T.C.
KASTAMONU ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
ORMAN MÜHENDİSLİĞİ ANA BİLİM DALI

MAKİNE ÖĞRENMESİ YAKLAŞIMLARI İLE TOMRUK SATIŞ FİYATLARININ MODELLENMESİ VE FİYAT TAHMİNİ

BÜŞRA ERGÜN KARAK

YÜKSEK LİSANS TEZİ

PROF. DR. GÖKHAN ŞEN

HAZİRAN - 2026
KASTAMONU

TEZ ONAYI

Büşra ERGÜN KARAK tarafından hazırlanan "**MAKİNE ÖĞRENMESİ YAKLAŞIMLARI İLE TOMRUK SATIŞ FİYATLARININ MODELLENMESİ VE FİYAT TAHMİNİ**" adlı tez çalışmasının savunma sınavı **23.06.2026** tarihinde yapılmış olup aşağıda verilen jüri tarafından oy birliği/oy çokluğu ile Kastamonu Üniversitesi Fen Bilimleri Enstitüsü **Orman Mühendisliği Ana Bilim Dalı Yüksek Lisans Tezi** olarak kabul edilmiştir.

Danışman	Prof. Dr. Gökhan ŞEN Kastamonu Üniversitesi	.....
Jüri Üyesi	Prof. Dr. Devlet TOKSOY Karadeniz Teknik Üniversitesi	.....
Jüri Üyesi	Doç. Dr. Fadime SAĞLAM Kastamonu Üniversitesi	.....

Jüri üyeleri tarafından kabul edilmiş olan bu tez Kastamonu Üniversitesi Fen Bilimleri Enstitüsü Yönetim Kurulunca onanmıştır.

Enstitü Müdürü Prof. Dr. Selahattin KAYMAKCI .....

TAAHHÜTNAME

Bu tezin tasarımı, hazırlanması, yürütülmesi, araştırmalarının yapılması ve bulgularının analizlerinde bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edilerek sunulduğunu; ayrıca tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını, bilimsel etiğe uygun olarak kaynak gösterildiğini bildirir ve taahhüt ederim.

Büşra ERGÜN KARAK

ÖZET

YÜKSEK LİSANS TEZİ

MAKİNE ÖĞRENMESİ YAKLAŞIMLARI İLE TOMRUK SATIŞ FİYATLARININ MODELLENMESİ VE FİYAT TAHMİNİ

BÜŞRA ERGÜN KARAK

KASTAMONU ÜNİVERSİTESİ FEN BİLİMLERİ ENSTİTÜSÜ
ORMAN MÜHENDİSLİĞİ ANA BİLİM DALI
DANIŞMAN: PROF. DR. GÖKHAN ŞEN

Bu çalışmada, Türkiye'de kızılçam normal boy tomruk açık artırmalı satış fiyatlarının makine öğrenmesi yöntemleri kullanılarak tahmin edilmesi amaçlanmıştır. Bu kapsamda, Orman Genel Müdürlüğü tarafından yayımlanan Ocak 2014–Aralık 2024 dönemine ait aylık satış verileri kullanılmıştır. Çalışmada, Türkiye'de kızılçam satışı gerçekleştirilen 21 Orman Bölge Müdürlüğüne ait veriler ile mevduat faiz oranı, sanayi üretim endeksi, TÜFE, ÜFE, döviz kuru, altın fiyatı, mazot fiyatı, gayrisafi yurt içi hasıla, ithalat ve ihracat göstergeleri modele dâhil edilmiştir. Modelleme sürecinde gecikmeli fiyat değişkenleri oluşturulmuş, kategorik değişkenler one-hot encoding yöntemiyle dönüştürülmüş ve Robust Scaler yöntemi kullanılarak veri ölçeklendirilmiştir. Çalışmada Linear Regression, Ridge Regression, Random Forest, XGBoost ve LightGBM algoritmaları uygulanmış; hiperparametre optimizasyonu Time Series Split tabanlı çapraz doğrulama yaklaşımı ile gerçekleştirilmiştir. Model performansları R^2, RMSE, MAE, NSE, KGE, MedAE ve sMAPE ölçütleri kullanılarak değerlendirilmiş, Entropi ve TOPSIS yöntemleri ile modeller sıralanmış, SHAP analizi ile değişken önem düzeyleri belirlenmiştir. Araştırma sonuçları, ağaç tabanlı makine öğrenmesi algoritmalarının doğrusal regresyon modellerine göre daha başarılı tahmin performansı sergilediğini göstermiştir. Performans değerlendirmeleri sonucunda XGBoost modeli en başarılı yöntem olarak belirlenmiştir. Ayrıca, 2025 yılına ait gerçek ve tahmin edilen fiyatlar karşılaştırılmış, XGBoost modeli kullanılarak 2026–2035 dönemine ilişkin fiyat projeksiyonları oluşturulmuştur. Sonuç olarak, geliştirilen modelin tomruk fiyatlarının tahmininde başarılı sonuçlar verdiği ve ormancılık ekonomisinde veri temelli karar verme süreçlerine katkı sağlayabilecek bir karar destek aracı niteliği taşıdığı değerlendirilmektedir.

ANAHTAR KELİMELER: Makine Öğrenmesi, Ormancılık Ekonomisi, Tomruk Fiyat Tahmini, XGBoost, Entropi, TOPSIS, SHAP Analizi

Haziran 2026, 93 Sayfa

ABSTRACT

MSC THESIS

MODELING AND PRICE FORECASTING OF LOG SALE PRICES USING MACHINE LEARNING APPROACHES

BÜŞRA ERGÜN KARAK

KASTAMONU UNIVERSITY INSTITUTE OF SCIENCE
DEPARTMENT OF FOREST ENGINEERING
SUPERVISOR: PROF. DR. GÖKHAN ŞEN

This study aimed to predict the auction sales prices of Turkish pine (*Pinus brutia*) standard-length logs in Türkiye using machine learning methods. Monthly auction sales data published by the General Directorate of Forestry covering the period from January 2014 to December 2024 were used. The dataset included sales data from 21 Regional Directorates of Forestry where Turkish pine logs are marketed, together with macroeconomic and market-related variables, including deposit interest rates, the industrial production index, the Consumer Price Index (CPI), the Producer Price Index (PPI), exchange rates, gold prices, diesel prices, gross domestic product (GDP), and import and export indicators. During the modelling process, lagged price variables were generated, categorical variables were transformed using one-hot encoding, and data were scaled using the Robust Scaler method. Linear Regression, Ridge Regression, Random Forest, XGBoost, and LightGBM algorithms were applied. Hyperparameter optimization was performed using a Time Series Split-based cross-validation approach. Model performance was evaluated using R^2, RMSE, MAE, NSE, KGE, MedAE, and sMAPE metrics. In addition, the models were ranked using the Entropy and TOPSIS methods, and the importance of predictor variables was examined through SHAP analysis. The results indicated that tree-based machine learning algorithms outperformed linear regression models in predicting log prices. Among the evaluated models, XGBoost achieved the best overall performance. Furthermore, actual and predicted prices for 2025 were compared to assess the model's predictive capability, and future price projections for the 2026–2035 period were generated using the XGBoost model. In conclusion, the proposed model demonstrated satisfactory performance in predicting log prices and has the potential to serve as a decision-support tool for data-driven decision-making in forest economics.

KEYWORDS: Machine Learning, Forest Economics, Log Price Forecasting, XGBoost, Entropy, TOPSIS, SHAP Analysis

June 2026, 93 Page

TEŞEKKÜR

Lisansüstü eğitimim ve tez çalışmam süresince bilgi, deneyim ve akademik birikimiyle bana yol gösteren, araştırmanın tüm aşamalarında değerli görüş, öneri ve desteklerini esirgemeyen kıymetli danışman hocam Sayın Prof. Dr. Gökhan ŞEN'e sonsuz şükranlarımı sunarım.

Tez jürimde yer alarak değerli görüş ve önerilerini paylaşan Sayın Prof. Dr. Devlet TOKSOY ve Sayın Doç. Dr. Fadime SAĞLAM hocalarıma teşekkürlerimi sunarım.

Ayrıca, akademik katkılarıyla çalışmama destek sağlayan Sayın Doç. Dr. Bahadır Çağrı BAYRAM hocama teşekkürlerimi sunarım.

Tez çalışmam boyunca gösterdikleri anlayış ve manevi destekleriyle yanımda olan değerli arkadaşlarım Arş. Gör. Tutku GENCAL ve Arş. Gör. Sevtap ERDOĞAN'a teşekkür ederim.

Tüm eğitim hayatım boyunca maddi ve manevi desteklerini her zaman yanımda hissettiğim ve her koşulda destek olan aileme teşekkür ederim.

Son olarak, tez çalışmam süresince ve hayatımın her döneminde desteği, anlayışı ve motivasyonu ile her zaman yanımda olan kıymetli eşim Furkan KARAK'a sonsuz teşekkür ederim.

BÜŞRA ERGÜN KARAK

Kastamonu, 2026

İÇİNDEKİLER

Sayfa

TEZ ONAYI ..... **ii**
TAAHHÜTNAME ..... **iii**
ÖZET ..... **iv**
ABSTRACT ..... **v**
TEŞEKKÜR ..... **vi**
İÇİNDEKİLER ..... **vii**
ŞEKİLLER DİZİNİ ..... **ix**
TABLOLAR DİZİNİ ..... **x**
SİMGELER VE KISALTMALAR DİZİNİ ..... **xi**
1. GİRİŞ **1**
1.1 Tomruk Satış Yöntemleri ve Fiyat Oluşum Mekanizmaları 3
1.2 Yapay Zeka ve Makine Öğrenmesinin Kavramsal Çerçevesi 7
1.3 Yapay Zekanın Tarihsel ve Kuramsal Gelişimi 8
1.4 Makine Öğrenmesi Yaklaşımları 9
1.4.1 Denetimli Öğrenme 11
1.4.2 Denetimsiz Öğrenme 12
1.4.3 Yarı Denetimli Öğrenme 12
1.4.4 Pekiştirmeli Öğrenme 13
1.5 Makine Öğrenmesi Uygulama Alanları ve Ormancılıkta Kullanımı 13
1.6 Araştırmanın Amacı, Kapsamı ve Katkısı 17
2. LİTERATÜR ÖZETİ **20**
3. MATERYAL VE YÖNTEM **30**
3.1 Çalışma Alanı ve Veri Seti 30
3.2 Verilerin Analize Hazırlanması 35
3.2.1 Tomruk Fiyatı Tahmin Modellerinde Makine Öğrenimi Yaklaşımı 36
3.2.2 Çalışmada Kullanılan Makine Öğrenmesi Modelleri 37
3.2.2.1 Doğrusal regresyon (Linear regression, LR) 38
3.2.2.2 Ridge regresyon (Ridge regression, RR) 38
3.2.2.3 Rastgele orman (Random forest, RF) 39
3.2.2.4 Aşırı gradyan artırma (Extreme gradient boosting, XGBoost) 39
3.2.2.5 Hafif gradyan artırma (Light gradient boosting machine, LGBM) 40
3.3 Model Optimizasyonu ve Doğrulama 40
3.4 Model Performans Metrikleri 41
3.5 Entropi ve TOPSIS Tabanlı Çok Kriterli Model Değerlendirmesi 43
3.6 SHAP Analizi 46
3.7 Gerçek ve Tahmin Edilen Fiyatların Karşılaştırması ile Gelecek Dönem Fiyat Projeksiyonları 47
4. BULGULAR **48**
4.1 Veri Analizi Bulguları 48
4.2 Model Performansları 52
4.2.1 Hiperparametre Optimizasyonu ve Çapraz Doğrulama Öncesi ve Sonrası Model Performans Metrikleri 52
4.2.2 Entropi Tabanlı TOPSIS Sonuçları ve Model Sıralaması 56

4.3 SHAP Tabanlı Değişken Etkilerinin Analizi 59
4.4 Gerçek ve Tahmin Edilen Fiyatların Karşılaştırması ile Gelecek Dönem Fiyat Projeksiyonları 60
5. TARTIŞMA 66
6. SONUÇ VE ÖNERİLER 72
KAYNAKLAR 75
ÖZGEÇMİŞ 92

ŞEKİLLER DİZİNİ

Sayfa

Şekil 1.1 Yapay zekanın başlıca alt alanları ve uygulama örnekleri 10
Şekil 1.2 Makine öğrenmesinin öğrenme yaklaşımları, yöntemleri ve uygulama alanları 11
Şekil 3.1 Araştırma kapsamında kullanılan OBM'lerin mekânsal dağılımı 31
Şekil 3.2 İş akış şeması 34
Şekil 4.1 Değişkenler arası Pearson Korelasyon matrisi ($p<0,05$) 51
Şekil 4.2 XGBoost modeli tahmin performansı 62
Şekil 4.3 RF modeli tahmin performansı 62
Şekil 4.4 LGBM modeli tahmin performansı 63
Şekil 4.5 LR modeli tahmin performansı 63
Şekil 4.6 RR modeli tahmin performansı 63
Şekil 4.7 XGBoost modeli ile 2026-2030 dönemi için tahmin edilen Türkiye ortalama tomruk AASF'leri 64
Şekil 4.8 XGBoost modeli ile 2026-2035 dönemi için tahmin edilen Türkiye ortalama tomruk AASF'leri 65

TABLOLAR DİZİNİ

Sayfa

Tablo 3.1 Çalışmada kullanılan değişkenler ve kullanım amaçları 32
Tablo 4.1 Tanımlayıcı istatistik sonuçları 49
Tablo 4.2 Hiperparametre optimizasyonu ve çapraz doğrulama öncesi model performans metrikleri 53
Tablo 4.3 Hiperparametre optimizasyonu ve çapraz doğrulama sonrası model performans metrikleri 53
Tablo 4.4 Hiperparametre optimizasyonu sonrası parametre kombinasyonları 55
Tablo 4.5 Modellerin performans metriklerine göre sıralamaları 55
Tablo 4.6 Modellerin test veri setine ait performans metrikleri 56
Tablo 4.7 Entropi yöntemi için normalize edilmiş karar matrisi 57
Tablo 4.8 Entropi yöntemi için olasılık matrisi 57
Tablo 4.9 Entropi analizi sonucunda elde edilen kriter ağırlıkları ve önem düzeyleri 58
Tablo 4.10 TOPSIS sonucunda elde edilen göreli yakınlık katsayıları ve model sıralamaları 59
Tablo 4.11 SHAP analizine göre değişken önem sıralamaları 60
Tablo 4.12 2025 yılına ait gerçek değer ve tahmin değerlerinin karşılaştırılması 61

SİMGELER VE KISALTMALAR DİZİNİ

Simgeler

α	: Değişkenlik oranı
β	: Yanlılık oranı
β_0	: Sabit terim
β_j	: Regresyon katsayısı
ε	: Hata terimi
κ	: Karar ağacı sayısı
λ	: Düzenlileştirme parametresi
η	: Öğrenme oranı
χ	: Girdi değişkenleri vektörü
Θ_k	: K. ağacın rassal örnekleme parametresi
r	: Pearson korelasyon katsayısı
p	: Bağımsız değişken sayısı
n	: Toplam gözlem sayısı
m	: Alternatif sayısı
k	: Entropi normalizasyon sabiti, karar ağacı indeksi
$Q1$	: Birinci çeyrek (1. kartil)
$Q3$	: Üçüncü çeyrek (3. kartil)
v	: Özgün gözlem değeri
v'	: Ölçeklenmiş değer
Y_i	: Gerçek (gözlenen) değer
$\hat{Y}_i$	: Model tarafından tahmin edilen değer
$\bar{Y}$	: Bağımlı değişkenin ortalama değeri
e_i	: Tahmin hatası
p_{ij}	: Normalize edilmiş olasılık değeri
x_{ij}	: Karar matrisinde i. alternatifin j. kritere ilişkin değeri
e_j	: j. kritere ait entropi değeri
d_j	: j. kritere ait farklılaşma değeri
w_j	: j. kriterin ağırlığı
r_{ij}	: Normalize değer
v_{ij}	: TOPSIS'te ağırlıklı normalize değer
A^+	: Pozitif ideal çözüm
A^-	: Negatif ideal çözüm
S_i^+	: Pozitif ideal çözüme Öklid uzaklığı
S_i^-	: Negatif ideal çözüme Öklid uzaklığı
C_i^*	: TOPSIS göreli yakınlık katsayısı
m^3	: Metreküp
R^2	: Determinasyon katsayısı

Kısaltmalar

AASF	**:** Açık Artırmalı Satış Fiyatı
AI	**:** Artificial Intelligence (Yapay Zeka)
ANN	**:** Artificial Neural Network (Yapay Sinir Ağı)
ARIMA	**:** Autoregressive Integrated Moving Average (Otoregresif Bütünleşik Hareketli Ortalama)
BATS	**:** Exponential Smoothing with Box-Cox Transformation, ARMA Errors, Trend and Seasonal Components
CBS	**:** Coğrafi Bilgi Sistemi
CPI	**:** Consumer Price Index (Tüketici Fiyat Endeksi)
Çz Kb	**:** Kızılçam Kısa Boy
Çz Nb	**:** Kızılçam Normal Boy
DVM	**:** Destek Vektör Makinesi
ETS	**:** Exponential Smoothing (Üstel Düzleştirme)
GBRT	**:** Gradient Boosted Regression Trees (Gradyan Artırmalı Regresyon Ağaçları)
GNN	**:** Graph Neural Network (Grafik Sinir Ağı)
GSYH	**:** Gayrisafi Yurt İçi Hasıla
IoT	**:** Internet of Things (Nesnelerin İnterneti)
IQR	**:** Interquartile Range (Çeyrekler Arası Aralık)
İHA	**:** İnsansız Hava Aracı
KGE	**:** Kling-Gupta Efficiency (Kling-Gupta Verimlilik Katsayısı)
LGBM	**:** Light Gradient Boosting Machine (Hafif Gradyan Artırma Makinesi)
LiDAR	**:** Light Detection and Ranging
LR	**:** Linear Regression (Doğrusal Regresyon)
LSTM	**:** Long Short-Term Memory (Uzun Kısa Süreli Bellek Ağı)
MAE	**:** Mean Absolute Error (Ortalama Mutlak Hata)
MAPE	**:** Mean Absolute Percentage Error (Ortalama Mutlak Yüzde Hata)
MB	**:** Merkez Bankası
MedAE	**:** Median Absolute Error (Medyan Mutlak Hata)
MLP	**:** Multilayer Perceptron (Çok Katmanlı Algılayıcı)
MSE	**:** Mean Squared Error (Ortalama Kare Hata)
NSE	**:** Nash-Sutcliffe Efficiency (Nash-Sutcliffe Verimlilik Katsayısı)
OGM	**:** Orman Genel Müdürlüğü
OBM	**:** Orman Bölge Müdürlüğü
PCA	**:** Principal Component Analysis (Temel Bileşenler Analizi)
PPI	**:** Producer Price Index (Üretici Fiyat Endeksi)
RBF	**:** Radial Basis Function (Radyal Tabanlı Fonksiyon)
RF	**:** Random Forest (Rastgele Orman)
RMSE	**:** Root Mean Square Error (Kök Ortalama Kare Hata)
RR	**:** Ridge Regression (Ridge Regresyon)
RS	**:** Robust Scaler
S-BERT	**:** Sentence Bidirectional Encoder Representations from Transformers
SARIMA	**:** Seasonal ARIMA (Mevsimsel ARIMA)

SHAP	**:** SHapley Additive exPlanations
sMAPE	**:** Symmetric Mean Absolute Percentage Error (Simetrik Ortalama Mutlak Yüzde Hatası)
SVM	**:** Support Vektor Machine
SOY	**:** Sürdürülebilir Orman Yönetimi
TBATS	**:** Trigonometric Seasonality, Box-Cox Transformation, ARMA Errors, Trend and Seasonal Components
TL	**:** Türk Lirası
TOPSIS	**:** Technique for Order Preference by Similarity to Ideal Solution
TÜFE	**:** Tüketici Fiyat Endeksi
UAV	**:** Unmanned Aerial Vehicle (İnsansız Hava Aracı / İHA)
USD	**:** United States Dollar (Amerikan Doları)
ÜFE	**:** Üretici Fiyat Endeksi
XGBoost	**:** Extreme Gradient Boosting (Aşırı Gradyan Artırma)
YSA	**:** Yapay Sinir Ağı

1. GİRİŞ

Ormanlar, dünya kara alanlarının yaklaşık üçte birini kaplayan ve biyolojik çeşitlilik açısından en zengin ekosistemler arasında yer alan doğal sermaye unsurlarıdır (Raihan, 2023). Bu ekosistemler, odun hammaddesi ve biyokütle gibi üretim odaklı çıktılar sağlamanın yanı sıra iklim düzenlemesi, karbon tutumu, suyun arıtılması, toprak stabilizasyonu ve sel gibi doğal afetlerin etkilerinin azaltılması gibi düzenleyici hizmetler sunmaktadır. Ayrıca, estetik, rekreasyon ve kültürel değerler gibi sosyal faydalarla insan refahını çok boyutlu olarak etkilemektedir (Nolander ve Lundmark, 2024).

Ormanların bu çok işlevli yapısı, onları yalnızca ekolojik varlıklar değil, aynı zamanda ekonomik ve sosyal sistemlerin ayrılmaz bir parçası haline getirmektedir. Bu doğrultuda günümüz ihtiyaçlarını karşılarken, gelecek nesillerin beklentilerini güvence altına almayı amaçlayan Sürdürülebilir Orman Yönetimi (SOY) anlayışı, orman kaynaklarının biyolojik çeşitlilik, üretim, koruma ve sosyal faydalar gibi farklı işlevlerini dikkate alan temel bir yönetim stratejisi haline gelmiştir (Akyol ve Tolunay, 2006; Bayramoğlu ve Toksoy, 2016; OGM, 2009).

Orman ürünleri üretimi, SOY'un ekonomik ve sosyal boyutunun en somut göstergelerinden biridir. Özellikle kırsal alanlarda, başta orman köyleri olmak üzere, yerel ekonomilerin desteklenmesi ve bölgesel kalkınmanın teşvik edilmesinde önemli rol oynamaktadır (Dalu vd., 2021; Kalkınma Bakanlığı, 2014).

Bu kapsamda odun hammaddesi; başta kereste, mobilya, kağıt ve levha sanayisi olmak üzere birçok sektör için temel girdi niteliği taşımakta ve bu sektörlerin üretim süreçlerinde önemli bir rol üstlenmektedir (FAO, 2014; Kalkınma Bakanlığı, 2014; OGM, 2009). Bu nedenle ormanlardan elde edilen tomruk ve diğer orman ürünleri, yalnızca orman köylüsü açısından bir geçim kaynağı değil, aynı zamanda sanayi üretiminin sürekliliğini etkileyen ekonomik bir kaynak olarak değerlendirilmektedir.

İleri bağlantı oranı yüksek olan ormancılık sektöründe odun hammaddesinin ekonomik değerinin belirlenmesi hem ormancılık faaliyetlerinin planlanması hem de piyasa

dinamiklerinin anlaşılması açısından önem taşımaktadır (Roberts vd., 1999). Odun hammaddesinin ekonomik değerinin belirlenmesinde tomruk fiyatları önemli bir gösterge olup, fiyatlar hem orman işletmelerinin gelir düzeyini hem de üretim ve satış planlamasını doğrudan etkilemektedir. Tomruk fiyatlarında meydana gelen değişimler, üretim maliyetleri, arz-talep dengesi, kalite sınıfları, piyasa koşulları ve makroekonomik değişkenlere bağlı olarak dalgalanabilmekte, bu durum ormancılık sektöründe belirsizliği artırarak karar alma süreçlerini zorlaştırmaktadır.

Ormancılık ekonomisi, orman kaynaklarının yönetimi, üretimi, tüketimi ve orman ürünleri piyasalarına ilişkin ekonomik süreçleri inceleyen uygulamalı iktisat alanlarından biridir (Zhang ve Pearse, 2026). Ayrıca odun hammaddesi orman ürünleri sanayisinin temel girdilerinden biri olması nedeniyle hem orman işletmelerinin ekonomik performansını hem de sanayinin rekabet gücünü doğrudan etkilemektedir (Bryngemark, 2019; Lauri vd., 2021; Nepal vd., 2021).

Odun hammaddesi piyasasında ürünler çoğunlukla kullanım amacı ve endüstriyel değer düzeyine göre sınıflandırılmaktadır. Bu sınıflandırma çerçevesinde tomruk, kereste ve kaplama üretimi başta olmak üzere mobilya, levha sanayii ve yapısal ahşap uygulamaları gibi yüksek katma değerli alanlara yönlendirildiği için ekonomik açıdan en önemli ürün gruplarından biri olarak değerlendirilmektedir (Ünver ve Acar, 2005). Buna karşılık sanayi odunu, lif-yonga odunu ve yakacak odun gibi ürünler, farklı sanayi kollarında girdi olarak kullanılmakta ve kullanım alanlarındaki farklılıklar nedeniyle piyasa içerisinde farklı fiyat düzeylerinde işlem görmektedir (Zengin, 2009). Dolayısıyla odun hammaddesi piyasasında fiyat oluşumu yalnızca arz ve talep miktarına bağlı değildir; ürünün cinsi, kalite düzeyi, standardizasyona uygunluğu ve ilgili sektörlerdeki piyasa koşulları gibi unsurlar fiyatların belirlenmesinde doğrudan etkili olmaktadır (Daşdemir, 2008; OGM, 2022).

Ormancılık sektöründe arzın biyolojik süreçlere dayanması, üretim süresinin uzunluğu ve kısa vadede arzın sınırlı ölçüde ayarlanabilmesi, orman ürünleri piyasalarının klasik emtia piyasalarından önemli ölçüde ayrılmasına neden olmaktadır (Hetemäki ve Hurmekoski, 2016). Kısa vadede arzın sınırlı ölçüde ayarlanabilmesi nedeniyle küresel odun piyasaları için geliştirilen arz ve talep fonksiyonlarının, ekonometrik modellerde

özel bir dikkatle ele alınması gerekmektedir (Morland vd., 2018). Arz esnekliğinin düşük olması, talep veya maliyet koşullarındaki değişimlerin fiyatlara daha güçlü yansımasına yol açmakta; bu durum fiyat dalgalanmalarını ve belirsizliği artırırken, özellikle tomruk ve kereste piyasalarında fiyat esnekliğinin ölçülmesini kritik hale getirmektedir (Zhai ve Kuusela, 2023).

Bu kapsamda tomruk piyasası, çok sayıda teknik ve ekonomik değişkenin etkileşimiyle şekillenen, doğrusal olmayan ilişkiler barındırabilen ve tahmin edilmesi güç bir fiyat yapısına sahiptir. Fiyat oluşum mekanizmasının bu niteliği, geleneksel belirleyici yaklaşımların ötesinde daha esnek modelleme tekniklerine yönelimi kaçınılmaz hale getirmektedir.

1.1 Tomruk Satış Yöntemleri ve Fiyat Oluşum Mekanizmaları

Odun hammaddesi satış yöntemleri ve piyasa organizasyonu, ülkelerin mülkiyet yapısı ve kurumsal düzenlemelerine bağlı olarak farklılık gösterebilmektedir (Hetemäki ve Hurmekoski, 2016; Jonsson, 2009). Bu yöntemlerin kullanım biçimi ve yaygınlığı, piyasa yapısına ve bölgesel özelliklere bağlı olarak değişiklik göstermektedir (Kozuch, 2021). Orman ürünleri piyasalarında fiyat oluşumu; arz, talep ve ticaret arasındaki karşılıklı etkileşim sonucunda şekillenmekte olup, bu unsurlar piyasa dinamiklerinin temel belirleyicileri arasında yer almaktadır (Morland vd., 2018).

Dünya genelinde tomruk satışları; açık artırma ve kapalı zarf usulü gibi geleneksel ihale yöntemleriyle ve son yıllarda dijitalleşmenin etkisiyle elektronik ihale sistemleri üzerinden gerçekleştirilmektedir (Athey vd., 2011; Wysocki vd., 2025). İhale sistemlerinin yanı sıra, odun hammaddesi satışında idari fiyatlandırma ve doğrudan müzakere yöntemleri de kullanılmaktadır. Ayrıca özel orman sahipleri satışlarını çoğunlukla toplu satış veya birim fiyat esasına dayalı sözleşmelerle gerçekleştirmektedir (FAO, 1998).

Ekonomik açıdan piyasalar; tam rekabet, monopol, oligopol ve monopolcü rekabet gibi farklı piyasa yapıları altında değerlendirilmektedir. Piyasa yapısı, piyasadaki satıcı ve alıcı sayısı, giriş-çıkış koşulları ile fiyat belirleme mekanizmalarını doğrudan etkilemektedir. Tam rekabet piyasasında fiyat arz ve talep koşulları altında oluşurken,

monopol piyasalarda fiyatlama davranışı büyük ölçüde tek satıcının kararlarına bağlıdır. Oligopol piyasalarda ise sınırlı sayıdaki üretici arasındaki stratejik etkileşimler fiyat oluşumunda belirleyici olmaktadır (George Brown College, 2014; Barkley, 2019).

Türkiye'de endüstriyel odun piyasası, arzın büyük ölçüde Orman Genel Müdürlüğü (OGM) tarafından gerçekleştirilmesi nedeniyle monopol özellikleri gösteren bir piyasa yapısına sahiptir. OGM tarafından yürütülen satışlar, üretim faaliyetlerinin kimin tarafından yürütüldüğüne bağlı olarak iki temel yöntemle sınıflandırılmaktadır. Kesme, sürütme ve taşıma gibi işlemlerin OGM tarafından tamamlanmasının ardından yapılan satışlar üretim sonrası (sonradan) satış olarak adlandırılırken, bu işlemlerin alıcıya bırakıldığı ve ağaçların dikili halde devredildiği uygulamalar üretim öncesi (önceden) satış ya da dikili satış kapsamında değerlendirilmektedir (Gültekin, 2015; Kabasakal ve Tolunay, 2021).

Tomruk satışlarında temel fiyat belirleme mekanizması açık artırma usulüne dayanmaktadır. Açık artırmaya esas olacak başlangıç fiyatı "muhammen bedel" olarak belirlenmektedir. Muhammen bedel; ürünün cinsi, kalite sınıfı, çap ve boy özellikleri, piyasa koşulları, üretim maliyetleri ve tarife bedelleri dikkate alınarak oluşturulmaktadır. Ayrıca piyasa koşulları ve satış durumuna bağlı olarak Orman İşletme Müdürlükleri muhammen bedelde %20'ye kadar, Bölge Müdürlükleri ise %50'ye kadar artırma veya azaltma yapabilme yetkisine sahiptir (OGM, 2022). Muhammen bedelin ürünün teknik özellikleri, üretim maliyetleri ve piyasa koşulları dikkate alınarak belirlenmesi, açık artırma sürecinin önceden belirlenmiş bir başlangıç fiyatı üzerinden yürütüldüğünü göstermektedir. Nihai satış fiyatı ise başlangıç fiyatına bağlı olmayıp; ihale zamanı, arz edilen ürün miktarı ve kalitesi, parti büyüklüğü, talep düzeyi ve piyasa koşulları gibi çeşitli faktörlerden etkilenmektedir (Daşdemir, 2008; OGM, 2022)

Açık artırma yöntemi kapsamında satışa ilişkin bilgiler önceden ilan edilmekte ve alıcılar bu şartlar çerçevesinde teklif vermektedir. İhale sürecinde tekliflerin artmasıyla en yüksek fiyatı veren alıcıya satış yapılmaktadır (Daşdemir, 2018). Açık artırma sistemi, bu yönüyle fiyatın alıcıların teklifleri doğrultusunda oluşmasına imkan

tanımaktadır. Açık artırmaya konu tomrukların türü, çapı, boyu ve kalite sınıfı gibi teknik özellikleri ile satış miktarının fiyat oluşumunda etkili olduğu kabul edilmektedir. Ayrıca ihale sürecine katılan alıcı sayısı ve oluşan rekabet düzeyi de nihai satış fiyatı üzerinde belirleyici olabilmektedir (OGM, 2022).

Devlet orman işletmelerinde gerçekleştirilen açık artırmalı tomruk satışlarında fiyatı etkileyen faktörlerin çok boyutlu bir yapı sergilediği ifade edilmektedir. Ürünün teknik nitelikleri ve satışa sunulan miktarın fiyat düzeyini belirleyen temel unsurlar arasında yer aldığı kabul edilmektedir (Daşdemir, 2008). Buna ek olarak, mevsimsel değişkenlerin tomruk satış fiyatları üzerinde etkili olduğu çeşitli çalışmalarda ortaya konulmuştur (Ok, 1998; Şen ve Güngör, 2018). Mevsimsellik etkisinin, tomruk satış fiyatları üzerindeki yansımasının talep ve üretim koşullarındaki dönemsel değişimlerle ilişkili olduğu değerlendirilmektedir.

