

T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

MAKİNE ÖĞRENMESİNE DAYALI TALEP TAHMİN
MODELLERİNİN KARŞILAŞTIRILMASI

YÜKSEK LİSANS TEZİ

Erhan KOR

Endüstri Mühendisliği Anabilim Dalı

Mühendislik Yönetimi Bilim Dalı

SUBAT 2024

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

**MAKİNE ÖĞRENMESİNE DAYALI TALEP TAHMİN
MODELLERİNİN KARŞILAŞTIRILMASI**

YÜKSEK LİSANS TEZİ

Erhan KOR

Endüstri Mühendisliği Anabilim Dalı

Mühendislik Yönetimi Bilim Dalı

Tez Danışmanı: Prof. Dr. Orhan TORKUL

ŞUBAT 2024

Erhan KOR tarafından hazırlanan “Makine Öğrenmesine Dayalı Talep Tahmin Modellerinin Karşılaştırılması” adlı tez çalışması 28.02.2024 tarihinde aşağıdaki jüri tarafından oy birliği/oy çokluğu ile Sakarya Üniversitesi Fen Bilimleri Enstitüsü Endüstri Mühendisliği Anabilim Dalı **Mühendislik Yönetimi** Bilim Dalı’nda Yüksek Lisans tezi olarak kabul edilmiştir.

Tez Jürisi

Jüri Başkanı:	Prof. Dr. Orhan TORKUL Sakarya Üniversitesi	
Jüri Üyesi:	Doç.Dr. Tijen ÖVER ÖZÇELİK Sakarya Üniversitesi	
Jüri Üyesi:	Dr. Öğr. Üyesi Mustafa YILMAZ Sakarya Uygulamalı Bilimler Üniversitesi	



ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ

Sakarya Üniversitesi Fen Bilimleri Enstitüsü Lisansüstü Eğitim-Öğretim Yönetmeliğine ve Yükseköğretim Kurumları Bilimsel Araştırma ve Yayın Etiği Yönergesine uygun olarak hazırlamış olduğum “MAKİNE ÖĞRENMESİNE DAYALI TALEP TAHMİN MODELLERİNİN KARŞILAŞTIRILMASI” başlıklı tezin bana ait, özgün bir çalışma olduğunu; çalışmamın tüm aşamalarında yukarıda belirtilen yönetmelik ve yönergeye uygun davrandığımı, tezin içerdiği yenilik ve sonuçları başka bir yerden almadığımı, tezde kullandığım eserleri usulüne göre kaynak olarak gösterdiğimi, bu tezi başka bir bilim kuruluna akademik amaç ve unvan almak amacıyla vermediğimi ve 20.04.2016 tarihli Resmi Gazete’de yayımlanan Lisansüstü Eğitim ve Öğretim Yönetmeliğinin 9/2 ve 22/2 maddeleri gereğince Sakarya Üniversitesi’nin abonesi olduğu intihal yazılım programı kullanılarak Enstitü tarafından belirlenmiş ölçütlere uygun rapor alındığını, çalışmamla ilgili yaptığım bu beyana aykırı bir durumun ortaya çıkması halinde doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi beyan ederim.

(...../...../20.....).

Öğrencinin Adı Soyadı



TEŐEKKÖR

Bu alıřmanın bařlatılmasında ve yűrűtűlmesinde desteklerini hi esirgemeyen tez danıřman hocam Prof. Dr. Orhan TORKUL'a ve Arř.Gör. Merve řİřÇİ'ye, alıřmalarım sırasında manevi destekte bulunan aileme, ayrıca yardımlarını esirgemeyen arkadaşlarıma teőekkűrű bor bilirim.

Erhan KOR



İÇİNDEKİLER

ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ	v
TEŞEKKÜR	vii
İÇİNDEKİLER	ix
KISALTMALAR	xi
SİMGELER	xiii
TABLO LİSTESİ	xv
ŞEKİL LİSTESİ	xvii
ÖZET.....	xix
SUMMARY	xxi
1. GİRİŞ.....	1
1.1. Araştırmanın Amacı	2
1.2. Araştırmanın Kapsamı ve Sınırlılıkları	2
1.3. Literatür Araştırması	3
2. YÖNTEMLER	17
2.1. Talep Tahmin Kavramı	17
2.2. Talep Tahmin İhtiyacı ve Önemi	18
2.3. Talep Tahmin Aşamaları	19
2.4. Nitel Tahmin Yöntemleri	19
2.4.1. Delphi yöntemi.....	20
2.4.2. Yönetici görüşleri esaslı tahmin.....	20
2.4.3. Anket yöntemiyle talep tahmini	20
2.4.4. Kilit personel aracılığıyla tahmin.....	20
2.4.5. Satış ekibinin tahminleri	21
2.4.6. Pazar araştırması:	21
2.4.7. Uzman görüşleri	21
2.5. Nicel Tahmin Yöntemleri.....	22
2.5.1. Son dönem talebi yöntemi.....	22
2.5.2. Basit ortalama	22
2.5.3. Hareketli ortalama:.....	22
2.5.4. Ağırlıklı hareketli ortalama	23
2.5.5. Basit üssel düzeltme yöntemi.....	23
2.5.6. Holt'un doğrusal yöntemi	24
2.5.7. Holt-Winters yöntemi	24
2.5.8. Regresyon analizi	25
2.5.9. Korelasyon analizi.....	26
2.5.10. Otoregresif (AR) modeli	27
2.5.11. Hareketli ortalama (MA) modeli.....	27
2.5.12. Otoregresif hareketli ortalama (ARMA) modeli.....	28
2.5.13. ARIMA modeli	28
2.5.14. Yapay sinir ağları	28
2.5.14.1. Yapay sinir ağlarının tanımı.....	28
2.5.14.2. Yapay sinir ağlarının avantajları ve dezavantajları	29
2.5.14.3. Yapay sinir hücreleri	31

2.5.14.4. Yapay sinir hücrelerinin temel bileşenleri	31
2.5.14.5. Yapay sinir ağlarının mimari yapılarına göre sınıflandırılması	33
2.5.14.6. Yapay sinir ağlarında öğrenme yöntemleri:	35
2.5.14.7. Yapay sinir ağlarında öğrenme kuralları	36
2.5.15. Karar ağaçları ve rasgele ormanlar	37
2.6. Nitelik Seçimi Yöntemleri	38
2.6.1. Parçacık sürüşü optimizasyonu algoritması	38
2.6.2. Harris şahinleri optimizasyonu algoritması	39
2.6.3. Gri kurt optimizasyonu algoritması	39
2.6.4. Yusufçuk optimizasyonu algoritması	39
2.6.5. Genetik optimizasyonu algoritması	40
2.6.6. Yerçekimi arama optimizasyonu algoritması	40
3. ARAŞTIRMA VERİLERİ VE METODOLOJİ	43
3.1. Verilerin Toplanması	44
3.2. Nitelik Oluşturma	47
3.3. Veri Setinin İstatistiksel Özellikleri	47
3.4. Verilerin Düzenlenmesi	49
3.4.1. Veri setinin bölünmesi	55
3.5. Makine Öğrenmesi Algoritmalarıyla Modelleme	56
3.6. Nitelik Seçimi	59
3.7. Performans Değerlendirme Kriterlerinin Seçimi	61
4. MAKİNE ÖĞRENMESİ ALGORİTMALARININ UYGULANMASI	65
4.1. Yapay Sinir Ağları Tahmin Modelleri	66
4.2. Karar Ormanı Tahmin Modelleri	72
4.3. Lineer Regresyon Tahmin Modelleri	77
4.4. Yöntemlerin Performans Ölçüt Değerlerinin Karşılaştırılması	83
5. TARTIŞMA VE SONUÇ	87
KAYNAKLAR	89
ÖZGEÇMİŞ	97

KISALTMALAR

ANFIS	: Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi
AR	: Otoregresif
ARIMA	: Otoregresif Bütünleşik Hareketli Ortalama
ARIMAX	: Otoregresif Bütünleşik Hareketli Ortalama eXplanatory
ARMA	: Otoregresif Hareketli Ortalama
CNN	: Konvolüsyonel Sinir Ağları
DTW	: Dinamik Zaman Bükmesi
ESN	: Yankı Durumu Sinir Ağları
GBT	: Gradyan Artırıcı Ağaçlar
GRU	: Geçitli Tekrarlama Ünitesi
KKP	: Kurumsal Kaynak Planlaması
KNFTS	: Zaman Serilerinde K-En Yakın Komşu Nitelikleri
KNN	: K-En Yakın Komşu
KNPTS	: K-En Yakın Komşu Şablonları
KOKH	: Kök Ortalama Kare Hatası
LR	: Lineer Regresyon
LSTM	: Uzun Kısa Dönemli Bellek
MA	: Hareketli Ortalama
MAD	: Ortalama Mutlak Sapma
MAE	: Ortalama Mutlak Hata
MAPE	: Ortalama Mutlak Yüzde Hata
MLP	: Çok Katmanlı Algılayıcı
MSE	: Ortalama Karesel Hata
NRMSE	: Normalize Kök Ortalama Kare Hata
OKH	: Ortalama Karesel Hata
OMH	: Ortalama Mutlak Hata
OMYH	: Ortalama Mutlak Yüzde Hata
PR	: Polinomal Regresyon
RF	: Rasgele Ormanlar
RMSE	: Kök Ortalama Kare Hata

RMSPE	: Kök Ortalama Kare Yüzde Hata
RNN	: Yinelemeli Sinir Ağları
SMAPE	: Simetrik Ortalama Mutlak Yüzde Hata
SSE	: Hata Kareleri Toplamı
ST	: Basit Ağaç
TE	: Ağaç Topluluğu
WDDFF	: Dalgacık Veriye Dayalı Tahmin Çerçevesi
PSO	: Parçacık Sürüsü Optimizasyonu
HŞO	: Harris Şahini Optimizasyonu
YO	: Yusufçuk Optimizasyonu
GO	: Genetik Optimizasyonu
YAO	: Yerçekimi Arama Optimizasyonu

SİMGELER

t	: Dönem sayısı
F_{t+1}	: Sonraki döneme ait tahmin değeri
Y_i	: i dönemine ait gerçek talep
F_t	: t dönem için tahmin değeri
D_{t-1}	: t -n dönem için gerçekleşen değer
n	: Dönem sayısı
w	: Ağırlık değeri
D	: Talep
Y_t	: Gerçekleşen talep
L_t	: t döneminde beklenen seviye
α	: Düzeltme katsayısı
T_t	: t dönemindeki trend değeri
B	: Trendin düzeltme katsayısı
β	: Düzeltme katsayısı
I_{t-l}	: L dönem öncesindeki mevsimsel gösterge
L	: Mevsimsellikteki döngü uzunluğu
I_t	: Dönem sonundaki düzeltme yapılmış mevsimsel gösterge
Y_{t+m}	: m dönem sonra bulunan tahmin değeri
X_i	: Bağımsız değişken
r	: Korelasyon
$\varphi_{1,2,3...n}$	: Otomatik regresyon değişkenleri
c	: y_t 'nin ortalamasını
ε_t	: Rassal değişken, anlık hata
θ_1	: Hareketli ortalama katsayısı
μ	: Doğrunun y eksenini kestiği nokta
Φ_p	: p kadar bağımlılık değişkeni
Θ_q	: q kadar hata değişkeni
Δ	: Fark operatörü
Z_t	: t anındaki tahmin değeri
γ	: t anındaki tahmin değeri

Y_{t+m} : t anındaki tahmin değeri



TABLO LİSTESİ

Tablo 2.1. Korelasyon katsayılarının değerlendirilmesi.....	27
Tablo 2.2. Aktivasyon fonksiyonları ve formülleri (Korkut, 2019).....	33
Tablo 3.1. İlgili dönemlerdeki bağımsız değişkenler.	45
Tablo 3.2. A ürünü veri setinin istatistiksel özellikleri.	48
Tablo 3.3. B ürünü veri setinin istatistiksel özellikleri.....	48
Tablo 3.4. C ürünü veri setinin istatistiksel özellikleri.....	49
Tablo 3.5. D ürünü veri setinin istatistiksel özellikleri.	49
Tablo 3.6. Yapay sinir ağları modellerinde kullanılan eğitim parametreleri.	57
Tablo 3.7. Karar ormanı modellerinde kullanılan eğitim parametreleri.....	58
Tablo 3.8. Lineer regresyon modellerinde kullanılan eğitim parametreleri.	59
Tablo 3.9. Nitelik Seçimi Algoritmaları için kullanılan parametreler.....	60
Tablo 3.10. Optimizasyon yöntemleri ile ulaşılan nitelik sonuçları.....	61
Tablo 3.11. MAPE değeri ve doğruluk değerlendirmesi (Lewis, 1982).	62
Tablo 4.1. Yapay sinir ağları modelleri optimizasyon yöntemleri karşılaştırması....	65
Tablo 4.2. Karar ormanı modelleri optimizasyon yöntemleri karşılaştırması.....	65
Tablo 4.3. Lineer regresyon modelleri optimizasyon yöntemleri karşılaştırması.	66
Tablo 5.1. Yöntemlerin doğruluklarının karşılaştırması.	87



ŞEKİL LİSTESİ

Şekil 2.1. Yapay sinir ağları yapı modeli (Gökler, 2020).....	29
Şekil 2.2. Yapay sinir ağları hücresi (Gollo, 2008).	31
Şekil 2.3. Yapay sinir hücresi temel bileşenleri (Çuhadar, 2009).	32
Şekil 2.4. İleri beslemeli sinir ağları yapısı (Yüksek, 2007).....	34
Şekil 2.5. Geri beslemeli sinir ağları yapısı.	35
Şekil 2.6. Danışmanlı öğrenme süreci ve aşamaları (Korkut, 2019).	35
Şekil 2.7. Danışmansız öğrenme süreci ve aşamaları (Korkut, 2019).	36
Şekil 2.8. Destekli öğrenme süreci ve aşamaları (Tozkan ve Balık, 2004).	36
Şekil 2.9. Karar ormanı örnek mimarisi (Chakure, 2019).	38
Şekil 3.1. Tahmin modeli oluşturma süreci akış şeması.....	43
Şekil 3.2. Azure ML Studio tahmin modeli mimarisi.....	50
Şekil 3.3. Azure ML Studio’da aykırı verilerin kırılması.....	51
Şekil 3.4. Azure ML Studio ile verilerin normalize edilmesi.	51
Şekil 3.5. Verilerin normalizasyon sonuçları örneği.	52
Şekil 3.6. Verilerin Ln dönüşümünün yapıldığı modül detayı.....	53
Şekil 3.7. Ln dönüşümü uygulanmış veriler.	53
Şekil 3.8. Verilerin %90-10 oranında bölünmesi.	56
Şekil 3.9. Parametre aralığı özelliği.	58
Şekil 4.1. Nitelik seçimleriyle A ürünü yapay sinir ağları talep tahmin modelleri. ..	66
Şekil 4.2. Tüm nitelikler ile A ürünü yapay sinir ağları talep tahmin modeli.	67
Şekil 4.3. Nitelik seçimleriyle B ürünü yapay sinir ağları talep tahmin modelleri....	68
Şekil 4.4. Harris Şahini ile B ürünü yapay sinir ağları talep tahmin modeli.	69
Şekil 4.5. Nitelik seçimleriyle C ürünü yapay sinir ağları talep tahmin modelleri....	69
Şekil 4.6. Genetik optimizasyonu C ürünü yapay sinir ağları talep tahmin modeli. .	70
Şekil 4.7. Nitelik seçimleriyle D ürünü yapay sinir ağları talep tahmin modelleri. ..	71
Şekil 4.8. Tüm niteliklerle D ürünü yapay sinir ağları talep tahmin modeli.	72
Şekil 4.9. Nitelik seçimleriyle A ürünü karar ormanı talep tahmin modelleri.....	72
Şekil 4.10. Genetik optimizasyonu ile A ürünü karar ormanı talep tahmin modeli. .	73
Şekil 4.11. Nitelik seçimleriyle B ürünü karar ormanı talep tahmin modelleri.	74
Şekil 4.12. Harris şahini ile B ürünü karar ormanı talep tahmin modeli.	74
Şekil 4.13. Nitelik seçimleriyle C ürünü karar ormanı talep tahmin modelleri.	75
Şekil 4.14. Tüm niteliklerle C ürünü karar ormanı talep tahmin modeli.....	76
Şekil 4.15. Nitelik seçimleriyle D ürünü karar ormanı talep tahmin modelleri.....	76
Şekil 4.16. Genetik optimizasyonu ile D ürünü karar ormanı talep tahmin modeli. .	77
Şekil 4.17. Nitelik seçimleriyle A ürünü lineer regresyon talep tahmin modelleri. ..	78
Şekil 4.18. Yerçekimi optimizasyonu A ürünü lineer regresyon tahmin modeli.....	79
Şekil 4.19. Nitelik seçimleriyle B ürünü lineer regresyon talep tahmin modelleri....	79
Şekil 4.20. Harris şahini ile B ürünü lineer regresyon talep tahmin modeli.	80
Şekil 4.21. Nitelik seçimleriyle C ürünü lineer regresyon talep tahmin modelleri....	81
Şekil 4.22. Parçacık sürüsü ile C ürünü lineer regresyon talep tahmin modeli.	81
Şekil 4.23. Nitelik seçimleriyle D ürünü lineer regresyon talep tahmin modelleri. ..	82
Şekil 4.24. Yerçekimi optimizasyonu D ürünü lineer regresyon tahmin modeli.....	83
Şekil 4.25. Ürün ve yöntemlere göre Ortalama Kare Hata değerleri.....	84

Şekil 4.26. Ürün ve yöntemlere göre Kök Ortalama Kare Hata değerleri.	84
Şekil 4.27. Ürün ve yöntemlere göre Ortalama Mutlak Hata değerleri.	85
Şekil 4.28. Ürün ve yöntemlere göre Ortalama Mutlak Yüzde Hata değerleri.....	86



MAKİNE ÖĞRENMESİNE DAYALI TALEP TAHMİN MODELLERİNİN KARŞILAŞTIRILMASI

ÖZET

Üretim planlarındaki gecikmelerin önlenmesi için hammaddenin ve yarı mamulün belirlenen miktarda bulundurulması planların gerçekleşmesinde önemli bir etkiye sahiptir. Bu doğrultuda literatürde yapılan çalışmaların tedarik zincirinde sürekliliğin sağlanması ve müşteriye teslim tarihlerinin gerçekleşmesinde talep tahmin modellerinin önemi yadsınamaz. Literatürde ve endüstriyel raporlarda sipariş gecikmelerinin önlenmesi için gerekli çalışmalardan biri olan gerçekçi talep tahmin modellerinin geliştirilmesi önemli bir yer tutmaktadır.

Bu çalışmada makine öğrenmesine dayalı gerçekçi bir talep tahmin modeli geliştirilmesi amaçlanmıştır. Bu çalışmayla ürünler için ihtiyaç duyulan sipariş gecikmelerinde birincil derecede önemli hammadde ve yarı mamulün ihtiyaç duyulan zamanda ve miktarda belirlenebilmesi bu problemleri önemli oranda azaltacaktır. Bu çalışmanın sonucunda aylık periyotta yapılan tahminler ile malzemelerin stok miktarlarının optimum seviyede bulundurulabilmesi sağlanacaktır. Sipariş fazlası ve ürün teslimatındaki gecikmelerin önemli oranda düşürülebileceği bu çalışmanın sonuçlarına dayanarak söylenebilir. Bu çalışmada geliştirilen modelin tahmindeki hataları azaltılabileceği, son üç dönem talep ortalamalarının bağımsız değişkenler olarak ele alınması ile sağlanabileceği gözlemlenmiştir. Geliştirilen modelde enerji maliyeti, euro/dolar paritesi, çelik fiyatı, 1 ay önceki sipariş miktarı, 2 ay önceki sipariş miktarı, 3 ay önceki sipariş miktarı ve son 3 dönem sipariş ortalaması niteliklerinin yanı sıra talebin artması ve azaltılması trendlerinin belirlenmesinde çelik hammadde fiyatındaki değişim ile enerji maliyetlerindeki değişim ve sipariş miktarındaki değişimler de bağımsız nitelikler olarak ele alınmıştır.

Tahmin modellerinin geliştirilmesinde yapay sinir ağları, karar ormanı ve lineer regresyon yöntemleri kullanılmış ve modellerin performansları değerlendirilerek karşılaştırılmıştır. Talep tahmin modellerinin geliştirilmesinde en ilgili özelliklerin belirlenebilmesi amacıyla Parçacık Sürüşü Optimizasyonu, Harris Şahini Optimizasyonu, Gri Kurt Optimizasyonu, Yusufçuk Optimizasyonu, Genetik Optimizasyonu ve Yerçekimi Arama Optimizasyonu olmak üzere 6 farklı nitelik seçimi yöntemi uygulanmıştır. Bu optimizasyon algoritmalarıyla nitelik seçimleri yapılarak daha doğru sonuç veren modeller geliştirilmiştir. Geliştirilen modellerde hammaddenin ve yarı mamullerin yeterli miktarda bulunmaması sipariş gecikmelerine, fazla olması ise stok maliyetlerinin artmasına neden olabilmektedir. Geliştirilmiş olan modelde tahmin hatalarının azaltılmasıyla sipariş gecikmelerinin ve stok maliyetlerinin azaltılabileceği öngörülmüştür.

Modelin uygulanmasında kullanılan veriler çelik imalat sektöründe faaliyet gösteren büyük ölçekli bir firmadan temin edilmiştir. Modelin uygulanmasında dört farklı ürünün geçmiş yıllara ait satış verileri kullanılmıştır. 89 aylık veri toplanmış ve bunun 80 aylık verisi modeli eğitmek için, 9 aylık veri de test ve performans verisi olarak

kullanılmıştır. Deneysel sonuçlara göre, nitelik seçimi yöntemlerinin genel olarak tahmin modellerinin performansını artırdığı sonucuna ulaşılmasına rağmen her bir ürün için en uygun tahmin performansını gösteren nitelik kümesi ve talep tahmini yöntemi kombinasyonunun farklılık gösterdiği değerlendirilmiştir. Geliştirilen modeller sayesinde ürünler için sırasıyla %93,6, %94,7, %90,3 ve %91,5 tahmin doğruluğu değerine ulaşılmıştır. Geliştirilen modeller MAPE, MAE, RMSE ve MSE performans ölçütlerine göre değerlendirilmiş, yapay sinir ağları yöntemiyle geliştirilen modelin diğer modellere göre daha iyi sonuç verdiği değerlendirilmiştir. Yapay sinir ağlarıyla geliştirilen modellerin ortalama %91,9, karar ormanı yöntemi ile geliştirilen modellerin ortalama %91,3, lineer regresyon yöntemiyle geliştirilen modellerin ortalama %87,3 doğruluk değerine ulaştığı gözlemlenmiştir. Çalışmada önerilen metodolojinin çelik sektöründe faaliyet gösteren firmalar bünyesindeki ürünler için etkili bir şekilde kullanılabileceği öngörülmektedir.



COMPARISON OF MACHINE LEARNING BASED DEMAND FORECASTING MODELS

SUMMARY

In order to prevent delays in production plans, keeping the raw materials and semi-finished products in the specified amount has a significant impact on the realization of the plans. In this regard, the importance of demand forecasting models in ensuring continuity in the supply chain and achieving customer delivery dates cannot be denied. Nowadays, as developments occur very rapidly and it becomes more and more difficult to keep up with developments, it has become a greater need for businesses to predict the future in order to maintain their existence. Being able to react to demands in a timely manner by adapting to changes in customer volumes and developments in technology contributes to the sustainability of the supply chain. It is possible for businesses to secure their future even in a highly competitive environment with a successful supply chain management. High variability in demand may cause disruptions in supply and inventory management. These disruptions may lead to increased costs due to excess stock or order losses as a result of products not being delivered. As a result of failure to control the disruptions, the situation may turn into customer loss for the business. Demand forecasting is one of the most needed functions in solving these problems. Demand forecasting methods offer advantages in many areas such as planning, cost and inventory management. With these advantages, companies' inadequacies decrease and their resilience in the market increases.

The development of realistic demand forecast models, which is one of the necessary studies to prevent order delays, has an important place in the literature and industrial reports. In this study, it is aimed to develop a realistic demand forecasting model based on machine learning. With this study, determining the primary raw materials and semi-finished products at the required time and quantity in order delays needed for products will significantly reduce the problems. Despite the complex problems involved in demand forecasting processes, the common goal in demand forecasting is to benefit businesses by making a future forecast with high accuracy. At the same time, thanks to accurate forecasts, the efficiency of businesses increases. More accurate determination of product quantity and variety places demand forecasting at the center of planning. Compared to traditional forecasting methods, machine learning-based forecasting methods provide better results. In this study, which was conducted using real sales data through a case study, solutions were realized with selected machine learning-based methods. It is aimed to determine the method that gives the optimum result with the established models.

The data to be used in demand forecast models were selected among the parameters that directly or indirectly affect the demands of products whose main component is steel. Euro/dollar parity was chosen as one of the independent variables, because the raw materials used in the production of the products are traded internationally in dollars and sales are made in euros. Since approximately 80% of the cost of the products comes from raw materials and the main component of the products is steel,

the price of steel has become another independent variable. Energy cost was used as another independent variable, as the most important cost item in the cost of the products after the raw material and machinery investment cost. Additionally, there was a need to add recent data to increase the accuracy of the demand forecast model. Thus, in the models, actual order data for each product one, two and three months ago was also evaluated among the independent variables. The actual sales data used in the demand forecast model was taken from a large-scale international company selling products in the steel industry. In addition to the data of the last three periods, the attribute was created with the moving average data of the last three months. In the re-model simulations, it was observed that the addition of these features significantly contributed to the reduction of errors. In addition, it was realized from the simulations that the change in variables should be included among the attributes in order for the model to follow the changes in orders. In this regard, the differences in steel prices between periods, the differences in energy costs between periods and the change values of orders between periods were added to the independent variables. When deciding to use independent variables in the models, various modeling simulations were made with the available data.

Comparisons of artificial neural networks, decision forest and linear regression methods were made to evaluate the performance of the demand forecasting model. Statistical methods have been applied to the independent components used in artificial neural networks, decision forest and linear regression models to obtain more accurate results in the models. In the training set, changes such as replacing the distribution of the data that disrupted the series and were at the extreme ends of the distribution with the average value, normalization, and logarithmic transformations were made. Outlier data in the data set used in the model were replaced with average values. While the values at the extremes were removed, the values above 95% and below 5% were selected. In addition, since the range of real sales values used in training the model was very wide, logarithmic transformation was performed to eliminate the skewed distribution in the data and obtain a distribution close to the normal distribution.

In order to determine the most relevant features in the development of demand forecast models, 6 different feature selection methods were applied: Particle Swarm Optimization, Harris Hawk Optimization, Grey Wolf Optimization, Dragonfly Optimization, Genetic Optimization and Gravity Search Optimization. By making feature selections with these optimization algorithms, models that give more accurate results have been developed. In the developed models, not enough raw materials and semi-finished products may cause order delays, while their excess may cause an increase in stock costs. In the developed model, it is predicted that order delays and inventory costs can be reduced by reducing forecast errors. As a result of this study, it will be ensured that the stock quantities of the materials are kept at the optimum level. Based on the results of this study, it can be said that overorders and delays in product delivery can be significantly reduced.

Considering all the findings in the literature, in this study, experiments were conducted with data splitting rates of 70-30%, 80-20% and 90-10% in training the models. Test studies have shown that the best results are achieved with the 90-10% option. It is predicted that the reason for this difference from the 80-20% rate found in the majority of the literature is that the number of periods of available data is relatively less. 89 months of data were collected, 80 months of which were used to train the model, and 9 months of data were used as test and performance data. The models developed within the scope of this study were compared according to different demand forecasting

methods. In this study, 84 (4x3x7) different models were developed for 4 different products selected for welded steel manufacturing products, 3 different machine learning algorithms and 7 cases with and without feature selection, and these models were evaluated in terms of performance criteria. When the developed models were evaluated according to MAPE, MAE, RMSE and MSE performance criteria, it was evaluated that the model developed with the artificial neural networks method gave better results than other models. Four models built with the artificial neural networks method made predictions with high accuracy. With the decision forest method, highly accurate forecast was obtained in 3 models and good forecast was obtained in 1 model. Among the models created with the linear regression method, highly accurate forecast was obtained in 1 model and good forecast values were obtained in 3 models. It was observed that the model developed with artificial neural networks reached an average accuracy of 91.9%, the model developed with the decision forest method reached 91.3%, and the model developed with the linear regression method reached 87.3% accuracy. The artificial neural networks method predicted the highest and lowest demands better than other methods. It is predicted that if the artificial neural networks method is used in other demand forecasting studies, as in this study, it will achieve the objectives of the research by providing highly accurate forecasts. If the decision forest method is used, generally highly accurate forecasts can be obtained, as in artificial neural networks. It can be said that the forecasts obtained with decision forests will similarly provide the desired benefits to the business at a slightly lower level than the artificial neural networks method. It can be predicted that the linear regression model can provide good forecasts, but when error rates are encountered, it does not need to be preferred over other methods. As a result, it has been observed that the artificial neural network model is a more accurate choice for the desired contributions.



