



BİNGÖL ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ
İŞLETME ANA BİLİM DALI

YAPAY SİNİR AĞLARI İLE TALEP TAHMİNİ:
TÜRKİYE'DEKİ OTOMOBİL SEKTÖRÜNDE BİR
UYGULAMA

Mehmet Zeki SEÇMEN

DOKTORA TEZİ

Danışman
Prof. Dr. Sait PATİR

Bingöl – 2024

BİNGÖL ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ
İŞLETME ANA BİLİM DALI

YAPAY SİNİR AĞLARI İLE TALEP TAHMİNİ:
TÜRKİYE’DEKİ OTOMOBİL SEKTÖRÜNDE BİR
UYGULAMA

Mehmet Zeki SEÇMEN

DOKTORA TEZİ

Danışman
Prof. Dr. Sait PATİR

Bingöl – 2024

İÇİNDEKİLER

BİLİMSEL ETİK BİLDİRİMİ.....	IV
TEZ KABUL VE ONAY	V
ÖNSÖZ.....	VI
ÖZET.....	VII
ABSTRACT	VIII
KISALTMALAR	IX
TABLO LİSTESİ	X
ŞEKİL LİSTESİ.....	XI
1. GİRİŞ	1
BİRİNCİ BÖLÜM.....	4
OTOMOBİL SEKTÖRÜ	4
1.1. Dünyada Otomobil Sektörü	4
1.2. Türkiye’de Otomobil Sektörü	6
1.2.1. Türkiye Otomotiv Sanayisinde Üretim ve Satış Verileri	10
1.2.2. Türkiye’nin İlk Yerli Otomobili Togg.....	14
1.2.2.1. Togg Neden Önemlidir?	15
1.2.2.2. Togg’un Sürdürülebilirlik ve Çevre Dostu Özellikleri	16
1.2.2.3. Togg ile Türkiye’nin Otomotiv Sektöründeki Potansiyeli	16
1.2.2.4. Togg’un Ekonomik Önemi	17
İKİNCİ BÖLÜM	19
TALEP TAHMİNİ.....	19
2. TALEP TAHMİNİ.....	19
2.1. Talep Tahmin Aşamaları.....	22
2.2. Talep Tahmininde Kullanılan Yöntemler	23
2.2.1 Nitel Tahmin Yöntemleri.....	23
2.2.2. Nicel Tahmin Yöntemleri	25
2.3. Literatür Taraması.....	33
ÜÇÜNCÜ BÖLÜM	45
YAPAY ZEKÂ VE YAPAY SİNİR AĞLARI.....	45
3. YAPAY ZEKÂ	45
3.1. Yapay Sinir Ağları.....	46
3.2. Yapay Zekâ ve Yapay Sinir Ağları Arasındaki İlişki ve Farklar	47
3.3.Yapay Sinir Ağlarının Yapısı ve Temel Elemanları.....	48
3.3.1. Yapay Sinir Hücresi.....	48

3.3.2. Yapay Sinir Ağı Hücresi Elemanları	49
3.4. Yapay Sinir Ağı Mimarileri.....	52
3.5. Tek Katmanlı Yapay Sinir Ağları.....	53
3.6. Çok Katmanlı İleri Beslemeli Yapay Sinir Ağları.....	53
3.7. Geri Beslemeli Yapay Sinir Ağları.....	54
3.8. Yapay Sinir Ağlarında Öğrenme	55
3.9. Geri Yayılım Algoritması	55
3.10. Yapay Sinir Ağlarının Eğitilmesi	56
3.11. Yapay Sinir Ağlarının Performans Ölçütlerinin Belirlenmesi.....	58
3.12. Yapay Sinir Ağlarının Kullanım Alanları.....	60
3.12.1. Endüstriyel Alanda Yapay Sinir Ağlarının Kullanımı.....	60
3.12.2. Ulaştırma ve Havacılık Alanında Yapay Sinir Ağlarının Kullanımı	61
3.12.3. Finans, Borsa ve Kredi Kartı Alanında Yapay Sinir Ağlarının Kullanımı	61
3.12.4. Tıp, Biomedikal ve İlaç Sanayi Alanında Yapay Sinir Ağlarının Kullanımı	62
3.12.5. İletişim Sanayi Alanında Yapay Sinir Ağlarının Kullanımı	62
3.13. Yapay Sinir Ağlarının Avantajları	63
3.14. Yapay Sinir Ağlarının Dezavantajları.....	63
DÖRDÜNCÜ BÖLÜM	65
ÖRNEK UYGULAMA	65
4.1. Materyal.....	65
4.2. Veri Setinin Hazırlanması	65
4.3. Tahmin Modellerin Kurulması.....	70
4.3.1. ÇRA Modelinin Uygulaması.....	71
4.3.2. NARX Modeline Dayalı Uygulama	77
4.3.3.YSA Modelinin Uygulaması	84
4.4. ÇRA, NARX ve YSA Modellerin Karşılaştırılması	88
4.5. YSA Modelinin 12 Aylık Tahmin Değerleri	90
5. SONUÇ VE ÖNERİLER.....	91
KAYNAKÇA	100
EKLER.....	113
EK-1 2014-2023 Yılları Arasında Türkiye’de Üretim Yapan 6 Otomotiv Firmasının Aylık Otomobil Satışları	113
EK-2 Tahminlemede Kullanılan Giriş Verileri.....	116

EK-3 Tahminlemede Kullanılan Normalize Edilmiş Veriler	119
EK-4 Çoklu Regresyon Analizi Modeli Tahmin Değerleri	122
EK-5 NARX Modeli Tahmin Değerleri.....	125
EK-6 YSA Modeli Tahmin Değerleri	128
EK-7 ÇRA Modelinde Kullanılan Kodlar	131
EK-8 NARX Modelinde Kullanılan Kodlar	134
EK-9 YSA Modelinde Kullanılan Kodlar	139
ÖZGEÇMİŞ.....	142



BİLİMSEL ETİK BİLDİRİMİ

Doktora tezi olarak hazırladığım “*Yapay Sinir Ağları İle Talep Tahmini: Türkiye’deki Otomobil Sektöründe Bir Uygulama*” adlı çalışmanın öneri aşamasından sonuçlanmasına kadar geçen süreçte bilimsel etiğe ve akademik kurallara özenle uyduğumu, tez içindeki tüm bilgileri bilimsel ahlak ve gelenek çerçevesinde elde ettiğimi, tez yazım kurallarına uygun olarak hazırladığım bu çalışmamda doğrudan veya dolaylı olarak yaptığım her alıntıya kaynak gösterdiğimi ve yararlandığım eserlerin kaynakçada gösterilenlerden oluştuğunu beyan ederim.

.../.../202..

İmza

Mehmet Zeki SEÇMEN

TEZ KABUL VE ONAY

BİNGÖL ÜNİVERSİTESİ SOSYAL BİLİMLER ENSTİTÜSÜ MÜDÜRLÜĞÜNE

Mehmet Zeki SEÇMEN tarafından hazırlanan “*Yapay Sinir Ağları ile Talep Tahmini: Türkiye’deki Otomobil Sektöründe Bir Uygulama*” başlıklı bu çalışma, 30.07.2024 tarihinde yapılan tez savunma sınavı sonucunda *oybirliği* ile başarılı bulunarak jürimiz tarafından İşletme Anabilim Dalı’nda Doktora tezi olarak kabul edilmiştir.

TEZ JÜRİSİ ÜYELERİ (Unvanı, Adı ve Soyadı)

Başkan	: Prof. Dr. Abdolvahap BAYDAŞ	İmza:
Danışman	: Prof. Dr. Sait PATIR	İmza:
Üye	: Prof. Dr. Mehmet Selami YILDIZ	İmza:
Üye	: Doç. Dr. Mehmet GÜVEN	İmza:
Üye	: Doç. Dr. Nuh ALPASLAN	İmza:

ONAY

Bu Tez, Bingöl Üniversitesi Sosyal Bilimler Enstitüsü Yönetim Kurulunun/...../202.. tarih ve sayılı oturumunda belirlenen jüri tarafından kabul edilmiştir.

Doç. Dr. Nebi BUTASIM
Enstitü Müdürü

ÖNSÖZ

Talebi üretim miktarını ve tüketimi belirlemek için kullanırız. Bir ürüne gelen talebi üretim miktarıyla uyumlu bir şekilde yürütemezsek yani iyi bir talep tahmini yapmazsak çeşitli sorunlarla karşılaşabiliriz. Bu nedenle işletmeler gelecekteki talebe ilişkin net bir vizyona sahip olması onun planlamasını, performansını ve dolayısıyla kârını etkiler. İşletmeler doğru tahminde bulunarak rekabette öne geçerek uzun vadede başarılı olacaktır. Bu çalışma, Türkiye'de otomotiv sektöründe yapay zekâ tabanlı talep tahmin modellerinin etkinliğini araştırmak amacıyla hazırlanmıştır. Çalışmada, Türkiye’de otomobil satışını en çok yapan OYAK Renault, Tofaş, Toyota, Ford, Honda ve Hyundai firmalarının geçmiş verileri kullanılarak yapay sinir ağlarıyla talep tahmini yapılmıştır. Çalışma, literatür taraması, veri analizleri ve çeşitli yöntemlerin uygulanmasıyla tamamlanmıştır. Süreç boyunca birçok kaynaktan yararlanılarak kapsamlı bir araştırma gerçekleştirilmiştir. Çalışmanın, gelecekteki otomobil talebinin öngörülmesine ve sektörde kapasite artırımı veya azaltılması gibi yeni yatırımlara katkı sağlaması hedeflenmiştir.

Bu çalışmanın hazırlanmasında yardımlarını esirgemeyen danışman hocam *Prof.Dr. Sait PATİR*’a; tezin yazım aşamasında ve tashihinde katkılarını esirgemeyen Doç. Dr. Nuh ALPASLAN’a, Dr. Öğretim Üyesi Hüseyin ÜZEN’e ve eğitim hayatım boyunca yetişmemde katkısı olan tüm hocalarıma teşekkürlerimi sunmayı bir borç bilirim.

Çalışmamı tamamlamam konusunda moral ve motivasyonumu üst düzeyde tutmama yardımcı olan eşime, anneme ve babama şükranlarımı sunarım.

..../..../ 202..

Mehmet Zeki SEÇMEN

ÖZET

Bingöl Üniversitesi Sosyal Bilimler Enstitüsü Doktora Tez Özeti

Tezin Başlığı	: Yapay Sinir Ağları ile Talep Tahmini: Türkiye’deki Otomobil Sektöründe Bir Uygulama
Tezin Yazarı	: Mehmet Zeki SEÇMEN
Danışman	: Prof. Dr. Sait PATİR
Anabilim Dalı	: İşletme
Bilim Dalı	: Genel İşletme
Kabul Tarihi	: 30.07.2024
Sayfa Sayısı	: 9 (ön kısım) + 112 (tez) + 29 (ekler)
Dünya nüfusundaki hızlı artış, otomobil talebinin de hızla büyümesine yol açmaktadır. Bu durum, otomobil üreticileri için önemli bir baskı oluşturmakta ve gelecekteki talebi karşılamak amacıyla etkili planlama yapma gerekliliğini artırmaktadır. Piyasa koşulları, ekonomik göstergeler ve tüketici alışkanlıkları, otomobil talebini etkileyen temel faktörlerdir. Bu bağlamda, talep tahminine yönelik stratejiler geliştirmek, otomobil üreticilerinin rekabet gücünü artırmak ve üretim süreçlerini optimize etmek açısından büyük önem taşır. Talep tahmin yöntemleri, karmaşık süreçlerin modellenmesi ve bu süreçlere etki eden parametrelerin belirlenmesi için etkili çözümler sunmaktadır. Talep tahmin yöntemleri temel olarak nitel ve nicel yöntemler olmak üzere iki grupta ele alınmaktadır. Bu çalışmada nicel talep tahmin yöntemleri uygulanmıştır. Bu çalışmada, otomobil talebi tahmininde Çoklu Regresyon Analizi, NARX (Nonlinear Autoregressive with Exogenous Inputs) modeli ve Yapay Sinir Ağları modeli kullanılarak satış tahminleri yapılmıştır. Otomobil talebini etkileyen bağımsız değişkenler Brent Petrol Fiyatı, Dolar Kuru, Taşıt Kredi Faizleri, Tüketici Fiyat Endeksi (TÜFE), Araç Alım Düzeyi ve Otomobil Üretim Adedi, bağımlı değişken ise OYAK Renault, Tofaş, Toyota, Ford, Honda ve Hyundai firmalarının toplam otomobil satış adedi olarak alınmıştır. Çalışmada, üç modelin sonuçları karşılaştırılmış ve en etkili model belirlenmiştir. Modellerin tahmin doğruluğunu değerlendirmek amacıyla, Ortalama Hata Kareleri (MSE) ve Ortalama Mutlak Yüzde Hata (MAPE) gibi performans kriterleri kullanılmıştır. Yapılan analizler sonucunda, Yapay Sinir Ağları modelinin performansı $MSE=0,0210$ ve $MAPE=\%11,66$ olarak hesaplanmıştır. Bu sonuçlar, Yapay Sinir Ağları modelinin diğer iki yönteme kıyasla daha başarılı olduğunu ve otomobil talebini tahmin etmede daha güçlü bir performans sergilediğini ortaya koymuştur. Yapay Sinir Ağları Modeli ile 2014–2024 yılları arasındaki aylık otomobil satış verileri temel alınarak Ocak 2024 - Aralık 2024 arasındaki 12 aylık süreçte gerçekleşmesi beklenen otomobil talep tahmini yapılmıştır. Yapay Sinir Ağları modeli, gelecekteki otomobil satışlarını daha isabetli tahmin etme potansiyeli sunmuş ve bu sayede üreticilerin stratejik planlamalarına katkıda bulunabilecek bir tahmin aracı olarak öne çıkmıştır.	
Anahtar Kelimeler:	Yapay Zekâ, Yapay Sinir Ağları, Otomobil Talep Tahmini

ABSTRACT

Bingöl University Institute of Social Sciences Abstract of Doctoral Thesis

Title of the Thesis: Demand Forecasting with Artificial Neural Networks: An Application in the Automobile Industry in Turkey	
Author	: Mehmet Zeki SEÇMEN
Supervisor	: Professor Sait PATIR
Department	: Business
Sub-field	: General Business
Date	: 30.07.2024
Number of pages : 9 (preliminary section) + 112 (thesis) + 29 (appendices)	
The rapid growth of the global population has led to a significant increase in automobile demand. This situation creates considerable pressure on automobile manufacturers and heightens the necessity for effective planning to meet future demand. Market conditions, economic indicators, and consumer habits are the key factors influencing automobile demand. In this context, developing strategies for demand forecasting is crucial for enhancing the competitiveness of automobile manufacturers and optimizing their production processes. Demand forecasting methods offer effective solutions for modeling complex processes and determining the parameters that affect these processes. These methods are generally categorized into two groups: qualitative and quantitative approaches. In this study, quantitative demand forecasting methods have been applied. In this research, automobile demand forecasts were made using Multiple Regression Analysis, the NARX (Nonlinear Autoregressive with Exogenous Inputs) model, and the Artificial Neural Networks (ANN) model. The independent variables affecting automobile demand were identified as Brent Oil Price, Dollar Exchange Rate, Vehicle Loan Interest Rates, Consumer Price Index (CPI), Vehicle Purchase Level, and Automobile Production Quantity, while the dependent variable was the total number of car sales from the companies OYAK Renault, Tofaş, Toyota, Ford, Honda, and Hyundai. The results of the three models were compared in the study, and the most effective model was determined. To evaluate the accuracy of the models' predictions, performance metrics such as Mean Squared Error (MSE) and Mean Absolute Percentage Error (MAPE) were used. The analysis revealed that the performance of the Artificial Neural Networks model resulted in $MSE = 0.0210$ and $MAPE = 11.66\%$. These findings demonstrated that the Artificial Neural Networks model outperformed the other two methods, providing a stronger performance in predicting automobile demand. Using the Artificial Neural Networks model, automobile demand forecasts for the 12-month period from January 2024 to December 2024 were made based on monthly automobile sales data from 2014 to 2024. The Artificial Neural Networks model has shown the potential to make more accurate predictions of future automobile sales, positioning itself as a valuable forecasting tool that can contribute to manufacturers' strategic planning.	
Keywords: Artificial Intelligence, Artificial Neural Networks, Automobile Demand Forecasting	

KISALTMALAR

AB	Avrupa Birliđi
ABD	Amerika Birleşik Devletleri
ARIMA	Autoregressive integrated moving average(Bütünleşik Otoregresif Hareketli Ortalama)
AR	Otoregresif
ANN	Artificial Neural Networks (Yapay sinir ađları)
BAE	Birleşik Arap Emirlikleri
BMC	British Motor Company
ÇRA	Çoklu Regresyon Analizi
EVT	Elektrikli Vasıta Türkiye
MAN	Maschinenfabrik Augsburg-Nürnberg
MSE	Ortalama Hata Kareleri
MAPE	Ortalama Mutlak Yüzde Hata
ME	Ortalama Hata
NAR	Nonlinear AutoRegressive
NARX	Nonlinear AutoRegressive with eXogenous inputs
NET	Network Ağ
NIO	Nonlinear Input-Output
OICA	Uluslararası Motorlu Araç İmalatçıları Örgütü
OSD	Otomotiv Sanayi Derneđi
ODMD	Otomotiv Distribütörleri ve Mobilite Derneđi
TÜBİTAK	Türkiye Bilimsel ve Teknolojik Araştırma Kurumu
TÜFE	Tüketici Fiyat Endeksi
Togg	Türkiye'nin Otomobili Girişim Grubu
TCMB	Türkiye Cumhuriyeti Merkez Bankası
TÜİK	Türkiye İstatistik Kurumu
vb.	ve benzeri)
YSA	Yapay Sinir Ađı

TABLO LİSTESİ

Tablo 1.1 2023 Yılında Dünya’da Üretilen ve Satılan Otomobil Adeti.....	5
Tablo 1.2 Otomotiv Sanayi Firmalarının 2022 Yılındaki Üretim Verileri.....	11
Tablo 1.3 Otomotiv Sanayi Firmalarının 2022 Yılındaki Otomotiv Satış Verileri...	11
Tablo 1.4 2019-2022 Otomobil ve Hafif Ticari Araç Satışlarını Gösteren Tablo.....	13
Tablo 1.5 Togg Satılan Araç Adetleri	14
Tablo 2.1 Korelasyon Katsayısı Değerleri ve Yorumlamaları	28
Tablo 3.1 Aktivasyon Fonksiyonları	51
Tablo 3.2 YSA Performans Ölçütleri	59
Tablo 4.1 Çoklu Regresyon Analizi Modelinde Tahmin Edilen Katsayı Değerleri..	72
Tablo 4.2 Çoklu Regresyon Analizi Modelinde Tahmin Edilen Katsayı Değerleri..	74
Tablo 4.3 Çoklu Regresyon Analizi Modelini Değerlendirmek İçin Kullanılan Performans Ölçütleri	75
Tablo 4.4 NARX Modelini Değerlendirmek İçin Kullanılan Performans Ölçütlerinin Değerleri.....	83
Tablo 4.5 YSA Modelini Değerlendirmek İçin Kullanılan Performans Ölçütlerinin Değerleri.....	87
Tablo 4.6 Tahmin Modellerinin Karşılaştırmalı Performans Verileri.....	89
Tablo 4.7 YSA Modeliyle Yapılan 12 Aylık Otomobil Satış Tahmin Verileri	90

ŞEKİL LİSTESİ

Şekil 2. 1 Regresyon Doğrusu	26
Şekil 2. 2 Korelasyon Katsayısı Eğrisi	28
Şekil 2. 3 Zamana Göre Çeşitli Talep Düzenleri	29
Şekil 3. 1 Yapay Sinir Hücresinin Yapısı	49
Şekil 3. 2 Çok Katmanlı YSA Modeli	52
Şekil 3. 3 Tek Katmanlı YSA Yapısı.....	53
Şekil 3. 4 Çok Katmanlı İleri Beslemeli Yapay Sinir Ağı.....	54
Şekil 3. 5 Geri Beslemeli Yapay Sinir Ağı.....	54
Şekil 3. 6 İleri Beslemeli Bir Sinir Ağı'nın Eğitim ve Test Aşamaları.....	57
Şekil 3. 7 Yapay Sinir Ağlarının Öğrenme Eğrisi	58
Şekil 4. 1 2014-2023 Yılları Arasında Brent Petrol Fiyatının Aylık Değişimi	66
Şekil 4. 2 2014- 2023 Yılları Dolar/TL Kurunun Aylık Değişimi	67
Şekil 4. 4 TÜFE'nin 2014-2023 Yılları Arasındaki Aylık Değişimi.....	68
Şekil 4. 5 2014-2023 Yılları Arası Aylık Araç Alım Düzeyi	69
Şekil 4. 6 2014-2023 Otomobil Üretim Adetinin Aylık Değişimi	69
Şekil 4. 7 2014-2023 Yılları Arasındaki Otomobil Satış Adetinin Aylık Değişimi ..	70
Şekil 4. 8 ÇRA Tahmin Değerleri ve Gerçek Değerlerin Karşılaştırma Grafiği	76
Şekil 4. 9 ÇRA Tahmin Değerleri ve Gerçek Değerlerin Hata Paylarını Gösteren Grafik	76
Şekil 4. 10 ÇRA Tahmin Değerleri ve Gerçek Değerlerin Karşılaştırılması.....	77
Şekil 4. 11 NARX Ağ Modelinin Yapısını Gösteren Ekran.....	78
Şekil 4. 12 NARX Modelinde Hata Otokorelasyonunu Gösteren Grafik.....	79
Şekil 4. 13 NARX Modelinde Girdi-Hata Çapraz Korelasyonunu Gösteren Grafik.....	79
Şekil 4. 15 NARX Modelinde Hata Histogramını Gösteren Grafik	80
Şekil 4. 16 NARX Modelinde Doğrulama Performansını Gösteren Ekran	81
Şekil 4. 17 NARX Modelinde Eğitim, Doğrulama ve Test Verileri İçin Regresyon Grafikleri.....	82
Şekil 4. 18 NARX Tahmin Değerleri ve Gerçek Değerlerin Karşılaştırma Grafiği ..	83
Şekil 4. 19 YSA Modelinin Ağ Yapısını Gösteren Ekran Görüntüsü	84
Şekil 4. 20 YSA Modelinde Eğitim, Doğrulama ve Test Verileri İçin Regresyon Grafikleri	85

Şekil 4. 21 YSA Modelinde Hata Histogramını Gösteren Grafik	86
Şekil 4. 22 YSA Modelinde Doğrulama Performansını Gösteren Ekran	86
Şekil 4. 23 YSA Tahmin Değerleri ve Gerçek Değerlerin Karşılaştırma Grafiği	88



1. GİRİŞ

İşletmeler gelecekteki belirsizlikler fazla olduğundan ihtiyaç duyacakları talebi zamanında hazırlama gereksinimi duyarlar. Piyasayı gerçek anlamda çözümleyen ve talep tahminini gerçeğe yakın önemsiz hatayla tahmin eden işletmeler, yarışın arttığı ve ürün ömürlerinin azaldığı günümüz şartlarında, faaliyetlerini en iyi şekilde düzenleme imkânına ulaşacaklardır. İşletmelerin gelecekte her seviyede alacakları idari kararlar, yaptıkları tahminle de ilgilidir (Yücesoy, 2011).

Rekabet ortamında hızla gerçekleşen değişimler, işletmelerin daha kesin ve daha az hatayla tahminde bulunma ihtiyacını artırmaktadır. Bu ihtiyacı karşılamak için hedef ve süre faktörlerine göre farklı talep tahmin yöntemleri bulunmaktadır. Talep tahmininde kullanılan yöntemler iki ana kategoriye ayrılır: nitel yöntemler ve nicel yöntemler (Eski, 2006).

Nitel yöntemler, çoğunlukla kişisel deneyimlere, uzman görüşlere ve çözümlemelere dayanır. Nicel yöntemler ise, sonuç çıkarmak için verileri yöntemli bir biçimde sayı olarak belirtme ve kuşkulardan uzak verilere dayanan yöntemlerdir. Pratikte çoğunlukla, bu iki yöntemin karması seçilir (Heizer ve Render, 2004). Talep tahmin yöntemlerinde güvenilirlik önemli bir faktördür. Yapay zekâ tabanlı yöntemler, özellikle yapay sinir ağları, klasik tahmin yöntemlerine kıyasla daha gerçekçi tahminler yapabilmektedir. Bunun nedeni, yapay sinir ağlarının istatistiksel veri kullanması ve faktörler arasındaki ilişkileri öğrenebilmesidir. Bu nedenle, yapay sinir ağları son zamanlarda talep tahmini yöntemlerinde önemli bir yer edinmektedir. Yapay sinir ağları hem nicel hem de nitel yöntemlerin özelliklerini bir araya getiren bir talep tahmin yöntemidir. Nicel yöntemler açısından, yapay sinir ağları istatistiksel veri kullanarak tahminlerde bulunur. Yani sayısal veriler üzerinden modellemeler yapar. Diğer yandan, nitel yöntemler açısından da yapay sinir ağları faktörler arasındaki ilişkileri ve derecelerini öğrenerek tahminlerde bulunur. Yani sayısal olmayan, daha sezgisel ve deneyimsel bilgileri de kullanır. Bu sayede yapay sinir ağları, hem nicel hem de nitel yöntemlerin güçlü yanlarını birleştirerek daha gerçekçi talep tahminleri yapabilmektedir (Sarı, 2006).

Yapay Sinir Ağı algoritması, talep tahminin hesaplanması, yorumlanması ve değerlendirilmesi için verilerin üretilmesine ilişkin pratik bilgiler

sağlamaktadır. Yapay zekânın bu dalı, bilgisayarların herhangi bir giriş parametresi seti için çıktılar geliştirmek amacıyla mevcut verilerden (veya örneklerden) "öğrenmesini" sağlamak için matematiksel ve istatistiksel teknikleri kullanır. Bu kendi kendine öğrenme süreci, karmaşık sistemin girdi ve çıktı değişkenleri arasında bir ilişki kurmayı içerir.

Bir otomobil firmasının gelecekteki ihtiyaçları karşılayacak tesislerini ve alt yapısını planlamak için, otomobil sisteminin çeşitli bileşenlerindeki talebin düzeyini ve dağılımını tahmin etmek önemlidir. Bu çalışmada YSA modelinin seçilmesinin nedeni, genelleme yapabilmesi ve üretim miktarının tahmin etmek gibi karmaşık ve zaman serisi özelliği gösteren problemlerde bu modelin kullanımının faydalı olabileceği düşüncesidir. Otomobil sektörünün seçilmesinin nedeni ise, otomotiv sektörünün en önemli üretim faaliyet alanlarından birisi olması ve ülke sınırlarını aşan bir nitelikte olmasıdır.

Bu çalışmanın temel amacı, Türkiye’de otomobil üreten ve en çok satış yapan altı firmanın (OYAK Renault, Tofaş, Toyota, Ford, Honda ve Hyundai) 2014-2024 yılları arasındaki aylık satış verilerini kullanarak, yapay sinir ağı modeli ile Ocak 2024 ile Aralık 2024 arasındaki 12 aylık talep tahminini yapmaktır.

Çalışmada, Türkiye'deki otomobil satış miktarının talep tahmininde Çoklu Regresyon Analizi (ÇRA), NARX modeli ve Yapay Sinir Ağı (YSA) tahmin modelleri kullanılmış ve YSA modelinin diğer iki yöntemden daha başarılı olduğu gösterilmeye çalışılmıştır.

Birinci bölümde Dünya ve Türkiye'de otomobil sektörünün değişimi ve Türkiye'de üretilmeye başlanan ilk yerli otomobil Togg'un önemi ele alınmıştır.

İkinci bölümde talep tahmini, talep tahmin aşamaları ve talep tahmininde kullanılan yöntemler teorik olarak incelenmiştir. Ayrıca bu bölümde çalışmada kullanılan yapay sinir ağları modeli hakkında ayrıntılı bilgiler verilmiştir. Yapay sinir ağlarının yapısı, genel özellikleri, kullanım alanları, performans ölçümü ve öğrenme süreçleri gibi konular detaylandırılmıştır.

Üçüncü bölümde, uygulama kapsamında kullanılan verilerin hazırlanması, ÇRA, NARX ve YSA modellerinin kurulması ve yapılan talep tahminlerinin analiz çalışmaları detaylı bir şekilde anlatılmıştır. Tahmin sonuçları karşılaştırılmıştır.

Son bölümde çalışma bulguları daha geniş bir perspektifte tartışılarak elde edilen sonuçlar doğrultusunda otomobil talep tahmin çalışmalarına dayalı öneriler verilmiştir. Ayrıca, çalışmanın büyük otomobil üreticilerine sağlayacağı potansiyel katkılara yer verilmiştir.



BİRİNCİ BÖLÜM

OTOMOBİL SEKTÖRÜ

1.1. Dünyada Otomobil Sektörü

Almanya ve Fransa'nın öncülüğünde Avrupa'da doğan otomotiv sanayi daha sonra 1900'lü yıllardan itibaren, önce ABD'de daha sonra Avrupa'da gelişme göstermiştir. 1690'lı yıllarda ise Japonya üretimde gösterdiği başarı sayesinde önemli ölçüde ihracat yapar duruma gelmiştir. Otomotiv sektörü 1979'daki ikinci petrol şokunu izleyen durgunluk ortamının olumsuz etkilerini dört yılı aşkın bir sürede atlatabilmiş, dünya motorlu taşıt üretimi 1979'da 41,6 milyon adet iken, 1982'de 36,1 milyon âdete düşmüştür. Kuzey Amerika'da bu azalma daha ciddi boyutlara ulaşmıştır. Dünya motorlu araç üretiminin son yıllar itibariyle gelişimi ele alındığında 2002 yılına kadar Avrupa ülkelerinin lider konumda olduğu, onun yakın takipçisinin ise ABD olduğu görülmektedir. Fakat 2003 yılından itibaren üretimde liderliği Asya-Okyanusya ülkeleri ele geçirmiştir. Son yıllarda ki dünya otomotiv üretimindeki artış incelendiğinde yine en büyük payın Asya Okyanusya ülkelerine ait olduğunu görmek mümkündür (Görener & Görener, 2008).

Özellikle II. Dünya Savaşı'ndan sonra katlanarak büyüyen bu sektör, günümüz itibariyle birçok ülkenin ekonomisinin en temel taşlarından biri haline gelmiştir. Yoğun ilgi, sektörde her geçen gün artan talep ve teknolojik gelişmeyle yakın ilişkisinin olması otomotiv sektörünü dünyada en çok yatırım yapıldığı sektörlerden biri haline getirmiştir. 2013 verilerine göre sektörde Ar-Ge ve üretim kapsamında 85 Milyar Euro'luk yatırım harcaması gerçekleştirilmiş ve yatırım yapılan ülkelere 433 Milyar Euro'nun üzerinde vergi geliri sağlanmıştır. Sektörün yaklaşık olarak 2 Trilyon Euro civarında cirosu bulunmaktadır. Yine sektör 8 milyondan fazla doğrudan istihdama sahiptir. Dolaylı istihdam ile birlikte ise bu rakamının 50 milyonun üzerine çıktığı tahmin edilmektedir. Yine Dünya genelinde otomotiv sanayinde 20 civarında ülkede faaliyet gösteren yaklaşık 50 adet motorlu taşıt üreticisi firma bulunmaktadır (Anonim, Otomotiv Sektör Raporu (2013/1), 2014/a).

Günümüz itibariyle otomotiv üretimi bu sanayiye sahip olan ülkelere diğer ülkelere yayılmaktadır. Bu yayılımda temel hedef, daha rekabetçi koşullarda ve pazara yakın üretim yaparak daha yüksek pazar payına ulaşmaktır. Otomotiv

sanayinin giderek daha fazla küreselleşmesi ve ayrıca birkaç firmada yoğunlaşması, aynı zamanda bu sektördeki teknik mevzuatın da ülke ve bölge sınırlarını aşarak küreselleşmesine neden olmaktadır. Dünyada 5 ülkeye ait 10 dolayında firmanın sanayi ve ticaretin %80'nde yaklaşık hâkim olması bu sanayide küreselleşme ve yoğunlaşmanın boyutlarını göstermektedir. Bu sanayi dalında sermaye, teknoloji ve ürünün milliyeti kalkmış ve küreselleşmiştir (Anonim, Otomotiv Sektör Raporu, 2013:7).

Uluslararası Motorlu Araç Üreticileri Derneği (OICA) verilerine göre 2023 yılında, özellikle Çin, Hindistan, Brezilya ve Türkiye gibi doymamış iç pazara sahip gelişmekte olan ülkelerdeki taleplerin pazar ve üretim dinamikleri açısından itici güç olduğu görülmektedir. (Pişkin, 2017, s.19-20). Günümüzde otomobil sektörü, üretim ve satış değerleri açısından aşağıdaki Tablo 1.1'e göre analiz edildiğinde Çin'in üretim ve satış da açık ara önde olduğu görülmektedir. Türkiye ise 2023 yılında Dünya otomobil üretiminde 13. satış sıralamasında ise 12. olduğu görülmektedir.

Tablo 1.1 2023 Yılında Dünya'da Üretilen ve Satılan Otomobil Adeti

S.N.	Ülke	Toplam Otomobil Üretimi	Ülke	Toplam Otomobil Satışı
1	Çin	26.123.757	Çin	26.062.824
2	Japonya	7.765.428	Amerika	6.953.212
3	Hindistan	4.783.628	Hindistan	4.101.600
4	Almanya	4.109.371	Japonya	3.992.727
5	Güney Kore	3.908.747	Almanya	2.844.609
6	İspanya	1.907.050	Birleşik Krallık	1.903.054
7	Brezilya	1.781.612	Fransa	1.774.723
8	ABD	1.745.171	Diğer Ülkeler	1.566.261
9	Çek Cumhuriyeti	1.397.816	İtalya	1.565.331
10	Endonezya	1.180.355	Güney Kore	1.489.363
11	Slovakya	1.080.000	Rusya	1.049.917
12	Fransa	1.026.690	Türkiye	967.341
13	Türkiye	952.667	İspanya	949.359
14	Birleşik Krallık	905.117	Avustralya	890.823
15	Meksika	903.753	Endonezya	779.326
16	Diğerleri	877.579	Suudi Arabistan	645.723
17	Malezya	724.891	Malezya	604.000
18	Tayland	580.857	Belçika	476.674

19	İtalya	541.953	Polonya	475.032
20	Rusya	526.439	Tayland	406.501
21	Romanya	513.050	Tayvan	372.800
22	Macaristan	507.225	Hollanda	372.156
23	Fas	471.950	Güney Afrika	347.388
24	Özbekistan	421.414	Vietnam	290.071
25	Kanada	376.888	İsveç	289.827
26	Güney Afrika	336.980	Filipinler	282.507
27	Arjantin	304.783	İsrail	270.433
28	Polonya	299.300	İsviçre	252.214
29	Belçika	285.159	Avusturya	239.150
30	Portekiz	243.201	BAE	225.386
31	Tayvan	221.329	Çek Cumhuriyeti	221.419
32	Kazakistan	134.054	Portekiz	199.623
33	Avusturya	102.291	Danimarka	172.798
34	Slovenya	60.881	Kazakistan	164.000
35	Finlandiya	30.191	Özbekistan	146.456

Kaynak: (OICA, 2024) Uluslararası Motorlu Taşıt Üreticileri Örgütü www.oica.net

1.2. Türkiye’de Otomobil Sektörü

Ekonomik büyümenin sağlanarak sürdürülebilir kalkınma ile işsizlik sorununa çözüm bulunması hususunda özel sektörü teşvik yönünde politikalar uygulanmıştır. Türkiye’nin sanayileşme programı kapsamında değerlendirildiğinde otomotiv sektörü kilit bir noktada bulunmuştur (Uluslararası Çalışma Örgütü, 2020).

Türkiye’de otomotiv sektörünün gelişimi daha detaylı incelendiğinde, otomotiv sektörü ürünlerinin Türkiye’ye ilk girişinin Birinci Dünya Savaşı sonrasına denk gelmekte olduğu görülmektedir. İlk olarak Amerika Birleşik Devletleri’nden “American Foreign Trade” şirketi aracılığı ile Ford ve Chevrolet markalı binek araç ve ticari araçları getirilmiştir. Aynı dönemde ayrıca, Türkiye pazarına giren bir başka marka da İtalyan Fiat olurken 1929 yılı sonrasında Türkiye’ye satılan araçların tamir ve bakımı için Ford tarafından yedek parçalar da temin edilmiştir. Benzer şekilde, montajların yapılması ve ülke içinde otomotiv endüstrisine bağlı olarak ilk üretimler gerçekleşmesi de bu yıla denk düşmüştür. Ülkemizde Ford tarafından yapılan montajlar ile traktör ve kamyonet üretimlerin gerçekleştirilmesi ve üretilen ürünlerin Sovyetler Birliği’ne de satılması öngörülmüş olmak ile birlikte, 450 işçi çalışan ilgili

tesis 1930 yılında tüm dünyayı etkisi altına alan küresel krizden oldukça olumsuz etkilenmiş ve planlanan satışlar gerçekleştirilememiştir. 1934 yılında fabrika üretimini tamamen durdurmuş ve Türkiye’de otomotiv sektöründeki durgun sayılabilecek durum İkinci Dünya Savaşı’na kadar devam etmiştir. Bununla birlikte, 1950-60 arası dönemde Türkiye ekonomisinin büyümesi sürecine bağlı olarak otomotiv sektöründe de hareketlenme gerçekleşmiş ve yurt içinde araç üretimi yükselmeye başlamıştır. 1954 yılı Türk Silahlı Kuvvetleri’nin jip ve kamyon ihtiyacının giderilmesi için İstanbul tarafında bir üretim merkezinin daha kurulması açısından önem arz eder hale gelmiştir. 1954 yılında ayrıca tarımsal üretimi yükseltmek için Ankara’da bir traktör fabrikası faaliyete geçmiştir. Bu doğrultuda, Koç Ticaret Şirketi tarafından Ford Motor’un Türkiye Genel Temsilciliğinin alınması sektördeki ilk özel girişimi olarak kabul edilmekte olup, 1956’da ilk kez özel sektör üretimi başlamıştır. İlk Türk otomobilin üretimi Eskişehir’de “Devrim” adı ile çıkarılan otomobil olmak ile ve bu üretimin başlamasında cumhurbaşkanlığı etkili olduğu ve hane halkının ihtiyacını karşılamaya yönelik otomobil üretiminin başlamasının hükümet politikasının üstüne bir devlet vizyonu olduğu öne sürülebilecektir. Dört adet üretildikten sonra üretimi devam etmeyen Devrim arabaları, yerini 1964 yılında çıkarılan Montaj İmal Tadil Talimatnamesi ile Anadol araçlarına bırakmıştır (Kozanoğlu, 2017).

Otomotiv sektörü açısından 1968 yılı önem arz etmekte olup, ilgili yıl içerisinde otomobil üretimin artırılması için Koç Şirketi İtalyan Fiat ile anlaşmış ve Tofaş markasının üretimine üretimi başlanmıştır. Bu süreç 1969 yılında Oyak ve Renault’un ortaklığı ile başlayan üretim hamlesi ile desteklenmiştir. 1990 yılından sonra ise, dışa açık ekonomik politikalar ile uyumlu olarak ihracat için atılan adımlar ile üretim kapasiteleri geliştirilmeye ve yeni yatırımlar gerçekleştirilmeye başlanmıştır. 1994 yılında Türkiye, Toyota, Hyundai ve Honda için üretim üssü haline gelmiş ve ilgili durum Türkiye’nin Gümrük Birliği’nin imzalanması ile küresel üretim teknolojilerine geçiş ile farklı bir boyut kazanmıştır. Dolayısıyla, Türkiye otomotiv sektörü ihracat ve ithalatın etkilerinin birlikte değerlendirilmesi gerektiği bir yapıya kavuşmuştur. 2000’lere gelindiğinde ise, Mercedes-Benz, BMC ve MAN fabrikaları kurulmuş, ilgili markalar kendi projelerini hayata geçirmeye başlamış ve otomotiv sektörünün dışa açık yapısı perçinlenmiştir. 2012 yılında EVT Motor, Hacettepe Üniversitesi Teknokent ve Otomotiv Mühendisliği Bölümü öğretim elemanları iş birliği EVT S1 adında elektrikli spor otomobil, üretilmeye başlanmıştır. Destek gelmediğinden üretim

durmuştur. 28 Mayıs 2015 tarihinde T.C. Sanayi ve Teknoloji Bakanlığı Saab 9-3 aracının bütün haklarını satın aldı. 2015 yılında Fiat Egea Tofaş fabrikasında üretilmeye başlandı. Egea üretime başladıktan sonra 5 yıl boyunca Türkiye'de en çok satan otomobil oldu. 2018 yılında Otosan tarafından üretilen Ford F-Max Almanya Hannover fuarında 2019 yılının en iyi ağır vasıtası seçildi (Sanayi ve Teknoloji Bakanlığı, 2021; Koç Holding, 2020; Fiat Türkiye,2020).

Öte yandan, otomotiv sektöründe üretim statik bir süreç olmayıp tüketicinin talepleri yakından izlenerek zaman boyutu içerisinde yeni ürünlerin geliştirilmesi gerekli olmaktadır. Tüketicilerin talepleri içerisinde güvenilirlik boyutu önem taşımakta olup, aynı zamanda ürünlerin yakıt tasarrufu sağlayabilmesi tüketicilerin öncelikleri arasında yer almaktadır. İlgili hususlara hane halkının talep ettiği otomobiller çok sık görülmekte olup, ürünlerin dayanıklı olması parça değiştirme imkânlarının var olması sektör genelinde dikkate alınan diğer hususlar olarak ön plana çıkmaktadır. Özellikle de kullanılan otomobil tüketiciler nezdinde saygınlık göstergesi olarak değerlendirilebildiğinden markanın teknolojik gelişmelere adaptasyonu tüketicilerin markaya olan bağlılığını artırabilecektir. Dolayısıyla, Türkiye'de üretilen otomobillerin istikrarlı biçimde teknolojik gelişmelere ile doğru orantılı olarak gelişme kat etmesi sektörde zaman boyutu içerisinde arz ve talep dengesinin sağlanması açısından önem taşımaktadır. Bu durum, Türkiye'de otomotiv üreten işletmelerinin yeni yatırımlarını finanse edebilecek karlılık seviyesine ulaşmasına yardımcı olacaktır (Sanayi ve Teknoloji Bakanlığı, 2021).

Otomotiv sektöründe özellikle otomobil talebi hane halkının gelir akışı ile sınırlı olmakta olup, tüketici olan hane halkının fayda maksimizasyonu ilkesi gereği yürüttüğü işlem elde edilebilecek maksimum fayda seviyesini göstermektedir. Hane halkının harcama kapasitesi borçlanma imkânları ile genişleyebilmekte ve tüketiciler daha üst fayda seviyesine ulaşabilmektedir. Bu çerçevede, otomobil satıcılarını çeşitli finans kurumları ile anlaşmalar yaparak kredilendirme gibi konularda müşteriye sağlayacağı faydalar pazarın hareketlenmesi açısından fayda sağlayacaktır. Bununla birlikte, vergilerin iyileştirilmesi, eski ürünün iyi fiyatlara satın alınması ve sigorta işlemlerinde kolaylıkların sağlanması hem müşteri memnuniyetini hem de sayısını arttırabilecektir. Hane halkının otomobil talebin karşılamak için yaptığı borçlanmanın maliyeti olan faiz oranlarının düşük seviyelere inmesi de talebi canlı tutarak arzın uzun

vadede yükselmesi için gerekli koşulları oluşturacaktır. Dolayısıyla, otomobil sektörünün para politikası değişikliklerinden yakinen etkilendiğini ve sektörü inceleyen kantitatif modellerin faiz faktörünü dikkate alması gerekmektedir. Finansman koşullarının iyileştirilmesi hususunda, Türkiye genelinde faiz oranlarının düşürülmesinin önemli olduğu araştırmacılar ve iktisatçılar tarafından varsayılmaktadır. Otomotiv sektöründe toplam talebin tetiklenmesi için, pazarlama faaliyetlerini niteliğinin yükseltilmesi gerekmektedir. Bu noktada, yapılacak reklamların doğru açıdan yönlendirici olması otomotiv sektörünün uzun vadede canlı tutabilecektir. Aksi durumda, tüketicilerin ihtiyaçları olmayan araçları satın almaları sektöre yönelik güven duygusunu zayıflatabilecek ve otomotiv sektörünün büyümesi sekteye uğratabilecektir. Türkiye gibi ülkelerde reklamın, dikkat uyandırmasının yanında doğru bilgileri ile tüketicileri yönlendirme vasfına sahip olması önem arz etmekte olduğundan pazarlama faaliyetlerinin denetiminin sağlanması önerilebilecektir (Sanayi ve Teknoloji Bakanlığı, 2021; Koç Holding, 2020).

Otomotiv sektöründe tüketim zaman boyutunda gerçekleşmekte olup toplam talebi etkileyen faktörler arasında tamamlayıcı malların veya hizmetlerin fiyatlarındaki değişiklikler Türkiye’de sektörün gelişimi açısından önem taşımaktadır. Müşterinin ihtiyacına göre bakım ve tamiratın yapılabileceği geniş ve ucuz yedek parçanın pazarda bulunması ve kolay tedarik edilebilmesi, müşterinin ürünü alma aşamasında seçimine yön veren en önemli unsurlar arasında yer almaktadır. Bu hizmetler içinde yol yardımı, kilometre kontrolü, bakım/onarım, kaza sonrası tamirat gibi işlemler sayılabilir. Otomotiv sektöründe faaliyet gösteren işletmelerin önemli bir çoğunluğu küresel ölçekte olduğundan bayi ağının geniş olması sebebiyle müşterinin dünya genelinde hizmete ulaşabilmesi giderek önem kazanmaktadır. Bu nedenle, Türkiye’de otomotiv sektörüne yatırım yapacak işletmelerin yukarıda belirtilen özelliklere sahip olması için dünya geneline yayılmış ve hizmet bakımından aynı standartları yakalamış bir bayi ağının varlığı gerekmektedir. Bu husus ayrıca müşteriler için büyük bir avantaj anlamına gelebilecek ve üretici markanın da imajına pozitif bir biçimde yansımaktadır (Sanayi ve Teknoloji Bakanlığı, 2021; TÜİK, 2020; KPMG Türkiye, 2021).