Bununla birlikte, fiyatların yalnızca ürünün teknik özellikleri ile arz ve talep koşullarından değil, genel ekonomik gelişmelerden de etkilendiği bilinmektedir. Faiz oranları, enflasyon, döviz kuru, ekonomik büyüme, sanayi üretimi, enerji fiyatları ve dış ticaret göstergeleri gibi makroekonomik değişkenlerin emtia fiyatları üzerindeki belirleyici rolü literatürde geniş bir şekilde ele alınmıştır. Frankel (2008), para politikası ve özellikle reel faiz oranlarındaki değişimlerin emtia fiyatlarını etkileyen temel makroekonomik unsurlardan biri olduğunu; faiz oranlarındaki artışın emtia fiyatları üzerinde aşağı, azalışın ise yukarı yönlü baskı oluşturabildiğini belirtmektedir. Gruber ve Vigfusson (2018) ise faiz oranlarının emtia fiyatlarının düzeyi kadar fiyat oynaklığı ve emtia grupları arasındaki birlikte hareket etme eğilimi üzerinde de etkili olduğunu ortaya koymuştur. Benzer şekilde, orman ürünleri piyasalarında da makroekonomik dalgalanmalar, iç ve dış talepte meydana gelen değişimler ile uluslararası ticaret hareketlerinin tomruk fiyatları üzerinde doğrudan veya dolaylı etkiler oluşturabildiği belirtilmektedir (Hetemäki ve Hurmekoski, 2016; UNECE ve FAO, 2022).

Türkiye'de tomruk fiyatlarının; teknik özellikler, piyasa koşulları ve açık artırma dinamiklerinin etkileşimiyle şekillenen çok değişkenli yapısı, doğrusal varsayımlara dayanan klasik parametrik modellerin açıklama gücünü ve tahmin performansını

sınırlayabilmektedir. Açık artırmalı tomruk satış fiyatlarının; talep düzeyi, ihale zamanı, üretimin kalitesi, standardizasyona uygunluk ve satış partisi büyüklüğü gibi birçok faktörden etkilendiği belirtilmektedir (Daşdemir, 2001). Ayrıca orman ürünleri piyasalarında fiyat oluşumunun arz-talep dengesi, piyasa yapısı ve satış organizasyonu gibi ekonomik değişkenlerden de etkilendiği ifade edilmektedir (Daşdemir, 2008). Değişkenler arasındaki karmaşık ilişkilerin ve kolayca fark edilemeyen yapıların ortaya konulabilmesi, daha esnek ve veri temelli modelleme yaklaşımlarının kullanılmasını gerekli kılabilmektedir.

Bu kapsamda literatürde, tomruk fiyatlarının belirlenmesine yönelik çalışmalarda çoğunlukla regresyon ve korelasyon analizleri ile zaman serisi ve ekonometrik modellerden yararlanıldığı görülmektedir (Daşdemir, 2008; Morland vd., 2018; Ok, 1998; Şen ve Güngör, 2018; Zhai ve Kuusela, 2023). Söz konusu yöntemler, değişkenler arasındaki ilişkilerin belirli varsayımlar altında modellenmesine imkan sağlamakta ve yorumlanabilir sonuçlar sunabilmektedir. Bununla birlikte, doğrusallık (değişkenler arasındaki ilişkinin doğrusal olması), durağanlık (serinin zaman içinde istatistiksel özelliklerinin sabit kalması) ve hata terimlerine ilişkin dağılım varsayımları (modelin açıklayamadığı rastgele etkilerin belirli istatistiksel özellikler göstermesi) gibi kısıtlayıcı koşullar; model kurulumunda esnekliği sınırlandırmakta ve gerçek piyasa dinamiklerinin yeterince yansıtılamamasına neden olabilmektedir (Zhai ve Kuusela, 2023). Ayrıca bu yaklaşımların, değişkenler arasındaki karmaşık etkileşimleri ve dinamik piyasa koşullarını sınırlı ölçüde yansıtabilmesi tahmin performanslarını bazı durumlarda kısıtlayabilmektedir. Bu durumun, daha esnek ve veri odaklı modelleme yaklaşımlarına yönelik ilgiyi artırdığı değerlendirilmektedir (Hetemäki ve Hurmekoski, 2016).

Bu kapsamda yapay zeka ve makine öğrenmesi yöntemleri, doğrusal olmayan ilişkileri ve değişkenler arasındaki karmaşık etkileşimleri veriden öğrenebilme kapasitesiyle öne çıkmaktadır. Söz konusu yöntemler, dağılım varsayımları gerektirmeksizin yüksek boyutlu veri yapılarında örüntüleri tespit edebilmektedir (James vd., 2021). Bu sayede, özellikle veri karmaşıklığının arttığı ve geleneksel istatistiksel modellerin yetersiz kaldığı durumlarda daha üstün tahmin performansı sunabilmektedirler (Herm vd., 2023). Bu özellikler, makine öğrenmesi yaklaşımlarının tomruk fiyat tahmininde

uygulanmasına yönelik araştırma potansiyelini güçlendirmekte ve yöntemsel çeşitliliğin artırılması gerektiğine işaret etmektedir.

1.2 Yapay Zeka ve Makine Öğrenmesinin Kavramsal Çerçevesi

Yapay zeka, insan zekasına özgü bilişsel yetenekleri algoritmik yapılar aracılığıyla taklit etmeyi ve bu sayede karmaşık problemlere otonom çözümler üretebilmeyi hedefleyen çok disiplinli bir bilim ve mühendislik alanıdır (Chakir vd., 2024). Yapay zeka sistemlerinde öğrenme, akıl yürütme, problem çözme ve algı gibi süreçler temel çalışma mekanizmaları olarak yer almaktadır (Özmen, 2019).

Yapay zeka araştırmaları tarihsel süreç içerisinde farklı yöntemsel yaklaşımlar etrafında şekillenmiştir. Literatürde genel olarak kural tabanlı yaklaşımlar ile veri temelli yaklaşımlar arasında bir ayrım yapılmaktadır (Nilsson, 1998; Russell ve Norvig, 2016). Kural tabanlı yaklaşımlar, insan bilgisini açık kurallar ve mantıksal çıkarım mekanizmaları aracılığıyla temsil etmeyi hedeflerken; veri temelli yaklaşımlar, sistemlerin örüntüleri doğrudan veriden öğrenmesini esas almaktadır (Mitchell, 1997). Günümüzde yapay zeka uygulamalarında veri temelli yöntemlerin ağırlık kazandığı ve özellikle makine öğrenmesi temelli modellerin ön plana çıktığı görülmektedir (Russell ve Norvig, 2016).

Makine öğrenmesi, yapay zekanın veri temelli alt alanı olarak, sistemlerin açık biçimde programlanmaksızın veriden öğrenmesini ve bu öğrenme süreci sonucunda tahmin veya karar üretmesini sağlayan yöntemler bütününü ifade etmektedir. Makine öğrenmesinin bir alt dalı olan derin öğrenme ise, çok katmanlı yapay sinir ağları aracılığıyla yüksek boyutlu veri temsillerini öğrenebilmektedir (Mijwil vd., 2022). Günümüzde makine öğrenmesi ve derin öğrenme yaklaşımları; finansal sistemler, sağlık hizmetleri, enerji yönetimi, ormancılık, tarımsal üretim ve endüstriyel süreçler başta olmak üzere birçok alanda karmaşık veri yapılarının analiz edilmesi ve tahmin doğruluğunun artırılması amacıyla kullanılmaktadır (Alami vd., 2025; Ardabili vd., 2022; Damar, 2024; Eker vd., 2023; Rane vd., 2024).

1.3 Yapay Zekanın Tarihsel ve Kuramsal Gelişimi

Yapay zekanın tarihsel gelişimi, matematik ve hesaplama kuramındaki gelişmelerle birlikte şekillenmiştir. Alanın kökenleri, 19. yüzyılda Charles Babbage'ın "Analitik Makine" tasarımına ve Ada Lovelace'ın algoritmik yaklaşımlarına kadar uzanmaktadır. Babbage'ın programlanabilir hesaplama makinesi fikri modern bilgisayar mimarisinin temelini oluştururken, Lovelace makinenin sembolik işlemler gerçekleştirebileceğini öngörmüştür (Grzybowski vd., 2024).

20. yüzyılın ortalarında Alan Turing'in çalışmaları yapay zekanın kuramsal temelini güçlendirmiştir. Turing, 1950 yılında yayımladığı çalışmasında makinelerin düşünebilirliği sorusunu ortaya koymuş ve "Turing Testi" olarak bilinen yaklaşımı geliştirmiştir. Bu dönem, dijital bilgisayarların gelişimiyle birlikte yapay zeka araştırmalarının kurumsallaşmaya başladığı bir süreç olarak değerlendirilmektedir (Rai, 2024).

1956 yılında Dartmouth Konferansı'nda John McCarthy tarafından "Yapay Zeka" teriminin kullanılması, alanın resmi başlangıcı olarak kabul edilmektedir (McCarthy vd., 2006). Bu dönemde sembolik yapay zeka yaklaşımları, mantık temelli çıkarım sistemleri ve teorem ispatlama programları ön plana çıkmıştır. Ancak erken dönem beklentilerinin karşılanamaması ve sistemlerin gerçek dünya problemlerinde sınırlı başarı göstermesi, 1970'lerde "Yapay Zeka Kışı" olarak adlandırılan durgunluk dönemine yol açmıştır. Bu süreçte özellikle perceptron modellerinin sınırlılıklarını ortaya koyan çalışmaların etkili olduğu belirtilmektedir (Delipetrev vd., 2020; Minsky ve Papert, 1969)

1970'ler ve 1980'lerde uzman sistemlerle birlikte sembolik yapay zeka yaklaşımları yeniden önem kazanmıştır. Ancak 1990'lı yıllardan itibaren istatistiksel ve veri temelli yöntemlerin gelişmesiyle makine öğrenmesi ön plana çıkmış; Karar Ağaçları (Decision Tree-DT), Destek Vektör Makineleri (Support Vector Machine-SVM) ve olasılıksal modeller yaygınlaşmıştır (Delipetrev vd., 2020).

Yapay zekanın alt dalı olan makine öğrenmesinin matematiksel temelleri daha eskiye dayanmaktadır. En küçük kareler yöntemi, 19. yüzyılda Gauss ve Legendre tarafından

geliştirilen önemli istatistiksel yaklaşımlar arasında yer almaktadır (Stigler, 1990). Yapay sinir ağlarının kuramsal gelişimi ise 20. yüzyılda hız kazanmış, derin öğrenmenin temelleri çok katmanlı yapay sinir ağlarının geliştirilmesiyle atılmıştır. Özellikle Ivakhnenko ve Lapa tarafından önerilen çok katmanlı ağ yapıları, modern derin sinir ağlarının erken örnekleri arasında değerlendirilmektedir (Schmidhuber, 2022). Ancak bu yöntemlerin yaygın biçimde uygulanabilir hale gelmesi, büyük veri kümelerinin ortaya çıkışı ve hesaplama kapasitesindeki artışla mümkün olmuştur (LeCun vd., 2015).

2010'lu yıllardan itibaren grafik işlem birimlerinin yaygınlaşması ve büyük veri altyapılarındaki gelişmelerle birlikte, derin öğrenme temelli yöntemlerin görüntü işleme gibi alanlarda yaygın biçimde kullanılmaya başladığı görülmektedir (Delipetrev vd., 2020).

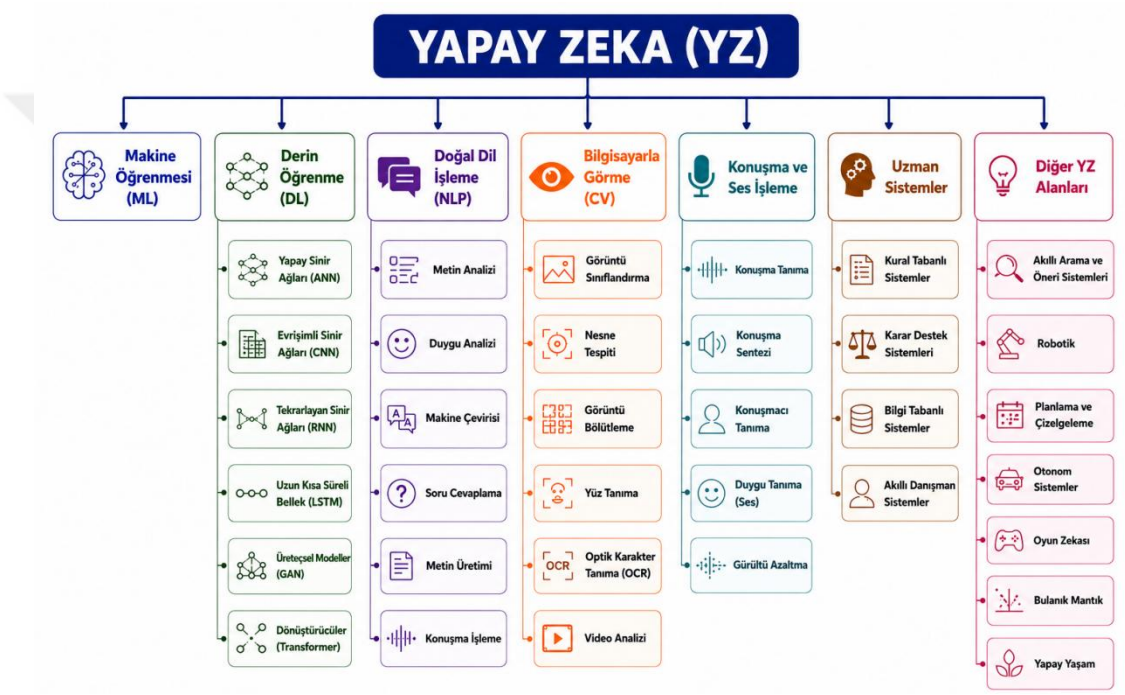
1.4 Makine Öğrenmesi Yaklaşımları

Makine öğrenmesi, Arthur Samuel tarafından bilgisayarların açıkça programlanmadan öğrenebilmesini sağlayan bir çalışma alanı olarak tanımlanmıştır (Samuel, 1959). Zaman içerisinde veri odaklı modelleme ve öğrenme yaklaşımlarına dayanan önemli bir yapay zeka alt alanı haline gelen makine öğrenmesi, artan hesaplama kapasitesi ve istatistiksel yöntemlerdeki gelişmelerle birlikte önemli ilerleme göstermiştir (Bishop ve Nasrabadi, 2006; Montáns vd., 2019).

Makine öğrenmesi yöntemleri, veri yapısı ve öğrenme yaklaşımına göre farklı algoritmik yapılardan oluşmaktadır. Literatürde bu yöntemler; denetimli, denetimsiz, yarı denetimli ve pekiştirmeli öğrenme gibi temel öğrenme yaklaşımları altında sınıflandırılmaktadır (Sarker, 2021). DT, SVM, Rastgele Orman (Random Forest-RF), Aşırı Gradyan Artırma (Extreme Gradient Boosting-(XGBoost), Hafif Gradyan Artırma Makinesi (Light Gradient Boosting Machine-LGBM) ve Kategorik Artırma (Categorical Boosting-CatBoost) gibi topluluk öğrenmesi algoritmaları yaygın olarak kullanılan makine öğrenmesi yöntemleri arasında yer almaktadır (Sarker, 2021; Zhang vd., 2022). Derin öğrenme kapsamında ise yapay sinir ağları temelli evrişimsel sinir ağları, tekrarlayan sinir ağları, uzun kısa süreli bellek ağları ve üretici çekişmeli ağlar

gibi çok katmanlı mimarilere dayalı modeller ön plana çıkmaktadır (Deng, 2014; Shrestha ve Mahmood, 2019).

Yapay zeka, farklı yöntem ve uygulama alanlarını kapsayan geniş bir çalışma alanıdır (Goodfellow vd., 2016). Makine öğrenmesi, derin öğrenme, doğal dil işleme ve bilgisayarla görme gibi alt disiplinler, yapay zeka teknolojilerinin temel bileşenlerini oluşturmaktadır (Janiesch vd., 2021). Şekil 1.1'de yapay zekanın başlıca alt alanları ve bu alanlara ilişkin temel uygulama örnekleri verilmektedir.

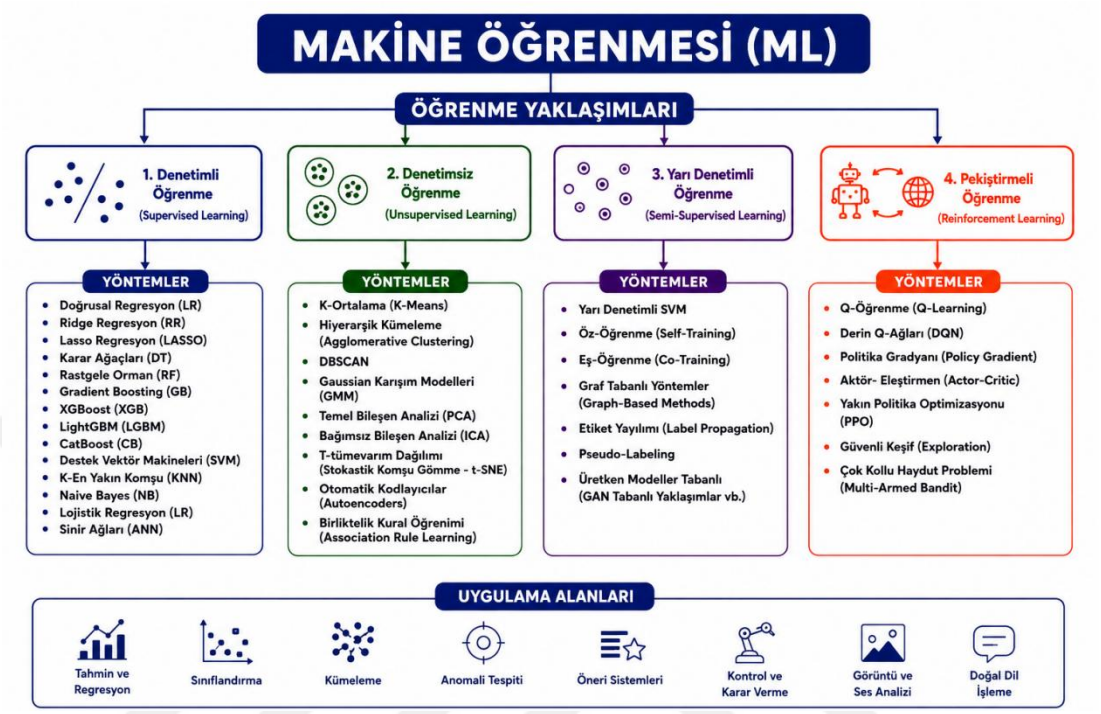


Şekil 1.1 Yapay zekanın başlıca alt alanları ve uygulama örnekleri

Şekil 1.1'e göre, yapay zeka; makine öğrenmesi, derin öğrenme, doğal dil işleme, bilgisayarla görme, konuşma ve ses işleme ile uzman sistemler gibi farklı alt alanlardan oluşmaktadır (Janiesch vd., 2021; LeCun vd., 2015). Ayrıca robotik, akıllı öneri sistemleri, otonom sistemler ve bulanık mantık gibi uygulama alanları da yapay zeka teknolojilerinin kullanım kapsamını genişletmektedir (Sarker, 2022).

Çalışmada, yapay zekanın alt dallarından biri olan makine öğrenmesi yaklaşımı kullanılmıştır. Makine öğrenmesi, öğrenme sürecinde kullanılan veri yapısı ve geri bildirim mekanizmasına göre farklı öğrenme yaklaşımlarına ayrılmaktadır (Mitchell,

1997). Şekil 1.2'de makine öğrenmesinin temel öğrenme yaklaşımları, kullanılan yöntemler ve başlıca uygulama alanları gösterilmektedir.



Şekil 1.2 Makine öğrenmesinin öğrenme yaklaşımları, yöntemleri ve uygulama alanları

Şekil 1.2'de görüldüğü üzere makine öğrenmesi; denetimli öğrenme, denetimsiz öğrenme, yarı denetimli öğrenme ve pekiştirmeli öğrenme olmak üzere dört temel öğrenme yaklaşımından oluşmaktadır. Bu yaklaşımlar kapsamında çeşitli algoritma ve yöntemlerin kullanıldığı, ayrıca tahmin ve regresyon, sınıflandırma, kümeleme, anomali tespiti, öneri sistemleri ve doğal dil işleme gibi birçok alanda uygulandığı görülmektedir (Duarte ve Berton, 2023; Gupta vd., 2022). Bu çalışmada ise makine öğrenmesinin denetimli öğrenme yaklaşımı kapsamında yer alan yöntemlerden yararlanılmıştır.

1.4.1 Denetimli Öğrenme

Denetimli öğrenme, girdi değişkenleri (x) ile hedef değişken (y) arasındaki ilişkinin etiketlenmiş veriler kullanılarak öğrenildiği bir makine öğrenmesi yaklaşımıdır. Bu yöntemde algoritma, eğitim verilerindeki özellikler ile doğru çıktılar arasındaki ilişkiyi öğrenerek yeni veriler üzerinde tahmin ve sınıflandırma işlemleri gerçekleştirmektedir (Cunningham vd., 2008). Denetimli öğrenmede veri seti, girdi değişkenleri ile bunlara

karşılık gelen doğru çıktıları içeren etiketli örneklerden oluşmaktadır. Hedef değişkenin yapısına bağlı olarak denetimli öğrenme problemleri sınıflandırma ve regresyon olmak üzere iki ana grupta incelenmektedir. Sınıflandırma problemlerinde model, gözlemleri belirli kategorilere atamayı amaçlarken; regresyon problemlerinde sürekli sayısal değerlerin tahmini hedeflenmektedir. Bu ayrım, kullanılacak algoritmaların ve performans değerlendirme ölçütlerinin belirlenmesinde önemli rol oynamaktadır (Nasteski, 2017).

1.4.2 Denetimsiz Öğrenme

Denetimsiz öğrenme, yalnızca girdi verilerinin (x) bulunduğu ve etiketli çıktıların yer almadığı durumlarda kullanılan bir makine öğrenmesi yaklaşımıdır. Bu yöntemde model, veri içerisindeki örüntüleri, benzerlikleri ve gizli yapıları ortaya çıkarmayı amaçlamaktadır. Denetimsiz öğrenme yöntemleri çoğunlukla keşifsel veri analizi süreçlerinde kullanılmaktadır (Ghahramani, 2003). Denetimsiz öğrenmede temel amaç, bir hedef değişkeni tahmin etmekten ziyade veri setinin içsel yapısını ortaya çıkarmaktır. Herhangi bir referans çıktı bulunmadığından, elde edilen sonuçların yorumlanması daha dikkatli bir değerlendirme gerektirmektedir (James vd., 2023).

Denetimsiz öğrenme yöntemleri genel olarak kümeleme ve boyut indirgeme olmak üzere iki ana grupta incelenmektedir. Kümeleme yöntemleri, benzer özelliklere sahip gözlemleri aynı gruplar altında toplamayı amaçlarken; boyut indirgeme teknikleri, yüksek boyutlu veriyi bilgi kaybını en aza indirerek daha düşük boyutlu bir yapıya dönüştürmektedir. Temel Bileşenler Analizi, bu amaçla yaygın olarak kullanılan yöntemlerden biridir (Konstantonis vd., 2013; Valkenborg vd., 2023).

1.4.3 Yarı Denetimli Öğrenme

Yarı denetimli öğrenme, sınırlı sayıda etiketli veri ile daha büyük miktardaki etiketsiz verinin birlikte kullanıldığı bir öğrenme yaklaşımıdır (Chapelle vd., 2009). Bu yöntem, etiketli verinin elde edilmesinin zor ve maliyetli olduğu durumlarda, etiketsiz verilerden yararlanarak model performansını geliştirmeyi amaçlamaktadır (Hady ve Schwenker, 2013). Amacı, etiketsiz verilerdeki yapısal bilgiden yararlanarak modelin genelleme performansını artırmaktır. Ancak bu yaklaşımın başarısı, veri dağılımına

ilişkin bazı varsayımların sağlanmasına bağlıdır; aksi durumda etiketsiz veriler model performansını olumsuz etkileyebilmektedir (Zhu, 2005).

1.4.4 Pekiştirmeli Öğrenme

Pekiştirmeli öğrenme, bir karar vericinin çevreyle etkileşim kurarak deneme-yanılma yoluyla optimal davranış politikasını öğrenmesini amaçlayan bir makine öğrenmesi yaklaşımıdır (Sutton ve Barto, 1999). Bu yöntemde karar verici, her zaman adımında bulunduğu duruma göre bir eylem seçmekte, çevreden ödül geri bildirimi almakta ve uzun vadeli toplam ödülü en üst düzeye çıkaracak karar politikalarını öğrenmektedir (Kaelbling vd., 1996; Li, 2017).

1.5 Makine Öğrenmesi Uygulama Alanları ve Ormancılıkta Kullanımı

Makine öğrenmesi yöntemleri günümüzde finans, enerji, tarım, madencilik ve lojistik gibi birçok farklı alanda yaygın biçimde kullanılmaktadır (Ateş, 2025; Gao vd., 2024; Van Klompenburg vd., 2020; Mosavi ve Bahmani, 2019; Na, 2024). Özellikle büyük hacimli verilerin analiz edilmesi, veri içerisindeki örüntülerin belirlenmesi, tahmin süreçlerinin geliştirilmesi ve karar destek mekanizmalarının desteklenmesi açısından önemli avantajlar sağlamaktadır (LeCun vd., 2015; Shinde ve Shah, 2018). Literatürde makine öğrenmesi yöntemlerinin; finans sektöründe fiyat tahmini ve risk analizi (Galindo ve Tamayo, 2000; Ndikum, 2020), enerji sektöründe tüketim ve üretim tahmini (Abisoye vd., 2024; Kamoona vd., 2023), tarım sektöründe hassas tarım uygulamaları ve hastalık tespiti (Ahmed ve Yadav, 2023; Jin vd., 2021), madencilik sektöründe jeolojik modelleme ve operasyon optimizasyonu (Leung vd., 2022; Martinez-Rau vd., 2025) ile lojistik sektöründe talep tahmini ve dağıtım planlaması (Pasupuleti vd., 2024; Rakholia vd., 2024) gibi farklı uygulama alanlarında etkin biçimde kullanıldığı görülmektedir.

Ormancılık alanında da makine öğrenmesi yöntemlerinden yaygın biçimde yararlanılmaktadır. Özellikle teknolojik gelişmelerin hız kazanmasıyla birlikte ormancılıkta geleneksel yöntemlerin yerini giderek veri temelli ve yenilikçi yaklaşımların aldığı görülmektedir. Ormancılık bilişimi, hassas ve akıllı ormancılık gibi kavramların literatürde daha sık yer alması, büyük veri ve makine öğrenmesi

yöntemlerinin karar verme süreçlerine entegrasyonunu hızlandırmıştır (Jing vd., 2023). Makine öğrenmesi tekniklerinin farklı ormancılık alt disiplinlerinde kullanımına yönelik akademik çalışmaların sayısında belirgin bir artış gözlenmektedir. Bu çalışmaların; orman ekolojisi ve yönetimi, orman ekonomisi, politika ve sosyal bilimler, orman envanteri, modelleme ve uzaktan algılama, orman sağlığı ve koruma ile orman toprağı ve hidrolojisi gibi ormancılığın farklı alt disiplinlerinde yer aldığı görülmektedir (Eker vd., 2023). Bu kapsamda makine öğrenmesi yöntemlerinin özellikle orman envanteri ve biyokütle tahmini çalışmalarında yaygın olarak kullanıldığı (Aksoy ve Günlü, 2025; Gleason ve Im, 2012; Li vd., 2019; Özdemir vd., 2024), bu çalışmalarda çoğunlukla doğrusal regresyon modelleri ile makine öğrenmesi algoritmalarının karşılaştırıldığı (Nandy vd., 2017; Zhang vd., 2024) ve biyokütle ile karbon stok tahmininde yüksek doğruluk düzeylerine ulaşılabildiği bildirilmektedir (Aksoy ve Günlü, 2025; Cheng vd., 2024; Karamanlı, 2025; Zhang vd., 2024).

Orman hasılatı ve amenajmanı ile karar destek sistemleri kapsamında makine öğrenmesi uygulamalarının, sürdürülebilir orman yönetimi hedefleri doğrultusunda planlama ve optimizasyon problemlerine odaklandığı anlaşılmaktadır (Espíndola vd., 2025). Uluslararası çalışmalarda makine öğrenmesi yöntemlerinin; idare süresinin belirlenmesi, gövde çapı ve gövde hacim tahmini, rotasyon ve sürekli örtü ormancılığı arasında optimal seçim yapılması, gençleştirme stratejilerinin planlanması ve karbon yutak alanlarının kapasitesine yönelik senaryo analizlerinde kullanıldığı; özellikle pekiştirmeli öğrenme algoritmalarının yüksek boyutlu ve stokastik yapıya sahip meşcere düzeyi optimizasyon problemlerinde ölçeklenebilir çözümler sunduğu anlaşılmaktadır (Malo vd., 2021; Sağlam, 2025; Suominen, 2025). Bunun yanı sıra derin öğrenme ve bilgisayarlı görü teknikleri, LiDAR, hiperspektral, İHA (insansız hava aracı) ve uydu verilerinin birlikte kullanıldığı çok modlu veri füzyonu yaklaşımları aracılığıyla envanter yönetimi ve izleme süreçlerinde karar desteğini güçlendirmektedir (Forkuo, 2026). Ulusal çalışmalarda ise; makine öğrenmesi yöntemlerinin amenajman planlarının doğrudan optimizasyonundan ziyade, planlama sürecinin temel girdilerinin üretilmesi aşamasında konumlandığı; envanter parametrelerinin otomatik çıkarımı ve meşcere tip haritalarının oluşturulmasında RF ve SVM gibi algoritmalarla yüksek doğruluk düzeylerine ulaşıldığı görülmektedir (Demirel vd., 2021; Vatandaşlar ve Zeybek, 2021)

Uzaktan algılama alanında yapılan çalışmalar, uydu görüntülerinin makine öğrenmesi ve derin öğrenme algoritmalarıyla entegre edilerek orman ekosistemlerinin izlenmesi, sınıflandırılması ve modellenmesine odaklanmaktadır (Mohammed vd., 2026). Türkiye'de Sentinel-2 ve Landsat verileri kullanılarak U-Net, RF ve SVM gibi yöntemlerle arazi örtüsü değişimi analizi, orman içi açıklıkların belirlenmesi ve meşcere özelliklerinin haritalanmasına yönelik uygulamalar gerçekleştirilmiştir (Çankaya vd., 2025; Kadı ve Yılmaz, 2024). Uluslararası literatür incelendiğinde; radar ve optik uzaktan algılama verilerinin açıklanabilir makine öğrenmesi yaklaşımlarıyla birlikte kullanılarak orman ekosistem hizmetlerinin değerlendirilmesi, toprak üstü biyokütle tahmini ve meşcere kapalılık düzeyinin modellenmesi üzerine odaklanıldığı anlaşılmaktadır (Ali vd., 2025; Mohammed vd., 2026; Seyrek vd., 2025).

Orman koruma alanında yapılan çalışmalar, uzaktan algılama verilerinin makine öğrenmesi ve derin öğrenme yöntemleriyle entegre edilerek yangın riski analizi, yangın tahmini ve orman sağlığının izlenmesine odaklanmaktadır (Sumer, 2025; Yıldırım vd., 2023). Uydu tabanlı meteorolojik ve çevresel veriler kullanılarak yangın oluşumunu etkileyen faktörlerin modellenmesi ve yangın duyarlılık haritalarının oluşturulması literatürde yaygın bir uygulama alanı olarak öne çıkmaktadır. Farklı sınıflandırma ve artırmalı öğrenme algoritmaları, yangın olasılığının tahmini ve erken uyarı sistemlerinin geliştirilmesinde kullanılmaktadır (Beşli ve Tenekeci, 2020; Uysal ve Uysal, 2025). Orman sağlığı kapsamında ise zaman serisi uydu verileri ve derin öğrenme modelleri aracılığıyla anomali tespiti yapılmakta; ayrıca yüksek çözünürlüklü İHA (insansız hava aracı) görüntüleri ve nesne tabanlı sınıflandırma yaklaşımları ile hastalık belirtilerinin ağaç düzeyinde belirlenmesine yönelik uygulamalar gerçekleştirilmektedir (Kirsch vd., 2025; Sun vd., 2022).

Havza yönetimi ve toprak özelliklerinin mekansal analizine yönelik çalışmalarda makine öğrenmesi ve uzaktan algılama tekniklerinin giderek daha yoğun biçimde kullanıldığı görülmektedir. Dijital toprak haritalama kapsamında uydu verileri, topoğrafik parametreler, uzaktan algılama indeksleri ve iklim zaman serileri birlikte değerlendirilerek toprak organik karbonu ve diğer toprak özelliklerinin mekansal dağılımı çeşitli makine öğrenmesi algoritmalarıyla modellenmektedir (Kakhani vd., 2024a; Kılıç vd., 2022). Özellikle RF, DVM, XGBoost ve yapay sinir ağları gibi

yöntemler, örneklenmemiş alanlardaki toprak özelliklerinin tahmin edilmesinde etkin biçimde uygulanmaktadır (Kakhani vd., 2024b; Kaya ve Dengiz, 2024). Havza ölçeğinde ise derin öğrenme temelli yaklaşımlar kullanılarak uydu kaynaklı toprak nemi verilerinin ölçek indirgenmesi yapılmakta (Şahin ve Gündüz, 2024), hidro-meteorolojik değişkenler aracılığıyla su seviyeleri ve hidrolojik süreçlerin tahminine yönelik çalışmalar gerçekleştirilmektedir (Güneş Şen, 2025a). Ayrıca makine öğrenmesi tabanlı yaklaşımlar kullanılarak su kalitesi değerlendirmesi ve hidrolojik parametrelerin modellenmesine yönelik çalışmalar da yürütülmektedir (Güneş Şen, 2025b)

Ormancılık ekonomisi ve ormancılık politikası alanlarında makine öğrenmesi uygulamaları incelendiğinde, bu çalışmaların ormancılığın envanter, uzaktan algılama, yangın yönetimi ve biyokütle modelleme gibi teknik alt disiplinlerine kıyasla daha sınırlı bir kapsamda ele alındığı görülmektedir. Literatürde makine öğrenmesi yöntemlerinin ormancılık ekonomisi alanında özellikle kereste ve tomruk fiyatlarının tahmini, piyasa eğilimlerinin analizi ve zaman serisi temelli öngörü çalışmalarında kullanıldığı görülmektedir (Kożuch vd., 2023; Lamichhane vd., 2023; Lopes vd., 2021; Thao ve Duc, 2025). Ormancılık politikası alanında ise metin madenciliği ve doğal dil işleme teknikleri aracılığıyla restorasyon ve sürdürülebilir orman yönetimine ilişkin politika belgelerinin sınıflandırılması ve politika gündemlerinin analizine yönelik uygulamaların geliştirildiği anlaşılmaktadır (Brandt, 2019). Ayrıca tür dağılım modelleri kapsamında bazı makine öğrenmesi algoritmalarının sürdürülebilir orman yönetimi karar süreçlerine destek amacıyla değerlendirildiği görülmektedir (Öğüt ve Kurdoğlu, 2025).