1. GİRİŞ

Günümüzde meydana gelen hızlı değişimler dolayısıyla işletmelerin geleceği tahmin etmesi varlıklarını devam ettirebilmeleri için temel bir ihtiyaç haline gelmiştir (Güven, 2020). Müşteri hacimlerindeki büyümeler, teknolojiye gelişmeler gibi sebeplerle pazar talebine hızlı reaksiyon verebilmek ve müşteriler için sürdürülebilir bir tedarik zinciri sağlayabilmek hayati önem taşımaktadır. Etkili bir tedarik zinciri yönetimi yüksek rekabetli bir çevrede dahi işletmenin sürekliliğini güvence altına almaktadır. Müşteri talebindeki değişkenlikler tedarik zincirleri yönetimini istikrarsızlaştırmakta ve envanter yönetimini bozmaktadır. Ürünlerin müşteriye teslimatının zamanında yapılamaması sadece stok seviyelerini etkileyip ilave maliyetlere sebep olmakla kalmayıp müşterinin beklentisinin düşmesine ve ürünleri alma konusunda motivasyonunun kırılmasına da neden olmaktadır. Bu nedenlerden dolayı teslimat gecikmeleri özellikle Endüstri 4.0 çağında muhtemel olan en kısa zamanda ele alınmalı ve çözümlenmelidir (Keung ve ark, 2021). Talep tahmini ve satış tahmini bahsedilen ihtiyaçlar doğrultusunda üreticilerin, dağıtıcıların ve ticaret yapan firmaların en önemli fonksiyonlarından biridir (Kochak ve Sharma, 2015).

Talep tahmin yöntemleri üretim planlama, maliyet, stok ve teslimat süreleri gibi konularda birçok avantaj sunmaktadır. Talep ve tedarik dengesinin sağlanarak envanterdeki fazlalıkların ve yetersizliklerin azaltılması ile karlılık artırılmaktadır (Kochak ve Sharma, 2015). Böylece şirketler tedarik zincirindeki esnekliklerini ve dayanıklılıklarını artırmak istemektedir. (El Filali ve ark, 2022).

Ürünler için yapılan talep tahmini ürünün karakteristiklerine ve endüstrinin özelliklerine bağlıdır. Bu sebeple ürün ve endüstri özellikleri ile talep tahmini arasında etkileşim bulunmaktadır (Feizabadi, 2022). Lineer olmayan veriye uyum sağlama, deneysel verilerdeki ince fonksiyonel ilişkileri yakalama, hatta altta yatan bilinmeyen ve tanımlanması zor ilişkilerin kurulmasında yapay sinir ağları (YSA) algoritmalarının etkili teknikler olduğu bulunmuştur (Kochak, Sharma, 2015).

1.1. Araştırmanın Amacı

Talep tahmin süreçlerinde yer alan karmaşık problemlere karşın talep tahminlerinde ortak amaç yüksek doğruluğa sahip bir gelecek tahmininde bulunarak işletmelere fayda sağlamaktır. Aynı zamanda yapılan doğru tahminler sayesinde işletmelerin verimliliğinde artış sağlanmaktadır. Ürün miktarının ve çeşidinin daha doğru belirlenmesi talep tahminini planlamanın merkezinde konumlandırmaktadır. Bu çalışmada da geliştirilmiş bir talep tahmin modeli ile yüksek doğruluklu tahminler elde edilerek kısa, orta ve uzun vadede bahsedilen bu faydaların işletmeye kazandırılması amaçlanmıştır. Geleneksel tahmin yöntemleri ile karşılaştırıldığında makine öğrenmesi tabanlı tahmin yöntemleri daha iyi sonuçlar sağlamaktadır. Örnek olay üzerinden gerçek satış verileri kullanılarak yapılan bu çalışmada seçilen makine öğrenmesi tabanlı yöntemler ile çözümler gerçekleştirilmiştir. Kurulan modeller ile optimum sonucu veren yöntemin belirlenmesi amaçlanmıştır.

1.2. Araştırmanın Kapsamı ve Sınırlılıkları

Çalışmada çeşitli talep tahminleri ile alınan örnek olayda aynı veriler kullanılarak sonuçların doğruluğunun nasıl değiştiği araştırılmıştır. Bu araştırma yapılırken 89 dönemlik gerçek geçmiş dönem satış verileri kullanılmıştır. Geçmiş dönem verilerinde 80 aylık satış değerleri eğitim veri seti olarak ele alınmış, 9 aylık geçmiş satış verisi ise test verisi olarak kullanılmıştır. Satış miktarları ele alınan ürünlere ait geçmiş dönem verileri kaynaklı çelik imalatı yapan büyük ölçekli bir şirketten alınmıştır. Talebi etkileyen parametreler bu doğrultuda çelik sektörüne göre belirlenmiştir. Talebi etkilemesi muhtemel parametreler arasından ilgili dönemlere ait doğrudan talebi etkileyeceği düşünülen euro/dolar paritesi, çelik hammadde fiyatı ve enerji maliyetleri seçilmiştir. Çelik hammaddenin dolar bazında satın alınıp, bitmiş ürünün euro bazında satışının gerçekleştirilmesi euro/dolar paritesinin bağımsız değişken olarak seçilmesinde etkili olmuştur. Ayrıca talep tahminin daha etkili olması açısından son üç aylık satış verisinin bağımsız değişkenler olarak eklenmesi gerektiği düşünülmüştür. Böylece bir ay önceki, iki ay önceki ve üç ay önceki geçmiş satış değerleri de modelde girdi değişkenleri olarak değerlendirilmiştir. Ayrıca modelin tahmin doğruluğunu artırmak adına 3 dönem taleplerinin ortalaması bağımsız değişkenler olarak kullanılmıştır. Modelin artış ve düşüşteki trendlerini

yakalayabilmesi için ise çelik hammadde fiyatındaki değişim, enerji maliyetindeki değişim ve sipariş miktarlarındaki değişim bağımsız nitelikler arasına eklenmiştir.

Tahmin modelleri kurulurken önceki araştırmalarda ve literatürde regresyon çalışmaları için önerilen yöntemler değerlendirilmiştir. Önerilen yöntemler arasından makine öğrenmesi tabanlı tahmin yöntemlerinden yapay sinir ağları, karar ağaçlarının birleşiminden oluşan karar ormanı ve lineer regresyon teknikleri seçilmiş ve tahmin modelleri geliştirilmiştir. Modellerin test edilmesi neticesinde elde edilen tahmin sonuçlarının gerçek zamanlı tahminler olması sayesinde bağımsız bileşenlerdeki hızlı değişimlere karşılık tahmin modeli yüksek hassasiyetle reaksiyon verebilmektedir. Bununla ilgili olarak tahmin modelinin asıl hedefinin uzun vadeli talep tahminleri yerine gerçek zamanlı tahmin yapmak olduğunu belirtmekte fayda bulunmaktadır.

Araştırmada kullanılan bağımsız değişkenlerin sadece belirlenmiş olan değişkenlerle kısıtlı olması ve sadece çelik sektörüne ait bir çalışma olması araştırmanın sınırlılıkları olarak sayılabilir. Farklı bağımsız değişkenler eklendiğinde ya da farklı bir sektörde aynı model kullanıldığında sonuçlar değişkenlik gösterebilir.

1.3. Literatür Araştırması

Bufalo ve Orlando (2023), yapmış oldukları çalışmada üç faktörlü stokastik model oluşturarak enerji materyallerinde talep tahmin çalışması yapmıştır. Çalışmada “Federal Reserve Economic Data”’dan aldıkları endüstriyel üretim endeks verileri kullanılmıştır. Model için ARIMA-GARCH yöntemi seçilmiş, modelin doğruluğu Normalize Ortalama Karekök Hata (NRMSE) ve Ortalama Mutlak Yüzde Hata (MAPE) performans kriterleriyle değerlendirilmiştir.

Elmir ve ark. (2023), kan bankası yönetimi için makine öğrenmesi tabanlı yöntemler kullanarak ilgili kan sınıfları için talep tahmin çalışması yapmıştır. Yapay sinir ağları ile gerçekleştirilen modelin doğruluğu %95 iken, rastgele orman modelinde doğruluk %94, destek vektör modelinde ve lineer regresyon modelinde %65, Naive Bayes modelinde ise %62 çıkmıştır. Bir önceki yılın geçmiş verileri kullanılarak oluşturulan model toplanan kan hacmini %11 artırmış ve envanter kaybını %20 azaltmıştır.

Lee ve ark. (2023), hızlı tüketim mallarının fiyatının belirlenmesinde önemli etkenlerden birisi olan yerine koyma etkisini inceleyerek ürünlerin optimum fiyatını belirleme üzerine çalışmışlardır. Yapmış oldukları çalışmada yerine koyma etkisini de

göz önünde bulundurarak talep tahmini için fiyat karar destek aracı ve fiyat optimizasyon modelleri önermektedirler. Talep tahmin sonuçları fiyat optimizasyon modellerinin kurgulanmasında girdi olarak kullanılmıştır. Tahmin metotları Kök Ortalama Kare Yüzde Hata (RMSPE) hata ölçüm kriteri ile karşılaştırıldığında makine öğrenmesi yöntemlerinin diğer yöntemlerden daha doğru sonuçlar verdiği gözlemlenmiştir.

Maisel ve ark. (2023), çalışmalarında lityum-iyon bataryaların geri dönüşüm potansiyelini ve gelecek için hammadde ihtiyacının talep tahminini araştırmıştır. Tahmin çalışması “Shared Socio-economic Pathways” yöntemiyle gerçekleştirilmiştir. Çalışmayla birlikte 2040 yılında ihtiyacın bugünkü üretim miktarının 8 katı olacağı sonucunu elde etmişlerdir. Ayrıca geri dönüşüm ile yarısının karşılanma potansiyeline rağmen yine de ihtiyacın bugünkü üretimin çok üstünde olduğu görülmüştür.

Orzechowski ve ark. (2023), elektrikli araçların şarj taleplerinin veri bazlı tahmin çalışmasını yapmışlardır. Araştırma halka açık şarj istasyonlarındaki potansiyel talep verilerine dayanarak bir hafta öncesinden tahmin etmeyi önermektedir. Çalışmada yapay sinir ağları, ARIMA, rastgele orman, destek vektör ve k-en yakın komşu algoritması ile farklı modeller oluşturulmuştur. MAE, RMSE ve Simetrik Ortalama Mutlak Yüzde Hata (SMAPE) hata ölçüm metrikleriyle karşılaştırma yapılarak ortalama değerler incelendiğinde yapay sinir ağlarının en iyi performansı sağladığı görülmüştür.

Abbate ve ark. (2022), teslimat platformları için yapay sinir ağları yöntemini kullanarak talep tahmin çalışması yapmıştır. Çalışmada internet üzerinden işleyen bir şirketin günlük talep tahminleri ele alınmıştır. Siteyi ziyaret sayısı, aylar, günler ve haftalar bağımsız değişkenler olarak değerlendirilmiştir. Yapay sinir ağları metotlarından Çok Katmanlı Algılayıcı (MLP) kullanılarak modeller oluşturulmuş, değerlendirme için ise RMSE ölçütü kullanılmıştır. Alınan sipariş verilerinin %20 kadarı test ve değerlendirme için ayrılmıştır.

Acı ve Doğansoy (2022), çalışmasında 2 yıllık e-ticaret verilerini kullanarak ürün satış tahmini yapmıştır. En doğru sonucu veren talep tahminini elde etmek için Derin Öğrenme, Yapay Sinir Ağları, Gauss Süreç Regresyonu, Regresyon Ağacı, Destek Vektör Regresyonu ve Topluluk Öğrenme yapay zekâ algoritmaları ile modeller

oluşturmuştur. Korelasyon katsayısı (R), Kök Ortalama Kare Hata (KOKH) ve Ortalama Mutlak Hata (OMH) ölçütleriyle sonuçlar arasında karşılaştırma yapılmıştır. En iyi sonuç Uzun/Kısa Süreli Bellek Ağları ile oluşturulan modelde bulunmuştur.

Alobaidi (2022), yapmış olduğu çalışmada C segment otomatik şanzımanlı araçların 2012-2021 yılları arasındaki 120 aylık veri seti kullanılarak satış tahmini gerçekleştirilmiştir. Yapay sinir ağları ve regresyon analizi yöntemlerinden yararlanılarak tahmin değerleri elde edilmiştir. Araç talep tahmini daha yüksek başarı oranı sağlayan yapay sinir ağları modeline göre değerlendirilmiştir.

Akbaş (2022) yapmış olduğu çalışmada tekstil sektöründe faaliyet gösteren bir firmanın 2018-2021 yılları arasındaki satış verilerini kullanmıştır. Matlab programı aracılığıyla yapay sinir ağları yöntemi kullanılarak tahmin modeli oluşturulmuş ve model testi sonucunda modelin tutarlı olduğu sonucuna varılmıştır.

Dey ve ark. (2023), Hindistan'ın gelecekteki yakıt araç emisyonu azaltma hedeflerini karşılamak adına alternatif olan etanol talebinin tahmin çalışmasını ele almışlardır. Bu talep tahmin çalışmasında Hindistan'ın geçmiş yakıt talebi verilerini kullanarak tahmin modelleri oluşturmuşlardır. ARIMA ve çeşitli regresyon modellerini MAPE performans değerlendirme ölçütü ile karşılaştırmışlardır. ARIMA (1,1,0) modeli en yüksek doğruluğu sağlayan model olmuştur.

El Filali ve ark. (2022), çalışmalarında elektrik ürünleri için talep tahminleri yaparak farklı YSA yöntemlerini karşılaştırmıştır. Derin öğrenmenin kullanımının kısıtlı olmasına karşın Yinelemeli Sinir Ağları (RNN) ve LSTM modellerini karşılaştırarak yeni bir derin öğrenme metodu olan Geçitli Tekrarlama Ünitesi (GRU) modelini önermiştir. Performans değerlendirme için SMAPE, RMSE ve MAE ölçütleri kullanılmıştır. GRU modeli en iyi sonuçları veren model olmuştur.

Engin (2022), bir tekstil firmasına ait geçmiş kumaş sipariş miktarları verilerini kullanarak çalışmalarında yapay sinir ağları yöntemiyle gelecek kumaş sipariş tahminlerini elde etmiştir. Bu doğrultuda Matlab2018b yazılımı kullanılmıştır. Yapay sinir ağları modelini oluştururken deneme yanılma ile Ortalama Kare Hatası (MSE) ve MAPE performans ölçütlerini kullanarak en iyi sonucu veren model seçilmiştir.

Feizabadi (2022), yapmış olduğu çalışmada tedarik zinciri performansını iyileştirmek amacıyla geleneksel yaklaşımların yanında sinir ağları ve Otoregresif Bütünleşik Hareketli Ortalama eXplanatory ARIMAX yöntemlerini kullanarak tahminler

gerçekleştirmiştir. Fonksiyonel bir ürün ve bir çelik üretici bağlamında yöntemler uygulanmış ve sonuçlar bu alınan bu veriler üzerinden değerlendirilmiştir. Değerlendirme sonucunda geleneksel yöntemlere nazaran yapay zekâ tabanlı yöntemlerin daha iyi sonuçlar verdiği kanaat getirilmiştir. ARIMAX ve YSA ayrıca değerlendirildiğinde ise ikisinin de kullanımında performans iyileştirmesi sağlayabildiği görülmüştür.

Hao ve ark. (2022), Milan şehrinin kentsel su talebi üzerine yaptıkları çalışmada yapay zekâ tabanlı tahmin modelleri oluşturmuştur. ARIMA, LSTM, yapay sinir ağları, destek vektör regresyonları, LightGBM, Dalgacık Veriye Dayalı Tahmin Çerçevesi (WDDFF) modellerini RMSE, MAE, MAPE ve belirleme katsayısı hata ölçme kriterleriyle karşılaştırmışlardır. 1 gün ve 7 gün önceden talebin tahmin edilmesi hedeflenen çalışmada en iyi sonucu WDDFF modeli vermiştir.

Mediavilla ve ark. (2022), yapay zekâ metotlarını kullanarak tedarik zinciri yönetiminde talep tahminin analiz çalışmasını gerçekleştirmiştir. Çalışma sonucunda yapay zekâ metotlarının “büyük veri” alanındaki eksiklikleri gözlemlenmiştir. Bu boşluğun giderilmesinde farklı yapay zekâ yöntemlerinin kombinasyonları etkili sonuç vermiştir.

Migueis ve ark. (2022), makine öğrenmesi yöntemleriyle gerçekleştirdikleri talep tahmin çalışmasında taze balık israfının azaltılması ve aynı zamanda bulunabilirliğin güvence altına alınması konusunu ele almışlardır. Çalışmada LSTM ağları, ileri beslemeli yapay sinir ağları, destek vektör regresyonu, rasgele ormanlar makine öğrenmesi yöntemleri kullanılmıştır. RMSE ve MAE performans değerlendirme ölçütleriyle karşılaştırıldığında en iyi sonucu LSTM modeli vermiştir.

Robus ve ark. (2022), çalışmalarında yapay sinir ağları (YSA) yöntemi ile yapılmış olan talep tahmini ile ilgili 193 yayını inceleyip kullanılan performans değerlendirme metotlarını ve bu yöntemlerden potansiyel tahmin yöntemini belirlemedeki temel metotları belirlemiştir. MAPE, MAE ve RMSE performans değerlendirme yöntemlerinin kombinasyonun kullanımın en yaygın kullanım olduğu sonucuna varmışlardır.

Singha ve Panse (2022), tedarik zinciri talep tahmin uygulama çalışmasında farklı makine öğrenmesi yöntemlerinin karşılaştırmalı analizini yapmıştır. Çalışmada Kaggle’den alınan “Mağaza Malzeme Talep Tahmini” veri seti kullanılmıştır. MLP,

CNN ve LSTM yöntemlerinin RMSE hata ölçüm kriterini kullanarak karşılaştırılması sonucunda MLP yönteminin en iyi sonucu verdiği görülmüştür.

Yani ve Aamer (2023), yapay zekâ yöntemiyle yapmış oldukları çalışmada ilaç tedarik zincirinde talep tahmin doğruluğunu belirlemiştir. Çok uluslu ilaç şirketlerinden alınan dokuz farklı ürünün verileri kullanılmıştır. Gradyan Artırıcı Ağaçlar (GBT), Rasgele Ormanlar (RF), Lineer Regresyon (LR), PR, Basit Ağaç (ST) ve Ağaç Topluluğu (TE) makine öğrenmesi yöntemleri kullanılarak kurulan modeller ile MAPE ölçüm kriteri kullanılarak performans değerlendirmesi yapılmıştır. Değerlendirme ile en iyi sonuçların veri setindeki %80 oranında verinin eğitim veri seti olarak kullanılması durumunda alındığı sonucuna varılmıştır. Rastgele orman modeli ile %87 doğruluk elde edilmiştir.

Dedeoğlu ve Çetin (2021), yapmış olduğu çalışmada ameliyat sayısı ve yatan hasta sayısı taleplerini içeren tahminler elde etmiştir. Talep tahminleri hareketli ortalama, üstel düzeltme, Holt yöntemi, trend analizi ve regresyon analizi yöntemleri ile gerçekleştirilmiştir. Modeller MS Excel ve SPSS paket programları kullanılarak oluşturulmuştur. MAPE, Ortalama Mutlak Sapma (MAD) ve MSE kriterleri kullanarak yöntemlerin performansları değerlendirilmiştir.

Dinç (2021), yapmış olduğu çalışmada Yapay Sinir Ağları (YSA), Bulanık Zaman Serisi ve Uyarlanabilir Ağ Yapısına Dayalı Bulanık Çıkarım Sistemi (ANFIS) gibi yapay zekaya dayalı tahmin yöntemlerinden faydalanan ve dondurulmuş paket künefe haftalık satış verilerinin kullanarak gelecek dönem talep tahmin değerleri elde etmiştir. Performans kriterleri olarak Ortalama Karesel Hatanın Karekökü (OKHK) ve MAPE ölçütlerinden faydalanmıştır. Performans ölçütlerine göre yapılan değerlendirme sonucunda geleneksel yöntemlere göre yapay zekâ modellerinin daha iyi sonuçlar verdiği görülmüştür.

Gonçalves ve ark. (2021), otomotivde tedarik zinciri üzerine yapmış oldukları çalışmada montaj endüstrisinde çok adımlı talep tahmini için çok değişkenli bir yaklaşım benimsemişlerdir. ARIMAX yöntemiyle yapay zekâ tabanlı tahmin yöntemlerini karşılaştırmışlardır. Örnek olay üzerinde NMAE performans değerlendirme kriteriyle yapılan karşılaştırmalar sonucunda MLP sinir ağları modeli en iyi sonucu veren model olmuştur.

Gül (2021), yapmış olduğu uygulamada kronik bir hastalığın tedavisinde kullanılmak üzere Türkiye’de üretilen ve satışa sunulan bir ilacın 12 aylık satış verilerini kullanarak hareketli ortalama, ağırlıklı hareketli ortalama, üstel düzeltme, trend analizi ve Holt’un trend içeren üstel düzeltme yöntemleri aracılığıyla oluşturduğu modellerle ilaç talebinin tahminlerini yapmıştır. Kullanılan yöntemler arasında bu veri setine uygun en iyi tahmini veren yöntemin trend analizi olduğu sonucuna varılmıştır.

Han ve ark. (2022), çalışmasında Holt Winters ve Yapay Sinir Ağları yöntemlerini kullanarak Türkiye’de sıfır otomobil satış adetlerinin tahmin değerlerini elde etmiştir. 2015-2020 arasındaki veriler ve döviz kuru, tüketici güven endeksi, gayrisafi yurt içi hasıla (GSYHİ), reel kesim güven endeksi bağımsız değişkenleri kullanılarak 2019 ve 2020 yıllarındaki otomobil satış tahminleri elde edilmiştir. Çeşitli performans göstergeleriyle yapılan karşılaştırmalar sonucunda YSA’nın Holt-Winters yöntemine göre daha iyi sonuç verdiği tespit edilmiştir.

Keung ve ark. (2021), perakende sektöründeki verilere dayanarak teslimat gecikmelerini ve satış tahminini hangi etmenlerin etkilediğini araştırmıştır. Çalışmada modeller Naive Bayes, karar ağacı, YSA ve K-En Yakın Komşu (KNN) algoritmaları ile geliştirilmiştir. Yerel faktörlerin ve ürün kategorilerinin satışlarda dalgalanmalara veya gecikmelere sebep olduğu sonucuna varılmıştır. KNN ve karar ağacı modelleri en iyi sonuçları veren modeller olmuştur.

Kück ve Freitag (2021), üretim planlama için müşteri taleplerinin tahmin çalışmasını KNN yöntemini kullanarak gerçekleştirmiştir. Yerel ortalama sabiti, yerel medyan sabiti, dört farklı düzenleme metodu ve çeşitli parametre kombinasyonlarıyla yüksek doğruluk elde edilmesi hedeflenmiştir. Çeşitli talep tahmin yöntemleri ile yapılan karşılaştırma sonucunda KNN metodunun en az hataya sahip yöntem olduğu ve endüstri alanında daha çok kullanılabileceği sonucuna varılmıştır.

Mohan ve ark. (2021), tedarik zincirinde talep tahmini ve rota optimizasyonu için yaptığı çalışmada Otoresif Bütünleşik Hareketli Ortalama (ARIMA) yöntemi ve benzetimli tavlama algoritmalarını kullanmıştır. MAPE performans ölçütünü kullanarak modelin doğruluğu değerlendirilmiştir.

Omella ve ark. (2021), Zaman Serilerinde K-En Yakın Komşu Şablonları (KNPTS) yöntemiyle konut ve küçük ticari binalarının elektrik talebinin tahmin çalışmasını yapmışlardır. Dinamik Zaman Bükmesi (DTW) ve Kök Ortalama Kare Hata (RMSE)

metrikleriyle yapılan karşılaştırma sonucu KNPTS yönteminin Zaman Serilerinde K-En Yakın Komşu Nitelikleri (KNFTS) yöntemine göre daha iyi sonuçlar verdiği görülmüştür.

Tavukçu ve Sennaroğlu (2021), iş makineleri için yedek parça satışı yapan bir firmadaki stok siparişlerinin tahmin değerlerini elde etmiştir. Firma bu çalışmadan önce stok siparişlerinin tahmini için 12 aylık talep verisinin hareketli ortalamasını kullanmıştır. Bu çalışmada ise 36 aylık talep verisi kullanılarak farklı talep tahmin yöntemleri ile tahminler gerçekleştirilmiştir. En iyi sonucu veren yöntemi belirlemek için stok tutma maliyeti ve kayıp satış maliyeti değerleri hesaplanarak değerlendirme gerçekleştirilmiştir. Sonuç olarak 3 farklı yedek parça için en iyi tahmin sonucunu Holt-Winters metodu kullanılmıştır.

Ünlü (2021), Destek Vektör Makineleri algoritmasını kullanarak bir üretim tesisindeki 3 farklı lokasyondaki haftalık malzeme girişi ve günlük malzeme girişi tahminlerini gerçekleştirmiştir. MAPE ile yapılan performans değerlendirmesi sonucunda haftalık tahmin değerleri Çorlu, İzmit ve Gebze lokasyonları için daha iyi sonuçlar vermiştir.

Abolghasemi ve ark. (2020), çalışmalarında farklı değişim katsayısı değerlerine sahip 843 gerçek talep tahmin serisini incelemiştir. İyi bilinen yapay zekâ yöntemleriyle talep tahmin modelleri kurup modellerin tahmin doğruluklarını ve envanter performansını değerlendirmişlerdir. Doğruluk ölçümlerinde ortalama mutlak ölçekli hata kriteri kullanılmıştır. Kullanılan yöntemlerden ARIMA'nın iyi performans gösterdiği, destek vektör regresyonu ve dinamik lineer regresyonun kuvvetli tahminler yapabildiği sonucuna varmışlardır. Aynı zamanda yapay sinir ağlarının düşük sapmalara sahip serilerde daha iyi sonuçlar verdiği görülmüştür.

Adalı (2020), yapmış olduğu uygulamada elektromekanik sanayiinde faaliyet gösteren bir şirketin 2009-2019 yılları arasındaki güç transformatörlerinin satış miktarlarını kullanarak Box Jenkins yöntemleri modeli aracılığıyla tahmin çalışması yapmıştır. Performans ölçüm kriterlerinden RMSE, Ortalama Mutlak Hata (MAE), Ortalama Mutlak Yüzde Hata (MAPE) ve Theil eşitsizlik katsayısı ölçütlerinden faydalanılmıştır. Sistemik olmayan hata %77 kadar iken serideki değişkenlik %77 ile tahmin edilebilmiştir.

Gençalp (2020), uygulama çalışmasında ATM nakit talep tahmini yapmıştır ve tahmin için Support Vector Regressor, K'th Nearest Neighbor Regressor, Random Forest

Regressor ve Gradient Boosting Regressor yapay zekâ algoritmaları kullanılmıştır. KNN algoritması 27% MAPE ve 92311 MAE ölçüm kriter değerleriyle en iyi sonucu vermiştir.

Güven (2020), çalışmasında yapay zekâ tekniklerinden yapay sinir ağları, destek vektör makineleri ve rastgele ormanlar modelleri ile bir perakende hazır giyim firmasının 2014 49. hafta ile 2018 52. haftaları arasında yaptığı satışları veri seti olarak kullanarak tahmin sonuçları elde edilmiştir. Performans kriterlerinden OKH, OMH, OMHY aracılığıyla ile gerçek değerler ile tahmin değerleri arasındaki farklar değerlendirilerek hangi yöntemin daha iyi sonuç verdiği belirlenmiştir. Yapay sinir ağları genel olarak daha uygun sonuçlar sağlamıştır.

