ana ölçütleri erişilebilirlik ve hareketlilik (Evren ve Dünder, 2016). Ulaştırma günlük hayatta hareketliliğin temel unsurlarından biridir. Ayrıca diğer sektörlerle ilişkisinden dolayı ülke ekonomisinin gelişmesine katkı sağlamaktadır. Ulaşım türleri dönem şartlarına bağlı olarak teknolojik ve ekonomik faktörlerin etkisi altında değişimler geçirebilir. Sunulan hizmet kapsamında dönemsel olarak kendi içlerinde popüler hale gelebilir. Yük ve yolcu taşımacılığında karayolu taşımacılığı sunduğu fırsatlardan dolayı daima ön planda tutulmuştur. Kapıdan kapıya ulaşım imkânı sunması Akbulut (2016), her bölgeye erişiminin mevcudiyeti tercih edilirliliği artmıştır. Bu avantajlarının göz önünde bulundurulmasından dolayı çevresel ve sosyal etkileri göz ardı edilmiştir. Böylece yatırımların bir tür üzerinde yoğunlaştırılması diğer türlerin durağanlaşmasına sebep olmuştur.

Kalabalık ya da gelişmekte olan toplumlarda hareketliliğin karşılanabilmesi için etkin bir ulaşım ağı oluşturulması zorunlu kılınmıştır. Demiryolu ulaşımı daha çok yük taşımacılığında kullanılırken, kalabalık nüfusa sahip ülkelerde yüksek kapasitede yolcu taşıma fırsatı sunduğu için önemli bir ulaşım aracı haline gelmiştir (Xu vd., 2018). Sürdürülebilir ulaşım kapsamında daha çevreci bir ulaşım fırsatı sunmasından dolayı da son zamanlarda daha çok gündemde tutulmaktadır. Tercih edilebilirliğini arttırmak ve daha iyi hizmet sağlamak için altyapı çalışmalarının yapılması ve teknolojik yeniliklere ayak uydurması gerekmektedir (Kidd vd., 2019). Şehirlerarası yolcu taşımacılığında hız parametresinin uygun düzeyde tutularak ve tüm güvenlik düzeyleri sağlanarak hızlı ulaşım sağlanması, şehir içi ulaşımında trafiğe karışmadan diğer türlerin sunduğu kapasitenin üzerinde bir kapasite ile ulaşım imkânı sağlaması demiryolu tercih edilebilirliğini etkilemiştir.

Türkiye demiryolu taşımacılığında önemli bir yere sahip olmasına rağmen Marshall Planı dâhilinde karayollarına yapılan yatırımlar arttırılmış ve ulaşım dışı bağımlı hale gelmiştir. Tek bir tür üzerine oluşturulan ulaştırma politikaları karayollarının gelişmesini desteklerken demiryolu ve diğer ulaşım türlerinin gelişmesi için yeterli kaynaklar sağlanmamıştır (Çetin vd., 2011).

Ulaşım planlaması ihtiyaç ve kapasite göz önünde bulundurularak ekonomik ve sürdürülebilirlik kavramları dâhilinde belirlenmelidir (Tanrıverdi, 2015). Yolcu tercihleri üzerindeki etki eden faktörlerin belirlenmesi ve bu faktörler göz önünde bulundurularak geleceğe yönelik seyahat taleplerinin tahmin edilmesi kapasiteye ayrılan yatırımların ve talebin yönetilmesinde büyük öneme sahiptir.

Talep arttıkça bunu karşılayacak kapasite artmazsa ulaşımında tıkanıklıklar oluşmaya başlayacaktır. Gereken kapasitenin belirlenmesinde talep tahmin yöntemleri geçmiş verilerden yola çıkarak ileriye yönelik oluşabilecek durumları belirlemeye yardımcı olur (Adıyaman, 2007). Yolcu taşımacılığın için uygun modların seçilmesi ve bu yönde çalışmalar yürütülmesi ülke ekonomisinin canlanmasına ve refah bir seviyeye yükselmesine katkı sağlar (Ulaştırma Denizcilik ve Haberleşme Bakanlığı [UDHB], 2013). Yolcu taşımacılığında toplam yolculuk sayısı ile üretim de yapılan planlamalar doğrusaldır. Yani yolculuk sayısı arttıkça bu talebi karşılayacak gerekli planlamalarda artış gösterir.

Bu çalışmada ikinci bölümde demiryollarının yolcu taşımacılığındaki tarihi, tarih boyunca geliştirilen tren türleri, Türkiye demiryolu yolcu taşımacılığının gelişimi, yolcu taşıma da kullanılan konvansiyonel, anahat, yüksek hızlı tren, kent içi taşımacılıkta kullanılan türler açıklanmıştır. Demiryolu yolcu taşımacılığında, YSA ile ilgili çalışmalar incelenmiştir. Bu çalışmalar göz önünde tutularak demir yolu yolcu taşıma üzerinde etkili olabilecek değişkenler belirlenmeye çalışılmıştır.

Üçüncü bölümde talep tahmini ve talep tahmininde kullanılan nicel, nedensel, zaman serileri ve simülasyon yöntemleri, yapay sinir ağlarının yapısı, öğrenme türleri, eğitilmesi ve eğitilmesinde kullanılan yöntemler açıklanmıştır.

Dördüncü bölümde demiryolu yolcu taşımacılığında etkili olan faktörler belirlendikten sonra 1998-2018 yılları arasındaki değişkenlere ait istatistiki değerler temin edilmiştir. Bu çalışmada demiryolu yolcu taşımacılığında etkili olan değerlerini dikkate alarak Çok Değişkenli Regresyon (ÇDR) analizi ve yapay sinir ağlarından oluşan iki model oluşturulmuştur. Elde edilen tahmin değerlerine göre modeller kıyaslanmıştır. Son bölümde çalışmadan ulaşılan sonuçlara yer verilmiştir.

2. KAYNAK ÖZETLERİ

2.1 Demiryolu Yolcu Taşımacılığının Tarihi

Demiryolu taşımacılığının verimli bir biçimde taşıma sistemleri arasında payının arttırılması ekonomik büyüme ve gelişme için önemlidir. Bölgesel ve ulusal alanlara erişim sağlaması diğer sektörlerle bağlantılar oluşturur ve ticaret payının artmasında destekleyici bir yapıdadır.

Demiryolu taşımacılığının geleceğe yönelik önde gelen ulaşım aracı olması için yolcu ihtiyaçları göz önünde tutularak planlamalar yapmak demiryollarının gelişmesine katkı sağlayacaktır. Yolcuların ulaşım aracı seçme kıstasları oluşan talebi karşılayabilecek uygun ve güvenli bir tür oluşturulmasıdır (International Union of Railways [UİC], 2019).

19. yüzyılın başlarında İngiltere de ticari amaçla kullanılmaya başlayan demiryolu ilk kez madenlerdeki taşımacılık dışında kullanılmış, zamanla ilgi duyulan ve dünyanın birçok noktasına yayılan ulaşım türü haline gelmiştir. Birçok ülke demiryolu raylarını inşa etmeye başlamıştır ve kısa sürede benimsenmiştir. Daha çok yük taşımacılıkta kullanılan demiryolları yolcu taşımacılığı için de çekici hale gelmiş ve henüz otomobilin de keşfedilmediği bu dönemde büyük bir yenilik olmuştur. Zamanla demiryolu üzerinde kullanılan araçlarda gelişmiş, teknoloji ile birlikte yenilikler getirmiştir (URL-1).

1829 yılında Raket adı verilen demiryolu aracı saatte 50 km hıza ulaşarak zamanın koşullarında en yüksek hızı temsil edilmiştir. Hız konusunda havayolu taşımacılığı daha kısa yolculuk süresi ile seyahat imkânı sağlaması, karayolları taşımacılığında seyahat aralıklarının sık oluşturulması, demiryolu yolcu taşımacılığında istenilen talebi oluşturmadığı için gelişmeyi zorunlu kılmıştır. 1850 yılında saatte 100 km, 1854 yılında 130 km/s, 1903 yılında 210 km/s hıza ulaşan demiryolları yolculuk süresini kısaltarak yolcu taşımacılığının merkezi olmaya ilerlemiştir. Demiryolu araçlarının hız ile entegrasyonu diğer türler ile arasında rekabet oluşturmuş ve başlangıçta buharlı araçlarla taşımacılık yapılırken elektrikli ve dizel araçlar da geliştirilmiştir (URL-1).

Türkiye’de demiryolu taşımacılığı ile birlikte karayolu taşımacılığı da 1950 yılına kadar gelişim göstermiştir. Ancak 1950 yılından sonra karayolu ile taşımacılık daha yoğun bir biçimde kullanılmaya başlamıştır. 1950 yılından 2000 yılına kadar ki süreçte karayolları üzerinde ağırlıklı olarak planlamalar yapılmıştır (Karayolları Genel Müdürlüğü [KGM], 2018).

Kapıdan kapıya ulaşım imkânı sağlaması Çetin vd. (2007) yolcu taşımacılığında yolcular için daha zahmetsiz hizmet sunması ve cazip gelmesinden dolayı dezavantajları görmezden gelinmiş, demiryolu üzerine yapılan çalışmalar yavaşlamıştır.

Son yıllarda enerji kullanımına sürdürülebilirlik kavramının da göz önünde bulundurulmasıyla ulaştırma sektöründe bazı yenilikler getirilmiştir (Nordenholz vd., 2016). Gelişmiş ülkeler çevresel sorunlar ve iklim değişikliklerinin sebep olduğu olumsuz etkileri hafifletmek için yenilebilir enerji kaynaklarını kullanan çevreci bir ulaşım oluşturmaya çalışmaktadır. Avrupa da ulaşımdan etkin ve güvenli, sosyal faydaları göz önünde tutan ve çevreci ulaşım araçlarının daha çok tercih edilmesini sağlayacak çalışmalar yürütülmektedir (Türkiye Cumhuriyeti Devlet Demiryolları [TCDD], 2018(b)).


Yolcu taşımacılığında hız parametresinin belirleyici bir faktör olması demiryollarında konvansiyonel taşımacılığın hız ile geliştirilerek yüksek hızlı demiryolları oluşturmayı sağlamıştır. Demiryollarında yüksek hıza ulaşabilen hatların oluşturulması ilgi çekmiştir. Böylece uzun süre üzerinde etkili çalışmalar yapılmamış demiryolları popüler hale gelmiştir.

Yapılan birçok çalışmada araçlar üzerinde değişikliklere gidilerek uygun hıza olanak sağlayacak yapılar elde edilmek istenmiştir. Manyetik levitasyonlu trenler yani Maglev trenler mıknatısların oluşturduğu manyetik alanların zıt kutupların birbirini itmesi tekniğine göre oluşturulmuştur. Altyapı da kullanılan mıknatısın itme gücü ile herhangi bir temas olmaksızın özel raylar üzerinde yol boyunca sıralanmış bobinlerden araca verilen alternatif akım frekanslarına göre aracın hızı kontrol edilmektedir (Göker, 1996; Şahin, 2001).

Japonya da geliştirilen Maglev trenin 7 km'lik hat üzerinde test sürüşü yapılarak 517 km/s hıza ulaştığı kaydedilmiştir. Ray ile araç arasında sürtünme olmadığı için aşınma durumu da oluşmayacaktır. Sürtünmenin olmamasından dolayı da Maglev trenler 500 km/s hıza erişebilmektedir. Mevcut demiryolu üzerinde işleme uygun olmadığı için yeni demiryolu altyapısı gerektirmektedir (Göker, 1996; Şahin, 2001).

Konvansiyonel teknoloji dâhilinde geliştirilen yalpalı trenler konvansiyonel trenlere göre daha hızlıdır. Özel olarak oluşturulan yüksek hız trenlerinin maliyetli olmasından dolayı mevcut altyapıdaki bazı değişiklikler sağlanarak 160-250 km arasında hızlara ulaşabilmektedir (Göker, 1996).

Hız arttıkça merkezkaç kuvveti büyüklüğü artar ve yolcular üzerinde rahatsız edici bir durum gerçekleştirir. Güzergâh üzerinde kurbalarda hızdan dolayı savrulmaları engellemek için dingillerde bulunan oynar parçalar kurb bölgesinde iç kısma doğru eğilerek yolcu konforunun etkilenmesini önlemektedir (Förstberg, 2000). Yalpalı tren yolcu konforu Şekil 2.1'de belirtilmiştir.



Şekil 2.1. Yalpalı tren yolcu konforu (Förstberg, 2000).

Yüksek hızın oluşturduğu ek enerji talebini seyahat süresi boyunca uniform hızla sürdürdüğü için konvansiyonel trenlerde kurb giriş noktalarında frenleme ve kurb çıkışlarında ivme kazanmada gerekli olan enerji de dikkate alındığında enerji tüketimleri eşitlenmektedir (Göker, 1996).

Yüksek-hız ile demiryolu bir arada önemli bir pazar alanı oluşturmuş ve diğer ulaşım türlerine göre tercih edilebilirliği artmıştır. Yolcu taşımacılığı için 200 km ve üzeri hızla erişebilen hatlar yeni altyapıyı da gerektirmiştir (Devlet Planlama Teşkilatı [DPT], 2001).

1964 yılında Japonya da yolcu taşımacılığına açılan Shinkansen, demiryollarında ilk kez yüksek hızlı tren sistemlerine geçişi temsil etmektedir. 1981 yılında Fransa'ya ait TGV 260 km/s hız ile işleme açılmıştır. 2008 yılına kadar İtalya Pendolino, Almanya ICE, İspanya AVE, Birleşik Krallık HS1, Çin CRH gibi birçok ülke de kendilerine has demiryolu araçlarıyla yüksek hızlı taşımacılık fırsatı sunmuştur ve yüksek hızlı tren kullanımı dünyaya yayılmıştır (URL-1).

Demiryolları geçtiği tüm güzergâhlara çağdaş bir taşımacılık imkânı sunmuştur (URL-2). Demiryolu şehirden şehre, bölgeden bölgeye uzak mesafelerde, şehir içi ulaşım da yolcu taşıma imkânı sağlamıştır.

2.2 Türkiye Demiryolu Yolcu Taşıma Tarihi

Türkiye genç bir ülke olmasına rağmen tarihi öncesinde birçok demiryolu çalışmaları yapılmış ve bu çalışmaları üzerine yeni planlamalar geliştirmeye devam etmiştir. Türkiye demiryolu tarihi Osmanlı demiryolları ve Türkiye demiryolları olarak ayrılabilir.

2.2.1 Osmanlı demiryolu tarihi

Demiryolu ağlarının dünyaya yayılmaya başlaması ile birlikte Osmanlı devleti de bu yeniliğe adım atmıştır. 1856 yılında Aydın-İzmir arasında 130 km'lik hat yabancı devletlere verilen imtiyazlarla inşa edilmeye başlamıştır. Osmanlı İmparatorluğunun demiryolu tarihi 1856 – 1923 yılları arasını kapsamaktadır. Bu tarihler arasında 2383 km uzunlukta Rumeli demiryolları, 2424 km Anadolu-Bağdat, 695 km İzmir-Turgutlu (Manisa), 610 km Aydın-İzmir hattının çevresi, 498 km Sam-Hama, 86 km Yafa-Kudüs, 42 km Bursa-Mudanya, 80 km Ankara-Yahşihan (Kırıkkale) olmak üzere toplamda 8619 km demiryolu hatları inşa edilmiştir (Ulaştırma Denizcilik ve Haberleşme Bakanlığı [UDHB], 2013).

İstanbul-Bağdat arasına demiryolu hattının kurulmasının ve işletiminin Almanlara verilmesi ile Adana-Mersin hat sahipliği tamamen Almanlara üstlenmesi Akdeniz’de liman bölgesine demiryolu ile erişim sağlamıştır. Taşımacılık için oldukça önemli olan liman şehirleri ve Bağdat hattının birleşmesi ile o dönemde en çok gelir elde eden demiryolu hattı oluşmuştur (Akpolat, 2004).

Yük ve yolcu taşımacılığında ilkel taşıma araçlarının kullanılması, uzak mesafeler için oldukça zaman kaybına neden olmakta ve güç gerektirmektedir. Ülkeler arası taşımacılıkta denize kıyısı olan şehirlerden gemi ile seyahatin günler sürmesi ve hava koşullarının denizde tehlike oluşturması ve kara üzerinde at arabaları ile seyahat edilmesiyle Osmanlı için demiryolları modern taşımacılığa geçişini sağlamıştır. Hem yolcu hem yük taşımacılığında kullanılan demiryolları Osmanlı için zamanın şartlarında taşımacılık için oldukça avantajlar sağlamıştır.

2.2.2 Türkiye demiryolu tarihi

Türkiye jeopolitik konumundan dolayı Asya ve Avrupa kıtaları arasında bir geçit ülkedir. Bu özelliğiyle de dış ticarete pek çok avantajlar sağlamaktadır. 1923 yılında Cumhuriyetin ilan edilmesiyle birlikte Osmanlı döneminde inşa edilmiş demiryollarından sadece bir kısmı Türkiye devleti sınırları içerisinde kalmıştır. Demiryollarına ait çalışmaların en hızlı gelişim gösterdiği 1923-1950 yılları arasında 3764 km uzunluğunda demiryolları inşa edilmiştir. Milli ekonomi düşüncesiyle milli kaynakların kullanılması gerektiği benimsenmiştir (UDHB, 2013).

Bir süre demiryolu çalışmaları üzerine yoğunlaşan planlamalarda demiryollarının oluşan talebi karşılamada yetersiz kaldığı düşüncesiyle karayolu çalışmalarına da önem verilmeye başlanmıştır (Türkiye Mühendis Haberleri [TMH], 2006). 1948 yılında Marshall Planı kapsamında hem teknik hem de mali destekten sonra karayolları üzerine yapılan çalışmalar daha fazla ağırlık kazanmıştır (Çetin vd., 2011). Böylece demiryolu araçlarının gelişiminden sonra petrol kaynaklı lastik tekerlekli araçlar kullanılmaya başlamıştır.

Petrol kaynaklarında dışa bağı olan Türkiye için demiryolu taşımacılığı en uygun taşıma sistemi iken ülkeyi dışa bağımlı hale getirecek ulaşım planlaması oluşturulmuş ve sahip oluğu değerler göz ardı edilerek karayolu taşımacılığı benimsenmiş, bu durum ekonomik olarak dış kaynaklara yatırım gerektirmiştir. Ayrıca motorlu taşıt ihtiyacını da dış ülkelerden karşılanmasıyla ağırlıklı olarak karayolları üzerine yatırımlar ve planlamalar oluşturulmuştur.

Çizelge 2.1’de görüldüğü gibi karayolları hat uzunluğu 1950-2000 yılları arasında %62 artarken demiryolu hat çalışmaları %10 oranında artış göstermiştir. Buradan da karayollarında yapılan çalışmaların 1950 yılından sonra önem kazandığı açık şekilde anlaşılmaktadır. 1950 yılında yolcu-km sayısı her iki ulaşım türü içinde yakın değerlere sahipken 1950 yılından sonra karayolu yolcu taşıma sayısı da hızla artış göstermiştir.

Çizelge 2.1. Karayolu ve demiryolu hat uzunluğu (KGM, 2018; URL-9).

Yıllar	Karayolu (km)	Karayolu (yolcu-km)	Demiryolu (km)	Demiryolu (yolcu-km)
1950	47 080	2 597	7 671	2 516
1960	61 542	10 880	7 895	4 396
1970	59 453	41 311	7 985	5 561
1980	60 785	73 127	10 144	6 011
1990	59 369	134 991	10 389	6 410
2000	62 764	185 681	10 922	5 832

Tüm dünya genelinde demiryollarının yeniden yapılanması gerektiği düşüncesi ile Avrupa Birliği demiryolu politikaları kapsamında 50 yıllık bir süre zarfında ihmal edilmiş demiryolları 2003 yılından sonra devlet politikası haline getirilerek yeniden gündeme alınmıştır. 1950-2003 yılları arasında demiryolu çalışmalarına yeterli önem verilmemesinden kaynaklı eksikliklerin giderilmesi ve demiryolu taşımacılığını yeniden aktif bir ulaşım türü haline getirilmesi için gerekli yatırımlar ve çalışmalar yapılmıştır (URL-2).

AB demiryolu politikaları 4 paket halinde oluşturulmuştur (Uğurlu, 2018). Bunlar;

2001 yılı 1. Demiryolu Paketi:

- Ulaşımda küreselleşmenin sağlanması

- Demiryolu müşterilerini planlamanın merkezinde tutarak bu durum göz önünde bulundurularak planlamalar yapma
- Taşımacılık türleri arasındaki dengenin yeniden gözden geçirilmesi

2004 yılı 2. Demiryolu Paketi:

- Yaşanmış kazaların değerlendirilmesi ile güvenliğin artırılması
- Demiryollarının kendi içinde rekabet ortamının oluşturulması

2007 yılı 3. Demiryolu Paketi:

- Yolcu hakları sisteminin oluşturulması
- Yolcu taşımacılığında uluslararası taşımacılık hareketlerinin artırılması

2016 yılı 4. Demiryolu Paketi:

- Ulusal yolcu pazarının rekabete açılması
- Altyapı çalışmalarının yönetilmesi gibi konuları kapsamaktadır.

Türkiye verimli ve dengeli bir ulaştırma sisteminin oluşturulması, karayolları yoğunluğunun demiryollarına yönlendirilmesi için fiyatlarda düzenleme yapılması, işletmelerin yapılarının iyi duruma getirilmesi ve altyapı eksikliklerinin tamamlanması gerekmektedir. Ayrıca demiryolu araçlarının içinde de dengeli bir çalışma planı oluşturulmalıdır. Yani ağırlıklı olarak yüksek hızlı demiryollarına ait taşıma planlarının yanı sıra diğer hatlara da gerekli planlamalar oluşturulmalıdır (Aydemir, 2016).

Şehir içi demiryolları için kapasite dikkate alınarak raylı sistem taşımacılığı başlatılmalıdır. Gerekli önlemlerin sağlanması için sinyalizasyon, elektrifikasyon ve yol yenileme çalışmaları ile yolcu taşımacılığının artacağı planlamalar dikkate alınmalıdır (Aydemir, 2016). Demiryolu altyapısının yetersiz olması ve eksiklikleri, kaliteli ulaşım imkânı sunmaması ve araç sayılarındaki yetersizliklerden dolayı düşük talep oluşmaktadır (UDHB, 2013).

Demiryolu kullanımını yaygınlaştırmak için yeni teknolojilerin izlenmesi ve akıllı ulaşım sistemlerinden faydalanarak yolcu taşımacılığı standartları arttırılabilir. 10. Ulaştırma şurasında Türk demiryollarının yapılanmasını sağlamak, hizmet zararlarını en aza indirmek ve işletme kalitesini arttırarak ulaşım rekabet ortamı sağlamak amaçlanmıştır (UDHB, 2013).

Yüksek hızlı demiryolu altyapısının oluşturulması ile hızlı seyahat imkânı sağlayacak yüksek hızlı trenlerin işleme açılması için planlamalar oluşturulmuştur. 2008 yılında konvansiyonel tren ve uluslararası tren ile toplam 23.970.000 yolcu taşınırken, 2018 yılında birçok ilde yüksek hızlı tren seferlerinin başlatılması ile birlikte kent içi taşımacılık hariç toplam 24.489.000 yolcu taşınmıştır. Demiryolları geçtiği tüm güzergâhlara çağdaş bir taşımacılık imkânı sunmuştur (URL-2).