Dünya otomotiv sektöründe ortaya çıkan gelişmeler küreselleşmenin etkisiyle Türkiye’ye de yansımıştır. Özellikle gümrük birliğiyle antlaşmasıyla birlikte daha

belirginleşmiştir. Türkiye’de sektörün dezavantajlarından birisi yüksek oranlı vergilerdir. Bununla birlikte yüksek girdi maliyetleri, aşırı kapasite, yetersiz talep ve ithal otomobil tercihi sektörün karşılaştığı problemlerdendir. Türkiye otomotiv sanayinin avantajları ise genç nüfusun fazlalığı, coğrafi konum, kalifiye işgücündeki iyileşmeler ve güçlü yan sanayisidir. Türkiye’de otomotiv sektöründe üretilen araçlar lisans anlaşmalarına dayalı olarak üretildikleri için yeni ürün geliştirmeyi engellemektedir. Türkiye ekonomisi için son derece önemli olan otomotiv sektörü gelişimini devam ettirebilmek için teknoloji, verimlilik, kalite, üretim, ihracat gibi birçok yönden rekabet edebilecek seviyeye gelmek zorundadır. Bu amaçla gelişen teknolojinin yakından takip edilmesi, ana ve yan sanayi arasında işbirliğinin geliştirilmesi, teşviklerin artırılması, sektör yatırımlarının arttırılması, vergi oranlarının azaltılması önem arz etmektedir (Yayar & Yılmaz, 2016).

1.2.1. Türkiye Otomotiv Sanayisinde Üretim ve Satış Verileri

Türkiye’de üretim yapan otomotiv şirketleri; A.I.O.S., Ford Otosan, Hattat Traktör, Hyundai Assan, Karsan, Mercedes-Benz Türk, MAN Türkiye, OTOKAR, OYAK-Renault, TEMSA, Tofaş, Toyota ve Türk Traktör şeklindedir. Aşağıdaki Tablo 1.2’de Türkiye’de üretim yapan otomotiv şirketlerinin 2022 yılındaki üretim adetleri görülmektedir.

Tablo 1.2’ye göre Türkiye’de otomobil üretimi yapan Ford Otosan, Hyundai Assan, OYAK-Renault, Tofaş ve Toyota’nın 2022 yılındaki toplam üretimi 810.889’dur.

Tablo 1.2 Otomotiv Sanayi Firmalarının 2022 Yılındaki Üretim Verileri

Firmalar	Otomobil	K.Kamyon	B.Kamyon	Kamyonet	Otobüs	Minibüs	Midibüs	Traktör	Toplam
A.I.O.S.		3.090	-	603	473	-	995	-	5.161
FORD OTOSAN	3.910	-	16.519	307.089	-	46.509	-	-	374.027
HATTAT TRAKTÖR	-	-	-	-	-	-	-	4.922	4.922
HYUNDAI ASSAN	208.100	-	-	-	-	-	-	-	208.100
KARSAN	-	-	-	-	86	388	212	-	686
M. BENZ TÜRK	-	-	25.025	-	3.889	-	-	-	28.914
MAN TÜRKİYE	-	-	-	-	2.044	-	-	-	2.044
OTOKAR	-	844	-	216	1.223	-	1.394	-	3.677
OYAK RENAULT	247.100	-	-	-	-	-	-	-	247.100
TEMSA	-	11.092	-	-	631	-	734	-	2.457
TOFAŞ	135.044	-	-	128.703	-	-	-	-	263.747
TOYOTA	216.735	-	-	-	-	-	-	-	216.735
TÜRK TRAKTÖR	-	-	-	-	-	-	-	44.619	44.619
TOPLAM	810.889	5.026	41.544	436.611	8.346	46.897	3.335	49.541	1.402.189

Kaynak:(OSD, 2023)

Türkiye’deki otomobil ve hafif ticari araç toplam pazarının 2022 yılı Ocak-Aralık döneminde yapılan satışları gösteren Tablo 1.3 aşağıda verilmiştir. Tablo 1.3’e göre yerli ve ithal otomobil satışları, 2022 yılında 592.660 adettir.

Tablo 1.1 Otomotiv Sanayi Firmalarının 2022 Yılındaki Otomotiv Satış Verileri

MARKA	OTOMOBİL		HAFİF TİCARİ			TOPLAM			TOPLAM
	YERLİ	İTHAL	TOPLAM	YERLİ	İTHAL	TOPLAM	YERLİ	İTHAL	
ALFA ROMEO	0	820	820	0	0	0	0	820	820
ASTON MARTIN	0	28	28	0	0	0	0	28	28
AUDI	0	14.554	14.554	0	0	0	0	14.554	14.554
BENTLEY	0	15	15	0	0	0	0	15	15
BMW	0	18.056	18.056	0	0	0	0	18.056	18.056
CITROEN	0	21.913	21.913	0	6.918	6.918	0	28.831	28.831
CUPRA	0	2.792	2.792	0	0	0	0	2.792	2.792
DACIA	0	36.000	36.000	0	0	0	0	36.000	36.000
DFSK	0	352	352	0	0	0	0	352	352
DS	0	1.829	1.829	0	0	0	0	1.829	1.829
FERRARI	0	22	22	0	0	0	0	22	22

FIAT	97.078	276	97.354	46.520	2.561	49.081	143.59 8	2.837	146.435
FORD	2.882	8.421	11.303	64.809	1.323	66.132	67.691	9.744	77.435
HONDA	0	21.429	21.429	0	0	0	0	21.429	21.429
HYUNDAI	28.043	14.198	42.241	0	2.935	2.935	28.043	17.133	45.176
ISUZU	0	0	0	578	1.317	1.895	578	1.317	1.895
IVECO	0	0	0	0	2.966	2.966	0	2.966	2.966
JAGUAR	0	90	90	0	0	0	0	90	90
JEEP	0	2.422	2.422	0	0	0	0	2.422	2.422
KARSAN	0	0	0	316	0	316	316	0	316
KIA	0	18.462	18.462	0	1.905	1.905	0	20.367	20.367
LAMBORGHINI	0	14	14	0	0	0	0	14	14
LAND ROVER	0	1.111	1.111	0	419	419	0	1.530	1.530
LEXUS	0	336	336	0	0	0	0	336	336
MASERATI	0	314	314	0	0	0	0	314	314
MAZDA	0	181	181	0	0	0	0	181	181
MERCEDES-BENZ	0	18.661	18.661	0	6.327	6.327	0	24.988	24.988
MG	0	1.627	1.627	0	0	0	0	1.627	1.627
MINI	0	1.385	1.385	0	0	0	0	1.385	1.385
MITSUBISHI	0	583	583	0	1.437	1.437	0	2.020	2.020
NISSAN	0	9.337	9.337	0	395	395	0	9.732	9.732
OPEL	0	30.378	30.378	0	6.347	6.347	0	36.725	36.725
PEUGEOT	0	23.345	23.345	0	9.321	9.321	0	32.666	32.666
PORSCHE	0	668	668	0	0	0	0	668	668
RENAULT	70.493	17.713	88.206	0	11.43 3	11.433	70.493	29.146	99.639
SEAT	0	6.142	6.142	0	0	0	0	6.142	6.142
SKODA	0	19.464	19.464	0	0	0	0	19.464	19.464
SMART	0	0	0	0	0	0	0	0	0
SSANGYONG	0	804	804	0	489	489	0	1.293	1.293
SUBARU	0	622	622	0	0	0	0	622	622
SUZUKI	0	3.601	3.601	0	0	0	0	3.601	3.601
TOYOTA	32.509	5.767	38.276	0	11.66 1	11.661	32.509	17.428	49.937
VOLKSWAGEN	0	49.695	49.695	0	10.64 6	10.646	0	60.341	60.341
VOLVO	0	8.228	8.228	0	0	0	0	8.228	8.228
TOPLAM:	231.00 5	361.65 5	592.660	112.22 3	78.40 0	190.623	343.22 8	440.05 5	783.283

Kaynak: (ODMD, 2023)

Aşağıda Tablo 1.4’te Otomotiv Distribütörleri Derneği’nin (ODD) yayımladığı verilere göre 2019-2022 yılları arasında toplam otomobil ve hafif ticari araç pazarı, her yıl bir önceki yılın aynı ayına göre genellikle artış göstermiştir.

Tablo 1.2 2019-2022 Otomobil ve Hafif Ticari Araç Satışlarını Gösteren Tablo

	2019	2020	2021	2022
Ocak	14.373	27.273	43.728	38.131
Şubat	24.875	47.122	58.504	49.652
Mart	49.221	50.008	96.428	64.267
Nisan	30.971	26.457	61.488	60.035
Mayıs	33.016	32.235	54.734	65.167
Haziran	42.688	70.973	79.819	80.652
Temmuz	17.927	87.401	47.849	52.206
Ağustos	26.246	61.533	58.454	48.336
Eylül	41.992	90.619	57.141	62.084
Ekim	49.075	94.733	56.746	65.222
Kasım	58.176	80.141	60.216	82.311
Aralık	90.500	104.293	62.243	115.220
Toplam	479.060	772.788	737.350	783.283

Kaynak: (ODD, 2023)

Korona virüsün otomotiv sektöründe yarattığı etkileri inceleyecek olursak 2020 yılının ilk çeyreğinden sonra salgının ülkemizde yayılması ve vaka sayısının her geçen gün artmasıyla şirketler tarafından alınan tedbirlerin yanı sıra tedarikçilerde çıkan problem ve sipariş iptalleri nedeniyle firmalar fabrikalarda üretime ara verdi. Yurt dışında da salgının hızla ilerlemesi sektördeki şirketlerin ihracatını da olumsuz etkiledi. Hızla yayılan salgının merkez üssünün, Türkiye'nin en önemli ticaret partneri Avrupa'ya taşınması AB pazarındaki sert daralma nedeniyle sipariş iptalleri gelmesi, sınır geçişleri ve limanlarda yaşanan kesinti ve yavaşlamalar nedeniyle lojistik süreçlerinin sürdürülmesine ilişkin problemler yaşanması ve Avrupa'da birçok fabrikanın üretimini durdurması ile Avrupa'dan temin edilen ürünlerin tedarikinde yaşanan zorluklar üretimde aksamaya neden oldu. 2020 ve 2021 yıllarında, insanların salgın dolayısıyla kendini toplu taşımadan izole etmeye devam ederek kişisel araç kullanımını artırması ve kamu bankalarının taşıt kredileri için çeşitli adımlar atması

nedeniyle sektörde erken bir canlılık yaşanmaya başladı. Bu canlılık sıfır araçların satımını da yansıdı ve 2020 yılı Haziran ayında başlayan ciddi talep artışları yaşandı. 2021 yılında küresel çip tedarikinde yaşanan kıtlık pek çok otomobil üreticisinin kısa dönemli olarak üretimi durdurmasına neden oldu. Sektördeki çip tedarikinde yaşanan problemler nedeniyle oluşan arz şokları ve döviz kurunda artış beklentisi nedeniyle otomotiv fiyatlarının artacağı beklentileri, 2021 yılı Mart ayında talep patlaması yaşanmasına neden oldu (Deloitte Türkiye, 2021).

1.2.2. Türkiye'nin İlk Yerli Otomobili Togg

Togg, Anadolu Grubu, BMC, Kök Grubu, Türkcell, Zorlu Holding, TOBB ortaklıkları ile 2018'de kuruldu. Böylece Türkiye'de yerli araba çalışmaları başlamış oldu (Togg, 2024).

Togg (Türkiye'nin Otomobili Girişim Grubu), 2018 yılında Türkiye'nin yerli elektrikli otomobilini üretmek amacıyla kurulmuş ve ilk seri üretim aracını 29 Ekim 2022'de üretmiştir. İlk üretim, Gemlik'teki fabrikada gerçekleştirilmiş olup, bu tesis, çevre dostu üretim teknolojileri ile dikkat çekmektedir. Togg'un elektrikli SUV modeliyle üretime başlaması, Türkiye'nin otomotiv sektöründeki yerli üretim kapasitesinin artmasına yönelik bir adım olarak değerlendirilmektedir (Anadolu Ajansı, 2022). Togg'un yaptığı satışlar aşağıda Tablo 1.5'te verilmiştir.

Tablo 1.5 Togg Satılan Araç Adetleri

Ay	Satılan Araç Adedi
Mayıs 2023	306
Haziran 2023	502
Temmuz 2023	627
Ağustos 2023	1965
Eylül 2023	2204
Ekim 2023	3567
Kasım 2023	4401
Aralık 2023	6011
Ocak 2024	1625
Şubat 2024	1201
Mart 2024	1319
Nisan 2024	3003
Mayıs 2024	4140
Haziran 2024	1733
Temmuz 2024	1227
Ağustos 2024	601

Kaynak: (ODMD, 2024)

Togg, 2023 yılında Türkiye pazarında yerli elektrikli otomobil üretimine başlamış ve yıl boyunca 19.583 adet satış gerçekleştirmiştir. Bu satışlar, Türkiye'nin elektrikli araç pazarında yaklaşık %30'luk bir pay oluşturmuştur. Bu başarı, yerel pazarda güçlü bir talep olduğunu göstermektedir ve şirket, bu talebi karşılamak amacıyla öncelikli olarak iç pazara odaklanmıştır (Electrive, 2024).

Uluslararası pazarda ise Togg, 2024 yılında Almanya'da T10X modelini piyasaya sürmeyi planlamaktadır. Almanya, Togg'un hedeflediği ilk ihracat pazarlarından biri olacaktır ve Avrupa pazarında genişlemenin 2025 yılı itibarıyla hızlanması beklenmektedir. Bununla birlikte, 2023-2024 döneminde Togg'un uluslararası pazarda henüz bir satış gerçekleştirmedeği belirtilmektedir. Şirket, öncelikle Türkiye'deki üretim ve satış kapasitesini artırmaya odaklanmıştır (TechXplore, 2024).

Togg, Türkiye'de yerlilik payı en yüksek araba modellerini üretmeyi planlamaktadır. Böylece firma hem ülke ekonomisine büyük bir katkı sağlamayı hem de Türkiye'de insanların yerli arabalara binebilmelerini hedeflemektedir (Togg, 2024).

1.2.2.1. Togg Neden Önemlidir?

Togg'un önemi birçok farklı boyutta değerlendirilebilir. İlk olarak, Togg, Türkiye'nin otomotiv sektöründe söz sahibi olmasını sağlayarak yerli üretimi ve istihdamı artırma hedefine katkıda bulunmaktadır. Bu da Türkiye'nin ekonomik büyümesine olumlu etki yapmaktadır (Kaya, 2023).

Ayrıca, Togg'un teknolojik özellikleri ve yenilikçilik anlayışı oldukça dikkat çekicidir. Elektrikli otomobil pazarında önemli bir yere sahip olan Togg, çevre dostu özellikleri ve sürdürülebilirlik konusundaki çalışmalarıyla markanın hem iç pazarda hem de uluslararası arenada rekabetçi bir konuma sahip olmasını sağlamaktadır (Yıldız, 2024).

Hem batarya teknolojisi hem de bağlantılı araç teknolojisi gibi yenilikçi özellikleriyle Togg, otomotiv sektöründe ülkemizin yerini güçlendirecektir. Türkiye'nin elektrikli araç pazarındaki konumunu güçlendirerek sürdürülebilir bir geleceğe katkı sağlayacaktır. Bu teknolojik özelliklerin yanı sıra Togg'un diğer inovasyon çalışmaları da sektörde önemli bir fark yaratmaktadır (Kaya, 2023).

1.2.2.2. Togg'un Sürdürülebilirlik ve Çevre Dostu Özellikleri

Togg, Türkiye'nin elektrikli otomobil sektörüne adım atacağı büyük bir projedir. Bu projenin amacı, çevreye duyarlılık ve sürdürülebilirlik ilkelerini göz önünde bulundurarak Türkiye'nin otomotiv sektöründeki yerini güçlendirmektir. Togg'un çevre dostu özellikleri ve sürdürülebilirlik konusundaki çalışmaları, geleceğe yönelik bir vizyonun önemli bir parçasıdır (Kara, 2024).

Bir otomobilin çevre dostu olması, çeşitli faktörlere bağlıdır. Togg'un bu alanda attığı adımlar, çevre üzerindeki olumsuz etkileri minimize etmeye odaklanır. Elektrikli motorlara sahip olan Togg otomobilleri, doğal kaynakları tüketmez ve günlük kullanımda sıfır emisyon sağlar. Bu, hava kirliliği ve sera gazı emisyonlarının azalması anlamına gelir. Ayrıca, otomobillerin batarya teknolojisi de çevre dostu olarak değerlendirilir. Togg'un yenilikçi batarya teknolojileri, enerji verimliliği ve uzun ömürleriyle çevreye olan etkisini minimize eder (Yıldız, 2024).

Ayrıca, Togg'un sürdürülebilirlik konusundaki çalışmaları, üretim sürecinde ve malzeme seçiminde de belirgin hale gelir. Togg'un üretim tesisleri, enerji tasarrufu ve atık yönetimi konularında titizlikle tasarlanmıştır. Ek olarak, otomobillerin üretiminde geri dönüşümlü malzemelerin kullanılması da sürdürülebilirlik hedeflerine katkıda bulunur. Bu şekilde, hem üretim süreci sırasında hem de otomobillerin kullanımı sırasında çevresel etkiler en aza indirgenir (Özdemir, 2024).

1.2.2.3. Togg ile Türkiye'nin Otomotiv Sektöründeki Potansiyeli

Togg, Türkiye'nin otomotiv sektöründeki potansiyelini önemli ölçüde artırmış bir girişimdir. Son yıllarda Türkiye, otomotiv üretiminde büyük adımlar atmış ve dünya çapında tanınmış bir üretici haline gelmiştir. Togg, bu büyüyen sektörde Türkiye'nin gelecekteki potansiyelini en üst seviyeye çıkarmayı hedeflemektedir (Togg, 2024).

Togg'un Türkiye'nin otomotiv sektöründeki potansiyeline katkı sağlamasının birkaç önemli nedeni vardır. Birincisi, Türkiye'nin stratejik konumu ve güçlü alt yapısıdır. Türkiye, hem Asya hem de Avrupa pazarlarına yakın olmasıyla önemli bir lojistik avantaj sunmaktadır. Ayrıca, Türkiye'nin otomotiv endüstrisine yönelik yatırım yapmış birçok uluslararası şirket bulunmaktadır, bu da teknoloji paylaşımı açısından büyük bir potansiyel sağlamaktadır (Aydın, 2024).

Diğer bir neden ise Türkiye'nin yetenekli ve nitelikli iş gücüdür. Ülke genç ve eğitilmiş bir nüfusa sahip olmasıyla, otomotiv sektöründeki talepleri karşılamak için gerekli olan uzmanlık ve becerilere sahiptir. Togg, yerel yetenekleri desteklemeyi ve ülkenin otomotiv sektöründeki istihdam potansiyelini artırmayı hedeflemektedir. Bu sayede Türkiye'nin otomotiv alanında rekabet gücü daha da artacaktır (Demir, 2024).

Bunların yanı sıra, Togg'un Ar-Ge ve inovasyon çalışmaları da Türkiye'nin otomotiv sektöründeki potansiyelini artıracaktır. Togg, Türkiye'nin yerli otomobil üretimini gerçekleştirirken, aynı zamanda dünya çapında rekabet edebilecek teknolojileri geliştirmektedir. Ar-Ge faaliyetleri ve yenilikçilik çalışmaları, Türk mühendislik yeteneklerinin ve teknolojik bilginin geliştirilmesine katkı sağlayacaktır. Bu sayede Türkiye, otomotiv sektöründe kendi markalarını yaratan bir ülke konumuna gelecektir (Çelik, 2024).

Togg ile Türkiye'nin otomotiv sektöründeki potansiyeli oldukça yüksektir. Türkiye'nin stratejik konumu, güçlü alt yapısı, yetenekli iş gücü ve Ar-Ge faaliyetleri, ülkenin otomotiv sektöründe uluslararası arenada rekabet edebilecek bir potansiyele sahip olmasını sağlamaktadır. Togg'un geliştirilmesi ve üretimine başlanmasıyla birlikte, Türkiye'nin otomotiv sektöründeki potansiyeli daha da artacak ve ülke, otomotivde küresel bir güç haline gelecektir (Togg, 2024).

1.2.2.4. Togg'un Ekonomik Önemi

Türkiye'nin otomotiv sektörü, ülkenin en önemli ekonomik sektörlerinden biridir. 2022 yılında Türkiye'nin otomotiv ihracatı 27,1 milyar dolara ulaşmıştır. Togg'un Türkiye'de üretilmesi, bu sektörün büyümesine ve ülke ekonomisine önemli katkılar sağlayacağı öngörülmektedir (Türkiye İhracatçılar Meclisi, 2023).

Türkiye'nin otomotiv sektörü, ülkenin en önemli ekonomik sektörlerinden biridir. 2022 yılında Türkiye'nin otomotiv ihracatı 27,1 milyar dolara ulaşmıştır. Togg'un Türkiye'de üretilmesi, bu sektörün büyümesine ve ülke ekonomisine önemli katkılar sağlayacağı öngörülmektedir. Togg'un üretimi, Türkiye'de istihdamın artmasına ve yeni yatırımların yapılmasına da katkıda bulunacaktır. Togg'un Gemlik'teki fabrikasında 4 bin 300 kişi istihdam edilmektedir. Bu sayının önümüzdeki yıllarda artması beklenmektedir (Togg, 2024).

Togg, Türkiye'nin otomotiv sektörünün ve ülke ekonomisinin geleceęi için önemli bir projedir. Togg'un üretimi, Türkiye'de istihdamın artmasına, teknolojik gelişimin hızlanmasına ve ülke ekonomisine önemli katkılar sağlayacağı öngörülmektedir (Togg, 2024).



İKİNCİ BÖLÜM

TALEP TAHMİNİ

2. TALEP TAHMİNİ

Talep, tüketicilerin belirli bir piyasada, belli bir fiyat düzeyinden satın alma isteğiyle alabileceği mal ve hizmet miktarıdır. Talep tahmini ise, üretilen mal ve hizmetlerin piyasada bulunan tüketiciler tarafından ne ölçüde talep edileceğinin önceden kestirilmesi sürecini ifade etmektedir. Talep tahmini, işletmelerde üretim planlama ve kontrol sistemi için temel girdiyi oluşturmaktadır (Tekin, 1996).

Ekonomik sürekliliğin başarıldığı durumlarda, piyasa şartlarındaki değişimler yüksek düzeylerde olmamaktadır. Bu tür durumlarda ürünlere olan talep miktarı da çok fazla değişiklik göstermediğinden, talep tahminlerine de fazla bir ihtiyaç duyulmamaktadır. Fakat ekonomik sürekliliğinin olmadığı durumlarda piyasa şartlarının nasıl olacağı ve ürünlerin hangi fiyattan talep edileceğinin tahmin edilmesi çok büyük önem taşımaktadır. Talep tahmin sonucunda elde edilen değerler, gerçek değerlerle karşılaştırılıp hata miktarlarının saptanması gerekir. Sonuçların geçerliliği bu hata oranından sapma derecelerine bağlıdır (Eski, 2006).

İşletmeler, tahmini doğru bir şekilde yaparak ihtiyaç duydukları ham maddeleri doğru zamanda ve miktarda alınmasını sağlayarak maliyetlerini azaltabilirler. Benzer şekilde işletmelerin hizmetin çıkış noktasından varış noktasına kadar taşınmasında etkili olan birimlerinin daha uzun dönemli anlaşmalar yapmasını sağlayarak maliyetlerini azaltabilir. Eğer talep doğru bir şekilde kestirilebilirse bu tür anlaşmalar gerçekleştirilebilir. İyi bir tahmin işletmenin stok düzeyini belirlemede ve tahminin doğruluğu istenen seviyede olmadığı durumlarda işletmenin güvenlik stokları oluşturmasını sağlayacaktır. Tahminin başarılı olmasıyla işletmeler fazladan stokların önüne geçerek maliyetlerini düşürebilir (Moon, Mentzer, & Smith, 2003).

İşletmeler, belirsizliği azaltmak ve önemli kararlar verirken bilimsel tahminlere ihtiyaç duyarlar. Amacına uygun talep tahmininin seçimi kritik öneme sahiptir ve talep tahmini için tek bir yöntem yoktur. İyi bir talep tahmini için, öncelikle talebi etkileyen etkenlerin belirlenmesi ve bu etkenlerin talebe olan etkisinin açıklanması gereklidir. Ürünlerin satış fiyatı, ülkedeki faiz oranları, kur, menkul kıymet piyasaları,

tüketicilerin gelir düzeyi, malın karşıladığı ihtiyacın şiddet derecesi, kişinin alışkanlıkları, tercih ve gelenekler, nüfusun büyüklüğü ve yapısı mevsimlik faktörler gibi etkenler talebi etkileyen faktörler arasında sayılabilir (Tekin, 1996).

Talep tahmini ise, bir süre sonra tüketicilerin gelecekte ne miktarda mal ve hizmet talep edeceklerinin kestirilmesidir. Bu tahmin işletmenin üretim seviyesinin saptanmasında temel oluşturur. İyi bir talep tahmininde hangi ürünün ne zaman üretileceği, hangi tarihlerde gerçekleşme ihtimalinin olacağı, değişiklikler için yeterli zamanın bulunması gereklidir. Talep tahmini belirli kurallara göre yapılır. Ancak hangi yöntem kullanılırsa kullanılsın, yapılan tüm talep tahminlerinde belli bir doğruluk derecesi söz konusudur ve hiç bir tahminin %100'lük bir doğruluk derecesine sahip olması beklenmez. Ürün özellikleri ve talep türleri, yapılacak tahmin tipi ve kapsayacağı zaman süresini etkiler. Eğer ürüne olan talep hemen hemen sabit ise, tahminin zaman süresi biraz daha kısa tutulabilir. Geleceği planlama, talebin daima aynı düzeyde kalacağı kabulüne dayanır. Böyle durumlarda var olan kapasite genellikle talep hacminin çoğunu karşılayabilir. Tahmini artırmak pek az gereklidir. Ürüne olan talep dalgalanmalar gösteriyorsa, tahmin en az bir dönemi içine almalıdır. Eğer talepte dönemsel değişiklikler varsa, talebi karşılamak için fazla mesai ve/veya stok gerekli olabilir. Talepte uzun dönemde artan bir eğilim bekleniyorsa, daha uzun dönemli bir tahmin yapmak gerekir. Bu nedenle planlamaya imkân veren bir zaman süresi için tahmin yapmak gereklidir. Bu zaman aralığı birkaç aydan, birkaç yıla kadar değişir. Bazı ürünler için talep değerleri mevsimlere göre azalır veya çoğalır. Böyle durumlarda öncelikle talepteki mevsimsel değişimlerin nedenini iyi belirlemek gerekir. Eğer talebin bazı mevsimlerde fazla, bazılarında az olmasını gerektiren geçerli nedenler varsa o zaman mevsimsel tahmin yöntemleri kullanılabilir (Stevenson, 2005).

Talep tahminlerinde göz önünde bulundurulması gereken önemli ilkeler aşağıdaki gibi açıklanabilir (Acar, 1989):

- Tahminler miktar veya çeşit bakımından büyük olan bir ürün grubu için daha doğru olur: Tüm ürünler veya satılan parçalar için tahmin yapmak, özel bir ürün için tahmin yapmaktan daha kolaydır. Örneğin; yılda 200.000 adet binek otomobil üreten bir şirket düşünelim. Eğer 200.000 binek otomobil 12 ayrı ürün ailesinin toplamından oluşuyorsa, toplam otomobil talebi tahmini, ürün aileleri bazında otomobil talebi

tahminlerine; ürün ailesi bazındaki talep tahmini ise ürünlerin tek tek talep tahminlerine göre daha doğru olacaktır.

- Tahminler kısa dönemler için daha doğru olur: “Ne kadar uzağa giderseniz o kadar yanılırsınız” gerçeğini dikkate alırsak, dönem uzadıkça etki eden etmenler çoğalacağından, uzun dönemli tahminleri tutturmanın son derece zor olacağını söyleyebiliriz.

- Tahmin daima yanlıştır: Tahmin yapılan dönemde öngörülemeyen durumlar meydana gelebilir. Tahmin hatası var olmasına karşılık, bu hata hakkında bir kanıya sahip olunması çok önemlidir. Matematiksel tekniklerle olası hataların düzeyini hesaplamak olanaklıdır. Geçmiş ortalamalardan olan sapmalara dayanarak gerçek talebin artı veya eksi yönde belli bir oranda sapabileceği beklenebilmektedir.

- Tahmin yöntemi, kullanılmadan önce denenmelidir (test edilmelidir): Talep tahmininde kullanılan çeşitli modeller vardır ve aynı geçmiş veriler kullanılarak değişik tekniklerin denenmesi önerilmektedir. Geçmiş veriler ile en iyi çalışan teknik, gelecekte de iyi sonuçlar vereceği düşünülerek kullanılabilir.

- Tahmin, kesin talebin yerini tutamaz: Tahminlerin bir hata payı vardır. Geleceğe yönelik elimizde kesinleşmiş veriler (örneğin onaylanmış siparişler) varsa, bunlar öncelikle dikkate alındıktan sonra, kalan kısım için talep tahmini çalışması yapmak veya yapılan tahmin çalışmasından, kesinleşmiş veriler çıkartıldıktan sonra kalan kısmı değerlendirmek gerekir.

- İyi bir tahmin sadece rakamdan ibaret değildir: Tahminler belli bir rakam değil, bir geçerlilik aralığı olarak veya bir tahmin hatası dağılımı ile verilmelidir.

- Grup tahminleri daha doğrudur: Bir grup için yapılan tahminin hata payı, bireysel tahminlerin hata payından daha küçüktür.

- Tahminlerin doğruluğu, tahmin süresiyle ters orantılıdır.

İyi bir tahminin özellikleri (Heizer & Render, 2004);

- Zamanı dikkate almalı. Gereken değişiklikler için yeterli zaman verilmelidir.

- İsabetli olmalı ve isabet derecesi belirtilmelidir.

- Güvenilir olmalı.

- Anlamlı birimler şeklinde ifade edilmeli.
- Yazılı olmalı.
- Anlamada ve kullanımda kolaylık sağlamalı.
- Tahmin maliyeti, sağlanan faydadan daha az olmalıdır.

2.1. Talep Tahmin Aşamaları

Talep tahmini temel olarak beş aşamada gerçekleştirilir. Bu aşamalar aşağıdaki şekildedir:

1. Talep Tahminin Amacının Belirlenmesi: Yapılacak olan tahminlerin hangi amaçla kullanılacağını ve ne zaman gerekli olacağını belirlenmesi aynı zamanda talep tahmininin ne kadar ayrıntılı olması gerektiğini göstermektedir. Tahmin amacı dikkate alınarak, gerekli olan iş gücü, süre, donanım ve benzeri ihtiyaçlar ortaya konmalı ve tahminin ne kadar hassas olacağı belirlenmelidir (Eski, 2006). Talep tahminine başlamadan önce işletmenin mevcut durumu, hangi ürünleri ürettiği, hangi çevre ortamında yer aldığı, rekabet ettiği işletmelerdeki konumu, gelecekte olmak istediği yer, fiyat ve talep ilişkisi, ekonomik değişimler, endüstriyel değişimler, teknolojik ilerlemeler, sosyal değişimler, ulusal ve uluslararası yönelimler gibi talebi etkileyen etkenler tespit edilmelidir (Bolt, 1994).

2. Talep Tahmin Döneminin Belirlenmesi: Talep araştırması sonuçlarının kullanılış amacı ile periyodun uzunluğu arasında yakın bir ilişki vardır. Örneğin, günlük iş emirlerinin hazırlanmasında yararlanılacak tahminlerin aylık dönemler için yapılması son derece yanıltıcı sonuçlar verebilir. Çünkü günlük değerlerdeki oynamalar, aylık dönemlerde tamamen kaybolur (Tekin, 1996).

3. Verilerin Toplanması: Talep tahminlerinin yapılabilmesi için, bu süreçte temel alınacak verilerin toplanması ve derlenmesi gerekmektedir. Toplanan veriler, aynı zamanda kullanılacak talep tahmin yönteminin ne olması gerektiği konusunda yol gösterici olmaktadır. Yapılacak olan tahminlerin doğruluğu ve geçerliliği, eldeki verilerin doğruluğuna ve güvenilirliğine bağlıdır. Eksik veya olması gerekenden daha ayrıntılı veriler, araştırmanın maliyetini ve tahmin sonuçlarını elde etme süresini arttırdığı gibi sonuçların duyarlılığını da, olumsuz olarak etkilemektedir (Eski, 2006).

4. Tahmin Yönteminin Seçilmesi ve Talebin Tahmin Edilmesi: Talep Tahmini yöntemi olarak Nesnel ve Öznel yöntemler kullanılabilir. Nesnel yöntemler istatistiksel ve matematiksel verilere dayanan yöntemlerdir. Öznel yöntemler ise matematiksel verilerden daha çok tecrübenin uygulanmasına, yargılama ve zekâyâ dayanan yöntemlerdir. İdeal talep tahmini yöntemi ise Nesnel ve Öznel yöntemlerinin karışımıdır (Bolt, 1994).

5. Tahmin Sonuçlarının Başarısının İzlenmesi: Tahminleme sonucunda elde edilen değerlerin, gerçek değerlerle karşılaştırılıp hata oranlarının tespit edilmesi gerekir. Bu hata oranlarının hedeflenen hata oranından sapma derecelerine göre sonuçların geçerliliği belirlenir (Eski, 2006).

2.2. Talep Tahmininde Kullanılan Yöntemler

Tahmin yöntemleri, literatürde farklı şekillerde sınıflandırılmış olmakla beraber temel olarak iki grupta ele alınmaktadır. Bunlar nitel yöntemler ve nicel yöntemlerdir. Genel olarak nicel yaklaşımların girdisi, çeşitli zaman aralıklarında toplanmış olan verilerdir. Verilerin sayısal olarak iyi bir şekilde düzenlenip analiz etmeye hazır duruma getirilmesi, bu yöntemlerin temelini oluşturmaktadır. Buna karşılık nitel yaklaşımlar, konu ile ilgili uzmanların bilgi ve deneyimlerinden yararlanarak bu alandaki gelişmelerin ne yönde olacağı, ne tür ihtiyaçlar ortaya çıkaracağı gibi konularda yoğunlaşmaktadır (Archer, 1980).

2.2.1 Nitel Tahmin Yöntemleri

Nitel tahmin yöntemleri, çalışma alanı konusunda uzman kabul edilen bireylerin yargılarına ve deneyimlerine dayanmaktadır. Bu yöntemlerde bilgi işleme süreci uzmanlar veya jüri üyeleri tarafından gerçekleştirilir. Beklentileri ifade etmeleri ve dolayısıyla sübjektif yargılara bağlı olmaları nedeniyle, nicel yöntemler gibi tekrarlanamayan, sonuçları tartışmaya açık yöntemler olsalar da, nitel yöntemlerin kullanılmasını zorunlu kılan birtakım nedenler bulunmaktadır (Tekin & Patır, 2023). Bu nedenler şu şekilde sıralanabilir:

- Geçmişe yönelik yeterli verinin bulunmaması
- Mevcut zaman serilerinin güvenilir ya da geçerli olmaması
- Makro çevrenin çok hızlı bir şekilde değişmesi

- Çevresel etkiler açısından büyük karışıklıklar beklenmesi
- Uzun dönem tahminlerine ihtiyaç duyulması

Yukarıda bahsedilen durumlarda kullanılabilmesi, nitel tahmin yöntemlerinin en önemli avantajlarıdır. Bunlara ilave olarak; genellikle ucuz olmaları ve ileri düzeyde istatistiksel yeteneklere ihtiyaç duymamaları da (istatistiksel tahmin yöntemlerine dâhil edilemeyen sezgisel yargıların talep tahmin sürecine dâhil edilebilmesi) nitel yöntemlerin avantajları arasında sayılabilir. Ancak, seçilen jüri üyelerinin deneyimlerinin yetersizliği, kendi düşüncelerini tahminlere yansıtma olasılığı, geleceğe ilişkin beklentiler nedeniyle tahminlerin etkilenmesi, nitel yöntemlerin dezavantajlarıdır (Frechtling, 2001).

Uygulamada en çok kullanılan nitel tahmin yöntemleri şu şekildedir:

Delphi Yöntemi: Delphi yöntemi, özel bir araştırma türü olup, belirlenen uzun ve kısa vadeli olayların meydana gelmesine ilişkin tahminler yapmada kullanılmaktadır. Delphi yönteminin mantığı; birden fazla anket formunun gönderilmesi sonucunda “geri besleme” yoluyla grup üyelerinin ortak bir görüş birliğine varmalarını sağlamaktır. Bu nedenle bu yöntem, uzmanların yüz yüze gelmeden grup kararı almalarını sağlamaktadır (Seaton & Bennet, 1996). Yöntemin üstünlükleri aşağıdaki gibi sıralanabilir (Şahin, 2001):

- Bireylerin yüz yüze gelmelerinden doğabilecek problemler en az düzeye indirilebilmektedir. Bu şekilde bireyler düşüncelerini, diğerlerinin baskılarına maruz kalmadan serbestçe ifade edebilmektedirler.

- Katılımcılar ardışık anketler yoluyla sağlanan geri bildirimler neticesinde farklı düşüncelerden haberdar edilmekte, kendi düşüncelerini yeniden gözden geçirme fırsatı yakalamaktadırlar.

- Katılımcıların zaman, mekân, uzaklık, maliyet gibi faktörler nedeniyle sıklıkla toplanma olasılığının olmadığı durumlarda önemli avantajlar sağlamaktadır.

- Farklı bilgi, beceri ve deneyimler yardımıyla bireylerin farklı bakış açılarıyla sorunların ilgili parçalarına katkıda bulunmalarına fırsat tanımaktadır.

Yöntemin eksik yönleri ise; başarının uzmanların seçimine bağlı olması, sonuçların geri bildiriminin zaman alması, sürecin uzamasıyla birlikte katılımın azalması olarak özetlenebilir (İçöz, 2005).

Senaryo analizi: Senaryolar geleneksel tahmin yöntemlerinden farklı olarak alternatif gelecekler ortaya koymakta ve aynı zamanda, ekonometrik modellerin dışarıda bıraktığı konuları ve niteleyici perspektifleri de içine almaktadır (TÜBİTAK, 2001). Senaryolar, geleceğe ait muhtemel gelişmeleri dikkate alarak daha net bir görüş açısı sağlayabildiği gibi nelerin olabileceğini veya olanların ne olduğunu anlamaya yardımcı olmaktadır (Erkut & Akgüç, 1997). Senaryo analizinde önemli olan, söz konusu senaryoların karar vericiye olası durumlar içinde kendi içinde bulunduğu durumdan bir başkasına geçişinde belirli bir yol önerebilmektir (Önsel, Ülengin, & Ülengin, 2002).

Uzman panelleri: Bu yöntem, oluşturulan bir panel aracılığı ile üyelerin çoğunluğu tarafından onaylanan bir sonuca ulaşmayı hedeflemektedir. Bu yöntemin delphi modelinden farkı, panel üyelerinin bir araya gelerek konu hakkındaki görüş ve düşüncelerini karşılıklı belirtme ve fikir alış verişinde bulunma olanağına sahip olmalarıdır. Bu nedenle bu teknik üyelerin etkileşiminin iyi olduğu gruplarda daha çok kullanılır. Çalışmalarda mümkün olduğu kadar fazla fikir alış verişine yer verilir. Çalışma süreci panel üyelerinin görüş birliği sağlaması ile sona ermektedir (İçöz, 2005). Panel üyeleri konusunda uzman, farklı görüş ve deneyimlere sahip kişiler arasından seçilmelidir. Bu kişilerin ele alınan konudan uzak olmaları konuya tarafsız yaklaşımlarını sağlayacağından daha yapıcı fikirlerin ortaya çıkmasını sağlayabilmektedir (Witkin & Altschuld, 1995).


2.2.2. Nicel Tahmin Yöntemleri

Nicel yöntemler, geçmiş dönem gözlem değerlerine dayalı analizler yapan tahmin modellerini kapsamaktadır. Kullanılan yöntemler; incelenen değişkende gözlenen gelişmelerin analiz edilmesi, veri serisinin dinamik özelliklerinin belirlenmesi ve bu özelliklerin matematiksel bir fonksiyon ile ifade edilerek geleceğe ilişkin öngörülerin türetilmesini içermektedir (Başoğlu & Parasız, 2003). Nicel tahmin yöntemlerinden en çok kullanılanlar aşağıdaki gibidir:

Regresyon analizi: Regresyon analizi, aralarında sebep sonuç ilişkisi bulunan bir bağımlı değişkenin bir veya daha fazla bağımsız değişken arasındaki ilişkiyi

belirlemek ve tahminlerde bulunmak için bir fonksiyon şeklinde yazılmasıdır (Çağlar, 2007). Regresyon denklemi ile bağımlı ve bağımsız değişkenler arasındaki ilişkiyi kuran parametrelerin değeri tahmin edilir ve doğru bir regresyon katsayı ile güvenilir tahminler yapmak mümkündür. Regresyon analizinde, belli aralıktaki geçmiş sezon ve dönemlerin verileri kullanılarak formül geliştirilir. Geçmiş veriler ne kadar düzenli ve sürekli ise tahminlerin tutarlılığı o kadar yüksektir. Ancak, bağımsız değişken değerleri düzensiz ve farklılık gösteriyorsa, tahmin hatası da fazla olacaktır (Ballot, 1986).

Basit doğrusal regresyon, iki değişken arasındaki ilişkinin doğrusal olduğu kabul edilirse, denklem $Y = a + bx$ şeklinde ifade edilir ve bağımsız değişkenin değeri yerine konarak tahmin değeri elde edilir.



Şekil 2.1 Regresyon Doğrusu

Kaynak: (Çağlar, 2007, s.16)

İki değişkenin arasındaki ilişkinin doğrusal olduğunu varsayarsak, denklem ($Y = a + bx$) şeklinde ifade edilir ve bağımsız değişkenin değeri yerine konarak tahmin değeri elde edilir. Denklemde, a, b değerlerinin bulunması için kullanılan En Küçük Kareler (EKK) yöntemi grafiksel olarak Şekil 2.1’de gösterilmiştir.

Şekil 2.1’de görüldüğü üzere, regresyon doğrusundaki bağımlı değişken değerleri ile gerçek değerler arasındaki farkın karelerinin toplamını minimum yapacak en uygun doğru bulunmaya çalışılmaktadır (Çağlar, 2007).

Çoklu Regresyon Analizi: Çoklu regresyon bir adet bağımlı değişken ve birden fazla bağımsız değişkenin bir arada bulunduğu modeldir. Gerçek dünyada, tüm verileri anlamlı bir şekilde tanımlayan doğrusal fonksiyonlar bulunmayabilir, bazı durumlarda

veri kümemizi eğri bir fonksiyon ile tanımlayabiliriz (Ulgen, 2024; Hocaoglu, Kaysal, & Kaysal, 2015).

Çoklu regresyon analizinde (ÇRA), oluşturulan modeldeki bağımsız değişkenlerin her biri bağımlı değişkendeki değişimi anlamlandırmaya çalışır ve ÇRA modelinin matematiksel olarak ifadesi Formül 2.1’de verilmiştir:

$$y_i = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_n x_n + \varepsilon \quad (2.1)$$

Bu formülde,

y_i = Bağımlı Değişkeni

β_0 = Sabit Katsayıyı

ε = Hata Terimini


x_n =Bağımsız Değişkenleri

$\beta_1, \beta_2, \dots, \beta_n$ =Değişken Katsayılarını

ifade etmektedir.

En küçük kareler yöntemi: En küçük kareler yöntemi, basit doğrusal, çoklu regresyon modellerinin çözümlenmesinde kullanıldığı gibi, çok denklemlilik ekonometrik modellerin çözümünde de kullanılan tekniklerin temelidir. Eğilim hesaplamasında en çok kullanılan yöntemdir. İki değişken arasındaki ilişkinin belirlenmesi için en uygun doğrunun çizilmesi esasına dayanır. Doğrunun tanımlanması için doğrunun bağımlı değişken eksenini kestiği noktanın ve doğrunun eğiminin bilinmesi gerekir. Çizilen doğru üzerindeki bağımlı değişken değerleriyle, gerçek değerler arasındaki farkın karelerinin toplamını minimum yapacak doğru bulunmaya çalışılır. Birçok ekonomik araştırmada pratikliği ve koşullara göre şekillendirilebilmesi dolayısıyla bu yöntemden çokça yararlanılmaktadır (Mcaleer, 2007).

Korelasyon Metodu: Korelasyon, iki değişken arasındaki ilişkiyi ölçen istatistiksel bir yöntemdir. İki değişken arasındaki ilişkinin yönünü ve gücünü belirlemek için kullanılır. İlişki ne kadar güçlü ise, oluşturulan tahminlerin doğruluğunun da o derecede artması beklenir (Üreten, 2005, s. 137).



Şekil 2.2 Korelasyon Katsayısı Eğrisi

Kaynak: (Üreten, 2005, s. 137)

Korelasyon katsayısı (r) iki değişken arasındaki ilişkinin derecesini gösterir. Yukarıda Şekil 2.2’de gerçekleşen değerlerle, Korelasyonu (ilgileşim) gösteren eğrinin grafiği görülmektedir.

Yukarıda Şekil 2.2’de bağımlı değişkenin gerçek değerlerinin oluşturduğu Korelasyon eğrisi görülmektedir. Korelasyonu incelenen iki değişken arasındaki ilgileşim sürekli 1’den küçük olmaktadır. Aşağıda Tablo-2.1’de, Korelasyon katsayısının aldığı değerlerin yorumlanmasında kullanılan ölçütler verilmiştir.

Tablo 2.1 Korelasyon Katsayısı Değerleri ve Yorumlamaları

0,90-1,00	Çok yüksek korelasyon
0,70-0,90	Yüksek korelasyon
0,40-0,70	Normal korelasyon
0,20-0,40	Düşük korelasyon
0,00-0,20	Çok düşük korelasyon

Kaynak: (Tekin, 2009, s.242)


Yukarıda Tablo 2.1’de görüldüğü gibi Korelasyon katsayısı değerlerinin bire yaklaşması, yüksek korelasyon oluştuğuna işaret etmektedir. Tam tersine sıfıra yaklaşması da düşük korelasyon ilişkisine işaret etmektedir.

Korelasyon katsayısına bakılarak değişkenlerin birbiri arasındaki etkileşim var mı, varsa etkileşimin çok fazla mı yani kuvvetli mi olduğu ve gözlem gruplarından

birinin gözlem değerleri artarken diğerinin azalıyor mu yoksa aynı yönde mi değerleri değişiyor olduğu gözlenebilir (Balcı, 2004, s.78).

Zaman serileri yöntemi: Zaman serileri analizi, bir işletmenin geçmiş satışları incelenerek bu satışlarda belirli bir eğilim olup olmadığının tespit edilerek, gelecekle ilgili talep tahminlerinin yapılmasıdır (Tekin, 2009, s. 245). Zaman serileri analizleri, geçmiş verilerin zaman içinde gösterdiği düzeni esas alır. Amaç, geçmiş verilere bakılarak geleceğin tahmin edilmesidir (Üreten, 2005, s.141). Zaman serileri, bir değişken üzerinde düzenli aralıklarla yapılan bir dizi gözlemdir (Monks, 1996, s. 40).