Torun ve Deste (2021), yapmış olduğu çalışmada Samsun Devlet Hastanesi Ortopedi Bölümü'nde en çok ihtiyaç duyulan 9 çeşit sağlık malzemesine ait 2015-2018 yılları arasındaki verileri kullanarak tahmin sonuçları elde etmiştir. Uygulamada Minitab 18 istatistik programı programı yardımıyla MSE göz önünde bulundurularak MAE ve MAPE değerleri elde edilmiştir. Sonuç olarak Basit Lineer Regresyon Metodu ve Kümülatif Holt-Winters Metodu'nun en uygun tahmin metotları olduğu belirlenmiştir.

Yılmaz ve Tosun (2020), yapmış olduğu çalışmada Eviews programını kullanarak çok değişkenli regresyon analizi ile Antalya ilindeki konut taleplerinin tahminini elde etmiştir. Ayrıca Matlab programı ile de ileri beslemeli geri yayımlı yapay sinir ağları modelini kullanarak tahminler yaparak iki yöntemin sonuçlarını karşılaştırmıştır. Yapılan karşılaştırma sonucunda yapay sinir ağları modelindeki hata değerinin daha düşük olduğu gözlemlenmiştir.

Alkap (2019), çalışmasında bağımlı değişken olarak 2013-2018 arası aylık iplik satış miktarını almış ve bu satış miktarlarına etki edebilecek 7 bağımsız değişken kullanmıştır. Yöntem olarak yapay sinir ağları kullanılmış ve model Matlab programı kullanılarak oluşturulmuştur.

Atay ve ark. (2019), çalışmasında İstanbul Atatürk Havalimanı'nın yerine inşa edilen 3.İstanbul havalimanının gelecek yıllardaki yolcu, yük talebi ve iç hat filosunu planlayabilmek amacıyla Yapay Sinir Ağları (YSA) ve Adaptif Ağ Tabanlı Bulanık Mantık Çıkarım Sistemi (ANFIS) yöntemleri kullanılarak tahminler elde etmiştir. Tahmin verileri Türk İstatistik Kurumu'ndan alınmış olup, modellerin performans

karşılaştırması için Kare Kök Ortalama Hata (RMSE) ve Hata Kareleri Toplamı (SSE) ölçütleri kullanılmıştır.

Aydın ve Yazıcıoğlu (2019), çalışmasında bir süpermarketin kasap reyonu için Ocak 2017- Aralık 2018 dönemindeki haftalık satış verileri ile 2019 yılı için haftalık talep tahmini elde etmişlerdir. Çalışmada ARIMA ile yapay sinir ağları modelleri ile tahmin sonuçları MAE ve MAPE ölçütleriyle karşılaştırılmıştır. Karşılaştırma sonucunda yapay sinir ağları modelinin optimal sonucu verdiği gözlemlenmiştir.

Fanoodi ve ark. (2019), sağlık sistemindeki tedarik zinciri için sekiz farklı kan ürünü üzerinde talep tahmin çalışması yapmıştır. Tahmin modelleri yapay sinir ağları ve ARIMA ile oluşturulmuştur. İki yöntemin de iyi doğrulukta sonuç vermesine karşın yapay sinir ağları az bir farkla daha isabetli sonuçlar vermiştir. Model performansını değerlendirmede RMSE ölçütü kullanılmıştır.

Korkut (2019), ayakkabı sektöründe gerçekleştirdiği uygulamada bir ayakkabı firmasına ait geçmiş satış verilerini kullanarak gelecek yıl için tahminde bulunmuştur. Çalışmada sadece spor ayakkabı grubuna yönelik tahmin gerçekleştirmeyi hedeflemişlerdir. Uygulama için Matlab R2013a programı ve yapay sinir ağları yöntemi kullanılmıştır. Model 2013-2018 yılları arasındaki verilerle eğitilerek 2019 yılına ait tahmin sonuçları elde edilmiştir.

İmece (2019), uygulama çalışmasında Holt Winters, Ridge Regression, Random Forest ve XGboost yöntemleri ile tahmin modelleri oluşturulmuştur. Veri seti olarak 2016, 2017 ve 2018 yıllarındaki günlük satış değerleri kullanılmıştır. Modeller Python 3.7 yazılım programında Jupyter Notebook aracılığıyla elde edilmiştir.

Matino ve ark. (2019), yankı durumu sinir ağları (ESN) modeli ile yüksek fırın gazı talep tahmin çalışması yapmıştır. Çalışma sonucunda çelik imalat süreçlerinden çıkan bu gazın tahmini ESN modeliyle yüksek doğrulukta tahmin edilebilmiş ve yüksek fırın gazının optimum kullanımı için gerekli değerler elde edilmiştir.

Nasuhoğlu (2019), bir eczanedeki 2015-2018 yılları arasındaki gerçek satış verilerini kullanarak 100 adet ilacın tahminlerini yapmıştır. Bu kapsamda yapay sinir ağlarının yanı sıra zaman serileri analizinden hareketli ortalama, üssel düzeltme, ikili üssel düzeltme ve Holt-Winters yöntemleri kullanılmıştır. Gerçek değerler ile tahmin değerleri arasındaki hata değerleri MSE yöntemi kullanılarak hesaplanmıştır.

Uygulamaya ait ürünlerin çoğunluğunda yapay sinir ağları ile daha iyi sonuçlar elde edildiği gözlemlenmiştir.

Türk ve Kiani (2019), yapmış olduğu çalışmada 2007-2015 dönemine ait beyaz eşya satış verilerini kullanarak Türkiye'deki toplam beyaz eşya satışlarını yapay sinir ağları ve regresyon modelleriyle tahmin etmiştir. Yapay sinir ağları modeli ve regresyon analizi modelini MSE performans ölçütü ile karşılaştırarak en iyi sonucu veren modelin yapay sinir ağları olduğu belirlenmiştir.

Yüzük (2019), çalışmasında çoklu regresyon ve yapay sinir ağları modellerini kullanarak Türkiye enerji talep tahmini gerçekleştirmiştir. Modeller SPSS.23 ve Matlab2015 paket programları aracılığıyla kurulmuştur ve 2018 yılına ait tahmin değerleri elde edilmiştir.

Zorlutuna ve Bircan (2019), Zaman Serileri Analizi ve Yapay Sinir Ağları yöntemlerini kullanarak Türkiye genelindeki aylık turizm talebinin tahminlerini elde etmiştir. Zaman Serileri Analizi için E-Views 7 programı ile Otoregresif Hareketli Ortalama (ARMA) veya ARIMA modelleri oluşturulmuştur. Yapay Sinir Ağları modeli ise MATLAB 7.9.0(R2009b) programı kullanılarak geliştirilmiştir. Çok sayıda deneme ile optimum başarı hedeflenmiştir. Yöntemler karşılaştırıldığında yapay sinir ağlarının daha yüksek doğrulukta sonuçlar verdiği gözlemlenmiştir.

Calp (2019), yapmış olduğu çalışmada özel bir işletmedeki 2 yıllık (2016-2018) yemekhane verisini kullanarak günlük yemek talep tahminlerini elde etmiştir. Tahmin modeli ileri beslemeli geri yayımlı yapay sinir ağı yöntemiyle oluşturulmuştur. Deney sonuçları Regresyon değerleri, Ortalama Mutlak Hata Yüzdesi (OMHY-MAPE) ve Ortalama Karesel Hata (OKH-MSE) ölçütleriyle yorumlanmıştır. Bu ölçütlere göre yapılan değerlendirme ile modelin hata oranının düşük olduğu ve performansının yüksek olduğu sonucuna varılmıştır.

Merkuryeva ve ark. (2019), toptancıdan dağıtıcıya ilaç ürünlerinde örnek olay üzerinden talep tahmin çalışması yapmıştır. Modeller basit hareketli ortalama, lineer regresyon ve sembolik regresyon yöntemleriyle oluşturulmuştur. Bu yöntemler ortalama mutlak sapma (MAD) hata ölçüm kriteriyle karşılaştırılmıştır. En az hatayı veren yöntemin sembolik regresyon olduğu sonucuna varılmıştır.

Aydın (2017), bir giyim şirketindeki verileri kullanarak aritmetik ortalama, hareketli ortalama ve ağırlıklı hareketli ortalama yöntemleriyle talep tahmin sonuçları elde

etmiştir. Ayrıca çalışmasında nitel yöntemlerin yanında nicel yöntemlerden de yararlanılması gerektiği sonucuna varmıştır.

Efendigil ve Eminler (2017), adaptif sinirsel bulanık çıkarım sistemi (ANFIS), yapay sinir ağları ve regresyon analizi yöntemlerini kullandıkları çalışmada yolcu talep tahmini elde etmiştir. Çoklu regresyon analizi için SPSS programı kullanılmış, ANFIS ve yapay sinir ağları için ise Matlab yazılımı kullanılmıştır. Modellerin karşılaştırılması için RMSE kullanılmıştır ve buna göre en iyi sonuç yapay sinir ağları yöntemi ile elde edilmiştir.

Akdağ (2016), yapmış olduğu çalışmada Yapay Sinir Ağları, Winters'in Mevsimsel Üstel Düzeltme ve Box-Jenkins yöntemleriyle içme suyu talep tahmin değerleri elde etmiştir. Tahminler 2003-2013 yılları arasındaki aylık veriler kullanılarak analizler yapılmıştır ve yöntemlerle elde edilen sonuçlar OKH, OHKK, OMYH ölçütleri ile karşılaştırılmıştır. Yapılan karşılaştırmalar Yapay Sinir Ağları yönteminin daha doğru sonuçlar verdiğini göstermiştir.

Kılınç ve Aydın (2016), çalışmasında büyük ölçekli bir hazır giyim işletmesinden farklı beden numaralarına sahip 2007-2012 yılları arasında satılan giyim ürünlerine ait talep verilerini kullanarak her bir beden numarası için talep miktarını tahmin etmiştir. Çalışmada giyim sektöründeki değişkenlik sebebiyle hesaplanması pratik olan aritmetik ortalama, hareketli ortalama ve ağırlıklı hareketli ortalama yöntemleri tercih edilerek, tahmin değerleri elde edilmiştir.

Kochak ve Sharma (2015), bir üretici şirketten aldıkları 2011-2013 arasındaki üç yıllık yakıt filtresi verilerini kullanarak YSA metodu ile 2014 yılının 12 aylık tahminlerini elde etmiştir. En iyi eğitim metodunu bulma hedefiyle modeli farklı metodlarla eğitmişler, YSA ve eğitim yöntemlerini baz alarak işbirlikçi bir mekanizma geliştirmişlerdir.

Solak (2013), yapmış olduğu çalışmada 2012-2020 dönemi için Otoregresif Entegre Hareketli Ortalama (ARIMA) modeli ile Türkiye'nin toplam petrol talebi tahminlerini elde etmiştir. Analizler Eviews (5.1.) programında 42 yıllık veri seti kullanılarak elde edilmiştir. Farklı çalışmalarda bulunan değerler ile bu çalışmada elde ettikleri tahmin değerlerini karşılaştırmışlardır.

Karaatlı ve ark. (2012), 2007-2011 yılları arasındaki veriler ile YSA yöntemini kullanarak çalışmalarında yeni otomobil satış miktarlarının tahminini

gerçekleştirmiştir. Çalışmada reel kesim güven endeksi, gayri safi yurtiçi hasıla, yatırım harcamaları, tüketici güven endeksi, tüketim harcamaları ve dolar kuru kullanılmış olan bağımsız değişkenlerdir. MSE, RMSE ve MAPE performans ölçütleri kullanılarak değerlendirme yapılmıştır ve doğru tahminler yapıldığı sonucuna varılmıştır.

Ying ve Hanbin (2010), MATLAB programını kullanarak yapay sinir ağları metodu ile talep tahmin çalışması yapmıştır. Gerçek satış verileri kullanılarak kurulan YSA modelinde gerçek satış değerlerine çok yakın sonuçlar elde edilmiştir. Hata oranının %0,08-%3,10 arasında değiştiği gözlemlenmiştir.

Ghiassi ve Nangoy (2009), çalışmalarında lineer olmayan tahmin problemleri için dinamik bir yapay sinir ağları modeli geliştirmiştir. DAN2 yapay sinir ağları modeli veri bazlı, ileri beslemeli, çok katmanlı ve dinamik bir mimariye sahiptir. Çalışmada lineer olmayan regresyon, YSA ve DAN2 modeli MSE, MAD ve MAPE hata değerlendirme kriterleriyle karşılaştırılmıştır. Bu yöntemler arasında geliştirilen DAN2 modeli en iyi sonucu vermiştir.

Aksoy (2008), çalışmasında döviz kurları ve müşteri memnuniyet derecesi verilerini kullanarak bu verilerin satış üzerindeki etkilerini korelasyon analizi ile incelemiştir. Hareketli Ortalamalar, Ağırlıklı Hareketli Ortalamalar, Üssel Düzeltme, Regresyon ve Bulanık Kümeler yöntemleriyle modeller oluşturularak talep tahminleri gerçekleştirmiştir. Bu yöntemlerin doğruluklarını MAE, MAPE, MSE performans ölçütleriyle karşılaştırmıştır. Ayrıca bu çalışmada Kurumsal Kaynak Planlaması (KKP) sistemlerindeki çeşitli parametrelerin talep tahminleri için doğru sonuçlar elde etmede faydalı olacağı sonucuna ulaşılmıştır.

Co ve Boosarawongse (2007), çalışmalarında Thailand'ın pirinç ihracatının tahminlerini gerçekleştirmiştir. İstatistiksel ve YSA yöntemleriyle ayrı modeller kurarak bu yöntemleri karşılaştırmışlardır. Yapay sinir ağları, üssel düzeltme ve ARIMA modellerinin doğrulukları MAE, MSE, MAPE ve RMSE yöntemleri kullanılarak değerlendirilmiştir. Holt-Winters ve Box-Jenkins modelleri tatmin edici şekilde uyum sağlasa da değerlendirme aşamasında görülmeyen verileri tahmin etmede iyi performans göstermemiştir. Yapay sinir ağları ise dinamik, lineer olmayan trendi, mevsimsel etkileri ve bunlar arasındaki aralarındaki ilişkiyi iyi yakalayabilmiştir.

Yapılan tüm bu literatür arařtırmaları ile literatürdeki çalışmaların çoğunun enerji, petrol, saėlık, turizm ve ekonomi alanında yapılmıř olduėu görölmektedir. Bu sektörleri takiben yedek parça ve otomotiv sektörü gelmektedir. Genel olarak çelik sektöründe yapılan çalışmaların bu sektörlerde yapılan çalışmaların sayısı ile kıyaslandığında çok daha az olduėu gözlemlenmiřtir. Bu da çalışmanın çelik sektöründe gerçekleştirilmesini literatür anlamında önemli hale getirmektedir.





2. YÖNTEMLER

2.1. Talep Tahmin Kavramı

Tüketicilerin belirli bir zaman içinde satın alma konusunda isteklerinin ve imkanlarının olduğu ürün veya hizmetin miktarı talep olarak adlandırılmaktadır (Yanık, 2019). Talep tahmini ise geçmiş verileri kullanarak gelecekteki talep miktarını belirleme yöntemidir (Korkut, 2019). Planlamanın ana unsurlarından biri olan talep tahmini, belirli bir ürün ya da hizmetin ne kadar talebi olacağının öngörülmesini sağlayarak satış fırsatlarının değerlendirilmesinde ve stok maliyetlerinin azaltılmasında büyük bir önem taşır (Persson ve Wilhelmsson, 2018). Şirketlerin mevcut konumunu korumaları açısından işletmedeki görevli kişilerin risklere ve belirsizliklere karşı doğru kararlar alabilmeleri gereklidir. Güvenilir talep tahmini çalışmaları şirketlerin yüksek itibarlı işletmeler arasında yer almasına yardımcı olur (Korkut, 2019).

Çeşitli amaçlar için kullanılan tahmin yöntemleri kullanımına göre farklılık göstermektedir. Üretim planlama ve stok sistemi nedeniyle satış tahminlerine ihtiyaç duyulmaktadır. Talep tahmininde siparişin zamanının ve miktarının belirlenmesini sağlayan karar kuralları binlerce ürüne düzenli bir şekilde aylık veya haftalık periyotlarda uygulanır. Uygun maliyetlerde depolanabilecek toplam bilgi miktarını aşmamak için tahminde bulunmak için ihtiyaç duyulan bilgi sayısı da en düşük düzeyde tutulmasına özen gösterilmelidir (Winters, 1960).

Talep tahminleri çeşitli ölçütlere göre sınıflandırılmaktadır ancak en çok tercih edilen sınıflandırma kriteri zaman aralığıdır. Zaman aralığı ölçütüne göre yapılan sınıflandırma dörde ayrılmaktadır. Günlük ve haftalık bazda yapılan tahminler çok kısa süreli tahminler olarak adlandırılmaktadır. İş çizelgelerinin hazırlanması, sarf malzeme ve diğer ürünlerin stok kontrolü gibi amaçlar doğrultusunda icra edilen tahminlerdir. Kısa süreli tahminler ise 1 haftadan 6 aya kadar olan süreci kapsamaktadır. İşgücü kapasite gereksiniminin belirlenmesi, tedarik sürelerinin ve üretim miktarlarının belirlenmesi için yapılan tahminlerdir. 6 ay-5 yıl arasında yapılan tahminler orta süreli tahminler olarak adlandırılmaktadır. Uzun süreli alımların veya

tedarik zamanı belli olmayan ürün alımlarının ve mevsimsel dalgalanma bulunan ürünlerin stoklarının belirlenmesi amacıyla yapılmaktadır. Uzun süreli tahminler ise 5 yıldan daha uzun süreler için yapılan tahminlerdir. Tesislerin planlanması, tezgâh veya makina alımı gibi yatırım konularını belirlemek ve netleştirmek amacıyla yapılan tahminlerdir (Kobu, 2003).

2.2. Talep Tahmin İhtiyacı ve Önemi

İş yöneticilerinin ekonomideki ve piyasalardaki dalgalanmalara karşı mücadele etmek amacıyla ekonomik trendlerden faydalanarak hazırlanmalarına duyulan gereklilik sonucunda talep tahmini ihtiyacı ortaya çıkmaktadır. Piyasalardaki talebe yönelik öngörüler sayesinde yönetimler üretim kapasitelerini, malzeme stoklarını ve eleman ihtiyaçlarını belirleyebilirler. Bu sayede yapılan değerlendirmeler sonrasında kapasite ve stoklarını artırma ya da azaltma yoluna gidebilme imkanları olabilir. Ekonomik daralma ya da gerileme öngörülüyorsa minimum zarar doğrultusunda önlemler alınabilir. Aynı şekilde ekonomik iyileşme öngörülüyorsa yapılan tahminler sayesinde maksimum fayda ve kar sağlayabilmek adına hazır olma imkânı bulunabilmektedir (Yanık, 2019).

Tedarik zincirinde bir önceki adımın belirlenmesi için talep tahmini girdisi elde edilmesi önemlidir. Satış tahminleri verileri kullanılarak hammadde sipariş miktarı, lojistik ihtiyaçları ve lokasyonlara göre stok kapasiteleri belirlenir. Müşterilere zamanında reaksiyon verilebilmesi için stok düzeyinin belirlenmesi ve güvenlik stoklarının tutulması gerekmektedir. Bu doğrultuda yapılan tahminler ile risk en düşük seviyeye indirgenerek stok ve taşıma maliyetleri azaltılabilmektedir (Akbaş, 2022). Talep tahmini sayesinde hangi üründen ne kadar ve ne zaman üretileceği belirlenerek üretim planlama ve stok kontrolü sağlanmaktadır. Orta ve uzun vadede her bir ürün için gerçekleşecek satış miktarının belirlenmesi sayesinde yöneticiler daha doğru kararlar alabilmektedir. Muhtemel olan bir olay ile gerçekleşen bir olay arasında geçen zaman arttıkça yapılan tahminin önemi ve doğruluğu da artmaktadır. Üretim planlama ve stok kontrolünün yanı sıra finansal planlama için de talep tahmini önem arz etmektedir. Yapılan tahminler nakit ihtiyacının belirlenmesine ve bütçelerin etkin bir şekilde kullanılmasına yardımcı olmaktadır (Gül, 2021).

2.3. Talep Tahmin Aşamaları

Talep tahminine ait adımlar 5 aşamadan oluşmaktadır. Bu adımlar aşağıdaki gibi sıralanabilir:

- a. Talebi etkileyen faktörlerin belirlenmesi: Talep tahmini çalışmaları yapılmadan önce işletmenin içinde bulunduğu çevre, ekonomik ortam, üretmekte olduğu ürünler, hedefleri, rakiplerine karşı yer aldığı pozisyon, teknolojik ve sosyolojik gelişmeler, maliyetler, endüstrideki değişiklikler iyi bir şekilde tanımlanmalıdır (İmece, 2019).
- b. Verilerin elde edilmesi ve toplanması: Talebi etkileyen etmenler planlamanın temelini oluşturmaktadır. Verilerin seçimi ve toplanması bu etmenler gözetilerek yapılmalıdır. Veriler çoğunlukla istatistiklerden, geçmiş gerçek değerlerden ve hedef verilerden oluşmaktadır. Bu veriler iç kaynaklardaki veriler olabileceği gibi işletmenin tahmin araştırmalarından ve ekonomik verilerden de elde edilmektedir (İmece, 2019).
- c. Talep tahmin periyodunun belirlenmesi: Talep tahmininde elde edilen sonuçlar ve dönem arasında bir bağlantı bulunmaktadır. Günlük veya haftalık gibi kısa dönemli tahminlerin uzun zamanda yanıltıcı olabileceği bahsedilen ilişkiye örnek olarak verilebilir (İmece, 2019).
- d. Tahmin Yönteminin Seçilmesi: Talep tahmin yöntemlerinde nicel ve nitel yöntemler bulunmaktadır. Matematiksel verilere dayanan yöntemler nicel yöntemlerdir. Nitel yöntemler ise öznel olup kişisel değerlendirmelere ve duylara dayanır. En uygun olan talep tahmin yöntemi ise nicel ve nitel yöntemlerin birlikte kullanılarak gerçekleştirilmektedir. (Akbaş, 2022)
- e. Sonuçların Doğruluk Oranlarının İncelenmesi: Talep tahmin çalışması sonucunda ulaşılan sonuçların gerçekte olan sonuçlar ile karşılaştırılması sonucu yapılan tahminin doğruluk derecesi incelenmektedir. Gerçek sonuçlar ile tahminden elde edilen sonuçlar arasında güçlü bir ilişki olması ve sapmaların düşük olması hedeflenmektedir (Akbaş, 2022).

2.4. Nitel Tahmin Yöntemleri

Nitel yöntemler kişisel fikirlerden veya pazar araştırması gibi detaylardan yararlanılarak oluşturulan ve öznelliğe dayalı yöntemlerdir. Geçmiş dönemlere ait

gerekli parametrelerin sayısal verilerine ulaşamıyor ise nitel yöntemlere başvurulmasına ihtiyaç duyulmaktadır (Adalı, 2020).

2.4.1. Delphi yöntemi

Bu yöntemde amaç uzman görüşlerinin toplanıp tekrar düzenlenip tahminler üzerinde görüş birliği sağlanmasıdır. Uygulaması basit bir yöntem olarak bilinse de uygulamada yönlendiren kişinin yeni birçok fikri değerlendirmesi ve çeşitlilikleri ortak bir noktada bir araya getirmesi gerekmektedir. Doğru bir şekilde uygulanmamış bir Delphi çalışmasında doğruluktan uzak ve kesin olmayan sonuçlara ulaşılması olasıdır. Uygulama süreci anonim bir çerçevede buluşan bilirkişilerin ortak bir paydada uzlaşması esasına dayanmaktadır. İstatistiksel tahmin yöntemlerini oluşturmak için yeterli matematiksel verinin olmadığı durumlarda bu yöntem kullanılmaktadır. Bilirkişilere belirlenmiş bir eş güdümcü tarafından uzman topluluğu anonim kalacak şekilde konu ile ilgili sorular sorulur. Eş güdümcü aldığı cevaplar sonucunda istatistiksel analizler yaparken aynı zamanda çıkarımlarda bulunur. Eş güdümcü verilen cevaplardan vardığı sonuçlar ile özet bir raporu bilirkişilere bir sonraki aşamada kullanmaları için yönlendirir. Bilirkişiler bu aşamada verdikleri cevapları değiştirmeyi uygun görebilirler. Bilirkişiler uzlaşmaya varana kadar turlar sürer. Bilirkişilere ait öznel yargıların tümüne uygun bir sentez son turda yapılır ve grubun ortak görüşü olarak beyan edilir (Adalı, 2020).

2.4.2. Yönetici görüşleri esaslı tahmin

İşletmeye ait satış tahminleri işletmedeki üst yönetim aracılığıyla yapılmaktadır. Hazırlanmasının uzun sürmemesi, sayısal becerilere ihtiyaç duyulmaması, teknik destek gerektirmemesi gibi avantajlarına rağmen bu şekilde yapılan bir tahmin genel bir tahmini yansıtmamaktadır (Akbaş, 2022).

2.4.3. Anket yöntemiyle talep tahmini

Hedef müşteri kitlesine uygulanan anket yöntemi çoğunlukla yeni bir ürün ya da hizmet pazara çıkarılırken veya yenilik çalışmaları gibi değişiklik içeren durumlarda gerçekleşecek talebin tahmininin yapılması için kullanılan bir yöntemdir (Akbaş, 2022).

2.4.4. Kilit personel aracılığıyla tahmin

Kilit personelin kararının esas alındığı bu yöntemde satış ve pazarlama departmanında yer alan kişilerin tecrübeleri ile tahminler yapılır. Yapılan tahminler yöneticiler

tarafından yorumlanır ve ihtiyaç duyulursa gerekli deęişiklikler ile son karara ulařılır. Maliyetin dięer yöntemlere nazaran daha düşük olması ve sonuca hızlı ulařılması bu yöntemin avantajlarıdır (Heizer ve ark., 2006).

2.4.5. Satış ekibinin tahminleri

Satış departmanında bulunan personel tarafından belirlenmiş periyotlarda yapılmış olan tahminlerin toplanmasıyla oluşturulmuş çalışmalardır. Genel olarak satış ekipleri hem pazar deneyimleri hem de müşterilerle olan bağları sayesinde işletmelerdeki talep tahminini dięer bölümlerde çalışan ekiplere göre daha yüksek doğrulukta tahmin edebilmektedir. Satış ekibinde bulunan kişilerin karakteristik özellikleri insan doğası kaynaklı olarak farklılık göstermektedir. Bazıları iyimser olabilirken bazıları daha karamsar olabilmekte, bazıları risk almak isterken bazıları ise risk almaktan kaçınabilecek kişilik özelliğine sahip olabilmektedir. Talep tahmini çalışması yapılırken bu sebeplerden dolayı çelişkiler içeren bir tablonun meydana gelebileceęi de göz ardı edilmemelidir. Bu sebeplerden ötürü sonuçlar birlikte ekipçe defalarca kontrol edilmeli ve düzeltmeler yapılmalıdır (Adalı, 2020).

2.4.6. Pazar araştırması:

Bu yöntemde gelecekte gerçekleşmesi olası talep hakkında telefon yoluyla görüşülerek, mülakat yöntemiyle veya anketler düzenlenerek bilgi alınmaktadır. Alınan bilgiler yalnızca talep tahmininde deęil, aynı zamanda yeni tasarlanan veya geliştirilen ürünlerde de kullanılmaktadır. Tüketici ile doğrudan etkileşim kurulması ve ilgili kaynaktan bilgi toplanması bu yöntemin avantajlarıdır. Alınan bilgilerin çok güvenilir olmaması, yöntemin zaman alması ve maliyetin yüksek kalması yöntemin dezavantajlarındandır (Aydın, 2017).

2.4.7. Uzman görüşleri

Tahmin yapılacak konu üzerinde işletmedeki çeşitli bölümlerde idare ve yönetim kısmında bulunan uzmanların tecrübelerine, bilgi birikimine ve öngörülerine başvurularak gerçekleştirilen tahmin yöntemidir. Veriler kullanılarak analiz yapılmadığından zamandan kazanım elde edilir. Zaman kısıtının olduęu ve hızlı karar alınmasını gerektiren durumlarda tercih edilebilir. Uzman görüşlerini esas alan bu yöntem dięer yöntemlere göre uygulanması daha basit olduğundan avantajlı olmasına rağmen öznel yargılara dayalı olmasından dolayı doğru sonuçlara varma olasılığı dięer yöntemlere göre daha düşük kalabilmektedir (Akbaş, 2022).