Türkiye demiryolu çalışmalarında 2023 yılına kadar 3.500 km yüksek hızlı demiryolu, 8.500 km konvansiyonel demiryolu ve 1.000 km konvansiyonel demiryolu inşa ederek toplam ağ uzunluğunu 25.000 km'ye ulaştırmayı, uluslararası demiryolu koridorlarının arttırılmasını hedeflemektedir. Tüm ulaşım türleri arasında yolcu taşıma payını %10'a çıkarmayı planlamaktadır. Ayrıca kent içi toplu taşıma hizmetlerini geliştirerek raylı sistemlerin daha aktif hale gelmesi sağlanacaktır (UDHB, 2013).

2.2.3 Türkiye yüksek hızlı demiryolu yolcu taşımacılığı

Türkiye'de ilk olarak Ankara-İstanbul şehirleri arasında yüksek hızlı demiryolu (YHD) inşası başlatılmış ve 2009 yılında Ankara-Eskişehir arasındaki hat işleme açılmıştır. 200 km/s ve üzeri hızlara erişerek karayolu ile yapılan yolculuklardaki seyahat süresinden daha az sürede seyahat imkânı sağlaması ve havayolu taşımacılığına göre fiyatlandırmalardaki uygunluk göz önünde bulundurularak Türkiye'de yüksek hızlı demiryolu çalışmalarına ağırlık verilmeye başlanmıştır. Şekil 2.2 incelendiğinde Ankara-İstanbul-Konya hatları aktif yolcu taşımacılığında kullanılmaktadır. Ankara-İzmir, Ankara-Sivas-Erzincan, Konya-Karaman, Adana-Osmaniye ve Osmaniye-Bursa arası inşası devam eden hatlardır. Diğer hatlar yapımı planlanan hatları temsil etmektedir.




Şekil 2.2. Yapımı planlanan, inşaat sürecinde ve işletimdeki YHD ağı (URL-5).

Ankara-Konya demiryolu taşımacılığında yolcular için konvansiyonel hat ile seyahat imkânı sağlanmıştır. Ancak güzergâhın Ankara'dan dolanarak Konya'ya ulaşması yaklaşık 11 saat sürdüğü için yolculuk süresi oldukça fazladır. Ankara-Konya arasında yeniden bir güzergâh belirlenerek 212 km uzunlukta yüksek hızlı demiryolu hattı oluşturulmuştur. 2011 yılında işletime açılan hat ortalama 2 saat gibi bir seyahat süresiyle ulaşımı sağlamıştır (URL-4).

2018 yılında Ankara-Eskişehir hattında toplam 1.426.304, Ankara-İstanbul hattında 3.268.635 yolcu taşınmıştır. YHT işletime açılmadan önce bu hat üzerinde demiryolu yolcu taşıma oranı %8 iken, YHT ile birlikte %72 oranına ulaşmıştır. Aynı zaman da çevresindeki illere de kombine taşımacılıkla seyahat fırsatı sağlamıştır.

Ankara-Konya hattında toplam 2.242.870 yolcu seyahat etmiştir. Bu noktalar arasında yüksek hızlı demiryolları ile yolcu taşıma payının %66'sını oluşturmaktadır. Konya-İstanbul hattı 533 km uzunlukta 2014 yılında işletime açılmıştır. 2018 yılında toplam 1.166.554 yolcu seyahat etmiştir (TCDD, 2018(a)).



Şekil 2.3. Türkiye YHT yolcu sayısı.

2019-2023 yılları arasında planlanan dönemde Ankara-İzmir yüksek hızlı demiryolları çalışmalarını tamamlanmasıyla 3 saat 20 dakika bir seyahat süresiyle karşılıklı 36 tren seferi düzenlenmesi ve 6 milyon yolcu taşınması planlanmaktadır. 2023 yılında hedeflenen çalışmalarında tamamlanmasıyla yüksek hızlı tren çalışmaları günlük 488 sefer ile yıllık 70 milyon yolcu taşınması amaçlanmaktadır (UDHB, 2013).

İnşası hala devam eden yüksek hızlı demiryollarının birçoğu gelecek yıllarda işleme açılması planlanmaktadır. Yapım aşamasında olan hat bilgileri Çizelge 2.2’de gösterilmiştir.

Çizelge 2.2. Yapım aşamasındaki yüksek hızlı demiryolu hatları (URL- 5).

Hat Adı	Max Hız	Mesafe
Osmaneli-Bursa	250	105
Kayaş-Yerköy	300	152
Yerköy-Sivas	300	245
Polatlı-Uşak-İzmir	300	470
Konya-Karaman	200	102
Adana-Toprakkale	200	79

Projeleri onaylanmış ama inşaatına başlanmamış yolcu taşımacılığında kullanılacak yüksek hızlı demiryolu hatları Çizelge 2.3'te belirtilmiştir.

Çizelge 2.3. Projesi onaylanmış yüksek hızlı demiryolları.

Hat Adı	Max. Hız (km/sa)	Mesafe (km)
Yerköy-Kayseri	250	142
Sivas-Erzincan	200	168
Halkalı-Kapıkule	200	230
Gebze-Halkalı	200	124
Antalya-Eskişehir	200	423
Antalya-Kayseri	200	530
Samsun-Kırıkkale	200	292
Delice-Ulukışla	200	321

Yapımı planlanan ve projesi henüz kararlaştırılmamış daha birçok yüksek hızlı demiryolları ile Türkiye demiryollarında öncü taşımacılık sergilemeyi ve ülkenin her bir köşesini demir ağlarla çevrelemeyi hedeflemektedir. Uzun vadede yüksek hızlı demiryolları ile ilgili planlanan hatlara ait bilgiler Çizelge 2.4'te verilmiştir.

Çizelge 2.4. Uzun vadede yapımı planlanan yüksek hızlı demiryolları.

Hat Adı	Max Hız	Mesafe
Ulukışla-Yenice	200	110
Sivas-Malatya	200	237
K.Maraş-Gaziantep-Şanlıurfa	200	197
Nusaybin-Habur	160	134
Gölbaş-Kahta	160	100
Erzincan-Erzurum-Kars-Iğdır	200	639
Tokat-Turhal	160	42
Malatya-Elazığ	200	126
Siirt-Kurtalan	160	36
Bergama-Soma	200	42
Şanlıurfa-Mardin	200	181
Ödemiş-Kiraz	160	30
Selçuk-Ortaklar-Aydın-Denizli	200	177
Bandırma-Bursa-Gemlik	200	98
Diyarbakır-Elazığ	200	150
Erzincan-Trabzon	200	248
Diyarbakır-Mardin	200	102
Erzincan-Muş	200	210

2.2.4 Türkiye konvansiyonel hatlarla yolcu taşımacılığı

Konvansiyonel hatlarda bölgesel trenler, uluslararası trenler ve anahat trenleri ile yolcu taşımacılığı yapılmaktadır. 2018 yılı itibariyle konvansiyonel hat uzunluğu şebeke yolları, iltisak yolları ve anahat yollarıyla toplam 11.527 km'dir. Anahat trenleriyle toplam 15.883.000 yolcu taşınmıştır (TCDD, 2018(a)).

2.2.4.1 Anahat trenleri

Türkiye’de yolcu taşımada kullanılan anahat trenleri, izledikleri güzergâh ve yolculuk sürelerine ilişkin bilgiler Çizelge 2.5’te verilmiştir.

Çizelge 2.5. Anahat trenleri (URL-6).

Hat Adı	Güzergâh	Seyahat süresi
İzmir Mavi Tren	İzmir-Manisa-Kütahya-Eskişehir-Ankara	13 saat 30 dakika
Konya Mavi Tren	Konya-Afyon-Uşak-Manisa-İzmir	12 saat 20 dakika
Karesi Ekspresi	İzmir-Manisa-Balıkesir	5 saat
Ege Ekspresi	İzmir-Manisa-Kütahya	11 saat 30 dakika
6 Eylül Ekspresi	İzmir-Manisa-Balıkesir	7 saat
17 Eylül Ekspresi	İzmir-Manisa-Balıkesir	6 saat 40 dakika
Pamukkale Ekspresi	Denizli-Afyon-Kütahya-Eskişehir	8 saat
Toros Ekspresi	Konya-Adana	6 saat 30 dakika
Doğu Ekspres	Ankara-Kayseri-Sivas-Erzincan-Erzurum-Kars	25 saat
Turistik Doğu Eks.	Ankara-Kayseri-Sivas-Erzincan-Erzurum-Kars	33 saat
Van Gölü Ekspres	Ankara-Kayseri-Sivas-Malatya-Elazığ-Van	24 saat
G. Kurtalan Ekspres	Ankara-Kayseri-Sivas-Malatya-D.bakır-Siirt	24 saat
Fırat Ekspresi	Elazığ-Malatya-Osmaniye-Adana	10 saat
Erciyes Ekspresi	Kayseri-Niğde-Adana	5 saat 30 dakika
Ankara Ekspresi	Ankara-Eskişehir-Bilecik-İzmit-İstanbul	8 saat 40 dakika
Göller Ekspresi	Isparta-Denizli-Aydın-İzmir	8 saat 30 dakika
Boğaziçi Ekspres	Ankara-Eskişehir-Bilecik-Arifiye	6 saat 10 dakika

Konvansiyonel hatları kullanan yolcular, yüksek hızlı demiryolu istasyonları ile konvansiyonel hatların kesiştiği istasyonlardan aktarma yaparak ve yüksek hızlı demiryollarını kullanarak seyahatlerini sürdürebilmektedir (TCDD, 2018(a)). Türkiye’deki anahat demir yolu ağı Şekil 2.4’te gösterilmiştir. 2023 yılında konvansiyonel trenlerle yolcu taşımacılığında günlük 516 sefer ile 56 milyon yolcu taşınması hedeflenmektedir (UDHB, 2013).



Şekil 2.4. Anahat tren haritası (URL-8).

2.2.4.2 Bölgesel trenler ile yolcu taşımacılığı

Birbirlerine yakın mesafedeki il ve ilçelere yolcu taşımacılığında kullanılan trenlerdir. Bu trenlere ait ağ haritası Şekil 2.5’te verilmiştir. Bazı bölgesel trenlerin geçtiği güzergâh üzerinde yüksek hızlı demiryollarına ait çalışmalar yapılırken güzergâhlar yolcu taşımacılığına kapatılmaktadır (URL-6).



Şekil 2.5. Bölgesel tren haritası (URL-8).

Şehir içi yolcu taşıma araçlarına ait bilgiler aşağıda verilmiştir (Atalay ve Tortum, 2019).

Tramvay: Lastik tekerli ulaşım türleri ile aynı yol yüzeyi üzerinde ulaşım imkânı sağlayan en düşük kapasiteli demiryolu aracıdır. Diğer ulaşım araçları ile ortak kullanım alanları olduğu için belirlenen hız limitini aşamazlar. Ancak tramvaya ait güzergâhların trafikten ayrı tutulması ve öncelik sağlanması sistematik olarak yolcu taşıma fırsatı sunar.

Hafif raylı sistemler: Hareketliliğin yoğun olduğu kesimlerde yer altında, diğer alanlarda yol yüzeyinde taşıma imkânı sunan demiryolu aracıdır. Esnek çalışma yapısına sahip olması, metroya göre düşük maliyetli ve kısa sürede inşa edilmesi şehir içi yolcu taşımacılığında avantaj sağlar.

Metro: En yüksek taşıma kapasitesi ve hıza sahip demiryolu aracıdır. Kalabalık nüfuslu şehirlerde oluşan yüksek kapasiteyi en uygun biçimde karşılar.

Banliyö: Şehir merkezinden uzakta kurulmuş yerleşkeler için merkez ile bağlantı sağlayan raylı yolcu taşıma aracıdır.

2023 yılı hedeflerinde kent içi yolcu taşımacılığında Marmaray, Başkentray, Egeray, Gaziray ile günlük sırasıyla 724, 258, 525, 57 sefer düzenlenmesi ve toplamda 874 milyon yolcu taşınması planlanmaktadır (UDHB, 2013). Kent içi yolcu taşımada şehirlere göre değişik isimlerle adlandırılmış yolcu taşıma araçları aşağıda verilmiştir (URL-7).

2.2.5.1 Marmaray

2018 yılında işleme açılan Marmaray banliyö hattı Marmara denizinin altında kurulan tüp geçitlerle Asya ve Avrupa kıtalarını demiryolu ile birbirine bağlamıştır. Gebze-Halkalı arasında demiryolu ile kesintisiz ulaşım fırsatı sağlarken metro hatları ile bağlantılı olacak şekilde inşa edilmesi aktarma ile demiryolu üzerinden kolay ulaşım sunmaktadır.

Marmaray banliyö hattı ile günlük 76 km mesafede, 43 istasyon arası taşımacılık yapan Marmaray günlük 285 sefer ile 120 dakika yolculuk süresine sahiptir. 2018 yılında Marmaray banliyö hattı ile toplam 949 milyon yolcu taşınmıştır.

2.2.5.2 Başkentray

Kayaş-Sincan arasında yolcu taşımacılıkta kullanılan Başkentray, 36 km uzunlukta ve 24 duraktan oluşan Ankara banliyö hattı çalışma nedeniyle 2016 yılında işletimine ara verilmiş ve 2018 yılında hat yeniden işleme açılmıştır. Yolcular Kayaş-Sincan hattında 49 dakika seyahat süresi ile yolculuk yapabilir, Yenışehir istasyonundan Ankara metrosuna, Kurtuluş ve Maltepe istasyonundan Ankaray hattına aktarma yaparak seyahatlerini sürdürebilir. Başkentray ile 2018 yılında toplam 237 milyon yolcu taşınmıştır. Ankara garı ve Eryaman YHT hattının geçiş noktaları üzerinde faaliyet gösterdiği için de şehirlerarası yolculuk yapmak isteyen yolculara doğrudan istediği istasyondan yüksek hızlı tren kullanımı için geçiş sağlar.

2.2.5.3 İzban

Aliağa-Menemen-Çiğili-Karşıyaka-Havaalanı-Cumaovası-Selçuk arasında 136 km mesafede 2010 yılında faaliyete geçirilen İzban Aliağa-Selçuk güzergâhında 41 istasyon ile yolcu taşımacılığında kullanılmaktadır. Türkiye de şehir içi ulaşımında havaalanı ile bağlantılı ilk banliyö hattıdır.

2.2.5.4 Gaziray

2018 yılında çalışmalarına başlanan Gaziray Gaziantep için Başpınar-Oduncular istasyonları arasında yolcu taşımacılığı için kullanılacaktır. Aynı zamanda yüksek hızlı demiryolları ile birlikte çalışacağı 2 adet banliyö, 2 adet de yüksek hızlı demiryollarına ait demiryolu altyapısı oluşturulacaktır. Toplam seyahat süresi 30 dakika sürmesi planlanan banliyö hattında günlük 358 bin yolcu taşınması hedeflenmektedir.

2.2.6 Demiryollarının yolcu taşımadaki avantajları ve dezavantajları

Yolcu taşımada oluşan yoğunluğu yüksek oranda taşıma kapasitesine sahip olduğu için trafik tıkanıklığını azaltmaya yardımcı, güvenli ve verimli bir biçimde uygun maliyetlerle taşıma fırsatı sağlar. Talep değişkenliğine ve çalışma koşullarında esneklik gösterir. Hatların inşa maliyetleri diğer türlere göre daha uygundur. Fosil yakıt tüketimi bakımında yenilenebilir enerji kaynaklarını kullanarak çevreci, sürdürülebilir ulaşım araçlarıdır. İklim değişikliklerinin oluşturduğu olumsuzluklara karşı dayanıklıdır. Dış dünya pazarına ve teknolojik değişimler karşısında yeniliğe açık bir sektör yapısına sahiptir (UİC, 2019).

Yüksek hızlı demiryolları minimum sürede maksimum kapasite taşıma imkânı ile şehirleri ve ülkeleri birbirine bağlar. Nüfusun kalabalık olduğu şehirlerde diğer türlere göre daha az platform genişliği üzerinde taşıma yapılabilir. Yolcuların can güvenliğini tehlikeye atmadan güvenli ulaşımı benimseyen demiryollarında kaza sayısı ve ölüm oranları oldukça azdır.

Teknolojik gelişmelerle birlikte rejeneratif frenleme yöntemiyle rayda yavaşlamak için kaybedilen kinetik enerji depolayarak harekete hazırlanan diğer trenlere aktarır. Böylece trenin yavaşlaması için harcanan enerji miktarı geri kazandırılırken enerji için gereken maliyet azalırken çevre üzerinde pozitif bir rol oynar. Yeşil ulaşımı hedefleyen demiryolları teknolojik gelişmişliğin tüm yönlerini en etkin biçimde araştırıp gerekli çalışmalar ışığında karbon ayak izini etkisiz hale getirme amacındadır (European Rail Research Advisory Council [ERRAC], 2017). Sağladığı enerji verimliliği ile diğer türleri gerisinde bırakır. Ayrıca karbondioksit salınımlarından oluşan olumsuz etkilerin azaltılmasına yardımcı olmaktadır. Yenilenebilir enerjilerden faydalanarak kaynak kullanımında çevreci bir ulaşım aracıdır.

Hızlı ulaşım, yolculuk sırasında konfor sağlaması ve çevreci bir ulaşım aracı olduğu için tercih edilebilirliği artmaktadır. Şehir içi taşımacılıkta kullanılan raylı sistemler trafiğe karışmadan ulaşım sağlar. Ayrıca kendilerine ayrılmış platform üzerinde çalıştıkları için belirlenmiş süre de sistematik olarak seyirlerini sürdürürler.

Demiryollarının gelişmesi sosyal ve demografik yapıyla doğrudan ilişkilidir. Teknik değişimler demiryolu hizmetinde erişim konusunda kolaylık sağlar. Örneğin rezervasyon ve kolay satış imkânı tercih edilebilirliği etkilemektedir. Demiryolu ile seyahat eden yolcular ayrıca zamanı daha etkin kullanabilmektedir. Zaman kavramı teknolojik değerler ile faydalı biçimde kullanılabilir (Worsley, 2012).

Yüksek taşıma kapasitesi sayesinde demiryolu araçlarında talepler fiyatlandırma düştüğünde artarken gelir düzeyi arttığında bireysel taşımacılık daha çekici gelmektedir. Blainey vd. (2012), demiryolu yolcu taşımacılığının uygun maliyetli olmasına rağmen yolcuların diğer modlara yönelmesini dikkate alarak demiryolu kullanımı önündeki engelleri tespit etmek için bir çalışma yapmıştır. Sert, yumuşak ve tamamlayıcı engeller olarak sınıflandırmışlardır.

Sert engeller seyahat süresi ve maliyetlerini kapsamaktadır. Bireysel farklılıklar oluştursa da tüm yolcular üzerinde etkilidir. Zaman tasarrufu için seyahat süresi tür seçimini önemli derecede etkiler. Böylece demiryolu seyahatlerindeki süreyi minimize etmek yolcular üzerinde çekici bir etki yaratır. Seyahat süresi, güvenilirlik, hizmet frekansı ve zaman çizelgesi, aktarma imkânlarının kısıtlılığı, coğrafi engellerin bulunduğu noktalarda güzergâh oluşturulmaması, maliyet, istasyon erişimi, araç bağımlılığı, uygulanan politikalar sert engellere örnektir. Yumuşak engeller bireysel değerler, varış noktaları ve seyahatlerin değerlendirilmesidir. Seyahat konforu, istasyon hizmetleri ve bilgi edinme gibi değerler yumuşak engelleri kapsamaktadır. Tamamlayıcı engeller ekonomik güç, alışkanlıklar, konum tercihleri, kişisel sorunlar ve gereksinimleri içermektedir. Yolcunun sağlık sorunlarının seyahati önündeki etkiler, yolcu yaşı, seyahat etme eğilimleridir (Blainey vd., 2012).

Yüksek hızın demiryolları ile entegrasyonunda bazı engeller vardır. Tarih boyunca yük ve yolcu hatlarının aynı altyapı üzerinde taşınmasıdır. Yolculuk için kullanılan yerel ve hızlı trenler ile yük taşımada kullanılan trenlerin sürüş modelleri belirlenen hız üzerindeki seyri altyapıdan dolayı engeller. Dağlık bölgelerden geçen demiryolu güzergâhlarındaki kurb yarıçapları küçük tutulduğundan savrulmaların yaşanmaması için hız sınırlandırılır. Böyle bölgelerde taşımacılıkta kullanılan trenlerin sabit hızlarla yol alması mümkün değildir (Nordenholz vd., 2016).

2.3 Literatür Özeti

Demiryolları dünya yaşamını tehlike altında bırakan küresel ısınma, karbon emisyonları gibi bazı kavramların olumsuz etkisini azalttığı için sağladığı avantajlar ile yolcu taşımacılığında gündemde yer edinmeye başlamıştır. Teknolojik yeniliklerle geliştirilerek yolcu taşımacılığındaki faydaları, yolcu tercihini arttıracak incelemeler ve oluşacak taleplerin önceden kestirilmesi gibi konularda pek çok çalışmalar yapılmıştır. Yapay sinir ağları pek çok alanda ve sektörde tahmin amaçlı kullanılmaktadır (Adıyaman, 2007). Bu çalışma da daha çok demiryolu taşımacılığında çözüm üretmek için kullanılan yapay sinir ağlarına ait çalışmalar incelenmiştir.

Wardman (2006) yaptığı çalışmada, demiryolu talebi önündeki dış etkenlerin Büyük Britanya devletinin 1990'lı yıllardaki büyümesini açıklamak ve demiryolu talebini tahmin etmek için bir model oluşturmuştur. Dış faktörlerin değerlendirmeye alınmasının zayıf tahminlerin ve büyüme oranlarındaki farkların sebeplerini açıklamaya yardımcı olduğunu ifade etmiştir. Talebi etkileyen faktörlerin başında GSYH gelirken, araba yolculuğu süresi, yakıt maliyetleri, araba sahipliliği ve nüfusun etkili olduğunu belirtmiştir. Tahmin verilerini kayıtlı bilet satışları ve 7 günlük seyahat anketlerinden elde etmiştir. Her iki veri seti ile formüller üzerinden modeller geliştirerek GSYH, araba seyahat süresi ve yakıt maliyetleri arttıkça demiryolu tercih edilebilirliğinin arttığını tespit etmiştir. Ayrıca nüfus artışından oluşan ihtiyaç için demiryolu talebinin bazı bölgelerde yükseleceğini belirtmiştir.

Wardman vd., (2007) yaptıkları çalışmada, şehirlerarası seyahat için 3 ana faktör ihmal edildiği düşünülerek demiryolu seyahat talebini gözden geçirmektedir. Ayrıntılı analiz için modeller geliştirmişlerdir. İlk model bilet satışlarını ele alarak istasyonlar arası seyahatleri zaman serileri temelli yaklaşımları kapsamaktadır. İkinci modelde istasyonlara erişim, nüfusun işlevlerini demiryolu hizmet kapsamı dışında incelenmektedir. Bilet satışlarından yola çıkarak istasyon erişimi ve çıkış zaman esnekliklerinin tahmin edilmesi için metodolojik yaklaşımlar geliştirilmiştir. Gelecekteki demiryolu taleplerinin arazi kullanım kalıplarına, sosyo-ekonomik ve demografik yapıya bağlı olabileceğini belirlemişlerdir.

