

**T.C.
SAKARYA ÜNİVERSİTESİ
İŞLETME ENSTİTÜSÜ**

**TEDARİK ZİNCİRİNDE YAPAY ZEKA TABANLI
TALEP TAHMİNİ VE ENVANTER
YÖNETİMİNİN PERFORMANSA ETKİLERİ**

YÜKSEK LİSANS TEZİ

**Gökhan TURGAY
ORCID: 0000-0003-0431-4448**

**Enstitü Anabilim Dalı : İşletme
Enstitü Bilim Dalı : İşletme**

**Tez Danışmanı: Dr. Öğr. Üyesi Metin BAYRAM
ORCID: 0000-0002-9483-7850**

ŞUBAT – 2025

Gökhan TURGAY tarafından hazırlanan “Tedarik Zincirinde Yapay Zeka Tabanlı Talep Tahmini ve Envanter Yönetiminin Performansa Etkileri” başlıklı bu tez, 15/01/2025 tarihinde Sakarya Üniversitesi Lisansüstü Eğitim ve Öğretim Yönetmeliği'nin ilgili maddeleri uyarınca yapılan Tez Savunma Sınavı sonucunda başarılı bulunarak, jürimiz tarafından Yüksek Lisans Tezi olarak kabul edilmiştir.

Danışman: Dr. Öğr. Üyesi Metin BAYRAM

Sakarya Üniversitesi

Jüri Üyeleri: Dr. Öğr. Üyesi Selman HIZAL

Sakarya Uygulamalı Bilimler Üniversitesi

Dr. Öğr. Üyesi Ömer Faruk SEYMEN

Sakarya Uygulamalı Bilimler Üniversitesi

 SAKARYA ÜNİVERSİTESİ	T.C. SAKARYA ÜNİVERSİTESİ İŞLETME ENSTİTÜSÜ TEZ SAVUNULABİLİRLİK VE ORJİNALLİK BEYAN FORMU	Sayfa: 1/1
Öğrencinin		
Adı Soyadı	:	Gökhan TURGAY
Öğrenci Numarası	:	Y229037017
Enstitü Anabilim Dalı	:	İşletme
Enstitü Bilim Dalı	:	İşletme
Programı	:	Yüksek Lisans
Tezin Başlığı	:	Tedarik Zincirinde Yapay Zekâ Tabanlı Talep Tahmini ve Envanter Yönetiminin Performansa Etkileri
Benzerlik Oranı	:	%5
Sakarya Üniversitesi İşletme Enstitüsü Lisansüstü Tez Çalışması Benzerlik Raporu Uygulama Esaslarını inceledim. Enstitünüz tarafından Uygulama Esasları çerçevesinde alınan Benzerlik Raporuna göre yukarıda bilgileri verilen tez çalışmasının benzerlik oranının herhangi bir intihal içermediğini; aksinin tespit edileceği muhtemel durumda doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi beyan ederim. / / 20.... İmza Öğrenci		
Sakarya Üniversitesi İşletme Enstitüsü Lisansüstü Tez Çalışması Benzerlik Raporu Uygulama Esaslarını inceledim. Enstitünüz tarafından Uygulama Esasları çerçevesinde alınan Benzerlik Raporuna göre yukarıda bilgileri verilen öğrenciye ait tez çalışması ile ilgili gerekli düzenleme tarafımda yapılmış olup, yeniden değerlendirilmek üzere gsbtz@sakarya.edu.tr adresine yüklenmiştir. Bilgilerinize arz ederim. / / 20.... İmza Danışman		
Uygundur Danışman Unvanı / Adı-Soyadı: Tarih: / / 20.... İmza:		
☒ Kabul Edilmiştir ☐ Reddedilmiştir	Enstitü Birim Sorumlusu Onayı	
EYK Tarih ve No: / / 20.... /		

ÖNSÖZ

Bu tez çalışmasının hazırlanmasında bilgi, destek ve teşvikleriyle yanımda olan birçok kişinin katkısı olmuştur. Bu değerli yardımları ve destekleri için teşekkür etmek istiyorum.

Öncelikle, tez çalışmamın her aşamasında yol gösteren, bilgi ve tecrübeleriyle beni her zaman destekleyen değerli danışman hocam **Sayın Dr. Öğr. Üyesi Metin Bayram**'a en içten teşekkürlerimi sunarım.

Her zaman yanımda olan ve sevgileriyle bana güç veren aileme, babam **Rıdvan Turgay**'a, annem **Makbule Turgay**'a, kardeşim **Figen Turgay**'a, sevgili eşim **Hilal Turgay**'a ve her anımı güzelleştirerek bana en büyük motivasyonu sağlayan canım kızım **İlbilge Turgay**'a sonsuz teşekkür ederim.

Bu çalışma, tedarik zincirinde yapay zeka tabanlı talep tahmini ve envanter yönetiminin performansa etkilerini araştırmaya yönelik bir katkı sunmayı hedeflemektedir. Bu çalışmanın hazırlanmasında emeği geçen herkese minnettarım.

Gökhan TURGAY

15.01.2025

İÇİNDEKİLER

KISALTMALAR	iv
TABLOLAR	v
ŞEKİLLER	vi
ÖZET.....	vii
ABSTRACT	viii

GİRİŞ	1
-------------	---

BÖLÜM 1. LİTERATÜR TARAMASI	3
-----------------------------------	---

1.1. Yapay Zeka ve Derin Öğrenme Teknikleri	3
---	---

1.1.1. Yapay Zekanın Temel Prensipleri.....	3
---	---

1.1.1.1. Öğrenme Türleri	3
--------------------------------	---

1.1.1.2. Veri ve Algoritmalar	4
-------------------------------------	---

1.1.1.3. Sinir Ağları	4
-----------------------------	---

1.1.1.4. Algılama ve Karar Verme.....	4
---------------------------------------	---

1.1.1.5. Doğal Dil İşleme.....	4
--------------------------------	---

1.1.2. Derin Öğrenmenin Tedarik Zincirinde Kullanımı	5
--	---

1.1.2.1. Talep Tahmini.....	5
-----------------------------	---

1.1.2.2. Envanter Optimizasyonu	5
---------------------------------------	---

1.1.2.3. Envanter Optimizasyonu	5
---------------------------------------	---

1.1.2.4. Risk Yönetimi ve Tedarikçi Değerlendirme	5
---	---

1.2. Talep Tahmini ve Yöntemleri	6
--	---

1.2.1. Kalitatif Talep Tahmin Türleri.....	6
--	---

1.2.1.1. Delphi Metodu	6
------------------------------	---

1.2.1.2. Pazar Araştırması Yöntemi.....	6
---	---

1.2.1.3. Satış Grupları Yöntemi	7
---------------------------------------	---

1.2.1.4. Yönetici Değerlendirmeleri Yöntemi	7
---	---

1.2.1.5. Tarihsel Bilgilere Dayalı Yöntem.....	7
--	---

1.2.2. Kantitatif Klasik Talep Tahmin Türleri	7
---	---

1.2.2.1. Zaman Serisi Analizi	7
-------------------------------------	---

1.2.2.2. Nedensel Teknikler	10
-----------------------------------	----

1.2.3. Yapay Zeka ve Derin Öğrenme Teknikleri.....	11
--	----

1.2.3.1. Yapay Sinir Ağları (ANN).....	11
--	----

1.2.3.2. Tekrarlayan Sinir Ağları (RNN).....	11
--	----

1.2.3.3. Uzun Kısa Süreli Bellek Ağları (LSTM).....	12
1.2.3.4. Gated Recurrent Unit (GRU).....	12
1.2.3.5. Erişimli Sinir Ağları (CNN)	13
1.2.3.6. Zaman Serisi Transformer Modelleri (TST).....	13
1.2.3.7. Otomatik Kodlayıcılar (Autoencoders)	14
1.2.3.8. Derin İnanç Ağları (DBN)	14
1.2.3.9. Generative Adversarial Network (GANs)	14
1.2.3.10. Attention Mekanizmaları	15
1.3. Envanter Yönetimi ve Performans Kriterleri	15
1.3.1. Envanter Yönetiminde Temel Yöntemler	15
1.3.1.1. Just-in-Time (JIT).....	16
1.3.1.2. Economic Order Quantity (EOQ).....	16
1.3.1.3. Reorder Point (ROP).....	16
1.3.2. Yapay Zeka ile Envanter Yönetimi.....	16
1.3.2.1. Talep Tahmin Optimizasyonu	16
1.3.2.2. Yenileme Stratejilerinin Optimizasyonu	17
1.3.2.3. Stokların Dinamik Yönetimi.....	17
1.3.3. Performans Kriterleri	17
BÖLÜM 2. UYGULAMA YÖNTEMLERİ.....	16
2.1. Veri Toplama ve Veri Hazırlama	16
2.1.1. Veri Toplama Süreci	17
2.1.2. Veri Hazırlama Adımları	18
2.2. ABC Ürün Analizi Ürün Seçimi.....	19
2.2.1. ABC Analizi için Verileri Hazırlama Adımları	19
2.2.2. ABC Analizine Göre Seçilen Veri Setleri.....	21
2.3. Matlab ile Yapay Sinir Ağları Tekniği Kullanarak Talep Tahmini .	25
2.3.1. Veri Setinin Yüklenmesi ve Normalizasyon.....	25
2.3.2. Modelin Oluşturulması ve Performansı	29
2.3.2.1. Eğitim Sonuçlarının Okunması.....	29
2.3.2.2. Ürün001 Eğitim ve Model Performansı	30
2.3.2.3. Ürün007 Eğitim ve Model Performansı	33
2.3.2.4. Ürün049 Eğitim ve Model Performansı	35
2.3.3. Sonuçların Analizi.....	37
2.3.4.1. Mutlak Hata	37
2.3.4.2. Ürün001 için Tahmin Sonuçları	38

2.3.4.3. Ürün007 için Tahmin Sonuçları	39
2.3.4.4. Ürün049 için Tahmin Sonuçları	40
SONUÇ VE ÖNERİLER.....	40
KAYNAKÇA	43
ÖZGEÇMİŞ.....	48



KISALTMALAR

AAP	: Ağızdan Ağıza Pazarlama
AD	: Algılanan Değer
AI	: Yapay Zeka (Artificial Intelligence)
ANN	: Yapay Sinir Ağları (Artificial Neural Networks)
AVE	: Ortalama Açıklanan Varyans
BPI	: Bütünleşik Pazarlama İletişimi
CNN	: Konvolüsyonel Sinir Ağları (Convolutional Neural Networks)
DBN	: Derin İnanç Ağları (Deep Belief Networks)
DL	: Derin Öğrenme (Deep Learning)
EOQ	: Ekonomik Sipariş Miktarı
GAN	: Generative Adversarial Networks
GRU	: Gated Recurrent Unit
LSTM	: Uzun Kısa Süreli Bellek (Long Short-Term Memory)
MAPE	: Ortalama Mutlak Yüzde Hata (Mean Absolute Percentage Error)
ML	: Makine Öğrenimi (Machine Learning)
MSE	: Ortalama Kare Hatası (Mean Squerred Error)
NLP	: Doğal Dil İşleme (Natural Language Processing)
PAE	: Yüzde Mutlak Hata (Percentage Absolute Error)
RNN	: Tekrarlayan Sinir Ağları (Recurrent Neural Networks)
SMAPE	: Simetrik Ortalama Mutlak Yüzde Hata (Symmetric Mean Absolute Percentage Error)
TST	: Zaman Serisi Transformer (Time Series Transformer)
TZY	: Tedarik Zinciri Yönetimi
YZ	: Yapay Zeka

TABLÖLAR

Tablo 1: 2021-2023 Yılları Arası Döviz Aylık Ortalama USD/TL Kurları.....	17
Tablo 2: ABC Analizi Değerleri Tablosu	20
Tablo 3: Ürün001 için Hazırlanan Veri Seti	22
Tablo 4: Ürün007 için Hazırlan Veri Seti	23
Tablo 5: Ürün049 için Hazırlanan Veri Seti	24
Tablo 6: Ürün001 için Normalizasyon Değerleri.....	26
Tablo 7: Ürün007 için Normalizasyon Değerleri.....	27
Tablo 8: Ürün049 için Normalizasyon Değerleri.....	28
Tablo 9: Ürün001 Eğitim Sonuçları	30
Tablo 10: Ürün007 Eğitim Sonuçları	33
Tablo 11: Ürün049 Eğitim Sonuçları	35
Tablo 12: Ürün001 için Tahmin Sonuçları	38
Tablo 13: Ürün007 için Tahmin Sonuçları	39
Tablo 14: Ürün049 için Tahmin Sonuçları	40

ŞEKİLLER

Şekil 1: Satış Hacim Dağılımı Grafiği.....	16
Şekil 2: Ürün001 için Performans Grafiği.....	32
Şekil 3: Ürün007 Performans Grafiği.....	34
Şekil 4: Ürün049 Performans Grafiği.....	36



ÖZET

Turgay, G. (2024). *Tedarik zincirinde yapay zeka tabanlı talep tahmini ve envanter yönetiminin performansa etkileri* (Yayımlanmamış yüksek lisans tezi). Sakarya Üniversitesi.

Bu çalışma, tedarik zinciri yönetiminde yapay sinir ağları (YSA) tabanlı talep tahmininin ve envanter yönetiminin işletme performansı üzerindeki etkilerini incelemeyi amaçlamaktadır. Araştırma kapsamında, 2021-2024 yılları arasındaki bir işletmeye ait satış verileri kullanılarak talep tahmin modelleri geliştirilmiştir. ABC analizi ile seçilen ürün gruplarına yönelik YSA modelleri uygulanmış ve tahmin sonuçları geçmiş verilere dayanarak doğruluk açısından değerlendirilmiştir.

Uygulama sürecinde, veri seti ön işleme adımlarından geçirilmiş ve YSA modelleri ile farklı talep seviyelerine yönelik tahminler gerçekleştirilmiştir. Modellerin sonuçları, stok maliyetlerini optimize etme ve müşteri memnuniyetini artırma potansiyeline sahip olduğunu göstermiştir. Ayrıca, döviz kurları ve müşteri davranışlarındaki değişkenliklerin, tahmin modellerinin performansına etkisi incelenmiştir. Bu değişkenlerin modellere dahil edilmesinin tahmin sonuçlarına iyi anlamda etki ettiği görülmüştür.

Bu çalışmada, yapay sinir ağları (YSA) kullanılarak gerçekleştirilen talep tahminlerinin doğruluk performansı değerlendirilmiştir. Elde edilen sonuçlar, YSA modellerinin klasik yöntemlere kıyasla daha düşük hata oranları (MAPE, PAE) ile yüksek doğruluk sağladığını göstermektedir. Bu bulgular doğrultusunda, yapay zeka entegrasyonlarının tedarik zinciri süreçlerine ve işletme operasyonlarında etkinlik sağladığını ve karar verme süreçlerini iyileştirdiğini ortaya koyulmuştur.

Anahtar Kelimeler: Yapay Sinir Ağları, Tedarik Zinciri Yönetimi, Talep Tahmini, Envanter Yönetimi, ABC Analizi

ABSTRACT

Turgay, G. (2024). *The effects of artificial intelligence-based demand forecasting and inventory management on supply chain performance* (Unpublished master's thesis). Sakarya University.

This study aims to examine the impact of artificial neural network (ANN)-based demand forecasting and inventory management on business performance in supply chain management. Sales data from a business for the years 2021-2024 were utilized to develop demand forecasting models. ANN models were applied to product groups selected through ABC analysis, and the accuracy of the forecasts was evaluated based on historical data.

During the application process, the dataset was preprocessed, and ANN models were employed to generate forecasts for different demand levels. The results indicated that the models have the potential to optimize inventory costs and improve customer satisfaction. Moreover, the effects of exchange rate fluctuations and customer behavior variability on model performance were analyzed. It was observed that incorporating these variables into the models positively influenced the forecasting results.

In this study, the accuracy performance of demand forecasting using Artificial Neural Networks (ANN) was evaluated. The results indicate that ANN models achieve higher accuracy with lower error rates (MAPE, PAE) compared to classical methods. Based on these findings, it has been demonstrated that the integration of the artificial intelligence enhances the efficiency of supply chain processes and business operations while improving decision-making processes.

Keywords: Artificial Neural Networks, Supply Chain Management, Demand Forecasting, Inventory Management, ABC Analysis

GİRİŞ

Tedarik zinciri yönetimi, işletmelerin maliyetlerini düşürme, müşteri memnuniyetini artırma ve rekabet avantajı elde etme süreçlerinde kritik bir öneme sahiptir. Giderek artan küresel rekabet ve belirsizlik ortamı, işletmeleri daha hassas talep tahminleri ve etkili envanter yönetimi stratejileri geliştirmeye yönlendirmiştir. Geleneksel yöntemler, hızlı değişen pazar koşulları ve belirsizlikler karşısında sınırlı kalmakta, bu nedenle işletmeler daha yenilikçi, veri odaklı ve esnek yaklaşımlar arayışına girmektedir (Johnson vd., 2022).

Yapay zeka (YZ) ve makine öğrenimi (ML), tedarik zinciri süreçlerinde yeni bir paradigma sunarak talep tahmini doğruluğunu artırma, envanter seviyelerini optimize etme ve operasyonel maliyetleri azaltma fırsatları sunmaktadır (Lee ve Shin, 2020). Özellikle yapay sinir ağları (ANN), uzun kısa süreli bellek ağları (LSTM), gradyan artış makineleri (GBM) ve diğer derin öğrenme teknikleri, geleneksel yöntemlere kıyasla talep tahmini doğruluğunu artırmakta ve işletmelere daha esnek karar alma süreçleri sunmaktadır (Choi, 2021; Goodfellow vd., 2016). Bu algoritmalar, büyük veri setlerini analiz ederek geçmiş eğilimleri ve gelecekteki talep değişimlerini yüksek doğrulukla öngörme yeteneğine sahiptir.