2.5. Nicel Tahmin Yöntemleri

Geçmiş dönemlerdeki talep miktarına göre istatistiksel olarak tahmin yapılan yöntemler nicel yöntemlerdir. Talebin meydana gelmesinde tesiri bulunan etkenlerle talep miktarı arasındaki bağlantının gelecekte de süreceği ve aynı eğilimi göstereceği düşüncesini temel almaktadır. Veriler istatistiksel yöntemlerle incelenir ve bunların temelinde gelecekteki talep miktarları tahmin edilir. Nicel yöntemler zaman serileri analizi ve nedensel yöntemler olmak üzere iki kategoriye ayrılır. Geleceğe dair yapılan tahminler incelenen parametrelerin gözlemlenerek analiz edilmesi, veri setinin dinamiklerinin belirlenmesi ve bunların matematiksel bir fonksiyonunun belirlenmesini içeren adımlarla gerçekleştirilir (Akbaş,2022).

2.5.1. Son dönem talebi yöntemi

Son dönemdeki talebin değişmeyeceği varsayılarak bir sonraki dönemde de talebin aynı kalacağını öngören talep yöntemidir. Verilerin hep belirli bir ortalama yakınlarında kaldığı zaman serilerine bu yöntemin uygulanması uygun olacaktır. Aksi takdirde son dönem harici geçmiş dönem verileri dikkate alınmadığından sonuçlar son derece yanıltıcı olacaktır (Adalı, 2020).

2.5.2. Basit ortalama

Geçmiş dönemlere ait verilerin tamamı toplanır ve elde edilen değer dönem sayısına bölünür. Tüm dönemlerin dikkate alınarak tahminde bir ortalama sağlanması ve basit bir şekilde uygulanma imkânı olması yöntemin avantajlarıdır (Aydın, 2017). Basit ortalama ile talep tahmininde il aşamada Denklem 2.1 kullanılmaktadır.

$$F_{t+1} = \frac{1}{t} \sum_{i=1}^t Y_i \quad (2.1)$$

t = dönem sayısını, F_{t+1} = sonraki döneme ait tahmin değerini, Y_i = i dönemine ait gerçek talebi ifade etmektedir. Bir sonraki adımda aşağıdaki Denklem 2.2 ile devam edilir:

$$F_{t+2} = \frac{1}{t+1} \sum_{i=1}^{t+1} Y_i \quad (2.2)$$

2.5.3. Hareketli ortalama:

Hareketli ortalama yönteminde sadece son dönemlerdeki taleplerin ortalaması alındıktan sonra tahmin elde edilmeye çalışılır. En eski dönemdeki talep en yakın

olanla değiştirilir ve tekrar hesaplama yapılır. Böylece n dönemdeki yakın zaman talepleri kullanılarak ortalama iletilmektedir (Jain ve Malehorn, 2012). Hareketli ortalama yöntemine ait matematiksel ifade Denklem 2.3'te gösterilmiştir (Torun, 2021).

$$F_t = \frac{(D_t + D_{t-1} + D_{t-2} + \dots + D_{t-k+1})}{k} \quad (2.3)$$

F_t =t dönem için tahmin değerini, D_{t-1} =t-n dönem için gerçekleşen değeri, n ise hareketli ortalama alanan dönem sayısını ifade etmektedir.

2.5.4. Ağırlıklı hareketli ortalama

Ağırlıklı hareketli ortalama yönteminde her döneme bir ağırlık atanır. Geçmiş dönemlere daha az atılacak şekilde ağırlıklar dağıtıldığında toplamaları bire eşit olmalıdır. Hareketli ortalama yöntemindeki dezavantajlardan bir kısmı bu yöntem sayesinde ortadan kalkabilmektedir. İlgili ağırlık değerleri o döneme ait talep miktarı ile çarpılır ve çarpımlar toplanarak hesaplama elde edilir (Mentzer ve Moon, 2004). Ağırlıklı hareketli ortalama yönteminde talep Denklem 2.4 aracılığıyla elde edilmektedir.

$$F_{t+1} = w_1 D_1 + w_2 D_{t-1} + w_3 D_{t-2} \quad (2.4)$$

t dönem sayısını, değişkenlerden w_1, w_2, w_3 dönemlere atanan ağırlıkları, D ise talebi ifade etmektedir.

2.5.5. Basit üssel düzeltme yöntemi

Bu yöntemde de hareketli ortalama olduğu gibi ağırlıklar kullanılır. Ancak bu yöntemde üssel olarak artan veya azalan bir seri elde edilir. Seçilen ağırlık üssel düzeltme faktörü olarak adlandırılır ve α simgesi ile ifade edilir. En yeni veriye en büyük ağırlık atanırken en eski veriye en düşük ağırlık atanmış olur (Nasuhoğlu, 2019). Üssel düzeltme yönteminde kullanılan formül Denklem 2.5'te gösterilmiştir.

$$F_{t+1} = \alpha * Y_t + (1 - \alpha)F_t \quad (2.5)$$

F_{t+1} =t periyodu tahmini, F_t = Önceki dönemdeki tahmin değerini, Y_t = Önceki döneme ait gerçek talebi, α = Düzeltme faktörünü göstermektedir ($0 \leq \alpha \leq 1$).

2.5.6. Holt'un doğrusal yöntemi

Holt'un doğrusal yöntemi mevsimsel tesirlere rastlanılmayan ancak trendin var olduğu zaman serileri çalışmalarında uygulanmaktadır. Gerekli olduğu takdirde ilave olarak bazı işlemler ile mevsimsel etkenlerin de bulunduğu veriler için de yine bu yöntem aracılığıyla tahminler gerçekleştirilebilmektedir (Adalı, 2020). Holt'un doğrusal yönteminde yararlanılan matematiksel ifadeler Denklem 2.6, Denklem 2.7 ve Denklem 2.8'de gösterilmiştir.

$$L_t = \alpha Y_t + (1 - \alpha)L_{t-1} + T_{t-1} \quad (2.6)$$

$$F_{t+n} = L_t + nT_t \quad (2.7)$$

$$T_t = \beta(L_t - L_{t-1}) + (1 - \beta)T_{t-1} \quad (2.8)$$

L_t = t döneminde beklenen seviyeyi, α =seviyenin düzeltme katsayısını, Y_t =mevcut döneme ait gerçek değeri, T_t =t dönemindeki trend değerini, β =trendin düzeltme katsayısını, n =tahmin yapılacak dönem sayısını göstermektedir.

2.5.7. Holt-Winters yöntemi

Holt-Winters yönteminde hem trend hem de mevsimsel etkiler dikkate alınır ve serideki her bir parametre için ayrı bir denklem kullanılarak tahmin yapılır. Mevsimsel etkilerin gözlemlenmesi için en çok tercih edilen yöntem Holt-Winters yöntemlerinden toplamsal ve çarpımsal yöntemlerdir. Holt-Winters yönteminde kullanılan denklemlerde üç eşitlik bulunmaktadır. Birincide zaman serisindeki t dönemine ait seviyenin belirlenmesi hedeflenmektedir. İkinci eşitlikte trend anlaşılmasına çalışılırken sonuncuda mevsimsel değişkenin saptanması hedeflenmektedir (Adalı, 2020).

Zaman serisi yöntemleri ele alındığında Holt-Winters yöntemi en kompleks görünen yöntemler arasında yer alır. Veriler değerlendirilirken mevsimselliği ve trendi dahil etmesinden ötürü diğer yöntemlerle karşılaştırıldığında denklem sayısı daha fazladır. Temel, trend ve mevsimsellik olmak üzere üç farklı düzeltme denklemi bulunmaktadır (Aydın, 2017). Holt-Winters yönteminde talep tahmini Denklem 2.9, Denklem 2.10, Denklem 2.11 ve Denklem 2.12 yardımıyla bulunmaktadır (Özger vd., 2019).

$$S_t = \alpha * \left(\frac{Y_t}{I_{t-l}} \right) + (1 - \alpha) * (S_{t-1} + b_{t-1}) \quad (2.9)$$

$$b_t = \beta * (S_t - S_{t-1}) + (1 - \beta) * b_{t-1} \quad (2.10)$$

$$I_t = \gamma * \left(\frac{Y_t}{S_t} \right) + (1 - \gamma) * I_{t-l} \quad (2.11)$$

$$Y_{t+m} = (S_t + b_t * m) * I_{t-l+m} \quad (2.12)$$

Y_t = t dönemi sonunda gerçekleşen talebi, α = S_t için düzeltme katsayısını ($0 < \alpha < 1$), S_t = mevsimselliğe ait tahmini, β = trend tahmininde kullanılan düzeltme katsayısını ($0 < \beta < 1$), b_t =trend için yapılan tahmini, I_{t-l} = L dönem öncesindeki düzeltme uygulanmış mevsimsel göstergeyi, L =mevsimsellikteki döngü uzunluğunu, γ =mevsimsel tahmindeki düzeltme katsayısını, I_t =t dönem sonundaki düzeltme yapılmış mevsimsel göstergeyi, Y_{t+m} =m dönem sonrasında bulunan tahmin değerini ifade etmektedir.

2.5.8. Regresyon analizi

Bağımsız bileşen ile bağımlı bileşen arasındaki etkileşim ve bağlantının belirlendiği yöntem regresyon analizidir. Tahmin modelinde bağımlı değişkene etki eden bir bağımsız değişken varsa bu regresyona tek değişkenli regresyon analizi denmektedir. Bağımlı değişkene etki eden birden fazla bağımsız değişkenin olduğu regresyon modeline çok değişkenli regresyon analizi denmektedir (Korkut, 2019). Doğrusal regresyon modelinde kullanılan eşitlik Denklem 2.13'te verilmiştir.

$$Y = \alpha + \beta X_i + \varepsilon \quad (2.13)$$

Bu denklemde Y tahmin değeri iken X_i ise bağımsız değişkeni ifade etmektedir. α ve β sabitleri gerçek değerler ile tahmin değerlerinin incelenmesi sonucunda zaman serisine ait verilerden Denklem 2.14, Denklem 2.15, Denklem 2.16 ve Denklem 2.17 yardımıyla elde edilmektedir (Nasuhoğlu, 2019).

$$\beta = \frac{\sum_{i=1}^n X_i Y_i - n * \bar{X} \bar{Y}}{\sum_{i=1}^n X_i^2 - n * \bar{X}^2} \quad (2.14)$$

$$\alpha = \bar{Y} - \beta \bar{X} \quad (2.15)$$

$$\bar{X} = \frac{\sum_{i=1}^n X_i}{n} \quad (2.16)$$

$$\bar{Y} = \frac{\sum_{i=1}^n Y_i}{n} \quad (2.17)$$

2.5.9. Korelasyon analizi

İki ya da daha çok parametre arasında en çok kullanılan değerlendirme yöntemlerinden biridir. İki değişken arasında bir ilişkinin olup olmadığı veya ne derece bir ilişkinin olduğunu gösteren analiz yöntemidir. Korelasyon analizinde bir parametredeki artış veya azalış diğer parametrenin artışı, azalışı veya aynı kalması ile neticelenmektedir. Analiz ile nicelikler arasındaki bağlantının varlığı ya da yokluğu araştırılmaktadır. Korelasyon katsayısına göre ilişkinin varlığının yanı sıra yönü de belirlenmektedir. Pozitif ya da negatif olması yönünü belirlerken büyüklüğü de zayıf veya güçlü bağlantı olduğunu tanımlamaktadır. Analiz sonucunda -1 ve +1 değerleri arasında bir korelasyon katsayısı elde edilmektedir. Korelasyon katsayısının $r=0$ olduğu durumlarda ise parametreler arasında bir ilişkinin olmadığı kanısına varılmaktadır. Korelasyon için uygulanan formül Denklem 2.18’de gösterilmiştir (Dinç, 2021).

$$r = \frac{\sum xy - \frac{(\sum x)(\sum y)}{n}}{\sqrt{\left(\sum x^2 - \frac{(\sum x)^2}{n}\right) * \left(\sum y^2 - \frac{(\sum y)^2}{n}\right)}} \quad (2.18)$$

Korelasyon katsayısının aşağıdaki tabloda belirtilen değerlere yakınlığına göre değişkenlerin arasındaki ilişkinin yorumlaması Tablo 2.1 yardımıyla yapılabilmektedir (Rumsey, 2016).

Tablo 2.1. Korelasyon katsayılarının değerlendirilmesi.

Korelasyon Katsayısı	
Değerleri	Değerlendirme
-1	Çok güçlü bir negatif doğrusal ilişki
-0.7	Güçlü bir negatif doğrusal ilişki
-0.5	Orta derecede negatif bir ilişki
-0.3	Zayıf bir negatif doğrusal ilişki
0	Doğrusal ilişki yok
0.5	Orta derecede pozitif bir ilişki
0.7	Güçlü bir pozitif doğrusal ilişki
+1	Çok güçlü bir pozitif doğrusal ilişki

2.5.10. Otoregresif (AR) modeli

Çok parametrelili regresyondaki doğrusal belirleyici yerine AR modelde araştırması yapılan parametrenin geçmiş dönemdeki veri setinin doğrusal birleştirilmesi ile tahminler yapılmaktadır. Otomatik regresyon, değişkenin kendisi ile arasında yapılan regresyon ile gerçekleştirilmektedir. AR modeli için kullanılan ilgili formül Denklem 2.19’da verilmiştir (Adalı, 2020).

$$y_t = c + \varphi_1 y_{t-1} + \varphi_2 y_{t-2} + \dots + \varphi_p y_{t-p} + \varepsilon_t \quad (2.19)$$

$c=y_t$ ’nin ortalamasını, $\varphi_{1,2,3\dots n}$ =otomatik regresyon değişkenlerini, ε_t =ortalama değeri sıfır ve sabit varyansı olan otokorelasyonu olmayan rassal değişkeni göstermektedir.

2.5.11. Hareketli ortalama (MA) modeli

Bu yöntemde model anlık değer geçmişi hatanın ve mevcut hatanın doğrusal birleşiminden meydana geldiğini ifade eder. MA modelinde kullanılan birinci matematiksel ifade Denklem 2.20’de gösterilmiştir (Kapkın, 2018).

$$y_t = \mu + \varepsilon_t + \theta_1 \varepsilon_{t-1} \quad (2.20)$$

μ =doğrunun y eksenini kestiği noktayı, ε_t =anlık hatayı, $\theta_1=1$ ile $+1$ arasında değer alan MA katsayısını göstermektedir.

2.5.12. Otoregresif hareketli ortalama (ARMA) modeli

Otoregresif ve hareketli ortalama yöntemlerinin birleşimi olan ARMA modeli, geçmiş değerlerin ve geçmiş hataların doğrusal fonksiyonu ile ifade edilmektedir. Tahmin modeli t zamanında yapılan tahminin p kadar önceki gözlemlenen değer ve q kadar önceki dönemde bulunan hata değerinin bir araya gelmesiyle oluşmaktadır. ARMA modellerinde kullanılan formül Denklem 2.21’de gösterilmiştir (Korkut, 2019).

$$Y_t = \mu + \Phi_1 Y_{t-1} + \dots + \Phi_p Y_{t-p} + \varepsilon_t - \Theta_1 \varepsilon_{t-1} - \dots - \Theta_q \varepsilon_{t-q} \quad (2.21)$$

$\Phi_p = p$ kadar bağımlılık değişkenini, $\Theta_q = q$ kadar hata değişkenini ifade etmektedir.

2.5.13. ARIMA modeli

ARIMA modelinde p değişkeni verilerin zaman serisinde birbirleriyle olan yakınlığına göre ilişkilerini ifade etmektedir. Modelde bulunan d değişkeni ise zaman serisini daha durağan hale getirmek için gereklidir. Zaman serisindeki çok yüksek çıkış veya düşüşler ise q değişkeni sayesinde tanımlanmaktadır. Sabit bir ortalaması ve varyansı bulunan veri durağan olabilmektedir. Eğer durağanlık mevcut değil ise d değişkeni ile durağan şekle gelebilmektedir. Bir dizi fark denklemi uygulanmaktadır. Farkı veren ifade Denklem 2.22’de gösterilmiştir (Adalı, 2020).

$$\Delta Y_t = Z_t = Y_t - Y_{t-1} \quad (2.22)$$

Δ =fark operatörünü, Z_t =t anındaki tahmin değerini ifade etmektedir. Z_t durağan bir seri meydana getiriyorsa d değişkeni 1 olarak kabul edilir, eğer değilse fark işlemi Denklem 2.23 ve Denklem 2.24 ile bir kere daha uygulanır.

$$\Delta^2 Y_t = W_t = Z_t - Z_{t-1} \quad (2.23)$$


$$\Delta^2 Y_t = W_t = (Y_t - Y_{t-1}) - (Y_{t-1} - Y_{t-2}) \quad (2.24)$$

2.5.14. Yapay sinir ağları

2.5.14.1. Yapay sinir ağlarının tanımı

Yapay sinir ağları sayesinde insan beynindeki sinir ağları örnek alınarak geleneksel metotlarla yapılamayan taklit ile öğrenme, anımsama yeni bilgilerin meydana

getirilmesi gibi eylemler oluşturulabilmektedir (Güven, 2020). Yapay sinir ağları yoğun bir şekilde birbirine bağlı yapılar ile eldeki verilerin işlendiği sistemler olarak tanımlanabilir. Eğitim aşamasında önceki olayların örneklerine bakıp genelleştirme yaparak bilgi edindikten sonra test aşamasında hiç deneyimlemediği ya da ilerde meydana gelmesi olası bir tahmin gerçekleştirir (Gökler, 2020). Yapay sinir ağlarına ait yapı Şekil 2.1’de gösterilmiştir.



Şekil 2.1. Yapay sinir ağları yapı modeli (Gökler, 2020).

Birçok sinir hücresinin birleşmesiyle yapay sinir ağları oluşur. Sinir hücresi yapay sinir ağlarında işlem yapan en küçük birimdir. Sonuç ise bir araya gelen birçok sinir hücresinin ortak sonucu olarak elde edilmektedir. Yapay sinir ağları hücrelerin birbirine bağlanmasıyla oluşur ve hücreler arasında bulunan bağlantılar ağırlıklar ile meydana getirilmektedir. Yapay sinir hücreleri arasındaki bağıntının kuvveti ağırlıklar belirlemektedir. Ağırlıklar pozitif ve negatif değerler alabileceği gibi sabit veya değişken de olabilmektedir. Yapay sinir ağının kurulabilmesi için en az birer adet giriş katmanı, gizli katman ve çıkış katmanı bulunmalıdır. Gizli katmanlar girişteki verilerin yorumlanması ve çıkışa iletilmesinde görev alır. Gizli katmanlarda işlem gören giriş verileri çıktı katmanına aktarılmaktadır. Şekilde de görülebileceği üzere bir yapay sinir ağı modelinde n adet girdi katmanı ve n adet çıkış katmanı olabilir (Güven, 2020).

2.5.14.2. Yapay sinir ağlarının avantajları ve dezavantajları

Geleneksel yöntemlerle çözülemeyen problemlerin çözümünde yapay sinir ağları birçok avantaja sahiptir. Sahip olduğu bu avantajlar sayesinde geleneksel yöntemlerle çözülemeyen problemlerin çözümüne gidilmektedir. Göz önünde bulunmayan ya da

fark edilemeyen etkenler arasında ilişki kurabilir ve bu sayede probleme özgü bir çözüm üretilmiş olur. Giriş verilerinde bulunan eksikliklere rağmen çözüm üretebilmesi ve kendi kendine öğrenme yetisinin bulunması yapay sinir ağlarının tercih edilme nedenleri arasındadır. Yapay sinir ağlarının avantajları şu şekilde sıralanabilir (Güven, 2020):

- a. Giriş veri setinde bulunan eksileri eğitim veri setinden edindiği veriler ile benzeştirir ve tamamlayabilir.
- b. Geleneksel yöntemlerle karşılaştırıldığında problemleri daha hızlı çözme yeteneği vardır.
- c. Veri değişikliği durumunda ya da diğer etkenler ile sinir hücreleri arasındaki bağlantı ağırlıklarını artırıp azaltabilir.
- d. Lineer bir yapıya sahip olmadıklarından gerçek problemlerde daha etkin uygulanabilmektedir.
- e. Sınıflandırma, kümeleme genelleme gibi çeşitli alanlarda iyi sonuçlar sağlamaktadır.
- f. Yapay sinir ağının bir bölümünde oluşan bozulmanın ve hataların sonucunda ağın bütünü etkilenmez ve model çalışmaya devam edebilir.
- g. Yapay sinir ağları birlikte ve aynı zamanda çalışabilen yapay sinir hücrelerinden meydana gelir.

Yapay sinir ağlarının birçok avantajı bulunmasına karşın bazı dezavantajları da bulunmaktadır. Bunlar aşağıdaki gibi sıralanabilir (Güven, 2020):


- a. Yapay sinir ağlarının başlangıç aşamasında model oluşumu için belirli bir yöntem olmamasından dolayı denemeler ile model oluşturulmaktadır. Çeşitli algoritmalara, bağımlı ve bağımsız değişkenlere ve farklı ağ yapılarına sahip olan yapay sinir ağlarında doğru model seçilemediğinde başarı oranı düşüktür.
- b. Problemin yapısı veya eğitim verilerinde bulunan eksikliklerden ötürü uygun bir çözüme gidilemeyebilir.
- c. Modelde bulunan gizli katmanlar nedeniyle model kapalı kutu gibi çalışmaktadır ve çözüme ilişkin net bir sağlamazlar. Bu sebeple açıklanamazlar.
- d. Paralel yapılarından dolayı güç tüketimi ihtiyaçları yüksektir ve iyi bir donanım gereksinimi ortaya çıkmaktadır.

- e. Yapay sinir ağlarında eğitimin çok önemli olduğu bilinmektedir ancak modelin ne kadar eğitime gereksinim duyduğu belirsizdir. Karmaşık veriler ve yüksek sayıda veri ile modelin öğrenmesi yavaşlayabilir.

2.5.14.3. Yapay sinir hücreleri

Yapay sinir hücrelerinin yapısını anlamak için öncelikle biyolojik sinir hücresinin yapısını ve işleyişini anlamak önem taşımaktadır. Biyolojik sinir ağları birçok biyolojik sinir hücresinin belirli fonksiyonları yerine getirmek için birleşmesiyle meydana gelmektedir. Bu sayede biyolojik sinir ağları karmaşık olayların çözümünü yapabilecek yeteneğe sahip olmaktadır. Bu şekilde bir çözüm yapabilme yeteneğinin bilgisayara kazandırılması yapay sinir ağları ile hedeflenmektedir (Nasuhoğlu, 2019).

Biyolojik sinir ağlarının yapı birimleri nöronlardır. Bilginin iletilmesinde nöronların yapılarında bulunan dentritler, hücre gövdesi, akson ve akson uçları görev almaktadır. Dentritler aracılığıyla çevreden toplanan veri hücre gövdesinde bilgiye dönüştürüldükten sonra akson üzerinden akson uçlarına geçerek diğer nöron hücrelerine iletilir (Kapkın, 2018). Şekil 2.2’de biyolojik sinir hücresinin yapısı gösterilmektedir.




Şekil 2.2. Yapay sinir ağları hücresi (Gollo, 2008).

2.5.14.4. Yapay sinir hücrelerinin temel bileşenleri

Yapay sinir hücresinde de biyolojik sinir hücresine benzer bir yapı bulunmaktadır. Elde bulunan veriler yapay sinir ağlarında girdiler olarak adlandırılmaktadır. Girdiler değerleri 0-1 arasında değişen rastgele atanmış sayılarla çarpılır. Elde edilen bu veriler toplama fonksiyonu ile işlendikten sonra bu aşamada aktivasyon fonksiyonunun girdileri olmaktadır. Aktivasyon fonksiyonu aracılığıyla işlenen veriler ise çıktıya

dönüşmektedir (Kapkın, 2018). Şekil 2.3'te yapay sinir hücresinin bileşenleri gösterilmektedir.



Şekil 2.3. Yapay sinir hücresi temel bileşenleri (Çuhadar, 2009).

Girdiler örnek verilerden, başka yapay sinir hücresinden veya kendi hücresinden dışarıdan giriş yapan verilerdir (Nasuhoğlu, 2019).

Ağırlıklar YSA'daki girdilerin etki katsayısıdır. Tüm girdilere karşılık gelen ağırlık değerleri vardır. Girdilerin sahip olduğu bu ağırlık değerleri önemlerinden bağımsızdır (Nasuhoğlu, 2019).

Toplama fonksiyonları bir yapay sinir hücresindeki net girdilerin hesaplanmasını sağlayan çeşitli fonksiyonlardır. Ağırlıklı toplam genelde tercih edilendir. Bu fonksiyonda girdiler ağırlıklarla çarpılıp toplanır. Çarpım fonksiyonunda ağırlık değerleri ile girdiler çarpıldıktan sonra elde edilen değerler birbiriyle çapılarak net girdiye ulaşılır. Maksimum fonksiyonunda girdiler ağırlıklarla çarpıldıktan sonra aralarından en büyük olan değer net girdi olarak seçilir. Maksimum fonksiyonunda girdiler ağırlıklarla çarpıldıktan sonra aralarından en küçük olan değer net girdi olarak seçilir. Çoğunluk fonksiyonunda ağırlıklar ile girdiler çarpıldıktan sonra pozitif ve negatiflerin sayısı belirlenir. Sonrasında sayılardan büyük olanı net girdi olarak seçilir. Kümülatif toplam fonksiyonunda ise ağırlıklı olarak toplanan bilgiler önceki bilgilere eklenerek net girdi elde edilir (Nasuhoğlu, 2019).

Aktivasyon fonksiyonu toplama fonksiyonu ile elde edilen net girdinin işlenerek çıktıya dönüşmesini sağlayan fonksiyondur. Toplama fonksiyonunda olduğu gibi

çeşitli fonksiyonlar kullanılmaktadır (Güven, 2020). Tablo 2.1’de yapay sinir hücrelerinde kullanılan aktivasyon fonksiyonları yer almaktadır.

Tablo 2.2. Aktivasyon fonksiyonları ve formülleri (Korkut, 2019).

Fonksiyon Adı	Fonksiyonun Formülü	Açıklama
Lineer Fonksiyon	$F(Net) = \alpha * Net$	Bu fonksiyonda girdiler hücrenin çıktısıdır.
Sigmoid Fonksiyonu	$F(Net) = \frac{1}{1 + e^{-Net}}$	En sık kullanılan fonksiyonlardan biridir. Girdi değerleriyle 0 ile 1 arasında değerler üretir.
Tanjant Hiperbolik Fonksiyonu	$F(Net) = \frac{(e^{Net} + e^{-Net})}{(e^{Net} - e^{-Net})}$	Sigmoid fonksiyonuna benzemekle birlikte çıktı değerleri -1 ile 1 arasında değişmektedir.
Eşik Değer Fonksiyonu	$F(Net) = \begin{cases} 0 & \text{eğer } Net \leq 0 \\ Net & \text{eğer } 0 < Net < 1 \\ 1 & \text{eğer } Net \geq 1 \end{cases}$	Girdi değerlerinin bulunduğu aralığa göre çıktı 0, kendisi veya 1 değerini almaktadır.
Sinüs Fonksiyonu	$F(Net) = \sin(Net)$	Öğrenilecek verilerin sinüs eğrisine uyumlu dağılıma sahip olduğu durumlarda tercih edilir.
Step Fonksiyonu	$F(Net) = \begin{cases} 1 & \text{eğer } Net > \text{eşik değer} \\ 0 & \text{eğer } Net < \text{eşik değer} \end{cases}$	Belirli eşik değerinin altında ya da üstünde kalan girdi değerine göre 0 ya da 1 değerini alır.


Çıktı ise aktivasyon fonksiyonundan çıkan değerdir. Diğer yapay sinir hücresine girdi olabileceği gibi dışarıya da gönderilebilmektedir. Birden çok girdiye karşılık tek bir çıktı değeri bulunmaktadır. Birden çok çıktı değerlerinin elde edildiği durumlarda ise çıktılar tek bir çıktı değerinde toplanmaktadır. Çıktı değerleri yapay sinir ağı yöntemiyle oluşturulan talep tahmin modellerinde istenilen sonucu sağlamaktadır. Bu sonuçlar ile hedeflenen talep tahmin performansları değerlendirilebilmektedir. (Nasuhoğlu, 2019).

2.5.14.5. Yapay sinir ağlarının mimari yapılarına göre sınıflandırılması

Yapay sinir ağları ileri ve geri beslemeli olmak üzere mimari olarak iki ayrı sınıfta incelenmektedir.