Topuz (2008) çalışmasında, İstanbul'da karayolu, demiryolu ve denizyolu araçlarını ile sağlanan toplu taşıma sistemlerini kullanan yolcuların, yolcu taleplerinin tahmin edilmesi için yapay sinir ağlarıyla modelleme yapmıştır. Ulaşım araçlarını kendi içlerinde değerlendirmek için ilgili kuruluşlar elde ettiği verilerden faydalanarak otokorelasyon değerleri belirleyip zaman serileri yöntemine dönüştürmüştür. Sonra her toplu taşıma için zaman serileri, zaman serileri ile hafta içi günlerin modellenmesi ve zaman serilerine ihtiyaç duymadan belirlenen bir tarihe ait bilgiye ulaşmak için tarihlendirilmiş veriler ile ileri beslemeli geri yayımlı YSA, radyal tabanlı YSA ve genelleştirilmiş YSA modellerini kullanarak analiz yapmıştır.

Analiz sonucunda yapay sinir ağlarının doğrusal regresyon analizine göre daha iyi sonuçlar oluşturduğunu tespit etmiştir. Modellerden en uygun sonucu tarihlendirilmiş ileri beslemeli geri yayımlı YSA verdiğini belirtmiştir. Ayrıca ileri beslemeli ağların modellemede kullanılan diğer ağlara göre az veri ile daha iyi sonuçlar elde ettiğini tespit etmiştir. Ancak bu olumlu özelliklerinin aksine diğer modellere uygun sonucun elde edilmesi için daha çok çalıştırılması gerektiğini ve simülasyon yönteminin uygulandığı durumlarda negatif sonuçlar oluşturacağını vurgulamıştır.

Çelebi vd., (2009) yaptıkları çalışmada, İstanbul hafif raylı sistemlerin operasyonel yönetimi için kısa vadeli yolcu talep modellerini geliştirmek için YSA ile modelleme yapılmıştır. Yolcu değerlerinin mevsimlere göre değişkenlik gösterdiğinden bu sorunla baş edebilmek için iki yaklaşım geliştirmişlerdir. İlk olarak günlük talepleri tahmin ederek mevsimsel değişimin rastlandığı zamana göre uyarlamak, ikinci yaklaşım ise farklı zaman aralıklarına ait yolcu verilerini göz önünde tutup her aralığa ait taleplerde elde etmektir. Araştırmada ikinci yaklaşım benimsenerek 06:00-02:00 arasında 2 yıllık günlük veriler dâhilinde 15 dakikalık zaman dilimlerine ayrılarak 74 ayrı zaman dilimi belirlenmiştir. MLP modeli ve zaman serilerinin en önemli bileşeni olan ARIMA modeli kullanılmıştır. Ağ 5 kez çalıştırılıp 1000 iterasyon tamamladığında ağın çalışması durdurulmuştur. Değerler değişkenlik gösterdiği için doğrusal olmayan zaman serileri analizi ile çalışma yürütülmüştür. Analiz sonunda geleneksel istatistiksel yöntemlerle sonuçlar karşılaştırıldığında ARIMA modelinin tahminde daha doğru sonuçlar elde ettiğini belirlemişlerdir.

Xie vd., (2014) çalışmalarında, yüksek hızlı trenlerle seyahatlerdeki kısa vadeli yolcu akışını tahmin etmek için yapay sinir ağları ve OD (Origin-Destination) matrisi dayanan DC (divide and conquer) yöntemi geliştirmişlerdir. İstasyonlara gelen ve giden yolcu sayılarından oluşan verileri dikkate alarak OD matrisi ve yapay sinir ağlarına uyarlamışlardır.

OD matrisi kullanarak tahmin etme öncül bilgilerin temin edilmesi, yol akışının kontrol edilmesi ve ölçülmesiyle yol karakterlerinin ve trafik atama matrisi ile elde edilir. Çalışma 15 istasyonda 10 aylık bir süreci kapsayan YHT kullanımını gözlemlemişlerdir. Sonuç olarak yüksek hızlı demiryollarında kısa vadeli yolcu talebini tahmin etmede belirledikleri yöntemin iyi performanslar oluşturduğunu belirlemişlerdir.

Korucuk (2016) çalışmasında, 1991-2015 yılları arasındaki Türkiye’de demiryolu yük taşımacılığını yapay sinir ağları ile modellemiştir. Demiryolu yük taşımacılığına etki eden bağımsız değişkenler; demiryolu hat uzunluğu, motorlu taşıt sayısı, nüfus, gayrisafi yurtiçi hasıla, enerji tüketimi, genel yük değerlerinden faydalanan demiryolu yük değerleri üzerindeki etkisini incelemiştir. Değişkenleri regresyon analizi ve yapay sinir ağları ile analizden sonra elde ettiği değerlerden yola çıkarak yapay sinir ağlarının modeli açıklama da daha iyi performans gösterdiğini belirtmiştir.

Bayata vd., (2018) çalışmalarında, Bakü-Tiflis-Kars demiryolu hattının Türkiye sınırları içinde İstanbul-Kocaeli-Eskişehir-Ankara-Sivas-Erzincan-Erzurum-Elazığ illeri ile kesiştiği noktalar üzerinde demiryolu ile seyahat eden 515 yolcu üzerinde anket çalışması yapmıştır. Ankette demiryollarını kullanan yolcuların memnuniyetlerini ve beklentilerini Analitik Hiyerarşik Proses (AHP) yöntemini kullanarak belirlemeye çalışmışlardır. Yolcuların seyahat seçmedeki kriterleri, memnuniyetleri ve yolculukla ilgili tutumlarından yola çıkarak Yapay Sinir Ağları (YSA), Çok Değişkenli Regresyon (ÇDR) ve Bulanık Mantık (BM) yöntemleri ile seyahat sıklığı talep modellemesi oluşturularak sonuçlar üzerinden bir kıyaslama yapılmış ve yorumlanmıştır. Zaman, konfor, hız, fiyat, güvenlik, ulaşım, hijyen ve personel ilişkisi açısından değerlendirmek için yolculara sorular yöneltilmiştir.

Analiz sonucunda güvenlik faktörünün en önemli olduğu belirlenmiştir. Fiyat ve hijyen faktörleri hariç yolcuların diğer faktörler memnun olduğu saptanmıştır. Seyahat sıklığını belirlemede YSA ile memnuniyet, önem ve tercihlerine göre anket sonuçları sınıflandırılmış ve [0-1] ölçeğinde normleştirilmiştir. Matlab paket programı ile girdi katmanında 3 nöron, çıktı katmanında 1 nöron ve gizli katman nöron sayısını iterasyon optimize ederek ağ mimarisini tasarlamışlardır. Anket sonuçlarına göre seyahat sıklığı tahmin edilmiştir.

ÇDR ve BM için de seyahat sıklığı tahminlerini analiz edilmiştir. BM yöntemi ve seyahat sıklığı arasındaki ilişki incelendiğinde memnuniyet, tercih ve önem seyahat sıklığı üzerinde etkili olduğu tespit edilmiş, düşük yoğunluklu cevapların seyahat sıklığını azalttığı gözlenmiştir. YSA ile ÇDR yöntemleri karşılaştırılarak YSA yönteminin daha anlamlı olduğu belirlenmiştir.

Gallo vd., (2019) yürüttükleri çalışmada, metro yolcu akışını tahmini için akıllı ulaşım sistemlerinin sağladığı yolcu sayılarını turnike sayımları ile elde etmiştir ve YSA yöntemini kullanarak çözümlemişlerdir. Çalışmanın amacı geçmiş zamanlı turnike sayımlarından elde edilen yolcu sayısı ile bir güzergâh üzerinde seyahat edecek yolcu sayısını tahmin etmektir. Yaklaşım Napoli metro hattını temsil alarak oluşturulmuştur. Hat üzerinde tek yönlü 18 turnike bulunmaktadır. Eğitim veri setleri rastgele belirlenen 2500 OD matrisi simülasyon modeli kullanılarak Matlab programından destek alınmıştır. YSA modelinin yolcu akışını tahmin etmede etkili olduğu belirlenmiştir.

Chen vd., (2019) yaptıkları çalışmada, LSTM (Long Short Term Memory) sinir ağlarının dil işleme alanındaki öğrenmeye uygun yapısından dolayı zaman serilerinin tahminde başarı sağladığı için faydalanmışlardır. Bu durumu göz önünde bulundurarak kısa vadeli metro yolcu akışını tahmin etmek için deneysel mod ayrıştırma (EMD) yöntemi ile birlikte LSTM sinir ağı modelini önermişlerdir. LSTM geri beslemeli yapay sinir ağlarının özel bir türüdür. Belirlenen veriler ile LSTM ve EMD-LSTM modeli oluşturmuşlardır. EMD-LSTM, LSTM, ARIMA ve BPN modelleri ile yaptıkları tahmin analizi sonunda EMD-LSTM modelinin daha iyi sonuç ürettiğini tespit etmişlerdir.

3. MATERYAL VE YÖNTEM

3.1 Talep Tahmini

Gelecekteki bir alanda üretim planlamalarında öncelikli olarak üretim için gerekli olacak miktarın belirlenmesidir. Üretim ile ilgili bir veri ya da tahmin değerleri olmadan planlama yapılamaz (Kobu, 2014). İnsan seçimleri yatırım politikalarını etkilediği için kullanıcılara sunulan hizmette seçimlerinin önceden tahmin edilerek projelerin oluşturulması üretimde doğru kararların verilmesinde etkilidir. Seçimlerini belirlemek ve bu yönde tahminde bulunmak için genelde lojistik regresyon yöntemi kullanılır. Lojistik regresyon seçimi üzerinde etkili olan bağımlı ve bağımsız değişkenler arasında ilişkileri belirlemeye ve muhtemel ağırlık değerleri ile bağımlı değişkenin tahmin edilmesinde kullanılan istatistiksel analiz yöntemidir (Tanrıverdi, 2015).

Talep tahmini yaşanmış olaylardan elde edilen verilere dayanarak, oluşan sonuçların değerlendirilmesi ile gelecekte oluşacak değerlerin ne gibi etkilere yol açacağını önceden belirlemeye çalışmaktır (Kobu, 2014).

Talep tahminleri zaman aralığı, kullanma amacı üretim türü, hesaplama tekniği gibi kriterlere göre ayrılır. Zaman aralığı sınıflandırma yöntemi tahminlerinin elde edilmesinde en çok tercih edilen yöntemdir. Zaman aralığı çok kısa, kısa, orta ve uzun vadeli planlamaların belirlenmesinin bir metodudur. Talep tahmininin kapsadığı zaman aralığı arttıkça talep sonuçları üzerindeki etkili değişken sayısı da artar. Değişkenler arası ilişki karmaşık ve belirsiz bir yapıya dönüşür. Uzun zamanlı talebin aksine kısa vadeli planlamalar için de zaman daraldıkça doğru değerlere yaklaşılr. Uygulamadaki küçük sapmaların belirlenmesinde etkilidir (Kobu, 2014).

Talep tahmininde öncelikli olarak yapılacak tahminin amacı belirlenmelidir. Tahmin edilecek konu ya da alan belirlendikten sonra tahminin hangi zamana hitap edeceği kesinleştirilmelidir. Geçmiş verilerden yola çıkarak, tahminde etkili olacak aynı zaman da çok eski tarihlerden kaçınarak yakın tarihler içinde güncelliğini sürdüren, tahmin yöntemi seçilmelidir. Analiz sonucunda gerçekleşen ve tahmin edilen değerlerin doğruluğu kontrol edilmelidir (Yalçın, 2013).

Yakın geçmişe ait verilerin kullanımı eski, güncelliğini kaybetmiş verilere kıyasla daha gerçekçi sonuçlar elde etmeyi sağlar. Baz alınan zaman ile verilerin oluşturulacağı zaman arası artıkça duyarlılık azalır. Tahmin için edilen verilere ait sonuçların hata analizi yapılarak standart sapma değerine göre en az sapma yapan model kullanılmalıdır. Grup değerlendirmesi yapılacak veriler için hitap ettiği zaman aralığı ne kadar kısa tutulursa o kadar verimli sonuçlar oluşturur. Talep tahmini elde bulunan sonuçlara göre uygulamaya koyulmadan önce doğruluğu netleştirilmelidir. Hata ve sapma değerlerine minimize edeceği çözüm önerileri geliştirilmelidir (Karahana, 2011).

Talep tahminini hatalı ya da eksik oluşturulduğu durumlarda belirlenen ürün ya da hizmet değerleri için mevcut talep eksik ya da fazla değerler oluşturur. Eksiklikler mevcut talebi karşılayamaz ve ek çözüm yöntemleri yapılmasını gerekli kılar ki bu da planlamalar dışında ek maliyetler oluşturur. Normal değerlerin üzerinde talep tahmini oluşturulması yatırımlarda zararlar meydana getirir.

Değişken üzerinde etkili olan faktörlerin tümünün işleme alınmaması, tahmin edilmek istenen konunun tam olarak belirlenmemesi tahmin değerlerinin net biçimde belirlenmesini, gerçekleşen değerlerin doğruluğunu tespit etmeyi zorlaştırır. Yani gerçeğe yakın değerlerin elde edilmesinin önünde büyük bir eksikliklerdir.

Ulaştırma sektörü için de talep tahmini ulaştırma sistemlerinin düzenli çalışmasını, işletme planlaması, yolcu yoğunluğunun yönetilmesi ve gelir yönetiminin kontrol altında tutulmasına yardımcı olur (Xie vd., 2014). Demiryollarında daha iyi hizmet sunmak, hat planlama ve zamanlamanın tahmin edilmesi için yolcuların seyahat seçme ölçütlerini belirlemeli ve uygun yolcu akışını verecek modeller oluşturulmalıdır (Hu vd., 2018).

Demiryolu talep tahmini temsili bir süre için oluşturulan tahminlere göre gelecek talebi potansiyel olarak yansıtmaya çalışır. Demiryolu talebi planlama ve yönetimin ana faktörüdür. Bu kapsam da demiryolu trafiği durumunun incelenmesi, sorunun tespit edilmesi ve eksik ya da yetersiz kısımların tahmin edilmesinde belirleyicidir (Bojovic ve Milenkovic, 2016).

Yolcu akışı tahmininde planlama dönemleri kısa, orta ve uzun vadeli dönemler olmak üzere 3'e ayrılır. Uzun vadeli planlamalar 3-15 yıl, kısa vadeli planlamalar bir sonraki hafta ile bir sonraki ay arasında oluşturulan planlamalardır (Chen vd., 2019). Orta vadeli planlamalar bir ay ile 2 yıl arasındaki süreci kapsar (Karahan, 2011). Uzun ya da kısa vadeli oluşturulan planlamalardaki demiryolu taşımacılığında fiyat esnekliği, ücretlerdeki artış taleplerin azalmasına neden olabilir (Kulshreshtha ve Nag, 2000).

Demiryolu çalışmaları uzun vadeli planlamalar çevresinde oluşturulmaktadır. Gelecek talebin yaklaşık değerlerde belirlenmesi, talebin karşılayacak çözüm yöntemleri ve stratejilerin geliştirilmesi demiryolu planlama sürecinde etkilidir. Yolcu talebini ticaret, eğitim, iş gibi rutin hareketlilik ya da keyfi yapılan seyahatler oluşturmaktadır.

3.1.1 Talep tahmin verilerini belirleme

Talep tahminin belirlenmesinde doğrudan ilişkili faktörlerin tespit edilmesidir. Talep fonksiyonu pazar dengesi, talep eğrisi, talebin fiyat ve gelir esnekliği, talep fiyat ilişkisi ve üretim faktörleri göz önünde bulundurularak değerlendirmeye alınır. Aşamalar şöyledir (Kobu, 2014; Tekin, 2012):

Bilgi toplama: Talep tahminin oluşturulması için gerekli faktörleri elde etmeye çalışmaktır. Talep konusunu ilgilendiren faktörlerin bir araya getirilmesi araştırma değerini veya geçerliliğinin belirlenmesinde önemlidir. Geçmişte kayıtları tutulmuş ilgili kaynaklardan değişkenlere ait verilerin değerleri elde edilir. Bilgi toplama hiçbir detayı atlamadan bütün faktörler göz önünde bulundurularak araştırmada etkili olacak bütün bilgileri kapsamalıdır. Bilgiler objektif ölçülere göre doğru şekilde ve eksiksiz toplanmalıdır.

Zaman tespiti: Talep tahmininde bilgi toplama tamamlandıktan sonra talebin hitap edeceği zaman dilimi belirlenmelidir. Zamansal değişikliklerinden talep üzerinde beklenen sonuçların oluşmasında kritik öneme sahiptir. Belirlenmiş zaman aralığı dışında bir zamana ait verilerin kullanılması sonuçta sapmalar oluşturur.

Talep tahmin yönteminin belirlenmesi: Analiz için belirlenen değişkenlerde duyarlılık, belirsizlik ve değişim gibi sebeplerden dolayı uygun yöntemin belirlenmesi veriler arasındaki çelişkileri ortadan kaldıracaktır. Talep araştırması için detaylı ya da yüzeysel analiz gerektiren yöntemleri uygun olduğu alanda kullanılmaması sonuca ulaşmayı da engeller.

Talep tahmini hata analizi: Tahmin edilen değerler ile gerçekleşen değerler arasındaki fark tahminde oluşan hatayı vermektedir. İki değer arasında hata oranı azaldıkça tahmin edilen değerlerin doğruluğu anlaşılır.

Tahmin modelinin açıklayamadığı hatalar tesadüfi hatalar; analiz yapmak için gerekli verileri toplarken yanlış bilgi elde etmek, değişkenler arasında bağlantılar oluşturamamak, mevsimsel faktörlerin etki ettiği analizde bu faktörleri işleme almamak ve hatalı eğilimlerin saptanmaması tesadüfi olmayan nedenler altında değerlendirilmektedir (Üreten, 2006).

Gerçekleşen değerler ile talep tahmin değerleri arasındaki fark hatayı verir. Hata değerleri elde etmek için ortalama mutlak sapma ya da hata kareleri ortalaması kullanılabilir. Ortalama mutlak sapma formülünde hatanın mutlak değeri alınarak veri sayısına bölünmesiyle tahmin hatası değerleri elde edilirken, hata kareleri ortalamasında hatanın kareleri işleme alınarak veri sayısına bölünmesiyle daha hassas hata değerlerini belirlemeyi sağlar.

$$\text{Ortalama Mutlak Sapma} = \frac{\sum_{i=1}^n |\text{Gerçekleşen değer} - \text{Talep tahmin değeri}|}{N} \quad (3.1)$$

$$\text{Hata Kareleri Ortalaması} = \frac{\sum_{i=1}^n (\text{Gerçekleşen değer} - \text{Talep tahmin değeri})^2}{N} \quad (3.2)$$

Tahmin değerlerinin gerçek değerlere yaklaştığını belirlemek için tüm verilerin hata karesi toplamı ortalama mutlak sapmaya bölünerek izleme sinyali hesaplanır. Toplam tahmin hata değerlerini mutlak sapma cinsinden ifade eder.

$$\text{İzleme Sinyali} = \frac{\sum_{i=1}^n (\text{Gerçekleşen değer} - \text{Talep tahmin değeri})^2}{\text{Ortalama mutlak sapma}} \quad (3.3)$$

Talep tahmin deęerlerinin uygunluęu: Tahmin edilen talep deęerlerinin gerekleřen deęerlere gre ne kadar tutarlı olduęunun tespit edilmesidir. Eęer gerekleřen deęerlerle arasında sapmalar varsa buna sebep olan sorunlar belirlenir. Hatalı kısımlar yeniden incelenerek gerek deęerlere en yakın deęerler elde edilmeye alıřılır.

3.1.2 Talep tahmin yntemleri

Talep tahmin yntemleri kantitatif, kalitatif ve yapay zeka yntemleri olarak ayrılır. Nicel tahminler talep tahmini iin gerekli deęiřkenler ya da gemiř verilere dayanan eřitli matematiksel hesaplamaları ierir. Nitel yntemlerde kullanılan veriler tecrbe, sezgi ve kiřisel yargılar yoluyla elde edilir. İlgili kuruluřlarda yer alan alıřan grřleri toplanarak model deęerleri belirlenir. Bu yntemler basit ve dřk maliyet ile oluřturulmasına raęmen tecrbeye dayalı olduęu iin model üzerinde uzman grř deęiřkenlik gsterebilir. Orta ve uzun vadeli planlamalarda bilgi alınan kiři iřinde en usta seviye de bulunsa da tahminleri yanıltıcı olabilir. Zaman serileri yntemi gelecekte oluřacak deęerleri gemiř kaynaklar ile iliřkilendirerek zm retmeyi saęlar (Kobu, 2014; Yalın, 2013).

Nitel yntemler grř toplama, Delphi yntemi, nominal grup, pazar arařtırması ve tarihi analog yntemler olarak ayrılır. Grř toplama yntemi tahmin de grřlerinin yararlı olacaęı bireylerin grřlerine bařvurularak elde edilir. Delphi yntemi tahmine ulařmak iin konu zerinde hemfikir grup dřncelerinden oluřur. Nominal yntemde Delphi yntemindeki gibi bir grup uzmanın bir araya gelerek tartıřma alanında fikir elde etmeleridir. Pazar arařtırma yntemi anket zerinden alıřmalar yapılabilir ancak zaman alıcı ve maliyetlidir. Tarihi analog ynteminde gemiřte benzer bir durum karřısında elde edilmiř deęerler kapsamında iřlem yapılır (reten, 2006).

Nitel yntemler fikirsel baęlantılarla oluřturulan konunun kelimeler, imgeler ve betimlemeler ile deęerlendirmeye alınır. Nitel yntemler kullanırken arařtırmacılar dřncelerini net bir biimde yansıtmalıdır. Nitel yntemler, konu hakkında tm deęerleri gz nnde bulundurarak alanında uzmanlařmıř bireylerden ya da bu bireylerden yardım alınarak analiz yapılır (Berg ve Lune, 2016).

Nitel yöntemler kullanılarak araştırma yapıldığında konuyla ilgili bilgi sahibi yönetim alanından sorumlu kişi ya da kişilerden destek alınır. Konuyla ilgili uzman görüşleri öznel değerlendirmeler doğrultusunda oluşacağı için farklılıklar gözlenebilir, ayrıca uzun zaman aralığında veriler sağlamayacağı için güncellik konusunda tutarlı değildir. Bu yöntemde daha iyi sonuçlar elde etmek için kullanıcılar üzerinde görüşlerini açık biçimde ifade edecek sorular yönlendirilerek elde edilen cevaplarla değerlendirme yapmakta mümkündür (Kobu, 2014).

Nicel yöntemler sayısal veriler toplanarak matematik denklemleri ve istatistiksel analiz yoluyla somut değerler üzerinden inceleme yapmayı sağlar. İlgili kaynaklardan yararlanarak güncelliğini koruyacak biçim de veriler temin edilebilir. Net değerler dikkate alınarak uygun analiz yöntemi ile sonuçlar belirlenir. Nicel yöntemlerin analizinde istatistiksel metotlar: nedensel, zaman serileri ve simülasyon yöntemleri olarak üç gruba ayrılır (Kobu, 2014; Yalçın, 2013).

Nedensel yöntemler: Tahminde etkili olacak değişkenlerin belirlenmesiyle ve aralarındaki ilişkinin matematiksel formüllerle ifade edilmesidir. Belirlenmek istenen değişken bağımlı değişken, bağımlı değişken üzerinde etkili olan değişkenler ise bağımsız değişken olarak nitelendirilir. Bağımsız değişken sayısı tahmin edilecek konuya göre farklı sayıda değişkenlerden oluşur. Regresyon analizi ile bağımlı ve bağımsız değişkenler arasındaki ilişki belirlenir. Bağımlı değişken, bağımsız değişkenlerin arasındaki bağlantılar yoluyla talep tahminin belirlendiği; bağımsız değişken, belirlenen verilerin bağımlı değişken üzerinde etkili olduğu değişkendir. Regresyon analizinde de bu değişkenler arasındaki nedensellik değerlerine göre tahmin elde edilir.