Mevcut çalışmaların kapsamı ve yoğunluğu dikkate alındığında, makine öğrenmesinin ormancılık ekonomisi ve politika analizlerinde henüz sistematik ve yaygın bir araştırma alanı haline gelmediği anlaşılmaktadır. Özellikle piyasa yapılarının, fiyat oluşum mekanizmalarının, kamu politikalarının ekonomik etkilerinin ve ormancılıkta karar alma süreçlerinin veri temelli yaklaşımlarla modellenmesine yönelik çalışmaların sınırlı kalması, ormancılığın diğer alt disiplinlerine kıyasla bu alanda belirgin bir literatür boşluğuna işaret etmektedir.

1.6 Araştırmanın Amacı, Kapsamı ve Katkısı

Odun hammaddesi piyasalarında fiyat belirsizliği, üretim planlamasını ve kaynak tahsisini olumsuz etkilemekte, bu durum orman işletmeciliği açısından öngörülemeyen ekonomik risklere yol açmaktadır (Leskinen, 1998). Kızılçam (*Pinus brutia*), Türkiye'de en yaygın ibreli ağaç türlerinden biri olup odun hammaddesi üretiminde önemli bir paya sahiptir (Yücesan ve Yıldırım, 2021). Bu nedenle kızılçam tomruk fiyatlarının sistematik ve veri temelli yöntemlerle tahmin edilmesi, sektörel karar alma süreçleri bakımından kritik bir gereksinim olarak değerlendirilmektedir.

Bu çalışmanın temel amacı, OGM tarafından yayımlanan resmi satış verileri kullanılarak kızılçam (*Pinus brutia*) normal boy tomruk açık artırmalı satış fiyatlarının (AASF) makine öğrenmesi yöntemleriyle tahmin edilmesi ve farklı modelleme yaklaşımlarının performanslarının karşılaştırmalı olarak değerlendirilmesidir. Bu kapsamda doğrusal ve doğrusal olmayan makine öğrenmesi algoritmalarının aynı veri seti üzerinde uygulanması, modellerin tahmin başarılarının farklı performans ölçütleri yardımıyla değerlendirilmesi, en başarılı modelin belirlenmesi ve fiyat tahmininde etkili olan değişkenlerin ortaya konması amaçlanmıştır. Ayrıca, tomruk fiyatlarının çok değişkenli ve doğrusal olmayan yapısı dikkate alınarak modellerin tahmin performansları nicel performans ölçütleri ve çok kriterli karar verme yaklaşımı çerçevesinde karşılaştırılmıştır.

Araştırmanın kapsamını, OGM tarafından yayımlanan Ocak 2014-Aralık 2024 dönemine ait aylık açık artırmalı kızılçam normal boy tomruk satış verileri oluşturmaktadır. Bu zaman dilimi hem mevsimsel dalgalanmaları hem de ekonomik kriz dönemlerini kapsayan geniş bir gözlem penceresi sunmaktadır. Çalışmada Türkiye'de kızılçam satışı gerçekleştirilen 21 Orman Bölge Müdürlüğüne (OBM) ait satış verileri kullanılmıştır. Bu bölgeler, kızılçamın doğal yayılış alanını ve Türkiye'deki bölgesel piyasa yapısını büyük ölçüde temsil etmektedir. Bölgesel farklılıkların fiyat oluşumu üzerindeki etkisini modele yansıtabilmek amacıyla OBM'ler kategorik değişken olarak modele dahil edilmiştir. Modelleme sürecinde tomruk fiyatlarını etkileyebileceği değerlendirilen makroekonomik göstergeler, ormancılık sektörüne ilişkin dış ticaret göstergeleri, arz değişkenleri ile geçmiş dönem

fiyat hareketlerini temsil eden gecikmeli değişkenler kullanılmış, farklı makine öğrenmesi algoritmaları aynı veri seti üzerinde uygulanarak tahmin performansları karşılaştırmalı olarak değerlendirilmiştir.

Araştırmanın bazı sınırlılıkları bulunmaktadır. Öncelikle çalışma yalnızca OGM tarafından gerçekleştirilen açık artırmalı kızılçam normal boy tomruk açık artırmalı satışlarını kapsamakta olup diğer odun hammaddesi ürün grupları araştırma kapsamına dahil edilmemiştir. Bu sınırlılık, bulguların doğrudan farklı ürün gruplarına genellenmesini kısıtlamakla birlikte, kızılçam odağındaki metodolojik tutarlılığı güçlendirmektedir. Ayrıca modelleme süreci yalnızca aylık veriler kullanılarak yürütülmüş olup günlük veya haftalık frekansta sistematik veri bulunmaması nedeniyle bu çözünürlüklerde analiz gerçekleştirilememiştir. Kullanılan bağımsız değişkenler güvenilir ve düzenli olarak erişilebilen ekonomik ve sektörel göstergelerle sınırlandırılmış, alıcı sayısı, ihale rekabet düzeyi, ürün kalite özellikleri, taşıma ve üretim maliyetleri gibi fiyat oluşumunu etkileyebilecek bazı değişkenler düzenli veri bulunmaması nedeniyle modele dahil edilememiştir. Bölgesel farklılıkların kısmen temsil edilebilmesi amacıyla OBM'ler modele kategorik değişken olarak dahil edilmiş olsa da, yerel piyasa koşulları, lojistik maliyetleri ve bölgesel üretim yapılarındaki ayrıntılı farklılıklar doğrudan modele yansıtılamamıştır. Son olarak, araştırmada yalnızca seçilen makine öğrenmesi algoritmaları değerlendirilmiş; derin öğrenme tabanlı modeller ve hibrit modelleme yaklaşımları kapsam ve karşılaştırma tutarlılığı gerekçesiyle çalışma dışında bırakılmıştır.

Bu çalışma, ormancılık ekonomisi literatürüne çeşitli yönlerden özgün katkılar sunmaktadır. İlk olarak, kızılçam normal boy tomruk fiyatlarının tahmininde doğrusal ve doğrusal olmayan makine öğrenmesi algoritmaları aynı veri yapısı üzerinde sistematik olarak karşılaştırılmış ve Türkiye koşullarına yönelik kapsamlı bir performans değerlendirmesi gerçekleştirilmiştir. Bu yönüyle çalışma, Türkiye'de kızılçam tomruk fiyat tahminine odaklanan sınırlı sayıdaki ampirik araştırmaya önemli bir katkı sağlamaktadır. İkinci olarak, model performansı yalnızca klasik hata ölçütleri kullanılarak değil, Entropi ve TOPSIS tabanlı çok kriterli karar verme yaklaşımıyla bütüncül olarak değerlendirilmiştir. Bu metodolojik yaklaşımın ormancılık ekonomisi alanındaki uygulamaları oldukça sınırlı olup çalışmanın literatüre metodolojik açıdan

katkı sunduğu değerlendirilmektedir. Üçüncü olarak, en başarılı model SHAP analizi kullanılarak açıklanmış, değişkenlerin fiyat tahminine olan bireysel katkıları ve etkilerinin yönü ortaya konularak modelin yorumlanabilirliği artırılmıştır. Son olarak geliştirilen fiyat tahmin modeli, üretim planlaması, satış stratejilerinin oluşturulması ve karar destek sistemlerinin geliştirilmesi açısından uygulanabilir bir analitik çerçeve sunmakta; ormancılık ekonomisinde veri temelli karar alma süreçlerinin geliştirilmesine katkı sağlamaktadır. Son olarak, çalışmada kullanılan veri seti, Türkiye'de kızılçam üretiminin büyük bölümünü temsil eden 21 OBM'den elde edilen uzun dönemli (2014-2024) aylık gözlemleri kapsamakta olup hem zamansal hem de bölgesel çeşitliliği aynı modelleme çerçevesinde değerlendiren nadir çalışmalardan biridir.

2. LİTERATÜR ÖZETİ

Bu bölümde, ulusal ve uluslararası çalışmalarda kullanılan yöntemsel yaklaşımlar, veri yapıları ve elde edilen bulgular çerçevesinde literatürdeki genel eğilimler, yöntemsel farklılıklar ve araştırma yönelimleri özetlenmektedir.

Ok (1998), açık artırmalı tomruk satış fiyatları üzerinde mevsim etkisini incelemiştir. Çalışmada Bucak, Gazipaşa, Mersin, Mut, Silifke ve Tarsus Orman İşletmelerine ait 3. sınıf normal boy kızılçam tomruk fiyatları analiz edilmiş; yalnızca Gazipaşa Orman İşletmesi'nde satış fiyatları üzerinde istatistiksel olarak anlamlı mevsim etkisi belirlenmiştir. Analiz sonuçlarına göre mevsimsel etkinin Şubat ile Eylül-Aralık aylarında fiyatları olumlu, diğer aylarda ise olumsuz yönde etkilediği tespit edilmiştir. Bu bulgular, açık artırmalı tomruk satış fiyatlarının belirli dönemlerde mevsimsel dalgalanmalardan etkilenebileceğini göstermektedir.

Kayacan ve Öztürk (2009), dünyada orman ürünleri piyasalarının modellenmesine yönelik çalışmaların tarihsel gelişimini ve günümüzde kullanılan başlıca piyasa modellerini karşılaştırmalı olarak incelemişlerdir. Çalışmada, II. Dünya Savaşı sonrasında gelişen ekonometrik piyasa modelleri ile 1980'li yıllardan itibaren geliştirilen Timber Assessment Market Model (TAMM), North American Pulp and Paper Model (NAPAP), CINTRAFOR Global Trade Model (CGTM), Global Forest Products Model (GFPM) ve Timber Supply Model (TSM) gibi kurumsal modeller tanıtılmıştır. Ayrıca Türkiye'de orman ürünleri piyasalarına yönelik çalışmaların ağırlıklı olarak arz ve talep tahminleri ile planlama raporları kapsamında yürütüldüğü belirtilmiş ve uluslararası piyasa modelleme deneyimlerinin gelecekte Türkiye'de geliştirilecek çalışmalara katkı sağlayabileceği vurgulanmıştır.

Koutroumanidis vd. (2009) tarafından yapılan çalışmada Yunanistan'daki yakacak odun fiyatlarının zaman içerisindeki değişimini doğru bir şekilde modelleyebilmek ve geleceğe yönelik fiyat tahminlerinde bulunabilmek amaçlanmıştır. Çalışmada hem geleneksel zaman serisi yöntemlerinin hem de yapay sinir ağı tabanlı modellerin tahmin doğrulukları karşılaştırılarak hangi yöntemin daha başarılı olduğunu belirlenmiştir. Çalışmada yakacak odun fiyat verileri kullanılarak Otoregresif

Bütünleşik Hareketli Ortalama (Autoregressive Integrated Moving Average-ARIMA), Yapay Sinir Ağları (Artificial Neural Networks-ANN) ve bu iki yöntemin birleşiminden oluşan hibrit ARIMA–ANN modeli uygulanmıştır. Elde edilen bulgular, odun fiyatlarının doğrusal ve doğrusal olmayan bileşenler içerdiğini, bu nedenle tek bir yöntemle başarılı sonuç elde etmenin zor olduğunu ortaya koymuştur. Çalışma sonucunda hibrit ARIMA–ANN modelinin fiyat dinamiklerini daha iyi yakaladığı ve tahmin doğruluğunu artırdığı belirlenmiş; bu da orman ürünleri fiyat tahmini çalışmalarında hibrit modellerin güçlü bir alternatif olabileceğini göstermiştir.

Hurmekoski ve Hetemäki (2013), ormancılık sektöründe uzun dönem öngörü çalışmalarında kullanılan yaklaşımları inceleyerek bu çalışmaların değişen küresel orman ürünleri piyasasını ne ölçüde yansıtabildiğini değerlendirmişlerdir. Çalışmada, geleneksel öngörü çalışmalarının özellikle küresel kâğıt piyasalarında yaşanan yapısal değişimleri yeterince yansıtamadığı ve benzer güçlüklerin diğer orman ürünleri piyasaları için de söz konusu olabileceği belirtilmiştir. Ayrıca, politika yapıcıların ve diğer paydaşların karar alma süreçlerinin daha etkin desteklenebilmesi amacıyla, ormancılık sektöründe yaygın olarak kullanılan mevcut modelleme yaklaşımlarının gelecek öngörüsü alanındaki yöntemlerle tamamlanmasının önemli avantajlar sağlayabileceği vurgulanmıştır.

Sivaram (2014), Hindistan'da tik odunu fiyatlarının geçmiş dönem eğilimlerini incelemiş ve geleceğe yönelik fiyat tahmininde istatistiksel yöntemler ile yapay sinir ağlarının performansını karşılaştırmıştır. Çalışmada, fiyat serisinin eğilimleri spline modeller kullanılarak analiz edilmiş ve fiyat değişim hızının farklılaştığı dönemler belirlenerek bu değişimlerin olası nedenleri tartışılmıştır. Geleceğe yönelik fiyat tahmininde ise Otoregresif Bütünleşik Hareketli Ortalama (Autoregressive Integrated Moving Average-ARIMA) modeli ile Yapay Sinir Ağları (Artificial Neural Networks-ANN) modeli karşılaştırılmıştır. Modellerin performansı Ortalama Mutlak Yüzde Hata (Mean Absolute Percentage Error-MAPE) ölçütü ile değerlendirilmiş; ANN modelinin ARIMA modeline göre daha düşük MAPE değerine sahip olduğu ve fiyat serisindeki dönüm noktalarını daha başarılı tahmin ettiği belirlenmiştir. Bununla birlikte, tek değişkenli ARIMA ve ANN modellerinin gelecek yıl fiyat tahminlerinin,

öngörülemeyen dışsal faktörler nedeniyle gerçek fiyatlardan sapabileceği ifade edilmiştir.

Bayramoğlu (2018) tarafından gerçekleştirilen çalışmada, OGM'nin 2001-2016 dönemine ait endüstriyel odun, dikili satış ve yakacak odun satış miktarı ile gelir verileri kullanılarak zaman serisi modelleri oluşturulmuş ve 2017-2027 dönemine ilişkin satış miktarı ile gelir tahminleri yapılmıştır. Çalışma sonucunda, 2027 yılı itibarıyla endüstriyel odun ve dikili satış miktarlarında artış, yakacak odun satış miktarında ise azalış öngörülmüştür. Buna karşın, yakacak odun gelirlerinde artış beklendiği belirtilmiş ve gelecekte yaşanabilecek politik ve ekonomik gelişmelerin tahmin sonuçlarını etkileyebileceği vurgulanmıştır.

Willcock vd. (2018), ekosistem hizmetlerinin modellenmesinde veri güdümlü modelleme (Data-Driven Modelling-DDM) ve makine öğrenmesi yaklaşımlarının potansiyelini incelemişlerdir. Çalışmada, Güney Afrika'da yakacak odun kullanımının modellenmesi ile Sicilya'da biyolojik çeşitlilik değerinin değerlendirilmesine yönelik iki farklı uygulama gerçekleştirilmiş ve bu uygulamalarda Weka ile ARIES yazılımları kullanılmıştır. Elde edilen bulgular, veri güdümlü modelleme yaklaşımının ekosistem hizmetlerinin modellenmesinde geleneksel yöntemlerle karşılaştırılabilir doğruluk sağladığını, belirsizlik bilgilerinin karar vericilere sunulmasına olanak tanıdığını ve karmaşık sosyo-ekolojik problemlere yönelik bütüncül çözümler geliştirilmesine katkı sağlayabileceğini ortaya koymuştur.

Şen ve Güngör (2018) çalışmalarında, Kastamonu Bölge Orman Müdürlüğü'nde açık artırma yöntemiyle satılan çeşitli tomruk türlerinin fiyatları üzerindeki mevsimsel etkileri incelemiş ve gelecek fiyat tahminleri gerçekleştirmiştir. Çalışmada zaman serisi analizi kullanılmış; sonuçlar tomruk satış fiyatlarının mevsimsel dalgalanmalardan etkilendiğini göstermiştir. İlkbahar ve yaz dönemlerinin fiyatlar üzerinde olumlu, sonbahar ve kış dönemlerinin ise olumsuz etkiler oluşturduğu belirlenmiştir.

Şenel (2018) tarafından gerçekleştirilen çalışmada, makroekonomik faktörlerin açık artırmalı tomruk satış fiyatı oluşumu üzerindeki etkileri incelenmiştir. Çalışmada,

Amasya OBM'de 2009–2017 yılları arasında gerçekleştirilen açık artırmalı satış verileri kullanılarak kayın, sarıçam ve karaçam tomruk fiyatları üzerinde altın fiyatı, petrol fiyatı, Amerikan doları kuru, TÜFE, ÜFE, sanayi üretim endeksi, reel faiz oranı ve bir önceki ürün fiyatı gibi makroekonomik değişkenlerin etkileri araştırılmıştır. Analizlerde tanımlayıcı istatistikler, korelasyon ve regresyon analizlerinden yararlanılmıştır. Çalışma sonucunda, farklı tür, sınıf ve boylardaki tomrukların açık artırmalı satış fiyatları üzerinde makroekonomik değişkenlerin etkili olduğu belirlenmiş; ayrıca bu değişkenler kullanılarak fiyat tahmin modelleri oluşturulmuştur.

Korkmaz ve Duman (2020) tarafından gerçekleştirilen çalışmada, Türkiye'de kestane, kekik, defne yaprağı ve çam fıstığı gibi bazı odun dışı orman ürünlerinin dış ticaret yapısı incelenmiştir. Çalışmada dış ticaret verileri kullanılarak ürünlerin ihracat ve ithalat miktarları ile değerlerindeki değişimler değerlendirilmiş; ayrıca kekik ve defne yaprağına ait ihracat miktarı ve gelirleri kullanılarak hareketli ortalamalar, üssel düzeltme ve trend analizleri yardımıyla geleceğe yönelik projeksiyonlar oluşturulmuştur. Çalışma sonucunda, 2019-2023 döneminde kekik ve defne yaprağı ihracat miktarı ve gelirlerinde artış beklendiği belirtilmiştir.

Verly Lopes vd. (2021) tarafından yürütülen bir çalışmada, ABD'deki Büyük Resesyon (2007–2009) ve COVID-19 pandemisi (2020) dönemlerinde kereste fiyatlarının tahmin edilebilirliği Uzun Kısa Süreli Bellek Ağları (Long Short-Term Memory-LSTM) tabanlı tekrarlayan sinir ağları kullanılarak incelenmiştir. Zaman serisi verilerinin zamansal yapısını korumak amacıyla geleneksel k-katlı çapraz doğrulama yerine time series split (zaman serisi bölmeli) çapraz doğrulama yöntemi uygulanmıştır. Model performansı Ortalama Kare Hata (Mean Squared Error-MSE), Kök Ortalama Kare Hata (Root Mean Squared Error-RMSE) ve Ortalama Mutlak Hata (Mean Absolute Error- MAE) metrikleriyle değerlendirilmiş ve sonuçlar, LSTM modelinin her iki kriz döneminde de kereste fiyatlarındaki eğilimleri düşük hata oranlarıyla başarılı biçimde tahmin edebildiğini göstermiştir.

Jaafari vd. (2021), İran'daki Hyrkanian Ormanları'nda orman yolu yapım maliyetlerinin tahmininde makine öğrenmesi yöntemlerinin başarısını incelemiştir. Çalışmada farklı algoritmalar karşılaştırılmış ve SVM modelinin en yüksek doğrulukla

maliyet tahmini yaptığı belirlenmiştir (R=0,993; RMSE= %2,44). Sonuçlar, makine öğrenmesi tabanlı yaklaşımların orman yolu projelerinde erken aşama maliyet planlaması ve kaynak tahsisi açısından etkili bir araç olduğunu göstermiştir.

Banaś vd. (2021) tarafından gerçekleştirilen çalışmada, Polonya'da 2005-2020 dönemine ait çam, ladin, kayın, huş ve kızılağaç yuvarlak odun fiyatları kullanılarak kısa dönem fiyat tahminleri yapılmıştır. Çalışmada Otoregresif Bütünleşik Hareketli Ortalama (Autoregressive Integrated Moving Average-ARIMA), Mevsimsel Otoregresif Bütünleşik Hareketli Ortalama (Seasonal Autoregressive Integrated Moving Average-SARIMA) ve dışsal değişken içeren Mevsimsel Otoregresif Bütünleşik Hareketli Ortalama (Seasonal Autoregressive Integrated Moving Average with Exogenous Variables-SARIMAX) modelleri karşılaştırılmıştır. Sonuçlar, mevsimsel bileşenin ARIMA modeline eklenmesinin mevsimsel değişim gösteren yuvarlak odun fiyatlarının tahmin doğruluğunu artırdığını, ayrıca CCI değişkenini içeren SARIMAX modelinin kısa dönem fiyat tahminlerinde iş döngülerindeki değişimleri daha başarılı şekilde yansıttığını göstermiştir.

Górna ve Adamowicz (2021), Polonya'da tomruk fiyatlarının tahmininde Doğrusal Yaklaştırma Yöntemi (Linear Approximation Method-LAM) ile Brown Üstel Düzleştirme Modelinin (Brown's Exponential Smoothing Model-BESM) tahmin performanslarını karşılaştırmışlardır. Çalışmada, 2006-2017 dönemine ait ortalama yıllık tomruk fiyatları kullanılarak 5, 7 ve 9 yıllık zaman serileri oluşturulmuş ve 2015–2017 yıllarına ilişkin fiyat tahminleri gerçekleştirilmiştir. Modellerin tahmin başarısı tahmin edilen ve gerçekleşen fiyatlar karşılaştırılarak değerlendirilmiş; sonuçlar, LAM yönteminin BESM'ye göre daha düşük mutlak ve bağıl hata değerleri ürettiğini göstermiştir. Ayrıca, doğrusal olmayan trendlerin de dikkate alındığı yeni çalışmaların tomruk fiyatlarının tahminine katkı sağlayabileceği belirtilmiştir.

Firebanks-Quevedo vd. (2022) tarafından yürütülen bir çalışmada, Latin Amerika ülkelerinde orman ve peyzaj restorasyonu politikalarında yer alan ekonomik teşviklerin otomatik olarak belirlenmesi ve sınıflandırılması amacıyla makine öğrenmesi ve doğal dil işleme temelli bir yaklaşım geliştirilmiştir. Meksika, El Salvador, Şili, Peru ve Guatemala'ya ait politika belgeleri "Dönüştürücülerden Çift

Yönlü Kodlayıcı Gösterimleri Temelli Cümle Modellemesi (Sentence Bidirectional Encoder Representations from Transformers-S-BERT)" ile temsil edilerek SVM, RF ve LGBM algoritmalarıyla sınıflandırılmıştır. Sonuçlar, en yüksek başarının RF modeliyle elde edildiğini ve teşvik sınıflandırmasında %93–94 aralığında F1 skoruna (kesinlik ve duyarlılık ölçütlerinin harmonik ortalaması) ulaşıldığını göstermiştir. Çalışma, ormancılık politikalarının analizinde veri temelli ve ölçeklenebilir karar destek sistemlerinin uygulanabilirliğini ortaya koymuştur.

Lamichhane vd. (2023) tarafından gerçekleştirilen bir çalışmada, ABD'nin güneyinde yer alan 22 farklı bölgede çam kerestelik tomruk fiyatlarının tahmini amacıyla ANN ile klasik ekonometrik yöntemlerin bir kombinasyonundan oluşan hibrit zaman serisi modellerinin performansını karşılaştırılmıştır. Çalışmada 1976–2022 dönemine ait çeyreklik fiyat verileri kullanılarak ARIMA, üstel düzeltme ve "Box-Cox Dönüşümü, ARMA Hataları, Trend ve Mevsimsel Bileşenler (Trigonometric, Box-Cox Transformation, ARMA Errors, Trend and Seasonal Components-Trigonometrik-TBATS)" yöntemlerini içeren hibrit modeller ile çok katmanlı algılayıcı yapısına sahip ANN modeli değerlendirilmiştir. Sonuçlar, ANN modellerinin 22 bölgenin 21'inde daha düşük hata değerleri (RMSE ve Ortalama Mutlak Yüzde Hata (Mean Absolute Percentage Error-MAPE)) üreterek hibrit modellere kıyasla daha başarılı tahmin performansı sergilediğini göstermiştir. Ayrıca ANN modellerinin ani fiyat değişimlerini yakalamada daha etkili olduğu, hibrit modellerin ise fiyat trendlerini yumuşatma eğiliminde olduğu belirlenmiştir. Çalışma, tomruk fiyatlarının tahmininde ANN tabanlı yöntemlerin orman endüstrisi ve yatırımcılar için daha güvenilir bir karar destek aracı sunduğunu ortaya koymuştur.

Kozuch vd. (2023) tarafından yürütülen çalışmada, Polonya'daki kereste fiyatlarının tahmininde yapay sinir ağları ile geleneksel zaman serisi modellerinin performansı karşılaştırılmıştır. Çalışmada 2005–2021 dönemine ait Sarıçam, Avrupa ladini, meşe, huş ve kızılağaç türlerine ilişkin çeyreklik nominal net tomruk fiyatları kullanılmıştır. Çok Katmanlı Algılayıcı ve Radyal Tabanlı Fonksiyon ağları; ARIMA, Hata, Trend, Mevsimsellik (Error, Trend, Seasonality-ETS), "Box-Cox Dönüşümü, ARMA Hataları, Trend ve Mevsimsel Bileşenler (Box-Cox Transformation, ARMA Errors, Trend and Seasonal Components-BATS)", TBATS ve Prophet gibi klasik zaman serisi

yöntemleriyle karşılaştırılmıştır. Modellerin başarımı RMSE ve MAE metrikleriyle, 12 çeyreklik (3 yıllık) tahmin ufku üzerinden değerlendirilmiştir. Bulgular, Çok Katmanlı Algılayıcı (Multilayer Perceptron-MLP) modelinin fiyat seviyeleri ve değişimlerini tahmin etmede diğer tüm yöntemlere kıyasla daha yüksek doğruluk sağladığını göstermiştir. Çalışmada, kereste piyasası gibi karmaşık ve doğrusal olmayan ekonomik süreçlerin tahmininde yapay sinir ağlarının geleneksel istatistiksel yöntemlere göre daha esnek ve güvenilir bir yaklaşım sunduğu sonucuna varılmıştır.

Özbalcı vd. (2024), Türkiye'deki kentsel orman rekreasyon alanlarının gelecekteki dağılımını makine öğrenmesi yöntemleriyle tahmin etmişlerdir. Çalışmada, 2013-2021 yıllarına ait Orman Genel Müdürlüğü tarafından yayımlanan D tipi kentsel orman rekreasyon alanı verileri kullanılarak doğrusal regresyon (Linear Regression-LR), Gradient Boosted Regression Trees (GBRT) ve ANN modelleri karşılaştırılmıştır. Modellerin performansı R^2, Ortalama Kare Hata (Mean Squared Error-MSE), Kök Ortalama Kare Hata (Root Mean Squared Error-RMSE), Ortalama Mutlak Hata (Mean Absolute Error-MAE) ve Ortalama Mutlak Yüzde Hata (Mean Absolute Percentage Error-MAPE) metrikleri ile değerlendirilmiştir. Sonuçlar, ANN modelinin en yüksek tahmin performansını (R^2=0,99) gösterdiğini ve makine öğrenmesi yöntemlerinin kentsel orman rekreasyon alanlarının geleceğe yönelik tahmininde güvenilir bir araç olarak kullanılabileceğini ortaya koymuştur.

Kaya vd. (2023), müşterilerin açık artırmalı tomruk satışlarından beklentilerine yönelik anket temelli çalışmalarında müşterilerin fiyat beklentileri, satın alma stratejileri, rekabet algıları ve açık artırma süreçlerine yönelik değerlendirmeleri incelemişlerdir. Çalışma sonuçları açık artırmalarda fiyatların yalnızca arz-talep dengesi ile değil; aynı zamanda müşteri psikolojisi, rekabet baskısı, algılanan risk ve işletmeler arası stratejik davranışlarla birlikte şekillendiğini göstermiştir.

Ji vd. (2024) tarafından Güney Kore'nin Gangwon Eyaleti'nde yer alan Bongpyeong pilot orman yönetim bölgesinde gerçekleştirilen çalışmada, ormanların ekonomik (kereste üretimi) ve ekolojik (karbon depolama ve su kaynağı yenileme) fonksiyonlarını birlikte optimize etmeyi amaçlayan bir orman yönetim modeli geliştirilmiştir. Çalışmada pekiştirmeli öğrenme yöntemlerinden Q-learning

algoritması kullanılmış ve CBS (Coğrafi Bilgi Sistemleri) tabanlı mekansal veriler ile idari kayıtlar analiz edilmiştir. Altmış yıllık dönem için dört farklı yönetim senaryosu karşılaştırılmış; sonuçlar karbon depolamaya öncelik veren senaryonun en yüksek ekonomik değeri sağladığını ve aynı zamanda sürdürülebilir kereste arzı ile orman yapısında iyileşme oluşturduğunu göstermiştir. Çalışma, pekiştirmeli öğrenmenin çok hedefli ve uzun vadeli orman yönetimi planlamasında etkili bir karar destek aracı olduğunu ortaya koymuştur.

Bardak vd. (2024), orman ürünleri sektöründe faaliyet gösteren Kartonsan firmasının hisse senedi fiyatlarını makine öğrenmesi yöntemleriyle tahmin etmişlerdir. Çalışmada, 2011–2022 yılları arasına ait üçer aylık finansal tablolar kullanılarak hesaplanan finansal oranlar girdi değişkeni, hisse senedi fiyatlarının üçer aylık ortalamaları ise çıktı değişkeni olarak kullanılmıştır. Hisse senedi fiyatlarının tahmininde Doğrusal Regresyon (Linear Regression-LR), Rastgele Orman (Random Forest-RF), Gradyan Güçlendirme Makinesi (Gradient Boosting Machine-GBM) ve Yapay Sinir Ağları (Artificial Neural Networks-ANN) algoritmaları uygulanmış ve tahmin performansları karşılaştırılmıştır. Çalışma sonucunda, GBM algoritmasının en başarılı tahmin performansını gösterdiği, RF algoritmasının LR ve ANN modellerine göre daha iyi sonuçlar verdiği, ANN modelinin ise hisse senedi fiyatı tahmininde en düşük performansa sahip yöntem olduğu belirlenmiştir.

Şen ve Ergün Karak (2024), Türkiye'de Karaçam–Sarıçam normal boy tomruklarının açık artırmalı satış fiyatlarını makine öğrenmesi teknikleriyle tahmin etmeyi hedefledikleri çalışmalarında, OGM'ye bağlı 26 OBM'den 2014-2023 dönemine ait aylık açık artırma satış verilerini kullanmışlardır. Çalışmada Doğrusal Regresyon (Linear Regression-LR), DR, RF ve XGBoost modellerini uygulamışlar ve sonuçlar tür çeşitliliğini ve piyasa etkileşimlerini modele dahil etmenin tahmin doğruluğunu artırdığını, XGBoost algoritmasının tomruk fiyat tahmininde güçlü bir araç olduğunu ve makine öğrenmesi tabanlı yaklaşımların sürdürülebilir orman kaynakları yönetimi ile piyasa öngörüleri açısından önemli bir potansiyel taşıdığını ortaya koymuştur.

Turgay (2024), çalışmasında tedarik zincirinde talep tahminine yönelik makine öğrenmesi modellerinin performansını incelemiş ve envanter yönetimi üzerindeki

etkilerini değerlendirmiştir. Elde edilen bulgular, makine öğrenmesi tabanlı talep tahminlerinin klasik yöntemlere göre daha düşük hata oranları ürettiğini; bunun da envanter maliyetlerinin azalmasına ve tedarik zinciri verimliliğinin artmasına katkı sağladığını göstermiştir.