COVID-19 pandemisi gibi küresel krizler, tedarik zinciri yönetiminin önemini daha belirgin hale getirmiştir. Pandemi döneminde yaşanan belirsizlikler, işletmelerin talep tahmini ve envanter yönetimi süreçlerinde daha etkin yöntemlere olan ihtiyacını artırmıştır. Özellikle tedarik zincirindeki kesintiler ve dalgalanan müşteri talepleri, doğru tahmin yapmanın ve envanter seviyelerini optimumda tutmanın önemini vurgulamıştır (Ivanov ve Dolgui, 2020; Chopra ve Sodhi, 2021). Bu bağlamda, yapay zeka tabanlı sistemler, işletmelerin bu belirsizlikleri yönetme kapasitesini artırarak süreçleri optimize etmektedir.

Bu çalışmada, Türkiye orman ürünleri sektörüne odaklanılarak yapay zeka tabanlı talep tahmininin envanter yönetimi performansına etkileri incelenecektir. Çalışma, 2021-2024 yıllarına ait simüle edilmiş veri setleri kullanılarak gerçekleştirilmiş ve klasik yöntemler ile yapay zeka tabanlı yaklaşımlar performans kriterleri üzerinden karşılaştırılmıştır. Doğrulama performansı için MAPE (Ortalama Mutlak Yüzde Hatası) kullanılarak algoritmaların etkinliği değerlendirilmiştir.

Bu araştırma, yapay zeka tabanlı modellerin tedarik zinciri süreçlerine entegrasyonunun işletmelere sağlayabileceği stratejik avantajları ortaya koymayı ve literatüre katkı sağlamayı amaçlamaktadır.



BÖLÜM 1. LİTERATÜR TARAMASI

1.1. Yapay Zeka ve Derin Öğrenme Teknikleri

Yapay Zeka (YZ), insan zekasına benzer şekilde öğrenme, problem çözme ve karar verme süreçlerini simüle eden sistemler oluşturmayı hedefleyen bir bilim dalıdır (Goodfellow vd., 2016). Bu sistemler, insan müdahalesi olmadan büyük miktarda veriyi analiz ederek öngörülerde bulunabilir. YZ'nin temel taşlarından biri olan Makine Öğrenimi (ML), veri odaklı algoritmalar kullanarak kendini geliştiren sistemler oluşturur. Makine öğrenimi, günümüzde yapay zekanın en yaygın kullanılan alt dalıdır ve sağlık, finans, üretim ve lojistik gibi sektörlerde uygulanmaktadır (Chen vd., 2020).

Derin Öğrenme (DL), yapay zekanın bir alt dalı olarak, çok katmanlı yapay sinir ağlarını kullanarak büyük veri kümelerinden anlamlı çıkarımlar yapar (LeCun vd., 2015). Derin öğrenme, özellikle karmaşık problemlerin çözümünde ve büyük veri kümeleri üzerinde tahmin modelleri oluşturmak için kritik bir rol oynar. İnsan beynindeki sinir ağlarının yapısını taklit eden bu teknik, yüz tanıma, konuşma analizi ve metin işleme gibi uygulamalarda yüksek başarı göstermektedir.

Tedarik Zinciri Yönetiminde (TZY) YZ ve DL'nin kullanımı, karmaşık süreçlerin optimizasyonuna ve maliyet tasarrufuna olanak tanır. Örneğin, talep tahmini, envanter yönetimi, rota optimizasyonu ve risk analizi gibi süreçlerde derin öğrenme algoritmalarıyla daha etkili çözümler sunulmaktadır. Bu teknikler, lojistik ve tedarik zincirinde daha doğru tahminler yaparak işletmelerin rekabet avantajı elde etmesini sağlamaktadır (Waller ve Fawcett, 2013).

1.1.1. Yapay Zekanın Temel Prensipleri

Yapay zekanın temel prensipleri, akıl yürütme, öğrenme, problem çözme, algılama ve doğal dil işleme gibi becerilere dayanır. Bu beceriler, YZ'nin farklı alanlarda uygulanabilirliğini artıran ve çeşitli çözümler sunmasını sağlayan önemli unsurlardır (Waller ve Fawcett, 2013).

1.1.1.1. Öğrenme Türleri

- **Denetimli Öğrenme (Supervised Learning):** Denetimli öğrenme, giriş verilerinin doğru sonuçlarla eşleştirilmesi yoluyla bir modelin eğitilmesini içerir. Bu yöntem, geçmiş verilerden geleceğe yönelik tahminler yapmak için idealdir.

Örneğin, perakende sektöründe bir ürünün gelecekteki satış miktarını tahmin etmek için kullanılır (Chen vd., 2020).

- **Denetimsiz Öğrenme (Unsupervised Learning):** Bu yöntem, etiketlenmemiş veri kümelerinde gizli yapıların ve ilişkilerin ortaya çıkarılmasına olanak tanır. Örneğin, müşteri segmentasyonu gibi tedarik zinciri yönetimi süreçlerinde yaygın olarak kullanılmaktadır (Xu vd., 2018).
- **Pekiştirmeli Öğrenme (Reinforcement Learning):** Çevreden gelen geri bildirimlere dayanarak sistemlerin ödül ve ceza mekanizmaları aracılığıyla öğrenmesini sağlar. Lojistik operasyonlarda rota optimizasyonu için oldukça etkili bir tekniktir (Silver vd., 2016).

1.1.1.2. Veri ve Algoritmalar

YZ'nin performansı büyük ölçüde kullanılan veri setinin kalitesine ve algoritmaların etkinliğine bağlıdır. Veri hazırlığı, özellik mühendisliği ve doğru algoritmaların seçimi, tedarik zinciri süreçlerinde daha iyi sonuçlar elde edilmesini sağlar (Goodfellow vd., 2016).

1.1.1.3. Sinir Ağları

Yapay sinir ağları, derin öğrenmenin temel taşlarından biridir. Bu ağlar, büyük veri kümelerinin katmanlar boyunca işlenerek anlamlı bilgiler üretilmesini sağlar. Özellikle, lojistik süreçlerde tahmin ve sınıflandırma gibi görevlerde sıklıkla kullanılmaktadır (LeCun vd., 2015). Sinir ağlarının uygulamaları arasında yüz tanıma, doğal dil işleme ve görüntü işleme yer almaktadır. Örneğin, Google'ın TensorFlow kütüphanesi, bu tür algoritmaların geniş ölçekte uygulanmasını mümkün kılmıştır (LeCun vd., 2015).

1.1.1.4. Algılama ve Karar Verme

YZ, görüntü tanıma, ses analizi ve metin işleme gibi algılama yeteneklerini geliştirmek için kullanılır. Örneğin, lojistik sektöründe ürünlerin otomatik olarak tanınması ve takip edilmesi bu teknolojilerle mümkündür. Bu sistemler, tedarik zincirinde hata oranını azaltarak süreçleri hızlandırır (Choi vd., 2020).

1.1.1.5. Doğal Dil İşleme

YZ'nin bir alt dalı olan NLP, insan dilini anlama ve işleme yeteneğine sahiptir. Müşteri taleplerini analiz etme, chatbotlar ve otomatik yanıt sistemleri gibi uygulamalarda

kullanılmaktadır. Örneğin, Amazon Alexa, NLP algoritmaları kullanarak müşteri deneyimini iyileştirmiştir (Goodfellow vd., 2016).

1.1.2. Derin Öğrenmenin Tedarik Zincirinde Kullanımı

Tedarik zinciri yönetimi (TZY), hammadde tedarikinden nihai ürün teslimatına kadar olan süreçlerin planlanması, yürütülmesi ve izlenmesiyle ilgili karmaşık bir sistemdir. Bu süreçler, hızla değişen müşteri talepleri, küresel tedarik ağları ve ani piyasa dalgalanmaları gibi birçok dinamik unsurdan etkilenir. Derin öğrenme (DL), bu karmaşıklıkları yönetmek ve optimize etmek için giderek daha fazla kullanılan güçlü bir teknolojidir. Derin öğrenme, büyük veri üzerinde çalışarak doğru tahminlerde bulunma, süreçleri optimize etme ve riskleri azaltma konusunda önemli avantajlar sunar (Chen vd., 2020).

1.1.2.1. Talep Tahmini

Derin öğrenme algoritmaları, geçmiş dönemlere ait satış verilerini analiz ederek gelecek dönemdeki talebi yüksek doğrulukla tahmin edebilir. Bu tahminler, stok seviyelerinin optimize edilmesini sağlar. Örneğin, Amazon, RNN tabanlı modellerle talep tahmin doğruluğunu artırmıştır (Chen vd., 2020).

1.1.2.2. Envanter Optimizasyonu

Fazla stok veya eksik stok problemleri, tedarik zincirindeki en büyük maliyet unsurlarındandır. Derin öğrenme tabanlı tahmin modelleri, bu problemleri minimize ederek maliyet tasarrufu sağlar (Choi vd., 2020).

1.1.2.3. Envanter Optimizasyonu

Nakliye ve lojistik süreçlerde rota optimizasyonu, derin öğrenme teknikleriyle daha etkin bir şekilde yönetilebilir. UPS, CNN algoritmalarını kullanarak günlük teslimat maliyetlerini düşürmüştür (Goodfellow vd., 2016).

1.1.2.4. Risk Yönetimi ve Tedarikçi Değerlendirme

Derin öğrenme, tedarik zincirindeki riskleri önceden tespit etmek ve tedarikçi performansını analiz etmek için kullanılabilir. Bu, operasyonel kesintilerin minimize edilmesine olanak tanır (Silver vd., 2016).

1.2. Talep Tahmini ve Yöntemleri

Tedarik zinciri yönetiminde talep, bir ürünün belirli miktar ve özellikler de istenilen zamanda satın alınması isteğidir. Talep tahmini ise, ürün veya hizmetlerin ne zaman ve ne miktarda isteneceğinin tahmin edilmesidir. Bu tahminleme, işletmelerin üretim planlamasında, işgücü planlamasında ve ihtiyacı olan hammaddelerin tedarikinin planlanmasında kritik bir rol oynar. İşletmelerin tahminlerindeki doğruluk, finans, işgücü, hammadde ve kapasite gibi kaynaklarını optimum seviyede kullanması ve işletme maliyetlerini en düşük seviyelerde tutarak faaliyet verimliliğini koruyabilmesini sağlar. Talep tahmin süreçleri 5 aşamada gerçekleştirilir. Bu 5 adım (Kobu, 2008) sırasıyla, hedefin belirlenmesi, tahmin zamanının belirlenmesi, tahmin zamanının belirlenmesi, bilgilerin toplanması, tahmin tekniğinin belirlenmesi ve tahmin hatasının hesaplanması süreçlerini içerir.

1.2.1. Kalitatif Talep Tahmin Türleri

Bu tür tahminler, bir veya birden fazla kişinin geçmiş deneyimlerini, sezgilerini ve kişisel değerlendirmelerini temel alarak, matematiksel modele dayanmadan gerçekleştirilir. Ancak, verilere dayanmadığından dolayı genellikle tahminlerin doğruluk düzeyi düşüktür.

1.2.1.1. Delphi Metodu

Tahmin sürecinde, karar verici kişi ya da kişiler bir araya gelmeden, uzmanlara sorular yöneltilir. Daha sonra alınan yanıtlar derlenerek raporlanır ve yeni sorular oluşturularak uzmanlara tekrar iletilir. Bu süreç, istenilen ve üzerinde uzlaşma sağlanmış sonuçlar elde edilinceye kadar sürdürülür. Tekniğin avantajı, kişilerin bir araya gelmemesi sebebiyle çatışmaların azalması ve herkesin bilgisinde istifade edilebilmesidir. Sistemin dezavantajı ise sistemin aşamalı olması sebebiyle yavaş işlemesidir. (Linstone ve Turoff, 1975, s. 3)

1.2.1.2. Pazar Araştırması Yöntemi

Tüketici talepleri, telefon ve e-posta görüşmeleri ve anketler gibi yöntemlerin kullanılarak tüketicilerden bilgi toplayarak gerçekleştirilir. Pazar araştırmalarında sık kullanılan yöntemler genellikle anket uygulamalarıdır. Yeni bir ürünün piyasa koşullarındaki olası taleplerinin öngörülmesi aşamasında anketler düzenlenir. Ancak, katılımcı cevaplarının net olmaması, testlere rastgele cevaplar verilmesi gibi dezavantajları bulunmaktadır. (Malhotra, 2010, s. 45)

1.2.1.3. Satış Grupları Yöntemi

Satış ekipleri veya satış ve pazarlama alanında faaliyet gösteren personellerin, sürekli müşteri iletişimi kurarak geliştirdikleri gelecekle ilgili elde ettiği tahminler ve kendi deneyim ve görüşlerine dayanarak oluşturulan tahminlerdir. Bu personellerin, tüketicilerle yüz yüze görüşme fırsatları olduğundan satış tahminlerin yapılmasında aşamasında bu yaklaşım iyi bir rol oynar. Ancak, öznel özellikler taşıdığından güvenilirliği tartışılan bir yöntemdir (Thomas, 2009, s. 24).

1.2.1.4. Yönetici Değerlendirmeleri Yöntemi

Bu tahmin yönteminde üst düzey yöneticilerin görüşleri esas alınır. Geçmiş verilere erişimin sınırlı olduğu durumlarda zaman ve maliyet açısından avantaj sağladığı için bu yöntem sıklıkla tercih edilir. Bununla birlikte, kararların kişisel değerlendirmelere dayanması, bazı dezavantajları beraberinde getirebilir ve yöneticilerin bireysel sorumluluklarını ön plana çıkarır (Kaya ve Demir, 2020).

1.2.1.5. Tarihsel Bilgilere Dayalı Yöntem

Geçmiş dönemlere ait aynı özellikleri içeren ürün veya ürün gruplarının verilerinin analiz edilmesiyle gerçekleştirilir. Yeni pazara girecek veya değişiklik yapılacak ürün veya ürün gruplarında tüketicilerin talep ve ihtiyaçları göz önünde tutularak değerlendirilebilir (Yılmaz ve Aydın, 2021).

1.2.2. Kantitatif Klasik Talep Tahmin Türleri

Geçmiş talep verilerinin istatistiksel yöntemlerle analiz edilerek gelecek dönem taleplerini belirlemeyi amaçlayan yöntemdir. Bu yöntem tipleri, verilere dayandığından dolayı tahmin performansında yüksek doğruluk sağlar ve tecrübe gerektirmeksizin kullanılabilir.

1.2.2.1. Zaman Serisi Analizi

Bu yöntem, geçmiş verilerin analiz edilmesiyle bir model oluşturulmasını ve bu modelin tahminlerde kullanılmasını içerir. Zaman dilimleri bağımsız değişkenleri oluştururken, stok miktarı, verim yüzdesi gibi değişkenler bağımlı değişkenlerdir. Ancak, öngörülemeyen değişimlerde bu yöntem yeterince etkili olmayabilir. Zaman serilerinde benzer yönde verilerin değişimini 'trend' olarak adlandırılır. Bu benzer değişimlere mevsimsellik örnek olarak gösterilebilir. Zaman serileri analizi için genellikle basit hareketli ortalama, üssel düzeltme, ağırlıklı hareketli ortalama, Holt'un lineer metodu,

Holt-Winter yöntemi, otoregresif modeller ve Box-Jenkins yöntemi gibi çeşitli teknikler kullanılır (Salttürk, 2022).

Basit hareketli ortalama yöntemi, geçmiş n dönemdeki talep değerlerinin ortalamasını alarak tahmin yapar (Salttürk, 2022). Bu yöntem, hesaplanacak dönemin tahminini önceki dönem verilerinden etkilenmesini varsayar. Doğru bir tahmin elde etmek için n değeri deneysel olarak belirlenebilir. Aşağıdaki denklemde, F_t 'nin t dönemi için tahminini Y_{t-1} 'in önceki dönemdeki gerçekleşen değerleri üzerinden ifade etmektedir. İfade denkliği (1.1) aşağıdaki gibidir.

$$F_t = \frac{-Y_{t-1} - 1 + Y_{t-1} - 2 + Y_{t-3} + \dots + Y_{t-n}}{n} \quad (1.1)$$

Bu formülde, F_t , t dönemindeki tahmin değerini; Y_{t-1} ise önceki dönemde gerçekleşen değeri temsil eder. n , toplam dönem sayısını ifade eder (Salttürk, 2022).

Ağırlıklı hareketli ortalama yönteminde, talep dönemlerine ağırlık çarpanı eklenerek, benzer dönemlerin ortalamaya daha fazla etkide bulunmasını sağlar. Bu yöntemde, dönemlere yakın olanlar daha yüksek ağırlığa sahiptir, uzak dönemler etkilerini daha az gösterir. Ağırlıkların toplamı her zaman '1' olmalıdır. Basit hareketli ortalama yönteminden farkı, dönemlere farklı ağırlık değerleri atanmış olmasıdır. Basit hareketli ortalama ise ağırlık değerleri dönemler arasında eşit kabul edilir, bu nedenle ağırlık çarpanı '1' olarak kalır. Aşağıdaki denklemdeki (1.2) gibi hesaplama yapılır.

$$F_t = \frac{W_1 * Y_{t-1} + \dots + W_n * Y_{t-n}}{W_1 + W_2 + \dots + W_n} \quad (1.2)$$

W_n , n dönemine ait gerçekleşen talebin W ağırlık değerleriyle çarpılması sonucunda elde edilir; burada W , ağırlık değerini temsil eder ve bağımsız değişkeni Y ifade eder.

Üssel düzeltme yöntemi, önceki dönem tahmin hatasına odaklanır. Tahmin edilen dönem, bir önceki dönem tahmin hatasının bir kısmıyla düzeltilir ve yeni bir tahmin oluşturulur. Pozitif hata değeri, tahminin gerçekleşen değerden yüksek olduğunu gösterir. α düzeltme sabitinin kullanılmasıyla tahmin hatası azaltılır ve bu sabitin genellikle 0.05 ile 0.30 arasında bir değer aldığı kabul edilir. Uygun bir α değeri belirleme önemlidir.

$$F_{t+1} = \alpha * Y_t + (1 - \alpha) * F_t \quad (1.3)$$

t periyodu, F_t tahmini F_{t+1} , önceki dönemin tahmini F_t , önceki dönemin talebini Y_t ve α düzeltme sabitini ifade etmektedir.