Zaman serileri yöntemi: Geçmiş verilerden faydalanarak gelecek ile ilgili tahminlerin elde edilmesinde kullanılır. Zamansal faktörler bağımsız değişkeni temsil eder. Zamansal değişimin bağımlı değişken üzerindeki etkisi incelenir. Zaman serileri geçmişteki değişim biçiminin gelecekte de devam edeceği varsayımına dayanır. Dönemsel ve mevsimsel değerlerdeki değişimler talebi etkiler. Dönemsel talep uzun bir süreci kapsayan ekonomik faktörlerin etkisine bağlı değişimlerdir. Mevsimsel talep mevsimlik, aylık ya da günlük olarak değişkenlik gösterir.

Simülasyon yöntemi: Model için belirlenen değişkenler arasındaki ilişki sade bir yapıdaysa matematiksel yöntemlerle çözüm yapmak uygundur. Ancak bazı modellerin yapısı karmaşık olduğunda matematiksel yöntemler çözüm için uygun olmayabilir. Bu gibi modellerin çözümünde simülasyon yöntemleri daha iyi sonuçlar verecektir (Law ve Kelton, 1991). Talep yöntemleri Çizelge 3.1’de kısaca açıklanmıştır.

Çizelge 3.1. Talep yöntemleri (Monks, 1996).

Yöntem	Tanım	Dönem
Yönetici Görüşleri	Tahmin ile ilgili konuda yetkili çalışanların bir arada değerlendirmeler yaparak ortak bir noktada toplanmaları ile elde edilen sonuçlardır.	Kısa- Uzun
Tarihi Analog	Daha önce kullanıma sunulan benzer ürün/ürünleri değerlendirip karşılaştırma yoluyla tahmin yapılmasıdır.	Kısa- Uzun
Delphi	Konu hakkındaki bilginin uzman görüşlerinin dikkate alınması, geri besleme sağlamaları ve tahmin sonuçlarını değerlendirmeleridir.	Uzun
Pazar araştırma	Tüketici görüşlerinin değerlendirilmesi için anket ya da görüşme yoluyla bilgi toplayarak talep tahmininde bulunmaktır.	Orta- Uzun
Hareketli Ortalamalar	Belirlenen döneme en yakın n sayıdaki değişkenin ortalamasıdır.	Kısa
Trend Analizi	Geçmiş değerlerin eğilimlerini doğrusal, üssel ya da başka bir biçimde tasvir edilmesidir.	Orta- Uzun
Ayrırma	Zaman serileri üzerinde değişkenliklerin sebep olduğu mevsimsel, dönemsel, trend ve tesadüfi olayların belirlenmesidir.	Kısa- Uzun
Üssel Düzeltme	Zamansal değerlerin ağırlıklandırılması ile belirlenen zamana yakın değerler daha fazla ağırlık verilmesi ile oluşturulur.	Kısa
Box-Jenkins	Bir zaman serisine regresyon modeli önerilerek istatistiksel olarak değerlendirilir, değiştirilir ve uygun yöntem elde edene kadar deneme yapılır.	Orta- Uzun
Regresyon-Korelasyon	Bir ya da daha fazla değişken arasında EKK denklemiyle tahmin etme veya değişkenler arasındaki ilişkinin belirlenmesi	Kısa- Orta

3.1.3 Talep tahmininde sayısal yöntemler

İstatistiksel yöntemler nitel verilerden yola çıkarak oluşturulan faktörler arasında analiz yaparak tahminde bulunmayı sağlar. Geçmişteki verileri ışığında gelecekle ilgili varsayımlar oluşturur. Somut değerler ile analiz yapıldığı için tahminlerde oluşan değerler matematiksel ispatlara dayanır. Değişkenler arasındaki ilişkinin karmaşık olduğu ya da nicel yöntemlerin tahminleri elde etmede verimli sonuçlar oluşturmadığı modellerde sayısal yöntemler daha iyi tahminler oluşturur (Kobu, 2014).


Bağımlı değişken belirlenen bir konu üzerinde doğrudan ilişkili faktörlerden etkilenen ve tahmin edilmeye çalışılan sonuç değerini ifade etmektedir. Bağımsız değişken bağımlı değişken üzerinde etkili olan, birden fazla faktör ile bağımlı değişken değerini açıklamaya yardımcı olur.

Sayısal tahmin yöntemleri kullandıkları verilere göre nedensel ve zaman serileri olarak ikiye ayrılır. Nedensel yöntemler talepte etkili olacak geçmiş veriler ile birlikte talebi etkileyen diğer değişkenlerin regresyon yöntemi, korelasyon analizi gibi hesaplamaları içerir. Zaman serileri yöntemi geçmiş veriler kullanılarak hareketli ortalamalar, üssel düzeltme ve trend analizi modelleri ile hesaplanır (Karahana, 2011).

3.1.3.1 Regresyon analizi

Regresyon analizi iki ya da daha fazla değişken arasındaki ilişkinin tahmin edilmesinde popüler istatistik araçlarından biridir. Bağımlı değişken ve bağımsız değişken arasındaki bağlantılarda bağımlı değişken üzerinde etkili olan bağımsız değişkenlerin etkilerine göre ayırt edilmesini sağlar. Basit regresyon analizi yalnızca iki değişken arasındaki ilişkiyi değerlendirir. Değişkenler arasındaki temel değişimlerden tahmin değerleri oluşturulabilir. Çoklu regresyon analizi ikiden fazla değişken arasındaki durumu değerlendirir. İki ya da daha fazla bağımsız değişken kombinasyonunun etkilerini değerlendirerek bağımlı değişkenin alacağı değerler belirlenmeye çalışılır (Anderson vd., 2010; Archdeacon, 1994).

Regresyon analizinde ilk adım ağırlık ya da katsayıların belirlenmesidir. Denklemden bağımsız değişkenler tanımlandığında bağımlı değişken değerlerine daha yakın sonuçlar elde edilir ve değişkenlerin önemlerini belirlemeye yardımcı olur (Anderson vd., 2010; Archdeacon, 1994). En küçük kareler yöntemi Şekil 3.1’de belirtilmiştir.



Şekil 3.1. Regresyon doğrusu ve en küçük kareler yöntemi (Üreten, 2006).

En küçük kareler yönteminde tahmin edilen değerler ile gerçekleşen değerler arasındaki farkın kareleri toplamının en küçük değeri alacağı yeni bir doğru belirlenir. Bu doğru şöyle yorumlanır: tüm dikey tahmin hatası sıfırdır ve hata karelerinin toplamı en küçük değeri alacak şekilde düzenlenmiştir. Değişkenler arasındaki ilişki bir doğru ile ifade edilmezse uygun bir sınırlar içerisinde kalacak biçimde eğri uydurma yöntemi ile bir doğru çizilir (Üreten, 2006; Tekin, 2012).

Basit doğrusal regresyon denklemi:

$$Y = a + bX \quad (3.4)$$

Denklemden Y bağımlı değişkeni, X bağımlı değişkeni ifade etmektedir. a ve b katsayılarının değerleri en küçük kareler yöntemi ile belirlendikten sonra denklemden yerine koyularak bağımlı değişken değerleri hesaplanır. Denklemden a ve b katsayıları aşağıdaki gibi hesaplanır:

$$a = \frac{(\sum Y) - b \sum X}{n} \quad (3.5)$$

$$b = \frac{n(\sum XY) - (\sum X)(\sum Y)}{n(\sum X^2) - (\sum X)^2} \quad (3.6)$$

Çoklu doğrusal regresyon denklemi:

$$Y = a + b_1X_1 + b_2X_2 + \dots + b_nX_n \quad (3.7)$$

Üssel regresyon denklemi: (Ballı, 2015)

$$Y = a + b_1^x \quad (3.8)$$

Eğrisel regresyon denklemi:

$$Y = a + b_1X + b_2X^2 + \dots + b_nX^n \quad (3.9)$$

$Y = a + bX$ denkleminde her gerçek X_i değeri için Y_t tahmini oluşturulabilir. Bağımlı değişkene ait gerçek değerler ve tahmin edilen değerler arasındaki fark tahmin hata derecesini veya duyarlılığını ifade eder. Standart hata aşağıdaki gibi formüle edilir (Kobu, 2014).

$$S_{y,x} = \sqrt{\frac{S(Y_i - Y_t)^2}{n-2}} \quad (3.10)$$

3.1.3.2 Korelasyon analizi


Bağımlı değişkene ait gerçek değerleri elde edilmemesi varyans ve standart hatanın yorumlanmasında yanıltıcı olabilir. Bağımlı değişken değerleri küçük ölçekte seçilirse hata küçük, büyük ölçekli seçilirse hata daha büyük değerler alır. Korelasyon katsayısı ile bağımlı ve bağımsız değişken arasındaki ilişki derecesi belirlenir. Bu ilişki derecesine göre tahmin değerlerinin doğruluğunun belirlmesine yardımcı olur. Değişkenler arasındaki ilişki arttıkça tahmin edilen değerde gerçek değere yaklaşır (Kobu, 2014; Üreten, 2005).

Çok değişkenli regresyon analizinde bağımsız değişkenler ile bağımsız değişken arasında korelasyon en iyi açıklayacak biçimde ele alınır. Bağımsız değişkenlerin en iyi tahmin oluşturabilmesi için değişkenlere ağırlık değerleri atanır (Anderson vd., 2010).

Korelasyon denklemi:

$$r = \frac{n \sum XY - (\sum X)(\sum Y)}{\sqrt{(n (\sum X^2) - (\sum X)^2)(n (\sum Y^2) - (\sum Y)^2)}} \quad (3.11)$$

Korelasyon katsayısı (r) -1 ile 1 arası değerler alır. Korelasyon katsayısı (0,1] aralığının da pozitif doğruyu, [-1,0) aralığında negatif doğruyu temsil eder. Korelasyon katsayısının 0 değerine sahip olması değişkenler arasında ilişki olmadığını belirtir. Korelasyon katsayısı +1'e yaklaştıkça güçlü pozitif ilişkiyi, -1'e yaklaştıkça değişkenler arasında güçlü negatif ilişkinin olduğunu belirtir. Bağımsız değişkende ki değişimler tesadüfi veya belirsiz nedenler, bağımsız değişken etkisi ve bağımsız değişken ile birlikte tesadüfi nedenleri kapsayan toplam değişimlere bağlıdır (Kobu, 2014; Tekin, 2012). Korelasyon değerleri arasındaki ilişki Şekil 3.2'de gösterilmiştir.



Şekil 3.2. Korelasyon katsayısı değerleri ve anlamları (Monks, 1996).

Bağımsız değişken değeri artıp bağımlı değişken azalıyorsa korelasyon negatif değerler alır. Bağımlı değişken artarken bağımlı değişken de artıyorsa değişkenler arasında pozitif ilişkiyi ifade eder (Üreten, 2006).


Değer 1'e yaklaştıkça ilişki güçlenir, -1'e yaklaştıkça ilişki zayıflar. Regresyon doğrusunun eğimine göre r katsayısının işareti belirlenebilir. Bir başka deyişle b katsayısının işareti r katsayısı ile daima aynı değere sahiptir (Üreten, 2006).

3.1.3.3 Zaman serileri

Bağımsız değişken değerlerinin ardışık ve eşit aralıklı zaman dilimlerindeki saat, gün, ay gibi zaman ölçüsünün temsidir. Geçmiş veriler kullanarak geleceğe ait değerlerin oluşturulmasında geçmişteki etkinin gelecekte de süreceği varsayılır. Ani ya da beklenmedik değişimlerin oluşabileceği alanlarda zaman yönteminin kullanılması doğru sonuçlar elde etmekte sınırlayıcı olabilir (Kobu, 2014).

Baz alınan bir döneme ait talep verileri oluşturulurken zamansal bir sıralamaya göre talep doğrusu belirlenir. Talep doğrusundaki ilerleyiş dikkate alınarak gözlemlenir. Bunun sonucunda doğrunun sabit, bir yönde eğimli, mevsimsel, dönemsel ya da tüm bu değişimlerin hepsini içeren değişimlerden hangisini geçirip geçirmediği tespit edilebilir. Uzun dönemli talepler dönemsel olarak farklılıklar gösterebilir ve trend doğrusu üzerinde dalgalanmalar oluşturur. Bu dalgalanmaların sebebi ekonomik, politik, teknolojik vs. faktörlerden kaynaklanmaktadır. Zaman içerisinde artan ya da azalan bir değer izleyen değişkenlerin eğilimleri dikkate alınarak analiz yapılır. Şekil 3.3'te mevsimsel doğrusal ve sabit değerlere göre talep tahmin davranışlarının nasıl davranış gösterdiği verilmiştir (Üreten, 2006). Sabit değişken zaman içerisinde herhangi bir faktörden etkilenmeden aynı durumunu koruyarak ilerler.

Zaman serileri durağan ve durağan olmayan seriler olarak ikiye ayrılır. Durağan zaman serilerinde belirlenen zaman aralığında belli noktalardaki gecikmelerin hata değerleri ya da ağırlıklı toplamaları değişken olarak kabul edilir. Durağan zaman serileri Trend analiz, Fark Analizi, Otoregresif Süreç (AR), Hareketli Ortalama (MA), Otoregresif Hareketli Ortalamadır (ARMA). Durağan olmayan zaman serilerinde pek çok nedenden dolayı değişkenlikler gösterir. Bu zaman serileri Otoregresif Bütünleşik Hareketli Ortalamalar Süreci, Box-Jenkins yöntemini içerir (Göktaş, 2005).



Şekil 3.3. Zaman serilerine göre talep değişimi.

Hareketli Ortalamalar: Değişken bilgilerinin güncelliği dikkate alınarak, eski bilgi değerlerinin yeni bilgiler ile değiştirilmesi, hareketli ortalamalar yöntemi ile hesaplanır. En eski değer çıkarılıp yeni değer eklenerek tekrar ortalama alınır ve sonuç bir sonraki dönemde tahmin değerini verir. Hareketli ortalamalar kontrol edilmeyen değişkenlerin oluşturduğu değişimleri minimize etmede kullanılmaktadır. Ortalama için belirlenen dönem aralığı kadar veriye gereksinim duyulur. Hareketli ortalama baz alınan bir zaman aralığındaki değerlerin basit aritmetik ortalama hesabı ile belirlenir (Kobu, 2014; Üreten, 2006).

Hareketli ortalamalar yönteminde üç, dört, altı ve on iki aylık dönemlerde talep ortalamaları hesabı yapılabilir. En çok 3 aylık dönemler kullanılarak hesaplama yapılır (Tekin, 2012).

Üssel Düzeltme: Hareketli ortalamalarda en yakın geçmişe daha fazla ağırlık verilerek geçmiş verilerin üssel olarak ağırlıklandırılan tahmin yöntemidir (Monks, 1996). Tesadüfi olaylardan kaynaklanan değişimleri ortadan kaldırmaya çalışmaktır. Düzeltme katsayısı ile talebi belirlemek için basit aritmetik ortalama yerine son gerçek değerler ve tahmin değerlerine düzeltme katsayısının belirlendiği uygun ağırlıklar verilerek bir ortalama alınır. Zamansal olarak yakın tarihli değerlere daha fazla ağırlık verilerek işleme alınır (Kobu, 2014; Üreten, 2006).

Üssel düzeltme yönteminde tahmin için bir önceki döneme ait gerçekleşen ve tahmini değerlerinin bilinmesi yeterlidir. Düzeltme katsayısı $0 \leq \alpha \leq 1$ arası değerler alır. Düzeltme katsayısı sıfıra yaklaştıkça bir önceki döneme ait hata göz ardı edilebilir. Tesadüfi olaylardan kaynaklı değişimlerin fazla olduğu durumlarda da düzeltme katsayısını değerini küçük tutmak daha doğru sonuçlar elde etmeyi sağlar (Kobu, 2014; Üreten, 2006).

Eğilim Analizi: Uzun dönemli talep tahmini için yıllara göre verilerde dalgalanmaların oluşmasını en iyi trend analizi açıklar. Zaman bağımsız değişken olarak kullanır ve tahmin oluşturulur. Trend modelinde zamansal değişimler lineer ya da non-lineer davranış gösterebilir (Bozkurt, 2013; Üreten, 2006).

Otoregresif Süreç: Zaman serisi kendine ait gecikmeli değerleri bir fonksiyon biçiminde tanımlamasıdır. Bağımlı değişkenin belirlenen bir zamandaki değeri bir önceki döneme ait değerler ile hata terimi etkiler (Göktaş, 2005).

Otoregresif Hareketli Ortalamalar: Hareketli ortalamalar ve fark denkleminin birleştirilmesi ile oluşturulan bu modelde fark denkleminin homojen bölümü p gecikmeleri, hareketli ortalamalar q gecikmeleri ifade eder ve ARMA(p,q) biçiminde gösterilir (Göktaş, 2005).

Box-Jenkins Yöntemi: Gelecek ile ilgili oluşturulacak bir tahmin için deneysel modeller geliştirerek en uygun modelin belirlenmesini sağlar. Zaman serileri yönteminde en sık tercih edilen yöntemdir. Zaman serilerinin durağanlığı belirlenerek hangi modele uygun olduğu tespit edilir (Bozkurt, 2013; Göktaş, 2005).

Otoregresif Bütünleşik Hareketli Ortalamalar: Stokastik nedenlerden kaynaklanan durağan olmayan serilerin farklarının alınması ile durağan hale getirilir. Durağanlığın d. Mertebeden olması serinin d. mertebeden bütünleşik olduğu anlamına gelir. Tahmin modellerinde verilerle model uyumu belirlenmesi için Ortalama Hata Kare (MSE), Kök Ortalama Hata Kare (RMSE), Ortalama Mutlak Hata (MAE), Ortalama Mutlak Yüzde Hata (MAPE), Ortalama Yüzde Hata(MPE) ve Kök Ortalama Yüzde Hata Kare (MSPE) en yaygın kullanılan denklemlerdir (Göktaş, 2005).

$$RMSE = \sqrt{\frac{\sum(Y^T - Y^G)^2}{t-k}} = \sqrt{MSE} \quad (3.12)$$

$$MAE = \frac{\sum|Y^T - Y^G|}{t-k} \quad (3.13)$$

$$MAPE = \sum \left| \frac{Y^T - Y^G}{Y^G} \right| \cdot \frac{100}{t} \quad (3.14)$$

$$MPE = \frac{1}{t-k} \cdot \sum \left(\frac{Y^T - Y^G}{Y^G} \right) \quad (3.15)$$

$$MSPE = \sqrt{\frac{1}{t-k}} \cdot \sum \left(\frac{Y^T - Y^G}{Y^G} \right)^2 \quad (3.16)$$

3.1.3.4 Simülasyon yöntemi

Simülasyon yönteminin amacı, belirlenen dönemde talep tahmini için sistem davranışını ve tepkisinin belirlenmesi sağlar. Basit problemlerde işlem için çok fazla matematiksel formül gerekmeden analiz yapılabilir. Ancak problemlerin büyümesi veya karmaşık hale gelmesi matematiksel yaklaşımlar modelleme ve çözüm için eksik kalabilir. Modele etki edecek girdi, çıktı ve süreç değişkenleri belirlenerek geçmiş verilerden ya da hayali olarak kabul edilmiş değişkenler farklı kombinasyonlarda uyarlanıp sonuç gözlenir. Girdi ve süreç değişkenleri değiştirilerek farkların gözlemlenebilmesi için birkaç kez çalıştırılır (Monks, 1996; Üreten, 2006).

Geçmiş olaylardan çıkarım yapıp bu olayların taklit edilmesi ile gerçek olayları yansıtmaya çalışmaktır. Simülasyon yönteminin amacı, belirlenen koşullar altında sisteme ait karakterleri araştırmak, çeşitli seçenekleri değerlendirmek ve olma olasılığını belirlemektir. Yani doğrudan sonuç elde edemez. Matematiksel yöntemler tahminde genel çözümler oluşturur. Bazı karmaşık yapıdaki modellerde diğer yöntemler etkili sonuç vermeyebilir. Modelin çok karmaşık olduğu, analitik ya da nümerik değerlendirmeyi elde etmenin zor olduğu durumlarda benzetim yöntemini kullanmak daha yararlıdır (Top ve Yılmaz, 2013; Yüksel, 2010).

Simülasyon yöntemi özel çözümler sunabilir ancak sistemin bütün şartlar altında bir çözüm üretmesi için değişik şartlarda tekrarlanması gerekmektedir. Böylece uygulamada uzun bir zaman gerektiren, maliyetli ve tehlikeli olayların değerlendirilmesinde daha ucuz, kısa sürede sonuç elde edecek ve güvenli bir yöntemdir (Top ve Yılmaz, 2013; Yüksel, 2010).

Simülasyon yöntemi deterministik veya stokastik, kesikli veya sürekli olarak ikiye ayrılır. Rastgele gerçekleşen olaylar etrafında oluşturulan simülasyon modelleri stokastik, rastgele olayları içermeyen değişkenler deterministik modelleri ifade etmektedir. Zaman içerisinde modelde artma azalma olmadan ilerliyorsa sürekli, belirli zamanlarda süreklilik sağlamıyorsa kesikli modeli temsil etmektedir (Yüksel, 2010).

Simülasyon yöntemi karmaşık ve matematiksel çözümü olmayan problemlerin çözümlenmesinde, uzun dönemli etkilerin belirlenmesinde, zamanda gerçek sistemlerin faaliyet halindeyken oluşabilecek risklerin önceden tespit edilmesinde avantajlıdır. Ancak, bir çözüm metodolojisi ve en uygun çözümü sunmayabilir, karmaşık ve kapsamlı modellerde uzmanlık gerektirir ve deterministik problemlere uygulanamaz (Monks, 1996).

3.1.4 Talep tahmininde duyarlılık

Gerçek değerler ile tahmin değerleri arasındaki sapmalar tahmin duyarlılığını ifade eder. Analiz tahmin değerleri elde edildikten sonra gerçek değerler de dikkate alınarak yapılır. Sapmalar kabul edilebilir sınır üzerinde değerler aldıkça hatanın kaynaklandığı durumlar belirlenerek düzeltilir. Hatanın kaynaklandığı bazı nedenler şöyledir (Kobu, 2014):

1. Tahminde etkili olan önemli bir değişkenin işleme alınmaması,
2. Çevresel koşullardan kaynaklı değişken özelliklerindeki önemli değişimler,
3. Ani değişimler (trend, dönemsel değişimler gibi),
4. Doğal afetler, ekonomik durgunluk, sosyal ve politik alanlardaki gerginliklerden kaynaklı yapısal değişimler,

5. Yanlış tahmin yöntemi uygulanması ya da yorumlanması,

6. Tesadüfi olaylar.

Talep tahmininde yanlış yöntemin seçilmesi durumunda sonuçta oluşacak hataları düzeltmek için değişik hata tahmin ölçümleri kullanılıp en düşük hata değerini oluşturan değer dikkate alınarak işleme devam edilebilir. En yaygın kullanılan hata ölçüm yöntemleri ortalama mutlak sapma (MAD), ortalama sapma (BIAS), hata kareleri ortalaması (MSE) ve izleme sinyalıdır. MAD ortalama hata miktarını, BIAS negatif ya da pozitif değerlere göre hata yönünü, izleme sinyalı tahmin boyunca hataların değişimini verir. Hata tahmin ölçümleri aşağıdaki gibidir (Kobu, 2014). A gerçekleşen değerleri, F tahmin değerlerini temsil etmektedir.

$$MAD = \frac{1}{n} \sum_{i=1}^n |A_i - F_i| \quad (3.17)$$

$$BIAS = \frac{1}{n} \sum_{i=1}^n (A_i - F_i) \quad (3.18)$$

$$MSE = \frac{1}{n} \sum_{i=1}^n (A_i - F_i)^2 \quad (3.19)$$

$$\text{İzleme Sinyalı} = \frac{\sum_{i=1}^n (A_i - F_i)}{MAD} \quad (3.20)$$

İzleme sinyalı pozitif ve negatif yönde 3 ile 8 arasında değerler alır. İzleme sinyalı değeri gerçek verilerin tahmin verileri arasındaki mutlak hatayı ifade eder. Negatif değerler, gerçek değerlerin tahmin değerlerinin altında olması durumunda oluşur (Üreten, 2006).