Tiryaki (2025) çalışmasında Türkiye'de endüstriyel odun üretiminin geleceğe yönelik tahmini için çeşitli trend analiz yöntemlerini karşılaştırarak üretim projeksiyonları oluşturmuştur. Çalışmada, Orman Genel Müdürlüğü tarafından yayımlanan 2000-2023 dönemine ait yıllık endüstriyel odun üretim verileri kullanılmış ve doğrusal (Linear), üstel büyüme (Exponential Growth), karesel (Quadratic) ve S-eğrisi (S-curve) trend analiz fonksiyonları uygulanmıştır. Modellerin tahmin performansı Ortalama Mutlak Yüzde Hata (Mean Absolute Percentage Error-MAPE) ve Belirleme Katsayısı (Coefficient of Determination-R^2) ölçütleri kullanılarak değerlendirilmiştir. Sonuçlar, doğrusal modelin en yüksek MAPE ve en düşük R^2 değerlerine sahip olduğunu, karesel modelin ise en düşük MAPE ve en yüksek R^2 değerlerini sağlayarak en başarılı tahmin performansını gösterdiğini ortaya koymuştur.

Thao ve Duc (2025), Vietnam'da kereste fiyatlarının tahminine yönelik olarak Grafik Sinir Ağları (Graph Neural Networks-GNN) ile Uzun Kısa Süreli Bellek (Long Short-Term Memory-LSTM) modelini bütünleştiren hibrit bir tahmin modeli geliştirmişlerdir. Çalışmada, 2000–2024 dönemine ait kereste fiyatları, hasat hacimleri, iklim verileri ve ihracat kayıtları kullanılmıştır. GNN modeli kereste üretim bölgeleri arasındaki mekânsal bağımlılıkları, LSTM modeli ise uzun dönemli zamansal eğilimleri modellemiştir. Sonuçlar, önerilen GNN-LSTM hibrit modelinin geleneksel ARIMA, SARIMA ve VAR modellerine göre daha yüksek tahmin doğruluğu sağladığını (MSE =0,0023; RMSE=0,0480; MAE=0,0340; R^2=0,94) ve karmaşık mekânsal-zamansal ilişkileri daha başarılı şekilde temsil ettiğini göstermiştir.

Chang ve Li (2025), çalışmalarında odun bazlı panel vadeli işlem fiyatlarının tahmini amacıyla tedarik zinciri özelliklerini modele dâhil eden çift frekanslı bir füzyon ağı (DM-FusionNet) geliştirmişlerdir. Çalışmada, günlük fiyat verileri çift yönlü Uzun Kısa Süreli Bellek (Bidirectional Long Short-Term Memory-Bi-LSTM) ağı ile, aylık

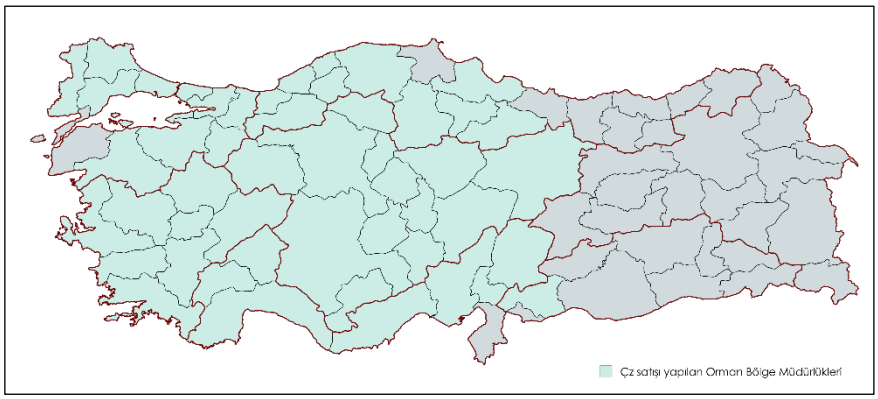
tedarik zinciri değişkenleri ise Transformer tabanlı bir yapı ile analiz edilmiş ve dinamik bir füzyon mekanizması kullanılarak birleştirilmiştir. Önerilen modelin performansı ANN, LSTM, GARCH-MIDAS ve Hierarchical BVAR modelleriyle karşılaştırılmıştır. Sonuçlar, DM-FusionNet modelinin tüm değerlendirme ölçütlerinde daha yüksek tahmin başarısı gösterdiğini, Ortalama Kare Hatada (Mean Squared Error-MSE) %16,8 iyileşme sağladığını ve R^2=0,870 değerine ulaştığını ortaya koymuştur.

3. MATERYAL VE YÖNTEM

Bu bölümde, kızılçam normal boy tomruk fiyatlarının tahminine yönelik gerçekleştirilen araştırmanın materyal ve yöntem çerçevesi sunulmaktadır. Araştırma kapsamında kullanılan veri setlerinin kaynakları, çalışma alanı, veri ön işleme süreci, modelleme yaklaşımı ve performans değerlendirme yöntemleri ayrıntılı olarak açıklanmıştır. Ayrıca tomruk fiyatlarının tahmininde kullanılan makine öğrenmesi modelleri ile model performanslarının karşılaştırılmasında yararlanılan değerlendirme ölçütleri ve çok kriterli karar verme yaklaşımına ilişkin metodolojik süreçlere yer verilmiştir.

3.1 Çalışma Alanı ve Veri Seti

Çalışma alanı, Türkiye'de kızılçam tomruk satışlarının gerçekleştirildiği OBM'leri kapsamaktadır. Kızılçam (*Pinus brutia*), yaklaşık 5,3 milyon hektarlık yayılış alanıyla Türkiye'nin en geniş yayılışa sahip ibreli ağaç türüdür (OGM, 2023). Bu nedenle çalışmada kızılçam normal boy tomruk açık artırmalı satış fiyatları esas alınmıştır. Araştırmada kullanılan veri seti, OGM tarafından yayımlanan resmi satış verileri temel alınarak oluşturulmuştur (URL-1, 2025). Analiz kapsamında kızılçam üretimi yapılan Adana, Amasya, Ankara, Antalya, Balıkesir, Bolu, Bursa, Denizli, Eskişehir, Isparta, İstanbul, İzmir, Kahramanmaraş, Kastamonu, Kayseri, Konya, Kütahya, Mersin, Muğla, Sakarya ve Zonguldak olmak üzere toplam 21 OBM'ye ait veriler kullanılmıştır. Araştırma kapsamında değerlendirilen OBM'nin mekânsal dağılımı Şekil 3.1'de verilmiştir.



Şekil 3.1 Araştırma kapsamında kullanılan OBM'lerin mekânsal dağılımı

Araştırmada kullanılan veri seti, OGM tarafından yayımlanan resmi açık artırmalı satış verileri esas alınarak oluşturulmuş olup Ocak 2014-Aralık 2024 dönemine ait aylık gözlemleri kapsamaktadır. Çalışmanın bağımlı değişkenini kızılçam normal boy tomruk açık artırmalı satış fiyatları oluşturmaktadır. Tomruk açık artırmalı satış fiyatlarını etkileyebilecek ekonomik, sektörel, bölgesel ve zamansal dinamiklerin modele yansıtılabilmesi amacıyla veri setine makroekonomik göstergeler, dış ticaret değişkenleri, sektörel göstergeler ile özellik mühendisliği kapsamında oluşturulan gecikmeli fiyat değişkenleri ve hareketli ortalama değişkeni dahil edilmiştir. Ayrıca, fiyat oluşumunda bölgesel heterojenliğin etkisini kısmen temsil edebilmek amacıyla satışların gerçekleştirildiği OBM'ler kategorik (dummy) değişkenler olarak modele dahil edilmiştir. Bu yaklaşım, bölgesel farklılıkların modele belirli ölçüde yansıtılmasına katkı sağlamakla birlikte, yerel maliyet yapıları, lojistik koşullar, piyasa dinamikleri ve diğer mekânsal farklılıkların doğrudan temsil edilmesini sağlayamamaktadır.

Çalışmada kullanılan bağımlı ve bağımsız değişkenler ile bu değişkenlerin bu modele dahil edilme gerekçeleri Tablo 3.1'de verilmiştir.

Tablo 3.1 Çalışmada kullanılan değişkenler ve kullanım amaçları

Sembol	Değişken	Açıklama
Y	Kızılçam normal boy tomruk açık artırmalı satış fiyatı	Modelin tahmin etmeyi amaçladığı bağımlı değişkendir.
X_1	Bölge müdürlüğü	Tomruk fiyatları üzerinde bölgesel piyasa koşulları, üretim yapısı ve lojistik farklılıkların oluşturabileceği heterojenliği kısmen temsil etmek amacıyla modele dahil edilmiştir. Modelleme aşamasında OBM değişkeni One-Hot Encoding yöntemi kullanılarak ikili (dummy) değişkenlere dönüştürülmüş olup, tabloda gösterim kolaylığı açısından tek değişken olarak sunulmuştur.
X_2	Ay (1-12)	Mevsimsellik ve takvim etkilerini temsil etmek amacıyla modele dahil edilmiştir.
X_3	Kızılçam kısa boy tomruk açık artırmalı satış fiyatı	Aynı türün farklı ürün sınıfındaki fiyat hareketlerinin bağımlı değişken fiyatı ile birlikte değişebileceği varsayımıyla modele dahil edilmiştir.
X_4	Kızılçam normal boy tomruk satış miktarı	Piyasadaki işlem hacmini ve arz koşullarını dolaylı olarak temsil etmesi amacıyla modele dahil edilmiştir.
X_5	Kızılçam kısa boy tomruk satış miktarı	Farklı ürün sınıfındaki işlem hacmini ve arz koşullarını dolaylı olarak temsil etmesi amacıyla modele dahil edilmiştir.
X_6	Sanayi üretim endeksi	Ekonomik faaliyet düzeyini temsil etmesi amacıyla modele dahil edilmiştir.
X_7	TÜFE	Genel fiyat düzeyindeki değişimleri temsil etmesi amacıyla modele dahil edilmiştir.
X_8	ÜFE	Üretici fiyatlarındaki değişimleri temsil etmesi amacıyla modele dahil edilmiştir.
X_9	Mevduat faiz oranı	Faiz piyasasındaki değişimleri ve alternatif yatırım tercihlerinin tomruk fiyatları üzerindeki olası etkilerini temsil etmesi amacıyla modele dahil edilmiştir.
X_{10}	Döviz kuru	Döviz piyasasındaki değişimleri temsil etmesi amacıyla modele dahil edilmiştir.
X_{11}	Altın fiyatı	Emtia piyasalarındaki fiyat hareketlerini, alternatif yatırım eğilimlerini ve ekonomik belirsizlik dönemlerinde oluşabilecek yatırım davranışlarını temsil etmesi amacıyla modele dahil edilmiştir.
X_{12}	Mazot fiyatı	Üretim, hasat ve taşıma maliyetlerindeki değişimleri temsil etmesi amacıyla modele dahil edilmiştir.
X_{13}	GSYH	Makroekonomik büyüme ve toplam ekonomik aktivite düzeyini temsil etmesi amacıyla modele dahil edilmiştir.
X_{14}	İhracat (44)	Orman ürünleri ihracatındaki değişimleri temsil etmesi amacıyla modele dahil edilmiştir.
X_{15}	İthalat (44)	Orman ürünleri ithalatındaki değişimleri temsil etmesi amacıyla modele dahil edilmiştir.
X_{16}	İhracat (47)	Kağıt ve kağıt ürünleri ihracatındaki değişimleri temsil etmesi amacıyla modele dahil edilmiştir.
X_{17}	İthalat (47)	Kağıt ve kağıt ürünleri ithalatındaki değişimleri temsil etmesi amacıyla modele dahil edilmiştir.
X_{18}	Kızılçam normal boy tomruk satış fiyatı (1 ay gecikmeli)	Kısa dönemli fiyat bağımlılığını temsil etmek amacıyla modele dahil edilmiştir.
X_{19}	Kızılçam normal boy tomruk satış fiyatı (3 ay gecikmeli)	Orta dönemli fiyat bağımlılığını temsil etmesi amacıyla modele dahil edilmiştir.
X_{20}	Kızılçam normal boy tomruk satış fiyatı (6 ay gecikmeli)	Uzun dönemli fiyat bağımlılığını temsil etmesi amacıyla modele dahil edilmiştir.
X_{21}	Kızılçam normal boy tomruk satış fiyatı (Son 3 aylık hareketli ortalama)	Kısa dönemli fiyat oynaklığını azaltarak genel fiyat eğilimini temsil etmek amacıyla modele dahil edilmiştir.

Tablo 3.1'de verilen bağımsız değişkenler, makroekonomik göstergeler, ormancılık sektörüne ilişkin ticaret değişkenleri, ürün bazlı satış değişkenleri ve özellik mühendisliği kapsamında oluşturulan değişkenlerden oluşmaktadır. Makroekonomik göstergeler kapsamında Türkiye Cumhuriyet Merkez Bankası mevduat faiz oranı (URL-2, 2025), sanayi üretim endeksi (URL-3, 2025), gayrisafi yurt içi hasıla (URL-4, 2025), tüketici fiyat endeksi (URL-5, 2025), üretici fiyat endeksi (URL-6, 2025), altın fiyatları (URL-7, 2025) ve mazot fiyatları (URL-8, 2025) kullanılmıştır. Dış ticaret göstergeleri olarak ise ormancılık sektörüne ait "İhracat (44)" ve "İthalat (44)" (ağaç, ahşap eşya ve odun kömürü) ile "İhracat (47)" ve "İthalat (47)" (odun veya diğer lifli selülozik maddelerin hamurları ile geri kazanılmış kağıt ve karton ürünleri) değişkenlerine ait veriler kullanılmıştır (URL-9, 2025). Ayrıca OGM tarafından yayımlanan kızılçam normal boy tomruk satış miktarı, kızılçam kısa boy tomruk açık artırmalı satış fiyatı ve satış miktarı verileri de modele dahil edilmiştir (URL-1, 2025). Geçmiş dönem fiyat hareketliliklerinin mevcut dönem fiyatı üzerindeki etkisinin modele yansıtılması amacıyla özellik mühendisliği kapsamında oluşturulan kızılçam normal boy tomruk açık artırmalı satış fiyatının 1, 3 ve 6 aylık gecikmeli değerleri ve son 3 aylık hareketli ortalama değişkeni veri setine eklenmiştir. GSYH verileri TÜİK tarafından çeyreklik frekansta yayımlandığından, aylık veri setiyle uyum sağlanabilmesi amacıyla her çeyreğe ait GSYH değeri ilgili üç aya atanmıştır. Böylece tüm değişkenlerin ortak zaman frekansında analiz edilmesi sağlanmıştır.

Ayrıca çalışmada başlangıçta kızılçam normal boy tomruk AASF'yi etkilediği düşünülen karaçam, sarıçam, meşe, sedir, göknar, ladin ve kayın türlerine ait satış fiyatı ve satış miktarı verileri de veri setine dahil edilmiştir. Ancak gerçekleştirilen ön analizler sonucunda bu türlere ait değişkenlerin tahmin performansına anlamlı bir katkı sağlamadığı ve modellerin genel başarısını artırmadığı belirlenmiştir. Bu nedenle veri setinin homojenliğini artırmak ve türler arası yapısal farklılıklardan kaynaklanabilecek etkileri azaltmak amacıyla analizlere yalnızca kızılçam tomruk verileri ile devam edilmiştir.

Çalışmada uygulanan yöntemsel süreç ve analiz aşamalarına ilişkin iş akışı Şekil 3.2'de verilmiştir.



Şekil 3.2 İş akış şeması

Şekil 3.2 incelendiğinde, çalışmada izlenen yöntemin veri toplama aşamasından başlayarak veri hazırlama, veri ön işleme, özellik mühendisliği, model geliştirme ve performans değerlendirme süreçlerinden oluştuğu görülmektedir. Veri hazırlama sürecinde veri setinin genel özelliklerini ortaya koymak amacıyla tanımlayıcı istatistikler hesaplanmış ve korelasyon analizi gerçekleştirilmiştir. Ardından veri ön işleme kapsamında one-hot encoding (kategorik değişkenlerin sayısal forma dönüşümü) ve ölçekleme işlemi (Robust Scaler-RS) uygulanmıştır. Ardından makine öğrenmesi modelleri kapsamında LR, Ridge Regresyon (Ridge Regression-RR), RF, XGBoost ve LGBM modelleri geliştirilmiş ve hiperparametre optimizasyonu gerçekleştirilmiştir. Modeller; Belirtme katsayısı (R^2), RMSE, MAE, Nash-Sutcliffe Etkinlik Katsayısı (Nash–Sutcliffe Efficiency-NSE), Kling-Gupta Etkinliği (Kling-Gupta Efficiency-KGE), Medyan Mutlak Hata (Median Absolute Error-MedAE) ve Simetrik Ortalama Mutlak Yüzde Hata (Symmetric Mean Absolute Percentage Error-

sMAPE) performans metrikleri kullanılarak değerlendirilmiştir. Sonraki aşamada Entropi ve TOPSIS yöntemleri ile en başarılı model belirlenmiş, belirlenen model için SHAP analizi uygulanarak değişken önem düzeyleri incelenmiştir. Son aşamada ise geliştirilen tüm makine öğrenmesi modelleri kullanılarak tomruk AASF'lerine ilişkin tahminler gerçekleştirilmiş ve elde edilen tahmin sonuçları grafik yardımıyla karşılaştırmalı olarak değerlendirilmiştir.

3.2 Verilerin Analize Hazırlanması

Veri analizi sürecinde, çalışma kapsamında elde edilen veriler makine öğrenmesi modelleme yaklaşımına uygun biçimde düzenlenmiş ve analiz sürecine hazırlanmıştır. Modellerin veri yapısı ve işlem mantıkları birbirinden farklı olduğundan, bazı modelleme yaklaşımlarında veri ön işleme ve değişken oluşturma süreçleri farklı biçimlerde gerçekleştirilmiştir. Analizler, Python v3.11 programlama dili kullanılarak yürütülmüştür. Veri analizi sürecinde, elde edilen modelleme sonuçlarının güvenilirliğini ve genellenebilirliğini artırmak amacıyla çeşitli ön işleme ve filtreleme adımları uygulanmıştır. Bu kapsamda, Türk lirası (TL) cinsinden ifade edilen satış fiyatı ve makroekonomik değişkenler, özellikle analiz döneminde yaşanan yüksek enflasyon ve kur oynaklığının neden olabileceği nominal dalgalanmaların etkisini azaltmak amacıyla Amerikan doları (USD) cinsine dönüştürülmüştür (URL-10, 2025). Böylece, değişkenler arası karşılaştırılabilirliğin artırılması ve fiyat serilerinin reel eğilimlerinin daha sağlıklı biçimde analiz edilmesi hedeflenmiştir. Bununla birlikte, yalnızca döviz cinsinden ifade edilen fiyat serileriyle kurulan modellerin, özellikle kısa vadeli fiyat hareketlerini açıklamakta sınırlı kaldığı gözlenmiştir. Bu nedenle, kur hareketlerinin tomruk fiyatları üzerindeki doğrudan etkisini modele yansıtabilmek amacıyla, döviz kuru değişkeni de açıklayıcı değişkenler arasına dahil edilmiştir.

Veri setindeki değişkenler arasındaki ilişkilerin belirlenebilmesi amacıyla, $p<0.05$ anlamlılık düzeyinde Pearson korelasyon analizi uygulanmıştır. Pearson korelasyon katsayısı -1 ile +1 arasında değer almakta olup, katsayının işareti ilişkinin yönünü, mutlak değeri ise ilişkinin gücünü ifade etmektedir (Mukaka, 2012). Evans (1996)'ın sınıflandırmasına göre korelasyon katsayısının mutlak değeri 0.00-0.19 arasında ise çok zayıf, 0.20-0.39 arasında ise zayıf, 0.40-0.59 arasında ise orta, 0.60-0.79 arasında

ise güçlü ve 0.80-1.00 arasında ise çok güçlü düzeyde ilişki olarak değerlendirilmiştir. Pearson korelasyon katsayısı hesaplama formülü aşağıda verilmektedir:

$$r = \frac{\sum_{i=1}^{n}(x_i - x)(y_i - y)}{\sqrt{[\sum_{i=1}^{n}(x_i - \bar{x})^2][\sum_{i=1}^{n}(y_i - \bar{y})^2]}} \quad (3.1)$$

Burada; r; Pearson korelasyon katsayısını, x_i; x değişkenine ait i. gözlem değerini, y_i; y değişkenine ait i. gözlem değerini, $\bar{x}$; x değişkeninin ortalamasını, $\bar{y}$; y değişkeninin ortalamasını, n; toplam gözlem sayısını ifade etmektedir. Bu kapsamda, değişkenler arasındaki ilişki düzeyleri incelenmiş ve özellikle makroekonomik göstergeler arasındaki yüksek ilişki yapıları değerlendirilmiştir.

Çalışmada, tür bazlı fiyat dinamiklerinin daha ayrıntılı biçimde incelenebilmesi amacıyla analiz kapsamı kızılçam türü ile sınırlandırılmıştır. Bu doğrultuda, incelenen dönem boyunca kızılçam üretimi gerçekleştirilmeyen OBM'leri veri setinden çıkarılmıştır. Kızılçam üretimi bulunmayan bölge müdürlüklerinin veri setinde yer almasının, satış fiyatları ve satış miktarları açısından gereksiz ya da eksik gözlemlerin oluşmasına yol açarak modelleme sürecini olumsuz etkileyebileceği değerlendirilmiştir. Bu veri düzenleme yaklaşımının temel amacı, modelleme sonuçlarına ilişkin istatistiksel çıkarımların güvenilirliğini ve ekonomik yorumların anlamlılığını artırmaktır.

3.2.1 Tomruk Fiyatı Tahmin Modellerinde Makine Öğrenimi Yaklaşımı

Modelleme sürecinde, tomruk fiyatlarının zamansal bağımlılık yapısını daha iyi temsil edebilmek amacıyla gecikmeli fiyat değişkenleri veri setine dahil edilmiştir. Zamana bağlı veri yapılarında gecikmeli değişkenlerin kullanımı, geçmiş dönem gözlemlerinin mevcut dönem değerleri üzerindeki etkisinin modele yansıtılmasına olanak sağlamaktadır (Hyndman ve Athanasopoulos, 2021). Bu kapsamda, bir önceki aya ait fiyatı temsil eden 1 aylık gecikmeli fiyat, üç ay önceki fiyatı temsil eden 3 aylık gecikmeli fiyat ve altı ay önceki fiyatı temsil eden 6 aylık gecikmeli fiyat değişkenleri oluşturulmuştur. Buna ek olarak, kısa dönemli fiyat eğilimlerini yansıtmak amacıyla son üç aylık ortalamayı temsil eden hareketli ortalama değişkeni kullanılmıştır.

OBM değişkeni nominal kategorik yapıda olduğundan, modelleme öncesinde One-Hot Encoding yöntemi kullanılarak ikili değişkenlere dönüştürülmüştür. Bu nedenle söz konusu değişken Pearson korelasyon analizine dahil edilmemiştir. One-Hot Encoding, kategorik değişkenleri her kategori için ayrı bir ikili değişken oluşturarak sayısal forma dönüştüren bir yöntemdir (Pargent vd., 2022). Veri seti, zaman bağımlılığı dikkate alınarak sıralanmış ve verilerin %80'i eğitim, %20'si test veri seti olarak ayrılmıştır.

Modelleme sürecinde, değişkenlerin ölçek farklılıklarının doğrusal modeller üzerindeki etkisini azaltmak amacıyla veri ölçekleme yöntemleri kullanılmıştır. Bu kapsamda, LR ve RR modellerinde, katsayı tahminlerinin daha kararlı ve karşılaştırılabilir olması amacıyla RS yöntemi tercih edilmiştir. Ağaç tabanlı modellerde (XGBoost, LGBM ve RF) ise bölünmeler değişkenlerin mutlak büyüklüklerinden ziyade göreli sıralamalarına dayandığından, ölçekleme işlemi uygulanmamıştır (Ouameur vd., 2020).

RS, veri setini medyan etrafında merkezleyerek ve ölçeklendirmeyi çeyrekler arası aralık (Interquartile Range) temelinde gerçekleştiren bir normalizasyon yöntemidir. Bu yaklaşımda, birinci çeyrek (Q1) ile üçüncü çeyrek (Q3) arasındaki fark esas alınmakta ve böylece uç değerlerin ölçekleme süreci üzerindeki etkisi azaltılmaktadır. RS yöntemi, aykırı gözlemlere karşı daha dayanıklı bir yapı sunmaktadır (Scikit-learn, 2025). Bu yöntemle gerçekleştirilen dönüşüm, aşağıdaki formül ile ifade edilmektedir:

$$v' = \frac{v - \mathrm{Q1_A}}{\mathrm{Q3_A} - \mathrm{Q1_A}} \tag{3.2}$$

Burada; v özgün değeri, A sayısal özniteliği ve $\mathrm{Q3_A}$ ve $\mathrm{Q1_A}$ çeyrekler arası aralığı ifade etmektedir (Thakker ve Buch, 2024).

3.2.2 Çalışmada Kullanılan Makine Öğrenmesi Modelleri

Çalışmada, kızılçam tomruk fiyatlarının tahmininde doğrusal (Linear Regression (LR) ve Ridge Regression (RR)) ile doğrusal olmayan (Random Forest (RF), Extreme Gradient Boosting (XGBoost) ve Light Gradient Boosting Machine (LGBM)) yapıları temsil eden beş farklı makine öğrenmesi modeli kullanılmıştır. Modeller, farklı

öğrenme mekanizmaları ve model yapıları temelinde karşılaştırmalı olarak değerlendirilmiştir.

3.2.2.1 Doğrusal regresyon (Linear regression, LR)

LR, bağımlı değişken ile tek bir bağımsız değişken arasındaki ilişkinin doğrusal bir fonksiyon aracılığıyla modellenmesini amaçlayan temel istatistiksel yaklaşımlardan biridir (Nau, 2014). Bu yöntemde ilişki;

$$y = \beta_0 + \beta_1 x + \varepsilon \tag{3.3}$$

biçiminde ifade edilmekte olup, β_0 sabit terimi, β_1 bağımsız değişkenin etkisini temsil eden katsayıyı, x bağımsız değişkeni ve ε ise modele dahil edilemeyen rastlantısal etkileri içeren hata terimini göstermektedir. Basit doğrusal regresyon yaklaşımı, bağımlı değişken üzerindeki bağımsız değişken etkisinin izole edilmesine olanak tanıyarak, gözlenen değişimin ne ölçüde açıklanabildiğinin değerlendirilmesini sağlamaktadır (Montgomery vd., 2021).

3.2.2.2 Ridge regresyon (Ridge regression, RR)

Ridge regresyon, çoklu doğrusal bağlantının yaygın olduğu veri yapılarında katsayı tahminlerinin kararlılığını artırmak amacıyla geliştirilen düzenlileştirilmiş bir doğrusal regresyon yöntemidir (Hoerl ve Kennard, 1981). Aşağıda RR modeline ait matematiksel formül verilmektedir:

$$\sum_{i=1}^{n}(yi - \beta_0 - \sum_{j=1}^{p}\beta_j x_{ij})^2 + \lambda \sum_{j=1}^{n}\beta_j^2 \tag{3.4}$$

Burada; yi bağımlı değişkenin gözlenen değerini, β_0 sabit terimi, β_j regresyon katsayılarını, x_{ij} bağımsız değişkenleri, n gözlem sayısını ve p bağımsız değişken sayısını ifade etmektedir. λ ise düzenlileştirme parametresi olup, katsayı büyüklüklerini kontrol ederek model karmaşıklığını azaltarak aşırı öğrenmenin önüne geçmektedir (James vd., 2021).

3.2.2.3 Rastgele orman (Random forest, RF)

RF, farklı rassal örneklem ve değişken alt kümeleri kullanılarak oluşturulan çok sayıda karar ağacından oluşan bir topluluk öğrenme yöntemidir. Regresyon problemlerinde nihai tahmin değeri, bireysel ağaçların ürettiği çıktılarının ortalaması alınarak elde edilmektedir. Bir RF modeli, rastgele vektörler yardımıyla oluşturulan κ adet karar ağacından oluşur (Breiman, 2001):

$$\{h(\chi, \Theta_k), k=1, 2, ...\} \quad (3.5)$$

Burada; $h(\chi, \Theta_k)$, χ girdi değişkenleri kullanılarak oluşturulan *k* karar ağacını, Θ_k ise her bir ağacın oluşturulmasında kullanılan rassal örneklem ve değişken seçim sürecini ifade etmektedir.

3.2.2.4 Aşırı gradyan artırma (Extreme gradient boosting, XGBoost)

XGBoost, Chen ve Guestrin (2016) tarafından önerilen ve yüksek hesaplama verimliliği ile ölçeklenebilirlik özellikleri öne çıkan, ağaç tabanlı bir artırmalı öğrenme yaklaşımıdır. Yöntem, klasik Gradyan Artırmalı Regresyon Ağaçları (GBRT) algoritmasının geliştirilmiş bir uzantısı niteliğinde olup, ardışık biçimde oluşturulan regresyon ağaçlarının bir topluluk yapısı altında birleştirilmesine dayanmaktadır (Friedman, 2001). Bu yapı sayesinde model, her iterasyonda önceki hataları azaltacak yeni ağaçlar oluşturarak daha karmaşık ilişkileri öğrenebilmektedir. XGBoost modelinde tahmin değeri, ardışık biçimde oluşturulan karar ağaçlarının çıktılarının toplamı şeklinde ifade edilmektedir:

$$\hat{y}_i = \sum_{k=1}^{K} f_k(x_i), f_k \epsilon F \quad (3.6)$$

Burada; $f_k(x_i)$, *k*. ağacın *i*. gözlem için ürettiği tahmini; *F* ise regresyon ağaçları uzayını göstermektedir. Modelin öğrenme süreci, kayıp fonksiyonu ile ağaç karmaşıklığını dengeleyen düzenlileştirilmiş bir amaç fonksiyonunun minimize edilmesine dayanmaktadır (Chen ve Guestrin, 2016).

3.2.2.5 Hafif gradyan artırma (Light gradient boosting machine, LGBM)

Light Gradient Boosting Machine (LGBM), histogram tabanlı öğrenme yaklaşımı üzerine kurulu, ağaç tabanlı bir boosting algoritmasıdır. Model, yaprak odaklı büyüme stratejisi, kategorik değişken desteği ve gradyan temelli örnekleme teknikleri sayesinde yüksek boyutlu verilerde hesaplama verimliliğini artırmayı ve aşırı öğrenme riskini azaltmayı amaçlamaktadır (Chu vd., 2020). LGBM matematiksel gösterimi aşağıdaki şekilde ifade edilmektedir:

$$\hat{y}(x) = f_0(x) + \sum_{m=1}^{M} n f_m(x) \tag{3.7}$$

Burada; $f_0(x)$: başlangıç tahminini, $f_m(x)$: m. ağacı, n: öğrenme oranı ve M toplam ağaç sayısını göstermektedir (Ahamed ve Arya, 2021).

3.3 Model Optimizasyonu ve Doğrulama

Modelleme sürecinde, tahmin performansının artırılması ve modellerin genellenebilirliğinin sağlanması amacıyla sistematik bir optimizasyon ve doğrulama yaklaşımı benimsenmiştir. Veri setinin zamansal yapısı dikkate alınarak, klasik rastgele bölme yöntemleri yerine zaman serisi tabanlı çapraz doğrulama (Time Series Split) yaklaşımı kullanılmıştır. Time Series Split, zaman serisi verilerinde çapraz doğrulama yapmak için kullanılan bir yöntemdir. Burada zaman sırası korunarak, eğitim ve test setleri karıştırılmamaktadır.

Makine öğrenmesi modellerinde, öğrenme sürecinin yapısını ve karmaşıklığını kontrol eden hiperparametreler, model eğitimi öncesinde kullanıcı tarafından belirlenen ve veri üzerinden doğrudan öğrenilmeyen ayarlardır (Maleki vd., 2020). Ağaç derinliği, öğrenme oranı, yaprak sayısı, düzenlileştirme katsayıları ve örnekleme oranları gibi hiperparametreler; modelin aşırı öğrenme ve yetersiz öğrenme eğilimlerini doğrudan etkilemektedir (Géron, 2022). Bu nedenle, hiperparametrelerin uygun biçimde seçilmesi, modelin genellenebilirliğini ve tahmin doğruluğunu artırmada kritik bir rol oynamaktadır. Bir modelin doğrulama veri kümesi üzerinde en yüksek performansı sağlayan hiperparametre kombinasyonunun belirlenmesini amaçlayan bir

optimizasyon sürecidir. Bu süreç aşağıdaki denklem ile ifade edilmektedir (Andonie, 2019).

Çalışmada, hiperparametre optimizasyonu her model için belirlenen parametre aralıkları üzerinden gerçekleştirilmiş ve doğrulama stratejisi olarak Time Series Split kullanılmıştır. Doğrusal Regresyon modeli ayarlanabilir hiperparametre içermediğinden bu modele optimizasyon uygulanmamıştır. RR ve ağaç tabanlı modellerde (XGBoost, LGBM, RF) ise hiperparametreler, Random Search CV kullanılarak çapraz doğrulama yaklaşımıyla optimize edilmiştir (Bergstra ve Bengio, 2012).

3.4 Model Performans Metrikleri

Model performanslarının kapsamlı biçimde değerlendirilmesi amacıyla, farklı performans ölçütlerinin model başarısını farklı yönlerden yansıtması nedeniyle çalışmada birden fazla değerlendirme metriği kullanılmıştır. Bu doğrultuda; modellerin açıklayıcılık düzeyini, hata büyüklüğünü, göreli hata oranlarını, tahmin-gözlem uyumunu ve sistematik sapmaları birlikte değerlendirebilmek amacıyla Determinasyon katsayısı (R^2), Kök Ortalama Kare Hata (RMSE), Ortalama Mutlak Hata (MAE), Nash-Sutcliffe Verimlilik Katsayısı (NSE), Kling-Gupta Verimlilik Katsayısı (KGE), Medyan Mutlak Hata (MedAE) ve Simetrik Ortalama Mutlak Yüzde Hatası (sMAPE) metrikleri tercih edilmiştir. Fayda yönlü metriklerde (R^2, NSE ve KGE) yüksek değerler daha iyi performansı temsil ederken; hata temelli metriklerde (RMSE, MAE, MedAE ve sMAPE) düşük değerler daha başarılı kabul edilmiştir.