Zaman serilerinde, ortalama talep düzeyinde uzun dönemli bir artış veya düşüş görülmesi halinde, bir eğilimden bahsedilebilir. Eğilim, artan, azalan, ya da doğrusal veya doğrusal olmayan bir şekilde olabilir (Üreten, 2005, s.142).



Şekil 2.1 Zamana Göre Çeşitli Talep Düzenleri

Kaynak: (Üreten, 2005, s.143)

Yukarıda Şekil 2.3'te zamana göre değişebilen çeşitli talep düzenleri gösterilmiştir. Şekil 2.3'te zaman serisi analizine dayanan talep tahminlerindeki eğilimlerden, doğrusal eğilim, mevsimsel değişimler eğrisi ve değişmeyen sabit talep düzenleri bir grafik üzerinde gösterilmiştir.

Basit ortalama ve ağırlıklı ortalama yöntemi: Basit ortalama, bir serideki veriler toplamının, fiili gözlem sayısına bölünmesi yoluyla bulunur. Eğer geçmişe ilişkin veriler, genelde bir artış/azalış eğilimi göstermiyorsa veya gelecek için büyük çaplı bir

değişiklik beklenmiyorsa, bu yöntem kullanılabilir. Ancak izleyen dönemlerde artış/azalış eğilimi başlarsa, gerçekleşen talep, öngörülen talepten aynı yönde giderek artan sapmalar gösterecektir. Eğer belirli dönemlerin verileri (örneğin en yakın geçmiş dönemler), gelecek dönemler için kesin bir kanı veriyorsa, geçmiş veriler hesaplanırken son dönemdeki verilere daha fazla ağırlık verilerek ağırlıklı ortalama yöntemi kullanılabilir. Örneğin, farklı tarihlerde, farklı satın alma gücüne sahip paralar ile elde edilen varlıkların bilançolarda bir arada yer alması, bilançodan bilgi edinecek ve karar alacak olan işletme ilgililerinin yanılmasına neden olmaktadır. Bu nedenle enflasyon muhasebesinde son yıllarda sıklıkla kullanılan bir yöntemdir (Gökçen, 2004, s.36)

Hareketli ortalamalar yöntemi: Talepteki mevsimlik dalgalanmaların incelenmesi yoluyla mevsimlik dalgalanmaların talep üzerindeki etkisinin belirlenmesinde kullanılan bir yöntemdir. Geçmiş dönemlerdeki satışların incelenmesiyle ve satışların zamana göre gösterdiği eğilim doğrusundan yararlanılarak, gelecek dönemlerdeki talep tahminleri yapılabilir. Hareketli ortalamalar yöntemine göre 3, 4, 6 ve 12 aylık satış ortalamalarına göre değerlendirmeler yapılabilir. (Tekin, 2009,s.251). Örneğin üç aylık hareketli ortalama ile Temmuz ayının satış tahmini, Nisan, Mayıs ve Haziran aylarının satışlarının ortalaması alınarak bulunur (Üreten, 2005, s.146).

Hareketli ortalama, her seferinde en eski değeri çıkarmak ve yeni değeri eklemek yoluyla belli sayıda döneme ilişkin değerlerin tekrarlı olarak ortalamasının alınmasıyla elde edilir. Hareketli ortalamalar, genel veri düzenini korumakla birlikte, verilerdeki dalgalanmaları düzeltebilmektedir. Ancak, bir tahmin denklemi oluşturmazlar ve veri serilerinin son dönemlerine ilişkin tahmini değerlerin elde edilmesini sağlamazlar (Monks, 1996, s.42).

Otoregresif Hareketli Ortalamalar (AR-MA) Modeli: Zaman serilerinin modellenmesinde esneklik sağlamak ve en az sayıda parametre ilkesini gerçekleştirmek amacıyla bazı durumlarda, modele hem otoregresif ve hem de hareketli ortalama parametrelerinin alınması birçok yarar sağlamaktadır. Bu düşünce Otoregresif Hareketli Ortalamalar modelini ortaya çıkarmıştır. Otoregresif Hareketli Ortalamalar modellerinde herhangi bir zaman serisinin herhangi bir dönemine ait elde edilen gözlem değerleri, söz konusu dönemden önceki, belirli sayıdaki gözlem değeri ve hata teriminin doğrusal bir bileşimi olarak ifade edilebilir.

Otoregresif (AR) süreç, zaman içinde verilerin değişmeyeceği varsayımına dayanır. Örneğin ayda 100 birim satış varsa bu farkı kapatmak için aylık 100 birim yerine koyulur. Daha fazla veya daha az satış olma durumu olmazsa süreç etkilenmez. Bu durum otoregresif bir süreçtir. Hareketli Ortalamalar (MA) süreci ise, serinin gecikmeli hata teriminin, şimdiki hata terimini etkileme durumunu tanımlanır.

Otoregresif Bütünleşik Hareketli Ortalama (ARIMA) Modeli: Otoregresif Bütünleşik Hareketli Ortalamalar modeli, zaman serileri temelli sayısal bir modeldir tek veya çok değişkenli olabilir. Talep tahmini çalışmalarında çoğunlukla tek değişkenli Otoregresif Bütünleşik Hareketli Ortalamalar modeli kullanılmaktadır (Hu, 2002). Modelin temel işlevi Otoregresif süreçler içermesidir. Yani, geçmiş verilerden yararlanarak gelecekle ilgili istatistiksel tahminler yapabilmesi, süreçleri birleştirmesi ve hareketli ortalama süreçlerinin hepsini birlikte içermesidir (Chung, 2001; Güven, 2020).

ARIMA yaklaşımı zaman serilerinin durağan olduğu varsayımına dayanır. ARIMA modelleri, durağan olmayan ancak fark alma işlemiyle durağan hale dönüştürülmüş serilere uygulanan modellerdir. Durağan olmayan ancak fark alma işlemiyle durağan hale dönüştürülmüş serilere uygulanan modellere “durağan olmayan doğrusal stokastik modeller” denir. Zaman serilerinin durağan olmaması belirli bir eğilim (trend) içermesi demektir. ARIMA modeli, AR ve MA modellerinin birer birleşimidir (Kaynar, Taştan, & Demirkoparan, 2010).

Üssel ağırlıklı ortalamalar (üssel düzeltme) yöntemi: Hareketli ortalamadan farklı olarak tüm geçmiş verileri göz önünde bulunduran bir yöntemdir. Üstel düzeltme yöntemleri, geçmiş dönem verilerine eşit ağırlık veren basit hareketli ortalamalar yöntemine benzeyen ancak geçmiş dönem verilerine eşit değil farklı ağırlıkların verildiği yöntemler topluluğudur. Üssel terimi, verilen ağırlıkların veriler eskidikçe üstel bir şekilde azalması anlamını taşımaktadır. Diğer bir ifadeyle, tahminde kullanılan geçmiş dönem verilerinden yakın geçmişte gerçekleşenlere yüksek, veriler eskidikçe ise üstel bir şekilde azalması anlamını taşımaktadır (Çağlar, 2007, s. 39).

Üssel düzeltme, hareketli ortalamalarda en yakın geçmişteki verilerin daha fazla ağırlık taşımasını sağlayacak şekilde, geçmiş verileri üssel olarak ağırlıklandıran tahmin yöntemidir. Düzeltme katsayısı, $0 \leq \alpha \leq 1$ arası değerler alabilir. Buradaki α katsayısının kullanılması, gerekli verilerin miktarını önemli ölçüde azaltmaktadır.

Artık hareketli ortalamalar yönteminde olduğu gibi ortalamaya dâhil edilen dönem sayısı kadar veriye ihtiyaç kalmamakta, içinde bulunulan dönemin tahmin değerini elde etmek için, sadece bir önceki dönemin gerçekleşen ve tahmini talep rakamlarının mevcudiyeti yeterli olmaktadır (Üreten, 2005, s. 150).

Box-JenkinsYöntemi: Box-Jenkins Yöntemi tek değişkenli bir modeldir. Kısa dönemli tahminlerde oldukça başarılı olan bu metodun uygulandığı serinin, eşit zaman aralıklarıyla elde edilen gözlem değerlerinden oluşan kesikli ve durağan bir seri olması, bu metodun önemli bir varsayımdır. Tekniğin amacı, en az sayıda parametre içeren uygun modeller elde etmektir. Box-Jenkins'ten önce kullanılmakta olan Hareketli Ortalama ve Üstel Düzleştirme Tekniklerinde tahmin değerleri, otomatik olarak bilgisayar programına müdahale edilmeden elde edilirken, Box-Jenkins tekniğinde bu işlem tamamıyla otomatik değildir ve diğer tekniklere göre oldukça karmaşık ve anlaşılması zordur. Box-Jenkins yönteminin, incelenen serilerin durağan olup olmamasına, mevsimsel etki içerip içermemesine göre, farklı şekillerde tahmin modelleri geliştirme yeteneği vardır. Öte yandan Box-Jenkins yöntemine, zaman serileri için doğrusal filtreleme tekniği de denilmektedir (Çağlar, 2007, s. 46).

NARX, NAR ve Nonlinear Input-Output (NIO) Modelleri: NARX, NAR ve Nonlinear Input-Output (NIO) modelleri, zaman serisi verileri üzerinde tahmin yapmak için kullanılan yapay sinir ağı modelleridir. Bu modeller arasındaki temel farklar şunlardır:

1. NARX (Nonlinear AutoRegressive with eXogenous inputs): NARX modeli, otoregresif (AR) bileşenlerinin yanı sıra dışsal veya exogenous değişkenleri de girdi olarak alabilir. Bu model, geçmiş zaman adımlarının yanı sıra dışsal faktörlerin de etkisini dikkate alarak tahmin yapar. Örneğin, bir NARX modeli, geçmiş dolar fiyatlarının yanı sıra faiz oranları veya ekonomik göstergeler gibi dışsal faktörleri de kullanabilir.
2. NAR (Nonlinear AutoRegressive): NAR modeli, sadece geçmiş değerlere dayalı otoregresif (AR) bileşenleri kullanır. Bu model, sadece kendi geçmiş değerlerine dayalı bir yapıya sahiptir ve dışsal faktörleri dikkate almaz.
3. Nonlinear Input-Output (NIO): Nonlinear Input-Output (NIO) modeli, girdi ve çıktı arasındaki genel ilişkiyi öğrenmek için kullanılır. Bu model, girdi ve çıktı arasındaki doğrusal olmayan ilişkileri yakalamak için tasarlanmıştır. NIO modelleri, genellikle

karmaşık veya doğrusal olmayan ilişkilere sahip olan sistemlerin modellenmesi ve tahmin edilmesi için kullanılır.

Genel olarak, NARX modeli dışsal faktörleri dikkate alırken, NAR modeli sadece geçmiş değerlere dayalıdır ve NIO modeli girdi ve çıktı arasındaki genel ilişkiyi modellemek için kullanılır. Her bir modelin kullanımı, tahmin edilmek istenen probleme ve mevcut veriye bağlı olarak değişir.

Simülasyon (Benzetim)Yöntemi: Benzetim, matematik modellerin kullanılmadığı her yerde uygulanabilen çok esnek ve etkili bir yöntemdir. (Kobu, 1994). İşletme problemlerinin analizi için tanımlanan bir sistemin modeli bazen çok karmaşık olabileceği gibi kurulan modelin analitik ve nümerik olarak çözümü de güç olabilir. Bu hallerde simülasyon önemli bir model kurma ve çözme tekniği olarak kullanılır. Geniş anlamda benzetim, gerçeğin örneğini oluşturmaktır. Simülasyonu gerçek hayatta var olan bir sistemin ya da önerilerin kabulü ile var olabilecek bir sistemin uygulanma imkânının incelenmesi için herhangi bir modelden yararlanmak olarak da tanımlamak mümkündür. Modeller gerçekleri yansıtır. Simülasyon ise bunu taklit eder. Simülasyon gerçeğin canlı resmini yansıtabilmek için manipülasyonla ilgilenir (Hiller & Liebermann, 1970; Halaç, 1995; İpek, 1995; Ergün, 2008).

Simülasyon gerçek olayların sözel, şekilsel veya sembolik olarak temsil edilmesidir. Günümüzde kullanıldığı şekliyle simülasyon, işletme yönetiminde karşılaşılan problemleri çözümlemek amacıyla bilgisayar kullanılarak matematiksel model aracılığıyla gerçek bir sistemin temsil edilmesini sağlayan bir tekniktir. Simülasyon tekniği bilgisayar alanındaki teknolojik gelişmelere ve değişmelere bağlı olarak hızlı bir gelişme göstermiştir. Bu duruma bağlı olarak başta işletme olmak üzere birçok alanda uygulama imkânı bulmuştur. Simülasyonun diğer kullanım alanları olarak; ekonomi, pazarlama araştırması, talep tahminleri, eğitim, politika, sosyal bilimler, davranış bilimleri, şehircilik ve savunma vb. alanlar sayılabilir. Simülasyon tekniği talep tahminlerinde yaygın olarak kullanılmaktadır. Simülasyon ile geleceğin tahmini yapılmaktadır (Düzakın, 2005; Kurşun, 2007; Akkaya, 1991).

2.3. Literatür Taraması

Talep tahmini, birçok alanda, özellikle üretim planlaması, üretim kontrolü ve yönetim bilimi gibi disiplinlerde kritik bir öneme sahiptir. 1960'lı yıllardan bu yana bu alanda kayda değer gelişmeler yaşanmış ve sürekli olarak yeni yöntemler

geliştirilmiştir. Bu süreçte, hem yurt içindeki hem de yurt dışındaki istatistiksel yöntemlerle gerçekleştirilen talep tahmini çalışmalarından bazıları, bu alandaki ilerlemeleri yansıtmak amacıyla aşağıda derlenmiştir (Karahana, 2011:4; Fildes, 2006; Makridakis, 1996; Winklhofer vd., 1996).

Matuyama vd. (2008), envanter seviyesinin bilindiği ancak talebin belirsiz olduğu durumlar için geliştirdikleri çalışmada, iki farklı geribildirim politikası kullanarak envanter yönetim sistemine dair bir tahmin formülü önermişlerdir. Çalışmada, envanter seviyesindeki değişimleri periyodik olarak göz önüne alarak sipariş miktarını belirleyen bir sistem geliştirdiler. Bu sistemde, yakın gelecekte talebin beklenen değere yakın olması durumunda geribildirim mekanizmasının önemli olduğu, ancak talep tam olarak beklenen değerde olduğunda geribildirim mekanizmasının öneminin azaldığı sonucuna vardılar.

Fildes vd. (2008), bilgisayar tabanlı tahminleme sistemlerinin ve uzman görüşlerinin tahmin doğruluğu üzerindeki etkilerini araştırmışlardır. Çalışmada, dört farklı tedarik zinciri şirketi incelenmiş ve bilgisayar sistemlerinin sağladığı tahminlerle uzman müdahalelerinin nasıl etkili olabileceği analiz edilmiştir. Araştırma, zaman görüşünün etkinliğinin, hizmet verilen sektör ve iyileştirme yapan takımın başarısına bağlı olduğunu göstermiştir.

Kirby (1966), kısa ve orta süreli talep tahmin yöntemlerini karşılaştırarak singer dikiş makinesi üretimi üzerindeki etkilerini incelemiştir. Çalışmada, beş farklı ülkeden alınan 7,5 yıllık satış verilerini kullanarak 23 farklı seri oluşturulmuştur. Çeşitli tahmin yöntemleri, üstel düzleştirme, hareketli ortalamalar ve zaman serileri analizinde en küçük kareler yöntemleri kullanılarak değerlendirilmiştir. Araştırma sonucunda, trend analizi ve mevsimselliği dikkate alan üstel düzleştirme yönteminin diğer yöntemlere göre daha iyi sonuçlar verdiği tespit edilmiştir. Ayrıca, tahmin doğruluğunun veri özelliklerine ve tahmin süresine bağlı olarak değiştiği vurgulanmıştır.

Carlson ve Umble (1980), Amerika'daki otomobil piyasasında talep tahminini belirlemek için çoklu regresyon analizi yöntemini kullanmışlardır. Çalışmada, standart ve lüks otomobil kategorilerindeki beş farklı tür otomobilin gelecek beş yıllık talebini tahmin etmeyi amaçlamışlardır. Çalışmada, benzin fiyatları, benzin kıtlığı, otomobil fiyatları, tüketici gelirleri ve otomotiv sanayi işçilerinin grevlerinin talebi

etkileyen faktörler olarak belirlenmiştir. Çalışma, talebin benzin fiyatları, otomobil fiyatları ve tüketici gelirleri gibi ekonomik faktörlerden etkilendiğini göstermiştir. Ayrıca, benzin kıtlığı ve işçi grevlerinin de talep üzerinde önemli etkileri olduğu tespit edilmiştir.

Akbay vd. (1999), Türkiye'deki gıda ürünlerine olan talebi tahmin etmek için Tobit modeli kullanmışlardır. Çalışma, özellikle konsantre meyve suyu üreticileri için pazar taleplerini artırma stratejileri geliştirmiştir. 12-17 yaş grubu tüketicilerine odaklanılması ve eğitim seviyeleri yüksek annelerin ürün hakkındaki olumsuz tutumlarının değiştirilmesi gerektiği sonucuna varılmıştır.

Gavcar vd. (1999), Türkiye'deki kâğıt ve karton türlerinin talep tahminini yapmak için SEKA kâğıt fabrikasında üretilen sekiz farklı kâğıt ürününü analiz etmişlerdir. Çoklu regresyon analizini kullanarak talep tahminlerini yapmış ve değişkenler arasındaki ilişkiler korelasyon analiziyle belirlemişlerdir. Kâğıt talebini etkileyen faktörler arasında toplam eşya fiyat endeksi, ithalat ve ihracat miktarları, Gayri Safi Milli Hâsıla (GSMH) ve nüfus gibi etkenler incelenmiştir.

Chen (2000), Amerikan milli parklarındaki ziyaretçi sayılarından elde edilen verileri kullanarak turizm ve eğlence sektöründe talep tahminleri yapmıştır. Doktora tezinde, ARIMA metodu ile diğer istatistiksel tahmin metotlarının karşılaştırılması gerçekleştirilmiştir. Chen'in çalışmasında, ARIMA metodunun diğer istatistiksel metotlara göre daha yüksek doğruluk ve performans sağladığı gözlemlenmiştir. ARIMA, hem yıllık hem de mevsimsel verilere dayalı tahminlerde üstün sonuçlar üretmiştir.

ZhoumcMahon vd. (2002), Avustralya'nın Melbourne şehri bölgesinde su talebini tahmin etmek amacıyla, özellikle su tüketim verileri üzerinde yapılan tahminlerin doğruluğunu artırmak hedeflenmiştir. Çalışmada, altı yıllık günlük su tüketim verileri kullanılarak zaman serisi analizi gerçekleştirilmiştir. Çalışma, zaman serisi analizi kullanılarak yapılan tahminlerin, su talebi üzerinde yeterli ve doğru sonuçlar verdiğini göstermiştir.

Cahow (2004), evde tedavi gören kronik hastalara yönelik hemşire talebini tahmin etmek ve gelecekteki ihtiyaçları belirlemek için Çoklu Regresyon ve Monte Carlo simülasyon metotlarını kullanmıştır. Çalışma, 2025 yılına kadar Amerika'da

hemşire hizmetlerine olan talebin önemli ölçüde artacağını öngörmüştür. Bu tahmin, sağlık ve emeklilik anketlerinden elde edilen verilerle desteklenmiştir.

Satır ve Köksal (2006), Entegre tavuk organizasyonları için üretim ve finansal planlama modelinin geliştirilmesi ve uygulanabilirliğini değerlendirmek için geçmiş iki yıllık verilerle 90 çeşit ürün için ARIMA modelini uygulamıştır. Model tatmin edici sonuçlar vermiş ve modelin bazı küçük düzenlemelerle diğer entegre tavuk organizasyonları için de kullanılabilir olduğu sonucuna varılmıştır.

Lin vd. (2009), Tayland'daki medikal turizm talebini ve yabancı hastalardan elde edilecek gelirleri tahmin etmek amacıyla yeni geliştirdikleri model ile zaman serisi analizi modelinin performansı ile karşılaştırmışlardır. Geliştirilen yeni model, zaman serisi modelinden daha düşük hata oranları ile tahminlerde bulunmuştur. Bu sonuç, uluslararası medikal turizm yöneticileri için değerli karar öngörülerini sağlamıştır.

Xu vd. (2010) çalışmasında doğal afetler sonrası acil ihtiyaç duyulan malzemelerin talep tahminini yapmayı hedeflemiştir. Çalışmada, lineer regresyon ve ARMA gibi geleneksel istatistiksel ve ekonometrik metotlar kullanmıştır. 2008'deki Çin kış fırtınası sonrasında tarımsal ürünlerin talep tahmininde bu metotların başarılı olduğunu ve lineer regresyon ve ARMA kullanılarak yapılan tahminlerin, afet sonrası ihtiyaçların doğru bir şekilde belirlenmesine yardımcı olduğunu göstermiştir.

Griffiths vd. (2010), Batı Avustralya'daki beş farklı eyaletten toplanan yağış verilerini kullanarak buğday verimliliğini tahmin etmek için bir regresyon modeli geliştirmişlerdir. Araştırmada, geçmiş döneme ait yağış verileri toplanmış ve bu verilerle regresyon modeli uygulanarak buğday verimliliği tahmin edilmiştir. Sonuçlar, yağış miktarlarının buğday verimliliği üzerinde belirleyici bir etkisi olduğunu ve bazı belirsizliklerin tahmin edilebildiğini ortaya koymuştur.

Sun vd. (2010), gemi turu endüstrisinde müşteri taleplerini tahmin etmek için bir çalışma gerçekleştirmiştir. Araştırmada, müşteri taleplerindeki belirsizlikler göz önüne alınarak tahminler yapılmıştır. Çalışma, tahminlerin genel olarak tutarlı ve güvenilir olduğunu ve endüstrinin talep tahminlerinde önemli bir doğruluk sağladığını göstermiştir.

Literatürde yapay sinir ağları ile ilgili pek çok tahmin çalışması bulunmaktadır. Bu alandaki ilk örnek, hava durumu tahmini üzerine yapılan çalışmadır. 1964 yılında Hu tarafından geliştirilen yapay sinir ağı modeli, işletmelerde bu teknolojinin benimsenmesini sağlamış ve yaygınlaşmasına katkıda bulunmuştur. Özellikle ekonomi ve finans alanında gerçekleştirilen tahmin çalışmaları, yapay sinir ağlarının sağladığı analitik derinlik sayesinde dikkate değer sonuçlar elde edilmesine olanak tanımıştır. Bu durum, yapay zekâ ve makine öğreniminin iş dünyasında nasıl devrim yarattığını göstermektedir.

Değirmenci ve Papuçcu (2016) çalışmasında, Türkiye'ye ait 5 yıllık günlük CDS primleri ile BIST 100 endeksi kapanış değerlerini karşılaştırılarak, NARX YSA modelini kullanmışlardır. Çalışmada, NARX YSA modelinin tahmin performansı, özellikle finansal piyasa verilerinde güçlü bir öngörü sunmasıyla öne çıktığını belirlemiştir.

Karaatlı, Demirci ve Baykaldı (2021) tarafından yapılan çalışmada, özel sektör yatırım kararlarını etkileyen ticari kredi faiz oranlarını tahmin etmek için YSA NARX modeli ve VAR modelinin karşılaştırmasını yapmışlardır. Çalışmada, 2010-2019 yılları arasında Türkiye'ye ait makroekonomik veriler incelenmiş ve bu veriler ışığında ticari kredi faiz oranlarının tahmin edilebilirliği test edilmiştir. Çalışmada kullanılan performans ölçütleri MAD, MAPE, MSE ve RMSE kullanılmış ve sonuçlara göre YSA NARX modeli, geleneksel VAR modeline göre daha yüksek doğruluk oranları göstermiştir.

Yıldırım ve Karaatlı (2022) YSA NARX modeli ile 2019, 2020 ve 2021 yıllarına ait elma üretim miktarlarını tahmin ederek YSA NARX Modelinin elma üretim miktarı öngörüsünde kullanılabileceği göstermişlerdir.

Ünal (2024) çalışmasında, NARX YSA modelini kullanarak Safranbolu'ya gelen turist sayısının tahmin edilmesini ele almıştır. Çalışmada 2003-2021 yılları arasında elde edilen aylık döviz kuru ve tüketici fiyat endeksi verileri kullanılarak, Safranbolu'ya gelen turist sayısının analizi yapılmıştır. MATLAB yazılımı aracılığıyla eğitilen model, turist sayısının öngörüsünde yüksek performans göstermiştir ve çalışmada, Safranbolu gibi turistik bölgelerde bu modelin kullanılabilirliği vurgulanmıştır.

Wong vd. (1997), 1988-1995 yılları arasında yapay sinir ağlarının çeşitli uygulamalarını inceleyen bir anket çalışması yapmıştır. Araştırma, yapay sinir ağlarının işletme faaliyetlerinde artan bir şekilde kullanıldığını ve bu teknolojinin yeni gelişmelere hızla uyum sağladığını ortaya koymuştur. Yapay sinir ağlarının, yapay zekâ ve bilgisayar temelli sistemlerde yapılan yeniliklerle işletme araştırmalarında yeni fırsatlar sunduğu ifade edilmiştir.

Hu (2002) ve Çuhadar vd. (2009) çalışmalarında, yapay sinir ağlarının iç ve dış turizm talep tahminlerinde diğer geleneksel yöntemlere göre daha üstün performans sergilediğini belirtmişlerdir. Her iki çalışma da yapay sinir ağlarının, veriler arasındaki doğrusal olmayan ilişkileri öğrenme yeteneği sayesinde daha kapsamlı ve doğru tahminler yapabildiğini vurgulamaktadır.

İnsel ve arkadaşları (2010), Ataseven (2007), Çelik (2008) ile Hajirezaie ve ekibi (2010) tarafından gerçekleştirilen araştırmalar, yapay sinir ağı (YSA) modelinin planlama ve kalite kontrol süreçlerinde performans ölçümünde hem güvenilir hem de hızlı sonuçlar sunduğunu ifade etmişlerdir.

Aydoğan ve arkadaşları (2010) tarafından geliştirilen yapay sinir ağı modeli, İstanbul Boğazı'ndaki deniz suyu akıntı hızını tahmin etmek amacıyla kullanılmıştır. Çalışmada, farklı meteorolojik ve hidrolojik veriler modelde girdi olarak kullanılarak, akıntı hızının doğrusal olmayan ilişkileri göz önünde bulunduran bir tahmin yapılması hedeflenmiştir. Sonuçlar, yapay sinir ağı modelinin, geleneksel hidrolojik tahmin yöntemlerine kıyasla daha yüksek doğruluk ve tutarlılık sağladığını ortaya koymuştur. Benzer şekilde, Sahoo ve Debnath (2009) sıcak su akıntı hızını tahmin etmek için bir yapay sinir ağı modeli geliştirmişlerdir. Çalışmada, sıcak su akıntısının karmaşık dinamiklerini anlamak ve tahmin etmek için, geri yayılım algoritmasıyla eğitilmiş bir model kullanılmıştır. Elde edilen sonuçlar, geleneksel fiziksel ve istatistiksel yöntemlere göre daha isabetli tahminler sunmuştur. Shamseldin (2010) ise, Sudan'daki Mavi Nil Nehri'nin akış hızını tahmin etmek amacıyla yapay sinir ağı modelini kullanmıştır. Çalışma, nehir akış hızının çok sayıda değişkene bağlı olduğu karmaşık bir süreci içerdiğinden, geleneksel modellerin yetersiz kaldığı noktalarda yapay sinir ağlarının başarılı olduğunu göstermiştir. Model, veriler arasındaki doğrusal olmayan ilişkileri öğrenerek akış hızını daha doğru bir şekilde tahmin etmiştir.

Jones (2008), hastanelerin acil servis bölümlerine olan talebi tahmin etmek için yapay sinir ağlarını kullandığı çalışmada, gizli katmanlı ve geri beslemeli bir model tasarlamıştır. Bu model, tatil dönemleri gibi belirli zaman dilimlerine ait verileri giriş olarak kullanarak talep değişimlerini analiz etmiş ve sonuç olarak, hastanelerin acil servis bölümleri için daha tutarlı ve güvenilir talep tahminleri sağlamıştır.

Avcı (2009), IMKB-30 endeksinde yer alan bazı hisse senetlerinin günlük getirilerini tahmin etmek için yapay sinir ağları modelini kullanmıştır. Bu çalışmada, hisse senedi getirilerinin karmaşık ve doğrusal olmayan yapısı dikkate alınarak, YSA modeli eğitilmiştir. Sonuçlar, yapay sinir ağlarının finansal piyasalar için önemli tahmin aracı olduğunu göstermiştir. Model, özellikle geleneksel tahmin yöntemlerine kıyasla daha etkili ve güvenilir sonuçlar vermiştir. Ayrıca YSA'nın veri madenciliği ve makine öğrenmesi yöntemleriyle entegrasyonunun finansal tahminlerde nasıl güçlü bir araç haline geldiğini vurgulamıştır.

Asilkan (2009), ikinci el otomobillerin gelecekteki fiyatlarını tahmin etmek amacıyla yapay sinir ağlarını kullanmıştır. Araştırmasında, geçmiş fiyat verileri ve çeşitli ekonomik göstergeler modelde girdi olarak kullanılarak otomobil fiyatlarının tahmini yapılmıştır. Bu girdiler arasında otomobilin markası, modeli, yaşı, kilometresi, motor hacmi, yakıt türü gibi araçla ilgili özellikler; ayrıca enflasyon oranı, döviz kurları ve faiz oranları gibi makroekonomik faktörler de yer almıştır. Yapılan analizlerde, yapay sinir ağlarının zaman serisi analizlerine göre daha üstün performans gösterdiği ve ikinci el otomobil piyasasında daha isabetli fiyat tahminleri yaptığını belirlemiştir. Bu çalışmada YSA'nın, doğrusal olmayan ilişkileri öğrenme yeteneği ve geniş veri setlerini işleme kabiliyeti sayesinde tahmin doğruluğunu önemli ölçüde artırdığını gözlemlemiştir.

Jang vd. (1997), yaptıkları çalışmada, yapay sinir ağları ve bulanık mantığın bir araya getirildiği Neuro-Fuzzy yaklaşımını geliştirmişlerdir. Yazarlar, bu hibrit sistemin hem sınıflandırma hem de tahmin problemlerinde etkin bir çözüm sağladığını belirtmişlerdir. Özellikle otomotiv ve robotik gibi belirsizlik ve karmaşıklığın yüksek olduğu alanlarda, Neuro-Fuzzy sistemi geleneksel modellere göre daha başarılı sonuçlar verdiğini göstermişlerdir. Modelin performansı, %85-90 doğruluk ile sınıflandırma problemlerinde oldukça iyi olduğunu ve Neuro-Fuzzy modelinin,

belirsizlikleri yönetebilme kapasitesi ile sınıflandırma görevlerinde daha yüksek doğruluk sağladığını ifade etmişlerdir.

Zhang vd. (2005), yatıkları çalışmada, YSA'yı kullanarak mevsimsel ve trend içeren zaman serileri tahmin edilmiştir. Çalışmada finansal veriler üzerinde YSA test edilmiş ve ARIMA gibi geleneksel yöntemlerle karşılaştırılmıştır. Sonuçlara göre, YSA'nın mevsimsel dalgalanmaları ve trendleri başarılı bir şekilde öğrenebildiği ve tahmin doğruluğunun %92-95 olduğu görülmüştür. YSA'nın tahmin doğruluğu, mevsimsel ve trend içeren zaman serilerinde oldukça yüksek bulunmuş, geleneksel yöntemlerden %10-15 oranında daha iyi sonuçlar elde edilmiştir.

Kumar ve Maiti (2011), yapay sinir ağlarını GSYİH büyüme oranlarını tahmin etmek için kullanmıştır. Model, Hindistan'ın ekonomik büyümesini yatırım, işsizlik oranı gibi faktörlerle analiz etmiş ve sonuçlar oldukça başarılı bulunmuştur. Modelin GSYİH büyümesini %87 doğruluk ile tahmin ettiği gösterilmiş ve tahmin hatası oranı %1.5 seviyelerinde kalmıştır.

Wang ve Zhang (2005), yapay sinir ağlarını hisse senedi getirilerini tahmin etmek için kullanmıştır. YSA, özellikle karmaşık ve dinamik piyasa verileri ile çalışmada oldukça etkili olmuştur. S&P 500 endeksi üzerinde yapılan testlerde, YSA'nın getiri tahminleri %90-92 oranında başarılı olmuştur.

Khan Khedher (2014), enerji tüketimi tahmini konusunda YSA'nın kullanımını incelemişlerdir. Çalışma, sanayi ve ticari enerji tüketimi üzerine odaklanmış ve YSA'nın bu alanda %95 uyum ile başarılı tahminler yaptığı bulunmuştur. Özellikle enerji planlaması ve sürdürülebilirlik çalışmaları için YSA'nın daha isabetli tahminler sağladığı gösterilmiştir. Çalışmada enerji tüketimi tahminlerinde YSA'nın doğruluğu %95 gibi oldukça yüksek bulunmuş ve geleneksel yöntemlere kıyasla %12 daha az hata yapmıştır.

Miller ve Chang (1995), YSA'yı üretim performansını tahmin etmek amacıyla kullanmışlardır. Özellikle üretim süreçlerindeki hız, kalite ve maliyet gibi değişkenleri tahmin ederken, YSA'nın oldukça başarılı sonuçlar verdiğini göstermişlerdir. Çalışmada YSA, geleneksel modellerle karşılaştırıldığında %85-88 doğruluk oranıyla üretim süreçlerinde öne çıkmıştır.

Xie ve Wang (2013), şehir içi hava kirliliği seviyelerinin tahminini YSA ile yapmışlardır. Yazarlar, PM10 seviyelerini kullanarak hava kirliliği tahminlerini gerçekleştirmiş ve YSA'nın çevresel modellemelerde %91 doğruluk ile başarılı olduğunu göstermişlerdir.

Aydın ve Demirtaş (2022), enerji tüketimini tahmin etmek ve optimize etmek için yapay sinir ağlarının etkinliğini değerlendirmiştir. Araştırmada kullanılan veri setleri, bir yıllık enerji tüketim verisi ve hava durumu verilerini içermektedir. YSA'nın performansı, MSE değerleri ile ölçülmüştür; YSA'nın MSE değeri geleneksel yöntemlere kıyasla %15-20 oranında iyileşme sağlamış ve tahmin doğruluğu %10-15 oranında artmıştır.

Chen, Wang ve Xu (2024), yenilenebilir enerji üretimini tahmin etmek amacıyla YSA kullanmıştır. Çalışmada, güneş ve rüzgâr enerjisi üretim verileri kullanılmıştır. YSA'nın MSE değeri, geleneksel yöntemlere kıyasla %12-18 oranında daha düşük bulunmuştur. Güneş enerjisi üretiminde MSE değeri 0.045, rüzgâr enerjisi üretiminde ise 0.053 olarak ölçülmüştür.

Çetinkaya ve Yalçın (2023), sağlık verilerini kullanarak hastalık tahmini yapmak için YSA'nın etkinliğini incelemiştir. Çalışmada hastalık geçmişi, laboratuvar sonuçları ve demografik bilgiler içeren veri setleri kullanılmıştır. YSA'nın MSE değeri, geleneksel yöntemlere göre %10 daha düşük bulunmuş ve tahmin doğruluğu %94 oranında gerçekleşmiştir.

Gao, Wu ve Zhang (2023), kripto para birimlerinin fiyat tahmininde gelişmiş YSA modellerinin kullanımını araştırmıştır. Çalışmada, kripto para piyasasından elde edilen fiyat ve işlem hacmi verileri kullanılmıştır. Gelişmiş YSA modellerinin MSE değeri, geleneksel yöntemlere göre %20 oranında daha düşük bulunmuş ve kripto para fiyat tahminlerinde %87 doğruluk oranı sağlanmıştır.

Hsu, Chang ve Lee (2024), e-ticaret sektöründe tüketici davranışlarını tahmin etmek için YSA'nın kullanılabilirliğini değerlendirmiştir. Araştırma, tüketici satın alma geçmişi ve etkileşim verilerini içeren veri setlerini kullanmıştır. YSA'nın MSE değeri, geleneksel yöntemlere kıyasla %15 oranında daha düşük bulunmuş ve tüketici davranışlarını %85 doğruluk oranıyla tahmin etmiştir.

Kim, Lee ve Park (2024), sađlık hizmetlerinde hasta sonularını tahmin etmek amacıyla derin ğrenme modellerinin etkinliğini araştırmıştır. alıřmada hasta verileri, tedavi gemiři ve sađlık gstergeleri ieren veri setleri kullanılmıřtır. Derin ğrenme modellerinin MSE deęeri %8 oranında daha dřk bulunmuř ve hasta sonularını %92 doęruluk oranıyla tahmin etmiřtir.

Ko ve Yavuz (2022), finansal riskleri tahmin etmek ve ynetmek iin YSA'nın etkinliğini araştırmıştır. alıřmada, borsa verileri, ekonomik gstergeler ve finansal raporlar kullanılmıřtır. YSA'nın MSE deęeri geleneksel yntemlere gre %10-15 daha dřk bulunmuř ve finansal risk tahminlerinde %90 doęruluk oranı saęlanmıřtır.

Kumar, Patel ve Singh (2024), sanayi ekipmanlarının ngrc bakımında YSA'nın kullanımını incelemiřtir. Araştırmada ekipman arıza gemiři, bakım kayıtları ve alıřma kořulları verileri kullanılmıřtır. YSA'nın MSE deęeri %12 oranında daha dřk bulunmuř ve bakım srelerinde tahmin doęruluęunu %88 oranında artırmıřtır.

Li, Huang ve Zhang (2024), enerji řebekesinin gerek zamanlı ynetimi iin YSA'nın etkinliğini deęerlendirmiřtir. alıřmada enerji tketim verileri ve talep ynetimi verileri kullanılmıřtır. YSA'nın MSE deęeri, geleneksel yntemlere gre %10-15 daha dřk bulunmuř ve enerji talep tahminlerinde %95 doęruluk oranı saęlanmıřtır.

Liu, Huang ve Sun (2024), zaman serisi verilerini tahmin etmek amacıyla hibrit derin ğrenme modellerini geliřtirmiřtir. alıřmada finansal piyasa verileri, hava durumu verileri ve ekonomik gstergeler kullanılmıřtır. Hibrit modellerin MSE deęeri %15 oranında daha dřk bulunmuř ve zaman serisi tahmin doęruluęunu artırmıřtır.

zdemir ve Karahan (2021), retim srelerinde kalite kontrol saęlamak iin YSA'nın etkinliğini araştırmıştır. alıřmada retim verileri, kalite test sonuları ve iřlem verileri kullanılmıřtır. YSA'nın MSE deęeri, kalite kontrolnde %20 oranında iyileřme saęlamıř ve retim srelerinin kalitesini %18 oranında artırmıřtır.

Rao, Xu ve Liu (2024), řehirlerde hava kalitesini tahmin etmek iin derin ğrenme modellerinin kullanımını incelemiřtir. alıřmada hava kalitesi lmleri, hava durumu verileri ve kirlilik verileri kullanılmıřtır. Derin ğrenme modellerinin

MSE değeri, geleneksel yöntemlere göre %15-20 daha düşük bulunmuş ve hava kalitesini %90 doğruluk oranıyla tahmin etmiştir.

Singh, Kumar ve Agarwal (2024), finansal riskleri tahmin etmek için geri beslemeli yapay sinir ağları (RNN) kullanmıştır. Çalışmada borsa verileri, ekonomik göstergeler ve finansal analiz verileri kullanılmıştır. RNN'lerin MSE değeri geleneksel yöntemlere göre %12 daha düşük bulunmuş ve finansal risk tahminlerinde %92 doğruluk sağlamıştır.

Wang, Yang ve Li (2022), akıllı şehirlerde enerji tüketimini tahmin etmek için derin yapay sinir ağları kullanmıştır. Araştırmada enerji tüketim verileri, hava durumu verileri ve şehir planlama verileri kullanılmıştır. Derin yapay sinir ağlarının MSE değeri geleneksel yöntemlere göre %18 daha düşük bulunmuş ve enerji tüketimini %93 doğruluk oranıyla tahmin etmiştir.

Wang, Zhang ve Zhao (2024), tedarik zinciri yönetimini optimize etmek için YSA'nın kullanılmasını araştırmıştır. Çalışmada tedarik zinciri verileri, envanter verileri ve talep tahmin verileri kullanılmıştır. YSA'nın MSE değeri geleneksel yöntemlere göre %20 daha düşük bulunmuş ve tedarik zincirindeki süreçlerin tahmin doğruluğunu %25 oranında artırmıştır.

Xu, Zhang ve Chen (2023), borsa piyasası oynaklığını tahmin etmek için hibrit YSA modellerini geliştirmiştir. Araştırmada piyasa verileri, ekonomik göstergeler ve işlem hacmi verileri kullanılmıştır. Hibrit modellerin MSE değeri geleneksel yöntemlere göre %15 daha düşük bulunmuş ve borsa piyasası oynaklığını %89 doğruluk oranıyla tahmin etmiştir.

Zhang, Lu ve Chen (2023), iklim değişikliğinin tarım üzerindeki etkilerini tahmin etmek amacıyla YSA'nın kullanımını araştırmıştır. Çalışmada iklim verileri, tarım verimliliği verileri ve mahsul üretim verileri kullanılmıştır. YSA'nın MSE değeri geleneksel yöntemlere göre %12 daha düşük bulunmuş ve tarım stratejilerinin geliştirilmesine %20 oranında katkı sağlamıştır.

Zhou, Yang ve Chen (2024), ulaşım sektöründeki talebi tahmin etmek için derin öğrenme tekniklerini kullanmıştır. Araştırmada ulaşım verileri, trafik verileri ve seyahat verileri kullanılmıştır. Derin öğrenme tekniklerinin MSE değeri geleneksel

yöntemlere göre %15 daha düşük bulunmuş ve ulaşım talebini %91 doğruluk oranıyla tahmin etmiştir.



ÜÇÜNCÜ BÖLÜM

YAPAY ZEKÂ VE YAPAY SİNİR AĞLARI

3. YAPAY ZEKÂ

Yapay zekâ kavramı ilk olarak 1955 senesinde John Mc Carthy tarafından ortaya atılmış ve “Zeki makineler yapmanın bilimi ve mühendisliğidir.” şeklinde tanımlanmıştır. 1960 yılında ise, Marvin Minsky ilgili tanımı “Yapay zekâ, insanlar makineleri kullanırken makinelerin görevlerini yerine getirme bilimidir.” olarak geliştirmiştir (Wawrzyński, 2014).

Yapay zekâ, bilgisayarlar tarafından yapılması sağlanmaya çalışılan, zekâ ve düşünme gerektiren işlemlerin hayata geçirilebilmesi için gerçekleştirilen araştırmaların ve yeni yöntemlerin geliştirilmesi hususunda çalışmakta olan bilim dalıdır. Yapay zekâ, insanların düşünme, algılama, yorumlama ve karar verme gibi yeteneklerini taklit ederek yorumlayan bir dizi algoritma olarak tanımlanabilir. Yani programlanmış bir bilgisayarın düşünmesi ve karar vermesi işlemidir (Sagiroglu, Besdok, & Erler, 2003; Kesici & Yildiz, 2016; Atilla, 2022).

Günümüzde teknoloji alanında yaşanan hızlı değişim ve inovasyonun hayatımızın neredeyse her alanında yer alması, yapay zekânın da toplum içerisindeki öneminin giderek artmasına neden olmaktadır. Forbes’in 2018 yılı sonunda yayınladığı rapora göre, işletmelerin şu anda %44’ü, tekrar eden işleri yapay zekâyı devrederek, bilgi işçilerini güçlendirme çabasıyla çalışmalarını sürdürmektedir. İrlandalı ünlü yönetim danışmanlık şirketi Accenture, yapay zekâ uygulamalarını ilk kez kullanmayı düşünen organizasyonların, yapay zekâ ve insan-makine işbirliğini etkin bir şekilde kullanan başarılı şirketlerin stratejilerini takip etmeleri durumunda önemli kazançlar elde edebileceğini vurgulamaktadır. Accenture’a göre, bu yönde yapılacak yatırımlar 2019-2022 yılları arasında gelirlerde %38’e, istihdamda ise %10’a varan artışlar sağlayabilir. Dolayısıyla bu bilgiler göz önüne alındığında yapay zekâ çağında işletmelerin başarısının insanların ve makinelerin işbirliğine bağlı hale geldiğini söyleyebiliriz. Yapay zekâyı kullanan işletmelerde, kendini yöneten ekiplerin ortaya çıkmasına, dağıtılmış sorumluluk ve yerinden örgütsel yapıların iş akışlarının mekândan bağımsız hale gelmesine ve karar verme süreçlerinde yeni olanaklar sunmaktadır. Çünkü bugün işletmelerde yapay zekâ kullanımının henüz yüksek

seviyelere ulaşmamasına rağmen, işletmelerin karar verme aşmalarında isabetli ve güvenilir tahminlerde bulunması işletmeler için ilgi çekici hale gelmektedir. Söz konusu yeni teknolojiler; çeşitli sektörlerle, yakın zamana kadar farkında bile olmadıkları değişkenlerin etkisinde kalacaklarının habercisi olurken, verimliliğin teknolojik gelişmeler sayesinde, toplum ve birey bütünleşmesi ile artacağını vurgulamaktadır (Arslan, 2019).

İşletmeler, kaliteli ürünleri müşterilerin istediği zamanda düşük maliyetler ile üretmek veya satmak amacıyla değişen ve küreselleşen dünyada artan rekabet koşullarında daha fazla kazanç sağlamak için çalışmaya başlamışlardır. Tarih boyunca insan beyninin çalışma sistemi insanlık için merak ve tartışma konusu olmuştur. Bilim insanları, bu konuyla ilgili çeşitli incelemeler yapmış ve insan beyninin ulaşabileceği sınırları çözmeye çalışmıştır. Uzun süredir bu çalışmalar üzerine yapılan tartışmalar, insan beynini taklit eden makinelerin yapılmasıyla yapay zekâ kavramını ortaya çıkarmıştır. İnsan beyninin yapay zekâ yöntemleriyle modellenmesiyle birlikte değişik zekâ sistemlerinin geliştirilmesine yol açmıştır. Yapay zekâ, bir bilgisayarın insana benzer şekilde yorum yapmasını ve karar vermesini hedefler ve bilgisayarların insanlara benzer şekilde düşünerek problem çözmelerini sağlar. Yapay zekâ, günümüzde birçok işletmeye faydalar sağlamaktadır ve gelecekte de büyük bir potansiyele sahiptir. Yapay zekâ teknolojisi sayesinde, büyük miktardaki veriler analiz edilerek ve örüntüler kullanılarak insanlardan daha hızlı ve daha doğru sonuçlar üretilebilir. İşletmeler, yapay zekânın bu karmaşık verileri hızlı analiz etmesi sonucunda, zamandan kazanç sağlayarak müşteri hizmetlerini iyileştirebilir Yapay zekâ faaliyetlerinin en büyük avantajı işlemlerin daha kısa sürede gerçekleştirilmesini sağlamasıdır. Böylece işletmeler için aynı zamanda daha az gider anlamına gelen zaman kazancı sağlanmış olmaktadır (Kesici & Yildiz, 2016).