İleri beslemeli yapay sinir ağlarında hücreler katmanlar şeklinde yer alır. İlk katmandaki çıktı diğer katmanda girdi değeri olmaktadır. Bu modelde veriler döngüye neden olmamaktadır. İleri beslemeli yapıda nöronlar girişten başlayıp çıkış yönüne doğru ilerlemektedir. Katmanlarda bulunan nöronlar yalnızca bir sonraki katman ile bağlantıda olmaktadır. Nörona ulaşan bilgi giriş katmanından başlayarak sırasıyla gizli katmanlara ve çıkış katmanına geçmektedir (Korkut, 2019).

İleri beslemeli yapıya ait yapı aşağıdaki şekilde gösterilmiştir.




Şekil 2.4. İleri beslemeli sinir ağı yapısı (Yüksek, 2007).

Geri beslemeli yapay sinir ağlarında bir yapay sinir hücresine ait olan çıkış kendisinin veya başka bir yapay sinir hücresinin girişidir. Geri besleme için geciktirme ara elemanları aracı görevi üstlenmektedir. Geri besleme aynı katmanda veya katmanlar arasında gerçekleşmektedir (Güven, 2020).

Geri besleme süreci yayılma ve uyum sağlama olmak üzere iki dereceden meydana gelmektedir. Geri yayılımdaki temel hedef istenen çıktı ile yapay sinir ağı aracılığı ile ulaşılan sonuç arasındaki hata değerini bulup, bu değeri girdi olarak kullanmak suretiyle düzeltme işlemi uygulamaktır. Böylece hata değeri minimize edilerek daha kabul edilebilir seviyeye çekilmektedir. Veri bilgisi ağda girişten çıkışa doğru ilerlerken hata düzeltme ise çıkıştan girişe doğru ilerlemektedir. Geri yayılım algoritması sayesinde iletilen hata bilgisi aracılığıyla ağırlıklar değiştirilerek hata en düşük seviyelere çekilmeye çalışılır ve böylece öğrenme prosesi gerçekleşir. Başta rastgele atanan ağırlıklar ile çıktı değeri elde edilir. Sonrasında ise çıktı değerindeki

hata hesaplanarak ağırlıklar tekrar belirlenir ve yeni çıktı değerleri elde edilir (Güven, 2020). Geri beslemeli yapıya ait yapı Şekil 2.5'te gösterilmiştir.




Şekil 2.5. Geri beslemeli sinir ağı yapısı.

2.5.14.6. Yapay sinir ağlarında öğrenme yöntemleri:


Yapay sinir ağları öğrenme yöntemlerine göre danışmanlı, danışmansız ve destekleyici olmak üzere üç ayrı sınıfta incelenmektedir.

Danışmanlı öğrenmede girdiler ve istenen çıktı değerleri belirtilir. Bu öğrenme tipinde istenen çıktı değeri ile hesaplanan çıktı karşılaştırılarak hata değeri elde edilir. Bulunan hata bilgilerine ile yapay sinir ağındaki ağırlıklar yeniden belirlenmiş olur. Hata değeri istenen sınırın altında kaldığında ağırlıkların güncellenme döngüsü sona erer. Yeterli sayıda eğitim verisi ile istenen doğrulukta sonuçlar elde edilmektedir. Bu yöntem kullanılarak bir probleme çözüm bulunduğunda benzer problemlerin sonucuna da ulaşılabilir (Güven, 2020). Danışmanlı öğrenme yöntemi Şekil 2.6'da gösterilmiştir.




Şekil 2.6. Danışmanlı öğrenme süreci ve aşamaları (Korkut, 2019).

Danışmansız öğrenme yöntemi aynı zamanda kendi kendine öğrenme şeklinde de adlandırılmaktadır. Danışmansız öğrenme yönteminde yalnızca giriş değerleri kullanılarak değişkenler arasındaki ilişkiyi yapay sinir ağının kendi kendine bulması hedeflenmektedir (Korkut, 2019). Danışmansız öğrenme yöntemi Şekil 2.7’de gösterilmiştir.



Şekil 2.7. Danışmansız öğrenme süreci ve aşamaları (Korkut, 2019).

Destekleyici öğrenme yöntemi danışmanlı öğrenmeye benzemektedir. Ancak istenilen çıktıların ağa tanıtılması yerine girdilerle birlikte ağın çıktısının doğruluğu kritik işaret öğreticisi aracılığıyla bildirilmektedir. Bu bildiriye göre yapay sinir ağında ağırlıklar güncellenir ve öğrenme döngüsü devam eder (Alkap, 2019). Destekli öğrenmeye ait yapı Şekil 2.8’de gösterilmiştir.



Şekil 2.8. Destekli öğrenme süreci ve aşamaları (Tozkan ve Balık, 2004).


2.5.14.7. Yapay sinir ağlarında öğrenme kuralları

Hebb öğrenme kuralı olarak bilinen kural Donald Hebb tarafından 1949’da bulunmuştur. Kendisinden sonra gelen öğrenme kurallarının temelini oluşturan bu kural en eski öğrenme kuralıdır. Sinyal alan ve veren nöronlar arasında bulunan

ağırlıklar aynı matematiksel işareti taşıyorsa bağ güçlendirilmeli, aksi takdirde bağ kuvveti düşürülmelidir. Hopfield öğrenme kuralı ise Hebb kuralına benzetmekle birlikte hücre bağlantılarının ne kadar güçlendirilmesi veya zayıflaması gerektiğini belirtir. Girdi ve çıktı arasındaki tutarlılık oranına göre ağırlık değiştirilir. 0-1 arasında değişen öğrenme katsayısını kullanıcı tayin etmektedir. Bir diğer kural olan Delta öğrenme kuralını ise Widrow ve Hoff geliştirmiştir. Ağda üretilen çıktı ile gerçekteki çıktı arasındaki farkın ağırlıkların sürekli güncellenerek azaltılması yöntemi ile çalışmaktadır. Kohonen öğrenme kuralında ise hücreler birbiriyle yarışarak ağırlıklarını günceller kazananlar diğer hücelere göre daha kuvvetli olmaktadır (Yanık, 2019).

2.5.15. Karar ağaçları ve rastgele ormanlar

Karar ağaçları açıklayıcı değişkenleri kullanarak bağımlı bir değişkenin tahminini yapmaktadır. Verinin nasıl kategorize edileceğini belirleyen bir dizi karar verme kuralları ile tahminler şekillenmektedir. Karar verme parametreleri artırıldıkça kedilerin köpeklerden ayırt edilebilmesi gibi sınıflandırma problemlerinin çözümünde veya regresyon çözümlerinde karar ağaçları etkili olmaktadır. Karar ağaçları kök, dallar ve yapraklardan oluşmaktadır. Kök veriyi en iyi ayıran veridir ve başlangıç düğüm noktasıdır. Kökten sonra genelde iki dala ayrılma olur ve bu dallar da kendi içlerinde başka dallara ayrılabilir. Tüm bu ayrılmış dallar yaprak adı verilen terminal düğümlerde son bulmaktadır. Yaprak düğümlerindeki değerler çıktıyı temsil etmektedir. Tahminleri birleştirmenin doğruluğu artırdığı bilinmektedir. Bahsedilen bu birleştirme yöntemi karar ağaçlarına “torbalama (bagging)” veya “önyükleme (bootstrap)” olarak adlandırılan tekniklerle uygulanabilmektedir. Böylece orjinal veri setinden rastgele örnekler alınarak orjinal olanla aynı büyüklükte yeni veri setleri oluşturulmaktadır. Her karar ağacı oluşturulan bu veri setleriyle eğitilebilmektedir ve her ağacın farklı bilgilere erişimi bulunmaktadır. Bu sayede tahmin modeli tek bir karar ağacından meydana gelebilecek aşırı uçlardaki verilere karşı daha az hassas olmakta ve tekil ağaçların sapmalarını nötralize etmek mümkün hale gelmektedir. Genel olarak bu yöntemi kullanan algoritma rastgele orman olarak adlandırılmaktadır (Spiliotis, 2022).



Şekil 2.9. Karar ormanı örnek mimarisi (Chakure, 2019).

2.6. Nitelik Seçimi Yöntemleri

2.6.1. Parçacık sürüsü optimizasyonu algoritması

Bir sosyal psikolog olan Kennedy ve bir elektrik mühendisi olan Ebenhart sosyal etkileşimlerdeki basit benzerlikleri açığa çıkartarak sayısal bir zekâ üretmeyi hedeflemişlerdir. Bu şekilde bireysel bilişsel yeteneklere odaklanmak yerine sosyal etkileşimlere odaklanmış oldular ve parçacık sürüsünün ilk fikirleri ortaya çıkmış oldu. İlk simülasyonlarda Heppner ve Grenander'in yapmış olduğu mısır arayan kuş sürüleri çalışmasındaki benzerliklerden yararlanmışlardır. Sonrasında ise bu modelin geliştirilmesi ile Parçacık Sürüsü Optimizasyonu ortaya çıkmıştır. Parçacık sürüsü optimizasyonunda belirli sayıdaki parçacık bir fonksiyon ya da problemdeki arama boşluğuna yerleştirilir ve her bir parçacık amaç fonksiyonunu kendi bulunduğu konumda değerlendirir. Her bir parçacık sürüdeki bir veya daha fazla üye ile birlikte geçmiş en uygun konumlarını birleştirerek boşluktaki hareketlerini belirler. Tüm parçacıkların hareketi tamamlanınca bir sonraki iterasyon başlar. Nihayetinde yiyeceğe yönelmekte olan bir kuş sürüsünde olduğu gibi sürü optimum uygunluk fonksiyonuna yakın hareket etmeye başlar (Poli ve ark., 2007).

2.6.2. Harris şahinleri optimizasyonu algoritması

Louis Lefebvre 1997 yılında beslenme davranışlarına bakarak kuş IQ'sunu ölçmek için bir yaklaşım önerisinde bulunmuştur. Zeki olması dolayısıyla şahinler üzerinde durulmuş ve şahinler arasında Harris Şahini türünün avlanırken aile üyeleriyle birlikte hareket etmesi sebebiyle Harris Şahini seçilmiştir. Bu tür diğer yırtıcı türlerin yalnız avlanma yöntemlerinin aksine takım üyeleriyle kooperatif olarak iz sürme, çembere alma gibi çeşitli inovatif yöntemler kullanarak zekice avlanmaktadır. En bilindik taktikleri “yedi öldürme” stratejisi olarak da bilinen sürpriz atılım şeklindedir. Liderin o anda başarısız olması halinde bir başka takım üyesi görevi devralır ve kovalamaca böylece devam eder. Avlamakta oldukları tavşan bu sayede yorulur ve daha savunmasız kalır. Son olarak yorulmuş tavşanı genelde tecrübeli bir üye yakalar ve takım üyeleriyle paylaşır. Harris Şahinleri Optimizasyonu bu keşfetme ve açığa çıkarma taktiklerinden esinlenerek elde edilmiş fazlardan oluşan topluluk tabanlı degradesiz bir tekniktir. Keşif fazında takım üyeleri rastgele konumlara geçerler iki farklı strateji ile keşif aşamasını gerçekleştirebilirler. Açığa çıkarma fazında ise avların kaçış eğilimlerinden kaynaklı olarak dört farklı kovalama stratejisi önerilmiştir. Avın kaçışının başarılı ya da başarısız olması durumuna göre sert ya da yumuşak kuşatma stratejisi belirlenmektedir. Avın kalan enerjisi de göz önünde bulundurularak yumuşak ya da sert kuşatma döngüleri devam eder ve avın yorgun düşmesi ile hedefe ulaşılır (Heidari ve ark., 2019).

2.6.3. Gri kurt optimizasyonu algoritması

Gri Kurt Algoritması Mirialili tarafından 2014 yılında kurt sürülerinin avlarını yakalama süreçlerinin canlandırmasını yansıtacak şekilde sunulmuştur. Bu süreçler avlarını takip etme, çevreleme ve ava saldırma aşamalarını içermektedir. Algoritma nispeten az kontrol parametreleri içermektedir ve uygulaması kolaydır. Gri kurt sürülerindeki sosyal hiyerarşiyi yansıtacak şekilde uygunluk değerini elde etmek amacıyla bir çözüm, alt çözüm ve de üçüncü bir çözüm olacak bulunmaktadır. Algoritmada bu çözümler sırasıyla alfa, beta ve delta olarak adlandırılmaktadır (Zeng ve ark., 2022).

2.6.4. Yusufçuk optimizasyonu algoritması

Yusufçuk optimizasyonu, yusufçukların eşsiz avlanma ve göç etme davranışlarından esinlenerek oluşturulmuştur. Avlanan sürü davranışı diğer bilinen adıyla statik sürü davranışı, küçük sürü gruplarının ani adım değişiklikleri ve yerel hareketleriyle

tanımlanmaktadır. Göçsel sürü davranışı ise aynı zamanda dinamik sürü olarak bilinmektedir ve tek bir yönde giden yüksek sayıdaki yusufçuğu ifade eder. Statik ve dinamik kavramları Yusufçuk Algoritması'nın açığa çıkarma ve keşif kapasitelerini belirtmektedir. Ayrışma, dizilme, birlikte durma, dikkat dağıtma ve yiyeceğe çekim gibi ögeler içeren davranış tanımlanmaktadır. Her bir yusufçuk arama boşluğundaki bir çözüme karşılık gelir ve bu beş farklı öge ile sürü hareketi belirlenir (KS ve Murugan, 2017).

2.6.5. Genetik optimizasyonu algoritması

Son yıllarda doğal biyolojik süreçlerin matematiksel çözümlerde kullanılmak üzere mühendislik analizlerine ve algoritmaların tasarımına adapte edilmesine duyulan ilgi artmıştır. Genetik optimizasyon algoritmaları doğal biyolojik süreçlerin adapte edilmesi ile elde edilen hesaplama yöntemlerden biridir. Genetik optimizasyonu çoklu çözüm vektörlerini aynı anda sürekli değerlendirmesi ayrıcalığıyla geleneksel yöntemlerden daha avantajlıdır. Genetik algoritmalar rastgele oluşturulmuş ve topluluğa karşılık gelen karar vektörlerinden oluşmaktadır. Her bir karar vektörü grup pürüzlülük değerleri ve talep ayarlama faktörleri içeren karar değişkenleri setinden oluşmaktadır. Her bir karar vektörü ikili sayılardan oluşmaktadır ve karar değişkeni değeri ikili sayı sistemine göre çevrilmektedir. İkili dizi setinin üst ve alt limitleri karar değişkeninin muhtemel en küçük varyasyonunu kontrol eder. Karar değişkeni değerleri ikili sisteme dönüştürülür ve ikili sistemden tekrar eski haline dönüştürülebilmektedir. İkili sistem kodlaması sayesinde karar vektörü 0 ve 1'lerden oluşan ikili diziye indirgenebilmektedir. Elde bulunan karar vektörlerinden uygunluk fonksiyonuna göre alt karar vektörleri seti seçilir. Bir karar vektörü popülasyonu seçildiğinde çaprazlama ya da mutasyon operasyonlarıyla yeni bir karar vektörü popülasyonu oluşturulur (Lingireddy ve Ormsbee, 2002).

2.6.6. Yerçekimi arama optimizasyonu algoritması

Yerçekimi arama optimizasyon algoritması Newton'un kütle çekim teorisinden esinlenerek ortaya çıkarılmıştır. Kütle çekim teorisinde kuvvet kütle ile doğru orantı ve uzaklığın karesi ile ters orantı olacak şekilde tanımlanmaktadır. Yerçekimi arama algoritmasında tanımlanmış olan parçacıklar pozisyon, kütle, aktif ve pasif yerçekimi olmak üzere dört farklı özellik taşımaktadır. Problemin çözümü parçacığın pozisyonu ile sağlanmaktadır ve kütleler uygunluk fonksiyonuna göre belirlenebilmektedir. Her


bir kütle çekim kanunu ve hareket kanunu olmak üzere iki kanuna tabidir (Yadav ve Deep, 2013).





3. ARAŞTIRMA VERİLERİ VE METODOLOJİ

Talep tahmini yapılırken tahmin modelinin oluşturulabilmesi için belirli adımlar takip edilmektedir. Bu çalışmada talep tahmin modeli oluşturmada izlenen adımları içeren süreç akış şeması Şekil 3.9’da gösterilmiştir.



Şekil 3.1. Tahmin modeli oluşturma süreci akış şeması.

3.1. Verilerin Toplanması

Talep tahmin modellerinde kullanılacak olan veriler ana bileşeni çelik olan ürünlerin taleplerini doğrudan ya da dolaylı olarak etkileyen parametreler arasından seçilmiştir. Ürünlerin imalatında kullanılan hammaddelerin uluslararası çapta dolar bazında işlem görmesi ve satışlarının euro bazında yapılması sebebiyle euro/dolar paritesi bağımsız değişkenlerden biri olarak seçilmiştir. Ürünlerin maliyetinin yaklaşık olarak %80 kadarının hammadde kaynaklı olması ve ürünlerdeki ana bileşenin çelik olması nedeniyle çelik fiyatı bir diğer bağımsız değişken olmuştur. Ürünlerin maliyetinde hammadde ve euro bazında yapılan makine yatırım bedelinden sonra en önemli maliyet kaleminin enerji maliyeti olması sonucu bir diğer bağımsız değişken olarak enerji maliyeti kullanılmıştır. Ayrıca talep tahmin modelinin doğruluğunu artırmak adına son dönem sipariş verilerinin eklenmesine ihtiyaç duyulmuştur. Böylece modellerde her bir ürününe ait bir, iki ve üç ay öncesinin gerçek sipariş verileri de bağımsız değişkenler arasında değerlendirilmiştir. Talep tahmin modelinde kullanılan gerçek satış verileri çelik sektöründe ürün satışı yapan büyük ölçekli uluslararası bir şirketten alınmıştır. Ürün gamından seride en çok satışı gerçekleşen ve sipariş dalgalanması daha az olan ürünler seçilmiştir. Bu verilere ek olarak basit hareketli ortalamadaki gibi son üç ayın siparişlerinin ortalaması bağımsız değişkenler arasına eklenmiştir. Ayrıca modelin siparişlerdeki değişimleri takip edebilmesi için bağımsız değişkenlerin de değişiminin nitelikler arasına katılması gerektiği yapılan simülasyonlar sonrasında fark edilmiştir. Bu doğrultuda çelik fiyatının dönemler arasındaki farkları, enerji maliyetinin dönemler arasındaki farkları ve siparişlerin dönemler arasındaki değişimi bağımsız değişkenler arasına eklenmiştir. Model simülasyonlarının her birinde ayrı ayrı bağımsız değişkenler eklenip kaldırılarak modele katkısının ağırlığı incelenmiştir. Örneğin enerji maliyetleri bağımsız değişkeni modellerden kaldırılarak sonuçta elde edilen doğruluk değeri kaldırılmadığında elde edilen doğruluk değeri ile karşılaştırılmıştır. Bu sayede bağımsız değişkenlerin modellerde kullanılması gerekliliğine karar verilmiştir. Yapılan incelemeler sonucunda siparişlerin ilgili dönemlerine ve tarihlerine karşılık gelen bağımsız değişkenler Tablo 3.1’de gösterilmiştir. Şirket satış verilerinin gizli tutulması sebebiyle tabloda siparişlere ait verilere yer verilmemiştir.

Tablo 3.1. İlgili dönemlerdeki bağımsız değişkenler.

Tarih	Dönem	Euro/Dolar	Enerji Maliyeti	Çelik Fiyatı	Enerji Maliyetindeki Değişim	Çelik Fiyatındaki Değişim
Nisan 2016	4	1,1	94	332	0	3
Mayıs 2016	5	1,1	91	335	-3	3
Haziran 2016	6	1,13	91	346	0	11
Temmuz 2016	7	1,15	91	387	0	41
Ağustos 2016	8	1,12	90	431	-1	44
Eylül 2016	9	1,11	90	464	0	33
Ekim 2016	10	1,12	87	439	-3	-25
Kasım 2016	11	1,12	81	439	-6	0
Aralık 2016	12	1,13	76	464	-5	25
Ocak 2017	13	1,09	71	475	-5	11
Şubat 2017	14	1,07	73	492	2	17
Mart 2017	15	1,05	73	607	0	115
Nisan 2017	16	1,07	73	607	0	0
Mayıs 2017	17	1,06	75	618	2	11
Haziran 2017	18	1,08	75	618	0	0
Temmuz 2017	19	1,09	74	613	-1	-5
Ağustos 2017	20	1,12	75	552	1	-61
Eylül 2017	21	1,14	76	541	1	-11
Ekim 2017	22	1,18	72	541	-4	0
Kasım 2017	23	1,21	68	547	-4	6
Aralık 2017	24	1,18	68	569	0	22
Ocak 2018	25	1,17	76	569	8	0
Şubat 2018	26	1,19	76	569	0	0
Mart 2018	27	1,2	74	585	-2	16
Nisan 2018	28	1,24	72	596	-2	11
Mayıs 2018	29	1,23	67	602	-5	6
Haziran 2018	30	1,23	98	618	31	16
Temmuz 2018	31	1,21	75	618	-23	0
Ağustos 2018	32	1,16	62	624	-13	6
Eylül 2018	33	1,17	56	607	-6	-17
Ekim 2018	34	1,17	77	602	21	-5
Kasım 2018	35	1,17	84	591	7	-11
Aralık 2018	36	1,18	85	607	1	16
Ocak 2019	37	1,14	84	602	-1	-5
Şubat 2019	38	1,14	86	591	2	-11
Mart 2019	39	1,15	83	574	-3	-17
Nisan 2019	40	1,15	79	563	-4	-11
Mayıs 2019	41	1,14	75	536	-4	-27
Haziran 2019	42	1,12	103	530	28	-6
Temmuz 2019	43	1,12	92	525	-11	-5
Ağustos 2019	44	1,12	93	497	1	-28
Eylül 2019	45	1,14	91	508	-2	11
Ekim 2019	46	1,12	104	511	13	3
Kasım 2019	47	1,11	105	503	1	-8

Tablo 3.1.(Devamı) İlgili dönemlerdeki bağımsız değişkenler.

Tarih	Dönem	Euro/Dolar	Enerji Maliyeti	Çelik Fiyatı	Enerji Maliyetindeki Değişim	Çelik Fiyatındaki Değişim
Aralık 2019	48	1,1	103	497	-2	-6
Ocak 2020	49	1,11	101	492	-2	-5
Şubat 2020	50	1,1	99	450	-2	-42
Mart 2020	51	1,12	95	442	-4	-8
Nisan 2020	52	1,1	88	445	-7	3
Mayıs 2020	53	1,1	86	483	-2	38
Haziran 2020	54	1,11	93	508	7	25
Temmuz 2020	55	1,09	87	503	-6	-5
Ağustos 2020	56	1,11	83	470	-4	-33
Eylül 2020	57	1,13	80	437	-3	-33
Ekim 2020	58	1,18	80	426	0	-11
Kasım 2020	59	1,19	79	442	-1	16
Aralık 2020	60	1,17	82	453	3	11
Ocak 2021	61	1,18	91	516	9	63
Şubat 2021	62	1,2	95	525	4	9
Mart 2021	63	1,23	88	585	-7	60
Nisan 2021	64	1,22	82	723	-6	138
Mayıs 2021	65	1,22	80	767	-2	44
Haziran 2021	66	1,18	94	789	14	22
Temmuz 2021	67	1,22	94	998	13	209
Ağustos 2021	68	1,22	95	1146	1	148
Eylül 2021	69	1,19	95	1229	-2	83
Ekim 2021	70	1,19	88	1273	-2	44
Kasım 2021	71	1,18	77	1333	-2	60
Aralık 2021	72	1,17	59	1234	-18	-99
Ocak 2022	73	1,17	130	1163	71	-71
Şubat 2022	74	1,13	128	1080	-2	-83
Mart 2022	75	1,14	120	1058	-8	-22
Nisan 2022	76	1,12	158	1036	38	-22
Mayıs 2022	77	1,13	148	992	-10	-44
Haziran 2022	78	1,11	135	1256	-13	264
Temmuz 2022	79	1,06	165	1520	30	264
Ağustos 2022	80	1,08	159	1383	-6	-137
Eylül 2022	81	1,05	157	1124	-2	-259
Ekim 2022	82	1,03	155	921	-2	-203
Kasım 2022	83	1	154	877	-1	-44
Aralık 2022	84	0,98	154	844	0	-33
Ocak 2023	85	1,01	192	822	38	-22
Şubat 2023	86	1,04	192	712	0	-110
Mart 2023	87	1,07	190	706	-2	-6
Nisan 2023	88	1,09	159	745	-31	39
Mayıs 2023	89	1,06	156	800	-3	55
Haziran 2023	90	1,09	132	860	-24	60
Temmuz 2023	91	1,11	116	921	-16	61
Ağustos 2023	92	1,07	113	910	-3	-11

3.2. Nitelik Oluřturma

Talep tahmin alıřması yapılırken ilk olarak talebi etkileyen euro/dolar paritesi, enerji maliyeti ve elik fiyatından bağımsız deęiřkenler olarak yararlanılmıřtır. Talebi etkileyen parametreler sektr bilgisine gre ve rn maliyetlerini etkileyen kalemlerin incelenmesiyle seilmiřtir. Modeller sadece bu deęiřkenlerle geliřtirildięinde hedeflenen doęruluk deęerlerine modellerin henz ulařamadıęı gzlemlenmiřtir ve son dnem verilerinden yararlanılabileceęi dřnlmřtr. Bu doęrultuda yapılan literatr taraması ile kayan pencereler yntemi incelenmiřtir.

Zaman serilerinde bulunan verilerle istatistiksel hesaplamalar yapmada, veri setindeki belirli bir aralıęın belirlenerek belirli bir sayıda rneęin kullanılması yntemi kayan pencereler yntemi (Rolling Window) olarak adlandırılmaktadır. Zaman serisindeki her dnemde eldeki verilere dair belirli sayıda gzlem yapılır. Bu gzlemlere her bir sonraki zaman serisi noktasında devam edilir. Elde edilen dnem verilerine ait gzlemler ile istatistiksel hesaplamalar yapılır. En sık kullanılan kayan istatistik yntemi hareketli ortalamadır (Lazzeri, 2020). Bu bilgiler doęrultusunda gemiř dnem satıř verilerinden 1 ay nceki sipariř miktarı, 2 ay nceki sipariř miktarı ve 3 ay nceki sipariř miktarı nitelikler arasına eklenmiřtir. Son  dnemlik verinin yanı sıra son  aylık hareketli ortalama verileri ile nitelik oluřturulmuřtur. Yeniden geliřtirilen modellerde bu niteliklerin eklenmesinin hataların azaltılmasında nemli derecede katkısı gzlemlenmiřtir. Ayrıca geliřtirilen modellerde artıř ve azalıř trendlerinin daha yksek olduęu dnemlerde daha fazla mutlak hatalarla karřılařılmıřtır. Bunun zerine oluřturulmuř olan niteliklerin artıř ve azalıř miktarları da nitelikler arasında yer almasının faydalı olacaęı dřnlmřtr. Enerji maliyetindeki deęiřim, elik fiyatındaki deęiřim ve gerek sipariř deęerlerinin deęiřimi ile yeni nitelikler oluřturulmuřtur.

3.3. Veri Setinin İstatistiksel zellikleri

Talep tahmin modelinin istenen doęrulukta alıřabilmesi iin girdilere ait veri setinin zelliklerinin iyi bilinmesi ve uygun veri n iřleme adımlarının izlenmesi gereklidir. Bu doęrultuda elde bulunan verilerin istatistiksel zellikleri nem tařımaktadır. A rn veri setinin istatistiksel zellikleri Tablo 3.2’de verilmiřtir.

Tablo 3.2. A ürünü veri setinin istatistiksel özellikleri.

Nitelikler	Ortalama	Medyan	Min	Maks	Standard Sapma	Eşsiz Veriler	Kayıp Veriler
Eur/Dol	1,132	1,13	0,98	1,24	0,056	25	0
Enerji maliyeti	98,52	88	56	192	31,8	51	0
Enerji maliyetindeki değişim	0,21	-2	-31	71	13,3	32	0
Çelik fiyatı	679,1	591	332	1520	269,6	67	0
Çelik fiyatındaki değişim	6,53	0	-259	264	72.04	44	0
1 ay önceki gerçek sipariş	16479	14768	3952	39728	8124	67	0
2 ay önceki gerçek sipariş	16596	15184	3952	39728	8102	67	0
3 ay önceki gerçek sipariş	16668	15184	3952	39728	8054	67	0
Son 3 ay sipariş ortalaması	16581	16085	7259	29328	6082	75	0
Gerçek siparişteki değişim	116.5	0	-24752	25168	9113	69	0
Gerçek sipariş	16322	14560	3952	39728	8170	67	0

B ürünü veri setinin istatistiksel özellikleri Tablo 3.3'te verilmiştir.