Holt lineer (İkili üssel düzeltme) yöntemi, tahmin yapmak için iki üssel düzeltme katsayısı (α ve β) kullanır. Holt, seriyi bir trende göre tahmin etmek amacıyla üssel düzeltme yöntemini geliştirmiştir ve bu nedenle Holt lineer yöntemi ortaya çıkmıştır. Her iki düzeltme sabiti, yalnızca 0 ile 1 arasında değer alabilir ve ilgili formülasyonlar (1.4), (1.5), (1.6) aşağıda gösterilmiştir.

$$L_t = \alpha * Y_t + (1 - \alpha) * (L_{t-1} + b_{t-1}) \quad (1.4)$$

$$b_t = \beta * (L_t - L_{t-1}) + (1 - \beta) * b_{t-1} \quad (1.5)$$

$$F_{t+m} = L_t + b_t * m \quad (1.6)$$

L_t serinin t zamandaki değerini, b_t serinin t zamandaki eğim değerini belirtir, m tahmin edilecek dönem sayısını ifade eder (Salttürk, 2022).

Holt-Winter yöntemi, talebin doğrusal modele sahip olmadığı özellikle zaman serisine trend ve mevsimsellik eklenmiş durumda ise durumlarda kullanılır. Bu yöntemde üç farklı düzeltme bulunmakta olup α düzeltme, β trend düzeltme, γ ise mevsimsellik için düzeltme sabitleridir. Bu üç sabit, sadece 0 ile 1 arasındaki değerleri alabilir. İlgili formülasyonlar (1.7), (1.8), (1.9), (1.10) aşağıdaki gibidir.

$$L_t = \alpha * (Y_t - S_t - s + (1 - \alpha) * (L_{t-1} + b_{t-1})) \quad (1.7)$$

$$b_t = \beta * (L_t - L_{t-1}) + (1 - \beta) * b_{t-1} \quad (1.8)$$

$$S_t = \gamma * (Y_t - L_t) + (1 - \gamma) * S_{t-s} \quad (1.9)$$

$$F_{t+m} = L_t + b_t * m + S_{t-s+f} \quad (1.10)$$

Box-Jenkins yöntemi, 1970-1976 yıllarında yöntemde ismini veren Box-Jenkins tarafından geliştirilmiştir (Salttürk, 2022). Kesikli serilerde, durağan serilerde ve tek değişkenli zaman serilerinin analizinde uygulanabilmektedir. Bu modeller, doğrusal ve durağan modeller olarak da bilinir. Herhangi bir döneme ait değeri, hata terimi ve zaman serisinin geçmiş değerlerinin doğrusal bir kombinasyonu ile ifade edilir. Yöntemin temel amacı, en uygun ve en az parametre içerecek doğrusal bir model oluşturmaktır. Box-Jenkins modeli, seriyi durağan hale getirmek için durağanlığı bozan unsurları belirler ve ardından da uygun modelleme yaparak tahmin gerçekleştirir. Bu yöntemin diğer yöntemlerde ayrıldığı özelliklerden birisi de herhangi bir belirgin eğilim göstermemesidir.

Yöntem sırasıyla, dönüştürme, model tanımı, tahmin, kontrol ve tahmin aşamalarıyla ilerler (Sarı, 2016). Dönüştürme aşamasında, verilere dönüştürme işlemi uygulanarak p ve q ifadelerinin derecelerinin bulunmasındaki adımdır. Bu dereceler, otoregresif özellikler ve hareketli ortalama ile bulunur. Model tanımı aşamasında, deneme olarak birden fazla model tanımlanır. Bu modeller içerisinde uygun görüleni öngörü olarak seçilir ve tahmin aşamasına geçilir. Tahmin aşamasında, modellerdeki tahminler yapılır ve en iyi olan model seçilir. Kişinin tecrübe ve bilgi seviyesi, en iyi olan modelin seçiminin kritik bir parçasıdır. Sonrasında parametre tahminleri gerçekleştirilir. Kontrol aşamasına gelindiğinde, model yetersiz bulunduğunda tekrar ikinci aşamaya dönülerek modeller tekrar değerlendirilir ve en uygun modeli belirlemek için adımlar tekrar edilir (Salttürk, 2022).

1.2.2.2. Nedensel Teknikler

Talebin gelecek zamandaki değerinin ve onu etkileyen faktörler arasındaki neden-sonuç ilişkisini anlamaya yönelik bir metodolojidir. Nedensel yöntemler, regresyon ve korelasyon analizi olarak adlandırılan matematiksel modellerin geliştirilmelerini içerir.

Regresyon analizi, bağımlı ve bağımsız arasındaki ilişkiyi ölçen bir analiz metodudur. Tek bir bağımsız değişken bulunuyorsa, tek değişkenli regresyon analizi olarak adlandırılır. Daha fazla bağımsız değişken varsa, çok değişkenli veya çoklu regresyon analizi olarak adlandırılır. Bu analiz için kurulan matematiksel modeller regresyon modelleri olarak bilinir. Hatanın normal bir dağılım varsayımına dayandığı en büyük olasılık yöntemi veya varsayım olmadan en küçük kareler tekniği kullanılır.

Tek değişkenli regresyon analizi, bir bağımlı değişken ile tek bir bağımsız değişken arasındaki ilişkiyi analiz eden bir tekniktir (Salttürk, 2022). Bu analiz, ilişkide ve değişkenlerde doğrusal bir yapı olduğunu varsayar. Çok değişkenli regresyon analizi ise bir bağımlı değişken ile birden fazla bağımsız değişken arasındaki ilişkiyi inceleyen bir tekniktir. İfade denklemi (1.11) aşağıdaki gibidir.

$$Y_i = \beta_i + \beta_0 + X_i + \varepsilon_i \quad i = 0,1,2 \dots n \quad (1.11)$$

Korelasyon analizi, değişkenler arasındaki ilişkinin gücünü gösterir (Özkaynar, 2024). Eğer değişkenler doğrusal bir ilişkiye sahipse, bu durum korelasyonu ifade eder. Korelasyon katsayısı, +1 ile -1 arasında değişen bir değeri temsil eder ve ilişkinin derecesini gösterir. Eğer korelasyon katsayısı 0'a yakınsa, bu durumda ilişki yoktur.

Negatif bir korelasyon -1'e yakinken, pozitif bir korelasyon +1'e yakındır. Aşağıdaki ifade (1.12) bu ilişkiyi ifade eder:

$$R = \frac{n \sum X_i Y_i - \sum X_i \sum Y_i}{\sqrt{n \sum X_i^2 - (\sum X_i)^2 (n \sum Y_i^2 - (\sum Y_i)^2)}} \quad (1.12)$$

1.2.3. Yapay Zeka ve Derin Öğrenme Teknikleri

1.2.3.1. Yapay Sinir Ağları (ANN)

Yapay sinir ağlarının temelleri, McCulloch ve Pitts tarafından 1943 yılında tanımlanmıştır (İrmak, 2022). 1958 yılında Rosenblatt'ın geliştirdiği “Perceptron” modeliyle önemli bir gelişme göstermiştir. Son yıllarda, talep tahminlemedeki başarısı fark edilmiş ve birçok çalışma da ve akademik incelemede yerini almıştır. Yapay sinir ağları ile perakendeden, otomotive kadar birçok sektöre özgü akademik çalışmalar yapılmıştır.

Yapay sinir ağları, insan beyninin sinir ağlarının çalışma prensinden esinlenilerek oluşturulmuş bir tekniktir (Taşar, 2023). Veri analizi ve modelleme süreçlerinde sık kullanılan bir yapay zeka yaklaşımıdır. Yapay sinir ağları, birden fazla gizli katman kullanarak karmaşık veri kümelerindeki doğrusal ve doğrusal olmayan ilişkileri öğrenebilir ve bu yetenekleriyle karmaşık ve çok parametrelili veri kümeleri için oldukça etkili sonuçlar sunmaktadır. Girdi ve çıktı arasındaki ilişkiyi modellemek amacıyla sıklıkla ileri beslemeli sinir ağları tercih edilir. Özellikle geçmiş satış, üretim, tüketim gibi verilerden eğilim ve desenlerin öğrenilmesi gibi talep tahminlemeye yönelik işlerde yaygın olarak kullanımı bulunmaktadır.

1.2.3.2. Tekrarlayan Sinir Ağları (RNN)

Tekrarlayan sinir ağlarının teorik temelleri 1986 yılında David Rumelhart ve Geoffrey Hinton tarafından atılmış olup özellikle zaman serisi analizleri ve ardışık veri modelleme süreçlerinde kullanılan bir yapay zeka yaklaşımıdır. Zaman serisi analizinde devrim niteliği taşıyan bu ağlar, ardışık verilerin analizine yönelik önemli avantajlar sağlamaktadır. Bu ağlar, zaman serilerinde ardışık bilgiyi öğrenmek için içsel bir bellek mekanizması kullanır ve her bir zaman adımındaki bilgiyi ağın durumunda tutarak sonraki tahminlerde değerlendirir (Lipton vd., 2015).

Günlük, haftalık veya aylık satış tahminleri gibi sıralı veri analizine dayalı uygulamalarda tekrarlayan sinir ağları modelleri önemli bir çözüm sunmaktadır. Örneğin, Patel ve ekibi

(2018), enerji sektöründe RNN kullanarak elektrik talebinin tahmininde yüksek doğruluk oranları elde etmiştir.

1.2.3.3. Uzun Kısa Süreli Bellek Ağları (LSTM)

Hochreiter ve Schmidhuber (1997) tarafından geliştirilen LSTM, zaman serisi verilerinin uzun vadeli analizinde çığır açmıştır. Örneğin, Amazon gibi büyük e-ticaret platformları, LSTM modellerini kullanarak stok yönetiminde yıllık talep döngülerini tahmin etmektedir.

RNN'nin bir varyasyonu olan LSTM, özellikle uzun dönemli bağımlılıkları öğrenme yeteneğiyle dikkat çeker. Geleneksel RNN modellerinde görülen "unutma" problemini çözmek amacıyla geliştirilmiştir. Bellek hücreleri ve kapı mekanizmaları sayesinde LSTM, mevsimsellik ve trend gibi uzun vadeli ilişkileri başarılı bir şekilde analiz edebilir (Hochreiter ve Schmidhuber, 1997).

Google, dil modelleme, arama sonuçlarının sıralaması ve kullanıcı etkileşimini analiz etmek için LSTM ağlarını kullanır. LSTM'ler, dil bağımlılıklarını öğrenmede ve anlama görevlerinde etkilidir, bu nedenle metin verilerini işlemek için idealdir.

1.2.3.4. Gated Recurrent Unit (GRU)

2014 yılında Cho ve arkadaşları tarafından önerilen GRU, lojistik sektörden e-ticaret platformlarına kadar birçok alanda uygulanmıştır. Örneğin, Zhang ve diğerleri (2021), GRU kullanarak lojistik sektöründe dinamik rota tahmini yapmış ve düşük maliyetli bir çözüm sağlamıştır.

GRU, üretim hatlarında ihtiyaç duyulan hammaddelerin ve bitmiş ürünlerin talebini tahmin etmek için de kullanılır. Yang ve diğerleri (2020), otomotiv sektöründe GRU tabanlı talep tahmininin stok maliyetlerini %20 oranında düşürdüğünü belirtmiştir (Yang vd., 2020). Benzer şekilde Erol ve İnkaya (2024) da hem LSTM hem de GRU'nun doğru tahminlerde bulunduğunu ortaya koymuştur.

GRU, LSTM'nin daha basitleştirilmiş bir versiyonu olarak tasarlanmıştır ve daha az parametre içerir. Bu özellik, GRU'nun daha hızlı çalışmasını ve daha az hesaplama gücü gerektirmesini sağlar. GRU, özellikle düşük işlem kapasitesine sahip cihazlarda veya gerçek zamanlı uygulamalarda kullanılmaktadır (Zhang ve Li, 2021).

1.2.3.5. Erişimli Sinir Ağları (CNN)

CNN, (Convolutional Neural Networks) ilk olarak 1980'lerde Fukushima tarafından geliştirilmiş, ardından 1990'larda LeCun'un katkılarıyla modern formunu kazanmıştır. Başlangıçta görüntü işleme için kullanılan bu yapı, son yıllarda zaman serisi verilerinde de uygulanmaktadır. CNN, veri içindeki yerel desenleri tespit etme yeteneği sayesinde talep tahmini gibi karmaşık problemlerde kullanılmaktadır.

Çok boyutlu talep verilerinde, CNN'in desen tanıma kapasitesi önemli bir avantaj sağlamaktadır. Örneğin, Amazon'un global tedarik zincirinde stok yenileme ve müşteri talebini tahmin etmek için kullanılmaktadır. Firma Satış geçmişine ve kullanıcı davranışlarına göre ürün önerisi yaparken CNN'lerden yararlanır. Talep tahminlerinde %30'a varan doğruluk artışı ile stok fazlası ve eksikliklerini optimize ettiği bilinmektedir.

CNN, Walmart'ın günlük satış verilerini analiz ederek belirli ürünler için talep tahminlerinde kullanılır. CNN modelleri ile müşterilerin talebine ve piyasa koşullarına göre fiyat stratejileri belirlenir. Bu modeller sayesinde lojistik maliyetlerini %20 oranında azalttığı bildirilmiştir (LeCun, 1990).

1.2.3.6. Zaman Serisi Transformer Modelleri (TST)

Transformer modelleri, uzun dönem bağımlılıkların olduğu zaman serisi verilerinde dikkate değer bir performans sunar (Vaswani vd., 2017). Dikkat mekanizmaları sayesinde büyük veri setlerinde yüksek doğruluk ve hız sağlar.

Transformer modelleri, 2017 yılında Vaswani ve ekibi tarafından geliştirildi. Özellikle uzun süreli bağımlılıkları ve büyük veri setlerini hızlıca analiz etme kapasitesiyle dikkat çeker. Zaman serisi uygulamalarında, Transformer modelleri örneğin e-ticaret sektöründe hızlı değişim gösteren müşteri taleplerinin tahmininde kullanılmaktadır.

Netflix, kullanıcı izleme alışkanlıklarını ve tercihlerini analiz ederek öneri sistemlerini geliştirmek için Transformer modellerinden yararlanır. Bu sayede, kullanıcılara kişiselleştirilmiş içerikler sunulur.

Google, arama trendleri, reklam harcamaları ve kullanıcı etkileşimi gibi konuları tahmin etmek amacıyla Transformer modellerini kullanır. Bu modeller, kullanıcıların arama eğilimlerini ve ilgilerini doğru bir şekilde öngörerek, kullanıcı deneyimini kişiselleştirir (Vaswani vd., 2017).

1.2.3.7. Otomatik Kodlayıcılar (Autoencoders)

İlk olarak 1980’lerde Hinton tarafından önerilen Otomatik Kodlayıcılar, düşük boyutlu temsillerin öğrenilmesi ve anormallik tespiti konularında geniş bir uygulama alanına sahiptir.

Otomatik Kodlayıcılar, veri setlerindeki bilgiyi daha düşük boyutlu temsillerde sıkıştırarak önemli özellikleri öğrenir. Bu yöntem, özellikle veri gürültüsünün azaltılması ve anormallik tespiti gibi görevlerde etkilidir. Talep tahmini alanında, eksik verinin olduğu durumlarda veri zenginleştirme amacıyla kullanılmaktadır. Talep tahmininde, az veriyle çalışan sektörlerde veri zenginleştirme için kullanılabilir (Hinton, 1980).

1.2.3.8. Derin İnanç Ağları (DBN)

DBN, 2006 yılında Hinton tarafından tanıtılmıştır. Bu yapı, çok katmanlı veri analizlerinde üstünlük sağlamaktadır. Örneğin, Li ve diğerleri (2018), üretim hatlarında DBN kullanarak tedarik zinciri verilerinde kritik desenleri tespit etmiş ve tahmin doğruluğunu artırmıştır (Li vd., 2018).

Derin İnanç Ağları (DBN), birden fazla gizli katmandan oluşur ve her katman, girdideki özellikleri öğrenerek verinin daha karmaşık temsilini oluşturur. Bu hiyerarşik öğrenme yapısı, bu tekniği özellikle karmaşık tedarik zincirlerinde talep tahmini için uygun hale getirir.

DBN’ler, üretim hatlarında kalite kontrol ve tedarik zinciri yönetiminde kullanılmaktadır. Örneğin, HveM gibi moda markaları, ürün taleplerini tahmin etmek ve stok yönetimini optimize etmek amacıyla bu ağları kullanır. Finansal hizmetler, hisse senedi fiyatları ve piyasa eğilimlerini analiz etmek için ise, Morgan Stanley gibi büyük bankalar, müşteri davranışlarını analiz etmek ve yatırım stratejilerini optimize etmek amacıyla bu ağları uygular (Morgan Stanley).

1.2.3.9. Generative Adversarial Network (GANs)

2014 yılında Goodfellow ve ekibi tarafından geliştirilen GAN modelleri, veri üretiminde devrim yaratmıştır. Örneğin, GAN’ler moda sektöründe yeni ürünlere yönelik talebi analiz etmek için sentetik veri üretimi amacıyla başarıyla kullanılmıştır.

Generative Adversarial Networks (GANs), bir üreten ve bir ayırt eden olmak üzere iki ağdan oluşur. Bu ağlar, veri üretimi ve doğrulama süreçlerinde birbirini geliştirerek

öğrenir. Talep tahmininde, sentetik veri üretimi ve veri genişletme gibi görevlerde önemli bir araçtır (Goodfellow vd., 2014).