Determinasyon katsayısı (R^2), bağımlı değişkendeki toplam varyansın ne kadarının bağımsız değişkenler tarafından açıklandığını göstermektedir. R^2, 0 ile 1 arasında değer almakta olup, değerin 1'e yaklaşması modelin bağımlı değişkendeki varyansı daha yüksek oranda açıkladığını ve model performansının arttığını göstermektedir. Aşağıda matematiksel formülü verilmektedir (Karch, 2020).

$$R^2 = 1 - \frac{\sum_{i=1}^{n}(Y_i - \hat{Y}_i)^2}{\sum_{i=1}^{n}(Y_i - \bar{Y})^2} \tag{3.8}$$

Burada: Y_i gerçek gözlem değerini, $\hat{Y}_i$ model tarafından tahmin edilen değeri, $\bar{Y}$ bağımlı değişkenin ortalama değerini ve *n* toplam gözlem sayısını ifade etmektedir.

MAE, gözlenen değerler ile model tarafından üretilen tahminler arasındaki farkların mutlak değerlerinin aritmetik ortalamasını ölçmektedir. RMSE ise tahmin hatalarının karelerinin ortalamasının karekökü olarak tanımlanmakta olup, büyük hatalara MAE'ye kıyasla daha fazla ağırlık vermektedir. Bu performans ölçütlerinde ideal değer 0 olup, hata değerlerinin sıfıra yaklaşması model başarısının arttığını ifade etmektedir. MAE ve RMSE performans ölçütlerine ait matematiksel ifadeler aşağıda sunulmaktadır. Formülde e_i gerçek değer ile model tarafından tahmin edilen değer arasındaki hatayı, *n* ise toplam gözlem sayısını ifade etmektedir (Chai ve Draxler, 2014).

$$\mathrm{MAE} = \frac{1}{n}\sum_{i=1}^{n} |e_i| \tag{3.9}$$

$$\mathrm{RMSE} = \sqrt{\frac{1}{n}\sum_{i=1}^{n} e_i^2} \tag{3.10}$$

NSE, model tahmin hatalarının kareleri toplamının, gözlemlerin ortalama değerden sapmalarının kareleri toplamına oranının 1'den çıkarılmasıyla elde edilen ve modelin gözlemleri ne ölçüde temsil ettiğini değerlendiren bir performans ölçütüdür. NSE değerinin 1'e yaklaşması model performansının arttığını göstermektedir (Moriasi vd., 2007; Nash ve Sutcliffe, 1970).

$$\mathrm{NSE} = 1 - \left[\frac{\sum_{i=1}^{n}(Y_i^{obs} - Y_i^{sim})^2}{\sum_{i=1}^{n}(Y_i^{obs} - Y^{mean})^2}\right] \tag{3.11}$$

Burada: Y_i^{obs} gözlenen değeri, Y_i^{sim} model tarafından tahmin edilen değeri, Y^{mean} gözlenen değerlerin ortalamasını ve *n* toplam gözlem sayısını ifade etmektedir.

KGE, model çıktıları ile gözlenen değerler arasındaki uyumu; korelasyon, yanlılık ve değişkenlik gibi üç temel istatistiksel özelliği birlikte dikkate alarak değerlendiren ve bu bileşenleri tek bir dengeli performans göstergesinde bir araya getiren bir ölçüttür.

KGE değerinin 1'e yaklaşması model performansının arttığını göstermektedir (Gupta vd., 2009; Liu, 2020).

$$\mathrm{KGE} = 1 - \sqrt{(\mathrm{r}-1)^2 + (a-1)^2 + (\beta-1)^2} \tag{3.12}$$

Burada: r gözlenen ve tahmin edilen değerler arasındaki korelasyon katsayısını, α değişkenlik oranını ve β yanlılık oranını ifade etmektedir.

MedAE, model tahminleri ile gözlenen değerler arasındaki mutlak hataların medyanını alarak hesaplayan ve aykırı değerlere karşı dayanıklı bir regresyon performans ölçüsüdür. MedAE değerinin 0'a yaklaşması model performansının arttığını göstermektedir (Hosamo ve Mazzetto, 2024).

$$\mathrm{MedAE} = \mathrm{median}(|y_i - \hat{\mathrm{y}}_i|) \tag{3.13}$$

Burada: $\mathrm{y_i}$ gözlenen değeri, $\hat{\mathrm{y}}_i$ model tarafından tahmin edilen değeri ifade etmektedir.

sMAPE, tahmin hatasını, gerçek ve tahmin edilen değerlerin mutlak değerlerinin aritmetik ortalamasına bölerek normalize eden ve böylece hatayı göreli bir ölçekte değerlendiren bir performans metriğidir. sMAPE değerinin 0'a yaklaşması model performansının arttığını göstermektedir (Dierickx vd., 2021; Hewamalage vd., 2023).

$$\mathrm{sMAPE} = \frac{1}{\mathrm{n}} \sum_{\mathrm{t}=1}^{\mathrm{n}} \left(\frac{|y_t - \hat{y}_t|}{|y_t| + |\hat{y}_t|}\right) \tag{3.14}$$

Burada; y_t gerçek gözlem değerini, $\hat{\mathrm{y}}_t$ model tarafından tahmin edilen değeri, $|y_t - \hat{\mathrm{y}}_t|$ mutlak tahmin hatasını ve n toplam gözlem sayısını ifade etmektedir.

3.5 Entropi ve TOPSIS Tabanlı Çok Kriterli Model Değerlendirmesi

Bu çalışmada, makine öğrenmesi modellerinin performansı yalnızca tek bir ölçüt üzerinden değil, birden fazla performans göstergesini birlikte dikkate alan çok kriterli bir çerçevede değerlendirilmiştir. Çok kriterli karar verme yöntemleri, farklı ölçütlerin birlikte değerlendirilmesini gerektiren ve alternatifler arasından en uygun karar

seçeneğinin belirlenmesine yönelik analitik yaklaşımlardır (Turan, 2018). Bu amaçla Entropi ve TOPSIS yöntemleri birlikte kullanılmıştır.

Entropi yöntemi, kriter ağırlıklarının nesnel olarak belirlenmesinde kullanılan veri temelli bir yaklaşımdır. Yöntemin kuramsal temeli, Shannon'ın bilgi teorisine dayanan entropi kavramına uzanmaktadır (Yi, 2006). Çok kriterli karar verme açısından yöntem, kriterlerin karar matrisi içindeki dağılımına bağlı olarak ayırt edicilik düzeylerinin ölçülmesine dayanmaktadır (Sitorus ve Brito-Parada, 2020). Bu çerçevede, alternatifler arasında daha fazla farklılaşma yaratan kriterlerin bilgi katkısı daha yüksek kabul edilmekte ve bu kriterlere daha yüksek ağırlık atanmaktadır. Buna karşılık, alternatifleri ayırt etme gücü düşük olan kriterlerin ağırlığı görece azalmaktadır (Zakeri ve Konstantas, 2022). Dolayısıyla Entropi yöntemi, kriter önemlerinin karar verici yargısından bağımsız olarak, doğrudan veri yapısına dayalı biçimde belirlenmesine olanak sağlamaktadır.

Entropi yönteminin uygulanmasında ilk olarak karar matrisi X= $[x_{ij}]$ oluşturulmaktadır. Ardından karar matrisi normalize edilerek her kriter için olasılık benzeri değerler elde edilmektedir. Normalize değerler genel olarak şu şekilde ifade edilmektedir:

$$p_{ij} = \frac{x_{ij}}{\sum_{i=1}^{m} x_{ij}}, \qquad i = 1,2,\dots,m; j = 1,2,\dots,n \tag{3.15}$$

Burada m alternatif sayısını, n ise kriter sayısını, x_{ij}; i. alternatifin j. kritere ilişkin performans değerini ve p_{ij}; i'inci alternatifin j'inci kritere ait normalize edilmiş değerini ifade etmektedir. Daha sonra her kriter için entropi değeri aşağıdaki eşitlik yardımıyla hesaplanmaktadır:

$$e_j = -k \sum_{i=1}^{m} p_{ij} \ln(p_{ij}) \tag{3.16}$$

$$k = \frac{1}{\ln(m)} \tag{3.17}$$

Burada e_j; j'inci kriterin entropi değerini, k ise entropi sabitini göstermektedir. Entropi değerinden hareketle, her kriterin farklılaşma derecesi hesaplanmaktadır:

$$d_j = 1 - e_j \tag{3.18}$$

Burada d_j; j'inci kriterin farklılaşma derecesini ifade etmektedir. Son aşamada ise kriter ağırlıkları aşağıdaki eşitlik yardımıyla belirlenmektedir:

$$w_j = \frac{d_j}{\sum_{j=1}^{n} dj} \tag{3.19}$$

Burada w_j; j'inci kriterin ağırlık değerini göstermektedir. Böylece alternatifleri ayırt etme gücü daha yüksek olan kriterler daha yüksek ağırlık almaktadır (Babaei vd., 2025; Manjate vd., 2022).

R^2, MAE, RMSE, NSE, KGE, MedAE ve sMAPE performans ölçütlerinin Entropi yöntemi ile kriter ağırlıkları belirlendikten sonra, alternatiflerin çok kriterli performans sıralamasını yapmak amacıyla TOPSIS yöntemi uygulanmıştır. Ayrıca performans kriterlerinin değerlendirme yönünü gösterebilmek amacıyla, yüksek değerin tercih edildiği kriterler (+), düşük değerin tercih edildiği kriterler ise (-) işareti ile gösterilmiştir. TOPSIS, çok kriterli karar verme yöntemleri arasında yaygın olarak kullanılan yaklaşımlardan biridir. Yöntem, Hwang ve Yoon (1981) tarafından, en iyi alternatifin pozitif ideal çözüme en yakın ve negatif ideal çözüme en uzak konumda bulunduğu varsayımına dayalı olarak geliştirilmiştir. Bu yönüyle TOPSIS, birden fazla performans ölçütünün aynı anda dikkate alınmasına olanak tanıyarak alternatiflerin bütüncül biçimde sıralanmasını sağlamaktadır.

TOPSIS yönteminde, ilk olarak karar matrisi normalize edilmekte ve ardından Entropi yöntemiyle elde edilen kriter ağırlıkları kullanılarak ağırlıklı normalize karar matrisi oluşturulmaktadır. Vektör normalizasyonuna dayalı gösterimde normalize değerler genellikle şu şekilde ifade edilmektedir:

$$r_{ij} = \frac{x_{ij}}{\sqrt{\sum_{i=1}^{m} {x_{ij}}^2}} \tag{3.20}$$

Ağırlıklı normalize karar matrisi ise;

$$v_{ij} = w_j r_{ij} \tag{3.21}$$

eşitliği ile ifade edilmektedir. Daha sonra her kriter için pozitif ideal çözüm A^+ ve negatif ideal çözüm A^- belirlenmektedir. Fayda yönlü kriterlerde pozitif ideal çözüm en büyük, maliyet yönlü kriterlerde ise en küçük değeri içermektedir; negatif ideal çözüm ise bunun tersidir. Ardından her alternatifin bu iki referans noktaya olan uzaklığı Öklid uzaklığı ile hesaplanmaktadır:

$$S_i^+ = \sqrt{\sum_{j=1}^{n}(v_{ij} - v_j^+)^2} \tag{3.22}$$

$$S_i^- = \sqrt{\sum_{j=1}^{n}(v_{ij} - v_j^-)^2} \tag{3.23}$$

Göreli yakınlık katsayısı ise:

$$C_i^* = \frac{S_i^-}{S_i^+ + S_i^-} \tag{3.24}$$

eşitliği ile elde edilmekte ve alternatifler bu değere göre sıralanmaktadır. C_i^* değerinin yüksek olması, ilgili alternatifin pozitif ideal çözüme daha yakın olduğunu ve dolayısıyla daha iyi bir performans sergilediğini göstermektedir (Hwang ve Yoon, 2012; Biswas vd., 2016).

3.6 SHAP Analizi

Makine öğrenmesi modellerinin giderek artan karmaşıklığı, bu modellerin karar mekanizmalarının anlaşılmasını zorlaştırmakta ve özellikle gerçek dünya uygulamalarında güven sorunlarını beraberinde getirmektedir (Molnar, 2020). Bu kapsamda model çıktılarının yorumlanabilirliğini artırmayı amaçlayan SHapley Additive exPlanations (SHAP), model tahminlerini açıklamak için teorik olarak sağlam bir çerçeve sunmaktadır (Lundberg ve Lee, 2017). SHAP yöntemi, kökenini oyun teorisindeki Shapley değerlerinden almakta olup her bir girdinin model tarafından üretilen tahmine olan katkısını nicel olarak hesaplamaktadır (Shapley, 1953).

Çalışmada, tomruk fiyatlarının tahmininde kullanılan makine öğrenmesi modellerinin hangi değişkenlere daha duyarlı olduğu SHAP analiziyle ortaya konulmuş; makroekonomik göstergeler ve bağımsız değişkenlerin model çıktıları üzerindeki etkileri sistematik biçimde incelenmiştir.

3.7 Gerçek ve Tahmin Edilen Fiyatların Karşılaştırması ile Gelecek Dönem Fiyat Projeksiyonları

Geliştirilen modellerin tahmin performanslarının değerlendirilebilmesi amacıyla, 2025 yılına ait gerçek tomruk AASF'leri ile model tahmin değerleri karşılaştırılmıştır. Her bir model için elde edilen tahmin sonuçları gerçek gözlem değerleriyle birlikte incelenmiş ve model performansları değerlendirilmiştir. Böylece modellerin yalnızca eğitim ve test verileri üzerindeki performansları değil, aynı zamanda güncel dönem verileri üzerindeki genelleme yetenekleri de değerlendirilmiştir.

Model performans değerlendirmeleri sonucunda en başarılı model olarak belirlenen XGBoost algoritması esas alınarak geleceğe yönelik fiyat projeksiyonları oluşturulmuştur. Elde edilen projeksiyonlar, 5 yıllık (2026-2030) ve 10 yıllık (2026-2035) olmak üzere iki farklı tahmin dönemi kapsamında değerlendirilmiştir. Bu doğrultuda, gelecekteki olası fiyat eğilimi aylık bazda ortaya konulmuş ve tahmin sonuçları grafikler aracılığıyla görselleştirilmiştir.

4. BULGULAR

Bu bölümde; tüm değişkenlere ait tanımlayıcı istatistikler, makroekonomik koşullar etkisinde kızılçam tomruklarının açık artırmalı satış fiyatlarını tahmin etmeye yönelik olarak XGBoost, LGBM, RF, RR ve LR modelleri ile elde edilen karşılaştırmalı performans sonuçları kapsamlı biçimde incelenmektedir. Elde edilen bulgular aşağıda sırası ile verilmiştir.

4.1 Veri Analizi Bulguları

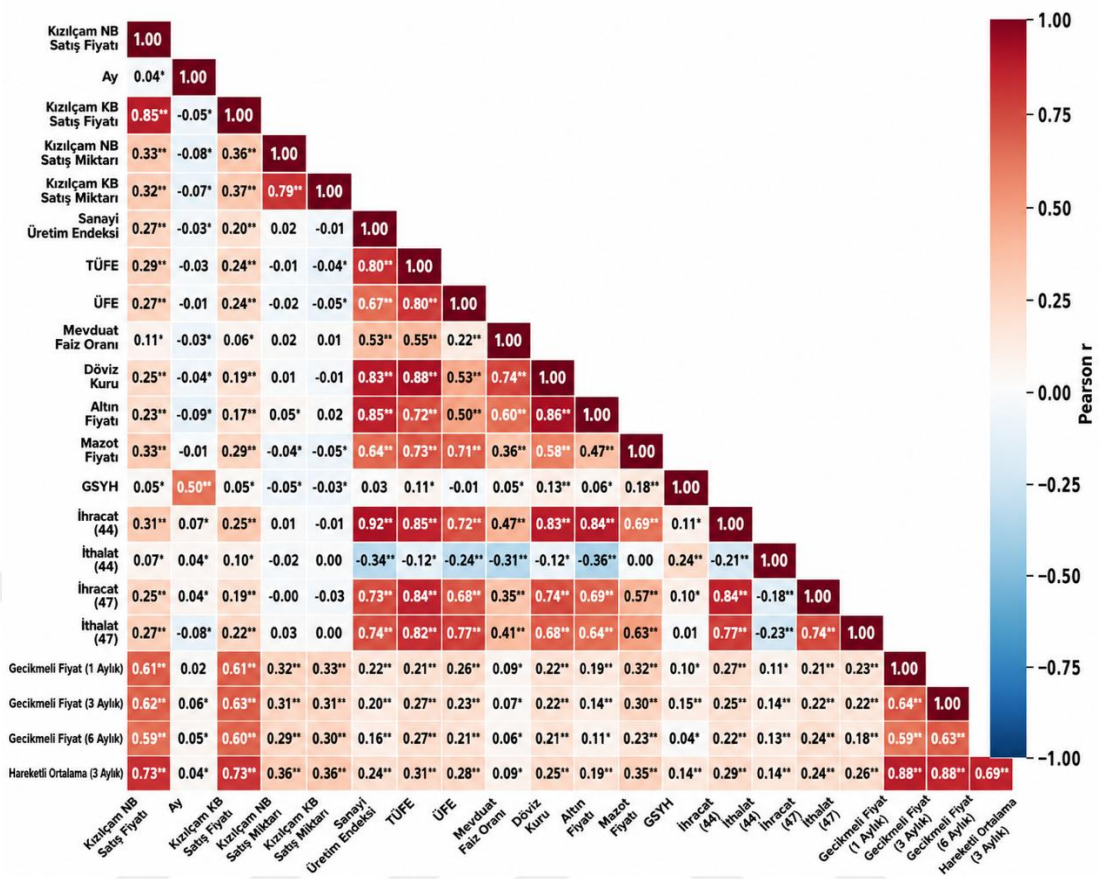
Çalışmada kullanılan değişkenlere ilişkin temel tanımlayıcı istatistikler Tablo 4.1'de verilmiştir. Tabloda kızılçam normal ve kısa boy satılan tomruk miktarları (m^3), ortalama satış fiyatları (USD) ve makroekonomik göstergelerin minimum, maksimum, ortalama ve standart sapma değerleri karşılaştırmalı olarak verilmiştir.

Tablo 4.1 Tanımlayıcı istatistik sonuçları

Değişken	Ortalama	En Düşük	%25	%50	%75	En Yüksek	Standart Sapma
Çz NB Ortalama Fiyatı	95,19	43,36	72,52	89,52	115,15	220,21	28,48
Çz KB Ortalama Fiyatı	87,98	39,04	67,97	81,68	105,64	207	26,55
Çz NB Satış Miktarı	3.424,4	2	595,75	1.962,5	4.606,5	27.693	4.072,16
Çz KB Satış Miktarı	1.835,6	3	379	960	2.491	12.369	2.139,47
Sanayi Üretim Endeksi	88,16	58,6	77,2	85,2	101,4	110,9	12,93
TÜFE	24,85	6,57	9,17	12,37	25,24	85,51	23,47
ÜFE	30,96	12,14	16,09	35,47	43,96	157,69	36,01
MB Faiz Oranı	15,07	7,5	8	9,75	18	50	10,84
Döviz Kuru	9,21	2,12	3,27	5,74	10,52	32,84	8,61
Altın Fiyatı	50,04	34,51	40,25	44,59	59,9	78,53	11,53
Mazot Fiyatı	62,31	18,84	48,33	59,63	75,85	114,67	18,06
GSYH	14.212.974,3	4.343.792	8.407.987	11.683.958	18.441.024	38.113.795	8.079.057,9
İhracat (44)	91.988,79	38.216,45	61.259,92	74.396,06	129.392,7	168.944,3	38.069,46
İthalat (44)	76.958,39	28.920,22	42.341,2	79.546,02	104.208,1	148.210,5	34.091,94
İhracat (47)	5.792,92	845,62	2.116,64	3.328,17	8.240,18	24.093,05	5.172,66
İthalat (47)	90.688,9	44.014,8	65.488,49	86.225,84	110.922	198.526,7	32.273,41
Gecikmeli Fiyat (1 Ay)	92,07	39,62	70,1	85,92	111,25	220,21	28,17
Gecikmeli Fiyat (3 Ay)	92,14	33,78	70,17	85,5	111,09	220,21	28,41
Gecikmeli Fiyat (6 Ay)	91,72	33,78	69,67	85,42	109,75	220,21	28,57
Son 3 Aylık Hareketli Ortalama	91,14	24,49	69,6	84,68	110,66	192,15	27,69

Tablo 4.1’de sunulan tanımlayıcı istatistik sonuçlarına göre, kızılçam normal boy ortalama satış fiyatının ortalama 95,19 USD, kızılçam kısa boy ortalama satış fiyatının ise 87,98 USD olduğu görülmektedir. Satış miktarları bakımından kızılçam normal boy tomrukların ortalama satış miktarı 3.424,4 m³, kızılçam kısa boy tomrukların ise 1.835,6 m³ olarak belirlenmiştir. Makroekonomik değişkenler incelendiğinde, sanayi üretim endeksinin ortalama 88,16, TÜFE'nin ortalama %24,85, mevduat faiz oranının ortalama %15,07, döviz kurunun ortalama 9,21, altın fiyatının ortalama 50,04 USD ve mazot fiyatının ortalama 62,31 USD olduğu görülmektedir. Ayrıca gecikmeli fiyat değişkenlerinin ortalamaları (1 aylık, 3 aylık ve 6 aylık) sırasıyla 92,07 USD, 92,14 USD ve 91,72 USD olup, son 3 aylık hareketli ortalama değeri 91,14 USD olarak hesaplanmıştır.

Şekil 4.1’de, çalışmada kullanılan kızılçam normal boy tomruk ortalama fiyatları ile modele dahil edilen bağımsız değişkenler arasındaki doğrusal ilişkileri ortaya koyan Pearson korelasyon matrisi sunulmuştur. Bu matriste korelasyon katsayıları renk yoğunlukları ile gösterilmekte olup, pozitif ilişkiler kırmızı tonlar, negatif ilişkiler ise mavi tonlar ile ifade edilmektedir.



Şekil 4.1 Değişkenler arası Pearson Korelasyon matrisi (p<0,05)

Şekil 4.1 incelendiğinde, kızılçam normal boy tomruk ortalama satış fiyatı ile açıklayıcı değişkenler arasında farklı düzeylerde doğrusal ilişkilerin bulunduğu görülmektedir. Kızılçam normal boy tomruk ortalama satış fiyatı ile kızılçam kısa boy tomruk AASF arasında çok güçlü düzeyde pozitif bir ilişki (r=0,85) belirlenmiştir. Benzer şekilde, son 3 aylık hareketli ortalama (r=0,73), 1 aylık gecikmeli fiyat (r=0,67) ve 3 aylık gecikmeli fiyat (r=0,62) değişkenleri ile güçlü düzeyde pozitif ilişkiler tespit edilmiştir. Buna karşılık, 6 aylık gecikmeli fiyat değişkeni ile orta düzeyde pozitif bir ilişki (r=0,59) belirlenmiştir. Kızılçam normal boy ve kısa boy satış miktarları ile zayıf düzeyde pozitif ilişkiler (r=0,33 ve r=0,32) belirlenmiştir. Makroekonomik göstergelerin büyük çoğunluğunun ise kızılçam normal boy tomruk ortalama satış fiyatı ile çok zayıf ile zayıf düzey arasında değişen pozitif ilişki gösterdiği görülmektedir. Ay değişkeni ile kızılçam normal boy tomruk ortalama satış fiyatı arasında ise çok zayıf düzeyde negatif bir ilişki (r=-0,04) belirlenmiştir.

4.2 Model Performansları

Bu bölümde, kızılçam normal boy tomruk açık artırmalı satış fiyatının tahminine yönelik olarak geliştirilen farklı makine öğrenmesi algoritmalarına ait performans sonuçları sunulmaktadır. Bu kapsamda, XGBoost, LGBM, RF, RR ve LR modellerine ait performans metrikleri karşılaştırmalı olarak ele alınmaktadır. Her bir model, eğitim ve test veri setleri üzerinden hesaplanan değerlendirme ölçütleri aracılığıyla analiz edilerek birbirleriyle karşılaştırılmıştır.

4.2.1 Hiperparametre Optimizasyonu ve Çapraz Doğrulama Öncesi ve Sonrası Model Performans Metrikleri

Fiyat tahminine yönelik geliştirilen makine öğrenmesi modellerinin performansları, yöntem bölümünde açıklanan değerlendirme ölçütleri doğrultusunda analiz edilmiştir. Bu kapsamda, hiperparametre optimizasyonu ve çapraz doğrulama uygulanmadan önce elde edilen performans sonuçları Tablo 4.2'de sunulmuştur. Modellerin başarısı hem eğitim hem de test veri setleri için R^2, RMSE, MAE, NSE, KGE, MedAE ve sMAPE ölçütleri kullanılarak değerlendirilmiştir.

Time Series Split tabanlı çapraz doğrulama ve hiperparametre optimizasyonu işlemleri sonrasında normal boy Kızılçam tomruk fiyatlarının tahmininde kullanılan makine öğrenmesi modellerine ait nihai performans sonuçları ise Tablo 4.3'te verilmiştir.

Tablo 4.2 Hiperparametre optimizasyonu ve çapraz doğrulama öncesi model performans metrikleri

Model	R^2		RMSE		MAE		NSE		KGE		MedAE		sMAPE	
	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test
XGBoost	0,999	0,907	0,702	9,157	0,507	5,733	0,987	0,906	0,981	0,953	1,894	2,949	2,651	5,697
LGBM	0,987	0,908	3,309	9,118	2,409	5,578	0,996	0,901	0,990	0,950	1,025	3,237	1,476	5,750
RF	0,988	0,892	3,113	9,850	2,130	5,737	0,988	0,911	0,968	0,949	1,641	2,881	2,583	5,493
RR	0,797	0,777	13,228	14,189	10,064	10,787	0,793	0,767	0,851	0,872	7,956	8,215	10,912	10,967
LR	0,798	0,775	13,216	14,239	10,069	10,875	0,798	0,775	0,862	0,884	8,143	8,693	10,911	10,927

Tablo 4.3 Hiperparametre optimizasyonu ve çapraz doğrulama sonrası model performans metrikleri

Model	R^2		RMSE		MAE		NSE		KGE		MedAE		sMAPE	
	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test	Eğitim	Test
XGBoost	0,987	0,904	3,299	9,278	2,439	5,632	0,989	0,902	0,983	0,951	1,761	2,957	2,557	2,957
LGBM	0,996	0,901	1,712	9,445	1,247	5,708	0,996	0,900	0,992	0,948	0,932	3,166	1,339	5,876
RF	0,988	0,911	3,155	8,944	2,305	5,427	0,989	0,896	0,971	0,944	1,446	2,892	2,342	5,797
RR	0,793	0,768	13,363	14,485	10,088	10,897	0,782	0,756	0,847	0,867	8,314	8,553	11,286	11,335
LR	0,798	0,775	13,216	14,239	10,069	10,875	0,782	0,756	0,848	0,868	8,341	8,511	11,29	11,343

Tablo 4.2 incelendiğinde, ağaç tabanlı modellerin doğrusal modellere kıyasla daha yüksek performans sergilediği görülmektedir. Özellikle XGBoost modeli eğitim veri setinde en yüksek R^2 değerine (0,999) ulaşırken, test veri setinde LGBM modelinin daha dengeli sonuçlar verdiği belirlenmiştir. LGBM modeli, test veri setinde en yüksek R^2 (0,908) değerinin yanı sıra en düşük RMSE (9,118) ve MAE (5,578) hata değerlerine ulaşmıştır. Ayrıca modelin düşük MedAE (3,238) ve sMAPE (%5,750) değerleri ile yüksek KGE (0,951) değeri, tahmin performansının güçlü olduğunu göstermektedir. RF modeli ise en yüksek NSE değerine (0,912) sahip olmasına rağmen, RMSE (9,850) ve MAE (5,737) değerlerinin LGBM modeline göre daha yüksek olduğu görülmüştür. LR ve RR modellerinin ise düşük R^2 (0,775–0,777) ve NSE (0,768–0,776) değerleri ile yüksek RMSE (14,189–14,239) ve MAE (10,787–10,875) değerleri nedeniyle diğer modellere kıyasla daha düşük performans sergilediği belirlenmiştir.

Tablo 4.3'te verilen hiperparametre optimizasyonu ve çapraz doğrulama sonrası elde edilen test veri seti sonuçları değerlendirildiğinde; RF modelinin en yüksek R^2 (0,911) değerine ve en düşük RMSE (8,944), MAE (5,427) ve MedAE (2,892) değerlerine ulaştığı görülmektedir. XGBoost modeli ise yüksek NSE (0,902) ve KGE (0,951) değerlerinin yanı sıra en düşük sMAPE (%2,957) değerini elde etmiştir. LGBM modeli de RF ve XGBoost modellerine yakın performans sergilemiş olup, R^2 değeri 0,901, RMSE değeri 9,445 ve KGE değeri 0,948 olarak hesaplanmıştır. Buna karşılık LR ve RR modellerinin R^2 değerlerinin sırasıyla 0,775 ve 0,768 düzeyinde kaldığı, RMSE değerlerinin ise yaklaşık 14 seviyesinde gerçekleştiği belirlenmiştir. Ayrıca bu modellerin MAE, MedAE ve sMAPE değerlerinin de diğer modellere kıyasla daha yüksek olduğu görülmektedir.

Her bir makine öğrenmesi modeli için farklı hiperparametre kombinasyonları performans ölçütleri açısından değerlendirilmiş ve en yüksek tahmin başarısı ile en düşük hata düzeyini sağlayan parametre değerleri optimum kombinasyon olarak belirlenmiştir. Hiperparametre optimizasyonu sonucunda elde edilen en uygun parametre kombinasyonları Tablo 4.4'te sunulmaktadır.

Tablo 4.4 Hiperparametre optimizasyonu sonrası parametre kombinasyonları

Model	Parametreler
XGBoost	{'alt örnekleme oranı': 0,8; 'L2 düzenleme katsayısı': 10; 'L1 düzenleme katsayısı': 0,1; 'tahminleyici sayısı': 1200; 'minimum düğüm ağırlığı': 3; 'maksimum derinlik': 4; 'öğrenme oranı': 0,03; 'gama değeri': 0; 'ağaç bazlı sütun örnekleme oranı': 0,6}
LGBM	{'alt örnekleme oranı': 0,7; 'L2 düzenleme katsayısı': 1; 'L1 düzenleme katsayısı': 0,1; 'yaprak sayısı': 63; 'tahminleyici sayısı': 500; 'minimum örnek sayısı': 5; 'maksimum derinlik': 5; 'öğrenme oranı': 0,1; 'ağaç bazlı sütun örnekleme oranı': 0,6}
RF	{'tahminleyici sayısı': 800; 'minimum bölünme örnek sayısı': 2; 'minimum yaprak örnek sayısı': 1; 'maksimum özellik sayısı': 'sqrt', 'maksimum derinlik': 14}
RR	{'alpha düzenleme katsayısı': 10}
LR	{Parametre uygulanmamıştır}

Tablo 4.4 incelendiğinde, XGBoost modelinde öğrenme oranının 0,03; ağaç derinliğinin 4 ve tahminleyici sayısının 1200 olarak belirlendiği görülmektedir. LGBM modelinde ise öğrenme oranı 0,1; yaprak sayısı 63 ve tahminleyici sayısı 500 olarak belirlenmiştir. RF modelinde maksimum derinlik değeri 14 ve ağaç sayısı 800 olarak elde edilirken, RR modelinde düzenlileştirme parametresi 10 olarak belirlenmiştir. LR modeli için ise ek bir hiperparametre optimizasyonu uygulanmadığı görülmektedir.

Model performanslarının metrik bazında karşılaştırmalı sıralamaları Tablo 4.5'te verilmektedir. Tabloda her performans metriği için en başarılı model "1" ile, en düşük performans gösteren model ise en büyük sıra değeri ile ifade edilmiştir.

Tablo 4.5 Modellerin performans metriklerine göre sıralamaları

Model	R^2	RMSE	MAE	NSE	KGE	MedAE	sMAPE	Toplam Rank
XGBoost	2	2	2	1	1	2	1	11
LGBM	3	3	3	2	2	3	3	19
RF	1	1	1	3	3	1	2	12
RR	5	5	5	4	5	5	4	33
LR	4	4	4	4	4	4	5	29

Tablo 4.5 incelendiğinde, RF modelinin RMSE, MAE ve MedAE metriklerinde ilk sırada yer aldığı görülmektedir. XGBoost modeli ise NSE, KGE ve sMAPE metriklerinde en başarılı model olarak öne çıkmıştır. LGBM modeli genel olarak dengeli sonuçlar elde etmiştir. Buna karşın doğrusal modeller olan LR ve RR'nin çoğu performans metriğinde son sıralarda yer aldığı belirlenmiştir.