3.1.5 Talep tahmininde yapay sinir ağları

Yapay sinir ağları girdi ve çıktı değişkenleri arasında ön bilgiye gerek duymadan lineer ya da non-lineer modelleme yapabilir. Bu yüzden diğer yöntemlere göre tahminin belirlenmesinde daha esnek ve genel yapıdadır. Yapay sinir ağları zaman serileri yöntemi ya da nedensel yöntemler kullanılarak model oluşturulabilir (Hamzaçebi, 2011).

Ücret değişiklikleri yolcuları göreceli olarak etkiler. Farklı seyahat türleri ve rotaları bir araya getirmeye çalışmak yeni ihtiyaçlar meydana getirebilir. Yolculuk amacına göre en büyük kapasite sorunu için tahminler bilet türüne göre oluşturulur. Gayri safi yurtiçi hasılanın esnekliği kişi başı geliri arttıracığından demiryolu taşımacılığı da o yönde aratacaktır. Nüfus artışı daha hızlı gelişen bölgelerde üretkenlikleri arttıracığından talep de bu doğrultuda artacak ve gelişme gösterecektir (Worsley, 2012).

Ulaştırma sektöründe yolcu tahmini ya da planlamalar için faydalanılan pek çok uygulama da yapay sinir ağların geri yayımlı ağ yapısı tercih edilmektedir. Trafik tahmini stratejik tahminler ve kısa vadeli tahminler olarak değerlendirilebilir. Stratejik tahminler aylar ve yıllara göre geleceğe yönelik trafik akışı ve yol planlamaları için uygun yöntemin belirlenmesini, kısa vadeli tahminler anlık değerlerden yola çıkarak trafik kontrol sistemlerini etkiler (Dougherty, 1995). Yapay sinir ağları 2. kısımda daha detaylı bir biçimde incelenmiştir.

3.2 Yapay Sinir Ağları

3.2.1 Yapay sinir ağlarının genel tanımı ve tarihi

Bilgisayar sistemleri karmaşık problemleri kolaylıkla çözebilirler. Ancak olayı anlama ve tecrübeler dayalı çözümler üretmekte başarısızdır. İnsan beyni mantıksal ve indüktif bilgi edinme yöntemlerini benzetmeye yönelik problem çözme yetisi gerekli araçları kapsar. Yapay zeka bilgisayar sistemlerine insan beyninin temel özellikleri entegre edilerek oluşturulmuştur (Agatonovic-Kustrin ve Beresford, 2000; Elmas, 2007).

Yapay zeka Uzman Sistemler (US), Bulanık Mantık (BM), Genetik Algoritma (GA) ve Yapay Sinir Ağları (YSA) olmak üzere dört gruba ayrılır. US uzman görüşlerinin bilgi ve tecrübesi dikkate alınarak bilgisayara aktarılmasıyla insan düşüncelerini gerçekleştirmeye çalışır. BM insan davranışlarını, tecrübe ve öngörülerini sayısal değerler yerine sembolik ifadelerle ara değerlere göre çalışır. GA geleneksel yöntemlerin çözemediği problemlerin çözümünde kullanılır (Elmas, 2007).

ANFIS (Adaptive Network Based Fuzzy Inference System) yapısı hem bulanık mantık hem de sinir ağlarının bir arada kullanılmasıyla oluşmaktadır. Yapı olarak 5 katmanlı ileri beslemeli yapay sinir ağı, bulanık mantık sistemlerindeki eğer-ise kuralları ve girdi-çıktı bilgi çiftleri, eğitilmesinde ve denetlenmesinde yapay sinir ağlarının öğrenme algoritmalarından meydana gelmektedir (Caner ve Akarslan, 2009).

İnsan beyninin davranışları dikkate alınarak bilgisayar programları üzerinde uyarlanması ile oluşturulan YSA, beyin fonksiyonlarını biyolojik sinir sistemlerinin çalışma şeklini cihazlar üzerinde gerçekleştirir. Öğrenme yolu ile herhangi bir yardım almadan yeni bilgiler oluşturabilir. Yapay sinir hücrelerinden oluşan YSA birbirini ile bağlantılı çalışır. YSA biyolojik sinir hücrelerinin davranışlarını temel olarak basit elamanları olan nöronlar tarafından bilgi işlenir. Nöronlar arasındaki bağlantılar, bir bağlantı bir ağırlığa eşittir, aracılığıyla sinyaller iletilir. Çıktı değerlerine girdi katmanındaki bilgilerin taşınması ile elde edilir. YSA öğrenme, ilişkilendirme ve özellik belirleme yöntemleri ile sınıflandırma, modelleme ve tahmin alanlarında kullanılmaktadır (Elmas, 2007; Hamzaçebi, 2011; Öztemel, 2003).

Yapay sinir ağları yapısında farklı mimariler ya da paradigmlar bulundurmaktadır. Bu paradigmların işleyişi farklılık gösterse de temel özelliklerinin bazıları kendi aralarında paylaşılır. Nöronlar gerekli verilerin temin edilmesiyle transfer fonksiyonuna taşındıktan sonra girdi değerlerine bağlı çıktılar oluşturur. Nöronlar ağırlıklı olarak birleştirilip bu ağırlıklara göre ölçeklendirilir. Doğrusal olmayan hesaplamalardan dolayı bir nöron çıktısı başka bir girdi katmanında kaynak olarak kullanılabilir (Dougherty, 1995).

Yapay sinir ağları 1943 yılında Warren McCulloch ve Walter Pitts tarafından keşfedilmiş ve elektrik devreleri ile basit bir sinir ağı oluşturmuşlardır. Winner 1948 yılında yayınladığı “Cybernetics” kitabında sinir davranışların tanıttı. 1949-1956 yılları arasında Hebb öğrenme ile ilgili temel davranışları işlediği “Organizations of Behaviour” yazmış ve Hebb Kuralını çıkarmıştır. Gabor hata karelerine bağlı ağırlıkların tespiti için dik inişli algoritma yardımı ile öğrenme süzgecini icat etmiştir (Elmas, 2007; Hamzaçebi, 2011).

1956 yılında Rochester ve arkadaşları tarafından öğrenme varsayımlarına dayanan sinir teorisini test etmek için ilk bilgisayar simülasyonunu geliştirmişlerdir. 1958 yılında Rosenblatt öğrenme modelini geliştirerek algılayıcı olarak adlandırılan tek çıkışa sahip tek katmanlı eğitilebilen yapay sinir ağını keşfetmiştir (Elmas, 2007; Hamzaçebi, 2011).

1959 yılında Widrow ve Hoff ADALINE ve MADALINE modelini geliştirmişlerdir. 1969 yılında Minsky ve Papert, basit algılayıcıların sınırlarını göstermiş ve 1982 yılına kadar YSA ilk başlarda verilen önem azalmıştır. 1982 yılında Hopfield sinir ağlarının çalışma biçimini matematiksel değerlerle sunmuştur ve YSA yeniden önem kazanmıştır. 1984 yılında Kohonen danışmansız ağ özelliklerini geliştirmiştir. 1986 yılında Rumelhart ve McClelland tarafından geri yayımlı öğrenme algoritması geliştirilmiştir. 1988 yılında Broomhead ve Lowe tarafından sayısal analiz ve doğrusal adaptif filtreleme alanlarını sinir ağlarıyla entegre edilmesi için Radyal Tabanlı Fonksiyon Ağlarını geliştirmişlerdir (Elmas, 2007; Hamzaçebi, 2011).


3.2.2 YSA yapısı

3.2.2.1 Biyolojik sinir hücresi ve yapay sinir ağlarının yapısı

YSA kullanılarak çözülmek istenen sorunlar için hem literatür hem de deneysel sonuçlardan faydalanmak yarar sağlamaktadır (Agatonovic-Kustrin ve Beresford, 2000). Bu yüzden yapay sinir hücrelerinin çalışma düzenini oluşturmak için biyolojik sinir hücrelerinin yapısı ve davranışlarını kavramak önemlidir.


Biyolojik sinir hücresi sinaps (sonlandırıcı düğümler), axon, soma, çekirdek ve dentritlerden oluşmaktadır. Biyolojik sinir hücresi bilgiyi aldığı anda hücreler arası bağlantıların sağlandığı sonlandırıcı düğümlere gelen bilgi akson aracılığı ile somaya gider. Soma bilgiyi işleyip değerlendirdikten sonra dentritlere gönderilir. Dentritlerden tekrar sonlandırıcı düğümlere iletilerek bu bilgi sinir hücrelerini oluşturan diğer hücrelere aktarılır. Sinaps ağırlıkları bilginin hafızada tutulmasını sağlar. Tüm bu işlemler çok kısa bir sürede gerçekleşir.

Yapay sinir ağıları biyolojik sinir hücresi yapısından esinlenerek snapslardan alınan bilginin somada işlenip aktarılmasını tasvir eden bir yapıya sahiptir. Ağ yapısının tam olarak oluşturulması için beyin davranışlarının belirlenmesinde çeşitli yapay sinir ağı modelleri oluşturulmuştur. Biyolojik sinir ağlarıyla benzer biçimde girdi katmanından alınan bilgi işlenerek sonuçlar çıktı katmanına iletilir (Öztemel, 2003). Hücre yapısı Şekil 3.4’te gösterilmiştir.




Şekil 3.4. Biyolojik hücre yapısı (Öztemel, 2003).

Hücre yapısı birbiri ile bağlantılı biçimde girdi, ara ve çıktı katmanlarından oluşur. Girdi katmanı gerekli bilgiyi dışarıdan alarak ara katmana iletir. Girdi katmanında sonucu istenen konuyu etkileyen bir ya da birden fazla değişken bulunabilir. Ara katmanda bilgi işlemden geçerek çıktı katmanına iletilir. Çıktı katmanında alınan oluşturulan yeni bilgiyi sunar. Katman arasındaki bağlantılar bilginin aktarılmasında rol alır. Katmanlar arasındaki bilgi aktarımını sağlayan bağlantılar biyolojik hücre yapısındaki axon görevi görür (Elmas, 2007).



Şekil 3.5. Yapay sinir ağının yapısı.

Şekil 3.5'te ağ şeması belirtilmiştir. Şekil 3.6'da belirtildiği gibi sinir ağlarının süreç elemanları girdi, ağırlıklar, toplam fonksiyonu, aktivasyon fonksiyonu ve hücre çıktısından oluşmaktadır. Girdi katmanında sunulan değişkenlerin etkileri ağırlıklarla ifade edilir. Ağırlık değerleri değişkenlerin hücre üzerindeki bilginin önemini ve etkisini gösterir. Ağırlıkların büyük ya da küçük olması ağ üzerindeki bilginin önemsiz ya da değersiz olduğunun belirtmez. Negatif ya da pozitif değerlere sahip ağırlık değerleri değişkenlerin üzerinde olumlu ya da olumsuz etkiyi ifade eder. Ağırlıkların belirlenmesi çıktının doğruluğu üzerinde etkilidir (Öztemel, 2003).



Şekil 3.6. Yapay sinir ağı hücre yapısı.

Toplam fonksiyonu, alınan bilgiye ait net girdiyi hesaplar. Bu elemana gelen her bilgi kendi ağırlığı ile çarpıldıktan sonra toplam değer belirlenir. Bu işlemin amacı ağa gelen net girdinin elde edilmesidir (Öztemel, 2003).

Çözümü istenen bir sorun için uygun bir yönteme ait net bir uygulama olmadığından deneme-yanılma yoluyla belirlenir. Toplama fonksiyonuna ait birçok formülasyon vardır. Net girdinin belirlenmesinde çarpım, maksimum, minimum, çoğunluk, birikmiş yöntemler kullanılır (Öztemel, 2003).

$$NET = \sum_i^n G_i A_i \quad (3.21)$$

Çarpım yönteminde ağırlıklara ait değerler ile girdi değerleri çarpılarak elde edilen değerler kendi aralarında tekrar çarpılıp net değer elde edilir.

$$NET = \prod G_i A_i \quad (3.22)$$

Maksimum ve minimum yönteminde girdi değerleri ağırlık değerleri ile çarpılıp sonuç içerisinde en büyük ya da en küçük değer net girdi olarak belirlenir.

$$NET = \text{Max}(G_i A_i); \text{Net} = \text{Min}(G_i A_i) \quad (3.23)$$

Çoğunluk yönteminde girdi değerleri ile ağırlık değerleri çarpılıp sonuçlar negatif ve pozitif değerler olarak ayrıştırılır. Çoğunlukta olan değer kümesi net girdi olarak belirlenmiş olur.

$$NET = \sum \text{sgn}(G_i A_i) \quad (3.24)$$

Kümülatif toplama yönteminde ağırlık değerleri ile girdi değerleri çarpılıp tüm değerler toplanır ve daha önceki bilgilere eklenerek net girdiyi oluşturur.

$$NET = \text{Net}_{\text{önceki}} + \sum G_i A_i \quad (3.25)$$

Aktivasyon fonksiyonda kullanılan fonksiyon denklemleri (Öztemel, 2003):

Lineer fonksiyon toplam fonksiyonundan elde edilen değerleri doğrudan çıktı olarak değerlendirir.

$$F(\text{Net}) = \text{Net} \quad (3.26)$$

Step fonksiyonu toplam fonksiyonundan gelen değerin belirlenen eşik değer ile kıyaslanması ile oluşan 1 veya 0 değerini çıktı değeri olarak kabul eder.

$$F(Net) = \begin{cases} 1 & Net > Eşik\ değer \\ 0 & Net \leq Eşik\ değer \end{cases} \quad (3.27)$$

Sinüs fonksiyonu öğrenilen konuların uygun dağılım gösterdiği YSA türlerinde uygulanabilir.

$$F(Net) = \sin(Net) \quad (3.28)$$

Eşik değer fonksiyonu Net değeri uygun koşula göre seçip çıktı değerini oluşturur. Çıktı değeri 0-1 arasında değerler alır.

$$F(Net) = \begin{cases} 0 & Net \leq 0 \\ Net & 0 < Net < 1 \\ 1 & Net \geq 1 \end{cases} \quad (3.29)$$

Hiperbolik tanjant fonksiyonu:

$$F(Net) = \left(\frac{e^{Net} - e^{-Net}}{e^{Net} + e^{-Net}} \right) \quad (3.30)$$

Aktivasyon fonksiyonu biyolojik hücre yapısındaki hücre gövdesinin çalıştığı gibi girdi katmanındaki bilgiyi değerlendirerek çıktı değeri belirler. Yapay sinir ağlarının bilgiyi işleminin yanı sıra ağırlıklı bağlantılar sayesinde öğrendiklerini saklayabilir. En yaygın olarak çok katmalı ağ modellerinde sigmoid aktivasyon fonksiyonu kullanılmaktadır (Öztemel, 2003).

$$F(Net) = \frac{1}{1 + e^{-Net}} \quad (3.31)$$

Yapay sinir ağlarının girdi olarak alınan değişkenlerden sonuç üretebilmesi için öncelikle eğitilmesi gerekir. Bağımsız değişkenler değerleri girdi, bağımlı değişken değeri çıktıyı oluşturur. Gizli katman bilgi işleme konusunda herhangi bir açıklama ya da işlemi nasıl yaptığı konusunda bilgi vermez. Bu özelliği ile mühendislik alanında kara kutu olarak da tabir edilmektedir (Öztemel, 2003).

3.2.3 Yapay sinir ağlarının özellikleri

Yapay sinir ağları doğrusal olmayan problemleri çözümlemesi, öğrenme ve modelleme yapabilmesi, hata toleransı gibi özelliklere sahip olduğu için mühendislik, tıp, işletme, finans gibi alanlarda fayda sağlamaktadır (Adıyaman, 2007; Hamzaçebi, 2011).

Paralellik: YSA aktivasyon fonksiyonu sayesinde lineer ya da non-lineer modelleme yapılabilir. Değişkenler arasında ilişkilerin doğrusal olmadığı problemlerin çözümünde bu özelliği sayesinde olumlu sonuçlar elde etmeyi sağlar.

Öğrenme: YSA insan beynini davranışlarını taklit ederek sunulan girdi değerlerine göre değişkenler arasındaki ilişki yapısını tespit ederek öğrenmeye çalışır. Öğrenme değişkenler arasındaki bağlantıların ağırlıklarının değiştirilmesi ile gerçekleştirilir.

Genelleme: Ağa tanıtılan değişkenlerden öğrendikleri bu özelliği ile farklı problemlere de çözüm sunabilir.

Uyarlanabilirlik: Başlangıçta ağa sunulan bilgilerin bağlantı ağırlıkları belirlendikten sonra elde edilmek istenen sonuca ulaşmaya kadar ağırlık değerleri değiştirilerek eğitilebilir. Ağa tanıtılan sorun değiştiğinde bu yeni probleme göre ağ uyarlanabilir ve eğitilerek sonuca ulaşılabilir.

Hata toleransı: Yapay sinir ağları çok sayıda hücrelerinin bir araya gelmesiyle oluştuğu için ağa tanıtılan değişken değerlerinde bazı değişimler oluşabilir ve istenen değer ile elde edilen değer arasında hata değeri oluşur. Bu hataların bağlantılar üzerindeki ağırlık değerlerine dağıtılması ile çıktı değerini olumsuz yönde etkilemesinin önüne geçilebilir. Böylece elde edilecek sonucun doğru değerinden uzaklaşmadan işlem yapılabilir. Ayrıca ağ yapısındaki bazı hücrelerde ya da bağlantılarda bozulmaların olması sonuç değerini önemli derece de etkilemez.


Dereceli bozulma: Yapay sinir ağı yapısında bulunan bağlantılar ya da hücrelerin bazılarında oluşan değişimler karşısında ağ işlevini tamamen kaybetmez. Hata toleransı sayesinde dereceli bozulma gerçekleşir.

Kılıç (2015), yapay sinir ağlarının temel özelliklerini şöyle sıralamıştır.

- Uygulamada sonuç üretmesi için öncelikle eğitilmesi ve test edilmesi gerekmektedir. Örnekler eğitim ve test kümesi olarak ayrılır. Eğitim kümesinde bulunan veriler eğitilir. Eğer ağ doğru cevaplar oluşturmaya başladıysa eğitim işlemi tamamlanır. Daha sonra ağın görmediği örnekler üzerinde doğru sonuçlar elde ediyorsa ağın uygun hale geldiği onaylanıp kullanılır.
- Daha önce karşılaşmadığı sorunlara çözüm üretebilir.
- Şekil ilişkilendirme ve sınıflandırma yapabilir.
- Eksik bilgi girişi olduğunda çalışmaya devam eder.
- Hata toleransı ile dengeleyicidir.
- Dereceli bozulma gösterdiği için ağ yapısı ve çalışması aniden bozulmaz.
- Bilgi tüm ağa yayıldığı için dağıtık belleğe sahiptir.

3.2.4 Yapay sinir ağlarının türleri

Çok sayıda düğüm ile bir araya gelen yapay sinir ağları bu düğümlerin bağlanma yapısına göre çeşitlere ayrılır. Şekil 3.7’ deki gibi bilgi akışına göre ileri beslemeli ve geri beslemeli, öğrenme yöntemine göre danışmanlı, danışmansız ve destekleyici öğrenme, katmanlarına göre tek katmanlı ya da çok katmanlı (MLP) , yapısına göre otoasosyatif ve heteroasosyatif olarak sınıflandırılır.



Şekil 3.7. Yapay sinir ağlarının türleri (Hamzaçebi, 2011).

İleri beslemeli ağlarda girdi katmanından alınan bilgi akışı daima tek doğrultuda çıktı katmanına doğru ilerler. Bağlantılar girdi katmanından ara katmana, ara katmandan da çıktı katmanına bağlanır. Girdi katmanı dış ortamlardan bilgi toplanan bilgilerin ağa sunulduğu ilk noktadır. Ara katman ağa giren bilgileri karıştırır ve yeni özelliklerini belirler. Çıktı katmanı tahminleri oluşturur ve hatayı yayar. Tahmin için en yaygın ileri beslemeli çok katmanlı algılayıcılar kullanılmaktadır (Tsai vd., 2009; Xie vd., 2014).

Girdi katmanından çıktı katmanına kadar ilerleyen bilgiler girdi katmanına tekrar dönmüyorsa ileri beslemeli, çıktı katmanındaki bilgi akışı aksi bir durum ile karşılaştığında tekrar girdi katmana geri dönerek işlemde geçiyorsa geri beslemeli ağ yapısına sahiptir (Agatonovic-Kustrin ve Beresford, 2000).

İleri beslemeli geri yayımlı bir ağ yapısında işlem sırasında aradaki katmanlarda değerlendirme yapılmadan bir sonraki ağa geçiş mümkün değildir. Girdi katmanında alınan veriler aradaki bağlantılar ve katmanlarda işlemlerden geçerek çıktı katmanına ilerler. Oluşan sonuç ile mevcut sonuç değerleri arasındaki farkların toplamı her düğümün belli bir oranda değerleri alacak biçimde geriye doğru yayılır (Kılıç, 2015).

Geri beslemeli ağ yapısı genellikle danışmansız öğrenmenin uygulandığı problemlerin çözümünde kullanılmaktadır. Ağın çıktı değeri kendisine ya da diğer hücrelere girdi değeri olabilir ve genellikle geciktirici elemanlar üzerinde geri besleme yapılır. Geri beslemeli ağ yapısı doğrusal olmayan dinamik bir davranış sergilemektedir (Ataseven, 2013).

Danışmanlı öğrenimde yönteminde istenilen çıktı değeri ağa tanıtılabilir. Ağa sunulan girdi ve çıktı değerleri ağ değerlendirilerek bir çıktı oluşturur. Yeni oluşan bu çıktı ile sunulan çıktı değerleri kıyaslanarak hataları tespit edildikten sonra ağırlık değerleri değiştirilip uygun sonuç elde etmeye çalışılır. Danışmanlı öğrenmeye geri yayımlı, basit algılayıcı, çok katmanlı algılayıcı yöntemleri örneklerdir. Danışmansız öğrenme de istenilen çıktı değeri ağa tanıtılmadan girdi değerlerine göre çıktı oluşturur (Elmas, 2007; Öztemel, 2003).

Danışmansız öğrenme Hopfield, Bozaltman makinası ve Rekabetçi öğrenme ağları vs. içermektedir. Destekleyici öğrenmede danışmanlı öğrenme yöntemine benzer biçimde bir öğretici bulunur. Ancak bu öğretici ağa çıktı değerleri vermeden ağın oluşturduğu sonuçların olumlu ya da olumsuz olduğunu belirten sinyaller vererek ağın ağırlıklarını düzenleyerek yeniden işlem yapması için uyarır (Elmas, 2007; Öztemel, 2003).