Moda markaları, GAN'leri yeni ürünler ve koleksiyonlar tasarlamak amacıyla kullanır. Örneğin, Nike ve Adidas gibi büyük spor giyim markaları, yeni tasarımlar için sentetik görseller oluşturmak ve müşteri taleplerini analiz etmek için bu ağlardan yararlanır. Talep tahmininde ve risk analizinde GAN'leri kullanır. JPMorgan gibi büyük finansal kuruluşlar ise, müşteri taleplerini analiz etmek ve kredi değerlendirme süreçlerini iyileştirmek amacıyla bu ağlardan yararlanır (Goodfellow vd., 2014).

1.2.3.10. Attention Mekanizmaları

Attention mekanizmaları, ilk kez 2014 yılında Bahdanau ve ekibi tarafından önerilmiştir. Günümüzde Transformer modellerinin temel bileşeni olan bu mekanizma, talep tahmini gibi karmaşık süreçlerde yaygın olarak kullanılmaktadır. Örneğin, Liu ve diğerleri (2021), lojistik sektöründe attention mekanizmalarını kullanarak dinamik talep tahmini gerçekleştirmiştir.

Bu mekanizmalar, verilerdeki kritik bilgileri seçici bir şekilde işleyerek modelin daha anlamlı sonuçlar üretmesini sağlar. Özellikle önemli veri noktalarının önceliklendirilmesini mümkün kılar ve talep tahmini uygulamalarında etkili bir şekilde kullanılabilir (Liu vd., 2021).

1.3. Envanter Yönetimi ve Performans Kriterleri

Envanter yönetimi, işletmelerin operasyonel başarılarını belirleyen kritik bir süreçtir. Doğru bir envanter yönetimi, maliyetlerin düşürülmesi, müşteri memnuniyetinin artırılması ve işletme kaynaklarının verimli bir şekilde kullanılması açısından büyük önem taşır (Gupta vd., 2021). Bu kapsamda, envanter yönetimi ile ilgili yöntemler, yapay zeka destekli optimizasyon yaklaşımları ve performans değerlendirme kriterleri incelenmektedir (Tang ve Mousavi, 2022).

1.3.1. Envanter Yönetiminde Temel Yöntemler

Envanter yönetiminde kullanılan yöntemler, işletmelerin farklı ihtiyaçlarına ve stratejik önceliklerine uygun olarak şekillenir.

1.3.1.1. Just-in-Time (JIT)

JIT, stok bulundurmayı minimuma indirerek üretimi doğrudan talebe dayalı olarak düzenleyen bir yaklaşımdır. Bu yöntem, gereksiz stok maliyetlerini azaltır ve üretim esnekliğini artırır (Özkan ve Esmeray, 2002).

Yapay zeka destekli sistemler, talep tahminlerini iyileştirerek JIT yönteminin daha etkin bir şekilde uygulanmasını sağlar. Örneğin, zaman serisi analizleri ile talep dalgalanmaları daha hassas bir şekilde öngörülebilir (Chopra ve Meindl, 2019).

1.3.1.2. Economic Order Quantity (EOQ)

EOQ, belirli bir dönemde en uygun sipariş miktarını hesaplayan bir yöntemdir. Bu yöntem, toplam envanter maliyetlerini optimize etmeyi hedefler. Geleneksel EOQ modelleri genellikle sabit talep varsayımlarına dayanır. Yapay zeka, değişken talepleri analiz ederek daha dinamik EOQ hesaplamaları yapılmasını mümkün kılar (Silver vd., 2016).

1.3.1.3. Reorder Point (ROP)

ROP, stok seviyesinin kritik bir eşik değere düştüğünde yeni siparişin verilmesini sağlayan bir stratejidir. Derin öğrenme ve makine öğrenimi algoritmaları, ROP seviyelerinin dinamik bir şekilde belirlenmesine olanak tanır. Talep öngörülerinin doğruluğunu artıran bu yaklaşımlar, stok eksikliklerini önlemeye yardımcı olur (Hochreiter ve Schmidhuber, 1997).

1.3.2. Yapay Zeka ile Envanter Yönetimi

Yapay zeka, envanter yönetiminde geleneksel yöntemlere kıyasla daha gelişmiş çözümler sunar. Envanter seviyelerinin belirlenmesi, yenileme stratejilerinin optimize edilmesi ve stokların gerçek zamanlı olarak izlenmesi gibi süreçlerde yapay zeka büyük bir avantaj sağlar (Goyal ve Soni, 2021; Ivanov vd., 2023). Bu teknolojiler, işletmelerin operasyonel verimliliğini artırırken aynı zamanda maliyetleri azaltmasına da olanak tanır.

1.3.2.1. Talep Tahmin Optimizasyonu

Yapay zeka, talep tahminlerini iyileştirmek için ARIMA, LSTM ve GRU gibi zaman serisi modelleri kullanır. Bu yöntemler, geçmiş verilerden elde edilen desenleri analiz ederek gelecekteki taleplerin daha doğru tahmin edilmesini sağlar (Makridakis vd., 2018).

ARIMA modelleri, kısa vadeli talep tahminleri için etkili bir yöntemdir. LSTM ve GRU algoritmaları, uzun vadeli tahminlerde ve karmaşık desenlerin öngörülmesinde daha etkilidir.

1.3.2.2. Yenileme Stratejilerinin Optimizasyonu

Genetik algoritmalar ve optimizasyon teknikleri, sipariş miktarlarını ve yeniden sipariş zamanlarını belirleyerek maliyetleri ve stok eksikliklerini minimize eder. Bu algoritmalar, stok seviyelerini dinamik bir şekilde optimize eder (Goldberg, 1989).

1.3.2.3. Stokların Dinamik Yönetimi

Yapay zeka destekli adaptif sistemler, stok seviyelerini gerçek zamanlı olarak izler ve talep değişikliklerine hızlı bir şekilde yanıt verir. Özellikle, yüksek talep dönemlerinde stok artırılırken, düşük talep dönemlerinde stok seviyeleri düşürülür (Goodfellow vd., 2016).

1.3.3. Performans Kriterleri

Yapay zeka destekli envanter yönetim sistemlerinin etkinliğini ölçmek için çeşitli performans kriterleri kullanılmaktadır.


Stok devir hızı, stokların hızlı bir şekilde tükendiğini ve etkin bir yönetim sürecini yansıtan önemli bir performans göstergesidir (Gupta ve Maranas, 2021). Yapay zeka, gereksiz stok bulundurmaya önleyerek envanter maliyetlerini azaltmakta önemli bir rol oynar (Silver vd., 2016). Ayrıca, doğru talep tahminleri ve optimize edilmiş stok seviyeleri sayesinde yüksek servis seviyesinin sağlanmasını kolaylaştırır (Makridakis vd., 2018). Bunun yanı sıra, yapay zeka yenileme stratejilerini optimize ederek teslimat süreçlerini hızlandırır ve zamanında teslimatı destekler (Ivanov vd., 2023).

BÖLÜM 2. UYGULAMA YÖNTEMLERİ

Bu bölümde, çalışmada kullanılan veri setinin özellikleri, veri toplama ve hazırlama süreçleri, ABC analizi yöntemiyle ürün seçimi, yapay sinir ağları ve analiz yöntemleri detaylı bir şekilde açıklanmaktadır. Çalışma, 2021-2024 yıllarına ait verileri içermekte olup, 2021-2023 yılları eğitim veri seti, 2024 yılı ise test veri seti olarak ayrıştırılmıştır. Seçilen modellerin performansı, tahmin edilen değerlerin gerçekleşen verilerle karşılaştırılması yoluyla değerlendirilmiştir. Çalışma kapsamında, 97 adet farklı ürüne ait veri seti kullanılmıştır. Şekil 1’de veri setine dahil edilen ürünlerin 2021-2023 yılları arasındaki ortalama satış hacimleri dağılımının pasta grafiği verilmiştir.

Şekil 1

Satış Hacim Dağılımı Grafiği



2.1. Veri Toplama ve Veri Hazırlama

Bu çalışmada kullanılan veri seti, bir işletmenin 2021-2024 yılları arasındaki satış siparişi kayıtlarından ve ilgili ekonomik göstergelerden elde edilmiştir. Veri seti, işletme içi kayıtlar temel alınarak oluşturulmuş olup tarih, sipariş numarası, müşteri adı, müşteri bölgesi, ürün adı, talep miktarı, ve aylık ortalama döviz kurları, değişkenlerini içermektedir. Bu değişkenler, talep tahmini ve bölgesel satış dinamiklerinin analiz edilmesinde kritik rol oynamaktadır. Özellikle döviz kurları, ürün fiyatlarının döviz

bazında değerini etkileyerek siparişlerin bölgesel dağılımında önemli bir faktör olarak değerlendirilmiştir.

Çalışma kapsamında, veri setindeki tüm ürünler yerine, belirli kriterlere göre seçilen ürün grupları üzerinde analiz gerçekleştirilmiştir. Bu yaklaşım, tahminleme modellerinin belirli ürün gruplarına odaklanarak daha yüksek doğruluk oranı sağlaması amacıyla tercih edilmiştir. Ayrıca, tahminleme sürecinde 2021-2023 yıllarına ait veriler eğitim veri seti olarak, 2024 yılına ait veriler ise test veri seti olarak kullanılmıştır. Model performansını değerlendirmek amacıyla tahmin edilen değerler, 2024 yılına ait gerçekleşen verilerle karşılaştırılmıştır.

2.1.1. Veri Toplama Süreci

Bu çalışmada kullanılan satış siparişi verileri, işletmenin iç sistemlerinden elektronik formatta temin edilmiştir. Döviz kurları ise resmi finansal kaynaklardan alınarak aylık ortalama değerler şeklinde hesaplanmıştır. Tüm veriler, aylık bazda birleştirilmiş ve tahminleme süreçlerine uygun bir yapı oluşturulmuştur. Ayrıca, ürün bazlı analizlerde kullanılmak üzere veri setine türetilmiş değişkenler eklenmiştir. Bu değişkenler arasında ürün için gelen toplam sipariş sayısı, ürünü sipariş eden müşteri sayısı ve toplam satış hacmine oran yer almaktadır. Tablo 1’de 2021-2023 yılları arası aylık ortalama USD/TL kurları verilmiştir (Türkiye Cumhuriyet Merkez Bankası [TCMB], 2021, 2022, 2023).

Tablo 1

2021-2023 Yılları Arası Döviz Aylık Ortalama USD/TL Kurları

Yıl	Ay	Ortalama USD/TL Kuru
2021	Ocak	7,34
2021	Şubat	7,02
2021	Mart	7,45
2021	Nisan	8,1
2021	Mayıs	8,3
2021	Haziran	8,6
2021	Temmuz	8,55
2021	Ağustos	8,65
2021	Eylül	8,85
2021	Ekim	9,2
2021	Kasım	9,5
2021	Aralık	10
2022	Ocak	13,5
2022	Şubat	14
2022	Mart	14,5
2022	Nisan	14,8
2022	Mayıs	15,2

<i>Tablolar Devamı</i>		
2022	Haziran	16,5
2022	Temmuz	17,5
2022	Ağustos	18
2022	Eylül	18,2
2022	Ekim	18,5
2022	Kasım	18,6
2022	Aralık	18,7
2023	Ocak	18,8
2023	Şubat	18,9
2023	Mart	19,2
2023	Nisan	19,4
2023	Mayıs	20,8
2023	Haziran	25,9
2023	Temmuz	26,9
2023	Ağustos	26,7
2023	Eylül	27,4
2023	Ekim	28,3
2023	Kasım	28,9
2023	Aralık	29,6

2.1.2. Veri Hazırlama Adımları

Veri seti, tahminleme modellerine uygun hale getirilmesi amacıyla çeşitli ön işleme adımlarından geçirilmiştir:

- **Eksik Verilerin Tespiti ve Doldurulması:** Eksik müşteri ve sipariş bilgileri, mevcut kayıtlar doğrultusunda tamamlanmıştır. Döviz kuru verileri için ilgili dönemlere ait ortalama değerler referans alınmıştır.
- **Değişkenlerin Hesaplanması ve Dönüştürülmesi:** Döviz kurları ve sipariş miktarları numerik değerlere dönüştürülmüştür. Ayrıca, ürün bazlı talep eden müşteri sayısı, toplam talep sayısına oran, toplam talep miktarına oran, ihracat oranı gibi türetilmiş değişkenler hesaplanmıştır.
- **Tutarsız Verilerin Silinmesi:** Sipariş numaralarının benzersizliği kontrol edilmiş, hatalı ve tutarsız kayıtlar temizlenmiştir. Tarih ve döviz kuru verileri eşleştirilerek tutarlılık sağlanmıştır.
- **Verilerin Ayrıştırılması ve Seçilmesi:** Veri seti, 2021-2023 yılları eğitim veri seti, 2024 yılı ise test veri seti olarak ayrılmıştır. Hesaplamalarda kullanılmak üzere, ürün bazlı talep eden müşteri sayısı, toplam talep sayısına oran, toplam talep miktarına oran, ihracat oranı gibi türetilmiş veriler ile talep miktarı, ortalama döviz kuru ve tarih verileri seçilmiştir.

2.2. ABC Ürün Analizi Ürün Seçimi

Bu çalışmada, 2021-2023 yılları arasındaki ürün grubunda yer alan tüm ürünlerin satış hacimlerine göre sınıflandırılması amacıyla ABC analizi yapılmıştır. Analiz kapsamında, 2021-2023 yılları arasında bir ürün grubuna ait tüm ürünler satış katkı oranlarına göre sınıflandırılmıştır. ABC analizi, ürünlerin toplam satış üzerindeki katkı oranlarına göre sınıflandırılmasını sağlayan, işletme yönetiminde yaygın olarak kullanılan bir yöntemdir. Bu yöntem, Pareto'nun 80/20 kuralına dayanmaktadır (Pareto, 1896). ABC analizi, işletmelere kaynak kullanımında önceliklerini belirleme fırsatı sunarak, stratejik karar alma süreçlerini destekler (Slack vd., 2010).

ABC analizi, ürünlerin toplam satış içerisindeki katkı oranlarını dikkate alarak gruplara ayrılmasını sağlar. Amaç, işletme kaynaklarının daha verimli kullanılmasını desteklemek ve ürün bazlı tahminleme süreçlerine rehberlik etmektir. Bu çalışmada, analizin iki ana hedefi bulunmaktadır:

- Talep tahmini modellerinde kullanılmak üzere, farklı talep hacimlerine sahip ürünlerin seçilmesi.
- Yüksek, orta ve düşük talep seviyelerinde model performanslarının karşılaştırılması.

Bu amaç doğrultusunda yapılan ABC analizi, özellikle stok yönetiminde kullanılan bir karar verme aracı olarak önemli bir rol oynamaktadır (Silver vd., 1998).

2.2.1. ABC Analizi için Verileri Hazırlama Adımları

- **Verilerin Düzenlenmesi:** Analiz için, her ürünün toplam satış katkı oranı hesaplanmıştır. 2021-2023 yıllarına ait veriler kullanılarak, daha önce belirlenmiş olan satış dağılım yüzdesi kontrol edilmiştir. Bu işlem, ürünlerin toplam satışa olan etkilerini yüzdesel olarak ifade etmeyi amaçlar (Slack vd., 2010).
- **Ürünlerin Sıralanması:** Ürünler, satış katkı oranlarına göre azalan sırada sıralanmıştır. En yüksek satış oranına sahip ürünler üst sıralara yerleştirilmiştir. Bu sıralama, toplam satış üzerindeki ürün katkısını net bir şekilde analiz etmeyi amaçlamaktadır (Silver vd., 1998).
- **Kümülatif Yüzde Hesaplama:** En büyük satış oranına sahip ürünün, kümülatif yüzde değeri satış oranıdır. Her bir ürünün, kendisinin satış oranı ile kendisinden önce gelenin kümülatif yüzdesi toplanarak kendisine ait kümülatif yüzde değeri

hesaplanmıştır. Bu hesaplama, ürünlerin toplam satış üzerindeki birikimli etkisini analiz etmeyi sağlar ve ABC analizinin temelini oluşturur (Ramanathan, 2006).

- **Kategori Belirleme:** Kümülatif yüzdelere göre ürünler üç gruba ayrılmıştır. A Grubu, toplam satışın %70-80'ini oluşturan en yüksek katkıya sahip ürünleri kapsar. B grubu, toplam satışın %80-95'ini oluşturan orta katkıya sahip ürünleri kapsamaktadır. C grubu ise, toplam satışın %95-100'ünü oluşturan düşük katkıya sahip ürünleri kapsamaktadır. Bu kategorilendirme, işletme literatüründe sıkça kullanılan bir yaklaşımdır ve ürünlerin önem sırasına göre yönetilmesini sağlar (Slack vd., 2010; Silver vd., 1998). Ürünlere ait hesaplanan değerler ve analiz sonucu kategorisi aşağıdaki Tablo 2’de yer almaktadır.