4.2.2 Entropi Tabanlı TOPSIS Sonuçları ve Model Sıralaması

Makine öğrenmesi modellerinin çok kriterli biçimde değerlendirilebilmesi amacıyla, performans karşılaştırmasında kullanılan R^2, RMSE, MAE, NSE, KGE, MedAE ve sMAPE metrikleri için Entropi yöntemi uygulanmıştır. Bu aşamada amaç, söz konusu performans ölçütlerinin model ayrıştırma gücünü nesnel biçimde ortaya koymak ve her bir metriğin göreli önem düzeyini belirlemektir. Böylece model performansı yalnızca tek bir hata ya da uyum ölçütüne dayalı olarak değil, farklı performans boyutlarını birlikte dikkate alan bir çerçevede değerlendirilmiştir.

Hiperparametre optimizasyonu ve çapraz doğrulama işlemleri sonrasında elde edilen modellerin test veri setine ait performans sonuçları Tablo 4.6'da verilmektedir. Modellerin tahmin başarılarının değerlendirilmesinde NSE, KGE, MedAE, sMAPE, R^2, RMSE ve MAE performans metriklerinden yararlanılmıştır.

Tablo 4.6 Modellerin test veri setine ait performans metrikleri

Model	NSE (+)	KGE (+)	MedAE (-)	sMAPE (-)	R^2 (+)	RMSE (-)	MAE (-)
XGBoost	0,902	0,951	2,957	2,957	0,904	9,278	5,632
LGBM	0,900	0,948	3,166	5,876	0,901	9,445	5,708
RF	0,896	0,944	2,892	5,797	0,911	8,944	5,427
RR	0,756	0,867	8,553	11,335	0,768	14,485	10,897
LR	0,756	0,868	8,511	11,343	0,775	14,239	10,875

Tablo 4.6 incelendiğinde, ağaç tabanlı modellerin performans açısından doğrusal modellere kıyasla daha başarılı sonuçlar verdiği görülmektedir. Özellikle RF modelinin yüksek R^2 ve düşük RMSE değerleri ile öne çıktığı, LGBM modelinin ise hata metrikleri açısından daha dengeli sonuçlar sunduğu belirlenmiştir. XGBoost modelinin de yüksek NSE ve KGE değerleri ile güçlü tahmin performansı sergilediği

görülmektedir. Elde edilen bu test performans değerleri, sonraki aşamada gerçekleştirilen Entropi tabanlı çok kriterli karar verme analizinde karar matrisi olarak kullanılmıştır.

Karar matrisi oluşturulduktan sonra, kriterlerin farklı ölçeklerde bulunmasından kaynaklanan etkileri ortadan kaldırmak amacıyla normalizasyon işlemi uygulanmıştır. Bu işlem sayesinde tüm kriterler ortak bir ölçeğe dönüştürülerek karşılaştırılabilir hale getirilmiştir. Normalize edilmiş karar matrisi Tablo 4.7'de verilmektedir.

Tablo 4.7 Entropi yöntemi için normalize edilmiş karar matrisi

Model	NSE	KGE	MedAE	sMAPE	R^2	RMSE	MAE
XGBoost	1,000	1,000	0,978	1,000	0,992	0,964	0,964
LGBM	0,988	0,997	0,913	0,503	0,989	0,947	0,951
RF	0,984	0,993	1,000	0,510	1,000	1,000	1,000
RR	0,830	0,912	0,338	0,261	0,843	0,618	0,498
LR	0,830	0,913	0,340	0,261	0,851	0,628	0,499

Tablo 4.7'de, modellerin test performans metriklerinin normalize edilmesiyle elde edilen karar matrisi verilmektedir. Normalizasyon işlemi ile farklı ölçeklerde bulunan performans kriterleri ortak bir ölçeğe dönüştürülerek karşılaştırılabilir hale getirilmiştir. Böylece kriterler arasındaki ölçek farklılıklarının Entropi ağırlıkları ve TOPSIS sıralaması üzerindeki etkisi azaltılmıştır.

Normalize edilmiş karar matrisi kullanılarak her bir kriter için olasılık değerleri hesaplanmıştır. Hesaplanan olasılık değerleri Tablo 4.8'de verilmektedir.

Tablo 4.8 Entropi yöntemi için olasılık matrisi

Model	NSE	KGE	MedAE	sMAPE	R^2	RMSE	MAE
XGBoost	0,214	0,208	0,274	0,394	0,212	0,232	0,247
LGBM	0,214	0,207	0,256	0,198	0,212	0,228	0,244
RF	0,213	0,206	0,280	0,201	0,214	0,241	0,256
RR	0,180	0,189	0,095	0,103	0,180	0,149	0,127
LR	0,180	0,190	0,095	0,103	0,182	0,151	0,127

Tablo 4.8 incelendiğinde, ağaç tabanlı modeller olan XGBoost, LGBM ve RF modellerinin çoğu kriterde daha yüksek olasılık değerlerine sahip olduğu görülmektedir. Özellikle ağaç tabanlı modellerden XGBoost ve RF'nin NSE, KGE, R^2, RMSE ve MAE kriterlerinde öne çıktığı belirlenmiştir. Buna karşın doğrusal modeller olan LR ve RR'nin birçok kriterde daha düşük olasılık değerlerine sahip olduğu görülmektedir.

Olasılık matrisi elde edildikten sonra her bir kriter için entropi değerleri hesaplanmıştır. Entropi değerlerinin hesaplanmasının ardından kriterlere ait farklılaşma değerleri elde edilmiştir. Bu değerler kullanılarak kriter ağırlıkları hesaplanmıştır. Farklılaşma değerlerinden yararlanılarak kriter ağırlıkları belirlenmiş ve sonuçlar Tablo 4.9'da verilmiştir.

Tablo 4.9 Entropi analizi sonucunda elde edilen kriter ağırlıkları ve önem düzeyleri

Metrik	Ağırlık	Sıralama
sMAPE (-)	0,4233	1
MedAE (-)	0,3307	2
MAE (-)	0,1509	3
RMSE (-)	0,0709	4
NSE (+)	0,0114	5
R^2 (+)	0,0097	6
KGE (+)	0,0031	7

Tablo 4.9 incelendiğinde, en yüksek ağırlığın sMAPE kriterine (0,4233) ait olduğu görülmektedir. Bu durum, modeller arasındaki farklılaşmanın en fazla sMAPE kriterinde gerçekleştiğini göstermektedir. MedAE kriteri 0,3307 ağırlık değeri ile ikinci sırada yer alırken, MAE kriteri 0,1509 ağırlık değeri ile üçüncü sırada bulunmaktadır. Buna karşın KGE (0,0031); R^2 (0,0097) ve NSE (0,0114) kriterlerinin daha düşük ağırlıklara sahip olduğu belirlenmiştir. Elde edilen kriter ağırlıkları, sonraki aşamada TOPSIS analizinde kullanılmıştır.

Entropi yöntemi ile belirlenen kriter ağırlıkları esas alınarak, alternatif modellerin çok kriterli performans sıralamasını yapmak amacıyla TOPSIS yöntemi uygulanmıştır. TOPSIS analizi sonucunda elde edilen göreli yakınlık katsayıları ve model sıralamaları Tablo 4.10'da sunulmuştur.

Tablo 4.10 TOPSIS sonucunda elde edilen göreli yakınlık katsayıları ve model sıralamaları

Model	Yakınlık Katsayısı	Sıralama
XGBoost	0,98974	1
RF	0,75035	2
LGBM	0,73735	3
LR	0,00515	4
RR	0,00075	5

Tablo 4.10 incelendiğinde, en yüksek yakınlık katsayısının 0,98974 ile XGBoost modelinde elde edildiği ve modelin ilk sırada yer aldığı görülmektedir. RF ve LGBM modellerinin yakınlık katsayıları sırasıyla 0,75035 ve 0,73735 olarak hesaplanmış ve bu modeller ikinci ve üçüncü sırada yer almıştır. LR ve RR modellerinin yakınlık katsayılarının oldukça düşük düzeyde gerçekleştiği görülmektedir. LR modeli 0,00515 yakınlık katsayısı ile dördüncü sırada yer alırken, RR modeli 0,00075 değeri ile son sırada yer almıştır.

4.3 SHAP Tabanlı Değişken Etkilerinin Analizi

TOPSIS analizi sonucunda en iyi performansı gösteren XGBoost modeli için değişkenlerin model tahminleri üzerindeki etkilerini değerlendirmek amacıyla SHAP analizi uygulanmıştır. Bu kapsamda, modele dahil edilen bağımsız değişkenlerin tahmin performansına katkı düzeyleri incelenmiş ve değişkenlerin göreli önem sıralamaları belirlenmiştir. Elde edilen SHAP değerleri doğrultusunda, değişkenlerin model çıktısı üzerindeki etki büyüklükleri karşılaştırmalı olarak değerlendirilmiştir. SHAP analizi sonucunda elde edilen değişken etki düzeyleri Tablo 4.11'de sunulmaktadır.

Tablo 4.11 SHAP analizine göre değişken önem sıralamaları

Değişken	SHAP Değeri	Etki Düzeyi Sırası	Değişken	SHAP Değeri	Etki Düzeyi Sırası
Çz NB Satış Miktarı	0,153	1	TÜFE	0,008	12
Çz KB Satış Miktarı	0,142	2	Gecikmeli Fiyat (6 Aylık)	0,007	13
Hareketli Ortalama (Son 3 Aylık)	0,106	3	MB Faiz Oranı	0,005	14
Gecikmeli Fiyat (1 Aylık)	0,085	4	Döviz Kuru	0,004	15
Çz KB Fiyatı	0,081	5	GSYH	0,004	16
Sanayi Üretim Endeksi	0,078	6	İhracat 47	0,004	17
İhracat 44	0,052	7	İthalat 47	0,003	18
Ay	0,022	8	ÜFE	0,003	19
İthalat 44	0,014	9	Altın Fiyatı	0,003	20
Mazot Fiyatı	0,013	10	OBM	0,001	21
Gecikmeli Fiyat (3 Aylık)	0,009	11			

Tablo 4.11 incelendiğinde, SHAP analizi sonucunda model tahminleri üzerinde en yüksek etkiye sahip değişkenin Çz NB satış miktarı olduğu görülmektedir (0,153). Bunu sırasıyla Çz KB satış miktarı (0,142), son 3 aylık hareketli ortalama (0,106), gecikmeli fiyat (1 aylık) (0,085), Çz KB fiyatı (0,081) ve sanayi üretim endeksi (0,078) izlemektedir. Orta düzeyde etkiye sahip değişkenler arasında İhracat 44 (0,052), Ay (0,022), İthalat 44 (0,014), mazot fiyatı (0,013), gecikmeli fiyat (3 aylık) (0,009) ve TÜFE (0,008) yer almaktadır. Buna karşılık MB faiz oranı (0,005), döviz kuru (0,004), GSYH (0,004), İhracat 47 (0,004), İthalat 47 (0,003), ÜFE (0,003), altın fiyatı (0,003) ve OBM (0,001) değişkenlerinin model üzerindeki etkisinin daha düşük olduğu belirlenmiştir.

4.4 Gerçek ve Tahmin Edilen Fiyatların Karşılaştırması ile Gelecek Dönem Fiyat Projeksiyonları

Çalışmada geliştirilen makine öğrenmesi modelleri kullanılarak 2025 yılına ilişkin tomruk fiyat tahminleri üretilmiştir. Tahminler, modelleme sürecinde öğrenilen ilişkiler esas alınarak ileriye dönük bir öngörü kapsamında gerçekleştirilmiştir. Elde edilen tahminler, modellerin tahmin performanslarının değerlendirilmesi amacıyla 2025 yılına ait gerçekleşen fiyat değerleri ile karşılaştırılmıştır.

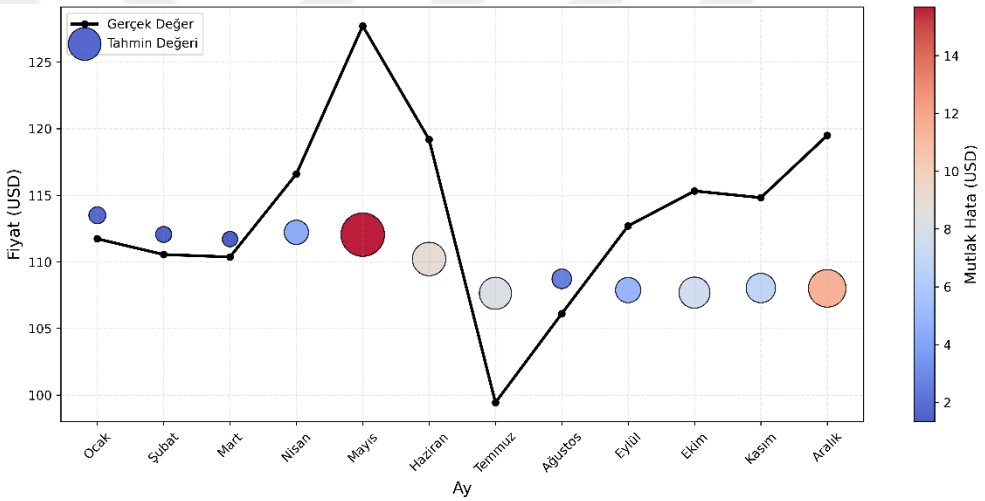
Tablo 4.12'de, 2025 yılına ait gerçekleşen tomruk AASF'leri ile makine öğrenmesi modelleri tarafından tahmin edilen AASF'lerin karşılaştırılması sunulmaktadır. Bu karşılaştırma, modellerin gerçek piyasa koşullarındaki tahmin başarısının değerlendirilmesine olanak sağlamaktadır.

Tablo 4.12 2025 yılına ait gerçek değer ve tahmin değerlerinin karşılaştırılması

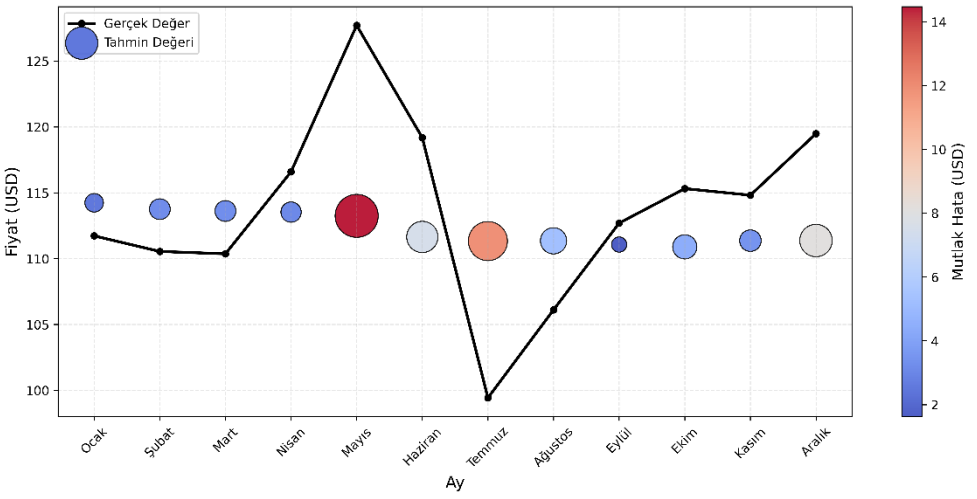
Aylar	Fiyat	Model				
		XGBoost	RF	LGBM	LR	RR
	Gerçek Değer (USD)	111,727	111,727	111,727	111,727	111,727
Ocak	Tahmin Değeri (USD)	113,494	114,242	105,039	46,308	46,154
	Fark	-1,767	-2,515	6,688	65,419	65,573
	Gerçek Değer (USD)	110,547	110,547	110,547	110,547	110,547
Şubat	Tahmin Değeri (USD)	112,056	113,757	104,808	45,502	45,411
	Fark	-1,509	-3,210	5,739	65,045	65,136
	Gerçek Değer (USD)	110,367	110,367	110,367	110,367	110,367
Mart	Tahmin Değeri (USD)	111,707	113,618	104,697	38,026	37,183
	Fark	-1,340	-3,251	5,670	72,341	73,184
	Gerçek Değer (USD)	116,596	116,596	116,596	116,596	116,596
Nisan	Tahmin Değeri (USD)	112,215	113,533	105,105	43,787	43,823
	Fark	4,381	3,063	11,491	72,809	72,773
	Gerçek Değer (USD)	127,716	127,716	127,716	127,716	127,716
Mayıs	Tahmin Değeri (USD)	112,039	113,249	104,580	43,289	43,286
	Fark	15,677	14,467	23,136	84,427	84,430
	Gerçek Değer (USD)	119,188	119,188	119,188	119,188	119,188
Haziran	Tahmin Değeri (USD)	110,211	111,648	104,137	42,672	42,660
	Fark	8,977	7,540	15,051	76,516	76,528
	Gerçek Değer (USD)	99,427	99,427	99,427	99,427	99,427
Temmuz	Tahmin Değeri (USD)	107,635	111,333	102,419	42,527	42,405
	Fark	-8,208	-11,906	-2,992	56,900	57,022
	Gerçek Değer (USD)	106,111	106,111	106,111	106,111	106,111
Ağustos	Tahmin Değeri (USD)	108,723	111,355	102,924	41,809	41,685
	Fark	-2,612	-5,244	3,187	64,302	64,426
	Gerçek Değer (USD)	112,699	112,699	112,699	112,699	112,699
Eylül	Tahmin Değeri (USD)	107,877	111,070	102,398	40,985	40,931
	Fark	4,822	1,629	10,301	71,714	71,768
	Gerçek Değer (USD)	115,318	115,318	115,318	115,318	115,318
Ekim	Tahmin Değeri (USD)	107,685	110,893	102,132	40,547	40,459
	Fark	7,633	4,425	13,186	74,771	74,859
	Gerçek Değer (USD)	114,818	114,818	114,818	114,818	114,818
Kasım	Tahmin Değeri (USD)	108,033	111,365	102,385	39,835	39,755
	Fark	6,785	3,453	12,433	74,983	75,063
	Gerçek Değer (USD)	119,491	119,491	119,491	119,491	119,491
Aralık	Tahmin Değeri (USD)	108,009	111,375	101,073	39,206	39,147
	Fark	11,482	8,116	18,418	80,285	80,344

Tablo 4.12 incelendiğinde, XGBoost ve RF modellerinin gerçek değerlere diğer modellere kıyasla daha yakın tahminler ürettiği görülmektedir. Buna karşın LGBM modelinin tahminlerinin daha düşük seviyede kaldığı, LR ve RR modellerinin ise gerçek değerlerden önemli ölçüde sapma gösterdiği belirlenmiştir.

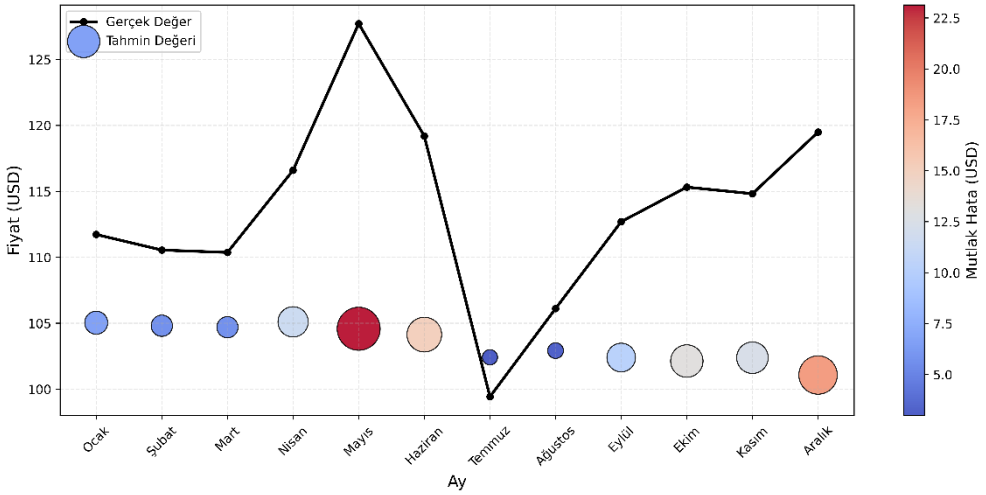
Gerçek ve tahmin edilen değerler arasındaki ilişkiler, modellerin tahmin performanslarının değerlendirilmesi amacıyla grafikler yardımıyla sunulmuştur (Şekil 4.2, Şekil 4.3, Şekil 4.4, Şekil 4.5 ve Şekil 4.6). Grafiklerde balon büyüklüğü ve renk yoğunluğu, gerçek ve tahmin edilen değerler arasındaki hata düzeyini temsil etmektedir. Buna göre, daha büyük ve koyu renkli balonlar daha yüksek hata düzeyini, daha küçük ve açık renkli balonlar ise daha düşük hata düzeyini göstermektedir.



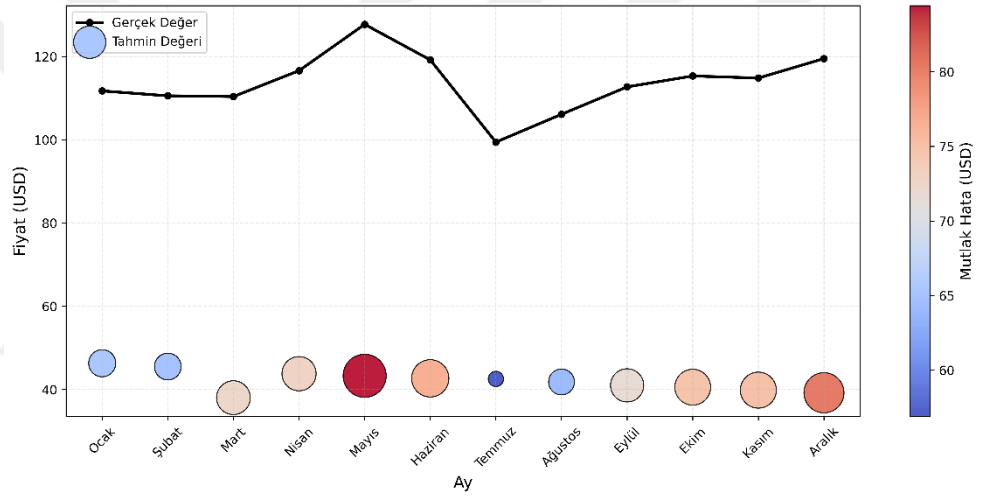
Şekil 4.2 XGBoost modeli tahmin performansı



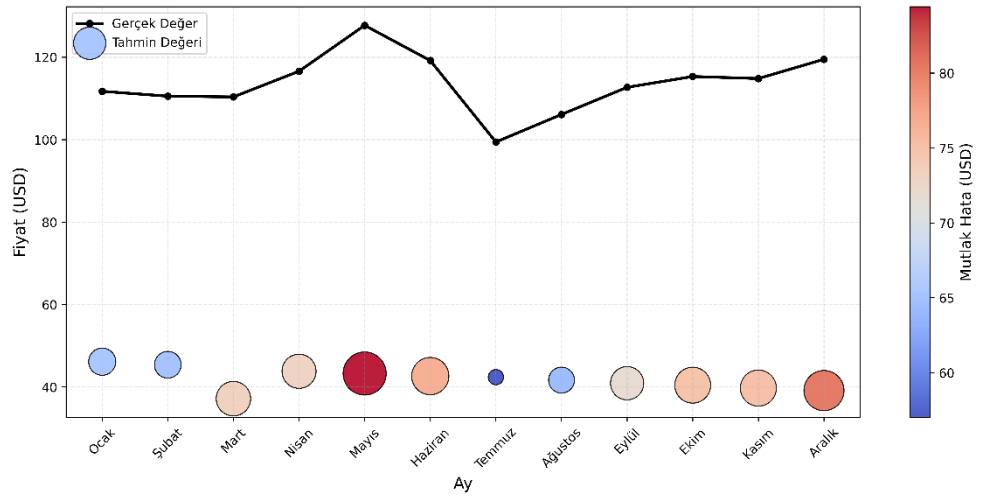
Şekil 4.3 RF modeli tahmin performansı



Şekil 4.4 LGBM modeli tahmin performansı



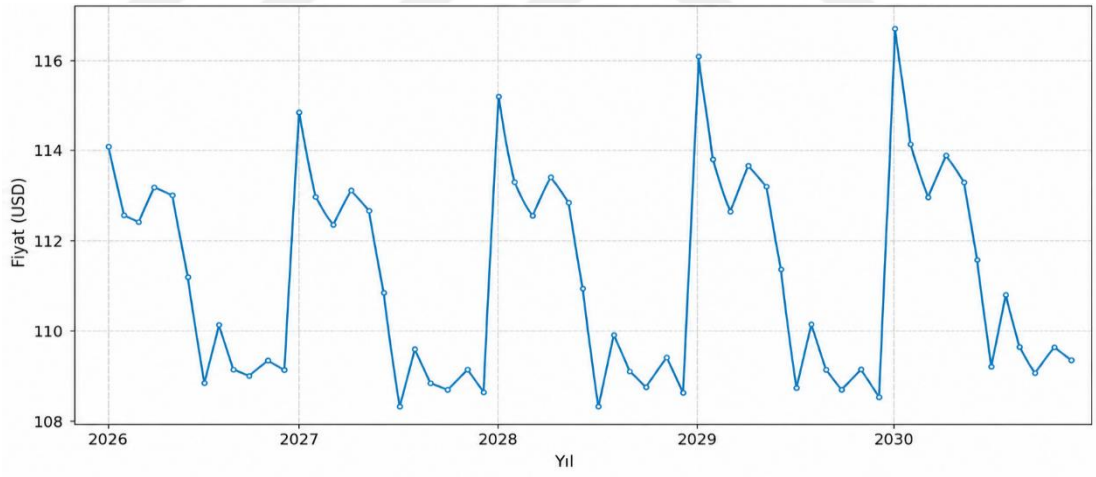
Şekil 4.5 LR modeli tahmin performansı



Şekil 4.6 RR modeli tahmin performansı

Şekil 4.2, Şekil 4.3, Şekil 4.4, Şekil 4.5 ve Şekil 4.6 incelendiğinde, XGBoost, RF ve LGBM modellerinde balon büyüklüğü ve renk yoğunluğunun genel olarak daha düşük olduğu görülmektedir. Bu durum, söz konusu modellerde gerçek ve tahmin edilen değerler arasındaki mutlak hata düzeylerinin daha düşük olduğunu göstermektedir. Buna karşılık, LR ve RR modellerinde daha büyük ve yoğun renkli balonların daha sık gözlendiği, dolayısıyla hata düzeylerinin daha yüksek olduğu belirlenmiştir.

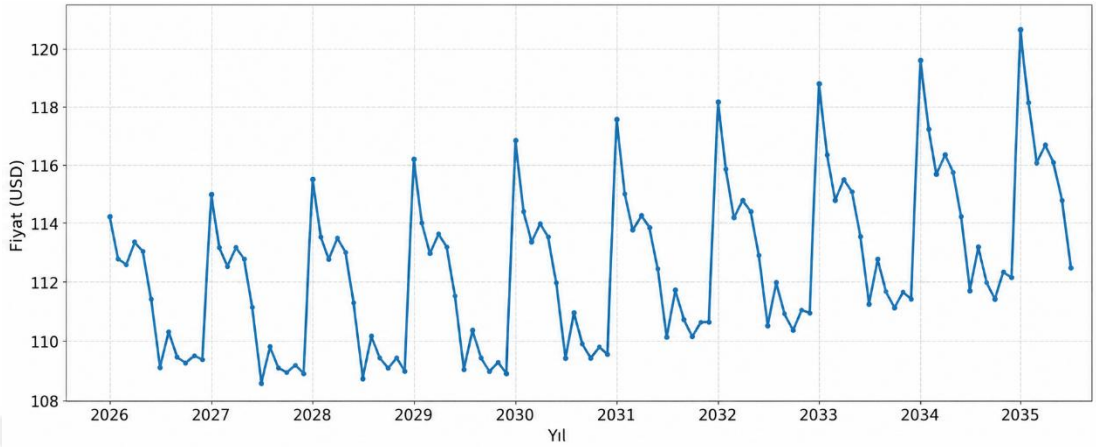
Model performans değerlendirmeleri sonucunda en başarılı performansı gösteren XGBoost modeli kullanılarak 2026-2030 (5 yıllık) ve 2026-2035 (10 yıllık) dönemlerine ilişkin fiyat tahminleri gerçekleştirilmiştir. Tahminler sonucunda aylık bazda fiyat serileri elde edilmiştir. Elde edilen tahminler doğrultusunda, fiyatların zaman içerisindeki değişimini ve uzun dönem eğilimini ortaya koymak amacıyla aylık fiyat serileri grafikler ile görselleştirilmiştir. XGBoost modeline ait 2026-2030 dönemi için yapılan tahmin sonuçları Şekil 4.7'de, 2026-2035 dönemi için yapılan tahmin sonuçları ise Şekil 4.8'de verilmiştir.



Şekil 4.7 XGBoost modeli ile 2026-2030 dönemi için tahmin edilen Türkiye ortalama tomruk AASF'leri

Şekil 4.7 incelendiğinde, XGBoost modeli kullanılarak oluşturulan 2026-2030 dönemi (5 yıllık) tomruk AASF tahminlerinin genel olarak yatay-yukarı yönlü bir eğilim sergilediği görülmektedir. Tahmin edilen fiyatlar dönem boyunca aylık bazda belirli dalgalanmalar göstermekle birlikte, genel fiyat seviyesinin korunduğu ve yıllar itibarıyla sınırlı bir artış eğiliminin devam ettiği görülmektedir. Ayrıca, her yıl

içerisinde benzer dönemlerde yükseliş ve düşüş hareketlerinin tekrarlanması, fiyat serisinde dönemsel değişimlerin sürdüğüne işaret etmektedir.



Şekil 4.8 XGBoost modeli ile 2026-2035 dönemi için tahmin edilen Türkiye ortalama tomruk AASF'leri

Şekil 4.8 incelendiğinde, XGBoost modeli ile oluşturulan 2026-2035 dönemine ilişkin tomruk AASF tahminlerinin uzun dönemde genel olarak artış eğilimini sürdürdüğü görülmektedir. Tahmin edilen fiyatlar dönem boyunca aylık bazda dalgalanmalar göstermekle birlikte, uzun dönemli eğilim yukarı yönlüdür. Yıllar itibarıyla fiyat seviyelerinde kademeli bir artış gözlenirken, aylık değişimlerin belirli bir aralıkta devam ettiği görülmektedir. Ayrıca, dönem boyunca fiyat serisinde ani ve keskin kırılmalar yerine kontrollü dalgalanmaların hakim olduğu, genel fiyat seviyesinin ise istikrarlı bir görünüm sergilediği söylenebilmektedir.

5. TARTIŞMA

Bu çalışmada kızılçam normal boy tomruk fiyatlarının tahmininde çeşitli makine öğrenmesi algoritmalarının karşılaştırmalı performansı incelenmiştir. Elde edilen bulgular, fiyat oluşum sürecinin doğrusal ve tek boyutlu bir yapıdan ziyade çok değişkenli ve karmaşık bir etkileşim örüntüsü içinde şekillendiğini ortaya koymaktadır. Bu bölümde söz konusu bulgular, kullanılan modellerin performans karşılaştırması, belirleyici değişkenlerin rolü ve literatürdeki ilgili çalışmalarla ilişkilendirilmesi kapsamında ele alınmaktadır.

Çalışmada kullanılan makroekonomik değişkenlerin birbirleriyle yüksek düzeyde ilişkili olması ve benzer ekonomik çevrimlerden etkilenmeleri nedeniyle, bu tür veri setlerinde yüksek korelasyon ve çoklu doğrusal bağlantı problemi yaygın olarak gözlenebilmektedir (Ubangida ve Abdullahi, 2023). Nitekim Pearson korelasyon analizi sonuçlarında bazı açıklayıcı değişkenler arasında yüksek düzeyde doğrusal ilişkiler belirlenmiştir. Bununla birlikte, yüksek korelasyon katsayıları tek başına ilgili değişkenlerin modelden çıkarılmasını gerektirmemektedir. Chan vd. (2022), çoklu doğrusal bağlantının giderilmesinde değişken seçimi, değiştirilmiş tahmin yöntemleri ve makine öğrenmesi tabanlı yaklaşımlar gibi farklı yöntemlerin kullanılabileceğini, uygun yaklaşımın ise çalışmanın amacına göre belirlenmesi gerektiğini ifade etmektedir. Ayrıca Derraz vd. (2023), çoklu doğrusal bağlantı içeren veri yapılarında topluluk öğrenme algoritmalarının geleneksel makine öğrenmesi yöntemlerine kıyasla daha başarılı sonuçlar elde edebildiğini bildirmiştir. Bu çalışmada da en yüksek performansın XGBoost, RF ve LGBM modelleri tarafından elde edilmesi, söz konusu bulguları desteklemektedir. Çalışmanın temel amacı, değişkenler arasındaki doğrusal ilişkiyi en aza indirmekten ziyade, kızılçam normal boy tomruk AASF'lerinin tahmininde yüksek doğruluk, kararlılık ve genellenebilirlik sağlayan bir makine öğrenmesi modeli geliştirmektir. Bu nedenle değişkenlerin modelde tutulmasına ilişkin karar yalnızca korelasyon katsayılarına göre verilmemiş; Time Series Split çapraz doğrulama sonuçları, model performans metrikleri ve SHAP analizi birlikte değerlendirilmiştir.