Otoasosyatif yapıli yapay sinir ağlarında girdi nöronları aynı zamanda çıktı nöronlarıdır. Heteroasosyatif ağ yapıları farklı girdi ve çıktı nöronlarından oluşmaktadır (Hamzaçebi, 2011).

Tek katmanlı yapay sinir ağlarında yalnızca girdi ve çıktı katmanı bulunur. Girdi ve çıktı değişkenleri bir ya da daha fazla sayıda olabilir. Diğer YSA türleri gibi bağlantıların her birinin ağırlığı vardır. Proses elemanlarının ve çıktı değerinin sıfır olmaması için eşik değeri daima 1'e eşittir. Ağırlıklandırılmış girdi değerleri eşik değeri ile toplanarak çıktı değerleri bulunur. Çıktı fonksiyonu doğrusaldır (Öztemel, 2003).

Girdi ve çıktı katmanları arasında bir ya da daha fazla katmandan oluşan ağ yapısı çok katmanlı olarak nitelendirilir (Çelebi vd., 2009). Çok katmanlı yapay sinir ağlarında girdi ve çıktı değerleri arasındaki ilişki doğrusal değildir. Doğrusal olmaması kullanılan sigmoid fonksiyonundan kaynaklıdır. Tahmin amaçlı kullanılan yapay sinir ağının anlaşılması kolay ve matematiksel ispat sağlamasından dolayı en yaygın kullanılan öğretme türüdür. Geri hatalar ağından geriye doğru yani çıktı katmanından girdi katmanına doğru azalttığı için geri yayılımlı ağ olarak da bilinmektedir. Gizli nöronlara sahip olması girdi değişkenlerinin karmaşık yapısını öğrenmesinde avantaj sağlar (Hamzaçebi, 2011; Kılıç, 2015).

Girdi katmanı işlem yapmadan verileri gizli katmana iletmekle görevlidir. Veri sayısının seçimi sinir ağının haritalama doğruluğu ve genelleme yeteneği için önemlidir. Gizli katmandaki nöron sayısı genelleme hatasını en aza indirecek model seçimi için kademeli eğitimden geçtikten sonra belirlenir. Çıktı katmanı yolcu verileri dâhilinde belirtilen zaman dilimine ait tahminlerin oluşturulduğu çıkış nöronlarından oluşur (Çelebi vd., 2009).

3.2.5 Yapay sinir ağlarında öğrenme

Bağlantı ağırlıklarında saklanan bilgiden faydalanarak istenilen sonucu elde etmek için ağırlık değerleri değiştirilerek ağa öğretilir. Yapay sinir ağlarında öğrenme danışmanlı ve danışmansız öğrenme olarak ayrılır.

Danışmanlı öğrenme bir ya da daha fazla değişkenlerinden faydalanarak 1 ya da daha fazla sonuç elde etmeyi sağlar. Gizli katman nöron sayısı bağlantıların işleyişini etkiler. Bağlantılarda nöron sayısının azlığı öğrenme sürecini kısıtlar. İstenilen sonuç elde edildiğinde ağırlık bağlantılarını hafızasına kaydeder ve başka bir problemde sonuç üretmek için analitik araç gibi kullanır (Agatonovic-Kustrin ve Beresford, 2000).

Danışmanlı öğrenmede ağ yapısını değerlendirmesi için bir öğreticiye ihtiyaç vardır. İstenilen çıktının oluşması için ağırlık hatalarının azaltılması için yeniden değerlendirilmesi gerekir. Giriş değerlerine göre istenen çıktı sistemde girdi-çıkı ilişkisini öğrenene kadar eğitilir. Ağırlık değerlerinin değiştirilmesi öğrenme kurallarına göre değişiklik gösterir. Çok katmanlı algılayıcılar (ÇKA), ADALİNE, delta kuralında danışmanlı öğrenme yöntemi kullanılır. Danışmansız öğrenme danışmana ihtiyaç duymadan girdi değerlerinin birbirine benzer olanları gruplandırır. Danışmanlı öğrenmeye göre daha hızlı işlem yapabilir. Kohonen, Hopfield ve Hebb kuralı bu öğrenme türüne örnektir (Elmas, 2007).

Danışmanlı öğrenme ağ kullanılmadan önce giriş ve çıkış bilgileri sunularak eğitilir. Her giriş değişkenine uygun çıkış değeri sağlanarak eğitim kümesi oluşturulur. Eğitim işlemi uzun zaman alabilir. Bir olay için ağ eğitildiğinde farklı bir durumla karşılaşması durumunda çözüm üretmekte zorlanabilir. Bu yüzden araştırmada kullanılacak değişkenler ve ulaşmak istenen çıktı değerleri için ağ öğrenmesi önemlidir. Girdi ve çıktı değerlerini uygun biçimde ağa sunulması analizde başarı elde etmek için önemli bir etkidir. Danışmanlı öğrenme eğitilen bilgiler doğrultusunda oluşan çıktı değerleri ile hedeflenen değerler arasında kıyaslama yapılmasını sağlar. Elde edilmek istenen sonuca ulaşmaya kadar ağırlık değerlerinde değişiklikler yapılarak eğitilir. Değişkenler arasındaki hata değeri azalınca eğitim tamamlanır (Elmas, 2007; Öztemel, 2003).

Danışmansız öğrenme çıktı değeri tanımlanmadığı için doğru çıktı değeri hakkında bilgisi olmadan girdi değerlerine göre kendiliğinden ağırlık değerleri belirleyerek bir değer oluşturur. Ağın öğrenmesi için kullanılan önem öğrenme kurallarından bazıları aşağıda açıklanmıştır (Elmas, 2007; Öztemel, 2003).

Delta Kuralı: Çıktı sonucunun gerçek değerlerle arasındaki farkı azaltmak için bağlantı değerleri değiştirilip önceki katmana yeniden gönderilir. Bu işleme ileri beslemeli geri yayılmalı ağ yapısı denir. Delta ağ yapısının kendine özgü algoritmik öğrenme yöntemi bulunur.

Hebb Kuralı: Sinirler arası bilgi aktarımında her iki değerın işareti aynıysa sinirler arası boyut kuvvetlendirilir.

Hopfield Kuralı: Sinirler arası bilgi değerlerine göre bağlantı boyutları artırılır ya da azaltılır. Hopfield ağ yapısı giriş, Hopfield katmanı ve çıkış katmanından oluşmaktadır. Her düğüm birbiri ile bağlıdır ve bu yüzden bilgi akışı her iki yönde hareket edebilir.

Kohonen Kuralı: Girdi katmanında sunulan değişkenlerle birlikte birbiriyle ilişkili tek bir çıktı katmanı bulunmaktadır. Girişler doğrudan çıktı katmanı ile bağlantılı olup rastgele ağırlıklarla analize başlar.

ADALİNE (Adaptif Lineer Element) Modeli: EKK yöntemi dayanan ADALİNE modeli delta öğrenme kuralı olarak da bilinmektedir. Çıktı sonucunun beklenen çıktı değeri ile aralarındaki hatanın minimum derecede kalacak biçimde ağırlıklarının değiştirilmesidir. Tek katmanlı ağ yapısı ile benzerlik gösterse de öğrenme kuralı farklıdır. MADALINE birden fazla ADALİNE yapısının bir araya gelmesiyle oluşur.

3.2.5.1 Geri yayımlı öğrenme

Geri yayımlı öğrenme danışmanlı öğrenmenin bir türü olup öğrenme kapasitesinin iyi olmasından dolayı da birçok alanda yaygın biçimde tercih edilmektedir (Yaşar, 2004). Geri yayımlı öğrenmede girdi- gizli ve çıktı katmanı arasında ağırlıkların çıktı olarak elde edilen değerlere ait hatanın uygun hale getirilmesi için kullanılmaktadır (Yalçın, 2012).

Girdi ve çıktı katmanının arasındaki gizli katman sayısı ve nöron sayısı ele alınan konuya göre deneme- yanılma yoluyla uygun sonuç elde edilmeye kadar sınanarak tespit edilir (Karahan, 2011). Hata değeri, istenilen çıktı değeri ($y(k)$) ve sinir ağından elde edilen çıktı değerinin ($o(k)$) farkı ile hesaplanır (Yaşar, 2004).

$$e(k) = y(k) - o(k) \quad (3.32)$$

$k+1$. katmanda i . birime net giriş aşağıdaki belirtilen formül ile hesaplanabilir.

$$n^{k+1}(i) = \sum_{j=1}^{s_k} w^{k+1}(i,j) \cdot o^k(j) b^{k+1}(i) \quad (3.33)$$

Denklemde w ağırlıkları, b biasları ifade etmektedir.

$$o^{k+1}(i) = f^{k+1}(n^{k+1}(i)) \quad (3.34)$$

M katmanlı ağ yapısı matris biçimde temsili aşağıdaki denklemlerle oluşturulur.

$$o^0 = x \quad (3.35)$$

$$o^{k+1}(i) = f^{k+1} w^{k+1} a^k + b^{k+1} \quad (3.36)$$

$k = 0, 1, 2, \dots, M-1$ ağ girdi ve çıktı değerleri arasındaki ilişkiyi öğrenmeyi ve ağın performansını belirlemek için;

$$E = \frac{1}{2} \sum_{q=1}^Q (y_q - o_q^M)^T (y_q - o_q^M) \quad (3.37)$$

$$e_q = y_q - o_q^M \quad (3.38)$$

Yukarıdaki formülde e_q ifadesi hatayı temsil etmektedir. Geri yayılım algoritmasını oluşturmak için steepest descent algoritmasından yararlanılmaktadır ve karesel ortalama hata (MSE) ile Denklem (3.39) toplam sembolünün yerini karşılar. Yeni oluşan karesel ortalama hata denklemi:

$$E = \frac{1}{2} e_q^T e_q \quad (3.39)$$

Steepest descent algoritması Denklem (3.40) ve (3.41)'de belirtilmiştir.

$$\Delta w^k(i, j) = -\alpha \frac{\partial E}{\partial w^k(i, j)} \quad (3.40)$$

$$\Delta b^k(i) = -\alpha \frac{\partial E}{\partial b^k(i)} \quad (3.41)$$

Denklemde α öğrenme oranını belirtmektedir. Öğrenme katsısı genellikle 0.1-0.9 arasında değerler alır. Öğrenme katsayısının uygun değeri ele alınan konuya göre değişkenlik göstermektedir. Öğrenme katsayısının değeri çözüme ulaşılacak hız üzerinde doğrudan etkilidir. Öğrenme katsayısının küçük seçilmesi durumunda ağız izlediği yol gradyen yoluna yakın olacağı için çözüme ulaşacak zaman uzar. Katsayının büyük seçilmesinde ise önce çözüme kolay yaklaşacaktır ancak bir döngüye girerek çözüm elde edemeyecektir (Oğuz, 2001). Performans duyarlılığı için k katmanındaki i birimin net girişindeki değer ile değiştirilerek Denklem (3.42) ve (3.43) elde edilir.

$$\delta^k(i) = \frac{\partial E}{\partial n^k(i)} \quad (3.42)$$

$$\frac{\partial E}{\partial w^k(i, j)} = \frac{\partial E}{\partial n^k(i)} \frac{\partial n^k(i)}{\partial w^k(i, j)} \quad (3.43)$$

$$\frac{\partial E}{\partial b^k(i)} = \frac{\partial E}{\partial n^k(i)} \frac{\partial n^k(i)}{\partial b^k(i)} \quad (3.44)$$

Aynı zamanda;

$$\frac{\partial E}{\partial w^k(i, j)} = \delta^k(i) \cdot o^{k-1}(j) \quad (3.45)$$

$$\frac{\partial E}{\partial b^k(i)} = \delta^k(i) \quad (3.46)$$

Hassaslığın yeterli olduğunu belirlemek için yenileme ilişkisiyle ifade edilir. Buradan $F^k(n^k)$ matrisi oluşturulur.


$$\delta^k = F^k(n^k) \cdot W^{k+1} \cdot \delta^{k+1} \quad (3.47)$$

$$F^k(n^k) = \begin{bmatrix} f^k(n^k(1)) & 0 & \dots & 0 \\ 0 & f^k(n^k(2)) & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & f^k(n^k(S_k)) \end{bmatrix} \quad (3.48)$$

$$f^k(n) = \frac{df^k(n)}{dn} \quad (3.49)$$

$$\delta^M = -F^M(n^M)(y_q - o_q) \quad (3.50)$$

Geri yayımlı öğrenme algoritmasında girdi değerleri ileriye doğru yayılır. Hatayı ağırlıklara dağıtmak için geri yayılım gösterir ve ağırlık değerleri güncellenir. Bu algoritma Şekil 3.8’de verilmiştir.



Şekil 3.8. Geri yayılım algoritması akış diyagramı.

Geriye yayımlı öğrenme algoritmasında hata gradyen azalma tabanlı olmasından dolayı ilk durumlarda belirlenen koşullara çok duyarlıdır. İlk atanan ağırlık vektörü hata yüzeyi minimum değerine çok yakın ve eğimli bölgede ağırlık öğrenmesi hızlıyken, ağırlık vektörü hata yüzeyi minimum değerine uzak ve eğimsiz bir bölgede bulunuyorsa ağırlık öğrenmesi zaman alır. Ağırlık değerleri başlangıçta -1 ile 1 ya da -0.5 ile 0.5 değerleri arasına keyfi olarak seçilir. Ağırlık değerlerini büyük seçilmesi halinde nöronlar doyma noktasına erken ulaşır ve öğrenmeye duyarsız hale gelir (Oğuz, 2001).

3.2.5.2 Levenberg-Marquardt algoritması

Geri yayılım algoritması en yaygın öğrenme yöntemi olarak kullanılsa da çözüm elde etmede çok yavaş ilerlemesi ve bölgesel minimuma yakalanma riskinden dolayı bazı dezavantajlara sahiptir. Minimum araştırma yöntemlerinin bir diğeri Levenberg Marquardt öğrenme algoritmasıdır (Yaşar, 2004).

Yapay sinir ağlarının eğitilmesinde kullanılan en etkili yöntem olan Levenberg-Marquardt Newton metodunun yaklaşık değeridir (Danial vd., 2018). Newton algoritmasının performans indeksinin ikinci türevi ile oluşturulur, ancak Jacobian tarafından Hessian matrisine yaklaşır. Ağ performansı hata kareleri toplamı (MSE) ile belirlenir. Aynı zamanda LM ağdaki her düğüm için aynı düğüm işlevine sahip uyarlanabilir bir yapıya sahiptir. (Kannaiyan vd., 2020; Mammadli, 2017).

Performans indeksinin optimizasyonu (Daniel vd., 2018; Yaşar, 2004);

$$x_{k+1} = x_k - A_k^{-1} g_k \quad (3.51)$$

Burada A_k ve g_k :

$$A_k = \nabla^2 F(x)|_{x=x_k} \quad (3.52)$$

$$g_k = \nabla F(x)|_{x=x_k} \quad (3.53)$$

Denklemde x değişkeni ağırlık değerlerini ifade etmektedir. Ağırlık öğrenmesi için öncelikle ağırlıklara ait değerler küçük ve rastgele seçilerek eğitilir. Gerçek değerler ile ağırlık oluşturduğu çıktı değerler arasında hata minimum olana kadar x ağırlık değerleri değiştirilir.

$$\Delta x = -(\nabla^2 F(x))^{-1} \cdot \nabla F(x) \quad (3.54)$$

Denklemde $\nabla^2 F(x)$ Hessian matrisini, $\nabla F(x)$ eğimi, $F(x)$ hata kareleri toplamını ifade etmektedir. Ağ çıktısı ve gerçek değerler arasındaki farkı $e(x)$ 'dir.

$$F(x) = \sum_{i=1}^N e^T(x) e(x) \quad (3.55)$$

Gradyanın j . bileşeni;

$$(\nabla F(x))_j = \frac{\partial F(x)}{\partial x_j} = 2 \sum_{i=1}^N e_i(x) \frac{\partial e_i(x)}{\partial x_j} \quad (3.56)$$

$$\nabla F(x) = 2J^T(x)e(x) \quad (3.57)$$

Denklemde Jacobian matrisi $J(x)$ ile gösterilmektedir.

$$J(x) = \begin{bmatrix} \frac{\partial e_1(x)}{\partial x_1} & \frac{\partial e_1(x)}{\partial x_j} & \dots & \frac{\partial e_1(x)}{\partial x_n} \\ \frac{\partial e_2(x)}{\partial x_1} & \frac{\partial e_2(x)}{\partial x_2} & \dots & \frac{\partial e_2(x)}{\partial x_n} \\ \vdots & \vdots & \dots & \vdots \\ \vdots & \vdots & \dots & \vdots \\ \vdots & \vdots & \dots & \vdots \\ \frac{\partial e_N(x)}{\partial x_1} & \frac{\partial e_N(x)}{\partial x_2} & \frac{\partial e_N(x)}{\partial x_3} & \frac{\partial e_N(x)}{\partial x_n} \end{bmatrix} \quad (3.58)$$

Hessian matrisi için;

$$(\nabla^2 F(x))_{kj} = \frac{\partial^2 F(x)}{\partial x_k \partial x_j} = 2 \sum_{i=1}^N \left[\frac{\partial e_i(x)}{\partial x_k} \frac{\partial e_i(x)}{\partial x_j} + e_i(x) \frac{\partial^2 e_i(x)}{\partial x_k \partial x_j} \right] \quad (3.59)$$

$$\nabla^2 F(x) = 2J^T(x)J(x) + 2S(x) \quad (3.60)$$

$$S(x) = \sum_{i=1}^N \nabla^2 e_i(x) \cdot e_i(x) \quad (3.61)$$

Newton yönteminde $S(x)$ değeri yaklaşık olarak sıfır kabul edilir ve yeni oluşan Hessian matrisi aşağıdaki denkleme dönüştürülür.

$$\nabla^2 F(x) \cong 2J^T(x)J(x) \quad (3.62)$$

Başlangıçta verilen x_{k+1} denkleminde $\nabla^2 F(x)$ ve $\nabla F(x)$ yerine koyulduğunda Newton yöntemi elde edilmiş olur.

$$x_{k+1} = x_k - [2J^T(x_k) \cdot J(x_k)]^{-1} \cdot (2J^T(x_k) \cdot e(x_k)) \quad (3.63)$$

Newton yönteminde ikinci derecen türeve ihtiyaç duyulmadığı için denklem aşağıdaki gibi oluşturulur.

$$x_{k+1} = x_k - [J^T(x_k) \cdot J(x_k)]^{-1} \cdot (J^T(x_k) \cdot e(x_k)) \quad (3.64)$$

Bu denklemde H matrisine eşit olan $J^T J$ ters çevrilemediğinden Hessian matrisinin modifikasyonu ile çözüm üretilebilir.

$$G = H + \mu I \quad (3.65)$$

I belirleme matrisi, μ ise sabit değerdir. Eigen değeri λ ve eigen vektörü z için;

$(\lambda_1, \lambda_2, \lambda_3, \dots, \lambda_n)$ ve $(z_1, z_2, z_3, \dots, z_n)$ ile bir önceki denklemde her iki tarafta eigen vektörü ile geliştirilir.

$$Gz_i = Hz_i + \mu z_i = \lambda_i z_i + \mu z_i \quad (3.66)$$

Burada $\lambda_i + \mu$ değerleri G ve H değerleri aynıdır. Buradan da $i>0$ için μ sabit bir değer olduğundan λ artmasıyla her belirleme matrisi için G pozitif değerler alacak ve matris ters çevrilebilecektir. Levenberg-Marquardt algoritması da;

$$x_{k+1} = x_k - [J^T(x_k) \cdot J(x_k) \cdot \mu_k I]^{-1} \cdot (J^T(x_k) \cdot e(x_k)) \quad (3.67)$$

Levenberg-Marquardt algoritmasının en önemli karakteristiği olan μ_k değeri arttırıldığında en keskin azalma algoritmasına doğru ilerler ve düşük öğrenme oranına sahiptir.

Büyük bir μ_k değeri için;

$$x_{k+1} \cong x_k - \frac{1}{\mu_k} J^T(x_k) \cdot e(x_k) = x_k - \frac{1}{2\mu_k} \nabla F(x) \quad (3.68)$$

μ_k değeri sıfıra yaklaştıkça Newton değerine eşit olabilir.

LM algoritmasında Jacobian matrisinin hesaplanması önemlidir. Yapay sinir ağları için geri yayılım algoritmasındaki değerlerin basit bir biçimde değiştirilmesiyle elde edilebilir. Standart geri yayılım algoritması;

$$x = [w^1(1,1)w^1(1,2) \dots w^1(S1,R)b^1(S1)w^2(1,1) \dots b^M(SM)]^T \quad (3.69)$$

$$N = Qx \quad SM \quad (3.70)$$

$$\frac{\partial E}{\partial w^k(i,j)} = \frac{\partial \sum_{m=1}^{SM} e_q^2(m)}{\partial w^k(i,j)} \quad (3.71)$$

Levenberg-Marquardt algoritmasında Jacobian matrisinin oluşması için ağ geri yayılmalıdır.

$$\frac{\partial e_q(m)}{\partial w^k(i,j)} \quad (3.72)$$

Levenberg-Marquardt algoritması minimum ortalama hata karelerini hesaplamaya yarayan bir yöntemdir. Newton ve Gradyan Azalma algoritmalarının sahip olduğu en iyi özelliklerden meydana geldiği için kısıtlamalardan etkilenmez. Levenberg-Marquardt algoritması minimum hata değerine karşılık gelen ağırlık değerlerinin tespit edilmesini amaçlamaktadır (Oğuz, 2001).

3.2.6 Yapay sinir ağlarının eğitilmesi

Yapay sinir ağlarında bağlantıların ağırlık değerlerinin belirlenmesi ağın eğitilmesi olarak nitelendirilmektedir. Ağırlık değerleri sisteme tanıtılan örneklere göre değişir. Ağın eğitilmesi uygun ağırlık değerlerinin belirlenmesi ve doğruluğunu etkiler. Ağa ait uygun bir yapı belirlendikten sonra ağ bilgileri işleyerek çıktı değeri oluşturur. Gerçek değerler ile çıktı değerleri arasındaki hata değerini minimum değerlere indirebilmek için ağ içinde işleme devam eder (Okkan, 2009).

Eğitimden sonra ağın öğrenme durumunu belirlemek için ağ test edilir. Testlerde daha önce ağa sunulmamış örnekler kullanarak ağırlık değerleri değiştirilmeden durumu sınanır. Analiz sonucunda elde edilen değerlere göre öğrenme kontrolü yapılabilir. Ancak ağ uzun süre eğitilirse yorulur ve genelleme yapamaz (Agatonovic-Kustrin ve Beresford, 2000; Öztemel, 2003).

Çok katmanlı ağlarda girdi değerleri girdi katmanından çıktı katmanına ilerler, hata değerleri hesaplanarak geriye yayılır ve bu hataya göre ağırlık değerleri değiştirilerek eğitilir. Eğitildikten sonra bilgi akış yönü ileri doğrudur (Hamzaçebi, 2011).