Tablo 2

ABC Analizi Değerleri Tablosu

Ürün Adı	Satış Dağılımı %	Kümülatif Yüzde %	Kategori	Ürün Adı	Satış Dağılımı %	Kümülatif Yüzde %	Kategori
Ürün001	43,54	43,54	A	Ürün035	0,20	97,18	C
Ürün022	10,95	54,49	A	Ürün033	0,18	97,35	C
Ürün019	3,34	57,83	A	Ürün025	0,17	97,52	C
Ürün004	3,23	61,06	A	Ürün038	0,15	97,67	C
Ürün018	3,21	64,27	A	Ürün062	0,14	97,80	C
Ürün003	2,38	66,65	A	Ürün031	0,14	97,94	C
Ürün008	2,18	68,83	A	Ürün054	0,13	98,07	C
Ürün045	1,82	70,65	A	Ürün067	0,12	98,19	C
Ürün026	1,78	72,43	A	Ürün057	0,11	98,30	C
Ürün010	1,62	74,05	A	Ürün042	0,11	98,40	C
Ürün012	1,48	75,53	A	Ürün041	0,10	98,51	C
Ürün006	1,06	76,59	A	Ürün076	0,10	98,60	C
Ürün009	1,05	77,64	A	Ürün068	0,09	98,69	C
Ürün059	1,03	78,67	A	Ürün082	0,08	98,77	C
Ürün053	1,01	79,68	A	Ürün032	0,08	98,85	C
Ürün007	0,97	80,65	B	Ürün048	0,08	98,93	C
Ürün017	0,90	81,56	B	Ürün078	0,07	99,00	C
Ürün029	0,86	82,42	B	Ürün077	0,07	99,08	C
Ürün044	0,85	83,27	B	Ürün075	0,07	99,14	C
Ürün015	0,83	84,10	B	Ürün043	0,06	99,21	C
Ürün011	0,83	84,93	B	Ürün069	0,06	99,26	C
Ürün027	0,82	85,75	B	Ürün064	0,05	99,32	C
Ürün028	0,76	86,50	B	Ürün046	0,05	99,37	C

<i>Tablolar Devamı</i>							
Ürün072	0,63	87,13	B	Ürün021	0,05	99,42	C
Ürün030	0,60	87,73	B	Ürün065	0,05	99,47	C
Ürün056	0,57	88,30	B	Ürün073	0,05	99,51	C
Ürün020	0,57	88,87	B	Ürün083	0,05	99,56	C
Ürün071	0,55	89,42	B	Ürün052	0,04	99,60	C
Ürün023	0,49	89,91	B	Ürün085	0,04	99,64	C
Ürün092	0,48	90,40	B	Ürün081	0,04	99,68	C
Ürün039	0,48	90,87	B	Ürün051	0,04	99,72	C
Ürün016	0,48	91,35	B	Ürün058	0,03	99,75	C
Ürün034	0,44	91,79	B	Ürün088	0,03	99,78	C
Ürün055	0,43	92,22	B	Ürün089	0,03	99,81	C
Ürün066	0,41	92,63	B	Ürün060	0,03	99,84	C
Ürün036	0,40	93,04	B	Ürün086	0,03	99,87	C
Ürün024	0,40	93,43	B	Ürün079	0,02	99,89	C
Ürün014	0,39	93,83	B	Ürün063	0,02	99,90	C
Ürün061	0,36	94,19	B	Ürün080	0,02	99,92	C
Ürün005	0,36	94,54	B	Ürün090	0,01	99,93	C
Ürün049	0,31	94,86	C	Ürün091	0,01	99,94	C
Ürün050	0,31	95,17	C	Ürün104	0,01	99,95	C
Ürün070	0,30	95,47	C	Ürün105	0,01	99,96	C
Ürün047	0,28	95,75	C	Ürün040	0,01	99,97	C
Ürün002	0,28	96,03	C	Ürün084	0,01	99,98	C
Ürün074	0,26	96,28	C	Ürün087	0,01	99,99	C
Ürün102	0,25	96,54	C	Ürün103	0,00	100,00	C
Ürün037	0,23	96,77	C	Ürün106	0,00	100,00	C
Ürün013	0,21	96,98	C				

- **Ürün Seçimi:** Her kategoriden bir ürün seçilmiştir. Burada amaç; tahminleme modellerinde farklı talep hacimlerini temsil edecek ürünler kullanılarak, model performanslarının analiz edilmesi için yapılmıştır. Ürün seçimi, farklı talep düzeylerinde model doğruluğunu anlamayı kolaylaştırır (Ramanathan, 2006).

2.2.2. ABC Analizine Göre Seçilen Veri Setleri

ABC analizleri sonucunda talep tahminleme modellerine dahil edilerek analizleri yapılmak üzere A grubu için, Ürün001, B grubu için Ürün007, C grubu için Ürün049 tercih edilmiştir. Bu ürünlere ait veriler aşağıdaki Tablo 3, Tablo 4, Tablo 5 isimli tablolarda verilmiştir.

Tablo 3*Ürün001 için Hazırlanan Veri Seti*

Yıllar	Aylar	Talep Eden Müşteri Sayısı	Toplam Talep Sayısına Oran	Toplam Talep Miktarına Oran	Ortalama USD/TL Kuru	İhracat Oranı %	Talep miktarı
2021	Ocak	5	0,17391	0,40804	7,34	98,41	25090
2021	Şubat	8	0,09600	0,40392	7,02	98,08	64936
2021	Mart	15	0,11700	0,20003	7,45	99,32	44352
2021	Nisan	18	0,48684	0,72370	8,1	98,86	133569
2021	Mayıs	8	0,19355	0,44638	8,3	98,64	44226
2021	Haziran	4	0,10127	0,17031	8,6	82,44	5125
2021	Temmuz	3	0,19048	0,38058	8,55	87,65	2430
2021	Ağustos	10	0,31579	0,60574	8,65	99,29	35160
2021	Eylül	16	0,17857	0,49368	8,85	90,91	35481
2021	Ekim	8	0,08219	0,17965	9,2	83,28	11071
2021	Kasım	16	0,25694	0,73394	9,5	96,22	75075
2021	Aralık	11	0,09881	0,34479	10	91,49	34370
2022	Ocak	11	0,32143	0,77060	13,5	99,90	101312
2022	Şubat	7	0,10000	0,23112	14	81,47	18620
2022	Mart	16	0,19500	0,46201	14,5	99,61	101923
2022	Nisan	13	0,32500	0,67549	14,8	90,15	63526
2022	Mayıs	9	0,34000	0,74072	15,2	96,61	50412
2022	Haziran	8	0,26984	0,62719	16,5	84,46	52586
2022	Temmuz	4	0,20588	0,50053	17,5	100,00	24885
2022	Ağustos	12	0,19231	0,31632	18	80,70	32779
2022	Eylül	11	0,11243	0,32386	18,2	77,45	19842
2022	Ekim	12	0,17424	0,23946	18,5	63,58	10517
2022	Kasım	6	0,16393	0,26876	18,6	55,70	11694
2022	Aralık	19	0,15985	0,36533	18,7	68,06	46185
2023	Ocak	8	0,14085	0,33454	18,8	0,00	5100
2023	Şubat	23	0,13953	0,25583	18,9	55,88	28476
2023	Mart	15	0,12459	0,25655	19,2	91,13	33832
2023	Nisan	5	0,19355	0,18410	19,4	0,00	1100
2023	Mayıs	7	0,14085	0,58454	20,8	11,99	12640
2023	Haziran	15	0,25000	0,30887	25,9	50,83	9609
2023	Temmuz	13	0,22018	0,56586	26,9	86,74	52128
2023	Ağustos	11	0,15385	0,43961	26,7	95,36	33707
2023	Eylül	10	0,16279	0,30874	27,4	90,80	26522
2023	Ekim	12	0,15079	0,32837	28,3	87,67	12693
2023	Kasım	18	0,27723	0,53005	28,9	76,27	20434
2023	Aralık	16	0,16296	0,35702	29,6	97,02	57665

Tablo 4*Ürün007 için Hazırlan Veri Seti*

Yıllar	Aylar	Talep Eden Müşteri Sayısı	Toplam Talep Sayısına Oran	Toplam Talep Miktarına Oran	Ortalama USD/TL Kuru	İhracat Oranı %	Talep miktarı
2021	Ocak	1	0,01449	0,03791	7,34	100,00	2331
2021	Şubat	3	0,02400	0,01747	7,02	100,00	2809
2021	Mart	6	0,01325	0,02978	7,45	98,49	6603
2021	Nisan	1	0,00000	0,00000	8,1	0,00	0
2021	Mayıs	1	0,01613	0,00313	8,3	100,00	310
2021	Haziran	1	0,01266	0,00332	8,6	0,00	100
2021	Temmuz	1	0,00000	0,00000	8,55	0,00	0
2021	Ağustos	1	0,00000	0,00000	8,65	0,00	0
2021	Eylül	1	0,00714	0,00721	8,85	100,00	518
2021	Ekim	3	0,02283	0,02191	9,2	100,00	1350
2021	Kasım	1	0,00000	0,00000	9,5	0,00	0
2021	Aralık	5	0,02767	0,01816	10	100,00	1810
2022	Ocak	1	0,01190	0,00365	13,5	100,00	480
2022	Şubat	1	0,00769	0,01862	14	100,00	1500
2022	Mart	1	0,01000	0,00113	14,5	100,00	250
2022	Nisan	2	0,02500	0,00976	14,8	100,00	918
2022	Mayıs	1	0,02000	0,00147	15,2	0,00	100
2022	Haziran	1	0,01587	0,00119	16,5	0,00	100
2022	Temmuz	1	0,00000	0,00000	17,5	0,00	0
2022	Ağustos	1	0,00962	0,00695	18	100,00	720
2022	Eylül	2	0,01775	0,00630	18,2	74,09	386
2022	Ekim	1	0,00000	0,00000	18,5	0,00	0
2022	Kasım	1	0,00000	0,00000	18,6	0,00	0
2022	Aralık	1	0,00743	0,00634	18,7	100,00	801
2023	Ocak	1	0,00000	0,00000	18,8	0,00	0
2023	Şubat	4	0,02326	0,01739	18,9	90,96	1936
2023	Mart	4	0,01967	0,01260	19,2	100,00	1662
2023	Nisan	1	0,03226	0,01674	19,4	0,00	100
2023	Mayıs	1	0,01408	0,00472	20,8	100,00	102
2023	Haziran	1	0,01042	0,00328	25,9	100,00	102
2023	Temmuz	1	0,00000	0,00000	26,9	0,00	0
2023	Ağustos	1	0,00000	0,00000	26,7	0,00	0
2023	Eylül	3	0,01744	0,02019	27,4	100,00	1734
2023	Ekim	1	0,00794	0,00931	28,3	100,00	360
2023	Kasım	1	0,00000	0,00000	28,9	0,00	0
2023	Aralık	6	0,02593	0,01777	29,6	96,52	2870

Tablo 5*Ürün049 için Hazırlanan Veri Seti*

Yıllar	Aylar	Talep Eden Müşteri Sayısı	Toplam Talep Sayısına Oran	Toplam Talep Miktarına Oran	Ortalama USD/TL Kuru	İhracat Oranı %	Talep miktarı
2021	Ocak	1	0,01449	0,00325	7,34	0,00	200
2021	Şubat	1	0,00800	0,00621	7,02	100,00	999
2021	Mart	5	0,01325	0,00922	7,45	84,10	2044
2021	Nisan	1	0,00000	0,00000	8,1	0,00	0
2021	Mayıs	1	0,00000	0,00000	8,3	0,00	0
2021	Haziran	1	0,00000	0,00000	8,6	0,00	0
2021	Temmuz	1	0,00000	0,00000	8,55	0,00	0
2021	Ağustos	1	0,01754	0,01395	8,65	100,00	810
2021	Eylül	1	0,00000	0,00000	8,85	0,00	0
2021	Ekim	1	0,00000	0,00000	9,2	0,00	0
2021	Kasım	2	0,01389	0,00391	9,5	75,00	400
2021	Aralık	1	0,00000	0,00000	10	0,00	0
2022	Ocak	1	0,01190	0,00548	13,5	100,00	720
2022	Şubat	1	0,00000	0,00000	14	0,00	0
2022	Mart	1	0,00000	0,00000	14,5	0,00	0
2022	Nisan	1	0,01250	0,00542	14,8	100,00	510
2022	Mayıs	1	0,02000	0,00147	15,2	0,00	100
2022	Haziran	1	0,01587	0,00515	16,5	100,00	432
2022	Temmuz	1	0,00000	0,00000	17,5	0,00	0
2022	Ağustos	1	0,00000	0,00000	18	0,00	0
2022	Eylül	1	0,00000	0,00000	18,2	0,00	0
2022	Ekim	1	0,00000	0,00000	18,5	0,00	0
2022	Kasım	1	0,00000	0,00000	18,6	0,00	0
2022	Aralık	2	0,00743	0,00167	18,7	64,45	211
2023	Ocak	2	0,02817	0,01640	18,8	0,00	250
2023	Şubat	1	0,00388	0,00090	18,9	0,00	100
2023	Mart	2	0,00656	0,00438	19,2	100,00	578
2023	Nisan	1	0,00000	0,00000	19,4	0,00	0
2023	Mayıs	1	0,01408	0,00513	20,8	100,00	111
2023	Haziran	2	0,02083	0,00643	25,9	0,00	200
2023	Temmuz	3	0,04587	0,00918	26,9	76,36	846
2023	Ağustos	3	0,03419	0,01242	26,7	100,00	952
2023	Eylül	1	0,00000	0,00000	27,4	0,00	0
2023	Ekim	1	0,00000	0,00000	28,3	0,00	0
2023	Kasım	1	0,00990	0,00529	28,9	100,00	204
2023	Aralık	1	0,00000	0,00000	29,6	0,00	0

2.3. Matlab ile Yapay Sinir Ağları Tekniği Kullanarak Talep Tahmini

Tedarik zinciri yönetimi, günümüz şartlarında firmaların rekabet avantajlarını sürdürmelerinde çok kritik bir rol oynar. Bu kapsamda, talep tahmini, ürün veya hizmetlerin ihtiyaç duyulan miktarlarının önceden belirlenmesine olanak tanır (Chopra ve Meindl, 2019). Geleneksel yöntemler genellikle doğrusal ilişkilere dayanırken, yapay sinir ağları (ANN) gibi modern yaklaşımlar doğrusal olmayan ve karmaşık veri desenlerini modelleyebilme yetenekleriyle öne çıkar (Zhang vd., 1998).

Bu çalışmada, ANN yardımıyla talep tahmini süreci MATLAB R2024b ortamında uygulanmış ve yöntemler adım adım açıklanmıştır.

2.3.1. Veri Setinin Yüklenmesi ve Normalizasyon

MATLAB'da veriler bir tablo olarak içe aktarılır. Eksik değerler ve tutarsızlıklar, analiz öncesinde temizlenir. Veri setinde, eksik veri ve aykırı değerler tespit edilmemiştir. Verinin kaliteli olması, modelin başarısını doğrudan etkiler (Chopra ve Meindl, 2019).

Normalizasyon, bir veri setindeki değişkenlerin farklı ölçeklerde olmasını dengeleyerek modelin daha etkili bir şekilde öğrenmesini sağlayan bir ön işleme yöntemidir. Bu işlem, özellikle yapay sinir ağları (ANN) gibi algoritmalarda model performansını artırır ve eğitim sürecini hızlandırır (Hyndman ve Athanasopoulos, 2021). Farklı ölçeklerdeki veriler, modelin ağırlık optimizasyon sürecinde dengesizliklere neden olabilir ve bu durum öğrenme sürecini zorlaştırır (Zhang vd., 1998). Bu sorunu çözmek için, veri özelliklerinin belirli bir aralığa dönüştürülmesi gerekir.

Veriye uygun olarak normalizasyon, "min-max normalizasyonu" yöntemi tercih edilmiştir. Bu yöntemde, veri her bir özellik için [0, 1] aralığına ölçeklendirilir (Makridakis vd., 1998). Kullanılan denklem şu şekildedir:

$$x' = \frac{x - \min(x)}{\max(x) - \min(x)} \quad (2.1)$$

Burada:

- x' : Normalleştirilmiş veri,
- x : Orijinal veri,
- $\min(x)$: Verinin minimum değeri,
- $\max(x)$: Verinin maksimum değeri.

Verinin minimum ve maksimum değerleri hesaplanır. Bu hesaplama, özellikle özelliklerin geniş bir aralıkta değişkenlik gösterdiği durumlarda önemlidir (Zhang vd., 1998).

Normalizasyon verileri hesaplanırken excel uygulaması kullanılmıştır. Her veri yukarıdaki denklem kullanılarak normalize edilmiş ve sonrasında tüm değerlerin 0 ve 1 aralığında olup olmadığının kontrolü yapılmıştır. Normalizasyon sonuçları aşağıdaki Tablo 6, Tablo 7 ve Tablo 8’de verilmiştir. Normalizasyon işlemi yapıldıktan sonra veriler matlab için uygun hale gelmesi için transpose edilmiştir. Transpoze edilen değerlerden; talep miktarı normalizasyon değeri target, diğer değerler input olarak programa yüklenmiştir.