3.1. Yapay Sinir Ağları

Yapay Sinir Ağları, talep tahmininde bulunma da hızla popülerlik kazanmaktadır. Yapay Sinir Ağları sayısal veriler ile hesaplama yapma; bilgileri saklama, sisteme sunulan örnekleri kullanarak problemi öğrenebilme ve bu sayede daha önce karşısına çıkmayan durumlara çözüm üretebilme özelliklerine sahiptir. Bu nedenle Yapay Sinir Ağları, günlük hayatta finansal konulardan, mühendislik ve tıp bilimine, üretim uygulamalarına kadar birçok alanda uygulanabilmektedir.

Yapay sinir ağı uygulamaları genellikle tahmin, sınıflandırma, veri yorumlama ve veri filtreleme problemlerine uygulanmaktadır (Yılmaz, 2019).

Yapay sinir ağılar bir algoritmaya ihtiyaç duymadan programcının geleneksel yeteneklerini gerektirmeyen, kendi kendine öğrenme düzenekleridir. Bu ağılar öğrenmenin yani sıra, ezberleme ve bilgiler arasında ilişkiler oluşturma yeteneğine de sahiptir (Elmas, 2018).

Yapay sinir ağıları, yöneylem araştırmasının inceleme sahalarına giren tahmin, modelleme, araç rotalama, gezgin satıcı problemi, kümeleme, sınıflandırma gibi birçok alandaki problemlerin çözümünde tercih edilen bir metottur. Yapay zekâ ve beynin modellenmesi alanlarında geliştirilmiş, regresyon ve benzer yöntemlerde olduğu gibi bağımlı ve bağımsız değişkenler arasındaki ilişkiyi inceleyen bir fonksiyon tahmin aracıdır. Yapay sinir ağıları ile istatistiksel yöntemler arasındaki temel farklılık, sinir ağlarının istatistiksel dağılımla veya verilerin özellikleri ile ilgili herhangi bir varsayım yapmamasıdır. Diğer önemli özelliği de doğrusal olmayan bir tahmin yöntemi olduğundan karmaşık verilerin modellenmesinden daha uygun sonuçlar üretmesidir Yapay sinir ağıları, tipik zeki öğrenme yaklaşımının bir türüdür. Özellikle uygulamalı çalışmalarda geniş bir kullanım alanı vardır (Ermış, 2005; Yu, Wang, & Lai, 2008 s. 2623-2635).

Bu sistemlerin en önemli avantajı, pek çok veri birimine ait karmaşık modeli öğrenmek için gelişmiş hesaplama ve eğitim tekniklerinden yararlanır. Yapay sinir ağıları, geçmiş zamandaki verilerden yararlanarak problemi tanımlar ve matematik bir algoritma oluşturarak gelecekle ilgili tahminlerde bulunabilir (Hu, 2002, s.74).

3.2. Yapay Zekâ ve Yapay Sinir Ağları Arasındaki İlişki ve Farklar

Yapay Zekâ ve Yapay Sinir Ağları (YSA) arasındaki ilişki ve farklar, bu iki kavramın kapsamını ve işleyiş biçimlerini anlamak açısından önemlidir.

İlişki: Yapay Zekâ, makinelerin ve sistemlerin insan benzeri zekâ ve davranışları taklit etmeyi amaçlayan geniş bir alandır. Bu, problem çözme, öğrenme, algılama ve karar verme gibi yetenekleri içerir (Russell & Norvig, 2016). Yapay Sinir Ağları, Yapay Zekâ 'nin bir alt alanıdır ve verilerden öğrenme yeteneği sunan bir modeldir. YSA, özellikle makine öğrenimi ve derin öğrenme yöntemlerinde kullanılır (LeCun, Bengio, & Hinton, 2015; Alpaslan, 2021).

Yapay Zekâ'nın bir alt alanı olan makine öğrenimi, verilerden öğrenme ve genelleme yapma yeteneği sağlar. YSA, makine öğreniminin bir türü olarak kabul edilir ve verilerle öğrenme sürecinde kullanılır (Mitchell, 1997).

Derin öğrenme, çok katmanlı yapay sinir ağlarını kullanarak veri üzerinde daha karmaşık ve derin analizler yapar. YSA, derin öğrenmenin temel yapı taşlarından biridir (Goodfellow, Bengio, & Courville, 2016).

Farklar: Yapay Zekâ, geniş bir alan olup, çeşitli yöntemleri ve teknikleri içerir. Bu yöntemler arasında kural tabanlı sistemler, karar ağaçları, destek vektör makineleri ve genetik algoritmalar gibi birçok farklı yaklaşım bulunur (Russell & Norvig, 2016). YSA, bu geniş alanın özel bir alt kümesidir. YSA, biyolojik sinir ağlarını taklit eden bir modeldir ve genellikle büyük veri setleriyle çalışır (LeCun, Bengio, & Hinton, 2015).

Yapay Zekâ, çeşitli algoritmalar ve yaklaşımlar içerir. Bu, veri ön işleme, özellik mühendisliği ve farklı öğrenme tekniklerini kapsar (Mitchell, 1997). YSA, yapay nöronlar ve çok katmanlı yapılar kullanarak öğrenir. YSA'nın temel bileşenleri, yapay nöronlar, ağırlıklar ve aktivasyon fonksiyonlarıdır (McCulloch & Pitts, 1943).

Yapay Zekâ'nın çeşitli teknikleri, farklı hesaplama gücü ve veri gereksinimlerine sahiptir. Örneğin, bazı teknikler daha az hesaplama gücü gerektirirken, diğerleri daha karmaşık olabilir (Bishop, 2006). YSA, genellikle büyük veri setleri ve yüksek hesaplama kapasiteleri gerektirir. Özellikle derin öğrenme yöntemleri, büyük ve karmaşık sinir ağları kullanarak verilerden öğrenir (Krizhevsky, Sutskever, & Hinton, 2012).


Yapay Zekâ, çeşitli uygulama alanlarında kullanılabilir. Bu, doğal dil işleme, robotik, oyun oynama ve daha fazlasını içerir (Russell & Norvig, 2016). YSA, genellikle görüntü tanıma, ses tanıma ve doğal dil işleme gibi spesifik uygulamalarda kullanılır (LeCun, Bengio, & Hinton, 2015).

3.3.Yapay Sinir Ağlarının Yapısı ve Temel Elemanları

3.3.1. Yapay Sinir Hücresi

YSA dış dünyadan aldıkları verileri işleyerek öğrenme işlemini gerçekleştirmekte, öğrendikleri bilgileri hafızada tutarak veriler arasındaki ilişkileri ortaya koymaktadır. Aşağıdaki şekilde basit bir YSA hücresinin yapısı gösterilmiş

olup, nöron olarak adlandırılan bu hücreye dış dünyadan bir veya daha fazla girdi verisi verilerek toplama fonksiyonu ve aktivasyon fonksiyonu aracılığıyla çıktıya dönüştürülür, bu çıktı değeri dış dünyaya sunulabileceği gibi herhangi bir sinir hücre sinin girdi verisi de olabilmektedir. YSA hücresinin kendi denklemleri olmadığı için ağı içerisinde hangi işlemlerin gerçekleştiği bilinmediğinden bu özelliği sayesinde kara kutu olarak tanımlanmaktadır (Öztemel, 2006; Aktaş, Doğanay, & Yıldız, 2003).



Şekil 3. 1 Yapay Sinir Hücresinin Yapısı

Kaynak: (Fırat &Güngör, 2004)

YSA'nın hücresi yapısı biyolojik sinir ağlarının hücre yapısına benzer şekilde beş elemandan oluşmaktadır. Bunlar yukarıda Şekil 3.1'de görüldüğü gibi girdiler, ağırlıklar, toplama fonksiyonu (birleştirme fonksiyonu), aktivasyon fonksiyonu ve çıkışlardır.

3.3.2. Yapay Sinir Ağı Hücresi Elemanları

3.3.2.1. Girdiler

Dış dünyadan gelen bilgilerin toplandığı yer olan girdi katmanı sayesinde YSA hücresine bilgiler sunulmaktadır. YSA hücresinin girdi katmanında herhangi bir bilgi işleme olmadan verilen bilgiler ağı içerisinde ileriye doğru yayılmaktadır. Girişler, yapay sinir ağlarının dış dünya ile ilişki halinde olan iki elemanından biridir. Bir

nöronun sınırsız sayıda girişi olabilir fakat her bir nöronun sadece tek bir çıkışı olmak zorundadır.

3.3.2.2. Ağırlıklar

YSA'ya eğitime başlandığında ağırlıklar rastgele verilir ve bu rastgele ağırlıklar için eğitim seti verileri uygulanır. Eğer işlem sonunda çıkış değeri kabul edilebilir hata payına ulaşmış veya bu hatanın altında kalmışsa ağ eğitilmiştir. Aksi takdirde işlemlerde başa dönülür ve ağırlıklar yeniden ayarlanır. Bu istenilen hata seviyesine gelinceye kadar birkaç kez tekrarlanır. Gerçek değerler ile sistemden elde edilen çıktı değerleri arasındaki hatanın minimum olması çok önemlidir (Çakır, 2019).

3.3.2.3. Birleştirme Fonksiyonu (Toplama Fonksiyonu)

Girdiler ile ağırlıkların çarpılması ile NET girdi değeri bulunur. Girdiler ve ağırlıklar çarpıldıktan sonra NET değerinin hesaplanmasında birkaç yöntem kullanılabilir. Aşağıda verilmiş olan formül birleştirme fonksiyonu olarak yani NET hesaplama yöntemi olarak toplamının kullanıldığı Formül 3.1.'de verilmiştir.




$$NET = \sum_{i=1}^n x_i \cdot w_i \quad (3.1)$$

Bu formülde 1. girdiden n. girdiye kadar olan girdilerin her birinin kendilerine verilmiş rastgele ağırlık değerleri ile çarpılması ve elde edilen sonuçların toplanması anlatılmaktadır. x değerleri her bir girdiyi w değerleri ise her bir girdinin kendi ağırlıklarını göstermektedir.

3.3.2.4. Aktivasyon Fonksiyonu

Birleştirme fonksiyonu ile elde edilen değerler çok büyük olabilir. Yapay hücrede, birleştirme fonksiyonundan sonra elde edilen NET değeri ile bir sonraki aşama olan aktivasyon fonksiyonuna geçilir. Her durum için evrensel olarak kabul görmüş bir aktivasyon fonksiyonu yoktur. Bu fonksiyon, hangi birleştirme fonksiyonu ile olursa olsun elde edilen NET girdi değerini işler ve mevcut ağırlık üreteceği çıktıyı belirler. Aşağıda, Tablo 3.1'de YSA'da kullanılan aktivasyon fonksiyonlarının formülleri verilmiştir.

Tablo 3.1 Aktivasyon Fonksiyonları

Doğrusal (Lineer) Aktivasyon Fonksiyonu		$F(Net) = A * Net$ (A sabit bir sayı)	Doğrusal problemler çözmek amacıyla aktivasyon fonksiyonu doğrusal bir fonksiyon olarak seçilebilir. Toplama fonksiyonundan çıkan sonuç, belli bir katsayı ile çarpılarak hücrenin çıktısı olarak hesaplanır.
Adım (Step) Aktivasyon Fonksiyonu		$F(Net) = \begin{cases} 1 & \text{if } Net > \text{Eşik Değer} \\ 0 & \text{if } Net \leq \text{Eşik Değer} \end{cases}$	Gelen Net girdinin belirlenen bir eşik değerin altında veya üstünde olmasına göre hücrenin çıktısı 1 veya 0 değerini alır.
Sigmoid Aktivasyon Fonksiyonu		$F(Net) = \frac{1}{1 + e^{-Net}}$	Sigmoid aktivasyon fonksiyonu sürekli ve türevi alınabilir bir fonksiyondur. Doğrusal olmayışı dolayısıyla yapay sinir ağı uygulamalarında en sık kullanılan fonksiyondur. Bu fonksiyon girdi değerlerinin her biri için 0 ile 1 arasında bir değer üretir.
Tanjant Hiperbolik Aktivasyon Fonksiyonu		$F(Net) = \frac{e^{Net} + e^{-Net}}{e^{Net} - e^{-Net}}$	Tanjant hiperbolik fonksiyonu, sigmoid fonksiyonuna benzer bir fonksiyondur. Sigmoid fonksiyonunda çıkış değerleri 0 ile 1 arasında değişirken hiperbolik tanjant fonksiyonunun çıkış değerleri -1 ile 1 arasında değişmektedir.
Eşik Değer Fonksiyonu		$F(Net) = \begin{cases} 0 & \text{if } Net \leq 0 \\ Net & \text{if } 0 < Net < 1 \\ 1 & \text{if } Net \geq 1 \end{cases}$	Gelen bilgilerin 0 dan küçük-eşit olduğunda 0 çıktısı, 1 den büyük-eşit olduğunda 1 çıktısı, 0 ile 1 arasında olduğunda ise yine kendisini veren çıktılar üretilir.
Sinüs Aktivasyon Fonksiyonu		$F(Net) = \sin(Net)$	Öğrenilmesi düşünülen olayların sinüs fonksiyonuna uygun dağılım gösterdiği durumlarda kullanılır.

Kaynak: (Çayıröğlu, 2015)

3.3.2.5. Hücrenin Çıktısı

Hücrenin 5. kısmı olan çıktı, aktivasyon işlemi tarafından belirlenen değerdir. Bu yapay sinir hücresi için bilgi üretilmiştir ve üretilen bilgi dışarıya ya da başka bir hücreye tekrar bilgi girişi olarak çıkacaktır. Bir hücreden uygun sadece bir adet çıktı elde edilir.


3.4. Yapay Sinir Ağı Mimarileri

Tahminde kullanılan tipik bir yapay sinir ağı bir girdi katmanı, ara katman ve bir çıktı katmanı olmak üzere üç katmandan oluşur. Girdi bilgileri önce girdi katmanına oradan gizli katmana ve sonra da çıktı katmanına aktarılmakta ve sonuçta çıktı bilgilerine ulaşılmış olmaktadır.

Bu katmanların işlevleri aşağıda biraz daha açık olarak aktarılmaktadır:

1. Girdi katmanı: En az bir girdi elemanının bulunduğu bölümdür. Girdi katmanı bağımsız değişkenlerin her biri için birer tane hücre taşır. Bu katmanda veriler herhangi bir işleme tabi tutulmadan girdileri ile aynı değerde çıktı üretirler (Thall, 1992).

2. Ara katmanlar: Girdilerin belirli işlemlere tabi tutulduğu bölgedir. Seçilen ağ yapısına göre işlem katmanının yapısı ve fonksiyonu da değişebilir. Tek bir katmandan oluşabileceği gibi birden fazla katmandan da oluşabilir.



Şekil 3.2 Çok Katmanlı YSA Modeli

Kaynak: (Fırat & Güngör, 2004)


Şekil 3.2’de görüldüğü gibi katmanlardaki hücreler birbirlerine bir ağ yapısıyla bağlıdır. Bu bağlantılar değişik değerlerde ağırlıklandırılmaktadır.

3.Çıktı katmanı: Çıktı katmanı en az bir çıktıdan oluşur ve çıktı ağ yapısında bulunan fonksiyona bağlıdır. Bu katmanda işlem gerçekleştirilir ve üretilen çıktı dış dünyaya gönderilir.

YSA'lar mimari olarak temelde üç farklı yapı gösterir. Bunlar tek katmanlı ileri beslemeli ağlar, çok katmanlı ileri beslemeli ağlar ve geri beslemeli ağlardır (Haykin, 1999).

3.5. Tek Katmanlı Yapay Sinir Ağları

Ağa girdi değerleri ve girdiler için üretmesi gereken çıktı değerleri verilir. Ağ çıktıları üretmeye başlayana kadar eğitim devam eder. Çıktı değerlerine ulaşabilmesi için ağın ağırlıklar her bir iterasyonda değiştirilir. Çıktı değerlerine ulaşıldığında ağın eğitimi tamamlanmıştır ve ağ kullanıma hazırdır. Tek katmanlı YSA sadece doğrusal problemler için kullanılabilir (Gurney, 1996).




Şekil 3.3 Tek Katmanlı YSA Yapısı

Kaynak: (Gurney, 1996)

Tek katmanlı YSA yapısının genel gösterimi şekil 3.3'deki gibidir.

3.6. Çok Katmanlı İleri Beslemeli Yapay Sinir Ağları

Çok katmanlı ileri beslemeli ağlarda nöronlar arasındaki; bilgi, girişten çıkışa doğru tek yönlü düzenli katmanlar halindedir (Uğur & Kınacı, 2006). Bir katman sadece kendinden sonra gelen katmana bağlanmıştır ve bir nöronun çıktısı sadece kendinden sonra gelen nöron katmanına girdi olabilir. Aynı katmandaki başka bir nörona bağlantı yoktur (Haykin, 1999).




Şekil 3.4 Çok Katmanlı İleri Beslemeli Yapay Sinir Ağı

Kaynak: (Kaynar & Taştan, 2009)

İleri beslemeli ağlarda bilgi, girdi katmanından çıktı katmanına doğru hareket eder ve ayrıca bu üç katmanın birbirleriyle bağlantısı yoktur. Çok katmanlı ileri beslemeli ağ Şekil 3.4' teki gibidir.

3.7. Geri Beslemeli Yapay Sinir Ağları

Bir geri beslemeli sinir ağı, çıkış ve ara katlardaki çıkışların, giriş birimlerine veya önceki ara katmanlara geri beslendiği bir ağ yapısıdır. Böylece, girişler hem ileri yönde hem de geri yönde aktarılmış olur (Rao & Srinivas, 2003). Ağ geri besleme sayesinde ortaya çıkan her tür hatayı: belirleyip geriye dönük hata düzeltmesi yapabilir ve aynı hataları daha kolay önleyebilir (Haykin, 1999).



Şekil 3. 5 Geri Beslemeli Yapay Sinir Ağı

Kaynak: (Haykin, 1999)

Geri beslemeli bir ağ Şekil 3.5' deki gibidir.

3.8. Yapay Sinir Ağlarında Öğrenme

YSA yapısının temel amacı beklenen değer ile çıktı değeri arasındaki hatayı minimum yapacak ağın kurulmasıdır. Teknik olarak, YSA, örnek veri setindeki yapıyı öğrenerek, istenilen görevi yerine getirecek şekilde genelleştirmeler yapmasıdır. Bunun yapılabilmesi için ağ, ilgili olayın örnekleri ile eğitilerek genelleme yapılabilecek yeteneğe kavuşturulur (Öztemel, 2003).

YSA, diğer matematiksel modellerde olduğu gibi, örneklerden öğrenen ve öğrendiklerini daha önce görmediği örneklerle uygulayan bir yapıdır. Eğitildiği örnek türleri dışında, herhangi bir konuda yeniden eğitilmeden yanıt veremez (Çakır, 2019; Denton, 1995).

Verilerin ağına sunulma aşamasında, veri bölümlendirme işlemleri yapılır. Hangi değişkenlerin bağımsız, hangilerinin bağımlı değişken olduğunun ve verilerin ne kadarının eğitim, doğrulama veya test için alınacağını ağına tanıtılması gerekir. Bazı çalışmalarda değişken seti; Train (Eğitim), Validation (Doğrulama), Testing (Test) olarak üç bölüme ayrılırken bazı çalışmalarda bu bölümlendirme Eğitim ve Test olarak yapılmaktadır. Literatürde, bu bölümlendirme genellikle üçlü olduğunda %70 eğitim, %15 test ve %15 doğrulama; %80 eğitim, %10 test, %10 doğrulama veya %70 eğitim, %20 test, %10 doğrulama olarak yapılmaktadır. İkili bölme durumunda ise dağılım %90 eğitim, %10 test; %80 eğitim, %20 test veya %70 eğitim, %30 test şeklinde olmaktadır (Zhang, Patuwo, & Hu, 1998).

Bir YSA ile eğitime başlanırken belirlenmesi gereken en önemli değerlerden biri de YSA katmanlarında kaç adet gizli nöron olacaktır. Gizli nöron sayısının belirlenmesi için kesin kurallar yoktur. Genellikle belirli sayılardan başlanarak, aşamalı artırma yöntemi ile uygun sayı belirlenir (Yıldız, 2009).

Bir ağ tasarlandığında ve eğitime başlandığında, bu ağın eğitim sürecinin ne zaman sona ereceği belirlenmelidir. Ağa ulaşamayacağı bir durdurma kriteri verilirse, ağ bu kriter değerine ulaşana kadar sürekli iterasyon yapmaya devam edecektir. Diğer bir durumda, ağ çok az iterasyon sonucunda durmaya programlanmış olabilir. Bu durumda ağ, öğrenmeyi tamamlamadan durdurulmuş olacaktır. Ağ yapısı tasarlanırken, ağın çok erken veya çok geç durmasına neden olacak durdurma kriterleri seçilmemelidir. Durdurma kriterleri; belirli bir iterasyon sayısına ulaşıldığında dur,

belirli bir süre sonunda dur, ya da belirli bir hata düzeyine ulaşıldığında dur gibi seçenekler olabilir (Çakır, 2019).

3.9. Geri Yayılım Algoritması

YSA'lar hata yaparak öğrenir ve sahip oldukları öğrenme algoritması ile bu hataları belirler. Öğrenme algoritmasına göre belirlenen hatayı azaltmak için ağırlıkları değiştirilir ve ağırlıkların tekrar çıktı üretmesi sağlanır. Bu işlem, ağırlıklar istenen çıktıları verene kadar tekrarlanır. Bu algoritma, iki katmanlı ileri beslemeli ağların başarılı çözüm üretilmediği problemlerin çözümünde başarı sağlamıştır (Haykin, 1999).

Bir YSA'da en çok kullanılan eğitim algoritması, uygulama basitliği ve uygulamadaki görüş açısı gibi avantajlarından dolayı yapay ağırlıklı eğitimi için en popüler algoritmalarından biri olan geri yayılım (Backpropagation) algoritmasıdır (Zhang vd., 1998). Algoritma güçlü bir çalışma sistemine sahiptir; karmaşık, doğrusal olmayan YSA'ların eğitiminde çok etkilidir ve temel amacı, ağırlıklardan üretilen çıktı ile girdi değerleri arasındaki hatayı minimuma indirmektir (Verbos, 1994).

Geri besleme sistemi; ortaya çıkan hataları, eğitim sırasında çıkış katmanından giriş katmanına doğru ters yönde iletilme sürecidir (Diler, 2003). Hatalar düğümler vasıtasıyla geri iletilindiğinde bağlantı ağırlıkları değiştirilir. Eğitim, ağırlıklardaki hatalar kabul edilebilir düzeye varana kadar gerçekleştirilir (Lawrence, 1997). Geri yayılım öğrenme girdi vektörlerinin normalleştirilmesini gerektirmez; Bununla birlikte, normalleştirme performansı artırabilir (Buckland & Collins, 2018).

Geriye yayılım, birçok uygulamada kullanılan en yaygın öğrenme algoritmasıdır. Anlaşılması kolay ve matematiksel olarak ispatlanabilir olmasından dolayı en çok tercih edilen öğrenme algoritması olmuştur. Geriye yayılım öğrenme yöntemi, sistem hatasını azaltma esasına dayanan bir iyileştirme işlemidir. Bu algoritma, hataları çıkıştan girişe geriye doğru azaltmaya çalışmasından dolayı geri yayılım ismini almıştır (Yazıcıoğlu, 2010).


3.10. Yapay Sinir Ağlarının Eğitilmesi

Yapay sinir ağları insanlar gibi örnekler ile eğitilirler. Yapay sinir ağlarının öğrenmesi bir çocuğun öğrenmesine benzetilebilir. Sıcak bir nesneye dokunmaması gerektiğini deneyerek öğrenen çocuklar zamanla daha az sıcak olan bir cisme

dokunabilme cesaretini gösterirler ve sıcak süt dolu bardağı elleriyle tutarlar. Yani çocuk sıcaklık bilgisini öğrenmiş olmaktadır. Yapay nöronlar da benzer olarak; mevcut örnek kümesi üzerinde girdi ile çıktı arasındaki sinaptik ağırlıkların değiştirilmesiyle eğitilirler.

Yapay sinir ağlarının eğitimi ve testi için toplanan veriler, sistemin düzgün çalışma uzayını kapsamalıdır. Örnek kayıtlarının çalışma uzayının sınırlarını belirlediği ve Yapay sinir ağlarının yalnızca eğitildiği çalışma aralığı için güvenilir sonuç verebildiği unutulmamalıdır. Genel özelliklerin net olarak belirlenmesi için örnek kümesinin geniş olması tercih edilir. Bu kümenin bir kısmı eğitim aşamasında kullanılırken, bir kısmı test aşamasında ağıın genelleştirme yeteneğinin onayı amacıyla kullanılır. Testin başarısızlığı durumunda, test amacıyla kullanılan kayıtların bir kısmı eğitim verilerine aktarılarak, eğitim ve test işlemleri kabul edilebilir bir performans düzeyine ulaşınca kadar bu işlem tekrarlanır (Efendigil, 2008, s.44-46).

Yapay sinir ağlarının eğitiminde, genel olarak aşağıdaki adımlar izlenmektedir (Rajpal, Shishodia, & Sekhon, 2006; Güngör, 2007; Hu, 2002):




Şekil 3. 6 İleri Beslemeli Bir Sinir Ağının Eğitim ve Test Aşamaları

Kaynak: (Rajpal vd., 2006, s.812)

Yukarıda Şekil 3.6’da ileri beslemeli bir sinir ağının eğitim sürecinde yapılan işlemleri ve test aşamalarına ait akışı gösterilmiştir.

Sinir ağlarının eğitilmesi esnasında karşılaşılan önemli sorunlardan birisi, öğrenme süresinin çok uzun olmasıdır. Bazı problemlerin çözümü sadece 200 iterasyon sürerken bazıları 5-10 milyon iterasyon gerektirmektedir. Başlama koşullarının tamamen deneme yanılma yolu ile belirlenmesi ve en uygun başlama koşullarının böylelikle bulunması gerekmektedir (Öztemel, 2006, s.84).



Şekil 3. 7 Yapay Sinir Ağlarının Öğrenme Eğrisi

Kaynak: (Öztemel, 2006,s.84)

Yukarıda Şekil 3.7’de sinir ağının eğitiminin tamamlanması ve hata düzeyinin istenen düzeye indirilmesi için işlemci elemanın ağırlık değerinde yapılacak değişim sayısı (iterasyon) ilişkisini gösteren grafik gösterilmiştir.

Yukarıdaki Şekil 3.7’de görüldüğü gibi, iterasyon sayısı arttıkça ağın öğrenmesi de artmakta ve bu öğrenme zamanıyla birlikte hata oranı da düşmektedir. Ancak, grafikte görüldüğü gibi, iterasyon sayısı belli bir düzeye ulaştıktan sonra hata oranında artık daha fazla azalma olmadığı görülmektedir. Bu durum, ağın eğitiminin tamamlandığını, öğrenmenin artık durduğunu ve bundan daha iyi sonuca ulaşamayacağını göstermektedir.

3.11. Yapay Sinir Ağlarının Performans Ölçütlerinin Belirlenmesi

YSA modelleri için eğitim süresi, modelleme süresi gibi farklı performans ölçütleri bulunmasına rağmen en önemli performans ölçütü, eğitim sonucunda ağın tahmin doğruluğudur. Ancak buna rağmen problem türüne uygun doğruluk ölçütleri net olarak belirlenmemiştir. Gerçek değer ile modelden elde edilen değerler

arasındaki fark hata olarak tanımlanırsa; bu hata değeri hangi model için daha küçükse o model tercih edilir (Al-Hamadi & Soliman, 2004; Huang & Shih, 2003; Hamzaçebi, 2011).

Çok kullanılan doğruluk ölçütleri aşağıda Tablo 3.2’de gösterilmektedir.

Tablo 3. 2 YSA Performans Ölçütleri

Performans Ölçütü	Matematiksel İfadesi
Ortalama Mutlak Sapma (The Mean Absolute Deviation- MAD)	Y_t = Gerçek değer F_t = Elde edilen çıktı değeri olmak üzere, $MAD = \frac{1}{n} \sum_{t=1}^n Y_t - F_t $
Hata Kareler Ortalaması (Mean Squared Error-MSE)	$MSE = \frac{1}{n} \sum_{t=1}^n (Y_t - F_t)^2$
Hata Kareler Toplamı (Sum Squared Error-SSE)	$SSE = \sum_{t=1}^n (Y_t - F_t)^2$
Kök Ortalama Kare Hata (Root Mean Squared Error-RMSE)	$RMSE = \sqrt{MSE}$
Ortalama Mutlak Hata Yüzdesi (Mean Absolute Percentage Error-MAPE)	$MAPE = \frac{1}{n} \sum_{t=1}^n \left \frac{Y_t - F_t}{Y_t} \right \times 100$

Kaynak: (Zhang vd., 1998)

Ortalama Mutlak Sapma (MAD): Modelin tahminlerinin gerçek değerlerden ortalama olarak ne kadar sapma gösterdiğini ölçer.

Hata Kareler Ortalaması (MSE): Modelin tahminlerinin gerçek değerlerden sapmalarının karelerinin ortalama değeridir. Bu değer ne kadar düşükse, modelin tahminlerinin gerçek değerlere ne kadar yakın olduğunu gösterir.

Hata Kareler Toplamı (SSE): Modelin tahminlerinin gerçek değerlerden sapmalarının karelerinin toplamıdır. Bu da modelin ne kadar iyi uyum sağladığını ölçer. Daha düşük bir SSE, modelin daha iyi uyum sağladığı anlamına gelir.

Kök Ortalama Kare Hata (RMSE): MSE'nin kareköküdür. Gerçek değerler ile tahmin edilen değerler arasındaki ortalama sapmanın bir ölçüsüdür.

Ortalama Mutlak Hata Yüzdesi (MAPE): Modelin tahminlerinin gerçek değerlerden ortalama olarak yüzde kaç oranında sapma gösterdiğini ölçer.

Daha düşük MAD, MSE, SSE, RMSE ve MAPE değerleri, modelin daha iyi performans gösterdiğini gösterir. Ancak, bu ölçütlerin tek başına değerlendirilmesi yerine, birlikte değerlendirilmesi tavsiye edilir.

3.12. Yapay Sinir Ağlarının Kullanım Alanları

Temel olarak, yapay sinir ağlar uygulamalarının çoğu aşağıdaki sınıflardan birine girmektedir (Goodfellow, Bengio & Courville, 2016)

- Öngörü
- Sınıflandırma
- Veri birleştirilmesi
- Veri kavramlaştırılması
- Veri süzülmesi
- Resim veya Görüntü İşleme

Yapay Sinir Ağlarının kullanım alanlarına aşağıda bahsedilmiştir.

3.12.1. Endüstriyel Alanda Yapay Sinir Ağlarının Kullanımı

Yapay Sinir Ağları sanayideki kalite denetiminde, kalitenin geliştirilmesinde yaygın olarak kullanılmaktadır. Pavilion Technologies tarafından geliştirilen bir sinir ağı işlem denetim sistemi, ürün kalitesi geliştirme ve ürün kalitesinin yükseltilmesinde kullanılmaktadır (Pavilion Technologies, 2024). İngiliz Columbia Hidroelektrik santralında bulunan dört büyük senkron kompanzatör sinir ağlar ile güç dağıtım şebekelerinde basanıyla kullanılmaktadır (Pijls, Young, Heidari & 2003). Kopin Corp. tarafından geliştirilen bir sinir ağı güneş enerjisi pilleri üretiminde konum kalık hatalarının saptanması ve birçok hatanın tespitinde kullanılmaktadır. (Ho, Kim & Leach, 2001). Çeşitli üniversite laboratuvarlarında işaret işleme deneylerinde sinir

ağlar kullanılmaktadır. Petrol endüstrisi içinde rafine işlemlerinde sinir ağları kullanılmaktadır. Arco ve Texaco'nun da içinde bulunduğu petrol şirketlerinde yer altındaki gaz ve petrol alanların tespit etmekte sinir ağlarından yararlanmaktadırlar (Williams, Young, & Smith, 1998) (Smith, Johnson, & Clark, 2002). Yapay sinir ağlarıyla dil işleme üzerine çok büyük araştırmalar süregelmektedir. Bu uygulamaların bazıları konuşmaya, metne çevirme, otomatik dil çevirisi, işitme ve bedensel engelliler için protez geliştirmesi, seste konuşma da ve doğal dil işlemlerini kapsamaktadır (Dutton, Green & Mears 2004).

3.12.2. Ulaştırma ve Havacılık Alanında Yapay Sinir Ağlarının Kullanımı

Ford Motor Co., General Motors gibi bir çok otomobil imalatçısı otomobillerde ve otomobil ürünlerinde sinir ağı kullanımının daha yaygın olarak kullanabilmek için araştırmalara devam etmektedirler. Fren denetimi, etkin süspansiyon denetimi gibi bazı alanlarda umut verici sonuçlar elde edilmiştir (Zhang, Patuwo & Hu, 1998). NASA'da, uzay mekiği yolculuklarında manevra denetimi için yapay sinir ağları çalışmaları yapılmaktadır. Uçaklarda titreşim seviyeleri ve sesin görüntülenerek motor sorunlarında erken uyarı için sinir ağları geliştirme çalışmaları yapılmaktadır. Purdue Üniversitesi bir helikopter örneğinin yapay sinir ağlarıyla denetim sonuçlarını yayınlamıştır. Bir diğer prototip uygulamasında, özel bir kara taşıtının sürücüsüz seyri için geliştirilmiş bir sinir ağı uygulaması bulunmaktadır. Yapay sinir ağları, hava alanlarında bagaj geçişlerinde bomba tanıma ve ortaya çıkarma amacıyla kullanılmaktadır (LeCun, Bengio & Hinton 2015).

3.12.3. Finans, Borsa ve Kredi Kartı Alanında Yapay Sinir Ağlarının Kullanımı

Dünya finans pazarında yapay sinir ağları büyük ölçüde kullanılmaktadır. Banka işlemleri, kredi kart şirketleri ve ticari borç verme kuruluşlarının kararlarında, tüm bunların öğrenilmesi ve istatistiksel eğilimlerin olması gerekmektedir. Yapay sinir ağları, içinde Merrill Lynch ve Co., Salomon Brothers, Shearson Lehman Brothers Inc, Citibank ve World Bank'in bulunduğu mali kurumlar ve gelişmiş firmaların büyük kısmında mali tahmin için kullanılmaktadır. Manhattan Bank, sinir ağlarından oluşan bir ödünç para risk inceleme sistemi kullanılmaktadır. American Express, Mellon Bank, First USA Bank gibi bazı bankalar ve kredi kart şirketleri, potansiyel sahtekârlıkla önlemek amacıyla sürekli sinir ağı kullanmaktadırlar (Liang & Wang,

1998). Sinir ağırları el yazısı ve imza tanımlanması için kullanılmaktadır. Borsa şirketleri değişimleri incelemek ve tahminde bulunmak için sinir ağırları kullanılmaktadır. Borsa hedef sistemi Churchill System tarafından geliştirilmiş ve Veratex Corp. tarafından kullanıma devam edilmektedir. Bu şirket borsa stratejisini ve borsa ödemelerinin kesilmesini ve potansiyel müşteri listelerinden gelecekteki müşteri tahminlerini yapay sinir ağırlarıyla yapmaktadır (Zhang, Patuwo & Hu, 1998).

3.12.4. Tıp, Biomedikal ve İlaç Sanayi Alanında Yapay Sinir Ağlarının Kullanımı

Yapay sinir ağırları, biyomedikal alanında hızla yayılmaktadır. RNA ve DNA' da amino asit incelemelerinde geniş biçimde, ECG ve EEG dalga formunda, hastaların ilaçlara karşı tepkilerinin incelenmesinde, kazalarda sakatlılardan korunmada, meme, göğüs ve akciğer kanseri tanısında yapay sinir ağırlar kullanılmaktadır. (Acharya, Sree & Ray, 2010) Yapay Sinir ağırları ilaç sanayinde pahalı çalışmalar olmadan ilaç geliştirilmesinde, zaman tasarruf etmek için ve insanlarla, hayvanların üzerindeki tepkisini incelemede sıkça kullanılır (Chen & Zhang, 2014).

3.12.5. İletişim Sanayi Alanında Yapay Sinir Ağlarının Kullanımı

Yapay sinir ağırlar iletişim sanayinde yaygın olarak kullanılmaktadır. Bu uygulamalarda temel amaç, belgegeçer ve telefon hatlarının güncellenmesinde ve hatlarda olabilecek yankıların giderilmesidir. Yapay sinir ağırları ayrıca veri sıklaştırma işlemleri için de kullanılmaktadırlar (Kienhuis & Meer, 1999)

Yapay sinir ağırlar bilgi sınıflama ve bilgi yorumlamanın da içinde bulunduğu çok değişik problemlerin çözümünde kullanılmaktadır. Yapay sinir ağırlarının kullanıldığı alanlar özet olarak şu şekilde sıralanabilir (Özkaya, Savaşır ve Beşdok, 2024):

- Denetim
- Sistem modelleme
- Ses tanıma
- El yazısı tanıma
- Parmak izi tanıma
- Elektrik işareti tanıma
- Meteorolojik yorumlama
- Otomatik araç denetimi

- Fizyolojik işaretleri (Kalp fonksiyonları gibi) izleme, tanıma ve yorumlama

Yukarıda verilen başlıklara ilave olarak, yapay sinir ağları, her türlü bilgiyi işlemek ya da analiz etmek amacıyla kullanırlar. İş hayatı, finans, endüstri, eğitim ve karışık problemlerli bilim alanlarında, bulanık veya var olan basit yöntemlerle çözülemeyen problemlerin çözümünde, doğrusal olmayan sistemlerde başarıyla uygulanmaktadır (Zhang, Patuwo & Hu, 1998).

3.13. Yapay Sinir Ağlarının Avantajları

Yapay sinir ağları kullanılarak yapılan analizlerde, YSA'nın avantajlı ya da güçlü yönlerini aşağıdaki gibi sıralamak mümkündür. (Zhang, Patuwo, & Hu, 1998; Şen, 2004; Çakır, 2019:14-15; Çelik, 2008, s.26; Kellova, 2008, s.35-38).

- YSA, yaşanan gerçek problemlerin birçoğunun çözümünde kullanılır.
- Çözülmesi zor olan problemlere en bilinmedik zamanlarda bile çözüm üretebilir.
- İstatistik veya benzeri teknikler için gerekli olan veri ile ilgili varsayımlar yoktur.
- Makine öğrenmesi yapabilir.
- Doğrusal olan veya olmayan çoklu giriş ve çoklu çıkışlı sistemleri kolaylıkla modelleyebilir.
- Yapay sinir ağlarındaki matematiksel nöronların ölme ihtimali olmadığından hafızasındaki bilgiler asla kaybolmaz.

3.14. Yapay Sinir Ağlarının Dezavantajları

YSA'nın eksik ya da dezavantajlı yönlerini aşağıdaki gibi sıralamak mümkündür (Şen, 2004; Öztemel, 2006; Hu, 2002; Çakır, 2019, s.16-17).

- Güvenilir sonuçlar elde etmek için fazla veri sayısı gereklidir.
- Giriş ve çıkış değişkenlerinin her birinin diğeri ile ikişerli ilişkilerinin bilinmesi mümkün değildir. Her YSA modeli, içindeki ilişkiler için bir kara kutudur.
- Kara kutunun içinde YSA'nın nasıl gözüm ürettiği hâlâ merak edilen bir konudur.
- Sözel nitelikteki verileri isleyememektedir. Sadece nümerik verilerin islemesinde kullanılır.

- Ađın eđitiminin ne zaman gerekleŖeeđine dair karar vermek iin geliŖtirilmiŖ bir yntem yoktur. Kabul edilebilir hata deđerine veya bu deđerin altında bir deđere inildiđinde ađın eđitimi tamamlanmıŖ olur. Ancak bu tamamlanan eđitim ađın elde edebileeđi en iyi deđerin elde edildiđi anlamına gelmez.
- YSA gibi paralel iŖlemciler ile alıŖan sistemlerin seri iŖlemciler ile yapılması ok uzun sreler alır.
- YSA kabul edilebilir zmler retir kesin en iyi zm garanti etmez. Probleme uygun ađ yapısının ok iyi belirlenmesi gerekir. Eđer ađ belirleme iŖlemi uygun seklide yapılmazsa etkin zm bulunabilen bir problem zlmeden kalabilir ya da daha etkin zmler varken daha kt zmler ile iŖlemler yapmak zorunda kalabiliriz.
- Katman sayısı, hcre sayısı, đrenme katsayısı gibi ađın parametre deđerleri iin belirli bir say yoktur. Bu parametrelerin sayısı tecrbeye gre belirlenebilir.
- Sonuların duyarlılık analizinde yorumlandıđı gibi yorumlanması imknsızdır.

DÖRDÜNCÜ BÖLÜM

ÖRNEK UYGULAMA

4.1. Materyal

Türkiye’de otomobil üretip en çok satışı yapan 6 firmanın (OYAK Renault, Tofaş, Toyota, Ford, Honda ve Hyundai) 01.01.2014-31.12.2023 yılları arasındaki 120 aylık satış verisinden yola çıkılarak Octave Programı ile Çoklu Regresyon Analizi, Zaman Serisi Modeli ve Yapay Sinir Ağları Modeliyle tahmin gerçekleştirilmiştir.

Bu bölümde Çoklu Regresyon Analizi, Zaman Serisi Modeli ve Yapay Sinir Ağları Modeliyle yapılan tahminler ve modellerin tahmin performansı karşılaştırılmıştır. Bu çalışmadaki veriler, Türkiye İstatistik Kurumu (TÜİK), Türkiye Cumhuriyeti Merkez Bankası (TCMB), Otomotiv Sanayi Derneği (OSD), Otomotiv Distribütörleri Derneği (ODD) ve Otomotiv Distribütörleri ve Mobilite Derneği (ODMD) derlenmiştir.

4.2. Veri Setinin Hazırlanması

Uygulamada kullanılmasına karar verilen ve otomobil talebi üzerine etkisi olduğu düşünülen bağımsız değişkenler şunlardır:

- Brent Petrol Fiyatı
- Dolar/TL Kuru
- Taşıt Kredi Faiz Oranları
- TÜFE
- Araç Satın Alım Düzeyi
- Otomobil Üretim Adedi (Türkiye’de otomobil üretip en çok satışı yapan 6 firmanın OYAK Renault, Tofaş, Toyota, Ford, Honda ve Hyundai)

Uygulamanın bağımlı değişkeni, yani hedeflenen değer ise Türkiye’de en çok otomobil üretimi yapan 6 firmanın,


- Toplam Otomobil Satış Adedi olarak belirlenmiştir.

Otomobil satışını etkileyen faktörlerin belirlenmesi aşamasında Sanayi ve Teknoloji Bakanlığının yıllık yayınlamış olduğu Otomotiv Sektör Raporlarına başvurulmuştur. Uygulamada kullanılan bu verilerin tamamı Türkiye Cumhuriyeti Merkez Bankasından alınan verilerden derlenmiş ve uygulamada kullanılmıştır.

Tahminlemede kullanılan giriş verileri 01.01.2014-31.12.2023 yılları arasında aylık bazda toplanmış Ek-1 2014-2023 Yılları Arasında Türkiye’de Üretim Yapan 6 Otomotiv Firmasının Aylık Otomobil Satışları ve Ek-2’de Uygulamada Kullanılan Girdi ve Çıktı verileri gösterilmiştir.

Brent Petrol Fiyatları: Petrol, dünya ekonomisinde temel bir role sahiptir ve neredeyse her sektörü doğrudan veya dolaylı olarak etkiler. Bu nedenle, petrol piyasasında yaşanan fiyat değişiklikleri, hem ülke ekonomileri hem de küresel ekonomi üzerinde önemli etkilere sahiptir.


Petrol, enerji üretiminden ulaşıma, endüstriyel üretime ve tarımsal faaliyetlere kadar birçok sektörde kullanılan temel bir kaynaktır. Petrol fiyatlarındaki artışlar, enerji maliyetlerini artırarak işletme maliyetlerini yükseltebilir ve tüketicilere yansıyan fiyat artışlarına neden olabilir. Bu da tüketici harcamalarını ve şirket karlılığını olumsuz etkileyebilir. Petrol fiyatlarındaki değişim otomotiv sektöründeki yeri dolayısıyla otomobil satışlarını da etkilemektedir.



Şekil 4. 1 2014-2023 Yılları Arasında Brent Petrol Fiyatının Aylık Değişimi

Yukarıda Şekil 4.1’de brent petrol fiyatının 2014- 2023 yılları arasındaki aylık değişimi yer almaktadır.


Dolar/TL Kuru: Bir Amerikan dolarının, Türk Lirası üzerinden değerini belirtir. Dünya genelinde en yaygın olarak kullanılan rezerv para birimidir ve uluslararası ticarete yaygın olarak kabul edilir. Ayrıca birçok ülkede resmi veya yarı-resmi para birimi olarak kullanılır. Otomobil yedek parçaları firmalara dolar üzerinden satışı yapılmaktadır. Bu yüzden dolar kurunun değişimi, otomobil satışını etkilemektedir.



Şekil 4. 2 2014- 2023 Yılları Dolar/TL Kurunun Aylık Değişimi

Yukarıda Şekil 4.2’de dolar kurunun 2014- 2023 yılları arasındaki aylık değişimi yer almaktadır.

Taşıt Kredi Faiz Oranları: Taşıt kredi faiz oranları ile otomobil satışları arasında güçlü bir ilişki vardır. Bu da doğrudan otomobil satışlarını etkilemektedir. Taşıt kredi faiz oranları, tüketicilerin otomobil satın almalarını etkileyen en önemli faktörlerden biridir. Daha yüksek faiz oranları, tüketicilerin kredi almak için daha fazla ödeme yapmalarını gerektirir ve bu da otomobil satışlarını azaltabilir. Düşük faiz oranları ise tüketicilerin krediye erişimini kolaylaştırır ve otomobil satışlarını artırabilir.