3.2.7 Yapay sinir ağlarının uygulama alanları

YSA genel olarak sınıflandırma, tahmin, veri işleme gibi değerlerine birçok alanda kullanılmaktadır (Öztemel, 2003). YSA yazı karakterlerini ayırt etme, banka işlemlerinde müşteri ve banka güvenliğinin sağlanmasında sınıflandırma, benzer yapıdaki değişkenlerin bir araya toplanmasında kümeleme, yüz tanıma ve kimlik doğrulama işlemlerinde örüntü tanıma, üretim alanında gelecek vadede talebin belirlenmesinde tahmin yöntemleri kullanılarak pek çok alanda fayda sağlamaktadır (Hamzaçebi, 2011). Bu alanlarda yapılan çalışmalar aşağıda açıklanmıştır (Elmas, 2007; Karahan, 2011).

Endüstriyel Alanlar: Sanayi üretiminin kalite kontrolü, kalite geliştirme ve yükseltilmesi için YSA faydalanılmaktadır. Günlük hayatta kullanılan birçok eşyaların şuan kullanıldığı biçime gelmesindeki etkenlerin tespiti ve eksikliklerinin giderilmesinde kullanılmıştır. Konuşmayı metin halinde sunma, otomatik dil çevirisi gibi kolaylıklar sağlamaktadır.

Ulaştırma ve Havacılık Alanları: Hareketliliğin karşılanması için uygulanan yöntemlerde temel eksikliklerin giderilmesi, planlama ve proje için uygun verinin sağlanması, kapasitenin yetersiz olduğu güzergâhlardaki sorunların giderilmesi, uçaklarda motor sorunlarının ses ve titreşime bağlı tespit ederek erken uyarıların yapılmasında, insansız araçların üretilmesinde ve ulaşım tesislerine girişte tehlikeli çantaların belirlenmesinde kullanılmaktadır.

Finans, Borsa Alanları: Bankaların mali tahminlerinde, belge sahteciliğine karşı güvenlik amaçlı el yazısı ve imza tanımada, borsa endekslerinin, enflasyonun tahmininde kullanılmaktadır.

Tıp ve Biyomedikal Alanlar: RNA ve DNA yapısının incelenmesi, hastaların ilaçlara olan hassasiyetinin belirlenmesi, kanser tanılarının teşhisinde faydalanılmaktadır.

İletişim Alanı: Telefon konuşmalarında dış seslerin sönümlenmesi, hatlarının güncellenmesi gibi alanlarda kullanılmaktadır.

Arıza Analizi ve Tespiti: Elektronik cihazların çalışma düzeni öğretilerek çalışma sırasında oluşacak arızaların önceden belirlenmesinde yardımcı olur.

Savunma: Görüntülenen nesneleri ayırma ve tanıma, silah otomasyonu ve hedef izleme, insansız hava araçları ile tehlikeli hedefleri belirleme ve imha etme gibi alanlarda kullanılmaktadır.

Otomasyon ve Kontrol: Otomatik pilot sistemi otomasyonu, ulaşım araçlarının otomatik yol bulmasında, robotik sistemlerin kontrolünde kullanılmaktadır.

3.2.8 Yapay sinir ağlarının avantajları ve dezavantajları

Yapay sinir ağları insan beyni davranışlarını bilgisayar üzerinde gerçekleştirebilir. Öğrenme yeteneği ile pek çok alanda sınıflandırma, tahmin ve modelleme amaçlı kullanılabilir. Ancak bilginin işlem aşaması gizli olduğu için sistemin çalışması denetlenemez. Bu yüzden aşırı öğrenme durumunda yanlış sonuçlar elde edilebilir. Ağın eğitilmesinde çok fazla denemeye ihtiyaç duyduğu için öğrenmesi uzun sürer (Elmas, 2007).

Çözümü zor ya da karmaşık problemlerin analizini yapabilme, eksik bilgi ile hata vermeden çalışabilme ve bağlantı ağırlıkları ile bilgiyi hafızasında saklama gibi özellikleri sayesinde avantajlar sağlamaktadır. Aşamalı bozulma gösterdikleri için ağ yapısında karşılaşılan bir sorundan tamamen etkilenmez, dereceli olarak bozulur (Karahan, 2011).

Pek çok sektörde sınıflandırma, genelleme ve tahmin amaçlı kullanımlarda fayda sağlar ancak tahmin amaçlı kullanımında bağımsız değişkenler belirlenirken modelin fazla değişkene sahip olması gerektiği düşünülmemeli ve uygun değişkenler seçilmelidir (Hamzaçebi, 2011; Karahan, 2011).

Avantajlarının yanı sıra problem çözümleri için uygun ağ yapısı deneme yanılma yöntemi ile belirlenir. Bu yüzden bazı problemlerin çözümünde sonuç üretmez ya da alakasız değerler oluşturabilir. Uygun ağ yapısının tespit edilmemesi istenilen sonucu elde etmede yetersiz kalır. Ağ parametrelerine ait değerlerin belirlenmesinde bir kural olmaması ve öznel yargılarla tespit edilmesinden dolayı sonuçlar araştırmacılara göre değişkenlik gösterir. Ağ yalnızca nümerik değerli problemlere çözüm ürettiği için bu yapıda olmayan verilerin dönüştürülmesi araştırmacının çalışmasına bağlı olduğundan çözüm üretmesi araştırmacının tecrübesine bağlıdır. Ağın eğitilmesi işleminde herhangi bir sınır bulunmadığı için verilerin hata değerleri belli bir değer altında kaldığında eğitimin tamamlandığı varsayılır (Karahan, 2011).

4. ARAŞTIRMA BULGULARI

4.1 Model Girdileri

Wardman (2006) demiryolu yolcu talebini etkileyen ana faktörün GSYH olduğunu belirtmiştir. Aynı zamanda araç sahipliliği, nüfus, yakıt maliyetleri ve araba ile yolculuk süreleri de demiryolu talebini etkilediğini vurgulamıştır.

Demiryolu yolcu taşımacılığı ile yapılan daha önceki çalışmalarda yolcu memnuniyeti, süre, demografik özellikler, tercih sebepleri gibi kriterler göz önünde bulundurularak anket yoluyla ve akıllı ulaşım sistemlerinin sunduğu kolaylıklar sayesinde veriler temin edilmiş ve analizler yapılmıştır.

Bu çalışmada kullanılan veriler demiryolu taşımacılığına ait yapılan çalışmalar da göz önünde bulundurularak oluşturulmuştur. Analiz verileri 1998-2018 yılları arasındaki değerleri kapsamaktadır. Verilerin temin edilmesinde TÜİK, TCDD ve KGM istatistik kaynaklarından faydalanılmıştır. Modelleme de regresyon analizi ve yapay sinir ağları ile analiz yapılmıştır. Modellemede istatistiki hesaplamalarda Statistica 12.0 paket programı kullanılmıştır.

Girdi katmanını bağımsız değişkenler, çıktı katmanını bağımlı değişkenler oluşturmaktadır. Verilerin anlamlılık testi ve genel model anlamlılığı F testi, %5 önem derecesi dikkate alınarak sonuç elde etmeye çalışılmıştır. Modelleme çok katmanlı ileri beslemeli (MLP) ağ yapısı danışmanlı öğrenme yöntemi ile oluşturulmuştur. Demiryolu Yolcu Sayısı (DYS) bağımlı değişkeni ifade ederken bağımsız değişkenlere ait veri bilgileri aşağıdaki gibidir.

Bağımlı değişkenler: Kişi başına düşen Gayri Safı Yurtiçi Hasıla (GSYH), Nüfus (N) 1000 kişi, 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).

Denizyolu ve havayolu yolcu sayılarına ait geçmiş dönemlerde net bir veri bilgisi bulunmadığı için analizde hatalı sonuçlar elde etmemek adına değerlendirmeye alınmamıştır. Motorlu taşıt sayısına ait veriler sadece yolcu taşımacılığında kullanılan araçlar dikkate alınarak oluşturulmuştur. Demiryolu hat uzunluğu değerleri manevra hatlarının uzunluğunu içermemektedir.



Çizelge 4.1. Analizde kullanılan veri değerleri.

Yıllar	GSYH	N	KYS	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

4.2 Talep Tahmin Analizi

4.2.1 Korelasyon analizi

Bağımsız değişkenler ve bağımlı değişkenler arasındaki ilişki korelasyon analizi ile yorumlanır. Korelasyon katsayısı (r), -1 ile +1 arasında değerler alarak değişkenler arasındaki bağlantıyı açıklar. Veri değerleri negatif yönde değerler alırsa değişkenler arasında zıt yönde bir ilişki, pozitif değerler alması değişkenlerin aynı yönlü bir ilişki içerisinde olduğunu ifade eder. Bağımlı ve bağımsız değişkenlere ait korelasyon ilişkisi Çizelge 4.2’de verilmiştir.

Korelasyon analizinde bağımlı değişken; Demiryolu Yolcu Sayısı ve bağımlı değişkenler; Gayrisafi Yurtiçi Hasıla, Nüfus, Karayolu Yolcu Sayısı, Otomobil Sayısı, Karayolu Motorlu Taşıt Sayısı, Demiryolu Hat Uzunluğu, Demiryolu Yolcu Vagon Kapasitesi, Demiryolu Yolcu Taşıma Giderleri arasında pozitif doğrusal bir ilişkinin bulunduğu saptanmıştır. Ancak Demiryolu Yolcu Vagon Sayısı ile bağımlı değişken arasında negatif yönlü bir ilişki olduğu belirlenmiştir. Bunun da sebebinin bazı bölgelerde altyapı, bakım-onarım çalışmalarından dolayı çalışmasına ara verilen hatlarda tren seferlerinde aksaklıkların mevcudiyeti ve sefer sıklığına göre vagon sayısındaki değişimlerden kaynaklandığı düşünülmektedir.

Çizelge 4.2. 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

4.2.2 Çoklu regresyon analizi

Bu analizin amacı bağımsız değişkenlerdeki değişimin bağımlı değişken üzerindeki etkisini açıklamak ve tahmin etmektir. Uygulama da açıklama ve tahmin ayrı ayrı çözümler için kullanıldığı gibi aynı problemde ikisi de uygulanabilir. Bu yöntemlerin oluşturulmasında hedefe ulaşmak için en küçük kareler kuralından faydalanılır. Esnek ve uyarlanabilir olduğu içinde neredeyse bütün bağımlı değişken ile ilgili işlemlerde kullanılır (Anderson vd., 2010). ÇDR sonuçları Çizelge 4.3'te gösterilmiştir.

Çizelge 4.3. Çoklu doğrusal regresyon analizi sonuçları.

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

Regresyon analizi sonucunda bağımsız değişken değerlerinin katsayılarını bazıları negatif çıkmıştır. Değişkenlerden arasından nüfus ve demiryolu hat uzunluğu anlamlı olduğu tespit edilmiştir.

Regresyon analizinin t testi, kritik t değerinden büyük olması H_0 yani sıfır hipotezini reddeder ve ilişkinin anlamlı olduğunu ifade eder. Kritik t değeri t tablosundan $t_{\alpha,(n-2)}$ kuralıyla elde edilir. Regresyon analizinde genel anlamlılık varyans analizi ile belirlenir (Yavuz, 2009). Regresyon analizine göre t testi değeri 1,614; t kritik değeri 1,729'dan küçüktür. Bunun için genel anlamlılık incelenir. R^2 değeri 0 ile 1 arasında değerler alır. Değer 1'e yaklaştıkça bağımsız değişkenler bağımlı değişkeni daha iyi açıklar (Yavuz, 2009). Bağımsız değişkenler bağımlı değişkeni yani demiryolu yolcu sayısının %93,7'sini açıklamaktadır ve korelasyon değeri (r) 0,968 olarak hesaplanmıştır.

Bağımsız değişkenlere ait beta (b*) değerleri bağımlı değişkendeki bir birimlik artışın hangi değere denk geldiğini ifade etmektedir (Sağlamyürek, 2018). Varyans analizine ait değerler Çizelge 4.4'te belirtilmiştir.

Çizelge 4.4. Varyans analizi.


	Kareler Toplamı	Serbestlik D.	Ort. Kareler	F	p-value
Regresyon	27964235	9	3107137	18,11109	0,000023
Hatalar	1887159	11	1715560		
Toplam	29851394				

F hesap değeri ve F kritik değerinden büyük olması sıfır hipotezini reddeder ve modelin anlamlı olduğu ifade eder (Yavuz, 2009). F tablosundan 0,05 önem düzeyinde F kritik değeri 3,11 olarak belirlenmiştir ve hesaplanan F değerinden küçük olduğu için sıfır hipotezi reddedilip modelin anlamlı olduğu ispatlanmıştır. Bağımlı değişkene ait gerçek değerler ve tahmin değerleri Çizelge 4.5'te verilmiştir.


Çizelge 4.5. Regresyon analizi gerçek değerler ve tahmin değerleri.

Yıllar	Gerçek Değerler	Tahmin Değerleri	Hata
1998	6161	6288,886	-127,886
1999	6146	6187,531	-41,531
2000	5833	5663,119	179,881
2001	5568	5497,821	70,179
2002	5204	5338,458	-134,459
2003	5878	5455,364	422,636
2004	5237	5489,750	-252,750
2005	5036	5223,142	-187,142
2006	5277	5251,882	25,118
2007	5553	5448,354	104,646
2008	5097	5130,449	-33,449
2009	5374	5380,101	-6,101
2010	5491	6258,757	-767,757
2011	7300	6455,157	844,843
2012	6612	6400,106	211,894
2013	6225	6558,769	-333,759
2014	7401	7429,261	-28,261
2015	8326	8278,461	47,539
2016	7829	7858,814	-29,814
2017	8465	8274,562	190,348
2018	8938	9092,175	-154,175


Regresyon analizine ait gerek deęerler ve tahmin deęerlerindeki baęlantı, hataların olasılıęı, hataların daęılımı ve histogramı grafięi ve grafiklere ait aıklamalar Őekil 4.1, 4.2, 4.3 ve 4.4'teki gibidir. Tahmin ve gerek deęerlere ait grafik incelendięinde deęerlerin birbirine yakın olduęu gzlenmektedir. Tahminden elde edilen deęerlere gre hata daęılımı sıfır aralıęında aęırlıklı olarak daęılmıştır. Hata histogramının da simetrik daęılım gsterdięi gzkmektedir. Bylece tahmin edilen deęerlerin gerek deęerler ile uyumlu sonular oluřturduęu aıklanabilir.




Őekil 4.1. Regresyon analizi tahmin ve gerek deęerler.



Őekil 4.2. Regresyon analizi tahmin deęerleri ve daęılımı.



Şekil 4.3. Regresyon analizi hata histogramı.



Şekil 4.4. Regresyon analizi hata normal olasılığı.

4.2.3 Yapay sinir ağları

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 (Öztemel, 2003).

Değişken sayılarına göre performansının ve modelin çalışmasında aksaklık ya da yanlışlıkların oluşmaması için tek gizli katmana sahip bir ağ yapısı oluşturulmuştur. Model Statistica 12.0 paket programından yararlanarak analiz edilmiştir.

Ağ yapısının en iyi performansı vermesi için yapay sinir ağlarının eğitilmesi esnasında değişik yapılar oluşturulmuştur. Ağ mimarisi transfer fonksiyonu ve ilk ağırlık katsayıları belirlenerek ağa sunulan veriler farklı yüzdeliklerde eğitim ve teste tabii tutulmuştur. Uygun mimari verilerin % 80'i eğitim, % 20'si test için kullanılarak gizli katman transfer fonksiyonu hiperbolik tanjant, çıktı katmanında log-sigmoid transfer fonksiyonu kullanılmıştır. Hatayı geriye doğru ağırlıklara yayarak minimum değeri oluşturduğu için Levenberg Marquardt algoritması kullanılarak 1000 iterasyonla sınanmıştır. Ağ performansının belirlenmesinde Hata Kareleri Ortalaması (MSE) kullanılmıştır. Ağ eğitildikten sonra uygun performans gösteren ağ yapısı (9x5x1) olarak belirlenmiş ve Çizelge 4.6'da gösterilmiştir.

Çizelge 4.6. Uygun değerleri oluşturan ağ yapısı.

Ağ yapısı	Training Perf.	Testing Perf.	Girdi	Gizli
9x5x1	0,995	0,991	9	5

Bağımlı değişken üzerindeki bağımsız değişken etkileri duyarlılık analizi ile tespit edilir. Bu modelde bağımlı değişken üzerindeki etki derecelerine göre bağımsız değişkenlere ait duyarlılık analizi Çizelge 4.7'de verilmiştir.

Çizelge 4.7. Duyarlılık analizi.

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

Duyarlılık analizi sonucunda gayrisafi yurtiçi hasılanın en önemli değişken olduğu ve 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 giderlerinin önemi belirlenmiştir.

Başlangıçta ağırlık eğitilmesi için belirlenen ağırlık değerleri uygun ağ yapısı belirlendikten sonra ağırlık değerleri ve biaslar Çizelge 4.8’de verilmiştir.

Çizelge 4.8. Ağa ait bias ve ağırlık değerleri.

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

Modelin genel denklemini oluşturmak için birinci fonksiyon hiperbolik tanjant, ikinci fonksiyon olarak log-sigmoid transfer fonksiyonu kullanılmıştır. Verilere ait değerler normalleştirilmiştir ancak ham değerlerin hata aralığı daha uygun olduğu için ham değerlere göre işlem yapılmıştır. Modele ait genel denklem:

$$DYS = f_s[w2]f_h \left\{ w1 \begin{bmatrix} GSYH \\ N \\ KYS \\ KMTS \\ OS \\ DHU \\ DYVS \\ DYVK \\ DYTG \end{bmatrix} + [b1] \right\} + b2 \quad (4.1)$$

Çizelge 4.8’den bias ve ağırlık değerlerine ait matrisler ile transfer fonksiyonlarına ait denklemler, modele ait genel denklemde yerine yazılarak elde edilebilir. Modelde kullanılan aktivasyon fonksiyonlarına ait denklemler, Denklem (4.2) ve (4.3) ‘te verilmiştir.

Hiperbolik tanjant fonksiyonu:

$$f_h = \frac{e^n - e^{-n}}{e^n + e^{-n}} \quad (4.2)$$

Log-sigmoid fonksiyonu:

$$f_s = \frac{1}{1 + e^{-n}} \quad (4.3)$$

b1 matrisi:

$$b_1 = [3,3799 \quad 6,5265 \quad -5,9584 \quad -7,0501 \quad -3,5902] \quad (4.4)$$

b2 matrisi:


$$b_2 = [2,5046] \quad (4.5)$$

Ağırlıklar:


$$w_1 = \begin{bmatrix} -3,0549 & -2,8612 & -2,2259 & -3,0234 & -3,1253 & -4,4021 & 1,3429 & -2,9446 & -2,8045 \\ -7,5441 & -1,989 & 18,0586 & -4,2367 & -4,7918 & -11,31 & 6,9640 & 8,1304 & -0,5274 \\ -2,7439 & -3,1354 & -2,8815 & -3,2471 & -3,1277 & -4,7547 & -4,019 & -1,7576 & -3,2545 \\ 7,1031 & -3,1354 & -5,3261 & 2,2257 & 3,8394 & 2,9535 & 4,9553 & -3,7249 & 1,6393 \\ -3,7086 & 3,8157 & -0,5144 & -0,6555 & -2,4799 & 0,2609 & 0,9279 & 1,5453 & 2,5413 \end{bmatrix} \quad (4.6)$$

$$w_2 = \begin{bmatrix} 2,9522 \\ -10,3417 \\ -3,2518 \\ 5,2848 \\ -6,059 \end{bmatrix} \quad (4.7)$$


Analiz sonucunda gerçek değer ve tahmin değerleri arasındaki kıyaslamaların grafik üzerinde incelenmesi, hata dağılımı, hata histogramı ve hatanın normal olasılık grafiği Şekil 4.5, 4.6, 4.7 ve 4.8 ‘de gösterilmiştir.




Şekil 4.5. Yapay sinir ağı tahmin ve gerçek değerleri.



Şekil 4.6. Yapay sinir ağı tahmin değerleri ve dağılımı.



Şekil 4.7. Yapay sinir ağıları hata histogramı.



Şekil 4.8. Yapay sinir ağıları hata normal olasılığı.

Tahmin edilen değerlere ait hata dağılımı sıfır çizgisine yakın bir biçimde dağıldığı görülmektedir. Hata histogramı sağa açık bir grafik oluşturmasına rağmen sıfır hata frekansı büyük olduğu için tahmin değerleri gerçek değerlerle uyumludur.

Analiz sonucunda yapay sinir ağılarına ait gerçek değerler ve tahmin değerleri ve bu değerler arasındaki hata değerleri Çizelge 4.9’da verilmiştir.

Çizelge 4.9. Yapay sinir ağıları gerçek değerler ve tahmin değerleri.

Yıllar	Gerçek Değerler	Tahmin değerleri	Hata
1998	6161	6222,649	-61,649
1999	6146	6211,235	-65,235
2000	5833	5815,466	17,534
2001	5568	5604,949	-36,949
2002	5204	5285,887	-81,887
2003	5878	5555,863	322,137
2004	5237	5244,929	-7,929
2005	5036	5142,698	-106,698
2006	5277	5137,734	139,266
2007	5553	5237,726	315,274
2008	5097	5109,968	-12,968
2009	5374	5452,331	-78,331
2010	5491	5507,757	-16,757
2011	7300	7298,056	1,944
2012	6612	6741,509	-129,509
2013	6225	6258,591	-33,591
2014	7401	7351,248	49,752
2015	8326	8385,498	-59,498
2016	7829	7781,125	47,875
2017	8465	8539,276	-74,276
2018	8938	8766,929	171,071

İki analiz sonuçlarının incelenmesi ve en uygun sonucu veren modelin tespit edilmesinde performans kriteri olarak belirlilik katsayısı ve hata kareleri ortalaması (MSE) dikkate alınmıştır. Hata kareleri ortalamasına (MSE) ait formülasyon Denklem (4.4)’de belirtilmiştir. Hata (e) tahmin değerleri ile gerçek değerler arasındaki farkı ifade etmektedir.

$$MSE = \frac{\text{Hata Kareleri Toplamı}}{N} \quad (4.4)$$

Belirleme katsayısı (R^2) (Günel, 2003):

$$R^2 = \frac{RSS}{TSS} = 1 - \frac{ESS}{TSS} \quad (4.5)$$

Belirleme katsayısının hesaplanması regresyon hata kareleri toplamın (RSS) ile genel hata karelerine (TSS) bölünmesiyle elde edilir. Ayrıca hata kareleri toplamı (ESS) genel hata karelerine bölünüp 1'den çıkarılarak da hesaplanabilir. Belirleme katsayısının büyük değerlere sahip olması analiz ile ilgisiz değişkenlerinde hesaplama dâhil edildiği için daima modelin uygun sonuçlar oluşturduğu anlamına gelmez. Ama modelde etkili olan verilerin açıklanmasında önemli bir belirleyicidir. Belirleme katsayısının karekökü alındığında bağımlı değişken ile bağımsız değişken arasındaki ilişkiyi ifade eden çoklu korelasyon katsayısının hesaplanmasını sağlar (Şahinler, 2000).

İki model için de değişkenleri açıklamak için uygun performans göstermektedir. İkinci performans kriteri olan MSE değerleri de uygun sınırlar içindedir. Ancak yapay sinir ağlarına ait model performansı belirleme katsayısı ve hata karelerinin ortalaması (MSE) bağımlı değişkenin gerçek değerlere daha yakın sonuçların oluşturulmasında daha etkili olduğu Çizelge 4.10'da açıkça görülmektedir.

Çizelge 4.10. Performans kriterleri.