Modellerin performansları incelendiğinde; LR ve RR modellerinin görece düşük tahmin performansı sergilemesi, tomruk fiyatlarının sabit katsayılı ilişkilerle yeterince açıklanamadığını göstermektedir. Nitekim bu modellere ait tahmin değerlerinin belirli bir bantta yoğunlaşması, doğrusal yapıların fiyatlardaki ani değişimleri ve karmaşık örüntüleri temsil etmekte yetersiz kaldığına işaret etmektedir. Buna karşılık, ağaç tabanlı makine öğrenmesi algoritmalarının daha yüksek tahmin başarısı sunması, değişkenler arasındaki doğrusal olmayan ilişkilerin modelleme sürecinde belirleyici bir rol üstlendiğini açıkça ortaya koymaktadır. Özellikle XGBoost, RF ve LGBM modellerinin daha düşük hata düzeyleri ve daha yüksek açıklayıcılık gücü sergilemesi, tomruk fiyatlarının ekonomik, sektörel ve satışa ilişkin değişkenlerin birleşik etkisi altında şekillendiğini teyit etmektedir.

Hiperparametre optimizasyonu sonrasında özellikle RF modelinde gözlenen performans artışı, model başarısının yalnızca kullanılan algoritmaya değil, veri yapısına uygun parametre kombinasyonlarının belirlenmesine de bağlı olduğunu göstermektedir. Bununla birlikte optimizasyon sürecinin tüm modeller üzerinde benzer düzeyde iyileşme sağlamaması, model performansının veri setinin yapısı, değişken çeşitliliği ve algoritmaların öğrenme mekanizmalarıyla doğrudan ilişkili olduğunu düşündürmektedir. Özellikle tomruk fiyatları gibi ekonomik dalgalanmalardan etkilenen piyasalarda veri yapısının doğrusal olmayan özellikler taşıması, bazı algoritmaların diğerlerine göre daha başarılı sonuçlar vermesine neden olabilmektedir. Bu durum, ormancılık ekonomisinde veri temelli modelleme çalışmalarında yalnızca algoritma seçiminin değil, veri ön işleme, değişken seçimi ve model optimizasyon süreçlerinin de kritik öneme sahip olduğunu göstermektedir.

Model performanslarının çok kriterli karar verme yaklaşımıyla değerlendirilmesi sonucunda XGBoost modelinin en uygun alternatif olarak belirlenmesi, çalışmanın dikkat çekici bulgularından biri olarak değerlendirilmektedir. RF ve LGBM modelleri bazı hata ölçütlerinde güçlü sonuçlar vermesine rağmen, Entropi temelli TOPSIS yaklaşımıyla yapılan bütüncül değerlendirme sonucunda XGBoost modelinin daha dengeli bir performans sergilediği belirlenmiştir. Bu durum, model performansının yalnızca tek bir hata ölçütüne göre değerlendirilmesinin yanıltıcı sonuçlar oluşturabileceğini göstermektedir. Özellikle ormancılık ekonomisi gibi çok boyutlu ve

değişken piyasa koşullarına sahip alanlarda, farklı hata ve uyum ölçütlerinin birlikte değerlendirilmesi daha sağlıklı sonuçlar sağlayabilmektedir. Bu yönüyle çalışma, makine öğrenmesi modellerinin karşılaştırılmasında Entropi temelli TOPSIS yaklaşımının kullanılabilirliğini ortaya koyarak ormancılık ekonomisi literatürüne metodolojik açıdan da katkı sunmaktadır.

SHAP analizi sonuçları, tomruk fiyatlarının oluşumunda sanayi üretim endeksi, dış ticaret göstergeleri ve kısa boy tomruk fiyatlarının belirleyici değişkenler olduğunu ortaya koymaktadır. Bunun yanı sıra ihracat ve ithalat değişkenlerinin yüksek katkı sağlaması, tomruk piyasasının yalnızca yerel piyasa koşullarından değil, küresel talep ve ticaret dinamiklerinden de önemli ölçüde etkilendiğini göstermektedir. Türkiye'de orman ürünleri sektörünün mobilya, MDF, yonga levha ve inşaat sektörleriyle doğrudan ilişkili olması, sanayi üretimindeki değişimlerin tomruk talebine yansımasına neden olabilmektedir. Benzer şekilde mazot fiyatının önemli değişkenler arasında yer alması, üretim ve nakliye maliyetlerinin tomruk fiyatları üzerindeki etkisini ortaya koymaktadır. Özellikle orman ürünlerinin taşıma maliyetlerine duyarlı olması ve nakliye süreçlerinin yoğun biçimde akaryakıt kullanımına bağlı olması, enerji maliyetlerindeki değişimlerin fiyatlara doğrudan yansımasına neden olabilmektedir. Buna karşılık faiz oranı, TÜFE ve altın fiyatı gibi genel makroekonomik göstergelerin modele katkısının daha sınırlı düzeyde kalması, tomruk fiyatlarının genel ekonomik göstergelerden ziyade reel sektör faaliyetleri ve sektöre özgü değişkenlerle daha güçlü ilişki içerisinde olduğunu düşündürmektedir.

Çalışmada kullanılan veri seti, 2014-2024 dönemine ait aylık gözlemlerden oluşmaktadır. Makine öğrenmesi modellerinin başarısı büyük ölçüde veri setinin kapsamına, temsil gücüne ve içerdiği ekonomik çeşitliliğe bağlıdır. Bu çalışmada kullanılan veri seti; ekonomik dalgalanmalar, döviz kuru hareketleri, yüksek enflasyon dönemleri ve COVID-19 sonrasında yaşanan piyasa değişimleri gibi farklı ekonomik koşulları kapsaması bakımından modellerin değişen piyasa dinamiklerini öğrenmesine olanak sağlamıştır. Bu durum, geliştirilen modellerin farklı ekonomik koşullara uyum sağlayabilmesine ve güçlü tahmin performansı sergilemesine katkıda bulunmuştur.

Bununla birlikte, daha uzun zaman dilimlerini kapsayan ve yeni gözlemlerle sürekli güncellenen veri setleri, farklı piyasa döngülerini daha kapsamlı biçimde yansıtarak modellerin genelleme yeteneğini daha da geliştirebilir. Bu nedenle, gelecekte veri setinin güncel gözlemlerle genişletilmesi ve modellerin yeniden eğitilmesi, tahmin performansının artırılmasına ve daha güvenilir uzun dönem fiyat projeksiyonlarının oluşturulmasına katkı sağlayacaktır. Ancak tahmin ufku uzadıkça ekonomik, sektörel ve küresel koşullarda meydana gelebilecek öngörülemeyen değişimlerin etkisi de artacağından, özellikle uzun dönemli fiyat projeksiyonlarının belirli varsayımlar altında değerlendirilmesi ve düzenli aralıklarla güncellenmesi önem taşımaktadır.

Doğrusal modellerin tahmin değerlerinin belirli bir bantta yoğunlaşması ve ani fiyat değişimlerini yeterince temsil edememesi, tomruk piyasasının dalgalı ve heterojen yapısıyla ilişkilendirilebilir. Özellikle açık artırmalı satış sistemlerinde fiyatların yalnızca ürün özelliklerinden değil; piyasa beklentileri, dönemsel talep değişimleri, ekonomik belirsizlikler ve arz koşullarından da etkilenmesi, doğrusal olmayan modelleme yaklaşımlarını daha avantajlı hale getirmektedir. Türkiye'de tomruk satışlarının önemli ölçüde açık artırmalı sistem üzerinden yürütülmesi ve piyasa koşullarının dönemsel olarak hızlı değişebilmesi, fiyat davranışlarının karmaşık bir yapı göstermesine neden olmaktadır. Nitekim Lamichhane vd. (2023), çam tomruk fiyatlarının tahminine yönelik çalışmalarında yapay sinir ağlarının fiyatlardaki dönüm noktalarını ve ani değişimleri klasik ekonometrik modellere göre daha başarılı biçimde yakalayabildiğini belirtmiştir. Benzer şekilde Kożuch vd. (2023), odun fiyat tahmininde doğrusal olmayan modelleme yaklaşımlarının karmaşık piyasa yapılarında daha başarılı sonuçlar verdiğini ifade etmektedir. Bu çalışmada elde edilen bulgular da söz konusu çalışmaları destekler niteliktedir.

Banaś ve Utnik-Banaś (2021), yuvarlak odun fiyatlarının tahmininde mevsimsellik ve sektörel göstergelerin önemli etkiler oluşturduğunu belirtmiş ve dışsal değişkenlerin modele dahil edilmesinin tahmin performansını artırdığını ortaya koymuştur. Bu çalışmada da sanayi üretim endeksi, dış ticaret verileri ve maliyet unsurlarının önemli değişkenler olarak belirlenmesi, tomruk fiyatlarının çok boyutlu ekonomik ilişkiler çerçevesinde şekillendiğini göstermektedir. Benzer şekilde Chang ve Li (2025), odun esaslı panel fiyatlarının tahmininde tedarik zinciri göstergeleri, enerji maliyetleri ve

talep değişkenlerinin birlikte değerlendirilmesinin tahmin doğruluğunu artırdığını belirtmiştir. Bu çalışmada SHAP analizi sonucunda üretim maliyetleri ve dış ticaret göstergelerinin yüksek önem düzeyine sahip olması, söz konusu çalışmalarla uyumlu sonuçlar ortaya koymaktadır.

Literatürde yer alan bazı çalışmalar, odun ürünleri fiyatlarının tahmininde hibrit ve derin öğrenme tabanlı modellerin başarılı sonuçlar verdiğini göstermektedir. Koutroumanidis vd. (2009), odun fiyatlarının hem doğrusal hem de doğrusal olmayan bileşenler içerdiğini ve hibrit ARIMA–ANN modellerinin başarılı sonuçlar sunduğunu belirtmiştir. Lopes vd. (2021) ise kriz dönemlerinde finansal piyasa tahminlerinde LSTM tabanlı modellerin yüksek performans gösterdiğini ifade etmektedir. Bununla birlikte bu çalışmada ağaç tabanlı makine öğrenmesi algoritmalarının daha başarılı sonuçlar vermesi, model performansının büyük ölçüde veri yapısı, değişken çeşitliliği ve piyasa özelliklerine bağlı olarak değişebileceğini göstermektedir. Özellikle açık artırmalı tomruk satışlarının heterojen yapısı, doğrusal olmayan ilişkileri güçlü biçimde modelleyebilen ağaç tabanlı algoritmaların avantaj sağlamasına neden olmuş olabilir.

Bu çalışmada tomruk fiyatlarının yalnızca geçmiş fiyat hareketleriyle değil; satış miktarı, dış ticaret göstergeleri, makroekonomik değişkenler ve gecikmeli fiyat etkilerinin birlikte kullanılmasıyla daha başarılı biçimde tahmin edilebildiği görülmüştür. Bu bulgu, odun ürünleri piyasalarında fiyat oluşumunun çok sayıda ekonomik ve sektörel faktörün etkileşimi sonucunda gerçekleştiğini göstermektedir. Benzer şekilde, makroekonomik değişkenlerin tomruk fiyatları üzerindeki belirleyici etkisi Şenel (2018) tarafından da ortaya konulmuş, fiyat tahmininde yalnızca geçmiş fiyat bilgisine dayalı modeller yerine ekonomik değişkenleri de içeren yaklaşımların daha kapsamlı sonuçlar sağlayabileceği vurgulanmıştır.

Son yıllarda gerçekleştirilen çalışmalar, orman ürünleri fiyat tahmininde yalnızca zamansal bağımlılıkların değil, mekânsal ve sektörel ilişkilerin de önemli olduğunu göstermektedir. Thao ve Duc (2025), Vietnam tomruk piyasasında GNN ve LSTM tabanlı modeller kullanarak hem zamansal hem de mekânsal bağımlılıkların fiyat oluşumunda etkili olduğunu ortaya koymuştur. Yang ve Zhang (2025) ise çok kaynaklı

veri füzyonu yaklaşımıyla ekonomik göstergeler, piyasa eğilimleri ve dış ticaret verilerinin birlikte kullanılmasının tahmin doğruluğunu artırdığını belirtmiştir. Bu çalışmalar birlikte değerlendirildiğinde, tomruk fiyatlarının yalnızca geçmiş fiyat hareketleriyle açıklanamayacağı; ekonomik, sektörel, mekânsal ve ticari ilişkilerin birlikte değerlendirilmesi gerektiği anlaşılmaktadır. Bu çalışmada dış ticaret göstergeleri, sanayi üretim endeksi ve maliyet unsurlarının önemli değişkenler olarak belirlenmesi de bu yaklaşımı desteklemektedir.

Bununla birlikte çalışmanın bazı sınırlılıkları da bulunmaktadır. Araştırmada kullanılan veri seti belirli bir dönemi kapsadığından, gelecekte meydana gelebilecek ekonomik krizler, küresel piyasa şokları, politika değişiklikleri veya sektörün yapısında oluşabilecek dönüşümlerin model performansı üzerindeki etkileri doğrudan değerlendirilememektedir. Ayrıca çalışmada OBM'lerin modele kategorik değişken olarak dahil edilmesi bölgesel heterojenliğin belirli ölçüde temsil edilmesini sağlamış olsa da, lojistik maliyetleri, yerel piyasa koşulları, alıcı davranışları, işletme bazlı operasyonel farklılıklar ve ürün kalite özellikleri gibi daha ayrıntılı değişkenlerin düzenli ve güvenilir veri eksikliği nedeniyle modele dahil edilememesi, fiyat oluşumunu etkileyen bazı unsurların tam olarak temsil edilememesine neden olmuş olabilir. Gelecekte gerçekleştirilecek çalışmalarda daha uzun dönemli veri setlerinin kullanılması, ayrıntılı bölgesel göstergelerin modele entegre edilmesi ve mekânsal bağımlılıkları doğrudan modelleyebilen yeni nesil makine öğrenmesi yaklaşımlarının uygulanması, tahmin doğruluğunun daha da artırılmasına katkı sağlayacaktır.

Genel olarak değerlendirildiğinde, çalışma bulguları tomruk fiyatlarının tahmininde doğrusal olmayan ilişkileri modelleyebilen veri temelli yaklaşımların daha başarılı sonuçlar sunduğunu ortaya koymaktadır. Ayrıca elde edilen bulgular, ormancılık ekonomisinde makine öğrenmesi yöntemlerinin fiyat tahmini, satış planlaması, piyasa analizi ve karar destek süreçlerinde önemli bir kullanım potansiyeline sahip olduğunu göstermektedir. Özellikle dış ticaret, üretim maliyetleri ve sektörel göstergelerin birlikte değerlendirilmesi, tomruk piyasalarının daha gerçekçi biçimde modellenmesine katkı sağlayabilmektedir. Bu kapsamda çalışmanın, ormancılık ekonomisinde veri temelli karar destek sistemlerinin geliştirilmesine ve ileri düzey tahmin modellerinin kullanımına katkı sunduğu düşünülmektedir.

6. SONUÇ VE ÖNERİLER

Bu çalışmada, OGM tarafından yayımlanan resmi satış verileri kullanılarak açık artırmalı kızılçam normal boy tomruk AASF'lerinin veri temelli yöntemlerle tahmin edilmesi amaçlanmış; doğrusal modeller ile ağaç tabanlı makine öğrenmesi algoritmaları karşılaştırmalı olarak değerlendirilmiştir. Araştırma, 2014-2024 dönemine ait aylık gözlemleri kapsayan ve Türkiye'de kızılçam üretiminin gerçekleştirildiği 21 OBM'ye ait veriler kullanılarak yürütülmüştür. Fiyat dinamiklerinin açıklanabilmesi amacıyla satış miktarı, makroekonomik göstergeler, dış ticaret değişkenleri ve özellik mühendisliği kapsamında oluşturulan gecikmeli fiyat değişkenleri birlikte kullanılmış; ayrıca bölgesel heterojenliğin etkisini kısmen temsil edebilmek amacıyla OBM değişkeni kategorik değişkenler olarak modele dahil edilmiştir. Model performansının yalnızca tek bir ölçüt üzerinden değerlendirilmesinin yanıltıcı olabileceği kabul edilerek, çok sayıda hata ve uyum metriği ile birlikte Entropi ve TOPSIS temelli çok kriterli değerlendirme yaklaşımı benimsenmiştir.

Çalışmadan elde edilen bulgular, kızılçam normal boy tomruk fiyatlarının doğrusal ve tek yönlü ilişkilerle yeterince açıklanamadığını; buna karşılık doğrusal olmayan ilişkileri ve değişkenler arasındaki karmaşık etkileşimleri modelleyebilen makine öğrenmesi algoritmalarının daha başarılı sonuçlar verdiğini göstermiştir. Hiperparametre optimizasyonu öncesinde LGBM modeli test veri setinde en yüksek R^2 ile en düşük RMSE ve MAE değerlerine ulaşarak dengeli bir performans sergilemiş, hiperparametre optimizasyonu sonrasında ise RF modeli test veri setinde en yüksek R^2 ile en düşük RMSE ve MAE değerlerini elde ederek öne çıkmıştır. Buna karşılık doğrusal modeller olan LR ve RR, hem eğitim hem de test veri setlerinde daha düşük açıklayıcılık ve daha yüksek hata düzeyleri üretmiştir. Bu sonuçlar, tomruk fiyatlarının tahmininde doğrusal olmayan modelleme yaklaşımlarının daha uygun olduğunu ortaya koymaktadır.

Araştırmanın önemli sonuçlarından biri, model performansının kullanılan değerlendirme yaklaşımına bağlı olarak değişebilmesidir. Tekil performans ölçütleri dikkate alındığında RF modeli daha başarılı görünürken, performans metriklerinin

Entropi yöntemi ile ağırlıklandırılması ve TOPSIS yöntemi ile birlikte değerlendirilmesi sonucunda XGBoost modelinin ideal çözüme en yakın alternatif olduğu belirlenmiştir. Bu bulgu, model seçiminde yalnızca tek bir performans ölçütüne dayalı değerlendirmelerin yeterli olmayabileceğini göstermektedir. Dolayısıyla farklı performans boyutlarını birlikte dikkate alan çok kriterli karar verme yaklaşımlarının daha güvenilir ve bütüncül sonuçlar sağlayabileceği değerlendirilmektedir.

Gerçekleştirilen SHAP analizi, kızılçam normal boy tomruk AASF'lerinin tahmininde en yüksek katkının satış miktarları, geçmiş dönem fiyat bilgileri (gecikmeli fiyatlar ve hareketli ortalama), kısa boy tomruk fiyatı ile sanayi üretim endeksi gibi sektörel ve piyasa dinamiklerini yansıtan değişkenlerden geldiğini göstermiştir. Buna karşılık faiz oranı, enflasyon göstergeleri, döviz kuru ve altın fiyatı gibi genel makroekonomik değişkenlerin modele katkısı daha sınırlı düzeyde kalmıştır. Bu bulgular, tomruk fiyatlarının yalnızca genel ekonomik koşullarla değil, ormancılık sektörüne özgü arz-talep yapısı, satış miktarları ve geçmiş fiyat hareketleriyle daha güçlü şekilde belirlendiğini ortaya koymaktadır.

Bu çalışma, Türkiye'de kızılçam normal boy tomruk AASF'lerinin tahmininde doğrusal ve doğrusal olmayan makine öğrenmesi algoritmalarını aynı veri seti üzerinde sistematik olarak karşılaştırması, model performansını Entropi ve TOPSIS tabanlı çok kriterli karar verme yaklaşımıyla değerlendirmesi ve SHAP analizi kullanılarak model sonuçlarının yorumlanabilirliğini artırması bakımından ormancılık ekonomisi literatürüne önemli metodolojik katkılar sunmaktadır. Ayrıca Türkiye genelinde kızılçam üretiminin gerçekleştirildiği 21 OBM'yi kapsayan uzun dönemli bir veri setinin kullanılması, geliştirilen modellerin farklı bölgesel piyasa koşullarını öğrenebilmesine ve sonuçların temsil gücünün artırılmasına katkı sağlamıştır.

Çalışmadan elde edilen bulgular doğrultusunda, gelecekte gerçekleştirilecek araştırmalarda daha uzun zaman aralıklarını kapsayan veri setlerinin kullanılması; bölgesel piyasa koşullarını daha ayrıntılı yansıtan değişkenlerin, alıcı davranışları, ürün kalite özellikleri ve işletme bazlı operasyonel değişkenler gibi faktörlerin modele dahil edilmesi önerilmektedir. Ayrıca bölgesel farklılıkların tomruk fiyatları üzerindeki etkisinin mekânsal analiz yöntemleriyle ayrıntılı olarak incelenmesi

literatüre önemli katkılar sağlayabilir. Bunun yanında derin öğrenme algoritmaları, hibrit makine öğrenmesi yaklaşımları ve açıklanabilir yapay zeka yöntemlerinin kullanılması, hem tahmin doğruluğunun hem de model yorumlanabilirliğinin artırılmasına katkı sağlayabilir. İklim değişkenleri, ayrıntılı üretim ve lojistik maliyetleri, dış ticaret göstergeleri ile sektörel talep göstergeleri gibi ilave değişkenlerin modele entegre edilmesiyle daha kapsamlı ve yüksek doğruluklu tahmin sistemlerinin geliştirilebileceği değerlendirilmektedir.

Uygulama açısından değerlendirildiğinde, OGM ve bağlı birimlerin satış planlaması, gelir projeksiyonları ve ihale stratejilerinde veri temelli tahmin modellerinden yararlanmasının önemli katkılar sağlayabileceği düşünülmektedir. Özellikle makroekonomik göstergeler, satış miktarı ve geçmiş fiyat hareketlerini birlikte dikkate alan modellerin, tomruk fiyatlarındaki değişimlerin daha isabetli biçimde öngörülmesine katkı sağlayacağı değerlendirilmektedir. Ayrıca bu modellerin karar destek sistemlerine entegre edilmesinin, hem kamu yöneticileri hem de odun hammaddesi piyasasında faaliyet gösteren sektör paydaşları açısından daha rasyonel, öngörülebilir ve veri temelli planlama süreçlerini destekleyebileceği öngörülmektedir.

KAYNAKLAR

Abisoye, B. O., Sun, Y., & Zenghui, W. (2024). A survey of artificial intelligence methods for renewable energy forecasting: Methodologies and insights. *Renewable Energy Focus*, *48*, 100529.

Ahamed, B. S., & Arya, M. S. (2021). Prediction of type-2 diabetes using the LGBM classifier methods and techniques. *Turkish Journal of Computer and Mathematics Education*, *12*(12), 223-231.

Ahmed, I., & Yadav, P. K. (2023). Plant disease detection using machine learning approaches. *Expert Systems*, *40*(5), e13136.

Aksoy, H., & Günlü, A. (2025). UAV and satellite-based prediction of aboveground biomass in scots pine stands: a comparative analysis of regression and neural network approaches. *Earth Science Informatics*, *18*(1), 66.

Akyol, A., & Tolunay, A. (2006). Türkiye'de sürdürülebilir orman kaynakları yönetimi, ilkeleri, göstergeleri ve uygulamaları. *Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, *10*(2), 221-234.

Alami, S. E. A. E., Mouiha, A., Hafid, A., & Alaoui, A. E. H. (2025). *Machine learning and deep learning in computational finance: A systematic review*. arXiv.

Ali, J., Haoran, W., Mehmood, K., Hussain, W., Iftikhar, F., Shahzad, F., ... & Zhongkui, J. (2025). Remote sensing and integration of machine learning algorithms for above-ground biomass estimation in Larix principis-rupprechtii Mayr plantations: a case study using Sentinel-2 and Landsat-9 data in northern China. *Frontiers in Environmental Science*, *13*, 1577298.

Andonie, R. (2019). Hyperparameter optimization in learning systems: R. Andonie. *Journal of Membrane Computing*, *1*(4), 279-291.

Ardabili, S., Abdolalizadeh, L., Mako, C., Torok, B., & Mosavi, A. (2022). Systematic review of deep learning and machine learning for building energy. *Frontiers in Energy Research*, *10*, 786027.

Ateş, H. (2025). Yapay zeka (AI) ve maden aramacılığında kullanımı. *MTA Doğal Kaynaklar ve Ekonomi Bülteni, 39*, 77-82.

Athey, S., Levin, J., & Seira, E. (2011). Comparing open and sealed bid auctions: Evidence from timber auctions. *The Quarterly Journal of Economics*, *126*(1), 207-257.

Babaei, H., Mohammadi, S., & Ghaneai, H. (2025). *A new decision-making method based on Shannon entropy analysis*. arXiv.

Banaś, J., & Utnik-Banaś, K. (2021). Evaluating a seasonal autoregressive moving average model with an exogenous variable for short-term timber price

forecasting. Forest Policy and Economics, *131*, 102564. doi.org/10.1016/j.forpol.2021.102564

Bardak, S., Ersen, N., Polat, K., & Akyüz, K. C. (2024). Makine öğrenmesi yöntemleri ile hisse senedi fiyat tahmini: kâğıt firması örneği. *Artvin Çoruh Üniversitesi Orman Fakültesi Dergisi*, *25*(2), 47-58.

Barkley, A. (2019). *The economics of food and agricultural markets*. New Prairie Press, Kansas State University Libraries. https://kstatelibraries.pressbooks.pub/economicsoffoodandag/ Erişim tarihi: 20/06/2026

Bayramoğlu, M. M. (2018). Türkiye'de oduna dayalı orman ürünleri üzerine bir araştırma: Zaman serisi analizi. *Artvin Çoruh Üniversitesi Orman Fakültesi Dergisi*, *19*(1), 18-26.

Bayramoğlu, M. M., & Toksoy, D. (2016). Devlet Orman İşletmelerinin Etkinlik DüzeylerininÖlçülmesi: Doğu Karadeniz Bölgesi Örneği. *Kastamonu Üni., Orman Fakültesi Dergisi*, *16*(2), 515-527.

Bergstra, J., & Bengio, Y. (2012). Random search for hyper-parameter optimization. *Journal of machine learning research*, 13, 281-305.

Beşli, N., & Tenekeci, E. (2020). Uydu verilerinden karar ağaçları kullanarak orman yangını tahmini. *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi*, *11*(3), 899-906.

Bishop, C. M., & Nasrabadi, N. M. (2006). *Pattern recognition and machine learning*. New York: Springer.

Biswas, P., Pramanik, S., & Giri, B. C. (2016). TOPSIS method for multi-attribute group decision-making under single-valued neutrosophic environment. *Neural computing and Applications*, *27*(3), 727-737.

Brandt, J. (2019). *Text mining policy: Classifying forest and landscape restoration policy agenda with neural information retrieval*. arXiv.

Breiman, L. (2001). Random forests. *Machine learning*, *45*(1), 5-32.

Bryngemark, E. (2019). Second generation biofuels and the competition for forest raw materials: A partial equilibrium analysis of Sweden. *Forest Policy and Economics*, *109*, 102022.

Çankaya, E. Ç., Gencal, B., & Sönmez, T. (2025). Advancing forest land monitoring in Istanbul Regional Directorate of Forestry: Integrating U-Net deep learning. *ArtGRID-Journal of Architecture Engineering and Fine Arts, 7*(1), 26-44.

Chai, T., & Draxler, R. R. (2014). Root mean square error (RMSE) or mean absolute error (MAE)?–Arguments against avoiding RMSE in the literature. *Geoscientific model development*, *7*(3), 1247-1250.

Chakir, A., Andry, J. F., Ullah, A., Bansal, R., & Ghazouani, M. (Eds.). (2024). *Engineering applications of artificial intelligence*. Elsevier.

Chan, J. Y. L., Leow, S. M. H., Bea, K. T., Cheng, W. K., Phoong, S. W., Hong, Z. W., & Chen, Y. L. (2022). Mitigating the multicollinearity problem and its machine learning approach: a review. *Mathematics*, *10*(8), 1283.

Chang, C., & Li, L. (2025). Wood-based panel futures price prediction incorporating supply chain features. *Forest Policy and Economics, 176*, 103512. doi:10.1016/j.forpol.2025.103512.

Chapelle, O., Scholkopf, B., & Zien, A. (2009). Semi-supervised learning [Book review]. *IEEE Transactions on Neural Networks*, *20*(3), 542-542.

Chen, T., & Guestrin, C. (2016). XGBoost: A scalable tree boosting system. *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 785-794.

Cheng, F., Ou, G., Wang, M., & Liu, C. (2024). Remote sensing estimation of forest carbon stock based on machine learning algorithms. *Forests*, *15*(4), 681.

Chu, Z., Yu, J., & Hamdulla, A. (2020). LPG-model: A novel model for throughput prediction in stream processing, using a light gradient boosting machine, incremental principal component analysis, and deep gated recurrent unit network. *Information Sciences*, *535*, 107-129.

Cunningham, P., Cord, M., & Delany, S. J. (2008). Supervised learning. M. Cord & P. Cunningham (Eds.), *Machine learning techniques for multimedia: Case studies on organization and retrieval* (pp. 21-49). Berlin, Heidelberg: Springer Berlin Heidelberg.

Dalu, M. T., Gunter, A. W., Makatu, M., Dowo, G. M., Dondofema, F., & Dalu, T. (2021). Contribution of natural forest products to rural livelihoods at Mavunde and Sambandou Villages, Vhembe Biosphere Reserve, South Africa. *Sustainability*, *13*(8), 4252.

Damar, M. (2024). Sağlık sektöründe karar destek araçları: İş zekâsı, makine öğrenmesi, derin öğrenme ve yapay zeka uygulamaları. *İzmir Sosyal Bilimler Dergisi*, *6*(2), 90-115.

Daşdemir, İ. (2001). Bartın ve Yenice orman işletmelerinde açık artırmalı göknar tomruk satış fiyatını etkileyen faktörler. *Bartın Orman Fakültesi Dergisi, 3*(3), 117-136.

Daşdemir, İ. (2008). Açık artırmalı kayın tomruk satış fiyatını etkileyen faktörler. *Bartın Orman Fakültesi Dergisi, 10*(14), 1-12.

Daşdemir, İ. (2018). *Ormancılık işletme ekonomisi* (4. bs.) Bartın Üniversitesi Yayınları.

Delipetrev, B., Tsinaraki, C., & Kostic, U. (2020). *Historical evolution of artificial intelligence*. Technical Report. Publications Office of the European Union.

Demirel, T. (2021). *Meşcere tipleri haritasının otomatik üretiminde uzaktan algılama verileri (LiDAR ve optik veriler) ve coğrafi bilgi sistemi (CBS) tekniklerine dayalı iki aşamalı yaklaşım* (Proje No. 1200461). TÜBİTAK.

Deng, L. (2014). A tutorial survey of architectures, algorithms, and applications for deep learning. *APSIPA Transactions on Signal and Information Processing*, *3*, e2.

Derraz, R., Muharam, F. M., Nurulhuda, K., Jaafar, N. A., & Yap, N. K. (2023). Ensemble and single algorithm models to handle multicollinearity of UAV vegetation indices for predicting rice biomass. *Computers and Electronics in Agriculture*, *205*, 107621.

Dierickx, M., Verschraegen, S., Wierinck, E., Willems, G., & van Wieringen, A. (2021). Noise disturbance and potential hearing loss due to exposure of dental equipment in Flemish dentists. *International Journal of Environmental Research and Public Health*, *18*(11), 5617.

Duarte, J. M., & Berton, L. (2023). A review of semi-supervised learning for text classification. *Artificial intelligence review*, *56*(9), 9401-9469.

Eker, R., Alkiş, K. C., Uçar, Z., & Aydın, A. (2023). Ormancılıkta makine öğrenmesi kullanımı. *Turkish Journal of Forestry*, *24*(2), 150-177.

Espíndola, R. P., Picanço, M. M., de Andrade, L. P., & Ebecken, N. F. F. (2025). Applications of Machine Learning Methods in Sustainable Forest Management. *Climate*, *13*(8), 159.

Evans, J. D. (1996). *Straightforward statistics for the behavioral sciences*. Thomson Brooks/Cole Publishing Co.

Firebanks-Quevedo, D., Planas, J., Buckingham, K., Taylor, C., Silva, D., Naydenova, G., & Zamora-Cristales, R. (2022). Using machine learning to identify incentives in forestry policy: Towards a new paradigm in policy analysis. *Forest Policy and Economics*, *134*, 102624.

Food and Agriculture Organization of the United Nations (FAO). (1998). *Forest revenue systems and concession management*. Rome: Food and Agriculture Organization of the United Nations.

Food and Agriculture Organization of the United Nations (FAO). (2014). *State of the world's forests: Enhancing the socioeconomic benefits from forests*.

Forkuo, G. O. (2026). Deep learning architectures for forest monitoring and tree inventory management: A review of computer vision applications and challenges. *Research Square*. doi:10.21203/rs.3.rs-8908445/v1.

Frankel, J. A. (2008). The effect of monetary policy on real commodity prices. In J. Y. Campbell (Ed.), *Asset prices and monetary policy* (pp. 291–333). University of Chicago Press. https://doi.org/10.7208/chicago/9780226092126.003.0007

Friedman, J. H. (2001). Greedy function approximation: A gradient boosting machine. *Annals of Statistics, 29*(5), 1189–1232.

Galindo, J., & Tamayo, P. (2000). Credit risk assessment using statistical and machine learning: basic methodology and risk modeling applications. *Computational economics*, *15*(1), 107-143.

Gao, H., Kou, G., Liang, H., Zhang, H., Chao, X., Li, C. C., & Dong, Y. (2024). Machine learning in business and finance: a literature review and research opportunities. *Financial Innovation*, *10*(1), 86.