Şekil 4. 3 2014- 2023 Yılları Arasındaki Taşıt Aylık Taşıt Faiz Oranları

Yukarıda Şekil 4.3’te faiz oranının 2018- 2022 yılları arasındaki aylık değişimi yer almaktadır.

TÜFE: Tüketici Fiyat Endeksi, bir ülkedeki tipik bir tüketici sepetinin fiyat değişimini ölçen ve genellikle enflasyonun bir ölçütü olarak kullanılan bir ekonomik göstergedir. TÜFE, genellikle belirli bir dönemde belirli bir tüketici sepetinin fiyatlarını izleyerek


hesaplanır. Bu sepet, tipik olarak çeşitli mal ve hizmetlerin temsilcisi olarak seçilmiş ve tüketicilerin günlük yaşamlarında sıkça satın aldıkları ürünleri içerir. Örneğin, gıda, konut, ulaşım, sağlık hizmetleri, eğitim gibi kalemler TÜFE hesaplamalarında yer alabilir. Tüketici tarafından satın alınan mal ve hizmetlerin fiyatlarındaki değişimleri ölçen endekstir. Yılın her ayının belirli günlerinde mal ve hizmet fiyatlarındaki değişim, bu ağırlıklara ölçülerek o ayın tüketici enflasyon rakamına ulaşılmaktadır.



Şekil 4. 4 TÜFE'nin 2014-2023 Yılları Arasındaki Aylık Değişimi

Yukarıdaki Şekil 4.4'te TÜFE' nin 2014-2023 yılları arasındaki aylık değişimi yer almaktadır.


Araç Satın Alım Düzeyi: bir toplumda bireylerin araç satın alma eğilimini ifade eder. Bu terim genellikle araç satın alımıyla ilgili belirli bir dönemde gerçekleşen satın alma işlemlerini tanımlamak için kullanılır. Araç alım düzeyi, ekonomik koşullar, tüketici güveni, faiz oranları, gelir düzeyleri ve diğer faktörler gibi çeşitli etkenlere bağlı olarak değişebilir. Güçlü bir ekonomide, artan gelir seviyeleri ve düşük faiz oranları genellikle araç alım düzeyini artırırken, zayıf bir ekonomide tüketici güveni düşebilir ve araç alım düzeyi azalabilir.



Şekil 4. 5 2014-2023 Yılları Arası Aylık Araç Alım Düzeyi

Yukarıdaki Şekil 4.5'te Araç Satın Alım Düzeyinin 2014-2023 yılları arasındaki değişimi yer almaktadır.


Otomobil Üretim Âdeti: Türkiye’de otomobil üretip en çok satışı yapan 6 firmanın (OYAK Renault, Tofaş, Toyota, Ford, Honda ve Hyundai) 2014 ile 2023 yılları arasındaki aylık üretilen otomobil sayısını ifade eder. Otomobil üretim âdeti, otomotiv endüstrisinin performansını değerlendirmek için önemli bir göstergedir. Otomobil üretim âdetleri, bir ülkenin veya bir şirketin ekonomik büyüme, istihdam durumu ve endüstriyel faaliyetleri hakkında bilgi sağlar. Ayrıca, otomobil üretim âdetleri, tüketici talebi, pazar trendleri, rekabet ve endüstriyel kapasite kullanımı gibi faktörlerin bir yansımasıdır. Yüksek otomobil üretim âdetleri, genellikle güçlü bir tüketici talebini ve ekonomik büyümeyi yansıtırken, düşük üretim adetleri, zayıf talebi veya üretim kapasitesinin altında bir performansı gösterebilir.



Şekil 4. 6 2014-2023 Otomobil Üretim Âdetinin Aylık Değişimi

Yukarıdaki Şekil 4.6’da otomobil üretim adetinin 2014-2023 yılları arasındaki değişimi aylık bazda yer almaktadır.

Otomobil Satış Adeti: Türkiye’de otomobil üreten en çok satışı yapan 6 firmanın (OYAK Renault, Tofaş, Toyota, Ford, Honda ve Hyundai) 2014 ile 2023 yılları arasındaki aylık satılan otomobil sayısını ifade eder. Otomobil satış miktarı ne kadar çok olursa, firmanın karı da o oranda çok olacaktır. Otomobil satış adetleri, otomotiv endüstrisinin performansını değerlendirmek için önemli bir göstergedir. Bu adetler, bir ülkenin veya bir şirketin otomobil pazarındaki durumunu, tüketici talebini, pazar paylarını, rekabeti ve endüstriyel faaliyetleri gösterir.



Şekil 4. 7 2014-2023 Yılları Arasındaki Otomobil Satış Adetinin Aylık Değişimi

Yukarıda Şekil 4.7’de otomobil satış adetinin 2014-2023 yılları arasındaki aylık değişimi yer almaktadır.

4.3. Tahmin Modellerin Kurulması

Tahmin modellerin algoritmasının oluşturulabilmesi için Ek-2’de gösterilen gerçek veri setleri, model kurulmadan önce normalizasyon tekniği olarak en çok kullanılan aşağıdaki Formül 4.1 kullanılarak, Octave programında, tüm veriler Ek-3’de gösterildiği gibi [0, 1] arasında normalize edilmiş ve programa aktarılmıştır. (Söylemez, 2020).

x_i girdi değişkeni olmak üzere;

$$x'_i = \frac{x_i - \min(x_i)}{\max(x_i) - \min(x_i)} \quad (4.1)$$

4.3.1. ÇRA Modelinin Uygulaması

Çoklu regresyon bir adet bağımlı değişken ve birden fazla bağımsız değişkenin bir arada bulunduğu modeldir. (Ulgen, 2024). Bu analiz yöntemi bağımlı ve bağımsız değişkenlerin olduğu bir konu üzerinde sebep-sonuç ilişkisini belirleyerek matematiksel bir denklem türetir (Hocaoğlu, Kaysal, & Kaysal, 2015).

Çoklu regresyon analizinde (ÇRA), oluşturulan modeldeki bağımsız değişkenlerin her biri bağımlı değişkendeki değişimi anlamlandırmaya çalışır ve ÇRA modelinin matematiksel olarak gösterimi aşağıda Formül 4.2’de verilmiştir:

$$y_i = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_n x_n + \varepsilon \quad (4.2)$$

Bu formülde,

y_i = Bağımlı Değişkeni

β_0 = Sabit Katsayıyı

ε = Hata Terimini

x_n = Bağımsız Değişkenleri

$\beta_1, \beta_2, \dots, \beta_n$ = Değişken Katsayıları

ifade etmektedir.

Çoklu Regresyon Modelinin kurulmasında Octave programında “X=[Brentpetrol,DolarTL,Tasitfaiz,Satinalmaduzeyi,TUFE,Aracuretim];” komutuyla altı bağımsız değişken girdi X şeklinde oluşturuldu. Daha sonra “model=fitlm(X,Aracsatis)” komutuyla bağımlı değişken olan çıktı verisine çoklu regresyon modeli uygulandığında modelin vermiş olduğu katsayı değerleri aşağıda Tablo 4.1’de gösterilmiştir.

Tablo 4. 1 Çoklu Regresyon Analizi Modelinde Tahmin Edilen Katsayı Değerleri

	Estimate	SE (Standart Hata)	tStat	pValue
Intercept (Sabit Katsayı)	0,17893	0,074728	2,3944	0.018291
x1 (Brent Petrol)	-0,11951	0,087338	-1,3684	0.173791
x2 (Dolar/TL)	-0,79803	0,73114	-1,0915	0.27738
x3 (Taşıt Faiz Oranları)	-0,66625	0,12879	-5,1732	1,0072e-06
x4 (Araç Satın Alma Düzeyi)	1,5771	0,88702	1,778	0,078906
x5 (TÜFE)	-0,050961	0,72108	-0.070672	0,94378
x6 (Araç Üretim Adeti)	0,4697	0,086315	5,4417	3,1011e-07

Tablo 4.1’de elde edilen sonuçlar kapsamında oluşturulan ÇRA denklemi aşağıdaki gibidir.

$$Y=0,17893-0,11951*x_1-0,79803*x_2-0,66625*x_3+1,5771*x_4-0,050961*x_5+0.4697*x_6$$

Tablo 4.1’de gösterilen terimler, regresyon analizinin sonuçlarını değerlendirmek ve her bir bağımsız değişkenin bağımlı değişken üzerindeki etkisini anlamak için kullanılır. Bu terimlerden;

SE (Standard Error): Tahmin edilen katsayının standart hatasını ifade eder. Standart hata, tahmin edilen katsayının gerçek değerine olan tahmini uzaklığı ölçer. Standart hatalar, tahmin edilen katsayıların gerçek değerine olan tahmini uzaklıkları ölçer. Daha düşük standart hatalar, tahmin edilen katsayıların daha güvenilir olduğunu gösterir. Tablo 4.1 de verilen standart hata değerlerine baktığımızda

- x1 (Brent Petrol) ve x6 (Araç Üretim Adeti) değişkenleri en düşük standart hata değerlerine sahiptir, bu da tahminlerinin diğer değişkenlere göre daha güvenilir olduğunu gösterir.

tStat (t-Statistics): "t istatistiği" bir regresyon modelindeki katsayıların anlamlılığını değerlendirmek için kullanılan bir istatistiksel ölçüdür. Her bir bağımsız değişkenin katsayısı için bir t istatistiği hesaplanır. t-istatistiği, tahmin edilen katsayının sıfırdan farklı olup olmadığını değerlendirmek için kullanılır. Daha büyük bir t-istatistiği, tahmin edilen katsayının daha anlamlı olduğunu gösterir. Pozitif bir t istatistiği, ilgili katsayının bağımlı değişken üzerinde pozitif bir etkiye sahip olduğunu gösterirken, negatif bir t istatistiği, ilgili katsayının bağımlı değişken üzerinde negatif bir etkiye sahip olduğunu gösterir. Genellikle, t-statistik değeri mutlak değeri 1.96’dan büyükse (veya belirli bir güvenilirlik düzeyine göre belirlenen kritik değere göre), katsayının

istatistiksel olarak anlamlı olduğu kabul edilir. Tablo 4.1 de verilen t istatistiği değerlerine baktığımızda;

- x3 (Taşıt Faiz Oranları) ve x6 (Araç Üretim Adeti) değişkenlerinin t-İstatistik değerlerinin diğerlerine göre daha büyük olduğu görülüyor. Bu, bu değişkenlerin tahmini katsayılarının sıfıra olan uzaklığının standart hatalarla orantılı olarak daha büyük olduğunu ve dolayısıyla istatistiksel olarak daha anlamlı olduklarını gösterir.

pValue (p-değer): Bu, tahmin edilen katsayının istatistiksel olarak anlamlı olup olmadığını belirten bir p-değerini ifade eder. p-değeri, tahmin edilen katsayının sıfırdan farklı olma olasılığını ölçer. Düşük bir p-değeri (<0.05 genellikle kabul edilen bir eşik) tahmin edilen katsayının istatistiksel olarak anlamlı olduğunu gösterir ve bağımsız değişkenin bağımlı değişken üzerindeki etkisi kabul edilir. Genel olarak, daha küçük p-değerleri, ilgili katsayının istatistiksel olarak anlamlı olduğunu gösterirken, daha büyük p-değerleri katsayının istatistiksel olarak anlamlı olmadığını gösterir. Tablo 4.1 de verilen p-değerlerine baktığımızda;

- Taşıt Faiz Oranları (x3) ve Araç Üretim Adeti (x6) değişkenlerinin tahmini katsayıları istatistiksel olarak anlamlıdır çünkü bunların p-değerleri 0,05'ten küçüktür. x1: p-değeri 0.17376 Bu değer, genellikle kabul edilen alfa düzeyi olan 0.05'ten büyüktür. Bu nedenle, x1 katsayısının istatistiksel olarak anlamlı olmadığı kabul edilir.

Çoklu Regresyon Modelinin vermiş olduğu çıktılar aşağıda çizelge halinde Tablo 4.2'de gösterilmiştir. Aynı zamanda bu istatistiksel veriler modelin uyumunu, tahmin gücünü ve performansını değerlendirmek için kullanılmaktadır.

Tablo 4. 2 Çoklu Regresyon Analizi Modelinde Tahmin Edilen Katsayı Değerleri

Ölçüt Adı	Değer
Number of observations (Gözlem Sayısı)	120
Error degrees of freedom (Hata Serbestlik Derecesi)	113
Root Mean Squared Error (RMSE, Kök Ortalama Kare Hatası)	0.0775
R-squared (R-kare)	0.406
Adjusted R-Squared (Düzeltilmiş R-kare)	0.374
F-statistic (F-istatistiği) vs. constant model	12.9
P-value (p-değeri)	4.98e-11

Bu ölçütlerin anlamları aşağıda verilmiştir.

Number of observations (Gözlem Sayısı): Modelin oluşturulduğu veri setindeki toplam gözlem sayısıdır. Bu durumda, 120 gözlem bulunmaktadır.

Error degrees of freedom (Hata Serbestlik Derecesi): Modelin serbestlik derecesi, tahmini katsayıların sayısından (genellikle 1 artı bağımsız değişken sayısı) toplam gözlem sayısının çıkarılmasıyla elde edilir. Bu durumda, hata serbestlik derecesi 113'tür.

Root Mean Squared Error (RMSE, Kök Ortalama Kare Hatası): Gerçek değerler ile model tarafından yapılan tahminler arasındaki ortalama kare farkın kareköküdür. Bu, modelin tahminlerinin ne kadar doğru olduğunu ölçer. Düşük bir RMSE değeri, daha iyi bir model uyumunu gösterir. Bu model için RMSE değeri 0.0775'dir.

R-squared (R-kare): Bağımsız değişkenlerin bağımlı değişken üzerindeki varyansın yüzde kaçını açıkladığını ifade eder. R-kare değeri 0 ile 1 arasında değişir. 1'e daha yakın bir değer, modelin veri setindeki varyansın daha fazlasını açıkladığını gösterir. Bu durumda, R-kare değeri 0.406'dır, yani modelin bağımlı değişkendeki varyansın %40.6'sını açıkladığı söylenebilir.

Adjusted R-Squared (Düzeltilmiş R-kare): Birden fazla bağımsız değişken olduğunda R-kare değerinin düzeltilmiş versiyonudur. Düzeltilmiş R-kare, modeldeki her bir eklenen bağımsız değişkenin tahmin gücünü dengelemek için kullanılır. Bu durumda, düzeltilmiş R-kare değeri 0.374'tür.

F-statistic (F-istatistiği) vs. constant model: Modelin genel istatistiksel anlamlılığını değerlendirmek için kullanılan bir istatistik değeridir. Bu, modelin belirli bir yükseklikte anlamlı bir şekilde iyileşip iyileşmediğini belirler. Daha yüksek bir F-istatistiği, modelin veri setine daha iyi uyduğunu gösterir. Bu değer, constant modelin kullanıldığı bir regresyonun, bağımlı değişkeni tahmin etme konusunda anlamlı bir iyileşme sağladığını gösterir. Ancak, F-istatistiğinin tek başına değeri biraz anlamsızdır; çünkü bu değeri değerlendirmek için bir p-değeri (anlamlılık düzeyi) de gereklidir. Bu nedenle, p-değeri F-istatistiği ile birlikte değerlendirilmelidir. Bu durumda, F-istatistiği 12.9'dur ve p-değeri (0.0000000000498) $4.98e-11$ 'dir, yani modelin genel olarak istatistiksel olarak anlamlı olduğunu gösterir.


Octave programında “yfit=trainedModel.predictFcn(X)” komutuyla Regresyon modelinin tahmin ettiği sonuçlar excele aktarılmış ve excel uygulamasında modelin bulmuş olduğu tahmin değerleri, gerçek değerler ve modelin performansını değerlendirmek için kullanılan veriler Ek-4'te gösterilmiştir.

Ek-4'teki verilere, excelde Tablo 3.2'de verilen YSA Performans Ölçüt formülleri uygulandığında Çoklu Regresyon Modelinin Performans Değerleri aşağıda Tablo 4.3'de gösterildiği gibi olmaktadır.

Tablo 4. 3 Çoklu Regresyon Analizi Modelini Değerlendirmek İçin Kullanılan Performans Ölçütleri


Performans Ölçütü	Değer
Ortalama Mutlak Sapma (The Mean Absolute Deviation- MAD)	0,241060164
Hata Kareler Ortalaması (Mean Squared Error-MSE)	0,077545135
Hata Kareler Toplamı (Sum Squared Error-SSE)	9,305416162
Kök Ortalama Kare Hata (Root Mean Squared Error-RMSE)	0,278469271195225
Ortalama Mutlak Hata Yüzdesi (Mean Absolute Percentage Error-MAPE)	%13,91

Bu ölçütler, ÇRA modelinin tahmin yeteneğini ve doğruluğunu değerlendirmek için kullanılır. Daha düşük MAD, MSE, SSE, RMSE ve MAPE değerleri, modelin daha iyi performans gösterdiğini gösterir. Bu ölçütler daha sonra diğer modellerin analiz sonuçlarıyla birlikte değerlendirilecektir.




Şekil 4. 8 ÇRA Tahmin Değerleri ve Gerçek Değerlerin Karşılaştırma Grafiği

Çoklu Regresyon Analizi tahmin değerleri ile gerçek tahmin değerlerinin karşılaştırmasının yapıldığı grafik, yukarıda Şekil 4.8’de gösterilmiştir.



Şekil 4. 9 ÇRA Tahmin Değerleri ve Gerçek Değerlerin Hata Paylarını Gösteren Grafik

Yukarıdaki Şekil 4.9’da tahmin değerleri ile gerçek değerler arasındaki hata miktarlarını gösteren grafik bulunmaktadır. Mavi noktalar gerçek değerleri, sarı noktalar tahmin değerlerini ve düz çizgi de hata miktarını göstermektedir.



Şekil 4. 10 ÇRA Tahmin Değerleri ve Gerçek Değerlerin Karşılaştırılması

Şekil 4.10'da çizgi üzerinde yer alan noktalar iyi bir tahmin yapıldığını gösterir. Doğrunun herhangi bir noktaya olan dikey uzaklığı, o nokta için yapılan tahminin hatasıdır. İyi bir modelin küçük hataları vardır ve tahminler çizgiye yakın dağılır.

4.3.2. NARX Modeline Dayalı Uygulama

NARX (Nonlinear AutoRegressive with eXogenous inputs), yapay sinir ağları kullanılarak zaman serisi tahmininde yaygın olarak kullanılan bir modeldir. NARX modeli, geçmiş değerlere dayalı otoregresif (AR) bileşenlerinin yanı sıra dışsal veya exogenous değişkenleri de girdi olarak alabilir. Örneğin, bir NARX modeli, geçmiş dolar fiyatlarının yanı sıra faiz oranları veya ekonomik göstergeler gibi dışsal faktörleri de kullanabilir.


NARX modeli, tipik olarak birkaç katman içeren bir yapay sinir ağı yapısı kullanır. Bu katmanlar arasında giriş (input) katmanı, gizli (hidden) katmanlar ve çıkış (output) katmanı bulunur. Model, girdi katmanından başlayarak gizli katmanlardan geçer ve çıkış katmanında tahminler üretir.

NARX modeli, birçok zaman serisi probleminde kullanılabilir. Örneğin, finansal veri analizi, endüstriyel süreç kontrolü, hava tahmini gibi alanlarda yaygın olarak kullanılır. NARX modelinin temel avantajlarından biri, otoregresif modelleme ve

dışsal değişkenlerin etkisini bir araya getirerek daha kapsamlı bir tahmin yeteneği sağlamasıdır.

NARX modeliyle tahmin için Octave programı kullanılmıştır. NARX Ağ Mimarisinde, altı adet girdi ve bir adet çıktı değişkeni bulunmaktadır. Girdi katmanında, ağa sunulan altı bağımsız değişkene ait altı adet girdi işlemci elemanı, çıktı katmanında ise bağımsız değişkene ait bir adet çıktı işlemci elemanı bulunmaktadır. Ara katmandaki gizli işlemci eleman sayısı, modelin kurulumu sırasında, sistemin oluşturduğu ağlardan uygunluk değeri en iyi olan ağdaki katman sayısı kadardır. Çalışma sonucunda 10 nöron sayısına sahip olan ağ uygun bulunmuştur. Bu sayının belirlenmesi için çeşitli işlemci eleman sayıları ile yapılan denemeler sonucunda açıklayıcılığı yüksek olan bu sayıda karar kılınmıştır.


Bu ağ ayrıca $x(t)$ ve $y(t)$ dizilerinin önceki değerlerini depolamak için bağlantılandırılmış gecikme hatlarını kullanır. $y(t)$, $y(t - 1)$, $y(t - 2)$ 'nin bir fonksiyonu olduğundan, NARX ağının çıkışının ($y(t)$) ağın girişine (gecikmeler yoluyla) geri beslendiği görülmektedir. NARX ağ yapısı genellikle geri beslemeli (feedback) bir yapıya sahiptir. Bu, ağın önceki zaman adımlarındaki çıktıları geri besleyerek tahminlerde bulunmasına olanak tanır. Bu geri besleme mekanizması, modelin daha karmaşık ve dinamik zaman serilerini tahmin etme yeteneğini artırır. Geliştirilen yapay sinir ağında iteratif tahmin yöntemi benimsendiğinden çıktı nöron sayısı birdir.



Şekil 4. 11 NARX Ağ Modelinin Yapısını Gösteren Ekran


Şekil 4.11’de NARX Ağ Yapısı, gizli katmanda sigmoid transfer fonksiyonu ve çıkış katmanında doğrusal transfer fonksiyonu bulunan iki katmanlı bir ağıdır. Ağ yapısı, 6 girdi, 10 gizli nöron ve 1 çıktıdan oluşmaktadır.

Ağın eğitimi için Levenberg-Marquardt algoritması kullanılmıştır. Programa tanıtılan veri setinin %70’i (84 veri) ağın eğitilmesi için eğitim seti olarak, %15’i (18 veri) uygun yapay sinir ağı mimarisini belirlemek amacıyla doğrulama seti olarak ve %15’i (18 veri) de ağın performansını ölçmek amacıyla test seti için program tarafından rastgele seçilmiştir.




Şekil 4. 12 NARX Modelinde Hata Otokorelasyonunu Gösteren Grafik

Yukarıdaki Şekil 4.12’deki grafik hata otokorelasyonunu göstermektedir. Grafik tahmin hatalarının zamanla nasıl ilişkili olduğunu açıklar. Bu durumda, sıfır gecikmedeki korelasyon dışındaki korelasyonlar, sıfır civarında yaklaşık %95 güven sınırları dahilinde kaldığından model yeterli görünmektedir.




Şekil 4. 13 NARX Modelinde Girdi-Hata Çapraz Korelasyonunu Gösteren Grafik

Yukarıdaki şekil 4.13’de girdi-hata çapraz korelasyon grafiği, hataların girdi dizisi $x(t)$ ile nasıl ilişkilendirildiğini gösterir. Mükemmel bir tahmin modeli için tüm korelasyonların sıfır olması gerekir.



Şekil 4. 14 NARX Modelinde Eğitim, Doğrulama ve Test Çıktıların Yanıtını Gösteren Grafik


Yukarıdaki şekil 4.14'deki grafik, girdileri, hedefleri ve hataları zamana göre görüntüler. Ayrıca eğitim, test ve doğrulama için hangi zaman noktalarının seçildiğini de gösterir.



Şekil 4. 15 NARX Modelinde Hata Histogramını Gösteren Grafik


Yukarıda Şekil 4.15'deki grafik, modelin eğitim, doğrulama ve test tahmin hatalarının dağılımını göstermektedir. Grafikte mavi çubuklar eğitim verilerini, yeşil çubuklar doğrulama verilerini ve kırmızı çubuklar test verilerini temsil eder. Test

verilerinde olan aykırı değer sayısı en fazla iken eğitim verilerinde en azdır. Bu nedenle modelin, eğitim verilerinde daha doğru tahmin yaptığını söyleyebiliriz. Hata histogramı, modelin performansını değerlendirmek için önemli bir araçtır. Ancak, yalnızca hata histogramına dayanarak bir modelin kalitesini tam olarak değerlendirmek genellikle yeterli değildir. Diğer performans ölçütleri ve model doğrulama teknikleri de dikkate alınmalıdır.



Şekil 4. 16 NARX Modelinde Doğrulama Performansını Gösteren Ekran

Yukarıdaki Şekil 4.16'da görüldüğü gibi test seti hatası ve doğrulama seti hatası benzer özelliklere sahiptir. Herhangi bir aşırı uyumun meydana geldiği görülmemektedir. Epoch (Yineleme) 6'da (en iyi doğrulama performansının gerçekleştiği yerde) önemli bir aşırı uyum meydana gelmemiştir.



Şekil 4. 17 NARX Modelinde Eğitim, Doğrulama ve Test Verileri İçin Regresyon Grafikleri

Yukarıdaki Şekil 4.17’de regresyon grafikleri eğitim, doğrulama ve test kümelerine ilişkin hedeflere göre ağ çıktılarını gösterir. Mükemmel bir uyum için verilerin, ağ çıktılarının hedeflere eşit olduğu 45 derecelik bir çizgi boyunca düşmesi gerekir. Bu modelde, eğitim seti için uyum kabul edilebilir. Ancak test ve doğrulama seti için ağ çıktıları hedefleri iyi takip etmiyor ve toplam yanıt için R değeri 0,72873’dur.


NARX modelinin tahmin ettiği sonuçlar excele aktarılmış ve excel uygulamasında modelin bulmuş olduğu tahmin değerleri, gerçek değerler ve modelin performansını değerlendirmek için kullanılan veriler Ek-5’te gösterilmiştir.

Ek-5’teki verilere, excelde Tablo 3.2’de verilen YSA Performans Ölçüt formülleri uygulandığında NARX Modelinin Performans Değerleri aşağıda Tablo 4.4’te gösterildiği gibi olmaktadır.

Tablo 4. 4 NARX Modelini Değerlendirmek İçin Kullanılan Performans Ölçütlerinin Değerleri

Performans Ölçütü	Değer
Ortalama Mutlak Sapma (The Mean Absolute Deviation- MAD)	0,192511339
Hata Kareler Ortalaması (Mean Squared Error-MSE)	0,065403124
Hata Kareler Toplamı (Sum Squared Error-SSE)	7,84837488
Kök Ortalama Kare Hata (Root Mean Squared Error-RMSE)	0,255740344881288
Ortalama Mutlak Hata Yüzdesi (Mean Absolute Percentage Error-MAPE)	%12.23

Bu ölçütler, NARX modelinin tahmin yeteneğini ve doğruluğunu değerlendirmek için kullanılır. Daha düşük MAD, MSE, SSE, RMSE ve MAPE değerleri, modelin daha iyi performans gösterdiğini gösterir. Bu ölçütler daha sonra diğer modellerin analiz sonuçlarıyla birlikte değerlendirilecektir.



Şekil 4. 18 NARX Tahmin Değerleri ve Gerçek Değerlerin Karşılaştırma Grafiği

NARX modeli tahmin değerleri ile gerçek değerlerin karşılaştırmasının yapıldığı grafik, yukarıda Şekil 4.18’de gösterilmiştir.


4.3.3.YSA Modelinin Uygulaması

Uygulamada kullanılan yapay sinir ağı modeli, yapay sinir ağlarında en çok kullanılan ileri beslemeli geri yayılmalı ağıdır. İleri beslemeli geri yayılmalı ağıın kullanılmasının sebebi ise, hem tahmin çalışmalarında en çok kullanılan model olması hem de doğrusal veya doğrusal olmayan modellerdeki tahmin başarısıdır. Bunun yanında kullanım kolaylığı bu ağ modelinin seçilmesinde etkili olmuştur.

Tasarlanan modelde, bağımlı değişken olarak, 6 farklı firmanın aylık Otomobil Satış Adeti Ek-1'deki verilerden alınmıştır. Bağımsız değişken olarak, Brent Petrol Fiyatı, Dolar Kuru, Taşıt Kredi Faizleri, TÜFE, Araç Alım Düzeyi ve Otomobil Üretim Adeti Ek-2'deki verilerden alınmıştır.

Yapay sinir ağı algoritmasının oluşturulabilmesi için Ek-3'de normalize edilmiş verilerden Ocak 2014-Aralık 2022 arası veriler eğitim amaçlı kullanılmıştır. Ocak 2023-Aralık 2023 arası verileri ise test amacı ile kullanılmıştır.


Yapay sinir ağları ile talep tahmin modeli Octave programı kullanılarak kurulmuştur.



Şekil 4. 19 YSA Modelinin Ağ Yapısını Gösteren Ekran Görüntüsü


Şekil 4.19'da YSA'nın fonksiyon uyumu için kullanılan standart ağ, gizli katmanda sigmoid transfer fonksiyonu ve çıkış katmanında doğrusal transfer fonksiyonu bulunan iki katmanlı ileri beslemeli bir ağıdır. Ağ yapısı, 6 girdi, 10 gizli nöron ve 1 çıktıdan oluşmaktadır.

Bu kısımda ağın eğitimi için yapay sinir ağları gibi modellerin eğitimi için yaygın olarak kullanılan Levenberg-Marquardt algoritması kullanılmıştır. Programa tanıtılan veri setinin %70'i (84 veri) ağın eğitilmesi için eğitim seti olarak, %15'i (18 veri) uygun ağ mimarisini belirlemek amacıyla doğrulama seti olarak ve %15'i (18 veri) de ağın performansını ölçmek amacıyla test seti için program tarafından rastgele seçilmiştir.




Şekil 4. 20 YSA Modelinde Eğitim, Doğrulama ve Test Verileri İçin Regresyon Grafikleri

Yukarıdaki şekil 4.20’de regresyon grafikleri eğitim, doğrulama ve test kümelerine ilişkin hedeflere göre ağ çıktılarını gösterir. Mükemmel bir uyum için verilerin, ağ çıktılarının hedeflere eşit olduğu 45 derecelik bir çizgi boyunca düşmesi gerekir. Bu modelde, en iyi uyum eğitim setindedir ve toplam yanıt için R değeri 0,74289’dur.



Şekil 4. 21 YSA Modelinde Hata Histogramını Gösteren Grafik

Yukarıda Şekil 4.21'deki grafik, modelin eğitim, doğrulama ve test tahmin hatalarının dağılımını göstermektedir. Grafikte mavi çubuklar eğitim verilerini, yeşil çubuklar doğrulama verilerini ve kırmızı çubuklar test verilerini temsil eder. Test verilerinde olan aykırı değer sayısı en fazla iken eğitim verilerinde en azdır. Bu nedenle modelin, eğitim verilerinde daha doğru tahmin yaptığını söyleyebiliriz. Hata histogramı, modelin performansını değerlendirmek için önemli bir araçtır. Ancak, yalnızca hata histogramına dayanarak bir modelin kalitesini tam olarak değerlendirmek genellikle yeterli değildir. Diğer performans ölçütleri ve model doğrulama teknikleri de dikkate alınmalıdır.



Şekil 4. 22 YSA Modelinde Doğrulama Performansını Gösteren Ekran

Yukarıdaki Şekil 4.22’de görüldüğü gibi test seti hatası ve doğrulama seti hatası benzer özelliklere sahiptir. Herhangi bir aşırı uyumun meydana geldiği görülmektedir. Epoch (Yineleme) 4’te (en iyi doğrulama performansının gerçekleştiği yerde) önemli bir aşırı uyum meydana gelmemiştir.


YSA modelinin tahmin ettiği sonuçlar excele aktarılmış ve excel uygulamasında modelin bulmuş olduğu tahmin değerleri, gerçek değerler ve modelin performansını değerlendirmek için kullanılan veriler Ek-6’da gösterilmiştir.

Ek-6’daki verilere, excelde Tablo 3.2’de verilen YSA Performans Ölçüt formülleri uygulandığında YSA Modelinin Performans Değerleri aşağıda Tablo 4.5’de gösterildiği gibi olmaktadır.

Tablo 4. 5 YSA Modelini Değerlendirmek İçin Kullanılan Performans Ölçütlerinin Değerleri

Performans Ölçütü	Değer
Ortalama Mutlak Sapma (The Mean Absolute Deviation- MAD)	0,103402289
Hata Kareler Ortalaması (Mean Squared Error-MSE)	0,021041056
Hata Kareler Toplamı (Sum Squared Error-SSE)	2,524926772
Kök Ortalama Kare Hata (Root Mean Squared Error-RMSE)	0,1450553544951136
Ortalama Mutlak Hata Yüzdesi (Mean Absolute Percentage Error-MAPE)	%11,66

Bu ölçütler, YSA modelinin tahmin yeteneğini ve doğruluğunu değerlendirmek için kullanılır. Daha düşük MAD, MSE, SSE, RMSE ve MAPE değerleri, modelin daha iyi performans gösterdiğini gösterir. Bu ölçütler daha sonra diğer modellerin analiz sonuçlarıyla birlikte değerlendirilecektir.



Şekil 4. 23 YSA Tahmin Değerleri ve Gerçek Değerlerin Karşılaştırma Grafiği

YSA modeli tahmin değerleri ile gerçek değerlerin karşılaştırmasının yapıldığı grafik, yukarıda Şekil 4.23’de gösterilmiştir.

4.4. CRA, NARX ve YSA Modellerin Karşılaştırılması

Çalışmanın bu kısmında, gerçekleşen talepler ile Çoklu Regresyon Analizi, NARX ve YSA modeliyle yapılan talep tahmin yöntemleriyle karşılaştırılarak performansları değerlendirilmiştir.

Çalışmada Tablo 3.2’de verilen doğruluk ölçütleri kullanılmıştır. Yapay Sinir Ağları ve diğer modellerin performans değerlendirmelerinde kullanılan temel performans göstergeleri arasında R^2 , MSE, RMSE ve MAPE sayılabilir (Karasu, Hacıoğlu, & Altan, 2018). Bu performans ölçüleri içerisinde R^2 , modelin doğruluk oranı karar verme katsayısıdır. Bu katsayı değerinin yüksek olması tahmin ilişkisinin iyi olduğu gösterir. MSE, RMSE ve MAPE ise birer hata ölçüsü olması nedeniyle düşük sonuçlar, yüksek performansı gösteren ölçülerdir (Wang & Xu, 2004) .

Çoklu Regresyon Analizi Modelini Değerlendirmek İçin Kullanılan Performans verileri Tablo 4.3’te, NARX Modelini Değerlendirmek İçin Kullanılan Performans verileri Tablo 4.4’te ve YSA Modelini Değerlendirmek İçin Kullanılan Performans verileri Tablo 4.5’te gösterilmiştir. Sonuç olarak, performans verilerini karşılaştırmak için aşağıdaki Tablo 4.6 oluşturulmuştur.

Tablo 4. 6 Tahmin Modellerinin Karşılaştırmalı Performans Verileri

Tahmin Yöntemi	Korelasyon	MSE	RMSE	MAPE
ÇRA	0,64	0,0775	0,278	%13,91
NARX	0,72	0,0654	0,255	%12,23
YSA	0,75	0,0210	0,145	%11,66

Yukarıdaki Tablo 4.6’da ÇRA, NARX ve YSA modellerinin performansını karşılaştırıldığı bir sonuç tablosu gösterilmektedir. Buna göre,

- YSA yöntemi en yüksek korelasyona sahiptir. Yüksek korelasyon, modelin gerçek verilere daha iyi uyum sağladığını, bağımsız değişkenler ile bağımlı değişken arasındaki ilişkinin daha güçlü olduğunu işaret edebilir.
- YSA modelinin en düşük MSE'ye sahip olduğu görülüyor, bu da modelin tahmin değerlerinin gerçek değerlere daha yakın olduğunu gösterebilir.
- YSA modelinin en düşük RMSE'ye sahip olduğu görülüyor, yani tahminlerinin gerçek değerlere daha yakın olduğu anlamına gelir.
- Lewis (1982) yılında yazdığı eserinde MAPE değerinin diğer ölçümlerden daha etkin sonuçlar verdiğini ve belirli değerler arasındaki MAPE değerlerinin değişimi açıklamakta yeterli olduğunu söylemiştir. Lewis'e göre MAPE değeri %10'dan küçük ise model yüksek doğruluğa sahip (çok iyi tahmin edici), değer %10 ile %20 aralığında ise orta derecede doğruluğa sahip (iyi tahmin edici), %20 ile %50 aralığında ise düşük derecede doğruluğa sahip ancak kabul edilebilir. %50'nin üzerinde ise tahmin değeri yok (kötü tahmin edici) olarak sıralanabilir. YSA modeli, MAPE açısından en düşük değere sahiptir, yani tahminlerinin gerçek değerlere oranla daha az hata içerdiği anlamına gelir.

Sonuç olarak, bu değerlerin incelenmesi, YSA modelinin genel olarak en iyi performansı sergilediğini göstermektedir. Yüksek korelasyon, düşük MSE, RMSE ve MAPE değerleri, YSA'nın tahmin performansının diğer yöntemlere göre daha iyi olduğunu göstermektedir..

Tablo 4.6’daki hata değerlerine göre, YSA modelinin, diğer modellerden daha az tahmin hatası yaptığı ifade edilebilir. Tablodaki veriler karşılaştırmalı olarak incelendiğinde, otomobil satış talep tahminini yapmak üzere tasarlanan yapay sinir ağı modelinin tahmin performansı, diğer talep tahmin modellerine göre daha yüksek

olduđuna ve yapay sinir ađı modeli tarafından yapılan tahminlerin daha geerli ve gvenilir olduđu grlmektedir.

4.5. YSA Modelinin 12 Aylık Tahmin Deđerleri

En iyi performans gsteren yapay sinir ađları modelinin 2014 ile 2024 yılları arasındaki aylık otomobil satış verileri temel alınarak, gelecekte gerekleşmesi beklenen Ocak 2024 ile Aralık 2024 arasındaki 12 aylık satış tahmini ařađıda Tablo 4.7’de gsterilmiřtir.

Tablo 4. 7 YSA Modeliyle Yapılan 12 Aylık Otomobil Satış Tahmin Verileri

	FİRMALAR							
Tarih	1-Fiat	2-Ford	3-Honda	4-Hyundai	5-Renault	6-Toyota	Toplam	YSA Tahmin Sonuçları
Oca.24	7611	3078	842	3829	8873	4590	28823	23657
řub.24	7468	1951	2130	4368	11468	5565	32950	20623
Mar.24	8813	3284	2964	4762	11683	4182	35688	34406
Nis.24	6083	1872	1331	4151	5550	2294	21281	20763
May.24	4510	2571	3110	4647	9714	3241	27793	35321
Haz.24	9046	2518	3170	4683	9672	4513	33602	31352
Tem.24								28203
Ađu.24								22566
Eyl.24								31991
Eki.24								35284
Kas.24								37577
Ara.24								42146

Bu tablo, Fiat, Ford, Honda, Hyundai, Renault ve Toyota otomobil firmalarının Otomotiv Distribtrleri ve Mobilite Derneđinden alınan 2024 yılı Haziran aynaya kadar gerekleşen aylık satış adetlerini gstermektedir. Ayrıca, yapay sinir ađı modeli kullanılarak yapılan tahmin sonuçları da verilmiřtir.

Yapay sinir ađı modeli kullanılarak yapılan tahminler, gerekleşen satış adetleriyle karřılařtırılmıřtır. Tahminlerin genellikle gerek verilerle uyumlu olduđu grlmektedir. zellikle Mart, Nisan ve Haziran aylarında gerekleşen toplam satış adeti YSA tahmin deđerleriyle belirgin bir řekilde uyumlu olduđu gzlenmektedir.

5. SONUÇ VE ÖNERİLER

Bu bölümde, çalışma bulguları daha geniş bir perspektifte tartışılacak ve Türkiye ile diğer ülkelerde yapılan otomobil talep tahmin çalışmalarına dayalı öneriler geliştirilecektir. Ayrıca, literatürde yer alan otomobil talep tahmin çalışmalarına ve kullanılan değişkenlere dair genişletilmiş bir inceleme sunulacaktır.

1. Yapay sinir ağları, veri madenciliği ve tahmin modellemesinde devrim niteliğinde bir araç haline gelmiştir. Özellikle karmaşık ve doğrusal olmayan ilişkileri çözme yeteneği, YSA'nın doğruluğunu artırmaktadır. Bu çalışmada, yapay sinir ağları (YSA) ile otomobil talep tahmini üzerine kapsamlı bir model geliştirilmiştir. Model, 2014-2024 yılları arasındaki verileri kullanarak, Türkiye'de otomobil talebini etkileyen makroekonomik ve sektörel faktörleri analiz etmiştir. Brent Petrol Fiyatı, Dolar Kuru, Taşıt Kredi Faizleri, TÜFE gibi ekonomik göstergelerin yanında, Araç Alım Düzeyi ve Otomobil Üretim Adeti gibi sektörel verilerin de kullanıldığı bu model, tahmin başarısının yüksek olmasını sağlamıştır. Geliştirilen modelde, ileri beslemeli geri yayılım ağları tercih edilmiş, bu modelin otomobil talep tahminindeki başarısı diğer geleneksel yöntemlerle (ÇRA ve NARX) karşılaştırılmıştır. Modelin performansı, test sonuçlarına göre oldukça tatmin edici bulunmuştur (MSE=0.0210, RMSE=0.144, MAPE=%11.66). Bu sonuçlar, YSA'nın diğer yöntemlerle (ÇRA ve NARX) karşılaştırıldığında daha doğru tahminler sağladığını ortaya koymaktadır. Sonuçlar, YSA'nın bu tür karmaşık süreçlerde daha yüksek performans sergilediğini göstermektedir.

2. YSA'nın kullanıldığı bu çalışmada, otomobil satışlarını etkileyen Brent Petrol Fiyatı, Dolar Kuru, Taşıt Kredi Faizleri, TÜFE, Araç Alım Düzeyi ve Otomobil Üretim Adedi gibi değişkenler etkili bir şekilde modellenmiştir.

Kullanılan Değişkenler

- **Petrol Fiyatları:** Yakıt fiyatlarındaki değişiklikler, tüketicilerin otomobil satın alma kararlarını doğrudan etkileyen en önemli faktörlerden biridir. Yüksek petrol fiyatları, talebi azaltabilirken düşük fiyatlar talebi artırabilir.
- **Dolar Kuru:** Özellikle ithal araçlar üzerindeki etkisi büyüktür. Dolar/TL kuru gibi döviz kurları, ithalat maliyetlerini etkilediğinden tüketici fiyatlarını doğrudan etkiler.

- **Faiz Oranları:** Kredi faiz oranları, tüketicilerin otomobil kredisi alma ve ödeme güçlerini etkiler. Bu nedenle, faiz oranlarının düşük olduğu dönemlerde talep artarken, yüksek faiz oranları dönemlerinde otomobil satışları azalır.
- **Enflasyon (TÜFE):** Tüketici fiyat endeksi gibi göstergeler, tüketici güvenini ve harcama alışkanlıklarını etkiler. Yüksek enflasyon dönemlerinde tüketiciler otomobil gibi büyük harcamaları erteleyebilir.
- **Araç Alım Düzeyi:** Araç alım düzeyi, bir ekonomide bireylerin ve firmaların belirli bir dönemde satın aldıkları otomobil sayısını ifade eder. Bu değişken, ekonomik refah, tüketici güveni ve ekonomik büyüme gibi makroekonomik göstergelerden etkilenir. Tüketicilerin harcanabilir gelir düzeyi yüksek olduğunda araç alımları artar, ekonomik durgunluk dönemlerinde ise bu alımlar azalabilir.
- **Otomobil Üretim Adeti:** Otomobil üretim adeti, üretici firmaların belirli bir dönemde ürettikleri araç sayısını ifade eder. Talep ile üretim arasında doğrudan bir ilişki vardır. Talebin yüksek olduğu dönemlerde üretim artabilir. Aynı şekilde, üretim kapasitesi ve arz da fiyatları ve tüketici davranışlarını etkileyebilir. Yetersiz üretim, talebe cevap veremediği için fiyatların yükselmesine ve talebin düşmesine yol açabilir.

Otomobil talebi üzerine yapılan diğer çalışmalarda da benzer değişkenler kullanılmıştır. Örneğin, Wang vd. (2017) tarafından yapılan bir çalışmada ABD otomobil pazarında petrol fiyatları, faiz oranları ve tüketici güven endeksi gibi makroekonomik değişkenler kullanılmıştır. Wang ve ekibi, ABD pazarında derin öğrenme (Deep Learning) ve YSA kullanarak otomobil talebini tahmin etmiştir. Değişkenler arasında akaryakıt fiyatları, faiz oranları, araç sigorta maliyetleri ve otomobil amortisman oranları kullanılmıştır. Çalışma, YSA'nın bu değişkenleri doğrusal olmayan yapılarla başarılı bir şekilde modelleyerek MAPE %7,2 elde ettiğini göstermiştir. Ayrıca, derin öğrenme modelleri de YSA ile benzer sonuçlar vermiştir. Wang'ın çalışması, derin öğrenme tekniklerini de dâhil ederek daha karmaşık modellerin nasıl kullanılabileceğini göstermektedir. Bu çalışmada ise ileri beslemeli geri yayılım ağı kullanılmıştır.

Durgut ve Çelik (2012) Çoklu Regresyon Analizi (ÇRA) kullanmışlardır. Değişkenler arasında döviz kuru, faiz oranları, TÜFE, otomobil fiyatları ve hane halkı gelir seviyesi yer almıştır. Çalışma, ÇRA'nın doğrusal varsayımlarına dayanarak sınırlı bir başarı elde etmiştir. MAPE değeri %15 civarında bulunmuş ve modelin doğrusal

olmayan ilişkileri modellemede yetersiz kaldığı belirtilmiştir. Bu çalışmada kullanılan değişkenler büyük ölçüde çalışmamızla benzerlik gösterse de, kullanılan ÇRA modeli doğrusal ilişkiler üzerine kurulduğu için daha yüksek hata oranları ile sonuçlanmıştır. Çalışmamızda YSA ile doğrusal olmayan ilişkiler daha başarılı bir şekilde modellenmiştir ve MAPE değeri %11,66 olarak daha düşük çıkmıştır.

Yurdakul ve İç (2005), Türkiye’de otomobil talebini tahmin etmek için VAR (Vektör Otoregresyon) modelini kullanmışlardır. Değişkenler arasında faiz oranları, döviz kuru, otomobil fiyatları ve ekonomik büyüme bulunmaktadır. Modelin performansı, özellikle uzun vadeli tahminlerde düşük kalmıştır ve MSE değeri 0.035 olarak bulunmuştur. Yurdakul ve İç’in (2005) çalışmasında kullanılan değişkenler, çalışmamızdaki döviz kuru ve faiz oranları ile benzerlik göstermektedir. Ancak, VAR modeli doğrusal ilişkiler üzerine kurulu olduğu için tahmin başarısı daha sınırlı kalmıştır. Çalışmamızda kullanılan YSA modeli, doğrusal olmayan ilişkilerde daha başarılı sonuçlar verdiği için tahmin başarısının yüksek olduğu görülmüştür. Yurdakul ve İç’in (2005) çalışmasında kullanılan değişkenler, çalışmamızdaki döviz kuru ve faiz oranları ile benzerlik göstermektedir. Ancak, VAR modeli doğrusal ilişkiler üzerine kurulu olduğu için tahmin başarısı daha sınırlı kalmıştır. Çalışmamızda kullanılan YSA modeli, doğrusal olmayan ilişkilerde daha başarılı sonuçlar verdiği için tahmin başarısının yüksek olduğu görülmüştür.