	R^2 (%)	MSE
YSA	99,0	87,149
Regresyon	93,7	199,747

5. SONUÇ VE ÖNERİLER

Çalışma da bağımlı değişken ve bağımsız değişkenler regresyon analizi ve YSA ile analiz yapılmıştır. Oluşturulan iki modelin kıyaslanabilmesi için belirleme katsayısı ve hata kareleri ortalaması performans kriteri olarak kullanılmıştır. Regresyon analizinde t testi ve F testi %95 güven aralığında test edilmiştir. Yapay sinir ağları ileri beslemeli ağ yapısı hatayı geriye doğru yayarak ağırlıklandıran Levenberg-Marquardt algoritması kullanılarak eğitilmiştir.

Demiryolu yolcu taşıma talebine ait değerlerin tespit edilmesinde öncelikli olarak değişken sayıları da göz önünde bulundurarak çoklu doğrusal regresyon analizi ile değişkenler arasındaki ilişki korelasyon analizi ile belirlenmiştir. Korelasyon analizinde bağımsız değişkenler modelin %96,8'ini açıklamıştır. Uygun değerlerin hesaplamasında bir kıstas oluşturabilmek için yapay sinir ağları ile modelleme yapılmıştır.

Yapay sinir ağları ile analizde bağımsız değişkenler çıktı değerinin açıklanmasında %99,5'ini oluşturmaktadır. Regresyon analizi ve yapay sinir ağları için bağımlı değişkeni açıklama oranı yeterli olduğu belirlenmiştir.

Regresyon analizin sonucunda bazı katsayılarının negatif değerler oluşturduğu, sadece nüfus (N) ve demiryolu hat uzunluğunun (DHU) anlamlı olduğu belirlenmiştir.

YSA ve regresyon analizinin grafikler ile gösterimlerinde tahmin değerleri-gerçek değerler, tahmin-hata, hata normal olasılığı grafiği ve hata histogramından faydalanılmıştır. Regresyon analizine ait grafiklerde tahmin-gerçek değerlerin birbirine yakın değerlerde olduğu, hata dağılımının sıfır aralığında dağılım gösterdiği ve hata histogramının simetrik dağılım gösterdiği görülmektedir.

YSA sonucu grafiklerde tahmin edilen değerlere ait hata dağılımı sıfır hata düzeyine yakın dağılım gösterdiği ve hata histogramının sağa açık bir grafik oluşturduğu tespit edilmiştir. Hata histogramı sağa açık bir grafik oluşturmasına rağmen sıfır hata frekansı büyük olduğu ve tahmin değerleri ile gerçek değerler arasında uygun bir yapının olduğu anlaşılmaktadır.

Demiryolu yolcu sayısının oluřturulmasında kullanılan bağımsız deęişkenlerin önem derecesine göre sıralama yapmayı saęlayan duyarlılık analizinde gayrisafi yurtiçi hasılanın en önemli deęişken olduęu belirlenmiştir. Duyarlılık analizinde deęişkenler önem derecesine göre karayolu yolcu sayısı, nüfus, motorlu taşıt sayısı, demiryolu yolcu vagon sayısı, otomobil sayısı, demiryolu hat uzunluęu, demiryolu yolcu vagon kapasitesi ve demiryolu yolcu taşıma giderleri olarak belirlenmiştir.

Modellerin performans kriterleri incelendięinde yapay sinir aęlarının regresyon analizine göre belirleme katsayısı modelinde bağımsız deęişkenlerin, bağımlı deęişkeni daha iyi açıkladıęı, hata kareleri ortalamasının daha düşük deęerler oluřturduęu tespit edilmiştir. Modellerden elde edilen sonuçlara baęlı olarak bağımlı deęişken deęerlerinin tahmin edilmesinde yapay sinir aęlarının daha uygun deęerler oluřturduęu belirlenmiştir.

Böylece yapay sinir aęları demiryolu yolcu taşıma talebinde:

- Yapımı planlanan hatlarda oluřacak yolcu kapasitesinin tespit edilmesi,
- Yolcu kapasitesine göre hat inşa etme ve planlama önceliklerinin belirlenmesi,
- Planlamalara ait uygun bütçe ve yatırımların oluřturulması,
- Mevcut hatlardaki oluřabilecek tıkanıklıkların önceden belirlenmesini,
- Kısa, orta ve uzun vadede yolcu talebinin tahmin edilmesi, yerinde kararların alınması ve maddi kaynakların belirlenen doęrultuda harcanmasında yarar saęlayacaęı düşünölmektedir.

KAYNAKLAR

- Adıyaman, F., 2007. Talep tahmininde yapay sinir ağlarının kullanılması, Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- Agatonovic-Kustrin, S. ve Beresford, R., 2000. Basic concept of artificial neural network modeling and its application in pharmaceutical research, *Journal of Pharmaceutical and Biomedical Analysis*, 22, 717-727.
- Akbulut, F., 2016. Kentsel ulaşım hizmetlerinin planlanması ve yönetiminde sürdürülebilir politika önerileri, *Kastamonu Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 11, 336-355.
- Akpolat, M. S., 2004. Tanzimat sonrası osmanlığında bir kesit: Adana-Mersin demiryolu istasyon binaları, *Hacettepe Üniversitesi Edebiyat Fakültesi Dergisi*, 21, 1, 77-93.
- Akyurt, İ. Z., 2015. Talep tahminin yapay sinir ağları ile modellenmesi: yerli otomobil örneği, *İstanbul Üniversitesi İktisat Fakültesi Ekonometri ve İstatistik Dergisi*, 23, 147-157.
- Anderson, R. E., Babin, B. J., Black, W. C., Hair, Jr. ve Joseph, F., 2010. *Multivariate data analysis*, 7. Edition, Pearson Prentice Hall, America.
- Archdeacon, T. J., 1994. *Correlation and regression analysis: a historian's guide*, 1. Edition, America.
- Atalay, A. ve Tortum, A., 2019. Türkiye’de sürdürülebilir ulaşım için türlerarası (intermodal) ulaşım sistemi, 13. Ulaştırma Kongresi, Erzurum, Bildiriler Kitabı, Cilt 1, 15-25.
- Ataseven, B., 2013. Yapay sinir ağları ile öngörü modellemesi, *Öneri Dergisi*, 10, 39, 101-115.
- Aydemir, H., 2016. Türkiye ulaştırma politikaları çerçevesinde demiryolu ulaştırma sisteminin genel durumunun irdelenmesi ve geleceğine bakış, *Demiryolu Mühendisliği*, 3, 41-46.
- Bayata, H. F., Sağlamyürek, H. N. ve Bayrak, O. Ü., 2018. Demiryolu yolcularının tutum ve davranışlarının farklı istatistiksel yöntemler ile modellenmesi, *Iğdır Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 8, 4, 141-151.
- Berg, B. L. ve Lune, H., 2016. *Qualitative research methods for science social*, Arı A. (Editör), 9. Baskı, Eğitim yayınevi, Konya.
- Blainey, S., Hickford, A. ve Preston, J., 2012. Barriers to passenger rail use: a review of the evidence, *Transport Reviews*, 32, 6, 675-696.

- Bojovic., N. ve Milenkovic, M., 2016. Railway demand forecasting, Rai B. U. (Editor), Handbook of Research on Emerging Innovations in Rail Transportation Engineering, Engineering Science Reference, USA.
- Bozkurt, H. Y., 2013. Zaman serileri analizi, 2. Baskı, Ekin Yayınevi, Bursa.
- Caner, M. ve Akarslan, E., 2009. Mermer kesme işleminde spesifik enerji faktörünün ANFIS ve YSA yöntemleri ile tahmini, Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi, 15, 2, 223.
- Chen, Q., Wen, D., Li, X., Chen, D., Lv, H., Zhang, J. ve Gao, P., 2019. Emprical mode decomposition based long short-term memory neural network forecasting model for the sorht-term metro passenger flow, Plos One, 14, 9, 1-18.
- Çelebi, D., Bolat, B. ve Bayraktar, D., 2009. Light rail passenger demand forecasting by artificial neural networks, 2009 International Conference on Computer & Industrial Engineering, 1-5.
- Çetin, B., Barış, S. ve Saroğlu, S., 2011. Türkiye’de karayolları gelişimine tarihsel bir bakış, Çankırı Karatekin Üniversitesi İktisadi İdari Bilimler Fakültesi Dergisi, 1, 1, 123-150.
- Daniel, L., Chaturvedi, T. K. ve Kolhe, L. M., 2018. Dynamic economic load dispatch using levenberg marquardt algorithm, Energy Procedia, 144, 95-103.
- Dougherty, M., 1995. A review of neural networks applied to transport, Transportation Research Part C: Emerging Technologies, 3, 4, 247-260.
- DPT, Devlet Planlama Teşkilatı, 2001. Demiryolu Ulaştırması Alt Komisyon Raporu, Sekizinci Beş Yıllık Kalkınma Planı, Ankara.
- Elmas, Ç., 2007. Yapay zeka uygulamaları, 1. Baskı, Seçkin Yayıncılık, Ankara.
- ERRAC, European Rail Research Advisory Council, 2017. Rail Vision 2050, Belçika.
- Evren, G. ve Dünder, S., 2016. Demiryolu, 3. Baskı, Birsan Yayınevi, İstanbul.
- Förstberg, J., 2000, Ride comfort and motion sickness in tilting trains: human responses to motion experiments and simulator experiments (TRITA-FKT), Adtranz, Sweden.
- Gallo, M., Luca, G. D., D’acierno, L. ve Botte, M., 2019. Artificial neural networks for forecasting passenger flows on metro lines, Sensors, 19, 15, 1-14.
- Göker, A., 1996. Yüksek hızlı tren TUBİTAK raporu, Ankara.

- Göktaş, Ö., 2005. Teorik ve uygulamalı zaman serileri analizi, Beşir Kitabevi, İstanbul.
- Günel, Alptekin, 2003. Regresyon denkleminin başarısını ölçmede kullanılan belirleme katsayısı ve kritiği, Doğu Üniversitesi Dergisi, 4, 2, 133-140.
- Hamzaçebi, C., 2011. Yapay sinir ağları tahmin amaçlı kullanımı, Ekin Yayınevi, Bursa.
- Hu, G., Liu, W. ve Yang, H., 2018. A reliability-based assignment method for railway networks with heterogeneous passenger, Transportation Research Part C: Emerging Technologies, 93, 501-524.
- Kannaiyan, M., Karthikeyan, G., Gowthami, J. ve Raghuvaran, T., 2020. Prediction of specific wear rate for LM25/ZRO2, composites using levenberg-marquardt backpropagation algorithm, Journal of Materials Research and Tecnology, 9, 1, 530-538.
- Karahan, M., 2011. İstatistiksel tahmin yöntemleri: yapay sinir ağları metodu ile ürün talep tahmini uygulaması, Doktora Tezi, Selçuk Üniversitesi, Sosyal Bilimler Enstitüsü, Konya.
- KGM, 2018. Karayolları Ulaşım İstatistikleri 2018, Ankara.
- Kılıç, G., 2015. Yapay sinir ağlarıyla yemekhane günlük talep tahmini, Yüksek Lisans Tezi, Pamukkale Üniversitesi, Fen Bilimleri Enstitüsü, Denizli.
- Kidd, M. P., Luby, R. M. ve Larsen, J., 2019. Passenger and operator-oriented scheduling of large railway projects, Transportation Research, Part C, 102, 136-152.
- Kobu, B., 2014. Üretim yönetimi, 17. Baskı, İstanbul.
- Korucuk, M. F., 2016. Türkiye demiryolu yurtiçi yük taşıma talebinin yapay sinir ağlarıyla modellenmesi, Yüksek Lisans Tezi, Fen Bilimleri Enstitüsü, Atatürk Üniversitesi.
- Kulshreshtha, M. ve Nag, B., 2000. Structure and dynamics of non-suburban passenger travel demand in indian railways, Transportation, 27, 221-241.
- Law, A. M. ve Kelton W. D., 1991. Simulation modeling and analysis, 2. Edition, International Edition Copyright, Singapore.
- Mammadli, S., 2017. Financial time series prediction using artificial neural network based on levenberg-marquardt algorithm, Procedia Computer Science, 120, 602-607.
- Monks, J. G., 1996. Schaum's outlines operations management: theory and problems, Çeviren:Sevinç Üreten, 2. Baskı, Nobel yayınevi, Ankara.

- Nordenholz, F., Winkler, C. ve Knörr, W., 2016. Analysing the model shift to rail potential within the long-distance passenger travel market in germany, 44th European Transport Conference, Spain.
- Oğuz, M., 2001. Yalıtkan maddelerde elektriksel delinme dayanımının yapay sinir ağları ile belirlenmesi, Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- Okkan, U., 2009. Aylık yağış ve sıcaklık değişimlerinin izmir içme suyu havzalarının akımlarına etkileri, Yüksek Lisans Tezi, Dokuz Eylül Üniversitesi, Fen Bilimleri Enstitüsü, İzmir.
- Okkan, U., ve Mollamahmutoğlu, A., 2010. Yiğitler çayı günlük akımların yapay sinir ağları ve regresyon analizi ile modellenmesi, Dumlupınar Üniversitesi Fen Bilimleri Enstitüsü Dergisi, 23, 33-48.
- Öztemel, E., 2003. Yapay sinir ağları, 1. Baskı, Papatya Yayıncılık, İstanbul.
- Sağlamyürek, H., 2018. TCDD yük ve yolcu taşımacılığının AHP yöntemi ile modellenmesi, Yüksek Lisans Tezi, Erzurum Üniversitesi, Fen Bilimleri Enstitüsü, Erzurum.
- Şahin, İ., 2001. Kılavuzlanmış yüksek hız kara ulaştırma sistemleri ve teknolojileri, YTÜ Dergisi, 48-57.
- Şahinler, S., 2000. En küçük kareler yöntemi ile doğrusal regresyon modeli oluşturmanın temel prensipleri, MKÜ Ziraat Fakültesi Dergisi, 5, 1-2, 57-73.
- Tanrıverdi, S. M., 2015. Yüksek hızlı tren hatlarının ulaştırma seçimi üzerindeki etkisi, Yüksek Lisans Tezi, İstanbul Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- TCDD, 2018(a). Faaliyet Raporu 2018, Ankara.
- TCDD, 2018(b). Demiryolu Sektör Raporu, Ankara.
- Tekin, M., 2012. Üretim yönetimi, 8. Baskı, Günay Ofset, Konya.
- TMH, Türkiye Mühendislik Haberleri, 2006. 1923-1940 Dönemi Demiryolları, 2-3, 442-443.
- Top, A. ve Yılmaz, E., 2013. Üretim yönetimi, 3. Baskı, İdeal, Türkiye.
- Tsai, T., Lee, C. ve Wei, C., 2009. Neural network based temporal feature models for short-term railway passenger demand forecasting, Expert Systems with Applications, 36, 3728-3736.
- UDHB, Ulaştırma, Denizcilik ve Haberleşme Bakanlığı, 2013, 11. Ulaştırma, Denizcilik Ve Haberleşme Şurası Demiryolu Çalışma Grubu Rapor Özeti, Ankara.

- Uğurlu, Y., 2018. Avrupa birliğinde demiryolları, Demiryolu Mühendisliği, 7, 37-44.
- UİC, International Union of Railways, 2019. Railway Technical Strategy Europe 2019, Paris, Fransa.
- Üreten, S., 2006. Üretim/işlemler yönetimi, 5. Baskı, Gazi Kitabevi, Ankara.
- Wardman, M. R., 2006. Demand for rail travel and the effects of external factors, Transportation Research Part E: Logistics and Transportation Review, 42, 3, 129-148.
- Wardman, M., Lythgoe, W. ve Whelan, G., 2007. Passenger demand forecasting: cross-sectional models revisited, Research in Transportation Economics, 20, 119-152.
- Worsley, T., 2012. Rail demand forecasting using the passenger demand forecasting handbook on the move, Supporting the Paper 2, RAC Foundation, 1-31.
- Xie, M., Li, X., Zhou, W. ve Fu, Y., 2014. Forecasting the short-term passenger flow on high speed railway with neural networks, Computational Intelligence and Neuroscience, 1-8.
- Xu, G., Liu, W. ve Yang, H., 2018. A reliability-based assignment method for railway networks heterogeneous passengers, Transport Research Part C 93, 501-524.
- Yalçın, S. P., 2013, Talep yönetimi, dağıtımı ve tedarik zinciri performansı yönetim uygulamalarının tedarik zinciri performansı üzerindeki etkileri, Yüksek Lisans Tezi, Başkent Üniversitesi, Sosyal Bilimler Enstitüsü, Ankara.
- Yaşar, M., 2004. Günlük akışlardaki boşlukların yapay sinir ağları kullanılarak tamamlanması, Yüksek Lisans Tezi, Pamukkale Üniversitesi, Fen Bilimleri Enstitüsü, Denizli.
- Yavuz, S., 2009. Regresyon analizinde doğrusala dönüştürme yöntemleri ve bir uygulama, Atatürk Üniversitesi İktisadi ve İdari Bilimler Dergisi, 23, 1, 165-179.
- Yüksel, H., 2010. Üretim/işlemler yönetimi temel kavramlar, 2. Baskı, Nobel, Ankara.
- URL-1 <uic.org.tr/passenger/highspeed/article/high-speed-rail-history>, Erişim Tarihi: 18.11.2019.
- URL-2 <www.uab.gov.tr/uploads/pages/demiryolu/demiryolu.pdf>, Erişim Tarihi: 14.02.2020.
- URL-3 <tcdd.gov.tr/content/57>, Erişim Tarihi: 10.02.2020.
- URL-4 <tcdd.gov.tr/content/60>, Erişim Tarihi: 10.02.2020.

URL-5 <uic.org.tr/IMG/pdf/20181001-high-speed-lines-in-the-world.pdf>, Eriřim Tarihi: 13.12.2019.

URL-6 <tcddtasimacilik.gov.tr/trenler>, Eriřim Tarihi: 17.02.2020.

URL-7 <tcdd.gov.tr/content/95>, Eriřim Tarihi: 10.02.2020.

URL-8 <railturkeytravel.wordpress.com>, Eriřim Tarihi: 28.11.19.

URL-9 <tcddtasimacilik.gov.tr/sayfa/istatistikler>, Eriřim Tarihi: 17.02.2020.



EKLER

EK A. t tablosu

Ek B. F tablosu (0,05)



Ek A. t Tablosu

Çizelge A.1. t tablosu.

Serbestlik D.	Tek Yönlü				
	0,25	0,05	0,025	0,01	0,005
	Çift Yönlü				
	0,5	0,1	0,05	0,02	0,01
1	1,000	6,34	12,71	31,82	63,66
2	0,816	2,92	4,30	6,96	9,92
3	0,765	2,35	3,18	4,54	5,84
4	0,741	2,13	2,78	3,75	4,60
5	0,727	2,02	2,57	3,36	4,03
6	0,718	1,94	2,45	3,14	3,71
7	0,711	1,90	2,36	3,00	3,50
8	0,706	1,86	2,31	2,90	3,36
9	0,703	1,83	2,26	2,82	3,25
10	0,700	1,81	2,23	2,76	3,17
11	0,697	1,80	2,20	2,72	3,11
12	0,695	1,78	2,18	2,68	3,06
13	0,694	1,77	2,16	2,65	3,01
14	0,692	1,76	2,14	2,62	2,98
15	0,691	1,75	2,13	2,60	2,95
16	0,690	1,75	2,12	2,58	2,92
17	0,689	1,74	2,11	2,57	2,90
18	0,688	1,73	2,10	2,55	2,88
19	0,688	1,73	2,09	2,54	2,86
20	0,687	1,72	2,09	2,53	2,84
21	0,686	1,72	2,08	2,52	2,93
22	0,686	1,72	2,07	2,51	2,82
23	0,685	1,71	2,07	2,50	2,81
24	0,685	1,71	2,06	2,49	2,80
25	0,684	1,71	2,06	2,48	2,79
26	0,684	1,71	2,06	2,48	2,78
27	0,684	1,70	2,05	2,47	2,77
28	0,683	1,70	2,05	2,47	2,76
29	0,683	1,70	2,04	2,46	2,76
30	0,683	1,70	2,04	2,46	2,75
35	0,682	1,69	2,03	2,44	2,72
40	0,681	1,68	2,02	2,42	2,71
45	0,680	1,68	2,02	2,41	2,69
50	0,679	1,68	2,01	2,40	2,68

EK B. F Tablosu (0,05)**Çizelge B.1. F tablosu (0,05).**

V_2	V_1							
	4	5	6	7	8	9	10	12
3	9,12	9,01	8,94	8,89	8,85	8,81	8,79	8,74
4	6,39	6,26	6,16	6,09	6,04	6,00	5,96	5,96
5	5,19	5,05	4,95	4,88	4,82	4,77	4,74	4,68
6	4,53	4,39	4,28	4,21	4,15	4,10	4,06	4,00
7	4,12	3,97	3,87	3,79	3,73	3,68	3,64	3,57
8	3,84	3,69	3,58	3,50	3,44	3,39	3,35	3,28
9	3,63	3,48	3,37	3,29	3,23	3,18	3,14	3,07
10	3,48	3,33	3,22	3,14	3,07	3,02	2,98	2,91
11	3,36	3,20	3,09	3,01	2,95	2,90	2,85	2,79
12	3,26	3,11	3,00	2,91	2,85	2,80	2,75	2,69
13	3,18	3,03	2,92	2,83	2,77	2,71	2,67	2,60
14	3,11	2,96	2,85	2,76	2,70	2,65	2,60	2,53
15	3,06	2,90	2,79	2,71	2,64	2,59	2,54	2,48
16	3,01	2,85	2,74	2,66	2,59	2,54	2,49	2,42
17	2,96	2,81	2,70	2,61	2,55	2,49	2,45	2,38
18	2,93	2,77	2,66	2,58	2,51	2,46	2,41	2,34
19	2,90	2,74	2,63	2,54	2,48	2,42	2,38	2,31
20	2,87	2,71	2,60	2,51	2,45	2,39	2,35	2,28
21	2,84	2,68	2,57	2,49	2,42	2,37	2,32	2,25
22	2,82	2,66	2,55	2,46	2,40	2,34	2,30	2,23
23	2,80	2,64	2,53	2,44	2,37	2,32	2,27	2,20
24	2,78	2,62	2,51	2,42	2,36	2,30	2,25	2,18
25	2,76	2,60	2,49	2,40	2,34	2,28	2,24	2,16
26	2,74	2,59	2,47	2,39	2,32	2,27	2,22	2,15
27	2,73	2,57	2,46	2,37	2,31	2,25	2,20	2,13

ÖZGEÇMİŞ

Adı ve Soyadı : Fatma Çakır

Adres : Ankara

EĞİTİM BİLGİLERİ (Kurum ve Yıl)

Lisans : Bozok Üniversitesi, İnşaat Mühendisliği Bölümü, 2014-2018

Y. Lisans: Aksaray Üniversitesi, İnşaat Mühendisliği/Ulaştırma ABD, 2018-

MESLEKİ DENEYİM VE ÖDÜLLERİ

1. Demirten İnşaat İletişim Enerji San. Tic. Ltd. Şti. Kurumu / Yaz Stajı
2. Geotem Jeoteknik İnşaat Mühendislik Müşavirlik Şti. Kurumu / Yaz Stajı

TEZDEN ÜRETİLEN YAYINLAR, SUNUMLAR VE PATENTLER

Uluslararası Hakemli Dergilerde Yayınlanan Makaleler

1. Çakır, F. ve Tosun B., H., 2021. Türkiye demiryolu yolcu taşıma talebinin tahmini, Düzce Üniversitesi Bilim ve Teknoloji Dergisi, 9,1, 252-264.