Tablo 3.3. B ürünü veri setinin istatistiksel özellikleri.

Nitelikler	Ortalama	Medyan	Min	Maks	Standard Sapma	Eşsiz Veriler	Kayıp Veriler
Eur/Dol	1,132	1,13	0,98	1,24	0,056	25	0
Enerji maliyeti	98,52	88	56	192	31,8	51	0
Enerji maliyetindeki değişim	0,21	-2	-31	71	13,3	32	0
Çelik fiyatı	679,1	591	332	1520	269,6	67	0
Çelik fiyatındaki değişim	6,53	0	-259	264	72.04	44	0
1 ay önceki gerçek sipariş	1993	1841	479	7614	961	88	0
2 ay önceki gerçek sipariş	2004	1841	479	7614	953	88	0
3 ay önceki gerçek sipariş	2015	1850	479	7614	944	88	0
Son 3 ay sipariş ortalaması	2004	1936	696	3880	747	89	0
Gerçek siparişteki değişim	-11	29	-5773	5732	1032	86	0
Gerçek sipariş	1997	1841	479	7614	953	88	0

C ürünü veri setinin istatistiksel özellikleri Tablo 3.4'te verilmiştir.

Tablo 3.4. C ürünü veri setinin istatistiksel özellikleri.

Nitelikler	Ortalama	Medyan	Min	Maks	Standard Sapma	Eşsiz Veriler	Kayıp Veriler
Eur/Dol	1,132	1,13	0,98	1,24	0,056	25	0
Enerji maliyeti	98,52	88	56	192	31,8	51	0
Enerji maliyetindeki değişim	0,21	-2	-31	71	13,3	32	0
Çelik fiyatı	679,1	591	332	1520	269,6	67	0
Çelik fiyatındaki değişim	6,53	0	-259	264	72.04	44	0
1 ay önceki gerçek sipariş	12398	11901	1249	23913	4647	89	0
2 ay önceki gerçek sipariş	12466	11945	1249	23913	4597	89	0
3 ay önceki gerçek sipariş	12408	11945	1249	23913	4664	89	0
Son 3 ay sipariş ortalaması	12424	12787	6969	18845	2474	88	0
Gerçek siparişteki değişim	68	-142	-20411	17793	7240	89	0
Gerçek sipariş	12344	11756	1249	23913	4679	89	0

D ürünü veri setinin istatistiksel özellikleri Tablo 3.5’te verilmiştir.

Tablo 3.5. D ürünü veri setinin istatistiksel özellikleri.


Nitelikler	Ortalama	Medyan	Min	Maks	Standard Sapma	Eşsiz Veriler	Kayıp Veriler
Eur/Dol	1,132	1,13	0,98	1,24	0,056	25	0
Enerji maliyeti	98,52	88	56	192	31,8	51	0
Enerji maliyetindeki değişim	0,21	-2	-31	71	13,3	32	0
Çelik fiyatı	679,1	591	332	1520	269,6	67	0
Çelik fiyatındaki değişim	6,53	0	-259	264	72.04	44	0
1 ay önceki gerçek sipariş	1831	1711	561	9080	995	88	0
2 ay önceki gerçek sipariş	1835	1711	561	9080	994	88	0
3 ay önceki gerçek sipariş	1845	1723	561	9080	990	88	0
Son 3 ay sipariş ortalaması	1837	1779	677	5051	759	89	0
Gerçek siparişteki değişim	3,51	-35	-6306	6988	1115	84	0
Gerçek sipariş	1819	1704	561	9080	1000	88	0

3.4. Verilerin Düzenlenmesi

Yapay sinir ağları, karar ormanı ve lineer regresyon modellerinde kullanılan bağımsız bileşenlere modellerde daha doğru sonuçlar alabilmek için istatistiksel yöntemler uygulanmıştır. Microsoft Azure Machine Learning Studio (Azure ML Studio)’da

kaynak verilerin bulunduğu sütunlar bu yöntemlerle değiştirilmiştir. Tahmin modelleri kurulurken modeldeki hata oranının yüksek çıkmaması ve beklenen doğruluk oranlarına ulaşılabilmesi için gerekli veri düzeltmeleri Azure ML Studio’da bulunan veri dönüştürme modülleri aracılığıyla yapılmıştır. Eğitim setinde seriyi bozan ve dağılımda çok uçlarda yer alan verilerin dağılımının ortalama değeri ile değiştirilmesi, normalizasyon, logaritmik dönüşümler gibi gerekli değişimler gerçekleştirilmiştir.

Azure ML Studio’da kurgulanan tahmin modeline ait mimari yapı Şekil 3.1’de gösterilmiştir. Verilerin modele girişinin yapılması, verilerin düzenlenmesi, veri setinin bölünmesi, tahmin yönteminin seçilmesi, modelin eğitilmesi ve modelin değerlendirilmesi aşamaları bu mimaride görülmektedir.



Şekil 3.2. Azure ML Studio tahmin modeli mimarisi.

Modelde kullanılan veri setinde bulunan aykırı veriler ortalama değerlerle değiştirilmiştir. Uçlarda bulunan değerler çıkarılırken %95’in üzerinde bulunan ve %5’in altında bulunan değerler seçilmiştir. Bu verilerin seçilmesinde ve değiştirilmesinde Azure ML Studio’da bulunan Clip Values (Değerleri Kırp) modülü kullanılmıştır. Clip Values modülüne ait detaylar Şekil 3.2’de verilmiştir.

Properties Project

▲ Clip Values

Set of thresholds
ClipPeaksAndSubpeaks

Threshold
Percentile

Percentile number of upper threshold
95

Percentile number of lower threshold
5

Substitute value for peaks
Mean

Substitute value for subpeaks
Mean

Şekil 3.3. Azure ML Studio’da aykırı verilerin kırılması.

Model kurulurken veri setinde bulunan enerji maliyetleri ve çelik fiyatlarında normalizasyon işlemi uygulanmıştır. Normalizasyon, Azure ML Studio’da bulunan Normalize Data (Veriyi Normalize Et) modülü kullanılarak uygulanmıştır. Çeşitli seçenekler arasından MinMax dönüşüm metodu seçilmiştir. Modelde kullanılan Normalize Data modülüne ait detaylar Şekil 3.3’te verilmiştir.

Properties Project

▲ Normalize Data

Transformation method
MinMax


☒ Use 0 for constant columns when checked

Columns to transform
Selected columns:
Column names: energy_cost, steel_price
Launch column selector

START TIME 10/2/2023 10:34:48 PM
END TIME 10/2/2023 10:34:48 PM
ELAPSED TIME 0:00:00.000
STATUS CODE Finished
STATUS DETAILS Task output was present in output cache

Şekil 3.4. Azure ML Studio ile verilerin normalize edilmesi.

Veri setinde normalizasyon uygulanmış versiyon Şekil 3.4’te gösterilmiştir.



Şekil 3.5. Verilerin normalizasyon sonuçları örneği.

Veriler arasındaki dengesizliklerin ve çarpıklıkların giderilmesinde lognormal (Ln) dönüşümü kullanılmaktadır. Çok geniş veri aralıklarında daha küçük olan değerler büyük değerler tarafından bastırılabilir. Ln dönüşümü aykırı değerlerin dağılımdaki ağırlığını azaltır ve çan eğrisi elde etmemize olanak sağlar. Bu sayede dağılımda simetri tekrar elde edilmiş olur (Sauro ve Lewis, 2016). Modelin eğitiminde kullanılan gerçek satış değerlerinin aralığı çok geniş olduğundan verilerde çarpık dağılımın giderilerek normal dağılıma yakın bir dağılım izlemesi için logaritmik dönüşüm gerçekleştirilmiştir. Logaritmik dönüşüm Azure ML Studio’da bulunan Apply Math Operation (Matematik İşlemi Uygula) modülü kullanılarak uygulanmıştır. Model gerçek satış verilerinin Ln değerleri ile eğitilmiştir. Ln dönüşümünün uygulandığı detay Şekil 3.5’te gösterilmiştir.

Properties
Project

Apply Math Operation

Category
Basic

Basic math function
Ln

Column set

Selected columns:
Column names: product_1

Launch column selector

Output mode
Append

START TIME 10/2/2023 10:34:48 PM
END TIME 10/2/2023 10:34:48 PM
ELAPSED TIME 0:00:00.000
STATUS CODE Finished
STATUS DETAILS Task output was present in output cache

Şekil 3.6. Verilerin Ln dönüşümünün yapıldığı modül detayı.

Ln dönüşümü sonucu elde edilen gerçek satış verilerine ait örnek Şekil 3.6’da en sağdaki sütunda görülmektedir.

product_1
Select Columns in Dataset
Results dataset

rows 41
columns 9

ID	eur_dollar	energy_cost	steel_price	1m_ago	2m_ago	3m_ago	product_1	Ln(product_1)
4	1.095	82	807	96	468	176	401	5.993961
5	1.109	79	807	401	96	468	764	6.638568
6	1.123	84	487	764	401	96	80	4.382027
7	1.177	75	507	80	764	401	11	2.397895
8	1.193	71	556	11	80	764	39	3.663562
9	1.171	70	570	39	11	80	351	5.860786
10	1.164	70	595	351	39	11	147	4.990433
11	1.192	68	657	147	351	39	53	3.970292
12	1.119366	68	736	53	147	351	72	4.276666
13	1.213	76	737	72	53	147	51	3.931826
14	1.207	80	804	51	72	53	33	3.496508
15	1.172	76	916	33	51	72	9	2.197225
16	1.201	70	1049	9	33	51	50	3.912023
17	1.119366	113	1128	50	9	33	93	4.532599
18	1.185	81	1125	93	50	9	116	4.75359
19	1.187	81	1109	116	93	50	41	3.713572

Şekil 3.7. Ln dönüşümü uygulanmış veriler.

Ln dönüşümünü uygulandıktan sonra veri setleriyle yapılan denemeler sonucunda çıktı Ln tahmin değerlerinin gerçek siparişlerin Ln değerlerinin dağılımından yaklaşık olarak ortalama bir hata farkına sahip olduğu görülmüştür. Bu ortalama hata ile tahminlerin hepsi birden dağılımda gerçek sipariş miktarlarının üstünde ya da altında kalmaktadır. Programın genel olarak doğru trendi elde etmesine rağmen daha yüksek ya da düşük aralıklarda sonuçlar verdiği gözlemlenmiştir.

Günümüzde yapılan tahmin uygulamalarında gerçekte olan değerlerden sapmanın belirlenmesi ve gelecekte bu sapmaların eğitim veri setinde kullanılması sağlanmaktadır. Buna örnek olarak evet-hayır şeklinde doğrulama, ya da geri besleme döngüleri gösterilebilir. Örneğin Google haritalar uygulamasında tahmini varış süresi verilmektedir. Kullanıcı gitmek istediği yere vardığında ise tahmini varış süresinden daha farklı bir süreyle karşılaşılabilir. Bu durum gerçekleştiğinde gelecekteki tahmini varış sürelerinde kullanılmak üzere program aradaki farkı göz önünde bulundurarak yeni tahminler vermektedir. Bunlara benzer şekilde talep tahmin uygulamalarında da eğitim veri setindeki dağılım test veri setinden farklılık gösterebilmektedir. Bu gerçekleştiğinde ise bahsedilen uygulamalarda olduğu gibi otomatik düzeltme sistemi mevcut olmadığından talep tahmin modeli zamanla doğruluğu gittikçe azalan tahmin çıktıları vermektedir. Eğitim verisinin sınırlı olması ancak tahmin edilecek verilerin sınırsız olabilmesi, hesaplamalarda insan kaynakları faktörlerinin etkili olması gibi nedenlerle gerçek dünya verileriyle farklılık gösterebilmektedir. Eğitim tarafındaki verilerin sabit olmasına rağmen gerçek dünya verileri dinamikdir. Bu noktada eğitim veri seti ile tahmin verisi arasındaki sabit ve dinamik durumun dengelenmesi ve modelin daha doğru genelleme yapılabilmesi için veri öteleme yöntemleri tercih edilmektedir (Huyen, 2022).

Tüm bu bilgiler göz önünde bulundurularak tahmin modelinin gerçek değerlere daha yakın aralıklarda tahminler vermesi için veri ön işlemede matematiksel öteleme yapılması gerektiği sonucuna varılmıştır. Bu şekilde Ln gerçek sipariş değerlerinin tamamına, yaklaşık olarak ortalama sapmaya eşdeğer bir değer eklenmiş veya çıkarılmıştır. Bu sayede model eğitimi gerçekleşirken bulduğu sonuçlar gerçek değerlere daha yakın çıkabilmektedir. A ürününe ait test verisindeki ortalama Ln gerçek siparişlerin ortalaması 9,49'dur. Eğitim verisindeki gerçek değerlerden 0,15 değeri kadar matematiksel bir çıkarma işlemi uygulanmıştır. B ürününe ait test verisindeki ortalama Ln gerçek siparişlerin ortalaması 7,51'dir. Eğitim verisindeki gerçek değerlerden 0,30 değeri kadar matematiksel bir çıkarma işlemi uygulanmıştır. C ürününe ait test verisindeki ortalama Ln gerçek siparişlerin ortalaması 9,36'dır. Eğitim verisindeki gerçek değerlerden 0,30 değeri kadar matematiksel bir çıkarma işlemi uygulanmıştır. D ürününe ait test verisindeki ortalama Ln gerçek siparişlerin ortalaması 7,19'dur. Eğitim verisindeki gerçek değerlerden 0,38 değeri kadar

matematiksel bir çıkarma işlemi uygulanmıştır. Uygulanan bu matematiksel öteleme işlemi fonksiyonlarında yapılan öteleme işlemine benzemektedir.

3.4.1. Veri setinin bölünmesi

Tahmin modellerinin seçilmiş olan verilerle ve algoritmalarla eğitilmesi gereklidir. Eğitilmiş olan modelin ise doğruluğunu değerlendirebilmek için bir kısmının test verisi olarak ayrılması gereklidir. Veri setinin bölünmesi adı verilen bu işlemin oranları modelin eğitilmesini etkilemektedir ve tahmin doğruluğunu değiştirmektedir. Veri setinin doğru oranda bölünebilmesi için literatürde yapılmış olan çalışmalar incelendiğinde çalışmaların çoğunda veri setinin %70 eğitim, %30 test veya %80 eğitim, %20 test verisi olarak bölünmesi önerilmektedir. Çoğunluğunda ise en iyi sonucu %80-%20 bölünmenin verdiği görülmüştür.

Gholamy ve ark. (2018), yaptıkları istatistik çalışmasında $p \cdot (1 - p)$ değerinin en büyük olduğu ve aynı zamanda p değişkenine en küçük değerin atandığı durumda modelin en iyi eğitim olanağına sahip olduğu sonucuna varmıştır. Bu sonuca göre eğitim veri seti bölünmesini ifade eden p değeri 0.8 olmalıdır. Böylelikle tahmin modellerinde %80-20 bölünmenin en yüksek doğruluğu vereceğini öngörmüşlerdir. Dobbin ve Simon (2011)'un yaptıkları literatür araştırmaları ve model denemeleri sonucunda %80-20 veri bölünmesini modellerine uygulamıştır. Keung ve ark. (2021) çalışmalarında Dobbin ve Simon (2011)'un araştırmasını örnek alarak modellerini eğitmek için %80-20 oranını kullanmıştır. Yani ve Aamer (2023) çalışmalarında 9 ayrı ürün üzerinde çeşitli yöntemler kullanarak kurdukları tahmin modellerinde en iyi sonucu veren oranın %80-20 olduğu sonucuna varmıştır.

Literatürdeki tüm bulgular göz önünde bulundurulduğunda bu çalışmada modellerin eğitiminde verilerin %70-30, %80-20 ve %90-10 bölünme oranlarıyla deneme yapılmıştır. Yapılan deneme çalışmaları ile en iyi sonuçlara %90-10 seçeneğiyle ulaşıldığı görülmüştür. Literatürdeki %80-20 oranından farklı olmasının nedeninin elde bulunan verilerin dönem sayısının nispeten daha az olması öngörülmektedir. Şekil 3.7'de Azure ML Studio'da verilerin bölünmesi için yapılan seçim detayı gösterilmiştir.

Properties Project

Split Data

Splitting mode
Split Rows

Fraction of rows in the first output dataset
0.90

☐ Randomized split

Random seed
1234

Stratified split
False

START TIME	12/11/2023 8:54:55 AM
END TIME	12/11/2023 8:54:55 AM
ELAPSED TIME	0:00:00.000
STATUS CODE	Finished
STATUS DETAILS	Task output was present in output cache

Şekil 3.8. Verilerin %90-10 oranında bölünmesi.

3.5. Makine Öğrenmesi Algoritmalarıyla Modelleme


Uygulama çalışmasında tahmin modellerini oluşturmada makine öğrenmesi algoritmaları ile modelleme yapabilen bir program olan Azure ML Studio platformu kullanılmıştır. Tahmin çalışmasında çözüme ulaşmada makine öğrenmesi algoritmalarından yapay sinir ağları, karar ormanı ve lineer regresyon yöntemleri ile modeller elde edilmiştir.

YSA modellerinde nöron sayısı deneme yanılma yöntemiyle belirlenmektedir. Bu doğrultuda istenen performans düzeyi hedeflenerek nöron sayısı artırılarak ya da azaltılarak süreç ilerletilir. Nöron sayısı fazla olduğunda ağ verileri ezberleyebileceğinden, az olduğunda ise genelleme yeteneği artacağından dolayı nöron sayısı olabildiğince az tutulmalıdır. Nöron sayısının gereğinden az olması ise ağın öğrenmesinin düşük olmasına yol açabilir (Öztemel, 2006). Bu doğrultuda dokuz ayrı ürün için yapılan yapay sinir ağları modellerinde her biri için ayrı ayrı denemeler yapılarak düğüm ve iterasyon sayısı belirlenmiştir. Her bir ürüne ait yapay sinir ağları modellerinde kullanılan parametre seçimleri Tablo 3.6'da verilmiştir.

Tablo 3.6. Yapay sinir ağıları modellerinde kullanılan eğitim parametreleri.

Parametreler	A Ürünü	B Ürünü	C Ürünü	D Ürünü
Gizli düğüm noktası sayısı	8	8	8	8
Öğrenme oranı	0,003	0,002	0,001	0,001
Öğrenme iterasyon sayısı	12000	12000	12000	30000
İlk öğrenme ağırlığı	0,01	0,01	0,01	0,05
Momentum değeri	0,2	0,2	0,5	0,4
Normalize yöntemi	Min-Maks	Min-Maks	Min-Maks	Min-Maks

Karar ormanları modellerinde en iyi sonucu elde edebilmek için karar ağaçlarının sayısı, örnekleme metodu, karar ağaçlarının maksimum derinliği, her düğüm için rasgele bölünme sayısı ve her bir yaprak için minimum örnek sayısı parametrelere doğru değerler girilmesi gereklidir. Bu doğrultuda ilgili parametreler geniş bir aralıkta sistematik deneme yanılma uygulanarak bulunmuştur. Ayrıca modülde bulunan “Parameter Range (Parametre Aralığı)” özelliği ile otomatik olarak uygun parametre aralıklarını bulunabilmektedir. Azure ML Studio’da bulunan parametre aralığı özelliğine ait detay Şekil 3.8’de verilmiştir. Şekil 3.8’den görüleceği üzere karar ağaçlarının sayısı, karar ağaçlarının maksimum derinliği, her düğüm için rasgele bölünme sayısı ve her düğümde bulunan minimum yaprak sayısı gibi parametreler çok geniş aralıklarda otomatik olarak denenebilmektedir. Program bulduğu optimum değerleri modelde kullanıp sonuçlar vermektedir.



Şekil 3.9. Parametre aralığı özelliği.

Parametre aralığı özelliği ve sistematik denemeler sonucunda bulunan, karar ormanı modellerinin eğitiminde kullanılan parametre seçimleri Tablo 3.7’de gösterilmiştir.

Tablo 3.7. Karar ormanı modellerinde kullanılan eğitim parametreleri.

Parametreler	A Ürünü	B Ürünü	C Ürünü	D Ürünü
Yeniden örnekleme yöntemi	Torbalama	Torbalama	Torbalama	Torbalama
Karar ağacı sayısı	8	8	8	8
Karar ağaçlarının maksimum derinliği	32	32	32	32
Düğüm başına rastgele bölünme sayısı	298	256	256	128
Yaprak düğümü başına minimum örnek sayısı	1	1	1	2

Yapay zekâ tabanlı lineer regresyon modellemesinde ise çözüm metodu olarak en küçük kareler yöntemi seçilmiştir. L2 düzenleme ağırlığı ise 0,001 olarak girilmiştir. Bu detaylarla birlikte üç ayrı yöntemle kurulan modelleme çalışmaları belirlenen performans değerlendirme kriterleriyle karşılaştırılmıştır.

Sistematik denemeler sonucunda bulunan, karar ormanı modellerinin eğitiminde kullanılan parametre seçimleri Tablo 3.8’de gösterilmiştir.

Tablo 3.8. Lineer regresyon modellerinde kullanılan eğitim parametreleri.

Parametreler	A Ürünü	B Ürünü	C Ürünü	D Ürünü
Çözüm metodu	En küçük kareler	En küçük kareler	En küçük kareler	En küçük kareler
L2 düzenleme ağırlığı	0,001	0,001	0,001	0,001

3.6. Nitelik Seçimi

Modellerin uygulanmasında girdi olarak değerlendirilen niteliklerin bazılarının kullanılıp bazılarının kullanılmaması sonucu tahmin doğrulukları değişebilmektedir. Tahmin doğruluğunu artırmak amacıyla niteliklerin seçimine olanak sağlayan optimizasyon yöntemleri mevcuttur. Bu yöntemlerden faydalanabilmek için literatür araştırması yapılmıştır. Akdağ ve ark. (2020), araştırmalarında optimum yük akış probleminde yük kayıplarının azaltılmasını hedeflemişlerdir. Daha iyi sonuçlar elde edebilmek için Harris Şahini Optimizasyon algoritmalarını kullanmışlardır. Köse ve ark. (2023), çalışmalarında Yusufçuk Optimizasyon Algoritmasını Weibull olasılık dağılımını tahmin etmek için kullanmışlardır. Yusufçuk Algoritmasının diğer algoritmalarından daha iyi sonuçlar verdiği görülmüştür. Akto (2021) yapmış olduğu çalışmada veri madenciliğinde kümeleme ve sınıflandırmada Gri Kurt Optimizasyon Algoritmasını kullanmıştır ve diğer algoritmalarından daha iyi çalıştığı sonucuna varmıştır. Özkaya ve ark. (2021), çalışmalarında otonom sürüşte güvenlik amaçlı kullanılan seyir kontrol sistemi parametrelerinin düzenlenmesinde Parçacık Sürüş Optimizasyon Algoritmasını kullanmışlardır. Hussein ve ark. (2001), araştırmalarında örüntü tanıma nitelik seçimi ve karakter tanıma sistemi sınıfında modül ağırlıklarını optimize etmek için Genetik Optimizasyon Algoritmasını kullanmışlardır. Papa ve ark. (2011), güç dağıtım sistemlerinde sesli görüntü sınıflandırma, harf tanıma ve sahtekarlık tespiti gibi alanlardan elde edilen veri setleri üzerinde yapılan deneysel çalışmada nitelik seçimini ele alırken Yerçekimi Optimizasyon Algoritmasını kullanmışlardır.

Bu çalışmada, ürünlerin sipariş miktarı değişkeninin tahmin edilmesinde en ilgili özelliklerin belirlenmesi için Parçacık Sürüş Optimizasyonu, Harris Şahinleri Optimizasyonu, Gri Kurt Optimizasyonu, Yusufçuk Optimizasyonu, Genetik Optimizasyonu ve Yerçekimi Arama Optimizasyonu algoritmalarından faydalanılmıştır. Algoritmaların uygulama adımları Spyder 3.1 geliştirme ortamında

Python programlama dili ile açık kaynaklı ‘zoofs’ kütüphanesi yardımıyla yürütülmüştür. Uygulamada optimizasyon algoritmaları için kullanılan parametreler ve değerleri Tablo 3.9’da sunulmaktadır.

Tablo 3.9. Nitelik Seçimi Algoritmaları için kullanılan parametreler.

Nitelik Seçimi Algoritması	Parametre	Değer
Parçacık Sürüşü Optimizasyonu	İterasyon sayısı	1000
	Popülasyon büyüklüğü	20
	İlk ivme katsayısı	2,0
	İkinci ivme katsayısı	2,0
	Ağırlık parametresi	0,9
	Amaç fonksiyonu	Lojistik kayıp performans ölçütünün minimizasyonu
Harris Şahinleri Optimizasyonu	İterasyon sayısı	250
Harris Şahinleri Optimizasyonu	Popülasyon büyüklüğü	20
	Amaç fonksiyonu	Lojistik kayıp performans ölçütünün minimizasyonu
	Beta	0,5
Gri Kurt Optimizasyonu	İterasyon sayısı	1000
	Popülasyon büyüklüğü	20
	Metot	1
	Amaç fonksiyonu	Lojistik kayıp performans ölçütünün minimizasyonu
Yusufçuk Optimizasyonu	İterasyon sayısı	1000
	Popülasyon büyüklüğü	20
	Metot	ikinci dereceden
	Amaç fonksiyonu	Lojistik kayıp performans ölçütünün minimizasyonu
Genetik Optimizasyonu	İterasyon sayısı	1000
	Popülasyon büyüklüğü	20
	Seçici baskı	2
	Elitizm	3
	Mutasyon oranı	0.05
	Amaç fonksiyonu	Lojistik kayıp performans ölçütünün minimizasyonu
Yerçekimi Arama Optimizasyonu	İterasyon sayısı	15
	Popülasyon büyüklüğü	50
	Yerçekimi kuvveti sabiti	100
	Mesafe sabiti	0,5
	Amaç fonksiyonu	Lojistik kayıp performans ölçütünün minimizasyonu

Literatürde yer alan çalışmalardan yola çıkılarak bu çalışmada yer alan talep tahmin modellerinde nitelik seçimi için bahsedilen optimizasyon algoritmaları tüm nitelikler üzerinde uygulanmıştır. Optimizasyon algoritmalarının uygulanmasında ‘LightGBM’ Python kütüphanesinden (LightGBM, 2023) yararlanılarak LightGBM makine öğrenmesi regresyon modeli kullanılmıştır. Model parametrelerinden iterasyon sayısı 100, öğrenme oranı 0,1 ve yaprak sayısı 31 olarak belirlenmiştir. Altı nitelik seçimi yöntemi tarafından seçilen nitelikler Tablo 3.10’da verilmiştir. Niteliğin ilgili optimizasyon çıktısında yer alması X işareti ile belirtilmiştir.

Tablo 3.10. Optimizasyon yöntemleri ile ulaşılan nitelik sonuçları.

Nitelikler	PSO	HŞO	GKO	YO	GO	YAO
Eur/Dol	X	X	X	X	X	
Enerji maliyeti	X	X		X	X	X
Enerji maliyetindeki değişim		X			X	
Çelik fiyatı		X	X		X	X
Çelik fiyatındaki değişim	X	X	X	X	X	X
1 ay önceki gerçek sipariş	X	X	X	X		
2 ay önceki gerçek sipariş	X	X	X	X		X
3 ay önceki gerçek sipariş			X			X
Son 3 ay sipariş ortalaması		X	X		X	X
Gerçek siparişteki değişim		X	X		X	X

3.7. Performans Değerlendirme Kriterlerinin Seçimi

Talep tahmin çalışmalarında modellerin ne kadar doğrulukla ve hangi modelin daha iyi sonucu verdiğini ölçmek için performans değerlendirme kriterleri kullanılmaktadır. Literatürde tahmin modellerinin performans değerlendirmelerini yapmak amacıyla kullanılan birçok metrik mevcuttur. İhtiyaç duyulan bu ölçütlerin seçilmesi ve kullanılması için literatür incelenmiştir.