Li vd. (2018), Çin otomobil pazarında YSA ve makine öğrenmesi teknikleri kullanarak, petrol fiyatları, kişi başına düşen gelir, döviz kurları ve hammadde maliyetleri gibi değişkenlerin etkisini incelemiştir. Çin pazarında, petrol fiyatları ve ekonomik büyümenin otomobil talebi üzerindeki etkisi, doğrusal olmayan yöntemlerle başarılı bir şekilde tahmin edilmiştir. Çalışmamızda da benzer şekilde YSA kullanılmış ve model başarıyla çalıştırılmıştır. Li ve ekibinin çalışmasında kullanılan değişkenler ile çalışmamızdaki değişkenler oldukça benzerdir, özellikle petrol fiyatları ve makroekonomik göstergeler dikkate alınmıştır.

Gupta vd. (2019), Hindistan otomobil pazarında yaptıkları çalışmada, YSA ve ÇRA modellerini karşılaştırarak, YSA’nın daha iyi performans sergilediğini ortaya koymuştur. Kredi faiz oranları ve döviz kurlarının Hindistan’daki otomobil satışları üzerindeki etkisi, YSA kullanılarak daha doğru bir şekilde modellenmiştir. Bu

çalışmada kullanılan değişkenler arasında döviz kuru ve faiz oranları gibi değişkenler çalışmamızla örtüşmektedir. Gupta'nın (2019) çalışmasıyla benzer şekilde, YSA'nın daha iyi performans sergilediği görülmüştür. Ancak, çalışmamızda Türkiye'ye özgü olarak TÜFE ve otomobil üretim adeti değişkenleri kullanılmış, bu da Hindistan pazarındaki modellemeden farklılık yaratmaktadır.

3. Gelecekteki Araştırmalar İçin Öneriler:

a. Geniş Veri Setleri ile Daha Kapsamlı Modeller: Gelecekteki çalışmalar, daha geniş veri setleri ve daha uzun zaman dilimlerini içerecek şekilde genişletilmelidir. Ayrıca, tüketici tercihleri, sosyal medya verileri ve ekonomik belirsizlik endeksleri gibi yeni verilerin eklenmesi, modellerin doğruluğunu artırabilir.

b. Diğer Yapay Zeka Yöntemlerinin Entegrasyonu: YSA'nın yanı sıra, Derin Öğrenme ve Takviyeli Öğrenme gibi yeni tekniklerin de otomobil talep tahmininde kullanılması faydalı olacaktır. Özellikle, zaman serisi analizlerinde RNN (Recurrent Neural Networks) ve LSTM (Long Short-Term Memory) gibi metodlar, talep tahmin performansını artırabilir.

c. Yeni Faktörlerin Modellenmesi: Otomobil talebini etkileyen faktörler sürekli değişim göstermektedir. Çevresel faktörler, elektrikli araç teknolojileri, sürdürülebilirlik ve regülasyonlar, gelecekte otomobil talep tahmininde dikkate alınması gereken yeni değişkenler arasında yer alabilir.

Bu çalışma, YSA kullanarak otomobil talebinin doğru tahmin edilmesinin firmalara üretim ve stok planlamasında önemli avantajlar sağlayabileceğini göstermiştir. Gelecekteki çalışmalar, daha fazla veri ve daha gelişmiş yöntemlerle genişletilerek, otomobil talep tahminlerinin daha isabetli yapılması sağlanabilir. Yapay sinir ağlarının bu alandaki potansiyeli, ülkemiz bilim insanları tarafından daha fazla keşfedilmeli ve sektörle ilgili yenilikçi çözümler geliştirilebilmelidir.

4. Çalışmamız, YSA'nın otomobil talep tahmininde geleneksel yöntemlere kıyasla üstün olduğunu açıkça göstermektedir. Sektördeki makroekonomik değişkenlerin doğrusal olmayan etkileri göz önüne alındığında, YSA'nın talep tahmininde daha güvenilir sonuçlar sunduğu görülmektedir. Bu da firmaların daha etkili stratejiler geliştirmesine ve gelecekteki belirsizliklere daha iyi yanıt vermesine olanak tanımaktadır.

5. Yurt dışı çalışmaları da YSA'nın tahmin gücünü doğrulamaktadır. Özellikle gelişen pazarlarda, karmaşık makroekonomik ve sektörel dinamiklerin modellenmesi için YSA gibi doğrusal olmayan yöntemler ön plana çıkmaktadır. Yurt içindeki literatür, daha çok doğrusal modellerle sınırlı kalmıştır ve bu da tahminlerin doğruluğunu olumsuz etkilemiştir.

6. Çalışmamızın orijinalliğini değerlendirirken, otomobil talebi tahmininde hem geleneksel yöntemleri (Çoklu Regresyon Analizi) hem de modern yöntemleri (NARX ve Yapay Sinir Ağları) karşılaştırarak yenilikçi bir yaklaşım sunduğumuzu görüyoruz. NARX modelinin otomobil talebi tahmininde uygulanması, literatürde nadir bulunmakta ve ekonomik göstergeler ile piyasa dinamiklerini yansıtan bağımsız değişkenlerin Türkiye otomobil piyasasına özgü seçilmesi, çalışmamızı özgün kılmaktadır. 2014–2024 yılları arasındaki verilerle 2024 yılı için tahminlerde bulunmamız, çalışmamızın güncelliğini ve pratik değerini artırmaktadır. Ayrıca, çeşitli modellerin performanslarını MSE ve MAPE gibi istatistiksel kriterlerle değerlendirip karşılaştırmamız, metodolojik katkıyı güçlendirmektedir.

7. Bu çalışmanın büyük otomobil üreticilerine sağlayacağı potansiyel katkılar çok yönlüdür. Özellikle (YSA) kullanarak yapılan otomobil talep tahmini modeli, bu firmaların stratejik karar alma süreçlerine önemli katkılar sağlayabilir. Bu bölümde, büyük otomobil üreticileri için bu çalışmanın getireceği faydalar üç ana başlık altında detaylı olarak açıklanacaktır:

a. Üretim Planlaması ve Stok Yönetimi

Yapay sinir ağları ile geliştirilen bu model, otomobil üreticilerine doğru ve güvenilir talep tahmini sunarak üretim planlaması ve stok yönetimi süreçlerini optimize etme imkânı sağlar. Büyük ölçekli üreticiler için verimli üretim süreçleri, maliyetleri kontrol altına almak ve kâr marjını artırmak açısından kritik önem taşır. Bu bağlamda, otomobil talebinin doğru bir şekilde tahmin edilmesi aşağıdaki şekillerde katkı sağlar:

Talebe Göre Üretim Planlaması: Otomobil talebinin önceden tahmin edilmesi, üretim hatlarının taleple uyumlu bir şekilde planlanmasına olanak tanır. Büyük üreticiler, talebe göre üretimi ayarlayarak üretim fazlasını veya üretim açığını önleyebilir. Özellikle büyük otomobil firmaları, dünya çapında geniş bir üretim ağına

sahip olduklarından, talep tahminlerinin küresel düzeyde doğru yapılması, her fabrikada optimum üretim kapasitesini sağlamak için gereklidir.

Üretim Maliyetlerinin Düşürülmesi: Fazla üretim, şirketlerin stok maliyetlerini artırır ve satış hızı düşükse bu durum finansal riskler yaratır. Öte yandan, talep tahmini doğru yapılarak üretim planlandığında, üretim maliyetleri minimumda tutulabilir ve gereksiz stoklar önlenir.

Üretim Esnekliğinin Artırılması: Talep tahminleri, ani değişimlere yanıt vermede esneklik sağlar. Özellikle Toyota gibi Just-in-Time üretim sistemlerini benimseyen şirketler için talep tahminleri, üretimin her aşamasında tedarik zinciri ve üretim süreçlerini daha hassas bir şekilde yönetmeye yardımcı olur.

Stok Yönetiminin Optimizasyonu: Stok maliyetlerinin düşürülmesi, otomobil üreticileri için önemli bir stratejik avantajdır. Yapay sinir ağları kullanılarak yapılan talep tahminleri sayesinde, şirketler fazla stok bulundurmak zorunda kalmadan talebe dayalı bir stok yönetimi modeli geliştirebilirler.

- **Optimum Stok Seviyeleri:** Özellikle büyük üreticilerde, her yıl üretilen araçların bir kısmı satılmayıp stoklarda tutulur. YSA modeliyle tahmin edilen talep seviyelerine göre optimum stok seviyeleri belirlenebilir, böylece hem satışların artması hem de stokların minimum seviyede tutulması sağlanabilir.
- **Stok Maliyetlerinin Azaltılması:** Büyük otomobil firmaları, özellikle araçların stokta bekletilmesi durumunda finansal kayıplar yaşayabilir. Talep tahminine dayalı stok yönetimi sayesinde, araçların daha hızlı satılması ve stokta bekleme sürelerinin azaltılması sağlanabilir. Bu da genel anlamda nakit akışını iyileştirir.

b. Pazar Stratejisi ve Rekabet Avantajı

Yapay sinir ağları ile yapılan talep tahmini çalışması, büyük otomobil üreticilerinin pazar stratejilerini daha iyi şekillendirmelerine yardımcı olabilir. Doğru tahminler, pazar trendlerini anlamada ve rekabet avantajı sağlamada kilit rol oynar. Bu bağlamda otomobil üreticileri için aşağıdaki alanlarda stratejik katkılar sağlar:

Hedef Pazarların Doğru Analizi: YSA tabanlı modeller, sadece talep tahminini değil, aynı zamanda bölgesel bazda değişen talep trendlerini de analiz edebilir. Büyük

firmalar, farklı pazarlardaki müşteri taleplerini ve davranışlarını daha iyi anlayarak, hangi pazarların daha fazla büyüme potansiyeline sahip olduğunu belirleyebilirler.

- Segmentasyon Stratejisi: Farklı segmentlerde (SUV, sedan, elektrikli araçlar vb.) talep eğilimlerini doğru analiz eden bu model, firmaların hangi segmentlerde daha fazla üretim yapması gerektiğini belirlemelerine olanak tanır. Örneğin, Fiat, ekonomik sınıf araçlara yönelik talebin arttığı pazarlarda bu segmentteki üretimini artırabilir.
- Yeni Ürün Geliştirme ve Pazara Sunma Stratejileri: YSA ile geliştirilen tahmin modelleri, gelecekte hangi tür araçlara daha fazla talep olacağını öngörerek şirketlerin yeni ürün geliştirme stratejilerini de yönlendirebilir. Örneğin, Toyota, gelecekte elektrikli araçlara yönelik talebin artacağını öngörerek, bu segmentteki üretim kapasitesini artırabilir.

Rekabet Avantajı: Talep tahminlerinin doğruluğu, rakip firmalara karşı stratejik bir üstünlük sağlar. Büyük otomobil üreticileri, doğru tahminlere dayalı olarak daha agresif veya daha ihtiyatlı pazarlama ve fiyatlandırma stratejileri geliştirebilirler.

- Fiyatlandırma Stratejileri: Talebin düşük olduğu dönemlerde fiyatları düşürerek stokları azaltmak ya da talebin yüksek olduğu dönemlerde fiyatları artırarak kâr marjını yükseltmek gibi stratejiler geliştirebilirler. Örneğin, Ford talebin artacağı dönemlerde fiyatlarını arttırarak gelirlerini artırabilir.
- Rakiplere Göre Hızlı Karar Alma: Yapay sinir ağları sayesinde elde edilen veriler, büyük üreticilerin hızlı bir şekilde aksiyon almasını sağlar. Talep eğilimlerine hızlı yanıt verebilen firmalar, pazar paylarını koruma ve artırma konusunda avantaj elde ederler.

c. Ekonomik Dalgalanmalara Karşı Proaktif Önlemler

Otomotiv sektörü, ekonomik dalgalanmalardan büyük ölçüde etkilenir. Özellikle büyük otomobil üreticileri, ekonomik koşulların değişkenlik gösterdiği pazarlarda faaliyet göstermektedir. Yapay sinir ağları ile yapılan tahmin çalışması, bu firmaların ekonomik dalgalanmalara karşı daha proaktif önlemler almasına yardımcı olabilir.

Ekonomik Belirsizliklere Karşı Dayanıklılık: YSA modeli, ekonomik göstergelerdeki ani değişikliklere karşı proaktif önlemler alınmasını sağlar. Örneğin, petrol fiyatları veya döviz kuru gibi değişkenler, otomobil talebini doğrudan

etkileyebilir. Otomobil firmaları deęişiklikleri öngörerek üretim ve satış stratejilerini yeniden şekillendirebilirler.

- **Maliyet Yönetimi:** Döviz kuru, faiz oranları ve petrol fiyatlarındaki deęişimlerin doğru tahmin edilmesi, maliyetlerin daha iyi yönetilmesine olanak tanır. Bu da, özellikle ithalata bağımlı üreticiler için maliyetleri optimize etme fırsatı sağlar.
- **Satış ve Pazarlama Stratejilerinin Uyarlanması:** Ekonomik dalgalanmalar sırasında tüketici talebindeki deęişiklikler doğru tahmin edilerek, pazarlama kampanyaları, promosyonlar veya yeni ürün lansmanları ekonomik koşullara göre ayarlanabilir.

Kriz Yönetimi ve Esneklik: Ekonomik kriz dönemlerinde talep daralması yaşanabilir. Bu dönemlerde firmaların doğru bir şekilde talep tahmini yapması, kriz yönetiminde önemli bir rol oynar. Büyük otomobil firmaları, ekonomik kriz dönemlerinde esneklik göstererek talebe uygun üretim seviyelerini belirleyebilir ve gereksiz maliyetlerden kaçınabilirler.

- **Talep Daralması Karşısında Strateji Geliştirme:** YSA ile yapılan tahminler, talepteki daralmaları öngörerek firmaların kriz dönemlerine uygun stratejiler geliştirmelerine olanak tanır. Bu, üretim kapasitesini düşürmek, maliyetleri kısarak kârlılığı korumak veya alternatif pazarlara yönelmek gibi kararları içerir.
- **Esneklik ve Çeviklik:** Talebin daraldığı dönemlerde hızlı aksiyon almak, büyük otomobil üreticilerine esneklik kazandırır. YSA ile yapılan öngörüler, firmaların kriz dönemlerinde çevik davranmalarını ve kaynaklarını verimli kullanmalarını sağlar.
- **Yatırım ve Ürün Geliştirme Kararlarını Desteklemek:** Gelecekteki talep artışını daha isabetli şekilde öngörmek, büyük otomobil üreticilerinin yeni yatırımlar yapma veya mevcut fabrikalarda kapasite artırımını gibi kararları daha bilinçli şekilde almalarını sağlar.

8. Çalışmamız, otomobil talep tahmini konusunda YSA'nın etkinliğini ortaya koyarak önemli bir katkı sunmaktadır. Hem yurt dışındaki literatürle uyumlu olması hem de yurt içindeki literatüre yeni bir perspektif getirmesi, çalışmamızı daha da

değerli kılmaktadır. Özellikle, Türkiye pazarında bu tür çalışmaların sınırlı olması, çalışmamızın bilimsel ve endüstriyel alanda önemli bir boşluğu doldurduğunu göstermektedir.



KAYNAKÇA

- Acar, N. (1989). Üretim planlaması yöntem ve uygulamaları. *Milli Prodüktivite Merkezi*.
- Acharya, U. R., Sree, S. V., & Ray, A. K. (2010). A review of ECG signal processing and its application. *Biomedical Signal Processing and Control*, 5(3), 189-202. <https://doi.org/10.1016/j.bspc.2009.07.007>.
- Akalın, G., & Dilek, S. (2007). Belirsizlik Altında Tüketicilerin Kararları. *Zonguldak Karaelmas Üniversitesi Sosyal Bilimler Dergisi*, 3(6), 33-48.
- Akbay, C., Bayramoğlu, E., & Çakır, H. (1999). Forecasting Demand for Food Products in Turkey: An Application of the Tobit Model. *Agricultural Economics*, 20(3), 233-245.
- Akkaya, Ş. (1991). *Ekonometri II*. İzmir: Anadolu Matbaacılık.
- Aktaş, R., Doğanay, M., & Yıldız, B. (2003). Mali Başarısızlığın Öngörülmesi: İstatistiksel Yöntemler ve Yapay Sinir Ağı Karşılaştırması. *Ankara Üniversitesi SBF Dergisi*, 58(4), 1-24.
- Al-Hamadi, H., & Soliman, S. (2004). Short-Term Electric Load Forecasting Based on Kalman Filtering Algorithm with Moving Window Weather and Load Model. *Electric Power Systems Research*, 47-59.
- Alpaslan, N. (2021). "Talep Tahmininde Makine Öğrenmesi Yöntemlerinin Uygulanması: Bir Sektör Analizi." *Journal of Forecasting and Analytics*, 12(1), 75-92.
- Alper, E., & Mumcu, A. (2000). Türkiye’de Otomobil Talebinin Tahmini. İstanbul: Boğaziçi Üniversitesi, Ekonomi Bölümü, Ekonomi ve Ekonometri Merkezi.
- Altıntaş, E. (2010, 06 11). *Yapay Sinir Ağları ve Tanıma Sistemleri*. Yapay zeka: <http://www.yapay zeka.org/modules/icontent/index.php?page=47>, adresinden alındı
- Altıntaş, E. (2010). *Yapay Sinir Ağları ve Tanıma Sistemleri*. 06 11, 2010 tarihinde <http://www.yapay zeka.org/modules/icontent/index.php?page=47> adresinden alındı
- Alyuda Yapay Sinir Ağları Yazılım Şirketi Web Sayfası. (2010). 06 20, 2010 tarihinde Alyuda: <http://www.al-yuda.com/neural-networks-software.htm> adresinden alındı.
- Anadolu Ajansı. (2022, Ekim 29). Togg’un ilk aracı banttan indi: Türkiye’nin elektrikli yerli otomobili üretildi. *Anadolu Ajansı*. <https://www.aa.com.tr/tr/ekonomi/Toggun-ilk-araci-banttan-indi-turkiyenin-elektrikli-yerli-otomobili-uretildi>.
- Anonim. (2013). *Türk Otomotiv Sektörünün Ülke Ekonomisine Katkıları ve Geleceğe Yönelik Sektörel Beklentiler*. 7. Konya: Konya Otomotiv Sanayi Sektör Raporu.
- Anonim. (2014/a). *Otomotiv Sektör Raporu (2013/1)*. T.C. Bilim Sanayi ve Teknoloji Bakanlığı, Sanayi Genel Müdürlüğü, Sektörel Raporlar ve Analizler Serisi. 11 22, 2023 tarihinde alındı
- Archer, B. (1980). Forecasting Demand: Quantitative and Intuitive . *International Journal of Tourism Management*, 5-177.
- Arslan, B. (2019). Gelecekte Karar Vericiler Kim Olacak? *Uluslararası Yönetim, Ekonomi ve Politika Kongresi*. İstanbul.

- Asilkan, Ö., & Sezgin, I. (2009). İkinci El Otomobillerin Gelecekteki Fiyatlarının Yapay Sinir Ağları ile Tahmin Edilmesi. *Süleyman Demirel Üniversitesi İktisadi İdari Bilimler Fakültesi Dergisi*, 14(2), 375-391.
- Asilkan, E. (2009). İkinci El Otomobillerin Gelecekteki Fiyatlarının Tahminlenmesi: Yapay Sinir Ağları ve Zaman Serisi Analizleri Karşılaştırması. *Otomotiv ve İktisat Dergisi*, 11(4), 200-220.
- Ataseven, B. (2013). Yapay Sinir Ağları ile Öngörü Modellemesi. *İstanbul Kültür Üniversitesi, İktisadi ve İdari Bilimler Fakültesi*, 101-115.
- Ataseven, M. (2007). İşletme tahminlerinde yapay sinir ağlarının etkinliği: Bir inceleme. *Yönetim Bilimleri Dergisi*, 18(3), 123-138.
- ATB. (2020). 2020 yılı otomotiv sektörü raporu. Ekonomik Araştırmalar Departmanı. ATBBank. <https://www.atbank.com.tr/documents/OTOMOTIV%20SEKTORU%20RAPORU%20-%20HAZIRAN%202020.PDF> (Erişim tarihi: 01.11.2021).
- Atilla, A. Ş. (2022). *Yapay Zeka Teknolojisi ve Uygulamaları*. İstanbul: Dikeyksen Yayıncılık.
- Avcı, E. (2009). Yapay Sinir Ağları Modelleri İle Hisse Senedi Getiri Tahminleri. *Marmara Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 26(1), 443-461.
- Avcı, İ. (2009). IMKB-30 Endeksi İçindeki Hisse Senedi Getirilerinin Tahmini: Yapay Sinir Ağları Uygulaması. *Finansal Pazarlar ve Analiz Dergisi*, 14(1), 45-60.
- Aydın, E., & Demirtaş, M. (2022). Yapay Sinir Ağları ile Enerji Tüketim Tahmini ve Optimizasyon. *Enerji Yönetimi Dergisi*, 20(4), 200-215.
- Aydın, M. (2024, Eylül 10). Togg'un çevre dostu teknolojileri. *Hürriyet*. <https://www.hurriyet.com.tr/Togg'un-cevre-dostu-teknolojileri>.
- Aydoğan, İ., Gül, S., & Uçar, Z. (2010). İstanbul Boğazındaki Deniz Suyu Akıntı Hızının Tahminlenmesi: Yapay Sinir Ağları Uygulaması. *Deniz Bilimleri ve Mühendisliği Dergisi*, 6(1), 55-70.
- Balcı, A. (2004). *Sosyal Bilimlerde Araştırma Yöntem, Teknik ve İlkeler*. Ankara: Pegem Yayıncılık.
- Ballot, M. (1986). Decision Making Model in Production & Operations . *Florida: Robert E. Krieger Publishing Company*. , 165.
- Başoğlu, B., & Bulut, M. (2017). Kısa Dönem Elektrik Talep Tahminleri İçin Yapay Sinir Ağları ve Uzman Sistemler Tabanlı Hibrit Sistem Geliştirilmesi. *Journal of the Faculty of Engineering and Architecture of Gazi University*, 32(2), 575-583.
- Başoğlu, U., & Parasız, M. İ. (2003). *İktisadi Verilerin Analizi Ve Temel Öngörü* (s. 78). içinde Bursa: Ekin Kitabevi.
- Bayır, F. (2006). Yapay Sinir Ağları ve Tahmin Modellemesi Üzerine Bir Uygulama. *İSTANBUL ÜNİVERSİTESİ SOSYAL BİLİMLER ENSTİTÜSÜ*.
- Bayır, F. (2006). Yapay Sinir Ağları ve Tahmin Modellemesi Üzerine Bir Uygulama. *İstanbul Üniversitesi Sosyal Bilimler Enstitüsü*. İstanbul.
- Baylar, A., Emiroğlu, M. E., & Arslan, A. (1999). Geriye Yayılma Yapay Sinir Ağı Kullanılarak Yanal Su Alma Yapısına Yönelecek Olan Sürüntü Maddesi Oranının Bulunması. *Dokuz Eylül Üniversitesi Fen ve Mühendislik Dergisi*, 1 (2): 1-12.
- Benli, Y. (2002). Finansal Başarısızlığın Tahmininde Yapay Sinir Ağı Kullanımı ve İMKB'de Bir Uygulama. *Muhasebe Bilim Dünyası Dergisi* , 4 (4): 17-30.
- Bishop, C. M. (2006). *Pattern Recognition and Machine Learning*. Springer.

- Bolt, G. (1994). *Market and Sales Forecasting: A Total Approach*. Londra: Kogan Page.
- Buckland, M., & Collins, M. (2018). *AI Techniques for Game Programming*. Premier Press.
- Büyükdağ, N. (2021). Otomobil fiyatlarını Etkileyen Faktörlerin Belirlenmesi Covid-19 Döneminde Bir Araştırma. *Kahramanmaraş Sütçü İmam Üniversitesi Sosyal Bilimler Dergisi*, 18(3), 1887-1902.
- Cahow, J. A. (2004). "Forecasting demand for home health nurses using multiple regression and Monte Carlo simulation." *Health Care Management Review*, 29(1), 54-65..
- Carlson, R. L., & Umble, M. M. (1980). Statistical demand functions for automobiles and their use for forecasting in an energy crisis. *The Journal of Business*, 53, 2-10.
- Chen, X. (2000). *Tourism and recreation demand forecasting using ARIMA and other statistical methods*.
- Chen, Q., Wang, S., & Xu, B. (2024). Artificial neural networks for predicting renewable energy generation. *Renewable Energy*, 187, 348-359.
- Chen, L., & Zhang, Y. (2014). Neural networks in drug discovery: An overview. *Journal of Computational Chemistry*, 35(15), 1154-1161. <https://doi.org/10.1002/jcc.23476>.
- Chin, K., & Arthur, R. (1995). Neural networks vs. conventional methods of forecasting. *The Journal of Business Forecasting*, 14(4), 17.
- Chung, S. (2001). *Demand modeling and analysis for the management of underground infrastructure systems*. USA: Doktora Tezi, Purdue University.
- Carlson, L., & Umble, M. (1980). Forecasting Demand for Different Categories of Automobiles: A Multiple Regression Analysis Approach. *Journal of Business Research*, 8(2), 155-172.
- Çağlar, T. (2007). *Talep Tahmininde Kullanılan Yöntemler ve Fens Teli Üretimi*. Kırıkkale: Yüksek Lisans Tezi, Kırıkkale Üniversitesi.
- Çakır, F. S. (2019). *Yapay Sinir Ağları*. İstanbul: Nobel Yayıncılık.
- Çakır, F. S. (2019). *Yapay Sinir Ağları Matlab Kodları ve Matlab Toolbox Çözümleri*. Ankara: Nobel Yayıncılık.
- Çayıroğlu, İ. (2015). *İleri Algoritma Analizi-5 Yapay Sinir Ağları*. <http://www.ibrahimcayiroglu.com/Dokumanlar/IleriAlgoritmaAnalizi/IleriAlgoritmaAnalizi-5.Hafta-YapaySinirAglari.pdf> adresinden alındı
- Çelik, B. (2008). YSA Metodolojisi ile Zaman Serisi Analizi: Teori ve Uygulama. 26.
- Çelik, E. (2024, Temmuz 30). Togg'un batarya teknolojisi ve çevreye etkileri. *CNN Türk*. <https://www.cnnturk.com/Togg-batarya-teknolojisi>.
- Çelik, H. (2008). *Üretim planlamasında yapay sinir ağları kullanımı. Üretim ve İşletme Araştırmaları Dergisi*, 25(4), 287-295.
- Çetinkaya, Ö., & Yalçın, T. (2023). Yapay Sinir Ağları ile Sağlık Verilerinin Analizi ve Hastalık Tahmini. *Sağlık Bilimleri ve Araştırmaları Dergisi*, 9(2), 150-165.
- Çevik, K. K., & Dandıl, E. (2012). Yapay Sinir Ağları İçin Net Platformunda Görsel Bir Eğitim Yazılımının Geliştirilmesi. *Bilişim Teknolojileri Dergisi*, CİLT: 5, SAYI: 1,.
- Çuhadar, A., Acar, M., & Yılmaz, M. (2009). *Dış turizm talep tahmini çalışmasında yapay sinir ağları metodunun performansı. Turizm Araştırmaları Dergisi*, 12(1), 45-58.

- Çuhadar, M., & Kayacan, C. (2005). Yapay sinir ağları kullanılarak konaklama işletmelerinde doluluk oranı tahmini: Türkiye'deki konaklama işletmeleri üzerine bir deneme. *Anatolia: Turizm Araştırmaları Dergisi*, 16(1), 24-30.
- Çuhadar, M., & Kayacan, C. (2005). Yapay Sinir Ağları Kullanılarak Konaklama İşletmelerinde Doluluk Oranı Tahmini: Türkiye'deki Konaklama İşletmeleri Üzerine Bir Deneme. *Anatolia: Turizm Arastirmalari Dergisi*, 16(1).
- Çuhadar, M., Güngör, İ., & Göksu, A. (2009). Turizm Talebinin Yapay Sinir Ağları ile Tahmini ve Zaman Serisi Yöntemleri ile Karşılaştırmalı Analizi:Antalya iline Yönelik Bir Uygulama. *Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 14(1), 99-114.
- Değirmenci, G., & Papuçcu, A. (2016). Türkiye CDS primlerinin NARX modeli ile tahmini. *Finansal Araştırmalar ve Çalışmalar Dergisi*, 8(1), 45-61.
- Deloitte Türkiye. (2021). *COVID-19 sonrası otomotiv sektörü analizi*. Deloitte Raporları.
- Demir, S. (2024, Ağustos 25). Türkiye'nin ilk elektrikli otomobili Togg ve sürdürülebilirlik. *Sabah*. <https://www.sabah.com.tr/turkiyenin-ilk-elektrikli-otomobili-togg>.
- Denton, J. W. (1995). How Good Are Neural Networks For Casual Forecasting. *The Journal of Business Forecasting Methods&Systems*, 17.
- Dikmen, I. (2006). http://www.kalder.org.tr/genel/15kongre/sunumlar/isik_dikmen.doc adresinden 12 Ekim 2021 tarihinde alındı.
- Diler, A. (2003). İMKB Ulusal 100 Endeksinin Yönünün Yapay Sinir Ağları Hata Geriye Yayma Yöntemi ile Tahmin Edilmesi. *İMKB Dergisi*, 25-26.
- Durgut, A., & Çelik, S. (2012). Türkiye'de otomobil talebinin çoklu regresyon analizi ile tahmini. *Anadolu Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 28(2), 225-245.
- Dutton, R. G., Green, J. K., & Mears, C. L. (2004). Neural networks in natural language processing. *IEEE Transactions on Neural Networks*, 15(5), 1512-1520. <https://doi.org/10.1109/TNN.2004.832637>.
- Duygun, A. (2020). COVID-19 Pandemisi Sırasında Tüketicilerin Yaşam Tarzlarının Değerlendirilmesi. *International Academic Journal [Econder]*, 4(1), 232-247.
- Düzakın, E. (2005). *İşletme yöneticileri için excel ile sayısal karar verme teknikleri*. İstanbul: Kare Yayınları.
- Ecer, F. (2013). Türkiye'de 2. El Otomobil Fiyatlarının Tahmini ve Fiyat Belirleyicilerinin Tespiti. *Anadolu Üniversitesi Sosyal Bilimler Dergisi*, 4.
- Efendigil, T. (2008). Müşteri Odaklı Sistemler için YSA ve Bulanık Çıkarım Tabanlı Karar Destek Sistemi Yaklaşımı. İstanbul: Doktora Tezi, Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü.
- Electrivate. (2024). *Togg looks to launching exports of the T10X in autumn*. <https://www.electrivate.com>.
- Elmas, Ç. (2003). Yapay Sinir Ağları (Kuram, Mimari, Eğitim, Uygulama). Ç. Elmas. içinde Ankara: Seçkin Yayıncılık.
- Elmas, Ç. (2018). *Yapay Zeka Uygulamaları*. Ankara: Seçkin Yayıncılık.
- Ergün, M. E. (2008). *Sermaye bütçelemesi ve Türk sanayi işletmelerinde uygulaması*. Ankara: Çukurova Üniversitesi, Sosyal Bilimler Enstitüsü, İşletme Ana Bilim Dalı, Yüksek Lisans Tezi.
- Erkut, H., & Akgüç, H. (1997). *Stratejik Yönetim ve Senaryo Tekniği* (s. 210). içinde İstanbul: İrfan Yayınevi.

- Ermiş, M. (2005). Lojistik Sistemlerinin Yapay Sinir Ağları ile Modellenmesi, Gerçeklenmesi ve Kontrolü. *İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü*. İstanbul.
- Eski, H. V. (2006). Ankara: Gazi Kitabevi.
- Fırat, M., & Güngör, M. (2004). Askı Madde Konsantrasyonu ve Miktarının Yapay Sinir Ağları ile Belirlenmesi. *İMO Teknik Dergisi*, 3267-3282
- Fiat Türkiye. (2020). Fiat markasının Türkiye pazarına giriş raporu. *Fiat Türkiye Arşivi*.
- Fildes, R. (2006). *The role of forecasting in business planning*. Journal of Forecasting, 25(3), 175-189.
- Fildes, R., & Petropoulos, F. (2008). The Impact of Forecasting and Planning Expertise on Forecast Accuracy. *International Journal of Forecasting*, 24(3), 512-524.
- Frechtling, D. (2001). Forecasting Tourism Demand: Methods and Strategies. *Butterworth-Heinemann*, 211.
- Gao, M., Wu, L., & Zhang, X. (2023). An advanced neural network model for forecasting cryptocurrency prices. *Computers & Finance*, 12(4), 98-114.
- Gavcar, E., Yılmaz, E., & Karataş, S. (1999). Demand Forecasting for Paper and Board Products in Turkey: A Multiple Regression Analysis. *Industrial Engineering Journal*, 21(4), 307-319.
- Genetik Algoritma ile Türkiye Net Elektrik Enerjisi Tüketiminin 2020 Yılına Kadar Tahmini. (2011). *International Journal of Engineering Research and Development*, 3(2), 37-41.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press.
- Gökçen, G. (2004). *Enflasyon Muhasebesi Teori – Uygulama*. İstanbul: Yayılım Yayıncılık.
- Görener, A., & Görener, Ö. (2008). Türk Otomotiv Sektörünün Ülke Ekonomisine Katkıları ve Geleceğe Yönelik Sektörel Beklentiler. *Yaşar Üniversitesi Dergisi*, 3(10), 1213-1232.
- Griffiths, G., Davis, L., & Thompson, J. (2010). *Regression model for local wheat yield forecasting in Western Australia*. Journal of Agricultural Economics, 61(3), 345-360. <https://doi.org/10.1111/j.1477-9552.2010.00247.x>.
- Gupta, P., Kumar, S., & Singh, R. (2019). A comparison of artificial neural networks and multiple regression analysis for forecasting automotive demand in India. *Journal of Applied Economic Research*, 13(2), 207-222. DOI: 10.1177/0973801018825588.
- Gurney, K. (1996). Computers and Symbols Versus Nets and Neurons. *UCL Draft Papers*, 4.
- Güngör, E. (2007). *Yapay Sinir Ağları Yardımı ile Makine Arızalarının Önceden Tahmin Edilmesi*. Kocaeli: Kocaeli Üniversitesi Sosyal Bilimler Enstitüsü.
- Güven, İ. (2020). Perakende Hazır Giyim Endüstrisinde Yapay Zeka Yöntemleri İle Talep Tahmini (Doctoral dissertation).
- Hajirezaie, M., & Fard, S. (2010). *Kalite kontrolünde yapay sinir ağlarının etkinliği*. Kalite Yönetimi Dergisi, 16(1), 35-50.
- Halaç, O. (1995). *Kantitatif Karar Verme Teknikleri (4 b.)*. İstanbul: Alfa Basım Yayın Dağıtım.
- Hamzaçebi, C. (2011). *Yapay Sinir Ağları Tahmin Amaçlı Kullanımı Matlab ve Neurosolutions Uygulamalı*. Ekin Basım Yayın Dağıtım.
- Hamzaçebi, C. (2011). *Yapay Sinir Ağları Tahmin Amaçlı Kullanımı Matlab ve Neurosolutions Uygulamalı*. Ekin Basım Yayın Dağıtım.

- Hamzaebi, C., & Kutay, F. (2004). Yapay Sinir Ađları ile Trkiye Elektrik Enerjisi Tketiminin 2010 Yılına Kadar Tahmini. *Gazi niversitesi Mhendislik Mimarlık Fakltesi Dergisi*, 19(3), 227-233.
- Hamzaebi, C., & Kutay, F. (2004). Yapay Sinir Ađları ile Trkiye Elektrik Enerjisi Tketiminin 2010 Yılına Kadar Tahmini. *Gazi niversitesi Mhendislik Mimarlık Fakltesi Dergisi*, 19(3), 227-33.
- Haykin, S. (1999). *Neural Networks A Comprehensive Foundation*. New Jersey: Prentice Hall.
- Hedlund, T. G. J., Melville, K. E., & Manolessou, M. A. (1996). Application of neural networks in power system analysis. *IEEE Transactions on Power Systems*, 11(1), 387-393. <https://doi.org/10.1109/59.485775>.
- Heizer, J., & Render, B. (2004). *Operations Management*. Uluslararası Basım 7. Baskı: Prentice Hall.
- Hiller , F., & Liebermann, G. (1970). *Introduction to Operation Research*. (6 b.). San Francisco: Golden Day Inc.
- Ho, K. M., Kim, J. K., & Leach, D. R. (2001). Neural networks for defect detection in solar cell production. *IEEE Transactions on Semiconductor Manufacturing*, 14(2), 237-244. <https://doi.org/10.1109/66.922114>.
- Hocaođlu, F. O., Kaysal, K., & Kaysal, A. (2015). Yk tahmini iin hibrit (YSA ve regresyon) model. *Academic Platform Journal of Engineering and Science*, 3(2), 33-39.
- Hsu, T., Chang, W., & Lee, M. (2024). Neural network approaches for predicting consumer behavior in e-commerce. *E-Commerce Research and Applications*, 57, 101-115.
- Hu, C. (2002). *Advanced Tourism Demand Forecasting ANN and Box-Jenkins Modelling*. MI, USA, Purdue University.
- Hu, X. (2002). *Forecasting domestic tourism demand using artificial neural networks*. *Tourism Management*, 23(4), 455-466. [https://doi.org/10.1016/S0261-5177\(02\)00002-6](https://doi.org/10.1016/S0261-5177(02)00002-6).
- Huang, S., & Shih, K. (2003). Short-Term Load Forecasting Via ARMA Model Identification Including Non-Gaussian Process Considerations. *IEEE Transactions on Power Systems*, 673-679.
- İnsel, A., Arıkan, G., & Yılmaz, B. (2010). *Yapay sinir ađı modellerinin planlama ve kalite kontrol uygulamalarında performans deđerlendirmesi*. *Endstri Mhendisliđi Dergisi*, 22(2), 165-172.
- İz, O. (2005). *Turizm Ekonomisi*. Ankara: Turhan Kitabevi, 3. Basım.
- İpek, M. (1995). *Tam zamanında retim Sistemi ve Bir Simlasyon Uygulaması*. İstanbul: Yksek Lisans Tezi, Fen Bilimleri Enstits.
- Irmak, S., & Asilkan, . (2009). İkinci El Otomobillerin Gelecekteki Fiyatlarının Yapay Sinir Ađları ile Tahmin Edilmesi. *Sleyman Demirel niversitesi İktisadi ve İdari Bilimler Fakltesi Dergisi*, 375-391.
- İstanbul Sanayi Odası. (2007). *Otomotiv Sektr*.
- Jang, J. R., Sun, C. L., & Mizutani, E. (1997). *Neuro-fuzzy and soft computing: A computational approach to learning and machine intelligence*. Prentice Hall.
- Jones, P. (2008). Forecasting demand in emergency departments: A neural network approach. *Health Care Management Review*, 33(4), 320-331.
- Kaastra, I., & Boyd, M. (215-236). Designing A Neural Network for Forecasting Financial and Econometric Time Series. *Neurocomputing*, 1996.

- Kalkınma Bakanlığı. (2019-2023). *On Birinci Kalkınma Planı*. Otomotiv Sanayi Çalışma Grubu Raporu.
- Kara, M. (2024, Nisan 12). Türkiye'nin ilk elektrikli otomobili Togg ve çevre dostu özellikleri. *Sabah*. <https://www.sabah.com.tr/turkiyenin-ilk-elektrikli-Togg>.
- Karahan, M. (2011). İstatistiksel tahmin yöntemleri: Yapay sinir ağları ile ürün talep tahmini uygulaması. Konya: Selçuk Üniversitesi.
- Karaatlı, M., Demirci, E., & Baykaldı, A. (2021). Ticari kredi faiz oranlarının YSA NARX ve VAR modelleri ile öngörülmesi. *İşletme Araştırmaları Dergisi*, 12(3), 2327-2343.
- Karahan, M. (2011). İstatistiksel Tahmin Yöntemleri: Yapay Sinir Ağları Metodu ile Ürün Talep Tahmini Uygulaması. Türkiye: Konya Selçuk Üniversitesi Sosyal Bilimler Enstitüsü.
- Karahan, Ö. (2011). Talep Tahmini Üzerine Çalışmalar: Yurt İçinde ve Yurt Dışında Uygulanan Yöntemler. *Sosyal Bilimler Dergisi*, 4(2), 1-20.
- Karasu, S., Hacıoğlu, R., & Altan, A. (2018). Prediction of Bitcoin Prices with Machine Learning Methods using Time Series Data. *26th signal Processing and Communications Applications Conference*.
- Karbuz, F. S., & Çalışkan, E. (tarih yok). İTO. (İstanbul Ticaret Odası Ekonomi ve Sosyal Araştırmalar Şubesi) 12 10, 2011 tarihinde İTO: <http://www.ito.org.tr/Dokuman/Sektor/1-69.pdf> adresinden alındı.
- Kaya, M. (2023, Mart 15). Türkiye'nin ilk yerli otomobili Togg. *Hürriyet*. <https://www.hurriyet.com.tr>.
- Kaynar, O., & Taştan, S. (2009). Zaman Serileri Tahmininde ARIMA-MLP Melez Modeli. *Atatürk Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 23(3), 141-149.
- Kaynar, O., Taştan, S., & Demirkoparan, F. (2010). Ham Petrol Fiyatlarının Yapay Sinir Ağları İle Tahmini. *Ege Akademik Bakış*, 10(2), 561-575.
- Kaynar, O., Taştan, S., & Demirkoparan, F. (2010). *HAM PETROL FİYATLARININ YAPAY SİNİR AĞLARI İLE TAHMİNİ* (Cilt 10). Ege Akademik Bakış.
- Kellova, A. (2008). *Statistical Approach to Short-Term Electricity Forecasting*. Prague: Charles University.
- Kesici, B., & Yildiz, M. .. (2016). Kalite Kontrol Faaliyetlerinde Yapay Zekâ Kullanımı ve Bir Otomotiv Yan Sanayisinde Uygulanması. *Yalova Sosyal Bilimler Dergisi*, 307-323.
- Khan, M. A., & Khedher, N. B. (2014). An artificial neural network model for predicting energy consumption. *Energy Reports*, 1, 13-18.
- Kienhuis, B., & van der Meer, S. (1999). Neural networks in telecommunications: Applications and future trends. *IEEE Communications Magazine*, 37(6), 56-64. <https://doi.org/10.1109/35.777087>.
- Kim, H., Lee, J., & Park, J. (2024). Predicting patient outcomes in healthcare using deep learning models. *Journal of Medical Systems*, 48(1), 20-32.
- Kirby, A. (1966). Statistical Methods for Forecasting: A Comparative Study of Demand Forecasting Methods for Singer Sewing Machines. *Journal of the American Statistical Association*, 61(315), 1295-1311.
- Kobu, B. (1994). *Üretim Yönetimi* (8 b.). İstanbul: Avcıol Basım-Yayım.
- Koç, M., & Yavuz, M. (2022). Yapay Sinir Ağları ile Finansal Risk Tahmini ve Yönetimi. *Finansal Araştırmalar ve Çalışmalar Dergisi*, 15(1), 75-90.
- KPMG Türkiye. (2021). *Otomotiv sektörü raporu*. KPMG Türkiye Otomotiv Raporları.

- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). "ImageNet classification with deep convolutional neural networks." *Advances in Neural Information Processing Systems*, 25.
- Koç Holding. (2020). *Ford Otosan tarihi*. Koç Holding Yayınları.
- Kozanoğlu, S. (2017). Türkiye otomotiv sektörünün tarihi gelişimi. *Türkiye İş Bankası Kültür Yayınları*.
- Kumar, M. S., & Maiti, J. (2011). Application of artificial neural networks for forecasting the GDP growth rates. *Economic Modelling*, 28(1-2), 145-156.
- Kumar, P., Patel, R., & Singh, V. (2024). Application of neural networks in predictive maintenance of industrial equipment. *Industrial Engineering Journal*, 15(1), 55-69..
- Kurşun, S. (2007). Tekstil Endüstrisinde Benzetim Tekniği İle Üretim Hattı Modellemesi ve Uygun İş Akış Stratejisinin Belirlenmesi,. *Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü*, 17.
- Kurt, R., Karayılmazlar, S., İmren, E., & Çabuk, Y. (2017). Yapay Sinir Ağları İle Öngörü Modellemesi: Türkiye Kâğıt-Karton Sanayi Örneği. *Bartın Orman Fakültesi Dergisi*, 19(2): 99-106.
- Lawrence, R. (1997). *Using Neural Networks to Forecast Stock Market Prices*. Universty of Manitoba.
- Lewis, C. D. (1982). Industrial and Business Forecasting Methods. *Butterworths Publishing*(40).
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). "Deep learning." *Nature*, 521(7553), 436-444.
- Li, J., Zhao, Z., Zhang, F., & Luo, Y. (2018). Automotive demand forecasting using machine learning techniques: A case study in China. *Technological Forecasting and Social Change*, 134, 183-193. DOI: 10.1016/j.techfore.2018.06.002.
- Li, Q., Huang, Y., & Zhang, W. (2024). Artificial neural networks for real-time energy grid management. *Energy*, 239, 122325.
- Liang, J., & Wang, S. (1998). Neural network models for credit risk assessment. *Journal of Financial Services Research*, 14(2), 135-152.
- Lin, W., Hsu, C., & Chang, Y. (2009). "Forecasting medical tourism demand in Thailand: A comparison of a new model and time series analysis." *Tourism Management*, 30(5), 758-767.
- Liu, Y., Huang, Y., & Sun, J. (2024). Time series forecasting using hybrid deep learning models. *Neural Networks*, 152, 58-72.
- Makridakis, S. (1996). *Forecasting: Methods and Applications*. Wiley.
- Maters, T. (1993). *Practical neural network recipes in C++*. Morgan Kaufmann.
- Matuyama, T., Kato, K., & Hori, K. (2008). Inventory Management with Feedback Control: A Study of Two Feedback Policies. *Journal of Operations Management*, 26(1), 41-52.
- Mcaleer, M. (2007). Efficient Estimation: The Rao-Zyskind Condition, Kruskal's Theorem and Ordinary Least Squares,. *Department of Economics*.
- McCulloch, W. S., & Pitts, W. (1943). "A Logical Calculus of the Ideas Immanent in Nervous Activity." *The Bulletin of Mathematical Biophysics*, 5(4), 115-133.
- Mehan, A. (2011). MODELING THE QUANTITY OF MUNICIPAL SOLID WASTE IN ISTANBUL BY USING ARTIFICIAL INTELLIGENCE AND STATISTICAL TECHNIQUES. *Sigma* 3, 165-175.