Tablo 6

Ürün001 için Normalizasyon Değerleri

Talep Eden Müşteri Sayısı Normalizasyo nu	Toplam Talep Sayısına Oran Normalizasyo nu	Toplam Talep Miktarına Oran Normalizasyo nu	Ortalama USD/TL Kuru Normalizasyo nu	İhracat Oranı % Normalizasyo nu	Talep miktarı Normalizasyo nu
0,10000	0,22667	0,396032288	0,01	0,984057393	0,18110
0,25000	0,03412	0,389170319	0,00	0,980750277	0,48189
0,60000	0,08602	0,049515019	0,02	0,993235931	0,32651
0,75000	1,00000	0,921882303	0,05	0,98858268	1,00000
0,25000	0,27519	0,45989306	0,06	0,98643332	0,32556
0,05000	0,04714	0	0,07	0,824390244	0,03038
0,00000	0,26760	0,350286264	0,07	0,87654321	0,01004
0,35000	0,57728	0,725366037	0,07	0,992889647	0,25712
0,65000	0,23818	0,538689004	0,08	0,909106282	0,25954
0,25000	0,00000	0,015573491	0,10	0,832806431	0,07527
0,65000	0,43186	0,938938349	0,11	0,962237762	0,55843
0,40000	0,04108	0,29065962	0,13	0,914896712	0,25115
0,40000	0,59122	1	0,29	0,99901295	0,75649
0,20000	0,04401	0,10130458	0,31	0,81471536	0,13226
0,65000	0,27878	0,48593697	0,33	0,996075469	0,76111
0,50000	0,60004	0,841568446	0,34	0,901536379	0,47125
0,30000	0,63711	0,950230247	0,36	0,966079505	0,37225
0,25000	0,46373	0,761101403	0,42	0,844635454	0,38866
0,05000	0,30567	0,550111521	0,46	1	0,17955
0,45000	0,27213	0,243244715	0,49	0,807041093	0,23914
0,40000	0,07472	0,255792881	0,50	0,7744683	0,14148
0,45000	0,22748	0,115198439	0,51	0,635827708	0,07109

<i>Tablolar Devamı</i>					
0,15000	0,20201	0,164010535	0,51	0,557037797	0,07997
0,80000	0,19192	0,324887398	0,52	0,68063224	0,34034
0,25000	0,14495	0,27358433	0,52	0	0,03020
1,00000	0,14171	0,142472762	0,53	0,558751229	0,20666
0,60000	0,10478	0,143670836	0,54	0,911326555	0,24709
0,10000	0,27519	0,02298053	0,55	0	0,00000
0,20000	0,14495	0,690047856	0,61	0,119857595	0,08711
0,60000	0,41470	0,230831534	0,84	0,508273494	0,06423
0,50000	0,34101	0,658944267	0,88	0,867441682	0,38521
0,40000	0,17708	0,448630026	0,87	0,953570475	0,24615
0,35000	0,19918	0,230606059	0,90	0,908000905	0,19191
0,45000	0,16953	0,263306674	0,94	0,876703695	0,08751
0,75000	0,48199	0,599284384	0,97	0,762650484	0,14595
0,65000	0,19961	0,311045321	1,00	0,970172548	0,42701

Tablo 7

Ürün007 için Normalizasyon Değerleri

Talep Eden Müşteri Sayısı Normalizasyo nu	Toplam Talep Sayısına Oran Normalizasyo nu	Toplam Talep Miktarına Oran Normalizasyo nu	Ortalama USD/TL Kuru Normalizasyo nu	İhracat Oranı % Normalizasyo nu	Talep miktarı Normalizasyo nu
0,00000	0,44928	1	0,01	1	0,35302
0,40000	0,74400	0,460912082	0,00	1	0,42541
1,00000	0,41060	0,785553765	0,02	0,984855369	1,00000
0,00000	0,00000	0	0,05	0	0,00000
0,00000	0,50000	0,082535278	0,06	1	0,04695
0,00000	0,39241	0,087657619	0,07	0	0,01514
0,00000	0,00000	0	0,07	0	0,00000
0,00000	0,00000	0	0,07	0	0,00000
0,00000	0,22143	0,190121499	0,08	1	0,07845
0,40000	0,70776	0,577881831	0,10	1	0,20445
0,00000	0,00000	0	0,11	0	0,00000
0,80000	0,85771	0,478965154	0,13	1	0,27412
0,00000	0,36905	0,096308169	0,29	1	0,07269
0,00000	0,23846	0,491134004	0,31	1	0,22717
0,00000	0,31000	0,029893303	0,33	1	0,03786
0,20000	0,77500	0,257493781	0,34	1	0,13903
0,00000	0,62000	0,038759304	0,36	0	0,01514
0,00000	0,49206	0,031461771	0,42	0	0,01514
0,00000	0,00000	0	0,46	0	0,00000
0,00000	0,29808	0,18328339	0,49	1	0,10904

<i>Tablolar Devamı</i>					
0,20000	0,55030	0,166191481	0,50	0,740932642	0,05846
0,00000	0,00000	0	0,51	0	0,00000
0,00000	0,00000	0	0,51	0	0,00000
0,00000	0,23048	0,167138047	0,52	1	0,12131
0,00000	0,00000	0	0,52	0	0,00000
0,60000	0,72093	0,458811326	0,53	0,909607438	0,29320
0,60000	0,60984	0,332453026	0,54	1	0,25170
0,00000	1,00000	0,441486316	0,55	0	0,01514
0,00000	0,43662	0,124428337	0,61	1	0,01545
0,00000	0,32292	0,086487893	0,84	1	0,01545
0,00000	0,00000	0	0,88	0	0,00000
0,00000	0,00000	0	0,87	0	0,00000
0,40000	0,54070	0,532458553	0,90	1	0,26261
0,00000	0,24603	0,245669917	0,94	1	0,05452
0,00000	0,00000	0	0,97	0	0,00000
1,00000	0,80370	0,468728653	1,00	0,965156794	0,43465

Tablo 8

Ürün049 için Normalizasyon Değerleri

Talep Eden Müşteri Sayısı Normalizasyo nu	Toplam Talep Sayısına Oran Normalizasyo nu	Toplam Talep Miktarına Oran Normalizasyo nu	Ortalama USD/TL Kuru Normalizasyo nu	İhracat Oranı % Normalizasyo nu	Talep miktarı Normalizasyo nu
0,00000	0,31594	0,198344419	0,01	0	0,09785
0,00000	0,17440	0,378934463	0,00	1	0,48875
1,00000	0,28874	0,562144249	0,02	0,840998043	1,00000
0,00000	0,00000	0	0,05	0	0,00000
0,00000	0,00000	0	0,06	0	0,00000
0,00000	0,00000	0	0,07	0	0,00000
0,00000	0,00000	0	0,07	0	0,00000
0,00000	0,38246	0,850957016	0,07	1	0,39628
0,00000	0,00000	0	0,08	0	0,00000
0,00000	0,00000	0	0,10	0	0,00000
0,25000	0,30278	0,238459282	0,11	0,75	0,19569
0,00000	0,00000	0	0,13	0	0,00000
0,00000	0,25952	0,333953998	0,29	1	0,35225
0,00000	0,00000	0	0,31	0	0,00000
0,00000	0,00000	0	0,33	0	0,00000
0,00000	0,27250	0,330694143	0,34	1	0,24951
0,00000	0,43600	0,089600047	0,36	0	0,04892
0,00000	0,34603	0,314194933	0,42	1	0,21135

<i>Tablolar Devamı</i>					
0,00000	0,00000	0	0,46	0	0,00000
0,00000	0,00000	0	0,49	0	0,00000
0,00000	0,00000	0	0,50	0	0,00000
0,00000	0,00000	0	0,51	0	0,00000
0,00000	0,00000	0	0,51	0	0,00000
0,25000	0,16208	0,101778847	0,52	0,644549763	0,10323
0,25000	0,61408	1	0,52	0	0,12231
0,00000	0,08450	0,054784921	0,53	0	0,04892
0,25000	0,14295	0,267275636	0,54	1	0,28278
0,00000	0,00000	0	0,55	0	0,00000
0,00000	0,30704	0,313021643	0,61	1	0,05431
0,25000	0,45417	0,392028287	0,84	0	0,09785
0,50000	1,00000	0,560014329	0,88	0,763593381	0,41389
0,50000	0,74530	0,7571401	0,87	1	0,46575
0,00000	0,00000	0	0,90	0	0,00000
0,00000	0,00000	0	0,94	0	0,00000
0,00000	0,21584	0,322687349	0,97	1	0,09980
0,00000	0,00000	0	1,00	0	0,00000

2.3.2. Modelin Oluşturulması ve Performansı

2024 verileri için tahmini döviz verileri ve diğer veriler için geçmiş yılların ortalaması ile 2024 yılı input verileri oluşturulmuştur. Verilerin Matlab sistemine yüklenmesi sonrası Neural Network Fitting (nftool) işlemleri yapılmıştır (İleri beslemeli geri yayılım sinir ağı modeli). Bu işlemle birbirinden bağımsız veriler arasında bağ yapısı oluşturulmuştur. Oluşturulan modeller için eğitim tabloları ve performans grafikleri aşağıdaki başlıklarda incelenmiştir.

2.3.2.1. Eğitim Sonuçlarının Okunması

Makine öğrenimi ve derin öğrenim modellerinde eğitim sürecini açıklayan bu tablo, çeşitli metriklerin başlangıç, durdurma ve hedef değerlerini sunarak model optimizasyon sürecine dair bilgi verir. **Epoch** başlığı, modelin bir veri seti üzerinde tamamladığı tam eğitim döngüsünü temsil eder ve eğitim başlangıcından (Initial Value) durdurulma (Stopped Value) anına kadar olan ilerlemeyi gösterir (Goodfellow vd., 2016). **Elapsed Time**, model eğitimi sırasında geçen süreyi ifade eder; bu tablolarda durdurma anında geçen zamanı ifade eder ancak hedef bir süre belirtilmemiştir. **Performance**, genellikle modelin kayıp fonksiyonu üzerinden değerlendirilen performansını ifade eder ve

başlangıç değerinden (Initial Value) hedeflenen bir minimum kayba doğru (Target Value) iyileşme sürecini gösterir (Chollet, 2017).

Tablodaki **Gradient**, optimizasyon sürecinde kayıp fonksiyonunun eğim büyüklüğünü temsil eder ve genellikle zamanla küçülerek modelin daha stabil hale geldiğini gösterir (Kingma ve Ba, 2015). **Mu**, Levenberg-Marquardt algoritmasında kullanılan damping parametresini ifade eder; bu parametre, optimizasyon sürecinde dengeleme sağlar ve genellikle model eğitimi boyunca değişir (Hagan vd., 1996). Son olarak, **Validation Checks**, doğrulama setinde modelin performansını kontrol etmek için yapılan değerlendirme sayısını temsil eder. Bu metrik, erken durdurma kriterleriyle ilişkilidir ve aşırı öğrenmeyi önlemek için kullanılır (Prechelt, 1998).

2.3.2.2. Ürün001 Eğitim ve Model Performansı

Ürün001 için oluşturulan modelin eğitilmesi aşamasındaki sonuçlar aşağıdaki Tablo 9’da verilmiştir.

Tablo 9

Ürün001 Eğitim Sonuçları

Unit	Initial Value	Stopped Value	Target Value
Epoch	0	8	1000
Elapsed Time	-	00:00:01	-
Performance	2.42	1.60E-19	0
Gradient	3.63	4.04E-10	1.00E-07
Mu	0.001	1.00E-09	1.00E+10
Validation Checks	0	5	6

Epoch: Eğitim başlangıcında epoch sayısı 0 olup, durdurulma noktasında sadece 8 epoch tamamlanmıştır. Hedef epoch sayısı 1000’dir, ancak model, erken durdurma kriteri nedeniyle eğitimin tamamlanmasından önce sonlandırılmıştır. Bu, modelin doğrulama seti üzerindeki performansına bağlı olarak fazla uyumlamayı önlemek amacıyla eğitimin erken durdurulduğunu göstermektedir (Prechelt, 1998).

Elapsed Time: Eğitim süresince geçen zaman durdurulma anında sadece 1 saniye olarak belirtilmiştir. Bu durum, modelin eğitiminin nispeten hızlı bir şekilde tamamlandığını ve küçük bir veri seti veya hızlı bir optimizasyon süreciyle çalışıldığını düşündürmektedir. Bu aynı zamanda uygulamanın kullanıldığı bilgisayar performansına da bağlıdır. (Intel

Core i5-4200M, 2.5 GHz hızında, Turbo Boost ile 3.1 GHz'e kadar çıkabilen çift çekirdekli bir işlemci kullanılmıştır.)

Performance: Modelin başlangıç kaybı 2.42 olup, eğitimin sonunda bu değer $1.60E-19$ 'a kadar düşmüştür. Hedef kayıp değeri 0'dır. Bu dramatik düşüş, modelin kayıp fonksiyonunu neredeyse tamamen minimize ettiğini ve etkili bir öğrenme süreci gerçekleştirdiğini göstermektedir (Chollet, 2017). Kayıp değerindeki bu düşük seviyeye ulaşmak, modelin doğru yapılandırılmış hiperparametrelerle eğitildiğini ve optimizasyon sürecinin verimli olduğunu işaret eder.

Gradient: Başlangıç gradyanı 3.63 iken durdurulma noktasında $4.04E-10$ 'a kadar düşmüştür. Bu, optimizasyon algoritmasının (örneğin, Adam veya Levenberg-Marquardt) model ağırlıklarını başarılı bir şekilde güncellediğini ve kayıp fonksiyonunun minimum noktasına yaklaştığını göstermektedir. Hedef gradyan değeri olan $1.00E-07$ 'nin altına inilmiş olması, modelin optimizasyon sürecinde hedeflenen stabiliteyi aştığını göstermektedir (Kingma ve Ba, 2015).

Mu: Levenberg-Marquardt algoritmasında kullanılan damping parametresi, başlangıç değeri olan 0.001'den $1.00E-09$ 'a kadar düşmüştür. Bu, modelin optimizasyon sürecinde çok daha küçük adımlarla ilerlediğini ve hassas bir şekilde kayıp fonksiyonunun minimumuna yaklaştığını göstermektedir. Ancak hedef damping parametresi olan $1.00E+10$ 'a ulaşamamıştır. Bu, eğitimin daha uzun süre devam etmesi durumunda algoritmanın farklı bir dengeleme seviyesine geçebileceğini düşündürmektedir (Hagan vd., 1996).


Validation Checks: Eğitim süreci boyunca 5 doğrulama kontrolü yapılmış ve hedeflenen 6 kontrol sayısına ulaşamamıştır. Bu, erken durdurma kriterinin modelin doğrulama setindeki performansı temel alarak eğitimi sonlandırdığını göstermektedir. Bu, aşırı öğrenmeyi önleme ve modelin genelleme yeteneğini artırma açısından önemli bir adımdır (Prechelt, 1998).

Veriler, modelin hızlı ve etkili bir şekilde optimize edildiğini ve kaybın neredeyse tamamen ortadan kaldırıldığını göstermektedir. Gradyan büyüklüğündeki düşüş ve damping parametresindeki azalma, optimizasyon algoritmasının başarılı bir şekilde çalıştığını ortaya koymaktadır. Modelin eğitim süreci kısa sürmesine rağmen doğrulama ve performans kriterlerine göre etkili bir sonuç elde edilmiştir.

Aşağıdaki grafik, yapay sinir ağı modelinin eğitim sürecindeki **Mean Squared Error (MSE)** değişimini göstermektedir. Grafik, eğitim (train), doğrulama (validation) ve test setlerindeki hataları epoch (iterasyon) sayısına göre karşılaştırır.

Şekil 2

Ürün001 için Performans Grafiği



Eğitim performansını belirten mavi çizgi, eğitim seti üzerindeki hatayı temsil etmektedir. Model, epoch ilerledikçe bu hata değerini azaltmaktadır. Grafik, eğitim sürecinde modelin sürekli öğrenme kaydettiğini göstermektedir. Doğrulama performansı olan yeşil çizgi, doğrulama setindeki hata oranını ifade eder. Model, doğrulama setinde en iyi performansı epoch 3'te sergilemiştir (MSE = 0.051017). Bu noktadan sonra doğrulama hatası değişmemiştir ve sabit kalmıştır. Test performansı olan kırmızı çizgi, test setindeki hata oranını göstermektedir ve doğrulama performansına oldukça yakındır. Bu durum, modelin genelleştirme yeteneğinin tatmin edici olduğunu ifade etmektedir. Overfitting riski, epoch 3'ten sonra eğitim hatası hızla azalırken doğrulama ve test hatalarının sabit kalması, modelin overfitting yapabileceğini düşündürmektedir. Bu durumda erken durdurma (early stopping) stratejisi önerilebilir (Goodfellow vd., 2016).

2.3.2.3. Ürün007 Eğitim ve Model Performansı

Ürün007 için oluşturulan modelin eğitilmesi aşamasındaki sonuçlar aşağıdaki Tablo 10'da verilmiştir.

Tablo 10

Ürün007 Eğitim Sonuçları

Unit	Initial Value	Stopped Value	Target Value
Epoch	0	13	1000
Elapsed Time	-	00:00:00	-
Performance	0.247	1.27E-05	0
Gradient	0.696	1.50E-04	1.00E-07
Mu	0.001	1.00E-05	1.00E+10
Validation Checks	0	6	6

Epoch: Eğitim başlangıcında epoch sayısı 0 olup, durdurulma noktasında 13 epoch tamamlanmıştır. Hedef epoch sayısı 1000'dir ancak model eğitimi erken durdurma kriteri ile sonlandırılmıştır. Bu, modelin doğrulama setinde en iyi performansı elde ettiği noktada eğitim sürecinin durdurulduğunu ve fazla uyumlamanın önüne geçildiğini göstermektedir (Prechelt, 1998).

Elapsed Time: Eğitim süresine ilişkin durdurulma anında herhangi bir zaman bilgisi sunulmamıştır. Ancak tamamlanan 13 epoch üzerinden, modelin nispeten kısa bir eğitim süreci geçirdiği çıkarılabilir.

Performance: Modelin başlangıç kaybı 0.247 iken eğitim durdurulduğunda bu değer 1.27E-05'e düşmüştür. Hedeflenen performans kaybı 0'dır. Kayıptaki bu belirgin azalma, modelin etkili bir şekilde optimize edildiğini ve öğrenmenin başarılı olduğunu göstermektedir (Chollet, 2017).

Gradient: Başlangıç gradyan değeri 0.696 olarak verilmiştir ve durdurulma noktasında 1.50E-04'e kadar düşmüştür. Gradyan değerindeki bu azalma, optimizasyon algoritmasının (muhtemelen Adam veya Levenberg-Marquardt gibi) ağırlıkları düzenli bir şekilde güncellediğini ve modelin stabil bir öğrenme sürecinde olduğunu göstermektedir. Ancak hedef değer olan 1.00E-07'ye ulaşamamıştır; bu, eğitim süresinin yeterince uzun olmamasından kaynaklanabilir (Kingma ve Ba, 2015).

Mu: Levenberg-Marquardt algoritmasında kullanılan damping parametresi başlangıç değeri olan 0.001'den durdurulma noktasında 1.00E-05'e düşmüştür. Bu, optimizasyon


sürecinde modelin daha esnek bir şekilde öğrenme gerçekleştirdiğini ve kayıp fonksiyonunun minimum noktasına yaklaştığını göstermektedir (Hagan vd., 1996). Ancak hedef damping parametresine ($1.00E+10$) ulaşılmamıştır, bu da eğitimin yeterince uzun süre devam etmediğini gösterebilir.

Validation Checks: Toplam 6 doğrulama kontrolü yapılmıştır. Bu, erken durdurma kriterinin aktif olarak uygulandığını ve modelin doğrulama setindeki performansına göre optimize edildiğini göstermektedir. Doğrulama kontrolleri, modelin aşırı öğrenmesini önlemek ve genel performansı artırmak için kritik bir araçtır (Prechelt, 1998).