Robus ve ark. (2022), talep tahminleriyle ilgili inceledikleri 193 çalışmada en sık kullanılan ölçütlerin MAPE, RMSE, MSE ve MAE ölçütleri olduğunu analiz etmiştir. Yaptıkları analiz sonucunda çalışmalarında tahmin modellerini değerlendirmek için MAPE, RMSE ve MAE ölçütlerinin kombinasyonlarını kullanmışlardır. Gökler (2020), benzer şekilde yapmış olduğu çalışmada modellerini karşılaştırmak için istatistiksel performans kriterlerinden MAPE, RMSE, MSE ve MAE kriterlerini

kullanmıştır. Kriterlere ait formüller Denklem 3.1, Denklem 3.2, Denklem 3.3 ve Denklem 3.4'te verilmiştir.

$$MAPE = \frac{100}{n} \sum_{i=1}^n \left| \frac{Y_i - \bar{Y}_i}{Y_i} \right| \quad (3.1)$$

$$MSE = \frac{1}{n} \sum_{i=1}^n (Y_i - \bar{Y}_i)^2 \quad (3.2)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (Y_i - \bar{Y}_i)^2} \quad (3.3)$$

$$RMSE = \frac{1}{n} \sum_{i=1}^n Y_i - \bar{Y}_i \quad (3.4)$$

Bee-Hua (2000), Kolassa ve Siemsen (2016) MAPE ölçütünün tahmin hatasını belirlemede çok sık karşılan bir değerlendirme kriteri olduğunu belirtmiştir. Hyndman ve Koehler (2006) MAPE'nin tahmin performanslarının karşılaştırılmasında en çok önerilen ve tahmin hatasını belirlemede en çok tercih edilen ölçüt olduğunu dile getirmiştir (Yani ve Aamer, 2023). Dey ve ark. (2023), yaptıkları tahmin çalışmasında modellerin performanslarını değerlendirmek için Lewis ölçeğini kullanmıştır. Tablo 3.11'de Lewis ölçeği değerlendirme detayı gösterilmiştir.

Tablo 3.11. MAPE değeri ve doğruluk değerlendirmesi (Lewis, 1982).

MAPE Değeri	Tahmin Doğruluğu
%10'dan küçük	Yüksek Doğrulukta Tahmin
%11-%20 arası	İyi Tahmin
%21-%50 arası	Makul Tahmin
%51'den büyük	Doğru Olmayan Tahmin

Tahmin doğruluğunun değerlendirilmesinde Denklem 4.1 kullanılmıştır (Feizabadi, 2022).

$$\text{Tahmin doğruluğu(\%)} = 1 - \text{MAPE} \quad (4.1)$$

Tüm bu değerlendirmeler göz önünde bulundurularak çalışmada oluşturulan tahmin modellerini ve yöntemlerini karşılaştırmada MAPE, RMSE, MSE ve MAE ölçütlerinin kullanılmasına karar verilmiştir.





4. MAKİNE ÖĞRENMESİ ALGORİTMALARININ UYGULANMASI

A, B, C ve D olarak adlandırılan dört farklı ürün için yapay sinir ağları, karar ormanı ve lineer regresyon makine öğrenmesi algoritmalarıyla modeller oluşturulmuştur. Bu modeller oluşturulurken öncelikle tüm bağımsız nitelikler kullanılarak sonuçlar incelenmiştir. Bağımsız nitelikler arasından seçim yapılmasına olanak sağlayan çeşitli optimizasyon yöntemleriyle modeller tekrar çalıştırılmıştır. Parçacık sürüsü optimizasyonu (PSO), Harris Şahini optimizasyonu (HŞO), gri kurt optimizasyonu (GKO), yusufçuk optimizasyonu (YO), genetik optimizasyonu (GO) ve yerçekimi arama optimizasyonu (YAO) algoritmalarıyla elde edilen bağımsız değişken seçimleriyle farklı talep tahmin sonuçları elde edilmiştir. MAPE performans ölçütü ile en düşük hata değerini veren optimizasyon seçeneği ayrıca ele alınmıştır. Yapay sinir ağları modellerinde nitelik seçim yöntemlerinin doğruluk değerlerinin karşılaştırması Tablo 4.1’de verilmiştir.

Tablo 4.1. Yapay sinir ağları modelleri optimizasyon yöntemleri karşılaştırması.

YSA Modelleri	Tüm Nitelikler	PSO	HŞO	GKO	YO	GO	YAO
A Ürünü	%93,6	%87,0	%89,5	%87,3	%87,0	%92,2	%86,1
B Ürünü	%92,6	%84,4	%93,8	%92,4	%84,4	%92,8	%92,0
C Ürünü	%89,7	%89,7	%85,2	%88,8	%89,7	%90,3	%80,9
D Ürünü	%90,0	%67,8	%89,2	%86,8	%67,8	%89,4	%71,1

Karar ormanı modellerinde nitelik seçim yöntemlerinin doğruluk değerlerinin karşılaştırması Tablo 4.2’de verilmiştir.

Tablo 4.2. Karar ormanı modelleri optimizasyon yöntemleri karşılaştırması.

KO Modelleri	Tüm Nitelikler	PSO	HŞO	GKO	YO	GO	YAO
A Ürünü	%89,1	%84,3	%86,8	%89,8	%84,3	%91,4	%88,3
B Ürünü	%91,9	%83,6	%93,9	%91,4	%83,6	%90,7	%90,1
C Ürünü	%88,4	%81,6	%83,1	%85,9	%81,6	%83,4	%81,1
D Ürünü	%84,7	%74,8	%80,4	%80,5	%74,8	%91,5	%88,9


Lineer regresyon modellerinde nitelik seçimi yöntemlerinin doğruluk değerlerinin karşılaştırması Tablo 4.3'te verilmiştir.

Tablo 4.3. Lineer regresyon modelleri optimizasyon yöntemleri karşılaştırması.

LR Modelleri	Tüm Nitelikler	PSO	HŞO	GKO	YO	GO	YAO
A Ürünü	%82,9	%87,0	%83,9	%89,1	%86,9	%83,3	%89,4
B Ürünü	%94,2	%86,0	%94,7	%93,8	%86,0	%93,3	%94,1
C Ürünü	%80,9	%85,4	%82,3	%78,9	%85,4	%82,4	%85,2
D Ürünü	%81,9	%76,5	%81,9	%83,1	%76,5	%84,9	%85,7

4.1. Yapay Sinir Ağları Tahmin Modelleri


A ürünü yapay sinir ağları metoduyla tüm nitelikler ve ayrıca altı farklı optimizasyon yönteminin verdiği nitelikler kullanılarak oluşturulan modellerin karşılaştırıldığı çizgi grafiği Şekil 4.1'de gösterilmiştir. En iyi sonucun tüm nitelikler ile elde edildiği gözlemlenmiştir.



Şekil 4.1. Nitelik seçimleriyle A ürünü yapay sinir ağları talep tahmin modelleri.


A ürünü yapay sinir ağları modeline ait gerçek değerlerin ve tahmin değerlerinin karşılaştırıldığı çizgi grafiği Şekil 4.2'de gösterilmiştir. Tahmin modeli tüm dönemler için düşük hata değerleriyle gerçek talebe yakın tahmin değerleri sunmuştur, 86, 89 ve 92. dönemlerde ise diğer dönemlere nazaran mutlak hatanın daha yüksek olduğu

gözlemlenmiştir. Mutlak hataların bu dönemlerde yüksek olmasına karşılık model siparişlerin trendini takip edebilmeyi başarmıştır. Bu sayede model yüksek tahmin performans değerlendirme sınırının üstünde sonuç vermiştir. Model belirlenmiş olan performans ölçütlerine göre değerlendirildiğinde MSE değeri 370505, RMSE değeri 609, MAE değeri 502 ve MAPE değeri %6,4 bulunmuştur.




Şekil 4.2. Tüm nitelikler ile A ürünü yapay sinir ağları talep tahmin modeli.

B ürünü yapay sinir ağları yöntemiyle tüm nitelikler ve ayrıca yedi farklı optimizasyon yönteminin verdiği nitelikler kullanılarak oluşturulan modellerin karşılaştırıldığı çizgi grafiği Şekil 4.3'te gösterilmiştir. En iyi sonucun Harris Şahini Optimizasyonu ile elde edildiği görülmüştür.




Şekil 4.3. Nitelik seçimleriyle B ürünü yapay sinir ağları talep tahmin modelleri.

B ürünü yapay sinir ağları modeline ait gerçek değerlerin ve tahmin değerlerinin karşılaştırıldığı çizgi grafiği Şekil 4.4'te gösterilmiştir. Tahmin modeli genel olarak düşük hata değerleriyle gerçeğe yakın tahminler gerçekleştirmiştir. 86, 88 ve 89. dönemlerde ise gerçekten daha düşük sonuçlar vermiştir ve bu dönemlerde mutlak hatalar diğer dönemlere göre daha yüksek kalmıştır. Model belirlenmiş olan performans ölçütlerine göre değerlendirildiğinde MSE değeri 8692, RMSE değeri 93, MAE değeri 74ve MAPE değeri %6,2 bulunmuştur.




Şekil 4.4. Harris Şahini ile B ürünü yapay sinir ağları talep tahmin modeli.

C ürünü yapay sinir ağları yöntemiyle tüm nitelikler ve ayrıca altı farklı optimizasyon yönteminin verdiği nitelikler kullanılarak oluşturulan modellerin karşılaştırıldığı çizgi grafiği Şekil 4.5'te gösterilmiştir. En iyi sonucun Genetik Optimizasyon kullanıldığında elde edildiği görülmüştür.




Şekil 4.5. Nitelik seçimleriyle C ürünü yapay sinir ağları talep tahmin modelleri.

C ürünü yapay sinir ağı modeli ait gerçek değerlerin ve tahmin değerlerinin karşılaştırıldığı çizgi grafiği Şekil 4.6’da gösterilmiştir. Tahmin modeli 89 ve 91. dönem haricinde gerçek değerlere yakın sonuçlar sunmuştur. Model belirlenmiş olan performans ölçütlerine göre değerlendirildiğinde MSE değeri 900005, RMSE değeri 949, MAE değeri 747, ve MAPE değeri %9,7 bulunmuştur.




Şekil 4.6. Genetik optimizasyonu C ürünü yapay sinir ağı talep tahmin modeli.

D ürünü yapay sinir ağı yöntemiyle tüm nitelikler ve ayrıca altı farklı optimizasyon yönteminin verdiği nitelikler kullanılarak oluşturulan modellerin karşılaştırıldığı çizgi grafiği Şekil 4.7’de gösterilmiştir. En iyi sonucun tüm nitelikler kullanıldığında elde edildiği gözlemlenmiştir.



Şekil 4.7. Nitelik seçimleriyle D ürünü yapay sinir ağları talep tahmin modelleri.


D ürünü yapay sinir ağları modeline ait gerçek değerlerin ve tahmin değerlerinin karşılaştırıldığı çizgi grafiği Şekil 4.8’de gösterilmiştir. Tahmin modeli genel olarak iyi tahminler vermiştir ancak sadece 88, 91 ve 92. dönemlerde gerçek değerlerden uzak sonuçlar vermiştir 84, 85, 86, 89 ve 90. dönemlerde gerçek değerlere çok yakın tahmin değerleri elde edilmiştir. Model 90. döneme kadar 88. dönem haricinde sipariş trendlerini yakalamayı başarmıştır. 91 ve 92. dönemlerde ise trendden bağımsız olarak ortalamaya yakın tahmin sonuçları vermiştir. Son dönemlerde trendden uzaklaşmasına rağmen model yüksek doğruluk tahmin değeri hedefini sağlamıştır. MSE değeri 19736, RMSE değeri 140, MAE değeri 88 ve MAPE değeri %10,0 bulunmuştur.



Şekil 4.8. Tüm niteliklerle D ürünü yapay sinir ağları talep tahmin modeli.


4.2. Karar Ormanı Tahmin Modelleri

A ürünü karar ormanı makine öğrenmesi yöntemiyle tüm nitelikler ve ayrıca altı farklı optimizasyon yönteminin verdiği nitelikler kullanılarak oluşturulan modellerin karşılaştırıldığı çizgi grafiği Şekil 4.9’da gösterilmiştir. En iyi sonucu Genetik Optimizasyonun sağladığı nitelik seçimi gerçekleştirmiştir.




Şekil 4.9. Nitelik seçimleriyle A ürünü karar ormanı talep tahmin modelleri.

A ürünü karar ormanı modeline ait gerçek değerlerin ve tahmin değerlerinin karşılaştırıldığı çizgi grafiği Şekil 4.9’da gösterilmiştir. Tahmin modelinin 86, 87 ve 92. dönemlerde daha fazla hata çıktısı verdiği gözlemlenmiştir. Bu dönemlerde gerçekleşen mutlak hata değerlerine rağmen model tüm test dönemleri süresince siparişlerin trendini takip edebilmiştir. Trendin takip edilebilmesi sayesinde genel olarak modelin tahminleri yüksek doğruluk tahmin aralığında bulunmaktadır. Model belirlenmiş olan performans ölçütlerine göre değerlendirildiğinde MSE değeri 670423, RMSE değeri 819, MAE değeri 693 ve MAPE değeri %8,6 bulunmuştur.




Şekil 4.10. Genetik optimizasyonu ile A ürünü karar ormanı talep tahmin modeli.

B ürünü karar ormanı makine öğrenmesi yöntemi ile tüm nitelikler ve ayrıca yedi farklı optimizasyon yönteminin verdiği nitelikler kullanılarak oluşturulan modellerin karşılaştırıldığı çizgi grafiği Şekil 4.11’de gösterilmiştir. En iyi sonucu Harris Şahini Optimizasyonunun sağladığı nitelik seçimi vermektedir.




Şekil 4.11. Nitelik seçimleriyle B ürünü karar ormanı talep tahmin modelleri.

B ürünü karar ormanı modeline ait gerçek değerlerin ve tahmin değerlerinin karşılaştırıldığı çizgi grafiği Şekil 4.12’de gösterilmiştir. Tahmin grafiği incelendiğinde siparişlerin pik yaptığı dönemlerde bulunan yüksek sipariş dönemlerinde daha yüksek hata çıktıkları görülmüştür. Model genel olarak yüksek doğruluklu tahmin aralığında sonuçlar vermiştir. Model belirlenmiş olan performans ölçütlerine göre değerlendirildiğinde MSE değeri 9657, RMSE değeri 98, MAE değeri 74 ve MAPE değeri %6,1 bulunmuştur.




Şekil 4.12. Harris şahini ile B ürünü karar ormanı talep tahmin modeli.

C ürünü karar ormanı makine öğrenmesi yöntemi ile tüm nitelikler ve ayrıca altı farklı optimizasyon yönteminin verdiği nitelikler kullanılarak oluşturulan modellerin karşılaştırıldığı çizgi grafiği Şekil 4.13'te gösterilmiştir. En iyi sonuç tüm nitelikler kullanıldığında elde edilmiştir.




Şekil 4.13. Nitelik seçimleriyle C ürünü karar ormanı talep tahmin modelleri.

C ürünü karar ormanı modeline ait gerçek değerlerin ve tahmin değerlerinin karşılaştırıldığı çizgi grafiği Şekil 4.14'te gösterilmiştir. Tahmin modelinde en yüksek hataların 87, 90, 91 ve 92. dönemlerde olduğu görülmüştür. 84, 85, 86, 88 ve 89. dönemlerde ise en iyi tahminleri sağlamıştır. Model 90. döneme kadar gerçek sipariş trendini yakalamayı başarmıştır. 91 ve 92 numaralı dönemlerde ise düşüş ve yükseliş trendini yakalamasına rağmen trenddeki değişimi değerlerinden çok daha yüksek sonuçlar vermiştir. Aynı şekilde 87. dönemde de değişim takip edilebilmiştir ancak gerçek değerden daha yüksek tahmin sonucu elde edilmiştir. Model belirlenmiş olan performans ölçütlerine göre değerlendirildiğinde MSE değeri 1244014, RMSE değeri 1115, MAE değeri 842 ve MAPE değeri %11,6 bulunmuştur.




Şekil 4.14. Tüm niteliklerle C ürünü karar ormanı talep tahmin modeli.

D ürünü karar ormanı makine öğrenmesi yöntemi ile tüm nitelikler ve ayrıca altı farklı optimizasyon yönteminin verdiği nitelikler kullanılarak oluşturulan modellerin karşılaştırıldığı çizgi grafiği Şekil 4.15'te gösterilmiştir. En iyi sonuç Genetik Optimizasyonu nitelikleri kullanıldığında elde edilmiştir.



Şekil 4.15. Nitelik seçimleriyle D ürünü karar ormanı talep tahmin modelleri.


D ürünü karar ormanı modeline ait gerçek değerlerin ve tahmin değerlerinin karşılaştırıldığı çizgi grafiği Şekil 4.16’da gösterilmiştir. Tahmin modelinde trendin gerçek değerlerin çizgi grafiğinin üzerinde seyrettiği gözlemlenmiştir. Grafikte 85. ve 91. dönemlerde hataların yüksek olduğu görülmüştür. Tahmin modelinin gerçek sipariş trendini genel olarak takip edebildiği görülmektedir. Model 89 numaralı döneme kadar gerçek sipariş miktarlarından daha düşük değerlerde tahminler sunmuştur. Siparişlerin zirve yaptığı dönemlerde ise siparişlerin artış yapacağı öngörülebilmıştır ancak bu dönemlerde mutlak hata değerleri yüksektir. Modelin yüksek doğruluk tahmin aralığında performans sergilemiştir. Tahmin modeli belirlenmiş olan performans ölçütlerine göre değerlendirildiğinde MSE değeri 20549, RMSE değeri 143, MAE değeri 100 ve MAPE değeri %8,5 bulunmuştur.



Şekil 4.16. Genetik optimizasyonu ile D ürünü karar ormanı talep tahmin modeli.


4.3. Lineer Regresyon Tahmin Modelleri

A ürünü lineer regresyon yöntemine ait modellerin karşılaştırıldığı çizgi grafikleri Şekil 4.17’de gösterilmiştir. Yerçekimi optimizasyonu en başarılı sonucu vermiştir.




Şekil 4.17. Nitelik seçimleriyle A ürünü lineer regresyon talep tahmin modelleri.

A ürünü lineer regresyon modeline ait gerçek değerlerin ve tahmin değerlerinin karşılaştırıldığı çizgi grafiği Şekil 4.18’de gösterilmiştir. Tahmin modeline ait çizgi grafiği incelendiğinde bazı dönemlerde gerçek değerlere yakın tahminler sağlamasına rağmen model genel olarak yüksek doğruluk vermemiştir. Düşük sipariş dönemlerinde model gerçek verileri daha iyi yakalamıştır. Model belirlenmiş olan performans ölçütlerine göre değerlendirildiğinde MSE değeri 1317273, RMSE değeri 1148, MAE değeri 912 ve MAPE değeri %10,6 bulunmuştur.




Şekil 4.18. Yerçekimi optimizasyonu A ürünü lineer regresyon tahmin modeli.

B ürünü lineer regresyon makine öğrenmesi yöntemi ile tüm nitelikler ve ayrıca altı farklı optimizasyon yönteminin verdiği nitelikler kullanılarak oluşturulan modellerin karşılaştırıldığı çizgi grafiği Şekil 4.19’da gösterilmiştir. En iyi sonuç Harris Şahini Optimizasyonu ile elde edilmiştir.




Şekil 4.19. Nitelik seçimleriyle B ürünü lineer regresyon talep tahmin modelleri.

B ürünü lineer regresyon modeline ait gerçek değerlerin ve tahmin değerlerinin karşılaştırıldığı çizgi grafiği Şekil 4.20’de gösterilmiştir. Tahmin modeli gerçek verilerin en yüksek ve en düşük olduğu dönemler haricinde gerçek değerler ile tahmin değerleri arasındaki fark düşük çıkmıştır. Model performansı yüksek doğruluk aralığında bulunmaktadır. Model belirlenmiş olan performans ölçütlerine göre değerlendirildiğinde MSE değeri 9699, RMSE değeri 98, MAE değeri 66 ve MAPE değeri %5,3 bulunmuştur.




Şekil 4.20. Harris şahini ile B ürünü lineer regresyon talep tahmin modeli.

C ürünü lineer regresyon makine öğrenmesi yöntemi ile tüm nitelikler ve ayrıca altı farklı optimizasyon yönteminin verdiği nitelikler kullanılarak oluşturulan modellerin karşılaştırıldığı çizgi grafiği Şekil 4.21’de gösterilmiştir. En iyi sonuç Parçacık Sürüsü Optimizasyonu ile elde edilmiştir.




Şekil 4.21. Nitelik seçimleriyle C ürünü lineer regresyon talep tahmin modelleri.

C ürünü lineer regresyon modeline ait gerçek değerlerin ve tahmin değerlerinin karşılaştırıldığı çizgi grafiği Şekil 4.22’de gösterilmiştir. Grafikte incelendiğinde modelin genel olarak daha yüksek tahmin değerleri verdiği görülmektedir. Model siparişlerin trendini yakalamayı başarmasına karşın 91 ve 92. dönemde yüksek hata ile karşılaşmıştır. Model belirlenmiş olan performans ölçütlerine göre değerlendirildiğinde MSE değeri 1659965, RMSE değeri 1288, MAE değeri 1019 ve MAPE değeri %14,6 bulunmuştur.




Şekil 4.22. Parçacık sürüsü ile C ürünü lineer regresyon talep tahmin modeli.

D ürünü lineer regresyon makine öğrenmesi yöntemi ile tüm nitelikler ve ayrıca altı farklı optimizasyon yönteminin verdiği nitelikler kullanılarak oluşturulan modellerin karşılaştırıldığı çizgi grafiği Şekil 4.23'te gösterilmiştir. En iyi sonucun yerçekimi optimizasyonu ile elde edildiği görülmüştür.



Şekil 4.23. Nitelik seçimleriyle D ürünü lineer regresyon talep tahmin modelleri.


D ürünü lineer regresyon modeline ait gerçek değerlerin ve tahmin değerlerinin karşılaştırıldığı çizgi grafiği Şekil 4.24'te gösterilmiştir. Tahmin modeli ilk ve son dönem haricindeki dönemlerde gerçek verilerden daha düşük tahmin çıktıları vermiştir. Modelin düşüş ve yükseliş trendini yeterince takip edemediği grafikten görülebilmektedir. Dönemler arasında siparişlerin dip yaptığı noktalarda ise tahmin ve gerçek değerler arasındaki fark daha az olmuştur. Model belirlenmiş olan performans ölçütlerine göre değerlendirildiğinde MSE değeri 47455, RMSE değeri 218, MAE değeri 164 ve MAPE değeri %14,3 bulunmuştur.



Şekil 4.24. Yerçekimi optimizasyonu D ürünü lineer regresyon tahmin modeli.


4.4. Yöntemlerin Performans Ölçüt Değerlerinin Karşılaştırılması

Kullanılan yöntemlere göre ortalama kare hatalarını (MSE) gösteren grafik Şekil 4.25'te verilmiştir. Tüm ürünler için kurulan lineer regresyon modellerinde MSE hata değerlerinin diğer yöntemlere göre daha yüksek olduğu görülmektedir. İkinci en yüksek hatayı veren yöntem ise karar ormanı olmuştur. Tüm ürünler için yapay sinir ağları ile kurulan modellerde en düşük MSE değerleri gözlenmektedir. MSE ölçütüne göre performans değerlendirilmesi yapıldığında tüm modellerde yapay sinir ağları yönteminin en doğru sonuçları verdiği görülmüştür. Yapay sinir ağlarından sonra karar ormanı yöntemi lineer regresyon yöntemlerine göre daha iyi sonuçlar sunmuştur.




Şekil 4.25. Ürün ve yöntemlere göre Ortalama Kare Hata değerleri.

Yapay sinir ağları, karar ormanı ve lineer regresyon yöntemleriyle kurulan modellerinin kök ortalama kare hataları (RMSE) Şekil 4.26’da gösterilmiştir. A, C ve D ürün modellerinde lineer regresyon yöntemi en yüksek RMSE hata değerlerini vermektedir. B ürününde ise lineer regresyon yöntemi karar ormanı ile aynı RMSE değerine sahiptir. Karar ormanı yöntemi ile yapay sinir ağları yöntemi karşılaştırıldığında karar ormanı daha yüksek RMSE hata değerlerine sahiptir. Tüm ürünler için yapay sinir ağları ile kurulan modellerde en düşük RMSE değerleri gözlenmektedir. RMSE ölçütüne göre performans değerlendirilmesi yapıldığında tüm modellerde yapay sinir ağları yönteminin en doğru sonuçları verdiği görülmüştür. Yapay sinir ağlarından sonra karar ormanı yöntemi lineer regresyon yöntemlerine göre daha iyi sonuçlar sunmuştur.




Şekil 4.26. Ürün ve yöntemlere göre Kök Ortalama Kare Hata değerleri.

Yöntemlere göre modellerin ortalama mutlak hatalarının incelendiği (MAE) grafiği Şekil 4.27’de gösterilmiştir. Ortalama mutlak hatalara göre yapılan değerlendirmede B ürünüde karar ormanı ve yapay sinir ağıları yöntemlerinin hata değerlerinin eşit olduğu görülmektedir. A, C ve D ürünlerine ait tahmin modellerinde ise hatalar karar ormanı yönteminde daha yüksektir. En yüksek hata değerlerinin lineer regresyon yöntemiyle kurulan modellerde, en düşük hata değerlerinin ise yapay sinir ağıları yöntemiyle kurulan modellerde olduğu gözlemlenmiştir. MAE değerlerine göre en iyi performansı yapay sinir ağıları sağlamıştır. Yapay sinir ağlarının performansını sırasıyla karar ormanı ve lineer regresyon modelleri izlemiştir.



Şekil 4.27. Ürün ve yöntemlere göre Ortalama Mutlak Hata değerleri.

Ortalama mutlak yüzde hatalara (MAPE) göre yöntemlerin karşılaştırıldığı sütun grafiği Şekil 4.28’de gösterilmektedir. Yapay sinir ağıları yöntemiyle kurulan tüm modellerde %10’dan düşük hata değerleri gözlemlenmiştir. Karar ormanı ile kurulan modellerde ise 1 modelde %10’dan düşük, 3 modelde %0-10 aralığında hata yüzdesi ile karşılaşılmıştır. Lineer regresyon yönteminde 1 modelin %10 hatanın altında kaldığı, 3 modelin %10-20 hata yüzde aralığında bulunduğu görülmektedir. MAPE ölçütüne göre yapılan değerlendirme sonucunda en iyi sonuca sırasıyla yapay sinir ağıları, karar ormanı ve lineer regresyon modelleriyle ulaşılmıştır.



Şekil 4.28. Ürün ve yöntemlere göre Ortalama Mutlak Yüzde Hata değerleri.

5. TARTIŞMA VE SONUÇ

Bu çalışma kapsamında geliştirilen modeller farklı talep tahmin yöntemlerine göre karşılaştırılmıştır. Bu çalışmada kaynaklı çelik imalat ürünleri için seçilen 4 farklı ürün, 3 farklı makine öğrenme algoritması ve 7 nitelik seçimli ve seçimsiz durum için 84 (4x3x7) farklı model geliştirilmiş ve bu modeller performans ölçütleri açısından değerlendirilmiştir.

Tablo 5.1’de geliştirilen modellerin doğruluk değerleri ve performans değerlendirmesi verilmiştir.

Tablo 5.1. Yöntemlerin doğruluklarının karşılaştırması.