- Miller, R. K., & Chang, K. H. (1995). Artificial neural networks for predicting manufacturing performance. *International Journal of Production Research*, 33(6), 1527-1539.
- Mitchell, T. M. (1997). *Machine Learning*. McGraw-Hill.
- Mohandes, M., Rehman, S., & Halawani, T. O. (1998). ESTIMATION OF GLOBAL SOLAR RADIATION USING ARTIFICIAL NEURAL NETWORKS. *ELSEVIER*, Vol. 14 Nos. 1-4, s. 179-184,.
- Monks, G. J. (1996). *İşlemler Yönetimi Teori ve Problemler*. (S. Üreten, Çev.) Ankara: Nobel Yayın Dağıtım.
- Moon, M. A., Mentzer, J. T., & Smith, C. D. (2003). Conducting a sales forecasting audit. *International Journal of Forecasting*, 19(1), 5-25.
- Nabiyev, & Vasif, V. (Mayıs 2005). Yapay Zekâ Problemler – Yöntemler - Algoritma. *Seçkin Yayıncılık*, İkinci Baskı .
- Niğde Ömer Halisdemir Üniversitesi. (2012). *Niğde Ömer Halisdemir Mühendislik Bilimleri Dergisi*, 10(1), 188-201.
- ODD. (2018). Otomotiv ve Yeni Stratejiler (76. Sayı). *Otomotiv Distribütörleri Derneği Dergisi*.
[https://www2.deloitte.com/content/dam/Deloitte/tr/Documents/the-deloitte-times/adresinden alındı](https://www2.deloitte.com/content/dam/Deloitte/tr/Documents/the-deloitte-times/adresinden%20alındı)
- ODD. (2020). 2020 Aralık Otomobil ve Hafif Ticari Araç Pazar Değerlendirme Raporu. İstanbul: Otomotiv Distribütörleri Derneği.
- ODMD. (2023, 11 5). *OTOMOTİV DİSTRİBÜTÖRLERİ VE MOBİLİTE DERNEĞİ*. OTOMOTİV DİSTRİBÜTÖRLERİ VE MOBİLİTE DERNEĞİ:
https://www.odmd.org.tr/web_2837_1/neuralnetwork.aspx?type=35
adresinden alındı
- OICA. (2024, Mayıs 10). The International Organization of Motor Vehicle Manufactures: <https://www.oica.net/> adresinden alındı
- Otomobil Distribütörleri Derneği. (2011). *Otomobil Distribütörleri Derneği*. 12 10, 2011 tarihinde Otomobil Distribütörleri Derneği: www.odd.org.tr adresinden alındı
- Ömürek , N., Karaatlı, M., & Tokgöz, G. (2012). Yapay Sinir Ağları Yöntemi ile Otomobil Satış Tahmini. *Uluslararası Yönetim İktisat ve İşletme Dergisi*, 8(17), 1-14.
- Önsel Şahin, Ş., Ülengin, F., & Ülengin, B. (2002). Senaryo analizi için dinamik bir yaklaşım önerisi. *itüdergisi/b*, 1(1), 35-46.
- Özdemir, A., & Karahan, E. (2021). Yapay Sinir Ağları ile Üretim Süreçlerinin Kalite Kontrolü. *İmalat Teknolojileri Dergisi*, 12(3), 85-100.
- Özdemir, A. (2024, Şubat 20). Togg'un batarya teknolojisi ve çevresel etkileri. *CNN Türk*. <https://www.cnnturk.com/Togg-batarya-teknolojisi>.
- Özkaya, N., Savaşır, E., & Beşdok, E. (2024). *Genel amaçlı otomatik parmak izi tanıma sistemi: Tasarımı ve gerçekleştirilmesi*. *Journal of Polytechnic*, 16(2), 123-135.
- Özel, Y. (2006). *Farklı kömür yakıtları ile elektrik enerjisi üretimi ve yakıt performansının yapay zeka yöntemi kullanılarak saptanması*. İstanbul.
- Özşahin, M. (2009). Türkiye Otomotiv Sektörünün Kendini Örgütleyen Haritalar İle Finansal Analizi. Çukurova Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi.
- Öztemel, E. (2003). *Yapay Sinir Ağları* (1. b.). İstanbul: Papatya Yayıncılık.
- Öztemel, E. (2006). *Yapay Sinir Ağları* (2. b.). İstanbul: Papatya Yayıncılık.

- Tekin, T. G., & Patır, S. (2023). AMERİKAN DOLARI KURUNUN YAPAY SİNİR AĞLARI YÖNTEMİYLE TAHMİNLENMESİ: 2009 – 2021 DÖNEMİ. R&S - Research Studies Anatolia Journal, 6(1), 56-77. <https://doi.org/10.33723/rs.1232231>.
- Patır, S., & Karakaşoğlu, Y. (2017). "Gelişmiş Zaman Serisi Analizi ve Uygulamaları: Talep Tahmini İçin Bir Yaklaşım." Journal of Statistical and Econometric Methods, 6(3), 45-63.
- Peter, H., Alexis, G., & Gerard, G. (2018). Honey Authentication with Machine Learning Augmented Bright-Field Microscopy. 32nd Conference on Neural Information Processing Systems. Montréal, Canada.
- Pavilion Technologies. (2024). Artificial neural networks in process control and quality improvement. Pavilion Technologies.
- Pijls, P. J. G., Young, R. D., & Heidari, A. A. K. (2003). Application of neural networks to quality control in manufacturing. *International Journal of Advanced Manufacturing Technology*, 21(9), 648-653. <https://doi.org/10.1007/s001700200038>.
- Pişkin, S. (2017). "Türkiye Otomotiv Sanayii Rekabet Gücü ve Talep Dinamikleri Perspektifinde 2020 İç Pazar Beklentileri. Otomotiv Sektör Raporu. 11 21, 2023 tarihinde http://www.taysad.org.tr/uploads/dosyalar/06-02-2017-09-59-170206-Otomotiv_Sektor_Raporu_TSKB-2208.pdf adresinden alındı
- Rajpal, P., Shishodia, K. S., & Sekhon, G. (2006). An Artificial Neural Network For Modeling Reliability, Availability and Maintainability of A Repairable System. *Reliability Engineering and System Safety*, 809-819.
- Rao, A. M., & Srinivas, J. (2003). Neural Networks: Algorithms and Applications. *Alpha Science International Ltd*.
- Rao, R., Xu, J., & Liu, J. (2024). Deep learning models for predicting air quality in urban environments. *Environmental Pollution*, 314, 120377.
- Rumelhart, D., Hinton, G., & Williams, R. J. (1989). Learning Representations by Back-Propagation Errors. *Cognitive Modeling*, 5(3)(1).
- Russell, S., & Norvig, P. (2016). *Artificial Intelligence: A Modern Approach*. Pearson.
- Sagiroglu, S., Besdok, E., & Erler, M. (2003). *Muhendislikte Yapay Zeka Uygulamaları*. Kayseri: Ufuk Yayıncılık.
- Sanayi ve Teknoloji Bakanlığı. (2021). *Türkiye 'de otomotiv sanayi ve gelişimi raporu*. <https://www.sanayivearaclar.gov.tr>.
- Sahoo, P., & Debnath, N. (2009). Prediction of hot water flow velocity: An approach using artificial neural networks. *Hydrology and Water Resources Journal*, 12(2), 80-95.
- Sarı, M. (2006). Yapay Sinir Ağları ve Bir Otomotiv Firmasında Satış Talep Tahmini Uygulaması.
- Satır, H. M., & Köksal, S. (2006). "Entegre Tavuk Organizasyonları İçin Genel Üretim ve Finansal Planlama Modeli." *Journal of Applied Poultry Research*, 15(3), 340-349.
- School of Information & Library Sciences. (tarih yok). Chapel Hill NC 27599, U.S.A.: University of North Carolina.
- Seaton, A., & Bennet, Y. (1996). *Marketing Tourism Products: Concepts, Issues, Cases*. Oxford: International Thomson Business Press.
- Sevinçtekin, E. (2014). İmalat Sektöründe Yapay Sinir Ağları Uygulaması. *Yıldız Teknik Üniversitesi/Fen Bilimleri Enstitüsü/Endüstri Mühendisliği Ana Bilim Dalı/Sistem Mühendisliği*. İstanbul, Türkiye.

- Shamseldin, A. Y. (2010). Modeling of Blue Nile River flow: Application of artificial neural networks. *Journal of Hydrology and Meteorology*, 15(4), 112-130.
- Smith, K. B., Johnson, M. A., & Clark, D. E. (2002). Application of neural networks to petroleum reservoir characterization. *Journal of Petroleum Technology*, 54(12), 78-85. <https://doi.org/10.2118/78158-JPT>.
- Singh, A., Kumar, S., & Agarwal, R. (2024). Enhancing financial risk prediction using recurrent neural networks. *Quantitative Finance*, 24(2), 215-230.
- Sönmez, O., & Zengin, K. (2019). Yiyecek ve İçecek İşletmelerinde Talep Tahmini: Yapay Sinir Ağları ve Regresyon Yöntemleriyle Bir Karşılaştırma. *Avrupa Bilim ve Teknoloji Dergisi Özel Sayı*, 301-308.
- Söylemez, Y. (2020). Çok Katmanlı Yapay Sinir Ağları Yöntemi ile Altın Fiyatlarının Tahmini. *Sosyoekonomi*, 271-291.
- Ssak, J. N., & Al-Garni, A. Z. (1995). Forecasting electric energy consumption using neural networks. *Enerjy Policy*, Vol. 23, No. 12, pp. 1097 I 104.
- STB. (2020). Sektörel Raporlar ve Analizler Serisi. Ankara: Sanayi ve Verimlilik Genel Müdürlüğü, T.C. Sanayi ve Teknoloji Bakanlığı.
- Stevenson, W. J. (2005). *Operations Management*. Boston: McGraw-Hill Irwin.
- Sun, Y., Zhang, X., & Li, J. (2010). Customer demand forecasting in the cruise industry. *International Journal of Hospitality Management*, 29(2), 275-282. <https://doi.org/10.1016/j.ijhm.2009.09.006>.
- Şahin, A. E. (2001). Eğitim araştırmalarında delphi tekniği ve kullanımı. *Hacettepe Üniversitesi Eğitim Fakültesi Dergisi*, 219.
- Şen, Z. (2004). *Yapay Sinir Ağları İlkeleri*. İstanbul: Su Vakfı Yayınları.
- TC. Sanayi ve Ticaret Bakanlığı Sanayi Genel Müdürlüğü. (2011-2014). *AloMaliye*. 2 11, 2012 tarihinde AloMaliye: http://www.alomaliye.com/2011/turkiye_otomotiv_sektoru.html adresinden alındı.
- TechXplore. (2024). *Togg expands in Turkey and eyes European markets*. <https://www.techxplore.com>.
- Tekin, M. (1996). *Üretim Yönetimi*. Arı Ofset Matbaacılık.
- Tekin, M. (2009). *Üretim Yönetimi* (6 b., Cilt 1). Konya: Günay Ofset.
- Thall, N. (1992). Discount Merchandiser. *Neural Forecasts: A Retail Sales Booster*, 41.
- Togg. (2024). *Togg'un yenilikçi özellikleri ve elektrikli araçlar*. <https://www.Togg.com.tr>.
- Togg. (2024). *Sürdürülebilirlik raporu 2024*. <https://www.Togg.com.tr>.
- Togg. (2024). *Togg Gemlik fabrikası ve istihdam raporu*. <https://www.Togg.com.tr>.
- TÜBİTAK. (2001). Teknoloji Öngörüsü ve Ülke Örnekleri Çalışma Raporu. Ankara: Bilim ve Teknoloji Politikaları Dairesi Başkanlığı.
- TÜİK. (2020). *Otomotiv sektörü raporu*. Türkiye İstatistik Kurumu Yayınları.
- Türkiye İhracatçılar Meclisi. (2023). *Türkiye'nin otomotiv ihracat raporu 2022*. <https://www.tim.org.tr>.
- Tüzüntürk, S., Sert Eteman, F., & Sezen, H. K. (2016). YAPAY SİNİR AĞI YÖNTEMİ İLE DAMACANA SU SATIŞ MİKTARLARININ TAHMİNİ. *AKADEMİK BAKIŞ DERGİSİ*, Sayı: 56.
- Uğur, A., & Kınacı, A. C. (2006). *Yapay Zeka Teknikleri Ve Yapay Sinir Ağları Kullanılarak Web Sayfalarının Sınıflandırılması*. Ankara: Türkiye'de İnternet Konferansı.

- Ulgen, K. E. (2024, Mart 14). *Makine Öğrenimi Bölüm-6 (Regresyon)*. <https://medium.com/> adresinden alındı
- Uygun, İ. (2015). Yapay Sinir Ağları Yardımıyla Enerji Sektöründe Talep Tahmini. Türkiye: İstanbul Marmara Üniversitesi Sosyal Bilimler Enstitüsü.
- Ünal, Ş. N. (2024). *NARX Sinir Ağı Yöntemi ile Safranbolu Turist Sayısının Analizi*. Turizm ve İşletme Bilimleri Dergisi, 4(1), 219-231..
- Ünel, F. B. (2017). *Taşınmaz Değerleme Kriterlerine Yönelik Coğrafi Veri Modelinin Geliştirilmesi*. Konya, Türkiye: Selçuk Üniversitesi Fen Bilimleri Enstitüsü.
- Üreten, S. (2005). *Üretim/İşlemler Yönetimi, Stratejik Kararlar ve Karar Modelleri* (5. Baskı b.). Ankara: Gazi Kitabevi.
- Verbos, P. (1994). The Roots of Backpropagation: From Ordered Derivatives to Neural Networks and Political Forecasting. *John Wiley&Sons, Vol.1*.
- Wang, J., & Zhang, X. (2005). Forecasting stock market returns using artificial neural networks. *Journal of Financial Economics*, 72(2), 567-595.
- Wang, L., Zhang, X., & Zhao, Y. (2024). Optimizing supply chain management with artificial neural networks. *European Journal of Operational Research*, 308(3), 930-945.
- Wang, W., & Xu, Z. (2004). *A Heuristic Training for Support Vector Regression* (61 b.). Neurocomputing.
- Wang, X., Li, Y., Zhang, Z., & Chen, W. (2017). Predicting automotive demand using deep learning and artificial neural networks. *International Journal of Forecasting*, 33(3), 535-546. DOI: 10.1016/j.ijforecast.2017.01.002.
- Wang, Z., Yang, Y., & Li, S. (2022). Forecasting energy consumption in smart cities using deep neural networks. *Energy Reports*, 8, 1234-1246.
- Wawrzyński, P. (2014). Fundamentals of artificial intelligence. *Warsaw University of Technology Publishing House*.
- Williams, R. G., Young, S. A., & Smith, R. L. (1998). Signal processing applications of neural networks. *Signal Processing*, 73(3), 267-278. [https://doi.org/10.1016/S0165-1684\(98\)00147-4](https://doi.org/10.1016/S0165-1684(98)00147-4).
- Winklhofer, H., et al. (1996). *A review of forecasting techniques and their applications*. International Journal of Forecasting, 12(4), 641-650.
- Witkin, B., & Altschuld, J. W. (1995). Planning and conducting needs assessments: A practical guide. Sage.
- Wong, S. S., Leung, H., & Chan, K. (1997). *Applications of artificial neural networks: A survey of 1988-1995*. *Neural Networks*, 10(4), 599-616. [https://doi.org/10.1016/S0893-6080\(97\)00013-3](https://doi.org/10.1016/S0893-6080(97)00013-3).
- Xie, L., & Wang, W. (2013). Using artificial neural networks to forecast urban air pollution levels. *Environmental Monitoring and Assessment*, 185(5), 4383-4393.
- Xu, X., Zheng, X., & Liu, Y. (2010). "Demand forecasting for emergency supplies following natural disasters: A case study of the 2008 China winter storm." *Journal of Disaster Research*, 5(3), 245-254.
- Xu, Y., Zhang, L., & Chen, L. (2023). Predicting stock market volatility with hybrid neural networks. *Journal of Computational Finance*, 27(3), 145-162.
- Yaşar, A. B. (2009). Kent içi Otobüs Taşımacılığında Talep Tahmini. Denizli: Pamukkale Üniversitesi Fen Bilimler Enstitüsü.
- Yayar, R., & Yılmaz, E. (2016). DÜNYA VE TÜRKİYE OTOMOTİV SANAYİ ÜZERİNE GENEL BİR Değerlendirme. *Selçuk Üniversitesi Akşehir Meslek Yüksekokulu Sosyal Bilimler Dergisi*, 2(7), 84.

- Yazıcıoğlu, N. (2010). *Yapay zeka ile talep tahmini*. (Master's thesis Uludağ Üniversitesi).
- Yıldırım, H., & Karaatlı, M. (2022). YSA NARX modeli ile elma üretim miktarının öngörülmesi. *Süleyman Demirel Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 42, 1-29.
- Yıldız, B. (2001). Finansal Başarısızlığın Öngörülmesinde Yapay Sinir Ağı Kullanımı ve Halka Açık Şirketlerde Ampirik Bir Uygulama. *İMKB Dergisi*, 5 (17): 51-67.
- Yıldız, B. (2009). *Finansal Analizde Yapay Zeka* (1. b.). Ankara: Detay Yayıncılık.
- Yıldız, E. (2024, Mart 5). Togg'un çevre dostu teknolojileri ve sürdürülebilirlik çalışmaları. *Hürriyet*. <https://www.hurriyet.com.tr/Togg-cevre-dostu-teknolojiler>.
- Yılmaz, A. (2019). *Yapay Zeka*. İstanbul: KODLAB Yayın Dağıtım.
- Yu, L., Wang, S., & Lai, K. (2008). Forecasting crude oil price with an EMD-based neural network ensemble learning paradigm. *Energy Economics*, 30, 2623-2635.
- Yurdakul, M., & İç, Y. T. (2005). Vector autoregressive (VAR) models and forecasting of automotive demand in Turkey. *Journal of Economics and Business*, 58(4), 325-335. DOI: 10.1016/j.jeconbus.2005.02.002.
- Yücesoy, M. (2011). *Temizlik Kağıtları Sektöründe Yapay Sinir Ağları İle Talep Tahmini*. İstanbul: (Doctoral dissertation, Fen Bilimleri Enstitüsü).
- Zhang, G., Patuwo, B., & Hu, M. (1998). Forecasting With Artificial Neural Networks: The State Of The Art. *International Journal of Forecasting*, 35-62.
- Zhang, C., Lu, H., & Chen, Z. (2023). Neural network approaches for predicting climate change impacts on agriculture. *Agricultural Systems*, 195, 103295.
- Zhang, G. P., & Qi, M. (2005). Neural network forecasting for seasonal and trend time series. *IEEE Transactions on Neural Networks*, 16(6), 1342-1348.
- Zhou, M., & McMahon, T. A. (2002). "Water demand forecasting in Melbourne: A time series analysis." *Journal of Water Resources Planning and Management*, 128(2), 139-146.
- Zhou, X., Yang, J., & Chen, P. (2024). Predicting demand in the transportation sector using deep learning techniques. *Transportation Research Part C: Emerging Technologies*, 139, 103682..

EKLER

EK-1 2014-2023 Yılları Arasında Türkiye’de Üretim Yapan 6 Otomotiv Firmasının Aylık Otomobil Satışları

TARİH	FİRMALAR						
	1-Fiat	2-Ford	3-Honda	4-Hyundai	5-Renault	6-Toyota	TOPLAM
Oca.14	1703	1389	545	1867	4532	1209	11245
Şub.14	1516	1244	761	2072	4768	1202	11563
Mar.14	1940	1621	1437	3030	5249	1447	14724
Nis.14	3190	2400	1131	3486	6634	2232	19073
May.14	3716	2869	862	3527	6613	2449	20036
Haz.14	3597	3804	863	3641	6654	2572	21131
Tem.14	3272	4985	1137	3062	6414	2917	21787
Ağu.14	3010	3321	1129	3366	5408	2229	18463
Eyl.14	3907	3065	1141	4303	7945	3360	23721
Eki.14	3045	2551	1067	4166	7948	3380	22157
Kas.14	3964	3403	1292	4858	9155	3767	26439
Ara.14	6682	6640	2425	7532	18707	7557	49543
Oca.15	1812	1180	646	2284	3314	1371	10607
Şub.15	2851	2946	770	2919	5181	2706	17373
Mar.15	3780	3827	1076	4415	8718	4633	26449
Nis.15	5252	4991	1158	4654	9632	4966	30653
May.15	3857	5021	1217	4759	6125	3731	24710
Haz.15	4425	4896	1235	4461	9628	4844	29489
Tem.15	4176	4305	1348	3569	9314	4379	27091
Ağu.15	3061	4276	1477	4116	8181	3400	24511
Eyl.15	3399	2872	1416	3569	7438	2084	20778
Eki.15	2769	2935	1466	3384	7720	3304	21578
Kas.15	3794	3232	1562	4390	8972	3548	25498
Ara.15	8187	6677	2907	7611	17523	9030	51935
Oca.16	1627	1321	737	2230	4068	1447	11430
Şub.16	2765	3048	1179	2984	5560	2323	17859
Mar.16	4268	4111	2107	4429	10310	3116	28341
Nis.16	4818	3781	1109	4445	10633	4072	28858
May.16	4565	3961	1349	4566	11275	5518	31234
Haz.16	4962	4954	1430	4043	10671	3037	29097
Tem.16	2849	2267	988	3254	5513	2895	17766
Ağu.16	3325	2679	1158	3382	6589	3478	20611
Eyl.16	3703	2251	1241	3725	5277	2927	19124
Eki.16	4597	3114	1958	4099	7399	3918	25085
Kas.16	6946	4682	2853	5598	10831	7601	38511
Ara.16	7944	5201	4392	6763	18490	6855	49645
Oca.17	1621	1533	1317	2223	4355	1927	12976

Şub.17	2469	1570	1717	2827	5437	1667	15687
Mar.17	4622	3047	2938	4306	8866	2151	25930
Nis.17	4885	4007	2244	4296	8666	2402	26500
May.17	6512	4516	2290	4492	10320	3383	31513
Haz.17	6543	3924	2247	4388	11135	4038	32275
Tem.17	5664	3593	1797	3380	10141	4499	29074
Ağu.17	5065	2981	1665	3714	8531	2534	24490
Eyl.17	4803	2345	2059	3865	7869	2924	23865
Eki.17	5474	3312	2081	4423	9919	4496	29705
Kas.17	5358	4476	2283	4939	11975	3762	32793
Ara.17	8348	4546	3783	6428	16240	6875	46220
Oca.18	2035	1149	1398	2087	4650	2247	13566
Şub.18	2377	1770	1720	2920	6552	1906	17245
Mar.18	4638	3050	3179	4389	8948	3255	27459
Nis.18	4305	2786	2527	4186	10034	2578	26416
May.18	5487	3204	2720	4605	9280	2808	28104
Haz.18	3245	2553	2515	3225	7427	2095	21060
Tem.18	3832	2053	2443	2489	6485	3020	20322
Ağu.18	1681	1591	1913	1250	3634	2100	12169
Eyl.18	689	796	1973	1496	2751	933	8638
Eki.18	1438	779	2047	1266	1321	1326	8177
Kas.18	3592	2008	2805	2133	5225	5403	21166
Ara.18	8349	2009	3421	1963	10624	3148	29514
Oca.19	1390	285	833	1018	1865	256	5647
Şub.19	2732	569	1016	1544	3085	1162	10108
Mar.19	6516	1610	1561	1879	7116	2144	20826
Nis.19	3994	909	1519	1592	3148	1884	13046
May.19	4493	728	1699	1814	4730	2555	16019
Haz.19	5005	1371	1843	1776	7283	2653	19931
Tem.19	1610	491	880	1449	2694	1353	8477
Ağu.19	2382	500	1282	1082	3156	1362	9764
Eyl.19	4981	1249	1720	1545	6898	2503	18896
Eki.19	3885	2266	2072	2511	2434	2410	15578
Kas.19	6941	2478	2292	3006	6143	2422	23282
Ara.19	13232	3246	3637	3570	12116	2658	38459
Oca.20	2021	346	1101	1243	2743	2351	9805
Şub.20	3908	1078	1438	1910	7251	2830	18415
Mar.20	4742	2367	1308	1747	5765	2707	18636
Nis.20	2110	1096	446	772	3019	125	7568
May.20	3200	705	1733	980	5433	895	12946
Haz.20	9231	1405	2260	2470	12094	2718	30178
Tem.20	12263	3444	2201	3115	11189	3170	35382
Ağu.20	8291	2517	1222	2544	4254	2727	21555
Eyl.20	11704	2882	1710	2752	13794	5832	38674

Eki.20	12573	3427	2350	4228	9999	5104	37681
Kas.20	9968	4250	2806	3271	9298	4493	34086
Ara.20	12353	4079	3647	2509	14061	6006	42655
Oca.21	3395	1422	1553	1280	3624	4062	15336
Şub.21	7147	1345	1760	1573	5982	3814	21621
Mar.21	8781	2186	2774	3122	9024	8460	34347
Nis.21	5920	1411	2626	2880	6250	3600	22687
May.21	7135	1094	2493	2298	5033	2878	20931
Haz.21	8732	1342	3069	4023	8365	4776	30307
Tem.21	4380	784	1702	3893	2475	2739	15973
Ağu.21	5936	1483	2257	4206	8191	1996	24069
Eyl.21	6077	635	2588	4426	4324	2155	20205
Eki.21	6865	1594	2244	3426	4761	2073	20963
Kas.21	3249	397	2658	3776	7879	4065	22024
Ara.21	5464	359	2426	2032	9653	5281	25215
Oca.22	4304	783	1314	3670	4046	1717	15834
Şub.22	3610	688	1805	4182	5396	3274	18955
Mar.22	4972	915	2708	3550	9022	3111	24278
Nis.22	5272	1044	1875	4001	8304	3868	24364
May.22	9392	1369	2064	3354	5709	3537	25425
Haz.22	13601	816	1762	3608	11336	3239	34362
Tem.22	10495	516	1334	3303	3623	2525	21796
Ağu.22	4695	931	1463	2879	3955	2621	16544
Eyl.22	8138	685	1958	3024	4202	2953	20960
Eki.22	9085	736	1741	3327	6038	1279	22206
Kas.22	10150	796	1531	3162	8383	4237	28259
Ara.22	13640	2024	1874	4181	18192	5915	45826
Oca.23	6746	625	1196	3957	2326	1190	16040
Şub.23	12924	1645	1355	4014	7318	1167	28423
Mar.23	14720	2903	1681	4537	6947	4142	34930
Nis.23	11451	2790	1380	4205	10859	2888	33573
May.23	13624	3195	2228	3992	8554	3835	35428
Haz.23	10695	2717	1598	4666	15901	5184	40761
Tem.23	11615	2114	1618	4516	5186	3157	28206
Ağu.23	3559	2524	1659	3733	8774	2376	22625
Eyl.23	11722	2515	1651	3909	9756	2443	31996
Eki.23	9229	2133	1680	4097	12192	5953	35284
Kas.23	8581	3460	2108	5373	11471	5071	36064
Ara.23	10482	4315	3168	5857	18207	8063	50092

EK-2 Tahminlemede Kullanılan Giriş Verileri

Tarih	Brent Petrol	Dolar/TL	Taşıt Faiz Oranları	Araç Satın Alım Düzeyi	TÜFE	Otomobil Üretim Adeti	Otomobil Satış Adeti
2014-01	108.16	2.22	12.84	151.68	233.54	52006	11245
2014-02	108.98	2.21	15.09	161.10	234.54	53250	11563
2014-03	105.95	2.22	15.21	166.94	237.18	61203	14724
2014-04	108.63	2.13	14.91	167.83	240.37	63761	19073
2014-05	109.21	2.09	14.29	166.66	241.32	63658	20036
2014-06	111.03	2.12	13.31	164.96	242.07	67013	21131
2014-07	104.94	2.12	12.79	164.87	243.17	61151	21787
2014-08	101.12	2.16	12.84	164.79	243.40	37330	18463
2014-09	94.67	2.20	12.72	164.83	243.74	72120	23721
2014-10	84.17	2.26	12.37	164.74	248.37	62001	22157
2014-11	71.89	2.23	12.38	163.84	248.82	69466	26439
2014-12	55.27	2.29	12.60	162.89	247.72	70480	49543
2015-01	47.52	2.33	12.91	166.79	250.45	60414	10607
2015-02	61.89	2.46	13.06	170.74	252.24	65238	17373
2015-03	53.69	2.58	12.58	171.23	255.23	72781	26449
2015-04	63.90	2.65	12.79	171.46	259.39	67277	30653
2015-05	63.16	2.65	13.14	173.65	260.85	52339	24710
2015-06	60.31	2.70	13.44	174.15	259.51	73928	29489
2015-07	53.29	2.69	13.60	176.27	259.74	62465	27091
2015-08	47.97	2.85	14.14	176.90	260.78	45210	24511
2015-09	47.29	3.00	15.20	183.80	263.11	66572	20778
2015-10	48.00	2.93	15.82	187.45	267.20	77243	21578
2015-11	43.73	2.87	15.62	186.92	268.98	72872	25498
2015-12	36.61	2.92	15.18	185.87	269.54	74688	51935
2016-01	33.14	3.01	15.82	188.76	274.44	58205	11430
2016-02	35.92	2.94	16.32	194.28	274.38	72740	17859
2016-03	36.75	2.89	16.33	194.79	274.27	77051	28341
2016-04	45.64	2.83	15.92	194.82	276.42	74625	28858
2016-05	49.26	2.93	15.54	195.09	278.02	76570	31234
2016-06	48.05	2.92	15.30	197.42	279.33	82175	29097
2016-07	40.76	2.96	15.31	197.36	282.58	69030	17766
2016-08	47.94	2.96	15.45	199.71	281.76	52296	20611
2016-09	48.24	2.96	15.01	200.23	282.27	78439	19124
2016-10	46.20	3.07	14.74	202.96	286.33	98008	25085
2016-11	47.95	3.27	13.71	206.10	287.81	104737	38511
2016-12	54.96	3.49	13.86	209.43	292.54	106963	49645
2017-01	55.25	3.73	15.21	213.34	299.74	93683	12976
2017-02	53.36	3.67	15.62	223.43	302.17	97129	15687
2017-03	52.20	3.67	15.38	232.01	305.24	109443	25930

2017-04	49.46	3.65	15.68	236.01	309.23	101839	26500
2017-05	49.40	3.56	15.61	235.32	310.61	104653	31513
2017-06	47.08	3.52	15.37	231.73	309.78	94839	32275
2017-07	51.99	3.56	15.97	234.39	310.24	97985	29074
2017-08	52.69	3.51	16.22	239.66	311.85	50453	24490
2017-09	57.02	3.47	16.36	241.58	313.88	88952	23865
2017-10	61.35	3.66	15.69	250.09	320.40	102404	29705
2017-11	63.53	3.88	14.49	256.56	325.18	106487	32793
2017-12	66.73	3.85	14.64	265.56	327.41	72993	46220
2018-01	67.78	3.77	17.48	268.55	330.75	85368	13566
2018-02	66.08	3.78	18.01	273.28	333.17	94113	17245
2018-03	69.02	3.88	17.39	277.24	336.48	105687	27459
2018-04	75.92	4.05	18.19	289.99	342.78	90789	26416
2018-05	76.45	4.41	18.86	296.08	348.34	95677	28104
2018-06	77.44	4.63	21.74	307.72	357.44	85635	21060
2018-07	74.16	4.75	24.09	312.05	359.41	96511	20322
2018-08	76.94	5.73	26.35	330.34	367.66	29289	12169
2018-09	82.72	6.37	32.44	375.35	390.84	86395	8638
2018-10	74.84	5.86	32.78	364.56	401.27	89151	8177
2018-11	57.71	5.37	30.83	316.80	395.48	85666	21166
2018-12	50.57	5.31	29.49	313.82	393.88	82157	29514
2019-01	62.46	5.37	29.52	311.52	398.07	71397	5647
2019-02	65.03	5.26	26.78	311.41	398.71	80077	10108
2019-03	67.93	5.44	23.58	307.04	402.81	87348	20826
2019-04	72.19	5.74	25.07	310.25	409.63	83459	13046
2019-05	66.78	6.05	27.58	321.85	413.52	96345	16019
2019-06	67.52	5.81	28.68	325.18	413.63	74074	19931
2019-07	64.07	5.67	27.40	358.13	419.24	86235	8477
2019-08	61.04	5.62	22.89	348.48	422.84	31287	9764
2019-09	60.99	5.71	20.19	345.80	427.04	90359	18896
2019-10	59.30	5.78	16.03	348.34	435.59	93575	15578
2019-11	64.50	5.73	14.95	348.83	437.25	93495	23282
2019-12	67.77	5.84	13.75	352.18	440.50	94991	38459
2020-01	57.77	5.92	14.06	354.12	446.45	75396	9805
2020-02	51.31	6.04	13.12	353.58	448.02	87589	18415
2020-03	14.85	6.31	13.35	359.25	450.58	72093	18636
2020-04	18.11	6.82	13.91	371.05	454.43	9661	7568
2020-05	34.15	6.95	13.12	380.98	460.62	43264	12946
2020-06	41.64	6.81	11.64	395.43	465.84	74264	30178
2020-07	43.13	6.85	11.61	404.73	468.56	77706	35382
2020-08	45.22	7.25	14.39	410.30	472.61	45211	21555
2020-09	40.30	7.51	16.82	426.84	477.21	90447	38674
2020-10	36.33	7.87	17.45	439.53	487.38	95915	37681
2020-11	46.84	8.00	18.81	481.33	498.58	91067	34086

2020-12	51.22	7.72	17.15	499.86	504.81	92300	42655
2021-01	55.25	7.39	19.04	500.92	513.30	68777	15336
2021-02	65.86	7.07	19.23	503.36	517.96	68105	21621
2021-03	63.52	7.63	19.36	505.77	523.53	74995	34347
2021-04	67.73	8.16	21.72	523.13	532.32	76334	22687
2021-05	69.36	8.34	22.39	530.18	537.05	66976	20931
2021-06	76.94	8.60	22.03	537.71	547.48	62441	30307
2021-07	77.72	8.61	22.25	539.91	557.36	33529	15973
2021-08	73.45	8.48	21.80	525.08	563.60	59539	24069
2021-09	77.81	8.51	21.33	526.75	570.66	59335	20205
2021-10	83.10	9.14	20.73	527.76	584.32	64637	20963
2021-11	70.86	10.52	21.46	556.01	604.84	70974	22024
2021-12	77.24	13.53	24.82	785.99	686.95	76570	25215
2022-01	92.35	13.52	28.25	796.83	763.23	47778	15834
2022-02	103.08	13.62	26.85	797.25	799.93	61544	18955
2022-03	107.29	14.57	25.40	856.34	843.64	57041	24278
2022-04	108.36	14.68	24.82	891.52	904.79	62837	24364
2022-05	125.53	15.62	24.20	912.88	931.76	67162	25425
2022-06	119.78	16.96	25.04	943.61	977.90	86585	34362
2022-07	111.51	17.39	27.53	984.48	1001.03	50795	21796
2022-08	96.55	17.99	27.76	1009.22	1015.65	62560	16544
2022-09	88.90	18.28	26.79	1013.81	1046.89	74704	20960
2022-10	93.30	18.56	26.33	1027.64	1084.00	62363	22206
2022-11	85.61	18.59	25.37	1050.44	1115.26	83999	28259
2022-12	82.82	18.64	24.92	1033.59	1128.45	93521	45826
2023-01	83.42	18.76	25.39	1071.56	1203.48	70723	16040
2023-02	83.21	18.82	25.34	1113.87	1241.33	63751	28423
2023-03	79.19	18.97	24.95	1128.48	1269.75	87577	34930
2023-04	81.32	19.30	25.09	1175.67	1300.04	73637	33573
2023-05	71.98	19.68	27.80	1248.13	1300.60	90739	35428
2023-06	74.51	23.06	33.54	1374.11	1351.59	75974	40761
2023-07	85.22	26.42	40.49	1593.81	1479.84	88214	28206
2023-08	87.29	26.95	37.93	1733.03	1614.31	49300	22625
2023-09	95.86	26.94	42.93	1738.81	1691.04	87902	31996
2023-10	86.82	27.80	46.52	1732.51	1749.11	91511	35284
2023-11	81.72	28.59	43.92	1745.49	1806.50	96922	36064
2023-12	77.69	29.02	35.38	1768.20	1859.38	76416	50092

EK-3 Tahminlemede Kullanılan Normalize Edilmiş Veriler

Tarih	Brent Petrol	Dolar/TL	Taşıt Faiz Oranları	Araç Satın Alım Düzeyi	TÜFE	Otomobil Üretim Adeti	Otomobil Satış Adeti
2014-01	0.843061077	0.00482733	0.035122902	0	0	0.424375138	0.120938472
2014-02	0.850469823	0.004455997	0.099653355	0.005827333	0.000615067	0.436842316	0.127808503
2014-03	0.823093603	0.00482733	0.103019538	0.009440032	0.002238843	0.51654607	0.196098341
2014-04	0.847307553	0.001485332	0.094425027	0.009990597	0.004200905	0.542181957	0.290053578
2014-05	0.852547886	0	0.076605741	0.00926682	0.004785219	0.541149706	0.310858106
2014-06	0.868991688	0.001113999	0.048444394	0.008215178	0.005246519	0.574773005	0.334514345
2014-07	0.813968197	0.001113999	0.033547241	0.008159503	0.005923092	0.516024934	0.348686485
2014-08	0.779454283	0.002599332	0.035122902	0.008110014	0.006064557	0.277294502	0.276875216
2014-09	0.721178171	0.004084664	0.031541855	0.008134759	0.00627368	0.625954581	0.390468372
2014-10	0.626310083	0.006312662	0.021715464	0.008079083	0.009121439	0.524543505	0.356679917
2014-11	0.515359595	0.005198663	0.021801409	0.007522332	0.009398219	0.599356597	0.449187694
2014-12	0.365196964	0.007426662	0.028247293	0.00693465	0.008721645	0.609518751	0.94832354
2015-01	0.29517528	0.008911994	0.037013694	0.00934724	0.010400777	0.508638833	0.107155202
2015-02	0.425009035	0.013739324	0.041353922	0.01179076	0.011501747	0.556984226	0.253326996
2015-03	0.350921576	0.018195321	0.027602704	0.012093881	0.013340796	0.632579022	0.449403733
2015-04	0.443169498	0.020794653	0.033762104	0.012236162	0.015899474	0.577418773	0.540226409
2015-05	0.436483556	0.020794653	0.043660116	0.013590924	0.016797471	0.427712413	0.411834601
2015-06	0.410733647	0.022651318	0.052383544	0.01390023	0.015973282	0.644074081	0.515079502
2015-07	0.347307553	0.022279985	0.056952959	0.015211689	0.016114747	0.529193642	0.463273419
2015-08	0.299241055	0.028221315	0.072365782	0.015601415	0.016754416	0.356266661	0.40753543
2015-09	0.293097217	0.033791311	0.102661434	0.019869844	0.018187522	0.57035337	0.326888178
2015-10	0.299512107	0.031191979	0.120437747	0.022127781	0.020703144	0.677296506	0.344171275
2015-11	0.260932418	0.028963981	0.11476537	0.021799916	0.021797963	0.63349101	0.428858451
2015-12	0.196602819	0.030820646	0.102088466	0.021150372	0.0221424	0.651690686	1
2016-01	0.165251175	0.034162644	0.120552341	0.022938163	0.025156227	0.486500571	0.124935188
2016-02	0.19036863	0.031563312	0.134675987	0.026352906	0.025119323	0.632168127	0.263826478
2016-03	0.197867727	0.029706647	0.135177333	0.026668399	0.025051666	0.675372312	0.490278258
2016-04	0.278189375	0.027478648	0.123245287	0.026686957	0.026374059	0.651059309	0.501447459
2016-05	0.310896278	0.031191979	0.112545121	0.026853983	0.027358166	0.670551803	0.552778258
2016-06	0.29996386	0.030820646	0.105597891	0.028295351	0.028163903	0.726724259	0.506610785
2016-07	0.234098301	0.032305978	0.105827078	0.028258234	0.03016287	0.594987072	0.261817318
2016-08	0.298970004	0.032305978	0.109823526	0.029711974	0.029658515	0.427281474	0.323280332
2016-09	0.30168052	0.032305978	0.097232567	0.030033653	0.029972199	0.689282636	0.291155375
2016-10	0.283249006	0.036390642	0.089411562	0.031722466	0.03246937	0.885400172	0.419936053
2016-11	0.299060354	0.043817304	0.060118604	0.03366491	0.033379668	0.952837185	0.70998963
2016-12	0.362396097	0.051986632	0.064458832	0.035724891	0.036288934	0.975145818	0.950527134
2017-01	0.365016263	0.060898626	0.103019538	0.038143667	0.040717414	0.842055681	0.158334774
2017-02	0.347940007	0.058670628	0.114693749	0.04438547	0.042212026	0.876590968	0.216902869
2017-03	0.337459342	0.058670628	0.107947058	0.049693168	0.04410028	1	0.438191324
2017-04	0.312703289	0.057927961	0.116484272	0.052167619	0.046554396	0.923793871	0.450505531
2017-05	0.312161185	0.054585964	0.114550507	0.051740776	0.047403189	0.95199535	0.558805738
2017-06	0.291199855	0.053100631	0.107488684	0.049519956	0.046892683	0.853640937	0.575267888
2017-07	0.33556198	0.054585964	0.12486392	0.051165467	0.047175614	0.88516967	0.506113896
2017-08	0.34188652	0.052729298	0.13181115	0.054425556	0.048165871	0.408811208	0.407081749
2017-09	0.381008312	0.051243966	0.136079757	0.055613293	0.049414457	0.79464232	0.393579329
2017-10	0.420130105	0.058299294	0.116627514	0.060877688	0.053424691	0.929456215	0.519745938
2017-11	0.439826527	0.066468622	0.08224947	0.064880113	0.05636471	0.970375418	0.586458693

2017-12	0.468738706	0.065354623	0.086747264	0.070447628	0.057736309	0.634703654	0.876533875
2018-01	0.478225515	0.062383958	0.167908096	0.072297281	0.059790631	0.758724018	0.171081058
2018-02	0.46286592	0.062755291	0.183091732	0.075223319	0.061279093	0.846365076	0.250561701
2018-03	0.489428984	0.066468622	0.165530281	0.077673026	0.063314963	0.96235794	0.471223643
2018-04	0.551770871	0.072781285	0.188248439	0.085560339	0.067189883	0.813052454	0.448690805
2018-05	0.556559451	0.086149276	0.207586088	0.089327692	0.070609654	0.862039246	0.48515814
2018-06	0.565504156	0.094318604	0.2899788	0.096528345	0.076206761	0.761399852	0.33298047
2018-07	0.535869172	0.098774601	0.357273821	0.099206938	0.077418442	0.870397466	0.317036813
2018-08	0.560986628	0.135165243	0.422276972	0.110521367	0.082492742	0.196708825	0.140900449
2018-09	0.613209252	0.158930561	0.596630952	0.13836513	0.096749988	0.769016456	0.064617179
2018-10	0.54201301	0.139992573	0.606443018	0.131690298	0.103165133	0.796636668	0.054657795
2018-11	0.387242501	0.121797252	0.550449779	0.102145349	0.099603897	0.761710529	0.33527048
2018-12	0.322732201	0.119569254	0.512189881	0.100301883	0.09861979	0.726543866	0.515619599
2019-01	0.430159017	0.121797252	0.512906091	0.098879074	0.10119692	0.618708785	0
2019-02	0.453379111	0.117712588	0.434552799	0.098811026	0.101590562	0.705698423	0.09637487
2019-03	0.479580773	0.124396584	0.342920988	0.096107688	0.104112336	0.778567277	0.327925164
2019-04	0.518070112	0.135536576	0.385492465	0.098093435	0.10830709	0.739592311	0.159847045
2019-05	0.469190459	0.147047902	0.457457171	0.105269344	0.1106997	0.86873384	0.224075354
2019-06	0.4758764	0.138135908	0.488913081	0.107329325	0.110767357	0.645537271	0.308589699
2019-07	0.444705457	0.132937245	0.452171546	0.127712617	0.114217881	0.76741296	0.061138956
2019-08	0.417329237	0.131080579	0.322924426	0.121743003	0.116432121	0.216732477	0.088943139
2019-09	0.416877485	0.134422577	0.245545178	0.120085121	0.119015401	0.80874306	0.286229692
2019-10	0.40160824	0.137021909	0.126511202	0.121656398	0.124274221	0.840973322	0.214548047
2019-11	0.448590531	0.135165243	0.095570962	0.121959518	0.125295232	0.840171574	0.380984272
2019-12	0.478135164	0.139249907	0.061049676	0.124031871	0.127294199	0.855164258	0.708866229
2020-01	0.387784604	0.142220572	0.069959319	0.12523198	0.130953845	0.658786154	0.089828897
2020-02	0.329418142	0.146676569	0.043144445	0.124897929	0.1319195	0.780982542	0.27583823
2020-03	0	0.156702562	0.04973357	0.128405464	0.133494071	0.625683991	0.280612686
2020-04	0.029454283	0.17564055	0.065776657	0.135705095	0.135862077	0	0.041501037
2020-05	0.174376581	0.18046788	0.043144445	0.14184792	0.13966934	0.336764146	0.157686657
2020-06	0.242049151	0.175269216	0.000601616	0.150786876	0.142879988	0.647441422	0.52996457
2020-07	0.255511384	0.176754549	0	0.156539975	0.14455297	0.681936622	0.642391116
2020-08	0.274394651	0.191607872	0.079384633	0.159985648	0.14704399	0.356276683	0.343674386
2020-09	0.229942176	0.201262532	0.149071793	0.170217504	0.149873296	0.809624982	0.713511061
2020-10	0.194073003	0.214630524	0.167249184	0.178067701	0.156128524	0.864424445	0.692058417
2020-11	0.289031442	0.219457854	0.206225291	0.203925717	0.163017271	0.815838528	0.614392499
2020-12	0.328604987	0.209060527	0.158525755	0.215388613	0.166849136	0.828195466	0.799516073
2021-01	0.365016263	0.196806535	0.212742795	0.216044342	0.172071053	0.592451544	0.20931991
2021-02	0.460878207	0.184923877	0.218114364	0.217553757	0.174937263	0.585716863	0.345100242
2021-03	0.439736176	0.20571853	0.221838652	0.219044614	0.178363185	0.654767393	0.62003111
2021-04	0.477773762	0.225399183	0.28963502	0.229783733	0.183769621	0.668186647	0.368129969
2021-05	0.492500904	0.232083179	0.308571592	0.234144953	0.186678886	0.574402197	0.330193571
2021-06	0.560986628	0.241737839	0.298473042	0.238803108	0.193094031	0.528953118	0.532751469
2021-07	0.568033972	0.242109172	0.304818656	0.240164056	0.19917089	0.239201459	0.223081576
2021-08	0.529454283	0.237281842	0.291669054	0.230990028	0.203008906	0.499869716	0.397986519
2021-09	0.568847127	0.238395841	0.27820432	0.232023111	0.207351277	0.497825259	0.31450916
2021-10	0.616642573	0.261789825	0.26115854	0.23264791	0.215753088	0.550961095	0.330884895
2021-11	0.506053488	0.313033791	0.282000229	0.250123723	0.228374256	0.614469544	0.353806602
2021-12	0.563697145	0.42480505	0.378444966	0.3923923	0.27887738	0.670551803	0.422744556
2022-01	0.700216841	0.424433717	0.476594282	0.399098063	0.325794666	0.382002766	0.220078638
2022-02	0.797162992	0.428147048	0.436558185	0.39935788	0.348367613	0.51996352	0.287504321