Veriler, modelin eğitim sürecinde performansını önemli ölçüde artırdığını ve kaybını optimize ettiğini göstermektedir. Gradyandaki düşüş ve damping parametresindeki azalma, optimizasyon algoritmasının stabil bir şekilde çalıştığını ortaya koymaktadır. Ancak hedef epoch sayısına ve damping parametresine ulaşılammış olması, eğitimin daha uzun süre devam etmesi durumunda model performansının daha da iyileşebileceğini düşündürmektedir.

Şekil 3

Ürün007 Performans Grafiği



Eğitim performansını belirten mavi çizgi, eğitim seti üzerindeki hatayı temsil etmektedir. Model, epoch ilerledikçe bu hata değerini azaltmaktadır. Grafik, eğitim sürecinde modelin sürekli öğrenme kaydettiğini göstermektedir. Doğrulama performansı olan yeşil çizgi, doğrulama setindeki hata oranını ifade eder. Model, doğrulama setinde en iyi

performansı epoch 7'de sergilemiştir ($MSE = 0.0088782$). Bu noktadan sonra doğrulama hatası sabit kalmış veya hafif bir artış göstermiştir. Test performansı olan kırmızı çizgi, test setindeki hata oranını göstermektedir ve doğrulama performansına oldukça yakındır. Bu durum, modelin genelleştirme yeteneğinin tatmin edici olduğunu ifade etmektedir. Overfitting riski, epoch 7'den sonra eğitim hatası hızla azalırken doğrulama ve test hatalarının sabit kalması veya artış göstermesi, modelin overfitting yapabileceğini düşündürmektedir. Bu durumda erken durdurma (early stopping) stratejisi önerilebilir (Goodfellow vd., 2016).

2.3.2.4. Ürün049 Eğitim ve Model Performansı

Ürün049 için oluşturulan modelin eğitilmesi aşamasındaki sonuçlar aşağıdaki Tablo 11'de verilmiştir.

Tablo 11

Ürün049 Eğitim Sonuçları

Unit	Initial Value	Stopped Value	Target Value
Epoch	0	10	1000
Elapsed Time	-	00:00:00	-
Performance	0.375	1.73E-05	0
Gradient	1.42	7.12E-04	1.00E-07
Mu	0.001	1.00E-05	1.00E+10
Validation Checks	0	6	6

Epoch: Eğitimin başlangıcından itibaren toplam 10 epoch tamamlanmıştır, ancak hedeflenen epoch sayısı 1000'dir. Eğitim, muhtemelen bir erken durdurma kriteri nedeniyle tamamlanmadan önce sona erdirilmiştir. Bu, modeli fazla uyumlamadan korumak için yaygın bir stratejidir (Prechelt, 1998).

Elapsed Time: Eğitim süresi durdurma noktasında belirtilmemiştir. Süre bilgisi eksik olsa da, epoch sayısına dayanarak nispeten kısa bir eğitim süreci olduğu düşünülebilir.

Performance: Başlangıç kaybı 0.375 iken durdurma noktasında bu değer 1.73E-05'e kadar düşmüştür. Bu, kaybın hedef değer olan 0'a yaklaştığını ve modelin optimize edildiğini gösterir. Performansta bu düzeyde bir azalma, modelin etkili bir öğrenme gerçekleştirdiğini ve doğru hiperparametrelerle eğitildiğini gösterir.

Gradient: Başlangıç gradyan büyüklüğü 1.42'den 7.12E-04'e düşmüştür. Bu azalma, modelin kayıp fonksiyonunu optimize ederken ağırlıkların düzenli bir şekilde

güncellendiğini ve modelin stabil bir duruma yaklaştığını gösterir. Hedef gradyan değeri olan $1.00E-07$ 'ye ulaşılmamış olsa da, gradyandaki bu düşüş eğilimi optimizasyonun başarılı olduğunu düşündürür (Kingma ve Ba, 2015).


Mu: Başlangıç damping parametresi 0.001 'den $1.00E-05$ 'e düşürülmüştür. Bu, modelin Levenberg-Marquardt algoritmasıyla uyumlu şekilde optimizasyon sürecini dengelediğini gösterir. Ancak hedef değer olan $1.00E+10$ 'a ulaşılmamıştır; bu durum, eğitim süresinin sınırlı olmasından kaynaklanıyor olabilir (Hagan vd., 1996).

Validation Checks: Eğitim sürecinde toplam 6 doğrulama kontrolü yapılmıştır. Bu, erken durdurma kriterlerinin aktif olarak uygulandığını ve modelin doğrulama seti üzerinde gözlemlenerek optimize edildiğini gösterir. Bu yaklaşım, eğitim sırasında modelin aşırı öğrenmesini önlemek için önemlidir (Prechelt, 1998).

Bu veriler, eğitim sürecinin etkili bir şekilde ilerlediğini ve modelin optimize edildiğini göstermektedir. Bununla birlikte, epoch sayısının sınırlı kalması ve hedef damping parametresine ulaşamaması, daha uzun bir eğitim sürecinin model performansını daha da iyileştirebileceğini düşündürmektedir.

Şekil 4

Ürün049 Performans Grafiği



Eğitim performansını belirten mavi çizgi, eğitim seti üzerindeki hatayı temsil etmektedir. Model, epoch ilerledikçe bu hata değerini azaltmaktadır. Grafik, eğitim sürecinde modelin sürekli öğrenme kaydettiğini göstermektedir. Doğrulama performansı olan yeşil çizgi, doğrulama setindeki hata oranını ifade eder. Model, doğrulama setinde en iyi

performansı epoch 4'te sergilemiştir (MSE = 0.012111). Bu noktadan sonra doğrulama hatası artış göstermiştir. Test performansı olan kırmızı çizgi, test setindeki hata oranını göstermektedir ve doğrulama performansına oldukça yakındır. Bu durum, modelin genelleştirme yeteneğinin tatmin edici olduğunu ifade etmektedir. Overfitting riski, epoch 4'ten sonra eğitim hatası hızla azalırken doğrulama ve test hatalarının sabit kalması ya da artış göstermesi, modelin overfitting yapabileceğini düşündürmektedir. Bu durumda erken durdurma (early stopping) stratejisi önerilebilir (Goodfellow vd., 2016).

2.3.3. Sonuçların Analizi

2.3.4.1. Mutlak Hata

Yüzde Mutlak Hata (PAE), bir modelin tahmin performansını değerlendirmek için kullanılan yaygın ve anlaşılır bir ölçüttür. Bu metrik, tahmin edilen değer ile gerçek değer arasındaki farkın, gerçek değere oranlanarak yüzdelik bir hata değeri olarak ifade edilmesini sağlar. Özellikle birim farklarının karışıklık yaratabileceği durumlarda, PAE modelin doğruluğunu standartlaştırılmış bir ölçüyle ifade etmek için idealdir.

$$\text{Yüzde Mutlak Hata} = \frac{|\text{Gerçekleşen} - \text{Tahmin}|}{|\text{Gerçekleşen}|} \times 100 \quad (2.2)$$

PAE, genellikle ekonomik göstergeler, enerji tüketimi, hava durumu tahminleri ve diğer gerçek değerlerle tahmin edilen değerlerin doğruluğunun karşılaştırıldığı alanlarda kullanılır. Bu metrik, farklı veri setlerinin performansını kolayca karşılaştırmaya olanak tanır. Örneğin, PAE farklı büyüklükteki veri noktalarını normalize ettiği için hem büyük hem de küçük ölçekli tahminlerin aynı standartta değerlendirilmesine imkan tanır (Hyndman ve Koehler, 2006).

Ortalama Mutlak Yüzde Hata (MAPE), modelin tahmin hatalarının ortalama yüzdesini gösteren bir hata metriğidir. PAE'nin tekil gözlemler için hata yüzdesini hesaplamasından farklı olarak, MAPE tüm tahminlerin ortalamasını alarak modelin genel doğruluğunu ölçer.

$$\text{Ortalama Mutlak Yüzde Hata} = \frac{1}{n} \sum_{i=1}^n \left| \frac{Y_i - y_i}{Y_i} \right| \times 100 \quad (2.3)$$

Burada:

- Y_i = Gerçekleşen değer
- y_i = Tahmin edilen değer

- n = Toplam veri noktası sayısı

MAPE, modelin tüm veri seti üzerindeki ortalama hata oranını belirlemek için kullanılır ve tahminlerin tutarlılığını değerlendirmede önemli bir ölçüttür. Ancak, gerçekleşen değer sıfıra yaklaştığında büyük hata yüzdeleri üretebilir, bu nedenle küçük veri setleri veya sıfıra yakın değerlerin olduğu durumlarda dikkatli değerlendirilmelidir (Hyndman ve Koehler, 2006).

Simetrik Ortalama Mutlak Yüzde Hata (SMAPE), MAPE'nin bir türevidir ve gerçekleşen değerlerin sıfır olduğu durumlarda aşırı büyük hata oranlarının ortaya çıkmasını önlemek için geliştirilmiştir. SMAPE, tahmin edilen ve gerçekleşen değerler arasındaki farkı, bu iki değerlerin ortalamasına bölerek hesaplanır.

$$\text{Simetrik Ortalama Mutlak Yüzde Hata} = 100 \times \frac{|Y_i - y_i|}{\frac{|Y_i| + |y_i|}{2}} \quad (2.4)$$

Burada:

- Y_i = Gerçekleşen değer
- y_i = Tahmin edilen değer

SMAPE, MAPE'nin aksine, hata yüzdesini tahmin edilen ve gerçekleşen değerlerin aritmetik ortalamasına bölerek normalize eder. Böylece, gerçekleşen değerlerin sıfır olduğu durumlarda hata oranlarının aşırı büyümesini engeller. Bu özelliği nedeniyle, SMAPE özellikle düşük talep veya sıfır gerçekleşen değerlerin olduğu tahmin modellerinde daha dengeli bir performans ölçütü sağlar (Hyndman ve Koehler, 2006).

2.3.4.2. Ürün001 için Tahmin Sonuçları

Tablo 12

Ürün001 için Tahmin Sonuçları

Yıllar	Aylar	Gerçekleşen	YSA Tahmini	YSA Mutlak Hata %	Hareketli Ortalama Tahmini	Hareketli Ortalama Mutlak Hata %
2024	Ocak	31265	14784	53%	24492	22%
2024	Şubat	17293	33017	91%	26108	51%
2024	Mart	13307	7409	44%	25911	95%
2024	Nisan	26750	25425	5%	25251	6%
2024	Mayıs	13250	3815	71%	27263	106%
2024	Haziran	4545	5631	24%	28482	527%
2024	Temmuz	25189	8480	66%	30055	19%
2024	Ağustos	14000	12979	7%	28215	102%
2024	Eylül	5400	18055	234%	27758	414%
2024	Ekim	43650	17808	59%	27861	36%
2024	Kasım	32221	24638	24%	29125	10%
2024	Aralık	22888	14886	35%	29849	30%

Ürün001 ABC analizi sonrası A grubu olarak belirlenen bir ürün grubundadır. Yüksek talep grubundaki ürün için hareketli ortalama tahmini son 12 aylık talep referans alınarak hesaplanmıştır. YSA ile yapılan tahmin değerlerinin daha yakın olduğu, ani talep değişimlerine daha duyarlı olduğu görülmektedir. Hesaplamaya göre MAPE (Ortalama Mutlak Yüzde Hatası) değeri %59.42 olarak bulunmuştur. Hareketli ortalama tahmini için MAPE (Ortalama Mutlak Yüzde Hatası) değeri %118.04 olarak hesaplanmıştır.

2.3.4.3. Ürün007 için Tahmin Sonuçları

Tablo 13

Ürün007 için Tahmin Sonuçları

Yıllar	Aylar	Gerçekleşen	YSA Tahmini	YSA Mutlak Hata %	Hareketli Ortalama Tahmini	Hareketli Ortalama Mutlak Hata %
2024	Ocak	90	191	112%	739	721%
2024	Şubat	408	340	17%	800	96%
2024	Mart	1440	444	69%	706	50%
2024	Nisan	2996	748	75%	626	79%
2024	Mayıs	0	8	200%	670	200%
2024	Haziran	0	24	200%	717	200%
2024	Temmuz	3218	785	75%	769	76%
2024	Ağustos	0	64	200%	833	200%
2024	Eylül	0	65	200%	902	200%
2024	Ekim	2232	1451	34%	833	62%
2024	Kasım	1455	649	55%	872	40%
2024	Aralık	2340	1280	45%	945	59%

Ürün007 ABC analizi sonrası B grubu olarak belirlenen bir ürün grubundadır. Orta talep grubunda olduğu için hareketli ortalama tahmini son 12 aylık talep referans alınarak hesaplanmıştır. Gerçekleşen 0 değerleri için SMAPE ile yüzde hata hesaplanmıştır. Tahminler sonucunda üründe ani talep dalgalanmalarının çok fazla olması sebebiyle hata miktarlarının çok olduğu görülmektedir. Ancak YSA ile yapılan tahmin değerlerinin klasik yöntemle göre daha yakın olduğu görülmektedir. Hesaplamaya göre YSA tahmini için MAPE (Ortalama Mutlak Yüzde Hatası) değeri %106.83 olarak bulunmuştur. Hareketli ortalama tahmini için MAPE (Ortalama Mutlak Yüzde Hatası) değeri %165.25 olarak hesaplanmıştır.

2.3.4.4. Ürün049 için Tahmin Sonuçları

Tablo 14

Ürün049 için Tahmin Sonuçları

Yıllar	Aylar	Gerçekleşen	YSA Tahmini	YSA Mutlak Hata %	Hareketli Ortalama Tahmini	Hareketli Ortalama Mutlak Hata %
2024	Ocak	0	0	0%	270	200%
2024	Şubat	306	257	16%	272	11%
2024	Mart	0	1	200%	286	200%
2024	Nisan	500	55	89%	262	48%
2024	Mayıs	0	517	200%	284	62%
2024	Haziran	340	247	27%	298	200%
2024	Temmuz	0	9	200%	306	12%
2024	Ağustos	0	7	200%	261	200%
2024	Eylül	0	5	200%	204	200%
2024	Ekim	306	0	100%	221	28%
2024	Kasım	720	233	67%	239	66%
2024	Aralık	0	0	0%	242	200%

Ürün049 ABC analizi sonrası C grubu olarak belirlenen bir üründür. Düşük talep grubunda olduğu için hareketli ortalama tahmini son 12 aylık talep referans alınarak hesaplanmıştır. Gerçekleşen 0 değerleri için SMAPE ile yüzde hata hesaplanmıştır. Tahminler sonucunda üründe ani talep dalgalanmalarının çok fazla olması sebebiyle hata miktarlarının çok olduğu görülmektedir. Burada YSA ile yapılan tahminlerde önemli hatalar göze çarpmaktadır. Ancak YSA ile yapılan tahmin değerlerinin klasik yöntemle göre daha yakın olduğu görülmekle birlikte uzun dönem veri setinde çok daha iyi sonuçlar elde edileceği anlaşılmaktadır. Hesaplamaya göre MAPE (Ortalama Mutlak Yüzde Hatası) değeri %108.25 olarak bulunmuştur. Hareketli ortalama tahmini için MAPE (Ortalama Mutlak Yüzde Hatası) değeri %118.91 olarak hesaplanmıştır.

SONUÇ VE ÖNERİLER

Hızla değişen piyasa koşulları ve artan rekabet ortamında, işletmelerin sürdürülebilir bir rekabet avantajı elde edebilmesi, doğru tahmin modelleri kullanarak kaynaklarını etkin bir şekilde yönetmesine bağlıdır. Bu bağlamda, yapay zeka ve derin öğrenme teknikleri, işletmelerin talep tahmini süreçlerinde geleneksel yöntemlere kıyasla daha doğru ve güvenilir sonuçlar sunmaktadır.

Bu çalışma kapsamında, 2021-2023 yıllarına ait bir işletmenin verileri analiz edilmiş ve Yapay Sinir Ağları (YSA) kullanılarak 2024 yılı için talep tahmini yapılmıştır. Çalışmada, ABC analizi yardımıyla yüksek, orta ve düşük talep hacimlerine sahip ürünler belirlenmiş ve bu ürünlerin tahmini için sipariş sayısı, döviz kuru ve ihracat oranı gibi kritik değişkenler modele dahil edilmiştir.

Çalışmada kullanılan veriler, orman endüstrisinde faaliyet gösteren bir firmanın 2021-2024 yıllarına ait verileri içermekte olup 2021-2023 yılları eğitim veri seti, 2024 yılı ise test veri seti olarak ayrıştırılmıştır. Veri seti, işletmenin iç kayıtlarına dayalı olarak oluşturulmuş olup; tarih, sipariş numarası, müşteri adı, müşteri bölgesi, ürün adı, talep miktarı ve aylık ortalama döviz kurları gibi değişkenleri içermektedir. Bu değişkenler, talep tahmini ile bölgesel satış dinamiklerinin analizinde önemli bir rol oynamaktadır. Özellikle döviz kurları, ürün fiyatlarının döviz bazında değerini etkileyerek siparişlerin bölgesel dağılımında belirleyici bir faktör olarak ele alınmıştır. Seçilen modellerin performansı, tahmin edilen değerlerin gerçekleşen verilerle karşılaştırılması yoluyla değerlendirilmiştir. Çalışma kapsamında, 97 farklı ürün için ABC analizi yapılmış ve her gruptan bir ürün seçilerek farklı ürün gruplarındaki sonuçlar incelenmiştir. ABC analizleri sonucunda talep tahminleme modellerine dahil edilerek analizleri yapılmak üzere A grubu için, Ürün001, B grubu için Ürün007, C grubu için Ürün049 tercih edilmiştir.