Makine Öğrenmesi Yöntemi	Nitelikler-Optimizasyon Yöntemi	Ürün	Doğruluk Değeri	Performans Değerlendirmesi
Yapay Sinir Ağları	Tüm Nitelikler	A	%93,6	Yüksek Doğrulukta Tahmin
	Harris Şahini Optimizasyonu	B	%93,8	Yüksek Doğrulukta Tahmin
	Genetik Optimizasyonu	C	%90,3	Yüksek Doğrulukta Tahmin
	Tüm Nitelikler	D	%90,0	Yüksek Doğrulukta Tahmin
Karar Ormanı	Genetik Optimizasyonu	A	%91,4	Yüksek Doğrulukta Tahmin
	Harris Şahini Optimizasyonu	B	%93,9	Yüksek Doğrulukta Tahmin
	Tüm Nitelikler	C	%88,4	İyi Tahmin
	Genetik Optimizasyonu	D	%91,5	Yüksek Doğrulukta Tahmin
Linner Regresyon	Yerçekimi Optimizasyonu	A	%89,4	İyi Tahmin
	Harris Şahini Optimizasyonu	B	%94,7	Yüksek Doğrulukta Tahmin
	Parçacık Sürüsü Optimizasyonu	C	%85,4	İyi Tahmin
	Yerçekimi Optimizasyonu	D	%85,7	İyi Tahmin

Tablo 5.1’den görüleceği üzere yapay sinir ağları yöntemiyle kurulan 4 model yüksek doğrulukta tahmin gerçekleştirmiştir. Karar ormanı yöntemiyle ise 3 modelde yüksek

doğrulukta tahmin, 1 modelde iyi tahmin elde edilmiştir. Lineer regresyon yöntemi ile oluşturulan modellerden 1 modelde yüksek doğrulukta tahmin, 3 modelde iyi tahmin değerleri elde edilmiştir. Yüksek doğruluklu tahminlerin elde edilmesinde en önemli etkenlerden biri veri ön işleme yöntemlerinden olan veri öteleme yönteminin kullanılması olmuştur. Veri öteleme sayesinde geçmiş dönemlerle son dönemler arasındaki veri trendlerindeki farklar en aza indirilerek daha düşük hataya sahip tahminler elde edilebilmiştir. Veri öteleme yapılmadığında ise talep tahmin miktarlarının test dönemlerinde gerçek talep miktarlarına göre çok yüksek ya da çok düşük kaldığı gözlemlenmiştir. Ayrıca farklı ürünlerde farklı talep dağılımları olması ve çeşitli tahmin metotlarının kullanılması sonucunda farklı nitelik seçimleri yapılması gerektiği görülmüştür. Farklı ürünler ve tahmin yöntemleri kullanıldığında, nitelik seçimlerinin değiştirilmesinin daha iyi tahminler sağladığı sonucuna ulaşılmıştır.

Yapay sinir ağları yönteminin bu çalışmada olduğu gibi başka talep tahmin çalışmalarında kullanılması durumunda yüksek doğrulukta tahminler sağlayarak araştırmadaki hedefleri gerçekleştireceği öngörülmektedir. Tedarik zinciri yönetiminde yapay sinir ağlarının kullanılması işletmeye amaçlanan faydaları sağlayacaktır. Karar ormanı yönteminin kullanılması durumunda ise yapay sinir ağlarında olduğu gibi genel olarak yüksek doğrulukta tahminler elde edilebilmektedir. Elde edilen yüksek doğruluk seviyesindeki tahminler yine benzer şekilde işletmeye istenen faydaları biraz daha düşük düzeyde sağlayacaktır. Lineer regresyon modeli ise iyi tahminler sağlayabileceği gibi diğer yöntemler yerine tercih edilmesine gerek görülmemektedir. Sonuç olarak arzu edilen katkılar için en doğru tercihin yapay sinir ağları modeli olduğu görülmektedir.

Gelecekte çalışmayı genişletmek adına farklı çalışmalar yapılabilir. Bu doğrultuda farklı veri seti büyüklükleri ya da farklı bağımsız değişkenler ile uygulama çalışması yeniden değerlendirilebilir. Ayrıca aynı veri setinin farklı veri bölme yüzdeleri kullanılarak sonuçların nasıl değiştiği gözlemlenebilir. Gelecek araştırmalarda derin öğrenme yöntemlerinden RNN, Evrimsel Sinir Ağları (CNN), Uzun Kısa Dönemli Bellek (LSTM), DNN yöntemleriyle çalışmanın tekrarlanması da bir diğer seçenek olabilir. Bu sayede derin öğrenme ile tahmin doğruluğunun makine öğrenmesi sinir ağları yöntemlerine göre doğruluğunun karşılaştırması yapılabilir. Benzer şekilde derin öğrenme yöntemlerinin farklı kombinasyonları ile yöntemlerin doğruluğunun artırılıp artırılamayacağı başka bir potansiyel çalışma konusu olabilir.

KAYNAKLAR

- Abbate, R., Manco, P., Caterino, M., Fera, M., & Macchiaroli, R. (2022). Demand forecasting for delivery platforms by using neural network. *IFAC-PapersOnLine*, 55(10), 607-612. <https://doi.org/10.1016/j.ifacol.2022.09.465>
- Abolghasemi, M., Beh, E., Tarr, G., & Gerlach, R. (2020). Demand forecasting in supply chain: The impact of demand volatility in the presence of promotion. *Computers & Industrial Engineering*, 142, 106380. <https://doi.org/10.1016/j.cie.2020.106380>
- Acı, M., & Doğanşoy, G. A. (2022). Makine öğrenmesi ve derin öğrenme yöntemleri kullanılarak e-perakende sektörüne yönelik talep tahmini. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 37(3), 1325-1340. <https://doi.org/10.23834/isrjournal.1289745>
- Adalı, E. (2020). *Makine imalat sanayiinde talep tahmini: Elektromekanik sanayiinde bir uygulama* [Yüksek lisans tezi]. Balıkesir Üniversitesi.
- Akbaş, B. C. (2022). *Tedarik zinciri yönetiminde yapay zeka tabanlı talep tahmini: bir tekstil firmasında uygulama* [Yüksek lisans tezi]. Akdeniz Üniversitesi.
- Akdağ, O., Ateş, A., & Yeroğlu, C. (2020). Harris Şahini Optimizasyon Algoritması ile Aktif Güç Kayıplarının Minimizasyonu. *Dokuz Eylül Üniversitesi Mühendislik Fakültesi Fen ve Mühendislik Dergisi*, 22(65), 481-490. <https://doi.org/10.21205/deufmd.2020226516>
- Akdağ, R. (2016). Yapay Sinir Ağları, Destek Vektör Makineleri ve Box-Jenkins Yöntemleriyle Kentsel İçmesuyu Talebi Tahmini ve Karşılaştırmalı Analizi. *Business & Economics Research Journal*, 7(1). <http://doi.org/10.20409/berj.2016116808>
- Aksoy, S. (2008). *Kurumsal kaynak planlaması yazılımlarında talep tahmin yöntemleri ve uygulamaları*. [Yüksek lisans tezi]. İstanbul Üniversitesi.
- Akto, İ. (2021). *Gri Kurt Optimizasyon Algoritmasının Veri Madenciliği Problemlerine Uygulanması* [Yüksek lisans tezi]. Necmettin Erbakan Üniversitesi.
- Alkap, M. (2019). *Yapay sinir ağları yöntemiyle talep tahmini: İplik fabrikası örneği* [Yüksek lisans tezi]. Kahramanmaraş Sütçü İmam Üniversitesi.
- Alobaidi, D. H. M. A. (2022). *Evaluation of Automobile Demand Forecast in Turkey Using Artificial Neural Networks* [Doktora Tezi]. Karabuk University.
- Atay, M., Eroğlu, Y., & Seçkiner, S. U. (2019). Yapay Sinir Ağları ve Adaptif Nörobülün Sistemler ile 3. İstanbul Havalimanı Talep Tahmini ve Türk Hava Yolları İç Hat Filo Optimizasyonu. *Endüstri Mühendisliği Dergisi*, 30(2), 141-156.
- Aydın Çakır, M. (2017). *Giyim endüstrisinde talep tahmin yöntemlerinin uygulanması: Örnek bir uygulama*. [Yüksek Lisans Tezi]. Selçuk Üniversitesi.

- Aydın, M. R. (2019). Yapay Sinir Ağları ile Talep Tahmini: Perakende Sektöründe Bir Uygulama. *İstanbul Ticaret Üniversitesi Fen Bilimleri Dergisi*, 18(35), 43-55.
- Bee-Hua, G. (2000). Evaluating the performance of combining neural networks and genetic algorithms to forecast construction demand: the case of the Singapore residential sector. *Construction Management & Economics*, 18(2), 209-217. <https://doi.org/10.1080/014461900370834>
- Bufalo, M., & Orlando, G. (2023). A three-factor stochastic model for forecasting production of energy materials. *Finance Research Letters*, 51, 103356. <https://doi.org/10.1016/j.frl.2022.103356>
- Calp, M. H. (2019). İşletmeler için personel yemek talep miktarının yapay sinir ağları kullanılarak tahmin edilmesi. *Politeknik Dergisi*, 22(3), 675-686. <https://doi.org/10.2339/politeknik.444380>
- Chakure, A. (2019). Random Forest Classification. *Computing, Information Systems & Development Informatics Journal*, 11(1), 39-48. <https://doi.org/10.23939/jcpee2021.02.001>
- Co, H. C., & Boosarawongse, R. (2007). Forecasting Thailand's rice export: Statistical techniques vs. artificial neural networks. *Computers & industrial engineering*, 53(4), 610-627. <https://doi.org/10.1016/j.cie.2007.06.005>
- Çuhadar, M., Güngör, İ. ve Göksu, A., (2009), Turizm Talebinin Yapay Sinir Ağları İle Tahmini ve Zaman Serisi Yöntemleri İle Karşılaştırmalı Analizi: Antalya İline Yönelik Bir Uygulama, *Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, Cilt: 14, Sayı:1, ss. 99-114.
- Dedeoglu, T., & Çetin, O. (2021). Sağlık sektöründe hasta talebinin tahmini. *Trakya Üniversitesi İktisadi ve İdari Bilimler Fakültesi E-Dergi*, 10(1), 25-38. <https://doi.org/10.47934/tife.10.01.03>
- Dey, B., Roy, B., Datta, S., & Ustun, T. S. (2023). Forecasting ethanol demand in India to meet future blending targets: A comparison of ARIMA and various regression models. *Energy Reports*, 9, 411-418. <https://doi.org/10.1016/j.egyr.2022.11.038>
- Dinç, M., (2021). *Yapay Zeka Tabanlı Talep Tahmin Yöntemlerinin Performans Üstünlükleri Açısından Değerlendirilmesi: Gıda Sektöründe Bir Uygulama* [Yüksek lisans tezi]. Manisa Celal Bayar Üniversitesi.
- Dobbin, K. K., & Simon, R. M. (2011). Optimally splitting cases for training and testing high dimensional classifiers. *BMC medical genomics*, 4(1), 1-8. doi: 10.1186/1755-8794-4-31
- Efendigil, T., & Eminler, Ö. E. (2017). Havacılık sektöründe talep tahminin önemi: Yolcu talebi üzerine bir tahmin modeli. *Yaşar Üniversitesi E-Dergisi*, 12, 14-30.
- El Filali, A., El Filali, S., & Jadli, A. (2022, July). Application of Deep Learning in the Supply Chain Management: A comparison of forecasting demand for electrical products using different ANN methods. *International Conference on Electrical, Computer and Energy Technologies*, 1-7. doi: 10.1109/HORA52670.2021.9461186

- Elmir, W. B., Hemmak, A., & Senouci, B. (2023). Smart platform for data Blood Bank management: Forecasting demand in blood supply chain using machine learning. *Information*, 14(1), 31. <https://doi.org/10.3390/info14010031>
- Engin, B. (2022). *Yapay sinir ağı metodu ile bir tekstil firmasında hammadde siparişi için talep tahmini uygulaması* [Yüksek Lisans Tezi]. Sakarya Üniversitesi.
- Fanoodi, B., Malmir, B., & Jahantigh, F. F. (2019). Reducing demand uncertainty in the platelet supply chain through artificial neural networks and ARIMA models. *Computers in biology and medicine*, 113, 103415. <https://doi.org/10.1016/j.combiomed.2019.103415>
- Feizabadi, J. (2022). Machine learning demand forecasting and supply chain performance. *International Journal of Logistics Research and Applications*, 25(2), 119-142. <https://doi.org/10.1080/13675567.2020.1803246>
- Gençalp, E., (2020), *ATM Demand Prediction with Machine Learning Methods* [Yüksek lisans tezi]. Galatasaray University.
- Ghiassi, M., & Nangoy, S. (2009). A dynamic artificial neural network model for forecasting nonlinear processes. *Computers & Industrial Engineering*, 57(1), 287-297. <https://doi.org/10.1016/j.cie.2008.11.027>
- Gholamy, A., Kreinovich, V., & Kosheleva, O. (2018). Why 70/30 or 80/20 relation between training and testing sets: A pedagogical explanation. *Departmental Technical Reports Computer Science*, 1209.
- Gollo, L. L. (2008). *Synchronization between populations of neurons* [Yüksek lisans tezi]. Universitat de les Illes Balears.
- Gonçalves, J. N., Cortez, P., Carvalho, M. S., & Frazao, N. M. (2021). A multivariate approach for multi-step demand forecasting in assembly industries: Empirical evidence from an automotive supply chain. *Decision Support Systems*, 142, 113452. <https://doi.org/10.1016/j.dss.2020.113452>
- Gökler, S. H. (2020). *Kan Bankalarında Talep Tahmini ve Stokastik Stok Yönetimi* [Doktora tezi]. Sakarya Üniversitesi.
- Gül, B., S., (2021). *Hareketli Ortalama, Üstel Düzeltme, ve Trend Analizi Yöntemleri ile Talep Tahmini: İlaç Sektöründe Bir Uygulama* [Yüksek lisans tezi]. Konya Gıda ve Tarım Üniversitesi.
- Güven, İ. (2020). *Perakende Hazır Giyim Endüstrisinde Yapay Zeka Yöntemleri ile Talep Tahmini* [Doktora tezi]. Karabük Üniversitesi.
- Han, G., Sönmez, E. F., Avcı, S., & Aladağ, Z. (2022). Uygun Normalizasyon Tekniği ve Yapay Sinir Ağları Analizi ile Otomobil Satış Tahminlemesi. *İşletme Ekonomi ve Yönetim Araştırmaları Dergisi*, 5(1), 19-45. <https://doi.org/10.33416/baybem.1001149>
- Hao, W., Cominola, A., & Castelletti, A. (2022). Comparing Predictive Machine Learning Models for Short-and Long-Term Urban Water Demand Forecasting in Milan, Italy. *IFAC-PapersOnLine*, 55(33), 92-98. <https://doi.org/10.1016/j.ifacol.2022.11.015>

- Heidari, A. A., Mirjalili, S., Faris, H., Aljarah, I., Mafarja, M., & Chen, H. (2019). Harris hawks optimization: Algorithm and applications. *Future generation computer systems*, 97, 849-872. doi: 10.1016/j.future.2019.02.028
- Heizer, J. H., & Render, B. (2006). *Operations Management*. (Global Edition). Pearson.
- Hussein, F., Kharma, N., & Ward, R. (2001). Genetic algorithms for feature selection and weighting, a review and study. *Proceedings of Sixth International Conference on Document Analysis and Recognition*, 1240-1244. <https://doi.org/10.1016/j.ifacol.2022.11.014>
- Huyen, C. (2022). *Designing machine learning systems*. O'Reilly Media.
- Hyndman, R. J., & Koehler, A. B. (2006). Another look at measures of forecast accuracy. *International journal of forecasting*, 22(4), 679-688. <https://doi.org/10.1016/j.ijforecast.2006.03.001>
- İmece, S. (2019). *Demand Forecasting with Individual and Combined Models in Pharmaceutical Industry*. [Yüksek lisans tezi]. Istanbul Technical University.
- Jain, C. L., & Malehorn, J. (2012). *Fundamentals of demand planning & forecasting*. Graceway Publ.
- Kapkın, A., N., (2018). *Sanayideki Enerji Yük Tahmin Modelleri* [Doktora tezi]. İstanbul Üniversitesi.
- Karaatlı, M., Helvacıoğlu, Ö. C., Ömürbek, N., & Tokgöz, G. (2012). Yapay sinir ağları yöntemi ile otomobil satış tahmini. *Uluslararası Yönetim İktisat ve İşletme Dergisi*, 8(17), 87-100. <https://doi.org/10.11122/ijmeb.2012.8.17.290>
- Keung, K. L., Lee, C. K., & Yiu, Y. H. (2021). A machine learning predictive model for shipment delay and demand forecasting for warehouses and sales data. *International Conference on Industrial Engineering and Engineering Management*, 1010-1014. doi: 10.1109/IEEM50564.2021.9672946.
- Kılınç, N., & Çakır Aydın, M. (2016). Hazır giyim işletmelerinde beden numaralarına göre oluşacak talebin belirlenmesi: Örnek bir uygulama ve karşılaştırma. *KMÜ Sosyal ve Ekonomik Araştırmalar Dergisi*, 18 (31), 30-35.
- Kobu, B. (2003). *Üretim Yönetimi* (10. Baskı). Avcıol Basım Yayın.
- Kochak, A., & Sharma, S. (2015). Demand forecasting using neural network for supply chain management. *International journal of mechanical engineering and robotics research*, 4(1), 96-104. <https://doi.org/10.1016/j.ifacol.2022.09.465>
- Kolassa, S., & Siemsen, E. (2016). *Demand forecasting for managers*. Business Expert Press.
- Korkut, D. (2019). *Yapay sinir ağları yöntemi ile talep tahmini ve ayakkabı sektörüne uygulaması*. [Yüksek lisans tezi]. Hacı Bayram Veli Üniversitesi.
- Köse, B., Aygün, H., & Pak, S. (2023). Parameter estimation of the wind speed distribution model by dragonfly algorithm. *Journal of the Faculty of Engineering and Architecture of Gazi University*, 38(3), 1747-1756. doi: 10.17341/gazimmfd.935689

- KS, S. R., & Murugan, S. (2017). Memory based hybrid dragonfly algorithm for numerical optimization problems. *Expert Systems with Applications*, 83, 63-78. <https://doi.org/10.1016/j.eswa.2017.04.033>
- Kück, M., & Freitag, M. (2021). Forecasting of customer demands for production planning by local k-nearest neighbor models. *International Journal of Production Economics*, 231, 107837. <https://doi.org/10.1016/j.ijpe.2020.107837>
- Lazzeri, F. (2020). *Machine learning for time series forecasting with Python*. John Wiley & Sons.
- Lee, H., Kim, S. G., Park, H. W., & Kang, P. (2014). Pre-launch new product demand forecasting using the Bass model: A statistical and machine learning-based approach. *Technological Forecasting and Social Change*, 86, 49-64. <https://doi.org/10.1016/j.techfore.2013.08.020>
- Lee, K. H., Abdollahian, M., Schreider, S., & Taheri, S. (2023). Supply Chain Demand Forecasting and Price Optimisation Models with Substitution Effect. *Mathematics*, 11(11), 1-28. <https://doi.org/10.3390/math11112502>
- Lewis, C.D. (1982) *Industrial and Business Forecasting Methods*. Butterworths Publishing.
- Lingireddy, S., & Ormsbee, L. E. (2002). Hydraulic network calibration using genetic optimization. *Civil Engineering and Environmental Systems*, 19(1), 13-39. <https://doi.org/10.29130/dubited.1158728>
- Maisel, F., Neef, C., Marscheider-Weidemann, F., & Nissen, N. F. (2023). A forecast on future raw material demand and recycling potential of lithium-ion batteries in electric vehicles. *Resources, Conservation and Recycling*, 192, 106920. <https://doi.org/10.1016/j.resconrec.2023.106920>
- Matino, I., Dettori, S., Colla, V., Weber, V., & Salame, S. (2019). Forecasting blast furnace gas production and demand through echo state neural network-based models: Pave the way to off-gas optimized management. *Applied Energy*, 253, 113578. <https://doi.org/10.1016/j.apenergy.2019.113578>
- Mediavilla, M. A., Dietrich, F., & Palm, D. (2022). Review and analysis of artificial intelligence methods for demand forecasting in supply chain management. *Procedia CIRP*, 107, 1126-1131. <https://doi.org/10.1016/j.procir.2022.05.119>
- Mentzer, J. T., & Moon, M. A. (2004). *Sales forecasting management: a demand management approach*. Sage Publications.
- Merkuryeva, G., Valberga, A., & Smirnov, A. (2019). Demand forecasting in pharmaceutical supply chains: A case study. *Procedia Computer Science*, 149, 3-10. <https://doi.org/10.1016/j.procs.2019.01.100>
- Miguéis, V. L., Pereira, A., Pereira, J., & Figueira, G. (2022). Reducing fresh fish waste while ensuring availability: Demand forecast using censored data and machine learning. *Journal of Cleaner Production*, 359, 131852. <https://doi.org/10.1016/j.jclepro.2022.131852>
- Mohan, B. A., Harshavardhan, B., Karan, S., Shariff, M. J., & Pranav, M. G. (2021). Demand forecasting and route optimization in supply chain industry using data Analytics. *Asian Conference on Innovation in Technology*, 1-7. doi: 10.1109/ASIANCON51346.2021.9544942

- Nasuhoglu, H. (2019). Eczacılık sektöründe yapay sinir ağıları ve zaman serileri analizi ile talep tahmini [Yüksek lisans tezi]. Maltepe Üniversitesi.
- Omella, M., Esnaola-Gonzalez, I., Ferreira, S., & Sierra, B. (2021). k-Nearest patterns for electrical demand forecasting in residential and small commercial buildings. *Energy and Buildings*, 253, 111396. <https://doi.org/10.3390/su151712951>
- Orzechowski, A., Lugosch, L., Shu, H., Yang, R., Li, W., & Meyer, B. H. (2023). A data-driven framework for medium-term electric vehicle charging demand forecasting. *Energy and AI*, 14, 100267. <https://doi.org/10.1016/j.egyai.2023.100267>
- Özger, Y., Akpınar, M., Musayev, Z., & Yaz, M. (2019). Electrical load forecasting using genetic algorithm based holt-winters exponential smoothing method. *Sakarya University Journal of Computer and Information Sciences*, 3(2), 108-123. <https://doi.org/10.35377/saucis.02.02.600620>
- Özkaya, E., Arslan, H., & Şen, O. T. (2021). Particle Swarm Optimization Method Based Controller Tuning for Adaptive Cruise Control Application. *Gazi University Journal of Science*, 34(2), 517-527. <https://doi.org/10.35378/gujs.762103>
- Öztemel, E. (2006). *Yapay sinir ağıları*. Papatya.
- Papa, J. P., Pagnin, A., Schellini, S. A., Spadotto, A., Guido, R. C., Ponti, M., Chiachia, G. & Falcão, A. X. (2011, May). Feature selection through gravitational search algorithm. *International Conference on Acoustics, Speech and Signal Processing*, 2052-2055. doi: 10.1109/ICASSP.2011.5946916
- Persson, H., & Wilhelmsson, E. (2018). The impact of omni-channel retailing on demand planning for new products at IKEA. *Management review*, 54(1), 27-35.
- Poli, R., Kennedy, J., & Blackwell, T. (2007). Particle swarm optimization: An overview. *Swarm intelligence*, 1, 33-57. <http://dx.doi.org/10.1007/s11721-007-0002-0>
- Robus, S., Walter, V., & Kömüves, Z. (2022). An Overview of Performance Measurement for Demand Forecasting Based on Artificial Neural Networks. *Regional and Business Studies*, 14(2), 5-20. doi: 10.33568/rbs.4434
- Rumsey, D. J. (2016). *Statistics for dummies*. John Wiley & Sons.
- Saha, P., Gudheniya, N., Mitra, R., Das, D., Narayana, S., & Tiwari, M. K. (2022). Demand forecasting of a multinational retail company using deep learning frameworks. *IFAC-PapersOnLine*, 55(10), 395-399. <https://doi.org/10.1016/j.ifacol.2022.09.425>
- Sauro, J., & Lewis, J. R. (2016). *Quantifying the user experience: Practical statistics for user research*. Morgan Kaufmann.
- Singha, D., & Panse, C. (2022). Application of different machine learning models for supply chain demand forecasting: comparative analysis. *2nd International Conference on Innovative Practices in Technology and Management*, 312-318. <https://doi.org/10.3390/computation11070141>

- Solak, A. O. (2013). Türkiye'nin Toplam Petrol Talebi ve Ulaştırma Sektörü Petrol Talebinin ARIMA Modeli ile Tahmin Edilmesi. *Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 18(3), 131-142.
- Spiliotis, E. (2022). Decision trees for time-series forecasting. *Foresight*, 1, 30-44.
- Tadayonrad, Y., & Ndiaye, A. B. (2023). A new key performance indicator model for demand forecasting in inventory management considering supply chain reliability and seasonality. *Supply Chain Analytics*, 3, 100026. <https://doi.org/10.1016/j.sca.2023.100026>
- Tavukçu, A. S., & Sennaroğlu, B. (2021). Applying Forecasting Methods to Reduce the Cost of Spare Parts Inventory in a Company. *Endüstri Mühendisliği*, 32(3), 396-413.
- Torun, Z., & DESTE, M. (2021). Sağlık İşletmelerinde Malzeme Yönetiminde Uygun Talep Tahmin Yönteminin Belirlenmesine Yönelik Bir Uygulama. *19 Mayıs Sosyal Bilimler Dergisi*, 2(3), 581-613. <https://doi.org/10.52835/19maysbd.908786>
- Tozkan, S., & Balık, H. H., (2004) *Yapay Sinir Ağları* [Bitirme tezi]. Fırat Üniversitesi.
- Türk, E., & Kiani, F. (2019). Yapay Sinir Ağları ile Talep Tahmini Yapma: Beyaz Eşya Üretim Planlama Örneği. *İstanbul Sabahattin Zaim Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 1(1), 30-37.
- Ünlü, V. (2021). *Demand Forecasting with Machine Learning Algorithm: Implementation in a Production Facility* [Doktora tezi]. Ankara Yıldırım Beyazıt Üniversitesi.
- Winters, P. R. (1960). Forecasting sales by exponentially weighted moving averages. *Management science*, 6(3), 324-342. <https://doi.org/10.1287/mnsc.6.3.324>
- Yadav, A., & Deep, K. (2013). Constrained optimization using gravitational search algorithm. *National Academy Science Letters*, 36, 527-534. doi: 10.1007/S40009-013-0165-8
- Yanık, E. (2019). *İş makineleri sektöründe yapay sinir ağları ile talep tahmini uygulaması* [Yüksek lisans tezi]. Kırıkkale Üniversitesi.
- Yani, L. P. E., & Aamer, A. (2023). Demand forecasting accuracy in the pharmaceutical supply chain: a machine learning approach. *International Journal of Pharmaceutical and Healthcare Marketing*, 17(1), 1-23. doi: 10.1108/IJPHM-05-2021-0056
- Yılmaz, H., & Tosun, Ö. (2020). Aylık Konut Satışlarının Modellenmesi ve Antalya Örneği. *Kafkas Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 11(21), 141-158. doi: 10.36543/kauibfd.2020.007
- Ying, Z., & Hanbin, X. (2010, August). Study on the model of demand forecasting based on artificial neural network. *Ninth International Symposium on Distributed Computing and Applications to Business, Engineering and Science*. 382-386. 573. doi: 10.17798/bitlisfen.1059772
- Yüksek, A. G. (2007). *Hava Kirliliği Tahmininde Çoklu Regresyon Analizi ve Yapay Sinir Ağları Yönteminin Karşılaştırılması*. [Doktora tezi]. Sivas Cumhuriyet Üniversitesi,

- Yüzük, F. (2019). *Çoklu Regresyon Analizi ve Yapay Sinir Ağları ile Türkiye Enerji Talep Tahmini* [Yüksek lisans tezi]. Sivas Cumhuriyet Üniversitesi.
- Zeng, D., Chen, L., Zhao, S., Ou, J., Yuan, H., & Wu, T. (2022). An Optimized Grey Wolf Algorithm. *International Conference on Sensing, Diagnostics, Prognostics, and Control*, 200-205. doi: 10.35378/gujs.820885
- Zorlutuna, Ş., & Bircan, H. (2019). Türkiye'ye Gelen Turist Sayısı Tahmininde Zaman Serileri Analizi ve Yapay Sinir Ağları Yöntemlerinin Karşılaştırılması. *Cumhuriyet Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 20(2), 164-185.



ÖZGEÇMİŞ

Ad-Soyad : Erhan KOR

ÖĞRENİM DURUMU:

- **Lisans** : 2016, İstanbul Teknik Üniversitesi, İnşaat Fakültesi, İnşaat Mühendisliği
- **Yüksek Lisans** : 2021, Sakarya Üniversitesi, Endüstri Mühendisliği Anabilim Dalı, Mühendislik Yönetimi (Tezsiz Yüksek Lisans)

MESLEKİ DENEYİM:

- 2016-2017 yılları arasında Gençali Yapı'da şantiye şefi olarak çalıştı.
- 2017-2018 yılları arasında Mavi Yapı'da şantiye şefi olarak çalıştı.
- 2019-2022 yılları arasında YILGENCİ San. ve Tic. A.Ş.'de üretim planlama mühendisi olarak çalıştı.
- 2022 yılından itibaren PERI Sakarya İskele ve Kalıp Üretim Sanayi Ticaret Limited Şirketi'nde proje mühendisi olarak çalışmaktadır.