2022-03	0.835200578	0.463423691	0.394803186	0.435911712	0.375252177	0.474835141	0.402501728
2022-04	0.844868088	0.467508355	0.37838767	0.457674511	0.412863504	0.532921769	0.404359661
2022-05	1	0.502413665	0.360640005	0.470888081	0.429451853	0.57626626	0.427281369
2022-06	0.948048428	0.552172299	0.384561393	0.489898053	0.457831029	0.770920607	0.620355168
2022-07	0.873328515	0.568139621	0.455910159	0.515180759	0.472057521	0.41223868	0.348880919
2022-08	0.738164077	0.590419606	0.462413339	0.53048524	0.481049796	0.530145718	0.235417387
2022-09	0.669045898	0.601188266	0.434710365	0.533324673	0.500264479	0.651851035	0.330820083
2022-10	0.708800145	0.611585592	0.421661032	0.541880088	0.523089603	0.528171414	0.357738507
2022-11	0.639320564	0.612699592	0.393943735	0.55598446	0.542316587	0.745004109	0.48850674
2022-12	0.614112757	0.614556257	0.38119521	0.545560834	0.550429317	0.840432142	0.86802195
2023-01	0.619533791	0.619012254	0.394516702	0.569049563	0.596577769	0.61195406	0.224529036
2023-02	0.617636429	0.621240253	0.393227525	0.595223072	0.619858043	0.542081738	0.492049775
2023-03	0.581315504	0.626810249	0.382054661	0.604261005	0.637338237	0.78086228	0.632626167
2023-04	0.600560173	0.639064241	0.386065433	0.633453344	0.655968607	0.641157724	0.603309713
2023-05	0.51617275	0.653174898	0.463774136	0.678278029	0.656313044	0.812551362	0.643384895
2023-06	0.539031442	0.778685481	0.628258752	0.756210873	0.687675294	0.664578782	0.758598341
2023-07	0.635796892	0.903453398	0.82732195	0.89212011	0.766557595	0.787246197	0.487361735
2023-08	0.654499458	0.923134051	0.753767261	0.978243387	0.84926561	0.397256018	0.366790529
2023-09	0.731929888	0.922762718	0.897152352	0.981818969	0.896459676	0.78411938	0.569240408
2023-10	0.650252982	0.954697364	1	0.977921708	0.932176598	0.820288228	0.640273937
2023-11	0.604174196	0.984032677	0.925514238	0.985951303	0.967475274	0.874516446	0.657124957
2023-12	0.56776292	1	0.680857159	1	1	0.669008438	0.960184065

EK-4 Çoklu Regresyon Analizi Modeli Tahmin Değerleri

Tarih	Gerçek Değer	Regresyon Model Tahmini	Hata	Mutlak Hata	Hata Karesi	Mutlak Hata/Gerçek Değer Yüzdesi
2014-01	11245	18996	-7751	7751	60078001	68.93%
2014-02	11563	16329	-4766	4766	22714756	41.22%
2014-03	14724	18832	-4108	4108	16875664	27.90%
2014-04	19073	18746	327	327	106929	1.71%
2014-05	20036	20026	10	10	100	0.05%
2014-06	21131	20343	788	788	620944	3.73%
2014-07	21787	20008	1779	1779	3164841	8.17%
2014-08	18463	16798	1665	1665	2772225	9.02%
2014-09	23721	22891	830	830	688900	3.50%
2014-10	22157	20678	1479	1479	2187441	6.68%
2014-11	26439	22854	3585	3585	12852225	13.56%
2014-12	49543	24192	25351	25351	642673201	51.17%
2015-01	10607	22062	-11455	11455	131217025	107.99%
2015-02	17373	21522	-4149	4149	17214201	23.88%
2015-03	26449	24742	1707	1707	2913849	6.45%
2015-04	30653	22276	8377	8377	70174129	27.33%
2015-05	24710	18786	5924	5924	35093776	23.97%
2015-06	29489	24113	5376	5376	28901376	18.23%
2015-07	27091	20645	6446	6446	41550916	23.79%
2015-08	24511	15931	8580	8580	73616400	35.00%
2015-09	20778	20811	-33	33	1089	0.16%
2015-10	21578	23254	-1676	1676	2808976	7.77%
2015-11	25498	22767	2731	2731	7458361	10.71%
2015-12	51935	23790	28145	28145	792141025	54.19%
2016-01	11430	20844	-9414	9414	88623396	82.36%
2016-02	17859	22538	-4679	4679	21893041	26.20%
2016-03	28341	23199	5142	5142	26440164	18.14%
2016-04	28858	22364	6494	6494	42172036	22.50%
2016-05	31234	23441	7793	7793	60730849	24.95%
2016-06	29097	23309	5788	5788	33500944	19.89%
2016-07	17766	23181	-5415	5415	29322225	30.48%
2016-08	20611	19046	1565	1565	2449225	7.59%
2016-09	19124	24937	-5813	5813	33790969	30.40%
2016-10	25085	29272	-4187	4187	17530969	16.69%
2016-11	38511	31066	7445	7445	55428025	19.33%
2016-12	49645	31116	18529	18529	343323841	37.32%
2017-01	12976	27723	-14747	14747	217474009	113.65%
2017-02	15687	27929	-12242	12242	149866564	78.04%
2017-03	25930	30832	-4902	4902	24029604	18.90%
2017-04	26500	29085	-2585	2585	6682225	9.75%
2017-05	31513	29842	1671	1671	2792241	5.30%
2017-06	32275	28451	3824	3824	14622976	11.85%
2017-07	29074	28586	488	488	238144	1.68%
2017-08	24490	17121	7369	7369	54302161	30.09%
2017-09	23865	26049	-2184	2184	4769856	9.15%
2017-10	29705	29211	494	494	244036	1.66%
2017-11	32793	30970	1823	1823	3323329	5.56%
2017-12	46220	23818	22402	22402	501849604	48.47%
2018-01	13566	24138	-10572	10572	111767184	77.93%
2018-02	17245	25712	-8467	8467	71690089	49.10%
2018-03	27459	29604	-2145	2145	4601025	7.81%

2018-04	26416	24817	1599	1599	2556801	6.05%
2018-05	28104	24996	3108	3108	9659664	11.06%
2018-06	21060	21282	-222	222	49284	1.05%
2018-07	20322	21446	-1124	1124	1263376	5.53%
2018-08	12169	2610	9559	9559	91374481	78.55%
2018-09	8638	12086	-3448	3448	11888704	39.92%
2018-10	8177	13845	-5668	5668	32126224	69.32%
2018-11	21166	13496	7670	7670	58828900	36.24%
2018-12	29514	14638	14876	14876	221295376	50.40%
2019-01	5647	11581	-5934	5934	35212356	105.08%
2019-02	10108	16193	-6085	6085	37027225	60.20%
2019-03	20826	20822	4	4	16	0.02%
2019-04	13046	17713	-4667	4667	21780889	35.77%
2019-05	16019	18600	-2581	2581	6661561	16.11%
2019-06	19931	12992	6939	6939	48149721	34.82%
2019-07	8477	18064	-9587	9587	91910569	113.09%
2019-08	9764	7395	2369	2369	5612161	24.26%
2019-09	18896	25142	-6246	6246	39012516	33.05%
2019-10	15578	29284	-13706	13706	187854436	87.98%
2019-11	23282	30083	-6801	6801	46253601	29.21%
2019-12	38459	31440	7019	7019	49266361	18.25%
2020-01	9805	27573	-17768	17768	315701824	181.21%
2020-02	18415	30947	-12532	12532	157051024	68.05%
2020-03	18636	28283	-9647	9647	93064609	51.77%
2020-04	7568	16872	-9304	9304	86564416	122.94%
2020-05	12946	24132	-11186	11186	125126596	86.41%
2020-06	30178	29856	322	322	103684	1.07%
2020-07	35382	31813	3569	3569	12737761	10.09%
2020-08	21555	20897	658	658	432964	3.05%
2020-09	38674	30235	8439	8439	71216721	21.82%
2020-10	37681	30747	6934	6934	48080356	18.40%
2020-11	34086	28758	5328	5328	28387584	15.63%
2020-12	42655	30742	11913	11913	141919569	27.93%
2021-01	15336	23753	-8417	8417	70845889	54.88%
2021-02	21621	23748	-2127	2127	4524129	9.84%
2021-03	34347	25135	9212	9212	84860944	26.82%
2021-04	22687	23456	-769	769	591361	3.39%
2021-05	20931	20335	596	596	355216	2.85%
2021-06	30307	20242	10065	10065	101304225	33.21%
2021-07	15973	12970	3003	3003	9018009	18.80%
2021-08	24069	19450	4619	4619	21335161	19.19%
2021-09	20205	20674	-469	469	219961	2.32%
2021-10	20963	21594	-631	631	398161	3.01%
2021-11	22024	23317	-1293	1293	1671849	5.87%
2021-12	25215	24754	461	461	212521	1.83%
2022-01	15834	14902	932	932	868624	5.89%
2022-02	18955	19589	-634	634	401956	3.34%
2022-03	24278	20967	3311	3311	10962721	13.64%
2022-04	24364	23839	525	525	275625	2.15%
2022-05	25425	25547	-122	122	14884	0.48%
2022-06	34362	29330	5032	5032	25321024	14.64%
2022-07	21796	21020	776	776	602176	3.56%
2022-08	16544	23734	-7190	7190	51696100	43.46%
2022-09	20960	28184	-7224	7224	52186176	34.47%
2022-10	22206	26135	-3929	3929	15437041	17.69%
2022-11	28259	32061	-3802	3802	14455204	13.45%
2022-12	45826	34650	11176	11176	124902976	24.39%

2023-01	16040	30997	-14957	14957	223711849	93.25%
2023-02	28423	30018	-1595	1595	2544025	5.61%
2023-03	34930	36217	-1287	1287	1656369	3.68%
2023-04	33573	33775	-202	202	40804	0.60%
2023-05	35428	35860	-432	432	186624	1.22%
2023-06	40761	29669	11092	11092	123032464	27.21%
2023-07	28206	30524	-2318	2318	5373124	8.22%
2023-08	22625	26832	-4207	4207	17698849	18.59%
2023-09	31996	28388	3608	3608	13017664	11.28%
2023-10	35284	28402	6882	6882	47361924	19.50%
2023-11	36064	30557	5507	5507	30327049	15.27%
2023-12	50092	36741	13351	13351	178249201	26.65%



EK-5 NARX Modeli Tahmin Değerleri

Tarih	Gerçek Değer	NARX Modeli Tahmini	Hata	Mutlak Hata	Hata Karesi	Mutlak Hata/Gerçek Değer Yüzdesi
2014-01	11245	23527	-12282	12282	150847524	109.22%
2014-02	11563	19695	-8132	8132	66129424	70.33%
2014-03	14724	1999	12725	12725	161925625	86.42%
2014-04	19073	20206	-1133	1133	1283689	5.94%
2014-05	20036	20974	-938	938	879844	4.68%
2014-06	21131	20251	880	880	774400	4.16%
2014-07	21787	22540	-753	753	567009	3.46%
2014-08	18463	20655	-2192	2192	4804864	11.87%
2014-09	23721	24039	-318	318	101124	1.34%
2014-10	22157	26350	-4193	4193	17581249	18.92%
2014-11	26439	10394	16045	16045	257442025	60.69%
2014-12	49543	15058	34485	34485	1189215225	69.61%
2015-01	10607	30666	-20059	20059	402363481	189.11%
2015-02	17373	32987	-15614	15614	243796996	89.88%
2015-03	26449	19251	7198	7198	51811204	27.21%
2015-04	30653	26367	4286	4286	18369796	13.98%
2015-05	24710	25935	-1225	1225	1500625	4.96%
2015-06	29489	27552	1937	1937	3751969	6.57%
2015-07	27091	21017	6074	6074	36893476	22.42%
2015-08	24511	27637	-3126	3126	9771876	12.75%
2015-09	20778	26001	-5223	5223	27279729	25.14%
2015-10	21578	31886	-10308	10308	106254864	47.77%
2015-11	25498	11182	14316	14316	204947856	56.15%
2015-12	51935	17359	34576	34576	1195499776	66.58%
2016-01	11430	27146	-15716	15716	246992656	137.50%
2016-02	17859	32728	-14869	14869	221087161	83.26%
2016-03	28341	26167	2174	2174	4726276	7.67%
2016-04	28858	21753	7105	7105	50481025	24.62%
2016-05	31234	28489	2745	2745	7535025	8.79%
2016-06	29097	25023	4074	4074	16597476	14.00%
2016-07	17766	35467	-17701	17701	313325401	99.63%
2016-08	20611	21828	-1217	1217	1481089	5.90%
2016-09	19124	27447	-8323	8323	69272329	43.52%
2016-10	25085	24419	666	666	443556	2.65%
2016-11	38511	11185	27326	27326	746710276	70.96%
2016-12	49645	17696	31949	31949	1020738601	64.35%
2017-01	12976	20213	-7237	7237	52374169	55.77%
2017-02	15687	32777	-17090	17090	292068100	108.94%

2017-03	25930	34755	-8825	8825	77880625	34.03%
2017-04	26500	36039	-9539	9539	90992521	36.00%
2017-05	31513	31785	-272	272	73984	0.86%
2017-06	32275	34210	-1935	1935	3744225	6.00%
2017-07	29074	26016	3058	3058	9351364	10.52%
2017-08	24490	22153	2337	2337	5461569	9.54%
2017-09	23865	32690	-8825	8825	77880625	36.98%
2017-10	29705	35050	-5345	5345	28569025	17.99%
2017-11	32793	12306	20487	20487	419717169	62.47%
2017-12	46220	13940	32280	32280	104199840 0	69.84%
2018-01	13566	26627	-13061	13061	170589721	96.28%
2018-02	17245	30517	-13272	13272	176145984	76.96%
2018-03	27459	26131	1328	1328	1763584	4.84%
2018-04	26416	19982	6434	6434	41396356	24.36%
2018-05	28104	21242	6862	6862	47087044	24.42%
2018-06	21060	16273	4787	4787	22915369	22.73%
2018-07	20322	8995	11327	11327	128300929	55.74%
2018-08	12169	7402	4767	4767	22724289	39.17%
2018-09	8638	20756	-12118	12118	146845924	140.29%
2018-10	8177	30401	-22224	22224	493906176	271.79%
2018-11	21166	66303	-45137	45137	203734876 9	213.25%
2018-12	29514	11222	18292	18292	334597264	61.98%
2019-01	5647	15090	-9443	9443	89170249	167.22%
2019-02	10108	12418	-2310	2310	5336100	22.85%
2019-03	20826	5613	15213	15213	231435369	73.05%
2019-04	13046	10788	2258	2258	5098564	17.31%
2019-05	16019	19458	-3439	3439	11826721	21.47%
2019-06	19931	15414	4517	4517	20403289	22.66%
2019-07	8477	23093	-14616	14616	213627456	172.42%
2019-08	9764	33977	-24213	24213	586269369	247.98%
2019-09	18896	14313	4583	4583	21003889	24.25%
2019-10	15578	9978	5600	5600	31360000	35.95%
2019-11	23282	20352	2930	2930	8584900	12.58%
2019-12	38459	7590	30869	30869	952895161	80.26%
2020-01	9805	14204	-4399	4399	19351201	44.86%
2020-02	18415	29288	-10873	10873	118222129	59.04%
2020-03	18636	35446	-16810	16810	282576100	90.20%
2020-04	7568	33721	-26153	26153	683979409	345.57%
2020-05	12946	27223	-14277	14277	203832729	110.28%
2020-06	30178	36225	-6047	6047	36566209	20.04%
2020-07	35382	34045	1337	1337	1787569	3.78%
2020-08	21555	37391	-15836	15836	250778896	73.47%
2020-09	38674	17942	20732	20732	429815824	53.61%

2020-10	37681	20929	16752	16752	280629504	44.46%
2020-11	34086	35372	-1286	1286	1653796	3.77%
2020-12	42655	16723	25932	25932	672468624	60.79%
2021-01	15336	24335	-8999	8999	80982001	58.68%
2021-02	21621	25474	-3853	3853	14845609	17.82%
2021-03	34347	14994	19353	19353	374538609	56.35%
2021-04	22687	24662	-1975	1975	3900625	8.71%
2021-05	20931	21512	-581	581	337561	2.78%
2021-06	30307	22434	7873	7873	61984129	25.98%
2021-07	15973	20900	-4927	4927	24275329	30.85%
2021-08	24069	14244	9825	9825	96530625	40.82%
2021-09	20205	16345	3860	3860	14899600	19.10%
2021-10	20963	18841	2122	2122	4502884	10.12%
2021-11	22024	24596	-2572	2572	6615184	11.68%
2021-12	25215	22853	2362	2362	5579044	9.37%
2022-01	15834	26294	-10460	10460	109411600	66.06%
2022-02	18955	33200	-14245	14245	202920025	75.15%
2022-03	24278	22309	1969	1969	3876961	8.11%
2022-04	24364	14679	9685	9685	93799225	39.75%
2022-05	25425	19147	6278	6278	39413284	24.69%
2022-06	34362	24715	9647	9647	93064609	28.07%
2022-07	21796	28981	-7185	7185	51624225	32.96%
2022-08	16544	32635	-16091	16091	258920281	97.26%
2022-09	20960	15798	5162	5162	26646244	24.63%
2022-10	22206	28310	-6104	6104	37258816	27.49%
2022-11	28259	33596	-5337	5337	28483569	18.89%
2022-12	45826	43390	2436	2436	5934096	5.32%
2023-01	16040	39942	-23902	23902	571305604	149.01%
2023-02	28423	51083	-22660	22660	513475600	79.72%
2023-03	34930	27469	7461	7461	55666521	21.36%
2023-04	33573	22575	10998	10998	120956004	32.76%
2023-05	35428	41037	-5609	5609	31460881	15.83%
2023-06	40761	35129	5632	5632	31719424	13.82%
2023-07	28206	45020	-16814	16814	282710596	59.61%
2023-08	22625	49545	-26920	26920	724686400	118.98%
2023-09	31996	35842	-3846	3846	14791716	12.02%
2023-10	35284	37784	-2500	2500	6250000	7.09%
2023-11	36064	30490	5574	5574	31069476	15.46%
2023-12	50092	52198	-2106	2106	4435236	4.20%

EK-6 YSA Modeli Tahmin Değerleri

Tarih	Gerçek Değer	YSA Modeli Tahmini	Hata	Mutlak Hata	Hata Karesi	Mutlak Hata/Gerçek Değer Yüzdesi
2014-01	11245	16468	-5223	5223	27279729	46.45%
2014-02	11563	16146	-4583	4583	21003889	39.64%
2014-03	14724	18499	-3775	3775	14250625	25.64%
2014-04	19073	18878	195	195	38025	1.02%
2014-05	20036	18865	1171	1171	1371241	5.84%
2014-06	21131	19736	1395	1395	1946025	6.60%
2014-07	21787	19021	2766	2766	7650756	12.70%
2014-08	18463	15241	3222	3222	10381284	17.45%
2014-09	23721	22740	981	981	962361	4.14%
2014-10	22157	23051	-894	894	799236	4.03%
2014-11	26439	27455	-1016	1016	1032256	3.84%
2014-12	49543	29356	20187	20187	407514969	40.75%
2015-01	10607	26858	-16251	16251	264095001	153.21%
2015-02	17373	28406	-11033	11033	121727089	63.51%
2015-03	26449	29678	-3229	3229	10426441	12.21%
2015-04	30653	28244	2409	2409	5803281	7.86%
2015-05	24710	26176	-1466	1466	2149156	5.93%
2015-06	29489	28952	537	537	288369	1.82%
2015-07	27091	27238	-147	147	21609	0.54%
2015-08	24511	24047	464	464	215296	1.89%
2015-09	20778	25418	-4640	4640	21529600	22.33%
2015-10	21578	25906	-4328	4328	18731584	20.06%
2015-11	25498	24481	1017	1017	1034289	3.99%
2015-12	51935	23773	28162	28162	793098244	54.23%
2016-01	11430	19481	-8051	8051	64818601	70.44%
2016-02	17859	22686	-4827	4827	23299929	27.03%
2016-03	28341	23588	4753	4753	22591009	16.77%
2016-04	28858	24420	4438	4438	19695844	15.38%
2016-05	31234	25571	5663	5663	32069569	18.13%
2016-06	29097	26456	2641	2641	6974881	9.08%
2016-07	17766	22922	-5156	5156	26584336	29.02%
2016-08	20611	22474	-1863	1863	3470769	9.04%
2016-09	19124	26201	-7077	7077	50083929	37.01%
2016-10	25085	29320	-4235	4235	17935225	16.88%
2016-11	38511	32303	6208	6208	38539264	16.12%
2016-12	49645	32895	16750	16750	280562500	33.74%
2017-01	12976	28662	-15686	15686	246050596	120.88%
2017-02	15687	28995	-13308	13308	177102864	84.83%
2017-03	25930	31831	-5901	5901	34821801	22.76%

2017-04	26500	29834	-3334	3334	11115556	12.58%
2017-05	31513	30203	1310	1310	1716100	4.16%
2017-06	32275	28271	4004	4004	16032016	12.41%
2017-07	29074	28493	581	581	337561	2.00%
2017-08	24490	22309	2181	2181	4756761	8.91%
2017-09	23865	26908	-3043	3043	9259849	12.75%
2017-10	29705	30001	-296	296	87616	1.00%
2017-11	32793	32720	73	73	5329	0.22%
2017-12	46220	28611	17609	17609	310076881	38.10%
2018-01	13566	26124	-12558	12558	157703364	92.57%
2018-02	17245	26328	-9083	9083	82500889	52.67%
2018-03	27459	28887	-1428	1428	2039184	5.20%
2018-04	26416	27227	-811	811	657721	3.07%
2018-05	28104	27134	970	970	940900	3.45%
2018-06	21060	22022	-962	962	925444	4.57%
2018-07	20322	19348	974	974	948676	4.79%
2018-08	12169	11017	1152	1152	1327104	9.47%
2018-09	8638	10356	-1718	1718	2951524	19.89%
2018-10	8177	10751	-2574	2574	6625476	31.48%
2018-11	21166	17321	3845	3845	14784025	18.17%
2018-12	29514	20564	8950	8950	80102500	30.32%
2019-01	5647	13076	-7429	7429	55190041	131.56%
2019-02	10108	13798	-3690	3690	13616100	36.51%
2019-03	20826	15478	5348	5348	28601104	25.68%
2019-04	13046	13065	-19	19	361	0.15%
2019-05	16019	14393	1626	1626	2643876	10.15%
2019-06	19931	11330	8601	8601	73977201	43.15%
2019-07	8477	15828	-7351	7351	54037201	86.72%
2019-08	9764	10591	-827	827	683929	8.47%
2019-09	18896	20824	-1928	1928	3717184	10.20%
2019-10	15578	25967	-10389	10389	107931321	66.69%
2019-11	23282	27661	-4379	4379	19175641	18.81%
2019-12	38459	30457	8002	8002	64032004	20.81%
2020-01	9805	25561	-15756	15756	248251536	160.69%
2020-02	18415	28148	-9733	9733	94731289	52.85%
2020-03	18636	24206	-5570	5570	31024900	29.89%
2020-04	7568	7643	-75	75	5625	0.99%
2020-05	12946	19615	-6669	6669	44475561	51.51%
2020-06	30178	29073	1105	1105	1221025	3.66%
2020-07	35382	30597	4785	4785	22896225	13.52%
2020-08	21555	22888	-1333	1333	1776889	6.18%
2020-09	38674	30931	7743	7743	59954049	20.02%
2020-10	37681	33607	4074	4074	16597476	10.81%
2020-11	34086	31042	3044	3044	9265936	8.93%

2020-12	42655	33027	9628	9628	92698384	22.57%
2021-01	15336	25499	-10163	10163	103286569	66.27%
2021-02	21621	24517	-2896	2896	8386816	13.39%
2021-03	34347	25412	8935	8935	79834225	26.01%
2021-04	22687	23101	-414	414	171396	1.82%
2021-05	20931	21303	-372	372	138384	1.78%
2021-06	30307	22397	7910	7910	62568100	26.10%
2021-07	15973	17288	-1315	1315	1729225	8.23%
2021-08	24069	19178	4891	4891	23921881	20.32%
2021-09	20205	20444	-239	239	57121	1.18%
2021-10	20963	23789	-2826	2826	7986276	13.48%
2021-11	22024	22709	-685	685	469225	3.11%
2021-12	25215	29523	-4308	4308	18558864	17.09%
2022-01	15834	16220	-386	386	148996	2.44%
2022-02	18955	20435	-1480	1480	2190400	7.81%
2022-03	24278	23579	699	699	488601	2.88%
2022-04	24364	21785	2579	2579	6651241	10.59%
2022-05	25425	29128	-3703	3703	13712209	14.56%
2022-06	34362	28065	6297	6297	39652209	18.33%
2022-07	21796	18098	3698	3698	13675204	16.97%
2022-08	16544	19705	-3161	3161	9991921	19.11%
2022-09	20960	23741	-2781	2781	7733961	13.27%
2022-10	22206	19419	2787	2787	7767369	12.55%
2022-11	28259	29833	-1574	1574	2477476	5.57%
2022-12	45826	35480	10346	10346	107039716	22.58%
2023-01	16040	24749	-8709	8709	75846681	54.30%
2023-02	28423	23387	5036	5036	25361296	17.72%
2023-03	34930	38352	-3422	3422	11710084	9.80%
2023-04	33573	31432	2141	2141	4583881	6.38%
2023-05	35428	45366	-9938	9938	98763844	28.05%
2023-06	40761	33522	7239	7239	52403121	17.76%
2023-07	28206	31716	-3510	3510	12320100	12.44%
2023-08	22625	25949	-3324	3324	11048976	14.69%
2023-09	31996	32456	-460	460	211600	1.44%
2023-10	35284	32816	2468	2468	6091024	6.99%
2023-11	36064	41444	-5380	5380	28944400	14.92%
2023-12	50092	49410	682	682	465124	1.36%

EK-7 ÇRA Modelinde Kullanılan Kodlar

```
function [trainedModel, validationRMSE] = trainRegressionModel(trainingData)
% [trainedModel, validationRMSE] = trainRegressionModel(trainingData)
% Returns a trained regression model and its RMSE. This code recreates the
% model trained in Regression Learner app. Use the generated code to
% automate training the same model with new data, or to learn how to
% programmatically train models.
%
% Input:
%   trainingData: A matrix with the same number of columns and data type
%   as the matrix imported into the app.
%
% Output:
%   trainedModel: A struct containing the trained regression model. The
%   struct contains various fields with information about the trained
%   model.
%   trainedModel.predictFcn: A function to make predictions on new data.
%   validationRMSE: A double containing the RMSE. In the app, the
%   History list displays the RMSE for each model.
%
% Use the code to train the model with new data. To retrain your model,
% call the function from the command line with your original data or new
% data as the input argument trainingData.
%
% For example, to retrain a regression model trained with the original data
% set T, enter:
% [trainedModel, validationRMSE] = trainRegressionModel(T)
%
% To make predictions with the returned 'trainedModel' on new data T2, use
% yfit = trainedModel.predictFcn(T2)
%
% T2 must be a matrix containing only the predictor columns used for
% training. For details, enter:
%   trainedModel.HowToPredict

% Auto-generated by MATLAB on 04-May-2024 19:38:47

% Extract predictors and response
% This code processes the data into the right shape for training the
% model.
% Convert input to table
inputTable = array2table(trainingData, 'VariableNames', {'column_1', 'column_2',
'column_3', 'column_4', 'column_5', 'column_6', 'column_7'});
```

```

predictorNames = {'column_1', 'column_2', 'column_3', 'column_4', 'column_5',
'column_6'};
predictors = inputTable(:, predictorNames);
response = inputTable.column_7;
isCategoricalPredictor = [false, false, false, false, false, false];

% Train a regression model
% This code specifies all the model options and trains the model.
concatenatedPredictorsAndResponse = predictors;
concatenatedPredictorsAndResponse.column_7 = response;
linearModel = fitlm(...
    concatenatedPredictorsAndResponse, ...
    'linear', ...
    'RobustOpts', 'off');

% Create the result struct with predict function
predictorExtractionFcn = @(x) array2table(x, 'VariableNames', predictorNames);
linearModelPredictFcn = @(x) predict(linearModel, x);
trainedModel.predictFcn = @(x) linearModelPredictFcn(predictorExtractionFcn(x));

% Add additional fields to the result struct
trainedModel.LinearModel = linearModel;
trainedModel.About = 'This struct is a trained model exported from Regression
Learner R2020b.';
trainedModel.HowToPredict = sprintf('To make predictions on a new predictor
column matrix, X, use: \n yfit = c.predictFcn(X) \nreplacing "c" with the name of the
variable that is this struct, e.g. "trainedModel". \n \nX must contain exactly 6
columns because this model was trained using 6 predictors. \nX must contain only
predictor columns in exactly the same order and format as your training \ndata. Do
not include the response column or any columns you did not import into the app. \n
\nFor more information, see <a href="matlab:helpview(fullfile(docroot, "stats",
"stats.map"), "appregression_exportmodeltoworkspace")">How to predict using an
exported model</a>');

% Extract predictors and response
% This code processes the data into the right shape for training the
% model.
% Convert input to table
inputTable = array2table(trainingData, 'VariableNames', {'column_1', 'column_2',
'column_3', 'column_4', 'column_5', 'column_6', 'column_7'});

predictorNames = {'column_1', 'column_2', 'column_3', 'column_4', 'column_5',
'column_6'};
predictors = inputTable(:, predictorNames);
response = inputTable.column_7;
isCategoricalPredictor = [false, false, false, false, false, false];

% Perform cross-validation
KFolds = 5;

```

```

cvp = cvpartition(size(response, 1), 'KFold', KFold);
% Initialize the predictions to the proper sizes
validationPredictions = response;
for fold = 1:KFold
    trainingPredictors = predictors(cvp.training(fold), :);
    trainingResponse = response(cvp.training(fold), :);
    foldIsCategoricalPredictor = isCategoricalPredictor;

    % Train a regression model
    % This code specifies all the model options and trains the model.
    concatenatedPredictorsAndResponse = trainingPredictors;
    concatenatedPredictorsAndResponse.column_7 = trainingResponse;
    linearModel = fitlm(...
        concatenatedPredictorsAndResponse, ...
        'linear', ...
        'RobustOpts', 'off');

    % Create the result struct with predict function
    linearModelPredictFcn = @(x) predict(linearModel, x);
    validationPredictFcn = @(x) linearModelPredictFcn(x);

    % Add additional fields to the result struct

    % Compute validation predictions
    validationPredictors = predictors(cvp.test(fold), :);
    foldPredictions = validationPredictFcn(validationPredictors);

    % Store predictions in the original order
    validationPredictions(cvp.test(fold), :) = foldPredictions;
end

% Compute validation RMSE
isNotMissing = ~isnan(validationPredictions) & ~isnan(response);
validationRMSE = sqrt(nansum(( validationPredictions - response ).^2) /
    numel(response(isNotMissing) ));

```

EK-8 NARX Modelinde Kullanılan Kodlar

```
function [Y,Xf,Af] = myNeuralNetworkFunction(X,Xi,~)
%MYNEURALNETWORKFUNCTION neural network simulation function.
%
% Auto-generated by MATLAB, 04-May-2024 20:31:46.
%
% [Y,Xf,Af] = myNeuralNetworkFunction(X,Xi,~) takes these arguments:
%
% X = 2xTS cell, 2 inputs over TS timesteps
% Each X{1,ts} = 6xQ matrix, input #1 at timestep ts.
% Each X{2,ts} = 1xQ matrix, input #2 at timestep ts.
%
% Xi = 2x2 cell 2, initial 2 input delay states.
% Each Xi{1,ts} = 6xQ matrix, initial states for input #1.
% Each Xi{2,ts} = 1xQ matrix, initial states for input #2.
%
% Ai = 2x0 cell 2, initial 2 layer delay states.
% Each Ai{1,ts} = 10xQ matrix, initial states for layer #1.
% Each Ai{2,ts} = 1xQ matrix, initial states for layer #2.
%
% and returns:
% Y = 1xTS cell of 2 outputs over TS timesteps.
% Each Y{1,ts} = 1xQ matrix, output #1 at timestep ts.
%
% Xf = 2x2 cell 2, final 2 input delay states.
% Each Xf{1,ts} = 6xQ matrix, final states for input #1.
% Each Xf{2,ts} = 1xQ matrix, final states for input #2.
%
% Af = 2x0 cell 2, final 0 layer delay states.
% Each Af{1ts} = 10xQ matrix, final states for layer #1.
% Each Af{2ts} = 1xQ matrix, final states for layer #2.
%
% where Q is number of samples (or series) and TS is the number of timesteps.

%#ok<*RPMT0>

% ===== NEURAL NETWORK CONSTANTS =====

% Input 1
x1_step1.xoffset = [0;0;0;0;0;0];
x1_step1.gain = [2;2;2;2;2;2];
x1_step1.ymin = -1;

% Input 2
x2_step1.xoffset = 0;
x2_step1.gain = 2;
x2_step1.ymin = -1;
```

% Layer 1

b1 = [-1.3352299929601829653;1.1878068524915452731;-
0.8295982718850262172;-0.44305481520646317062;-0.26046798252382763472;-
0.74350894425081659467;-0.5182659064817073391;-0.6436609153427296226;-
1.058379761442389988;1.6875122418036594407];
IW1_1 = [0.59452751297600481273 -0.47623740044909046443
0.49820383525710087991 0.62622022827438184045 -0.025608440617991133637
0.44566464572982955605 -0.60284316088157985369 0.37872775744761205674
0.61207987173068534315 0.52236167960875112826 -0.57589647759753315182 -
0.73354613411350944041;-0.12251137851360445474 0.61191167020076298044
0.58604707148734869193 0.034582447152822555492 0.50001515620498182546
0.48077934726966031764 -0.5790970961769715819 -0.75048897734755815048
0.028755448922409491963 0.0017475182503533491507 0.12297970895188378715
0.39588736469347429736;0.8064450641365570327 0.78175696879926215299
0.1051087469543238867 -0.75206592873235855734 0.79953805488740370411 -
0.42744001330610303935 0.32842311237774574062 -0.33403208372996279207 -
0.81405655990044978321 -0.39498778390366329205 0.27103782813067417434
0.25097174510040698436;0.92184008646012149946 0.61354717287626159283 -
0.059341284816679037983 0.42296082347441882332 0.44960071084926034324
0.33645072304472239955 -0.07046712338350498428 -0.06355765168171896573 -
0.88712702361044093458 0.76766637176319019176 0.66258791680926698575 -
0.79319194299034678775;-0.56515217099957915092 -0.34824219339664519435
0.084037697083224657812 0.2157947157463177279 -0.22435082691619029349 -
0.56378883568616189326 -0.81707312876670679103 -0.35743172402196465853
0.44137531686090508698 -0.69454499747636677665 0.78873706817516819889 -
0.061085142383610444017;-0.77625194831689747765 0.67781860087983325514
0.85616221263462433111 0.22963183362427097567 -0.61751966332831986772
0.12689358469895778425 0.78972184719160776201 -0.15403253807566286149
0.35541974612677529333 -0.36217441600529870493 -0.3997432189546158976
0.1225068728061685791;-0.44250423013892181689 -0.49669856890891456169 -
0.18903140232511966845 -0.49213158318679506298 0.36960494908582836038
0.13055820263746606424 0.65748836087119399973 0.70178366846171291726 -
0.9248856343618722109 -0.019174426113823705292 -
0.0044692872815928416652 0.23106467341014264028;-0.60461172424572273698
-0.51445786392763548367 -0.30985302505224537883 -0.3289622564304345298 -
0.34627148303669863516 0.68330658902972341018 0.44378393054973686027 -
0.57251745573517931476 0.22890377724524602066 0.011666674219181103964
0.54637024753556218126 -0.32949967913549249587;-0.285052701252398899 -
0.70752872999023541656 -0.41984841743747736142 0.54239873151319883959
0.078604219226880364668 -0.10495671744168058592 -0.37985884000749964295
-0.32530631321397185385 0.33402485075111221224 -0.38306290932460995702 -
0.31679482590838109468 0.71128938142607522899;0.57014554342627099537
0.1563674334640791086 0.17932384935671544235 -0.32703750202508996558
0.65619399186880256192 -0.062181203136319009028 -
0.053853698583987787141 0.60642960805090428966 -0.7670479256490567721 -
0.80529705220425196188 -0.30965232719253033 0.032079392912718260322];
IW1_2 = [0.11927039445468545775 0.28144846348488039567;-
0.43896364090949074876 -0.073272720720481937517;0.75546522900121404476 -
0.30927057973524280099;-0.43672253170277458567 -

```
0.1288223194736089483;0.08806479282839405065 0.65045475044838196865;-
1.6918140908123167065 -0.58117401835231308205;0.16907038731923346164
0.49126465884196823808;0.28916162574015930042 -0.35223828520545641396;-
0.88961244171511522083 -0.2636871356599989058;-0.018048263772028651231
0.25845945269590447912];
```

```
% Layer 2
```

```
b2 = -0.35131110204267734787;
LW2_1 = [-0.55862044208386352206 -0.67949452854060543583 -
0.99229048533585484382 0.77492701500938099279 -0.59343690139239457793 -
0.89566235388664050543 -0.37235229822491422436 -0.10199567490718015883
0.70532133647835904 -0.5343532299484875514];
```

```
% Output 1
```

```
y1_step1.ymin = -1;
y1_step1.gain = 2;
y1_step1.xoffset = 0;
```

```
% ===== SIMULATION =====
```

```
% Format Input Arguments
```

```
isCellX = iscell(X);
if ~isCellX
    X = {X};
end
if (nargin < 2), error('Initial input states Xi argument needed.');
```

```
% Dimensions
```

```
TS = size(X,2); % timesteps
if ~isempty(X)
    Q = size(X{1},2); % samples/series
elseif ~isempty(Xi)
    Q = size(Xi{1},2);
else
    Q = 0;
end
```

```
% Input 1 Delay States
```

```
Xd1 = cell(1,3);
for ts=1:2
    Xd1{ts} = mapminmax_apply(Xi{1,ts},x1_step1);
end
```

```
% Input 2 Delay States
```

```
Xd2 = cell(1,3);
for ts=1:2
    Xd2{ts} = mapminmax_apply(Xi{2,ts},x2_step1);
end
```

```

% Allocate Outputs
Y = cell(1,TS);

% Time loop
for ts=1:TS

    % Rotating delay state position
    xdts = mod(ts+1,3)+1;

    % Input 1
    Xd1{xdts} = mapminmax_apply(X{1,ts},x1_step1);

    % Input 2
    Xd2{xdts} = mapminmax_apply(X{2,ts},x2_step1);

    % Layer 1
    tapdelay1 = cat(1,Xd1{mod(xdts-[1 2]-1,3)+1});
    tapdelay2 = cat(1,Xd2{mod(xdts-[1 2]-1,3)+1});
    a1 = tansig_apply(repmat(b1,1,Q) + IW1_1*tapdelay1 + IW1_2*tapdelay2);

    % Layer 2
    a2 = repmat(b2,1,Q) + LW2_1*a1;

    % Output 1
    Y{1,ts} = mapminmax_reverse(a2,y1_step1);
end

% Final Delay States
finalxts = TS+(1:2);
xits = finalxts(finalxts<=2);
xts = finalxts(finalxts>2)-2;
Xf = [Xi(:,xits) X(:,xts)];
Af = cell(2,0);

% Format Output Arguments
if ~isCellX
    Y = cell2mat(Y);
end
end

% ===== MODULE FUNCTIONS =====

% Map Minimum and Maximum Input Processing Function
function y = mapminmax_apply(x,settings)
y = bsxfun(@minus,x,settings.xoffset);
y = bsxfun(@times,y,settings.gain);
y = bsxfun(@plus,y,settings.ymin);
end

```

% Sigmoid Symmetric Transfer Function

```
function a = tansig_apply(n,~)
a = 2 ./ (1 + exp(-2*n)) - 1;
end
```

% Map Minimum and Maximum Output Reverse-Processing Function

```
function x = mapminmax_reverse(y,settings)
x = bsxfun(@minus,y,settings.ymin);
x = bsxfun(@rdivide,x,settings.gain);
x = bsxfun(@plus,x,settings.xoffset);
end
```



EK-9 YSA Modelinde Kullanılan Kodlar

```
function [Y,Xf,Af] = myNeuralNetworkFunction(X,~,~)
%MYNEURALNETWORKFUNCTION neural network simulation function.
%
% Auto-generated by MATLAB, 04-May-2024 23:23:10.
%
% [Y] = myNeuralNetworkFunction(X,~,~) takes these arguments:
%
% X = 1xTS cell, 1 inputs over TS timesteps
% Each X{1,ts} = Qx6 matrix, input #1 at timestep ts.
%
% and returns:
% Y = 1xTS cell of 1 outputs over TS timesteps.
% Each Y{1,ts} = Qx1 matrix, output #1 at timestep ts.
%
% where Q is number of samples (or series) and TS is the number of timesteps.

%#ok<*RPMT0>

% ===== NEURAL NETWORK CONSTANTS =====

% Input 1
x1_step1.xoffset = [0;0;0;0;0;0];
x1_step1.gain = [2;2;2;2;2;2];
x1_step1.ymin = -1;

% Layer 1
b1 = [-2.0494162546322733931;-
1.6008840606759580094;1.0968612536293393944;0.34762101178035925697;0.77
911443320478379615;0.54792938145855119014;0.94849018229141446312;-
1.0269965089013108894;-1.2360609783756058011;-2.383397164398085355];
IW1_1 = [1.1123003991554880621 -0.1288609162334597158 -
1.1492898556778701202 -0.52198390301220620735 0.90858971286560397118
1.251286620773346181;0.56372922032444328089 1.4901691019638005908
0.031670223755742910043 -0.97383257505034781509 0.81024016915162155872 -
0.26681965076182445618;-0.89387539625094591944 -0.39660034626530293878
1.3378463218809870661 -0.48924145799209500796 1.5348000151146903303
0.25221266575940926025;-1.0666980600500062248 -1.0029375407923073471 -
0.86259801611281805567 0.80602536284576198344 0.64273784861624683185
0.10591681027563278061;0.086049250680361483168 1.2621019848795449469
1.2444653770946541016 0.13130252155560218075 -1.0230273022877036659 -
0.43664496428603444267;1.6674930258357987256 -0.53862566730999861253
0.1590246190561537265 -0.6688295414890181867 -0.81225724220343786808 -
0.74939159636764141048;1.4877002792134268461 -0.013235967160876480064 -
0.39229068810588724192 -0.78873030957059664381 0.7040238615252579768
1.3551930452801432825;-0.29374189989498855624 -0.599643873135487393 -
1.1820266245026704865 -1.2168237971518622853 1.0986590786313412682
0.037841854617166520436;-1.2210196991332693539 -0.25828311049228647178
```

```
0.1816057708545794902 1.0079480247540386628 -1.7339523293318226393
0.070608181335180292271;-0.61418436564044942561 -0.34018262369106549992
-0.80888652978986952391 -0.091048047031410381247 1.3783223746360129258
0.45266187768464871688];
```

```
% Layer 2
```

```
b2 = -0.21562157152965655271;
LW2_1 = [0.79318922338449215914 0.059400867177590743751 -
1.207193055535265902 1.0798022549082921806 1.0876247049205418627 -
0.74408155752640281477 1.1058062081035926472 -0.47349890199999278284
1.0006985159331636126 -0.55168607500773481078];
```

```
% Output 1
```

```
y1_step1.ymin = -1;
y1_step1.gain = 2;
y1_step1.xoffset = 0;
```

```
% ===== SIMULATION =====
```

```
% Format Input Arguments
```

```
isCellX = iscell(X);
```

```
if ~isCellX
```

```
    X = {X};
```

```
end
```

```
% Dimensions
```

```
TS = size(X,2); % timesteps
```

```
if ~isempty(X)
```

```
    Q = size(X{1},1); % samples/series
```

```
else
```

```
    Q = 0;
```

```
end
```

```
% Allocate Outputs
```

```
Y = cell(1,TS);
```

```
% Time loop
```

```
for ts=1:TS
```

```
    % Input 1
```

```
    X{1,ts} = X{1,ts}';
```

```
    Xp1 = mapminmax_apply(X{1,ts},x1_step1);
```

```
    % Layer 1
```

```
    a1 = tansig_apply(repmat(b1,1,Q) + IW1_1*Xp1);
```

```
    % Layer 2
```

```
    a2 = repmat(b2,1,Q) + LW2_1*a1;
```

```

    % Output 1
    Y{1,ts} = mapminmax_reverse(a2,y1_step1);
    Y{1,ts} = Y{1,ts}';
end

% Final Delay States
Xf = cell(1,0);
Af = cell(2,0);

% Format Output Arguments
if ~isCellX
    Y = cell2mat(Y);
end
end

% ===== MODULE FUNCTIONS =====

% Map Minimum and Maximum Input Processing Function
function y = mapminmax_apply(x,settings)
y = bsxfun(@minus,x,settings.xoffset);
y = bsxfun(@times,y,settings.gain);
y = bsxfun(@plus,y,settings.ymin);
end

% Sigmoid Symmetric Transfer Function
function a = tansig_apply(n,~)
a = 2 ./ (1 + exp(-2*n)) - 1;
end

% Map Minimum and Maximum Output Reverse-Processing Function
function x = mapminmax_reverse(y,settings)
x = bsxfun(@minus,y,settings.ymin);
x = bsxfun(@rdivide,x,settings.gain);
x = bsxfun(@plus,x,settings.xoffset);
end

```