Çalışmada, Yapay Sinir Ağı (YSA) modelleri yalnızca birer kez çalıştırılmış olup modelin erken durdurma mekanizması ile eğitimi tamamlanmıştır. MSE grafikleri incelendiğinde, modellerin hata oranlarının hızla düştüğü ve belirli bir noktada sabitlendiği görülmektedir. Bu durum, modelin rastgele çalışmasına rağmen istikrarlı sonuçlar verdiğini göstermektedir. Eğitim hatasının test hatasına göre düşük olması, modelin eğitim setine iyi uyum sağladığını ve aşırı öğrenmenin önlendiğini

göstermektedir. Bu nedenle, modellerin tekrar çalıştırılmasına gerek duyulmamıştır. Model performansını iyileştirmek için hiperparametre optimizasyonu ve ek değişken kullanımı gibi stratejiler kullanılabilir.

Yapay Sinir Ağı (YSA) modeli ve hareketli ortalama yöntemi ile yapılan tahminlerin doğruluğu MAPE (Ortalama Mutlak Yüzde Hata) metriği ile değerlendirilmiştir. YSA modeli için MAPE değerleri; yüksek talep hacmine sahip ürünlerde %59.42, orta talep hacmine sahip ürünlerde %106.83 ve düşük talep hacmine sahip ürünlerde %108.25 olarak hesaplanmıştır. Buna karşılık, hareketli ortalama yöntemi için MAPE değerleri sırasıyla %118.04, %165.25 ve %118.91 olarak bulunmuştur. Sonuçlar, YSA modelinin yüksek ve orta talep hacmine sahip ürünlerde geleneksel hareketli ortalama yöntemine kıyasla çok daha düşük hata oranları ürettiğini ve bu gruplarda talep tahmini açısından daha başarılı bir yöntem olduğunu göstermektedir. Düşük talep hacmine sahip ürünlerde ise daha iyi sonuç vermesine rağmen YSA modeli hareketli ortalamaya yakın bir hata oranına sahiptir. Bu da YSA modelinin düşük talep seviyelerinde dalgalanmalara karşı daha duyarlı olduğunu göstermekle beraber gerçekleşen değerlerin çoğunluğunun sıfır olması sebebiyle hata oranının etkilendiği görülmektedir. Özellikle yüksek talep hacmine sahip ürünlerde YSA'nın hareketli ortalamaya göre daha düşük hata oranına sahip olması, modelin düşük talep dalgalanmalarında çok daha iyi tahminleme yaptığını göstermektedir.

Çalışma sonuçları referans alındığında YSA ile yapılan tahmin seviyelerinin hareketli ortalama tahmin seviyelerinin altında değer gösterdiği görülmektedir. Bu aşamada hareketli ortalama tahminleri stok maliyeti oluştururken YSA tahminlerinin ise stok yetersizliği sebebiyle satış kaybına neden olabileceği düşünülmektedir. Bu aşamada, YSA tahmin sapmaları referans alınarak emniyet stoklarının belirlenmesi gibi çözümler kullanılabilir. Bu çözümler ışığında; YSA modeli ile talep tahminlerinin işletmelere stok maliyetlerinde önemli seviyelerde iyileştirme ve finansal olarak yüksek kazanım sağlayacağı düşünülmektedir.

Gelecekteki çalışmalar için farklı yöntemlerin kullanılması (LSTM, GRU ve Transformer tabanlı modeller gibi) model başarısını daha ileri seviyeye taşıyabilir. Modelin daha fazla eğitilmesi, farklı eğitim setleri ile yeniden eğitilerek hata oranlarının daha da düşürülmesi sağlanabilir. Ayrıca, sınırlı veri yerine daha uzun geçmiş verilerin analize dahil edilmesi, döviz kuru gibi ekonomik göstergelerin yanı sıra, faiz oranları, enflasyon ve sektörel

büyüme gibi ek değişkenlerin modele dahil edilmesi, ABC analizi kapsamında ürünleri yalnızca satış hacimlerine göre değil, müşteri profilleri ve pazar dinamikleri açısından da sınıflandırarak modelin farklı ürün gruplarına özel olarak uyarlanması gibi işlemler model başarısını daha da ileriye taşıyabilir.

Elde edilen bulgular, YSA modellerinin karmaşık ve değişken piyasa koşullarında başarılı tahminler yapabildiğini ortaya koymuştur. Özellikle, 2024 yılına ait test veri seti üzerinde yapılan analizlerde, yüksek talep dalgalanmalarına rağmen modellerin daha yüksek doğruluk içeren oranıyla tahmin yapabildiği görülmüştür. Bu sonuçlar, derin öğrenme tekniklerinin doğru veri hazırlama süreçleriyle birleştirildiğinde talep tahmini alanında güçlü bir araç olduğunu göstermektedir.

Çalışmada kullanılan yöntemler, işletmenin yalnızca belirli ürün gruplarında değil, genel operasyonel süreçlerinde de verimliliği artıracak bir yaklaşım sunmaktadır. Ayrıca, elde edilen sonuçların, işletmenin gelecekteki stratejik planlamalarına yön vermesi açısından önemli katkılar sunacağı düşünülmektedir. Bu çalışma, yapay zeka ve derin öğrenme tabanlı yaklaşımların tedarik zinciri yönetiminde daha geniş bir bakış açısıyla ele alınması gerektiğini de vurgulamaktadır.

KAYNAKÇA

- Armstrong, G. ve Kotler, P. (2011). *Marketing: An introduction*. (Tenth Edition). Pearson.
- Bahdanau, D., Cho, K., ve Bengio, Y. (2014). Neural machine translation by jointly learning to align and translate. *Proceedings of the International Conference on Learning Representations (ICLR)*. Eriřim adresi: <https://arxiv.org/abs/1409.0473>
- Chen, X., Zhang, Y. ve Zhang, G. (2020). Deep learning for supply chain optimization: A comprehensive review. *International Journal of Production Economics*, 223, 107511.
- Choi, T. M. (2021). Supply chain management in times of crisis: A review of Covid-19 literature. *International Journal of Production Economics*, 232, 107992.
- Choi, T. M., Wallace, S. W., ve Wang, Y. (2020). Big data analytics in operations and supply chain management: Current trends and future directions. *Journal of Business Research*, 108, 25-36.
- Chollet, F. (2017). *Deep learning with python*. Manning Publications.
- Chopra, S. ve Meindl, P. (2019). *Supply chain management: Strategy, planning, and operation*. Pearson.
- Chopra, S. ve Sodhi, M. S. (2021). Supply chain management under disruptions: Pandemic resilience and recovery strategies. *International Journal of Production Research*, 59(1), 1–17.
- Chung, J., Gulcehre, C., Cho, K. ve Bengio, Y. (2014). *Empirical evaluation of gated recurrent neural networks on sequence modeling*. Arxiv Preprint arXiv:1412.3555.
- Eren, U. ve Satoęlu, ř. I. (2017). *Perakende giyim sektöründe yapay sinir aęları ile talep tahmini*. Endüstri-İřletme Kurultayı.
- Erol, B. ve İnkaya, T. (2024). Satıř tahmini için derin öğrenme yöntemlerinin karşılařtırılması. *Uludaę Üniversitesi Mühendislik Fakültesi Dergisi*, 29(2), 535-554.
- Es, H., Kalender Öksüz, F. ve Hamzacebi, C. (2014). Forecasting the net energy demand of Turkey by artificial neural networks. *Journal of the Faculty of Engineering and Architecture of Gazi University*, 29(3).
- Goodfellow, I., Bengio, Y. ve Courville, A. (2016). *Deep learning*. MIT Press.
- Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., ... ve Bengio, Y. (2014). Generative adversarial nets. *Advances in Neural Information Processing Systems*, 27.

- Goyal, P. ve Soni, G. (2021). Artificial intelligence in supply chain management: A systematic review of applications and challenges. *Journal of Supply Chain Management Science*, 4(1), 23-34.
- Gupta, S. ve Maranas, C. D. (2021). Inventory optimization in the age of AI: Advances and challenges. *Computers ve Operations Research*, 129, 105245.
- Gupta, S., Sharma, R. ve Goyal, P. (2021). Inventory management strategies in dynamic environments: A review. *International Journal of Production Economics*, 233, 107974.
- Hagan, M. T., Demuth, H. B. ve Beale, M. H. (1996). *Neural network design*. PWS Publishing.
- Hinton, G. E. (1980). Autoencoders: Learning useful representations in a deep network with a locally connected network. *Proceedings of the International Conference on Neural Networks (ICNN)*, 1, 5-8.
- Hinton, G. E., Osindero, S. ve Teh, Y. W. (2006). A fast-learning algorithm for deep belief nets. *Neural Computation*, 18(7), 1527-1554.
- Hochreiter, S. ve Schmidhuber, J. (1997). Long short-term memory. *Neural Computation*, 9(8), 1735-1780.
- Hyndman, R. J. ve Athanasopoulos, G. (2021). *Forecasting: Principles and practice* (3rd ed.). OTexts.
- Hyndman, R. J. ve Koehler, A. B. (2006). Another look at measures of forecast accuracy. *International Journal of Forecasting*, 22(4), 679–688.
- Irmak, B. (2022). *Yapay sinir ağlarının eğitimi için kelebek optimizasyonu algoritmasının iyileştirilmesi* (Yayımlanmamış yüksek lisans tezi). Necmettin Erbakan Üniversitesi
- Ivanov, D. ve Dolgui, A. (2020). Viability of intertwined supply networks: Extending the supply chain resilience angles towards survivability. *International Journal of Production Research*, 58(10), 2904–2915.
- Ivanov, D., Dolgui, A. ve Sokolov, B. (2023). Real-time inventory optimization with artificial intelligence: A multi-echelon approach. *International Journal of Production Research*, 61(2), 187-204.
- Johnson, M. E., Lee, H. L. ve Davis, T. (2022). The role of predictive analytics in demand forecasting and inventory management. *Journal of Operations Management*, 68(3), 245–261.
- Kaya, F. ve Demir, T. (2020). Tahmin yöntemleri ve uygulamaları: Yönetici değerlendirmeleri yöntemi üzerine bir inceleme. *Beykoz Akademi Dergisi*, 8(2), 23-34.
- Kaya, S. K. ve Yıldırım, Ö. (2020). A prediction model for automobile sales in Turkey using deep neural networks. *Endüstri Mühendisliği*, 31(1), 57-74.

- Kingma, D. P., ve Ba, J. (2015, Mayıs). Adam: A method for stochastic optimization [Öz]. *International Conference on Learning Representations (ICLR)*, San Diego, CA, ABD. Erişim adresi: <https://arxiv.org/abs/1412.6980>
- Kobu, B. (2008). *Üretim yönetimi* (14. baskı). Beta Basım.
- LeCun, Y. (1990). The handwritten digit recognition experiment: A case study in using neural networks. *Neural Computation*, 2(1), 1-39.
- LeCun, Y., Bengio, Y. ve Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436–444.
- Lee, J. ve Shin, J. (2020). Artificial intelligence in supply chain management: A critical review and future research directions. *Computers ve Industrial Engineering*, 145, 106676.
- Li, Y., Dai, W. ve Wu, D. (2018). Application of deep belief networks in supply chain data mining. *Journal of Systems Science and Complexity*, 31(3), 767-779.
- Li, Y., Wang, X. ve Zhang, Z. (2018). Using deep belief networks for predictive analysis in production lines. *International Journal of Production Research*, 56(10), 3535-3550.
- Linstone, H. A. ve Turoff, M. (1975). *The delphi method: Techniques and applications*. Addison-Wesley Pub. Co.
- Lipton, Z. C., Berkowitz, J. ve Elhadad, N. (2015). A critical review of recurrent neural networks for sequence learning. *IEEE Transactions on Neural Networks and Learning Systems*, 26(5), 1019–1039.
- Liu, Y., Wang, Z., Zhang, X. ve Li, T. (2021). Dynamic demand forecasting with attention mechanisms in logistics. *Journal of Operations Management*, 37, 123-135.
- Liu, Y., Zhang, Y. ve Liu, Y. (2021). Dynamic demand forecasting with attention mechanism in logistics. *IEEE Transactions on Industrial Informatics*, 17(5), 3469-3479.
- Makridakis, S., Spiliotis, E. ve Assimakopoulos, V. (2018). Statistical and machine learning forecasting methods: Concerns and ways forward. *Plos One*, 13(3), e0194889.
- Malhotra, N. K. (2010). *Basic marketing research: Integration of marketing concepts with techniques*. Pearson Education.
- Morgan S. (b.t). Demand forecasting and inventory management using deep learning techniques. *Morgan Stanley Research Report*, 1-7.
- Nasuhoğlu, H. (2019). *Eczacılık sektöründe yapay sinir ağları ve zaman serileri analizi ile talep tahmini* (Yüksek lisans tezi). Maltepe Üniversitesi.
- Özkan, A., ve Esmeray, M. (2002). Bir maliyet kontrol sistemi olarak JIT üretim sistemi ve muhasebe uygulamaları. *Cumhuriyet Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 3(1), 129-146.

- Özkaynar, G. K. (2024). Bir dijital bağımlılık sendromu phubbing: işgören kariyer başarısı ve iş tatminine etkisi açısından araştırılması. *Yönetim Bilimleri Dergisi*, 22, 1807-1840.
- Pareto, V. (1896). *Cours d'économie politique*. Rouge.
- Prechelt, L. (1998). *Early stopping-but when? In neural networks: Tricks of the trade*. Springer.
- Ramanathan, R. (2006). ABC inventory classification with multiple-criteria using weighted linear optimization. *Computers ve Operations Research*, 33(3), 695–700.
- Salttürk, B. (2022). *Yapay sinir ağları ile ürün satış miktarlarının tahmini: Mobilya sektöründe bir uygulama* (Yüksek lisans tezi). Sakarya Üniversitesi.
- Sarı, M. (2016). *Yapay sinir ağları ve bir otomotiv firmasında satış talep tahmini uygulaması*. (Yüksek lisans tezi). Sakarya Üniversitesi.
- Silver, D., Huang, A., Maddison, C. J., Guez, A., Sifre, L., Van Den Driessche, G., ... ve Hassabis, D. (2016). Mastering the game of go with deep neural networks and tree search. *Nature*, 529(7587), 484-489.
- Silver, E. A., Pyke, D. F. ve Peterson, R. (1998). *Inventory management and production planning and scheduling*. Wiley.
- Slack, N., Chambers, S., ve Johnston, R. (2010). *Operations management* (6th ed.). Pearson Education.
- Sönmez, O. ve Zengin, K. (2019). Yiyecek ve içecek işletmelerinde talep tahmini: Yapay sinir ağları ve regresyon yöntemleriyle bir karşılaştırma. *Avrupa Bilim ve Teknoloji Dergisi*, 302-308.
- Tang, Y. ve Mousavi, S. (2022). Artificial intelligence for inventory management: A systematic review. *Expert Systems with Applications*, 200, 117006.
- Taşar, D. E. (2023). *Organizasyonel gelişim için otomatik konuşma tanıma sistemi önerisi* (Yüksek lisans tezi). Dokuz Eylül Üniversitesi.
- Thomas, J. C. (2009). *Sales forecasting management*. John Wiley ve Sons.
- Türkiye Cumhuriyet Merkez Bankası [TCMB]. (2023). *Döviz kurları verileri (2021-2024)*. Retrieved from <https://www.tcmb.gov.tr/kurlar>
- Ünlü, R. (2019). Zaman serileri tahminlenmesinde makine öğrenimi ve derin öğrenme tekniklerinin kıyaslanması: Türkiye elektrik üretimi için en iyi tahmin modelinin seçilmesine yönelik bir vaka çalışması. *Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 23(2), 359-370.
- Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, Ł. ve Polosukhin, I. (2017). Attention is all you need. *Advances in Neural Information Processing Systems*, 30, 5998–6008.

- Waller, M. A. ve Fawcett, S. E. (2013). Data science, predictive analytics, and big data: A revolution that will transform supply chain design and management. *Journal of Business Logistics*, 34(2), 77-84.
- Xu, K., Ba, J. L., Kiros, R., Cho, K., Courville, A., Salakhutdinov, R., Zemel, R. ve Bengio, Y. (2018). Show, attend and tell: Neural image caption generation with visual attention. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 39(4), 729-742.
- Yang, X., Li, Y., Chen, Z., ve Zhao, H. (2020). GRU-based demand forecasting in the automotive industry: Reducing inventory costs by 20%. *Journal of Supply Chain Management and Artificial Intelligence Applications*, 15(3), 45-58.
- Yazıcıoğlu, N. (2010). *Yapay zeka ile talep tahmini* (Yüksek lisans tezi). Bursa Uludağ Üniversitesi
- Yılmaz, A. ve Aydın, M. (2021). Tarihsel bilgilere dayalı yöntem: Yeni ürünlerde talep tahmini için bir yaklaşım. *Journal of Marketing Studies*, 5(1), 45-58.
- Zhang, W. ve Li, Y. (2021). Dynamic route prediction using gru networks: A case study in the logistics industry. *Journal of Transportation Technologies*, 11(2), 1-9.

ÖZGEÇMİŞ

Adı Soyadı: Gökhan TURGAY

ÖĞRENİM DURUMU

Öğrenim Derecesi	Öğrenim Yeri	Öğrenim Yılı
Yüksek Lisans	Sakarya Üniversitesi / İşletme Enstitüsü / İşletme	2025
Yüksek Lisans	Sakarya Üniversitesi / Fen Bilimleri Enstitüsü / Mühendislik Yönetimi	2022
Lisans	Cunhuriyet Üniversitesi / Mühendislik Fakültesi / Kimya Mühendisliği	2015
Lise	MithatPaşa Anadolu Lisesi	2006

İŞ DENEYİMİ

Yıl	Yer	Görev
2021-Halen	Çamsan Entegre Ağaç San.ve Tic. A.Ş.	Malz. Plan. Bölüm Sorm.
2019-2021	Alyan Gıda San.ve Tic. A.Ş.	Planlama Yöneticisi
2017-2019	Elvan Gıda San.ve Tic. A.Ş.	Üretim Mühendisi
2016-2017	Şenpiliç Gıda San.ve Tic. A.Ş.	Planlama Yetkilisi

YABANCI DİL

İngilizce