George Brown College. (2014). *Market structures*. Tutoring and Learning Centre. https://www.georgebrown.ca/sites/default/files/uploadedfiles/tlc/_documents/market_structures.pdf Erişim tarihi: 19/06/2026

Géron, A. (2022). *Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow*. O'Reilly Media.

Ghahramani, Z. (2003). Unsupervised learning. In *Summer school on machine learning* (pp. 72-112). Berlin, Heidelberg: Springer Berlin Heidelberg.

Gleason, C. J., & Im, J. (2012). Forest biomass estimation from airborne LiDAR data using machine learning approaches. *Remote Sensing of Environment*, *125*, 80-91.

Goodfellow, I., Bengio, Y., & Courville, A. (2016). Deep Learning. MIT Press.

Górna, A., & Adamowicz, K. (2021). A comparison of prediction efficiency for timber prices in Poland in times of economic crisis with the application of the linear approximation method and brown's exponential smoothing model. *Drewno. Prace Naukowe, Doniesienia, Komunikaty= Wood. Research Papers, Reports, Announcements*, *64*(208), 135-147.

Gruber, J. W., & Vigfusson, R. J. (2018). Interest rates and the volatility and correlation of commodity prices. *Macroeconomic Dynamics, 22*(3), 600–619. https://doi.org/10.1017/S1365100516000698

Grzybowski, A., Pawlikowska–Łagód, K., & Lambert, W. C. (2024). A history of artificial intelligence. *Clinics in dermatology*, *42*(3), 221-229.

Gültekin, Y. S. (2015). *Devlet orman işletmelerinde dikili ağaç satışı uygulamasının yapısal eşitlik modellemesiyle analizi*. Doktora Tezi, Düzce Üniversitesi Fen Bilimleri Enstitüsü, Düzce.

Güneş Şen, S. (2025a). Machine Learning-Based Water Level Forecast in a Dam Reservoir: A Case Study of Karaçomak Dam in the Kızılırmak Basin, Türkiye. *Sustainability*, *17*(18), 8378.

Güneş Şen, S. (2025b). From Indices to Algorithms: A Hybrid Framework of Water Quality Assessment Using WQI and Machine Learning Under WHO and FAO Standards. *Water*, *17*(21), 3050.

Gupta, C., Johri, I., Srinivasan, K., Hu, Y. C., Qaisar, S. M., & Huang, K. Y. (2022). A systematic review on machine learning and deep learning models for electronic information security in mobile networks. *Sensors*, *22*(5), 2017.

Gupta, H. V., Kling, H., Yilmaz, K. K., & Martinez, G. F. (2009). Decomposition of the mean squared error and NSE performance criteria: Implications for improving hydrological modelling. *Journal of hydrology*, *377*(1-2), 80-91.

Hady, M. F. A., & Schwenker, F. (2013). Semi-supervised learning. *Handbook on neural information processing*, 215-239.

Herm, L. V., Heinrich, K., Wanner, J., & Janiesch, C. (2023). Stop ordering machine learning algorithms by their explainability! A user-centered investigation of performance and explainability. *International Journal of Information Management*, *69*, 102538.

Hetemäki, L., & Hurmekoski, E. (2016). Forest products markets under change: review and research implications. *Current Forestry Reports*, *2*(3), 177-188.

Hewamalage, H., Ackermann, K., & Bergmeir, C. (2023). Forecast evaluation for data scientists: common pitfalls and best practices: H. Hewamalage et al. *Data Mining and Knowledge Discovery*, *37*(2), 788-832.

Hoerl, A. E., & Kennard, R. W. (1981). Ridge regression—1980: Advances, algorithms, and applications. *American Journal of Mathematical and Management Sciences*, *1*(1), 5-83.

Hosamo, H., & Mazzetto, S. (2024). Performance evaluation of machine learning models for predicting energy consumption and occupant dissatisfaction in buildings. *Buildings*, *15*(1), 39.

Hurmekoski, E., & Hetemäki, L. (2013). Studying the future of the forest sector: Review and implications for long-term outlook studies. *Forest Policy and Economics*, *34*, 17-29.

Hwang, C. L., & Yoon, K. (1981). Methods for multiple attribute decision making. In *Multiple attribute decision making: methods and applications a state-of-the-art survey* (pp. 58-191). Berlin, Heidelberg: Springer Berlin Heidelberg.

Hwang, C. L., & Yoon, K. (2012). *Multiple attribute decision making: methods and applications a state-of-the-art survey*. Springer Science & Business Media.

Hyndman, R. J., & Athanasopoulos, G. (2021). *Forecasting: Principles and practice* (3rd ed.). OTexts. https://otexts.com/fpp3/accuracy.html Erişim tarihi: 27/12/2025.

Jaafari, A., Pazhouhan, I., & Bettinger, P. (2021). Machine learning modeling of forest road construction costs. *Forests, 12*(9), 1169.

James, G., Witten, D., Hastie, T., & Tibshirani, R. (2021). *An introduction to statistical learning: With applications in R* (2nd ed.). Springer. doi:10.1007/978-1-0716-1418-1.

James, G., Witten, D., Hastie, T., Tibshirani, R., & Taylor, J. (2023). Unsupervised learning. In *An introduction to statistical learning: with applications in Python* (pp. 503-556). Cham: Springer International Publishing.

Janiesch, C., Zschech, P., & Heinrich, K. (2021). Machine learning and deep learning. Electronic Markets, 31(3), 685–695. https://doi.org/10.1007/s12525-021-00475-2

Ji, H. V., Han, S. K., & Park, J. W. (2024). Timber harvest planning using reinforcement learning: A feasibility study. *Forests, 15*(10), 1725.

Jin, X., Che, J., & Chen, Y. (2021). Weed identification using deep learning and image processing in vegetable plantation. *IEEE access*, *9*, 10940-10950.

Jing, W., Kuang, Z., Scherer, R., & Woźniak, M. (2023). Big data and artificial intelligence technologies for smart forestry. *Frontiers in Plant Science*, *14*, 1149740.

Jonsson, R. (2009). *Forest products markets: External drivers affecting Swedish forests and forestry*. Future Forests Working Report.

Kabasakal, E., & Tolunay, A. (2021). Comparison of Selling Prices of Raw Wood Materials in Terms of Sale Times in Turkey. *International Scientific and Vocational Studies Journal*, *5*(1), 34-49.

Kadı, F., & Yılmaz, O. S. (2024). Orman içi açıklıklara ait zamansal değişimlerin uzaktan algılama teknikleri ile Google Earth Engine platformunda tespit edilmesi: Trabzon-Düzköy İlçesi örneği. *Geomatik*, *9*(2), 141-155.

Kaelbling, L. P., Littman, M. L., & Moore, A. W. (1996). Reinforcement learning: A survey. *Journal of artificial intelligence research*, *4*, 237-285.

Kakhani, N., Alamdar, S., Kebonye, N. M., Amani, M., & Scholten, T. (2024b). Uncertainty quantification of soil organic carbon estimation from remote sensing data with conformal prediction. *Remote Sensing*, *16*(3), 438.

Kakhani, N., Rangzan, M., Jamali, A., Attarchi, S., Alavipanah, S. K., Mommert, M., ... & Scholten, T. (2024a). SSL-SoilNet: A hybrid transformer-based framework with self-supervised learning for large-scale soil organic carbon prediction. *IEEE Transactions on Geoscience and Remote Sensing*, *62*, 1-15.

Kalkınma Bakanlığı. (2014). *Sürdürülebilir orman yönetimi özel ihtisas komisyonu raporu*. Kalkınma Bakanlığı.

Kamoona, A., Song, H., Keshavarzian, K., Levy, K., Jalili, M., Wilkinson, R., ... & Meegahapola, L. (2023). Machine learning based energy demand prediction. *Energy Reports*, *9*, 171-176.

Karamanlı, E. (2025). Farklı Meşçere Tiplerinde Kızılçam (*Pinus brutia*) Ormanları İçin Toprak Üstü Biyokütle Karbon Tahmini: Landsat 9 Uydu Verileri ile Makine Öğrenmesi Yaklaşımı. *Journal of Anatolian Environmental and Animal Sciences*, *10*(4), 408-415.

Karch, J. (2020). Improving on adjusted R-squared. *Collabra: Psychology*, *6*(1), Article 45. https://doi.org/10.1525/collabra.343

Kaya, G., Ok, K., & Kulaç, C. (2023). Müşterilerin açık artırmalı tomruk satışlarından beklentileri: Ankara Orman Bölge Müdürlüğü örneği. *Turkish Journal of Forestry*, *24*(3), 272–286. doi.org/10.18182/tjf.1312231

Kaya, N. S., & Dengiz, O. (2024). Comparative analysis of multiple linear regression and random forest regression for predicting soil salinity in paddy fields. *International Symposium on Soil Science and Plant Nutrition*, Samsun, Türkiye.

Kayacan, B., & Öztürk, A. (2009, 19–21 Şubat). Dünyada orman ürünleri piyasa modelleri: Gelişim süreci ve Türkiye için yönelimler. *II. Ormancılıkta Sosyo-Ekonomik Sorunlar Kongresi*, Isparta, Türkiye, 152–165.

Kirsch, M., Wernicke, J., Datta, P., & Preisach, C. (2025). *Early detection of forest calamities in homogeneous stands—Deep learning applied to bark-beetle outbreaks.* arXiv preprint arXiv:2503.12883.

Kılıç, M., Günal, H., & Budak, M. (2022). Toprak organik karbon içeriğinin tahmin ve haritalanmasında makine öğrenmesi tekniklerinin kullanımı. *1st International Conference on Engineering, Natural and Social Sciences*, 211-217, Konya, Türkiye.

Konstantonis, D., Anthopoulou, C., & Makou, M. (2013). Extraction decision and identification of treatment predictors in Class I malocclusions. *Progress in orthodontics*, *14*(1), 47.

Korkmaz, M., & Duman, E. A. (2019). Türkiye'de bazı odun dışı orman ürünlerinin dış ticaretine yönelik değerlendirmeler. *Turkish Journal of Forestry*, *20*(4), 401-410.

Koutroumanidis, T., Ioannou, K., & Arabatzis, G. (2009). Predicting fuelwood prices in Greece with the use of ARIMA models, artificial neural networks and a hybrid ARIMA–ANN model. *Energy Policy*, *37*(9), 3627-3634. doi:10.1016/j.enpol.2009.04.024.

Kozuch, A. (2021). Cointegration analysis in the Central European spruce timber market. *Drewno. Prace Naukowe. Doniesienia. Komunikaty*, *64*(208)119-133.

Kożuch, A., Banaś, J., & Utnik-Banaś, K. (2023). A comparison of artificial neural network and time series models for timber price forecasting. *Forests*, *14*(2), 177. doi:10.3390/f14020177.

Lamichhane, S., Mei, B., & Siry, J. (2023). Forecasting pine sawtimber stumpage prices: A comparison between a time series hybrid model and an artificial neural network. *Forest Policy and Economics*, *154*, 103028. doi:10.1016/j.forpol.2023.103028.

Lauri, P., Forsell, N., Di Fulvio, F., Snäll, T., & Havlik, P. (2021). Material substitution between coniferous, non-coniferous and recycled biomass–Impacts on forest industry raw material use and regional competitiveness. *Forest Policy and Economics*, *132*, 102588.

LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *nature*, *521*(7553), 436-444.

Leskinen, P. (2025). Analyzing timber-price uncertainty in forest planning. *WIT Transactions on Ecology and the Environment*, *31*, 181-188.

Leung, R., Balamurali, M., & Lowe, A. (2022). Surface warping incorporating machine learning assisted domain likelihood estimation: a new paradigm in mine geology modeling and automation. *Mathematical Geosciences*, *54*(3), 533-572.

Li, Y. (2017). *Deep reinforcement learning: An overview*. arXiv preprint arXiv:1701.07274.

Li, Y., Li, C., Li, M., & Liu, Z. (2019). Influence of variable selection and forest type on forest aboveground biomass estimation using machine learning algorithms. *Forests*, *10*(12), 1073.

Liu, D. (2020). A rational performance criterion for hydrological model. *Journal of Hydrology*, *590*, 125488. doi.org/10.1016/j.jhydrol.2020.125488

Lopes, V. V., Reis, J., Silva, E., & Moreira, F. (2021). Forecasting financial markets during crisis periods using LSTM networks. *Expert Systems with Applications*, 171, 114561. https://doi.org/10.1016/j.eswa.2020.114561.

Lundberg, S. M., & Lee, S. I. (2017). A unified approach to interpreting model predictions. *Advances in Neural Information Processing Systems*, *30*.

Maleki, F., Ovens, K., Najafian, K., Forghani, B., Reinhold, C., & Forghani, R. (2020). Overview of machine learning part 1: Fundamentals and classic approaches. *Neuroimaging Clinics of North America*, *30*(4), e17-e32.

Malo, P., Tahvonen, O., Suominen, A., Back, P., & Viitasaari, L. (2021). Reinforcement learning in optimizing forest management. *Canadian Journal of Forest Research*, *51*(10), 1393-1409.

Manjate, E. P. A., Saadat, M., Toriya, H., Inagaki, F., & Kawamura, Y. (2022). Application of entropy method for estimating factor weights in mining-method

selection for development of novel mining-method selection system. *Journal of Sustainable Mining*, *20*(4), 296.

Martinez-Rau, L. S., Zhang, Y., Oelmann, B., & Bader, S. (2025). n-device anomaly detection in conveyor belt operations. *IEEE Open Journal of Instrumentation and Measurement*, *4*, Article 3613073. https://doi.org/10.1109/OJIM.2025.3613073

McCarthy, J., Minsky, M. L., Rochester, N., & Shannon, C. E. (2006). A proposal for the dartmouth summer research project on artificial intelligence, august 31, 1955. *AI magazine*, *27*(4), 12-12.

Mijwil, M. M., Aggarwal, K., Sonia, S., Al-Mistarehi, A. H., Alomari, S., Gök, M., ... & Abdulrhman, S. H. (2022). Has the Future Started? The Current Growth of ArtificialIntelligence, Machine Learning, and Deep Learning. *Iraqi Journal for Computer Science and Mathematics*, *3*(1), 115-123.

Minsky, M., & Papert, S. (1969). An introduction to computational geometry. *Cambridge tiass., HIT*, *479*(480), 104.

Mitchell, T. M. (1997). Does machine learning really work?. *AI magazine*, *18*(3), 11-20.

Mohammed, K., Kpienbaareh, D., Kerr, R. B., Wang, J., Luginaah, I., Lupafya, E., ... & Mkandawire, M. (2026). Integrating participatory GIS, remote sensing, and explainable machine learning to assess forest provisioning services. *Environmental Impact Assessment Review*, *117*, 108245.

Molnar, C. (2020). *Interpretable machine learning*. Lulu.com.

Montáns, F. J., Chinesta, F., Gómez-Bombarelli, R., & Kutz, J. N. (2019). Data-driven modeling and learning in science and engineering. *Comptes Rendus Mécanique*, *347*(11), 845-855.

Montgomery, D. C., Peck, E. A., & Vining, G. G. (2021). *Introduction to linear regression analysis*. John Wiley & Sons.

Moriasi, D. N., Arnold, J. G., Van Liew, M. W., Bingner, R. L., Harmel, R. D., & Veith, T. L. (2007). Model evaluation guidelines for systematic quantification of accuracy in watershed simulations. *Transactions of the ASABE*, *50*(3), 885-900.

Morland, C., Schier, F., Janzen, N., & Weimar, H. (2018). Supply and demand functions for global wood markets: specification and plausibility testing of econometric models within the global forest sector. *Forest Policy and Economics*, *92*, 92-105.

Mosavi, A., & Bahmani, A. (2019). *Energy consumption prediction using machine learning: A review.* Preprints. doi:10.20944/preprints201903.0131.v1.

Mukaka, M. M. (2012). A guide to appropriate use of correlation coefficient in medical research. *Malawi Medical Journal*, *24*(3), 69–71.

Na, N. (2024). Research on Supply Chain Demand Prediction Model Based on LSTM. *Procedia Computer Science*, *243*, 313-322.

Nandy, S., Singh, R., Ghosh, S., Watham, T., Kushwaha, S. P. S., Kumar, A. S., & Dadhwal, V. K. (2017). Neural network-based modelling for forest biomass assessment. *Carbon Management*, *8*(4), 305-317.

Nash, J. E., & Sutcliffe, J. V. (1970). River flow forecasting through conceptual models part I—A discussion of principles. *Journal of hydrology*, *10*(3), 282-290.

Nasteski, V. (2017). An overview of the supervised machine learning methods. *Horizons. b*, 4, 51-62.

Nau, R. (2014). *Notes on linear regression analysis*. Fuqua School of Business, Duke University. https://people.duke.edu/~rnau/Notes_on_linear_regression_analysis--Robert_Nau.pdf Erişim tarihi: 27/12/2025.

Ndikum, P. (2020). *Machine learning algorithms for financial asset price forecasting*. arXiv preprint arXiv:2004.01504. doi:10.48550/arXiv.2004.01504.

Nepal, P., Johnston, C. M., & Ganguly, I. (2021). Effects on global forests and wood product markets of increased demand for mass timber. *Sustainability*, *13*(24), 13943.

Nilsson, N. J. (1998). *Artificial intelligence: A new synthesis*. Morgan Kaufmann Publishers.

Nolander, C., & Lundmark, R. (2024). A review of forest ecosystem services and their spatial value characteristics. *Forests*, *15*(6), 919.

OGM. (2009). *Sürdürülebilir orman yönetimi kriter ve göstergeleri raporu 2008*. Orman Genel Müdürlüğü.

OGM. (2022). *Oduna dayalı orman ürünlerinin satış usul ve esasları hakkında tebliğ* (Tebliğ No: 312). Orman Genel Müdürlüğü.

OGM. (2023). *Ormancılık istatistikleri 2023.* https://www.ogm.gov.tr/tr/e-kutuphane/kitaplik/Ormancilik-istatistikleri Erişim tarihi: 14/05/2024

Öğüt, N., & Kurdoğlu, O. (2025). Tür dağılım modelleri ve sürdürebilir orman yönetimi. *Anadolu Orman Araştırmaları Dergisi*, *11*(2), 470-479.

Ok, K. (1998). Açık artırmalı tomruk satış fiyatları üzerine mevsim etkisinin araştırılması. *Journal of the Faculty of Forestry Istanbul University*, *48*(2), 9-22.

Ouameur, M. A., Caza-Szoka, M., & Massicotte, D. (2020). Machine learning enabled tools and methods for indoor localization using low power wireless network. *Internet of Things*, *12*, 100300.

Özbalcı, M. C., Dikici, S., & Bilgin, T. T. (2024). Forecasting urban forest recreation areas in Turkey using machine learning methods. *Journal of Scientific Reports-A*, 058, 40-56. https://doi.org/10.59313/jsr-a.1457140

Özdemir, E. G., Demiralay, A., & Şahin, B. (2024). Bartın'daki sahil çamı (Pinus pinaster Ait.) ağaçlandırma alanlarında Sentinel-1 ve Sentinel-2 uydu görüntüleri kullanılarak toprak üstü biyokütlenin kestirilmesi. *Türk Uzaktan Algılama ve CBS Dergisi*, *5*(1), 15-27.

Özmen, K. (2019). Integrating physics demonstrations in undergraduate audiology classroom. *Physics Education, 54*(6), 065020.https://doi.org/10.1088/1361-6552/ab4567

Pargent, F., Pfisterer, F., Thomas, J., & Bischl, B. (2022). Regularized target encoding outperforms traditional methods in supervised machine learning with high cardinality features. *Computational Statistics*, *37*(5), 2671–2692. doi.org/10.1007/s00180-022-01207-6

Pasupuleti, V., Thuraka, B., Kodete, C. S., & Malisetty, S. (2024). Enhancing supply chain agility and sustainability through machine learning: Optimization techniques for logistics and inventory management. *Logistics*, *8*(3), 73.

Rai, D. H. (2024). *Artificial intelligence through time: A comprehensive historical review*. Tribhuvan University, Institute of Science and Technology.

Raihan, A. (2023). A review on the integrative approach for economic valuation of forest ecosystem services. *Journal of Environmental Science and Economics*, *2*(3), 1-18.

Rakholia, K. R., Chandraprabh, C., Ramesh, R., Rao, K., Punitha, S., & Kumar, M. (2024). Optimizing inventory management through demand forecasting: A data-driven approach for enhanced supply chain efficiency. In *Proceedings of the 3rd International Conference on Optimization Techniques in the Field of Engineering (ICOFE-2024)*.

Rane, N. L., Mallick, S. K., Kaya, Ö., & Rane, J. (2024). Applications of machine learning in healthcare, finance, agriculture, retail, manufacturing, energy, and transportation: A review. In *Applied machine learning and deep learning: Architectures and techniques* (pp. 112–131). Deep Science Publishing. https://doi.org/10.70593/978-81-981271-4-3_6

Roberts, D., Chalmers, N., Crabtree, B., Thorburn, A., Van des Horst, D., Watt, G., & Thompson, K. (1999). *Scottish forestry: An input-output analysis*. Macaulay Land Use Research Institute, John Clegg & Co., University of Aberdeen.

Russell, S. J., & Norvig, P. (2016). *Artificial intelligence: A modern approach*. London: Pearson Education Limited.

Sağlam, F. (2025). Machine learning-based stem taper model: A case study with Brutian pine. *Frontiers in Forests and Global Change*, *8*, 1609549.

Şahin, O. G., & Gündüz, O. (2024). Toprak neminin LSTM derin öğrenme tekniği kullanılarak ölçek indirgenmesi: Batı Anadolu havzaları için yüksek çözünürlüklü toprak nemi haritalarının oluşturulması. İçinde *XII. Ulusal Hidroloji Kongresi Bildiriler Kitabı* (Cilt 2, ss. 322–328). Samsun, Türkiye.

Samuel, A. L. (1959). Some studies in machine learning using the game of checkers. *IBM Journal of Research and Development, 3*(3), 210-229.

Sarker, I. H. (2021). Machine learning: Algorithms, real-world applications and research directions. *SN Computer Science, 2*(3), 1-21.

Sarker, I. H. (2022). AI-based modeling: techniques, applications and research issues towards automation, intelligent and smart systems. *SN computer science, 3*(2), 158.

Schmidhuber, J. (2022). *Annotated history of modern AI and deep learning*. arXiv preprint arXiv:2212.11279. doi:10.48550/arXiv.2212.11279.

Scikit-learn. (2025). *RobustScaler*. https://scikit-learn.org/stable/modules/generated/sklearn.preprocessing.RobustScaler.html Erişim tarihi: 15/08/2025.

Şen, G,, & Ergün Karak, B. (2024). Karaçam-Sarıçam normal boy tomruk fiyatlarının makine öğrenmesi teknikleriyle geleceğe yönelik tahmini. *V. Ormancılıkta Sosyo-Ekonomik Sorunlar Kongresi Bildirileri*, Isparta, Türkiye, 30 Ekim–1 Kasım 2024.

Şen, G., & Güngör, E. (2018). Determination of the seasonal effect on the auction prices of timbers and prediction of future prices. *Bartın Orman Fakültesi Dergisi*, *20*(2), 266-277.

Şenel, Z. G. (2018). Makroekonomik faktörlerin açık artırmalı tomruk satış fiyatı oluşumuna etkiler. Yüksek Lisans Tezi, *Kastamonu Üniversitesi Fen Bilimleri Enstitüsü.* Kastamonu.

Seyrek, E. C., Narin, O. G., & Uysal, M. (2025). Forest canopy cover estimation with machine learning using GEDI and Landsat data in the Western Marmara Region, Türkiye. *Earth Science Informatics*, *18*(2), 230.

Shapley, L. S. (1953). A value for n-person games. H. W. Kuhn & A. W. Tucker (Eds.), *Contributions to the theory of games II*, 307-317. Princeton: Princeton University Press.

Shinde, P. P., & Shah, S. (2018). A review of machine learning and deep learning applications. *2018 Fourth International Conference on Computing Communication Control and Automation (ICCUBEA)*, 1-6, India. IEEE.

Shrestha, A., & Mahmood, A. (2019). Review of deep learning algorithms and architectures. *IEEE Access, 7*, 53040-53065.

Sitorus, F., & Brito-Parada, P. R. (2020). A multiple criteria decision making method to weight the sustainability criteria of renewable energy technologies under uncertainty. *Renewable and Sustainable Energy Reviews*, *127*, 109891.

Sivaram, M. (2014). Modeling the price trends of teak wood using statistical and artificial neural network techniques. *Electronic Journal of Applied Statistical Analysis*, *7*(2), 180-198.

Stigler, S. M. (1990). *The history of statistics: The measurement of uncertainty before 1900*. Harvard University Press.

Sumer, Y. F. (2025). Orman yangınlarının makine öğrenmesi ve uzaktan algılama yöntemleri kullanılarak tahmin edilmesi ve duyarlılık haritasının oluşturulması. Yüksek Lisans Tezi, *Batman Üniversitesi Lisansüstü Eğitim Enstitüsü*. Batman.

Sun, Z., Wang, Y., Pan, L., Xie, Y., Zhang, B., Liang, R., & Sun, Y. (2022). Pine wilt disease detection in high-resolution UAV images using object-oriented classification. *Journal of Forestry Research*, *33*(4), 1377-1389.

Suominen, A. (2025). *Optimized forest management via reinforcement learning*. Doctoral Thesis, *Aalto University, Aalto University Publication Series*. Finland.

Sutton, R. S., & Barto, A. G. (1999). Reinforcement learning. *Journal of Cognitive Neuroscience*, *11*(1), 126-134.

Thakker, Z. L., & Buch, S. H. (2024). Effect of feature scaling pre-processing techniques on machine learning algorithms to predict particulate matter concentration for Gandhinagar, Gujarat, India. *International Journal of Scientific Research in Science and Technology, 11*(1), 410–419. https://doi.org/10.32628/IJSRST52411150

Thao, N. T. P., & Duc, M. L. (2025). Timber price forecasting in Vietnam using graph neural network and LSTM method. *Proceedings of the Institution of Mechanical Engineers, Part B: Journal of Engineering Manufacture, 239*(18), 2487–2499. https://doi.org/10.1177/09544062251347213

Tiryaki, S. (2025). Forecasting of Türkiye's industrial wood production via some trend analysis tools. *Turkish Journal of Forestry, 26*(3), 413–422. doi.org/10.18182/tjf.1687966

Turan, G. (2018). Çok kriterli karar verme. B. F. Yıldırım, E. Önder (Ed.). *Çok kriterli karar verme yöntemleri* içinde (ss.15-20). Dora Basım Yayınları.

Turgay, G. (2024). Tedarik zincirinde yapay zeka tabanlı talep tahmini ve envanter yönetiminin performansa etkileri. Yüksek Lisans Tezi, *Sakarya Üniversitesi İşletme Enstitüsü.* Sakarya.

Ubangida, S., & Abdullahi, H. (2023). Addressing multicollinearity issues and macroeconomic variables in Nigeria: Correlation coefficients and variance inflation factors (VIF) analysis. *International Journal of Social Science and Economic Research, 8*(6), 1394-1410. doi:10.46609/IJSSER.2023.v08i06.016.

United Nations Economic Commission for Europe, & Food and Agriculture Organization of the United Nations. (2022). *Forest products annual market review 2021–2022*. United Nations. https://digitallibrary.un.org/record/4020232

Ünver, S., & Acar, H. H. (2005). Odun hammaddesi üretim çalışmalarının odun kalite sınıfları üzerine olan etkileri. *Kafkas Üniversitesi Artvin Orman Fakültesi Dergisi*, *6*(1-2), 128-134.

URL-1. *Orman Genel Müdürlüğü (OGM). Tomruk cinslerine göre açık artırmalı satılan ürünlerin fiyatları,* https://www.ogm.gov.tr/tr/e-kutuphane/kitaplik/tomruk-cinslerine-gore-acik-artirmali-satilan-urunlerin-fiyatlari, Erişim tarihi: 11/01/2025

URL-2. *Türkiye Cumhuriyet Merkez Bankası (TCMB). Elektronik Veri Dağıtım Sistemi (EVDS): Mevduat faiz oranları*, https://evds3.tcmb.gov.tr/charts/portlet/Njk4YzM2YjhjNjAxMWY0MDU2MDdkM2Iz/tr, Erişim tarihi: 12/05/2025

URL-3. *Türkiye İstatistik Kurumu (TÜİK). Sanayi Üretim Endeksi Veri Portalı,* https://veriportali.tuik.gov.tr/tr/search?q=sanayi%20%C3%BCretim%20endeksi, Erişim tarihi: 05/05/2025

URL-4. *Türkiye İstatistik Kurumu (TÜİK). Veri Portalı: Gayrisafi Yurt İçi Hasıla (GSYH),* https://veriportali.tuik.gov.tr/tr/search?q=gayrisafi%20yurt%20i%C3%A7i%20has%C4%B1la, Erişim tarihi: 07/05/2025

URL-5. *Türkiye Cumhuriyet Merkez Bankası (TCMB). Tüketici Fiyatları*, https://www.tcmb.gov.tr/wps/wcm/connect/TR/TCMB+TR/Main+Menu/Istatistikler/Enflasyon+Verileri/Tuketici+Fiyatlari, Erişim tarihi: 10/05/2025

URL-6. *Türkiye Cumhuriyet Merkez Bankası (TCMB). Üretici Fiyatları,* https://www.tcmb.gov.tr/wps/wcm/connect/tr/tcmb+tr/main+menu/istatistikler/enflasyon+verileri/uretici+fiyatlari, Erişim tarihi: 11/05/2025

URL-7. *Altın Piyasa. Altın Fiyatları Arşivi,* https://www.altinpiyasa.com/arsiv, Erişim tarihi: 21/05/2025

URL-8. *Investing.com. Crude Oil Historical Data*, http://tr.investing.com/commodities/crude-oil-historical-data, Erişim tarihi: 23/05/2025

URL-9. *Türkiye İstatistik Kurumu (TÜİK). Dış ticaret istatistikleri*, https://veriportali.tuik.gov.tr/tr/search?q=d%C4%B1%C5%9F%20ticaret%20istatistikleri, Erişim tarihi: 10/04/2025

URL-10. *Türkiye Cumhuriyet Merkez Bankası (TCMB). Elektronik Veri Dağıtım Sistemi (EVDS),* https://evds2.tcmb.gov.tr/, Erişim tarihi: 13/05/2025

Uysal, M. M., & Uysal, M. (2025). Uzaktan Algılama ve Veri Bilimi Teknikleriyle Orman Yangınları için Meteorolojik Etkilerin İzlenmesi. *Afyon Kocatepe Üniversitesi Fen ve Mühendislik Bilimleri Dergisi*, *25*(1), 137-143.

Valkenborg, D., Rousseau, A. J., Geubbelmans, M., & Burzykowski, T. (2023). Unsupervised learning. *American Journal of Orthodontics and Dentofacial Orthopedics*, *163*(6), 877-882.

Van Klompenburg, T., Kassahun, A., & Catal, C. (2020). Crop yield prediction using machine learning: A systematic literature review. *Computers and electronics in agriculture*, *177*, 105709.

Vatandaşlar, C., & Zeybek, M. (2021). Extraction of forest inventory parameters using handheld mobile laser scanning: A case study from Trabzon, Türkiye. *Measurement*, *177*, 109328.

Verly Lopes, D. J., Bobadilha, G. D. S., & Peres Vieira Bedette, A. (2021). Analysis of lumber prices time series using long short-term memory artificial neural networks. *Forests*, *12*(4), 428.

Willcock, S., Martínez-López, J., Hooftman, D. A. P., Bagstad, K. J., Balbi, S., Marzo, A., Prato, C., Sciandrello, S., Signorello, G., Voigt, B., Villa, F., Bullock, J. M., & Athanasiadis, I. N. (2018). *Machine learning for ecosystem services*. *Ecosystem Services*, *33*(B), 165–174. https://doi.org/10.1016/j.ecoser.2018.04.004

Wysocki, M., Budziński, W., Giergiczny, M., & Ślepaczuk, R. (2025). The cointegration of Polish timber sales channels: Patterns and implications. *Forest Policy and Economics*, *178*, 103566.

Yang, Z., & Zhang, Y. (2025). Enhancing cross-border forest product trade forecasting with LSTM and multi-source data fusion. *Discover Artificial Intelligence*, *5*, 342. doi:10.1007/s44163-025-00565-6.

Yi, Y. U. N. (2006). Entropy method for determination of weight of evaluating indicators in fuzzy synthetic evaluation for water quality assessment. *Journal of Environmental sciences*, *18*(5), 1020-1023.

Yıldırım, O., Gunay, F. B., & Yağanoğlu, M. (2023). Makine öğrenmesi yöntemleriyle orman yangını tahmini. *Journal of the Institute of Science and Technology*, *13*(3), 1468-1481.

Yücesan, Z., & Yıldırım, A. D. (2021). Kızılçam (Pinus brutia Ten.)'da orijinlere bağlı morfolojik varyasyonlar. *Theoretical and Applied Forestry*, *1*(1), 17-26.

Zakeri, S., & Konstantas, D. (2022). Solving decision-making problems using a measure for information values connected to the equilibrium points (IVEP) MCDM method and Zakeri–Konstantas performance correlation coefficient. *Information*, *13*(11), 512. doi:10.3390/info13110512.

Zengin, H. (2009). Yonga levha ve lif levha endüstrisinde odun hammaddesi sağlanması sorunları ve çözüm yolları. Yüksek Lisans Tezi, *İstanbul Üniversitesi Fen Bilimleri Enstitüsü.* İstanbul.

Zhai, J., & Kuusela, O. P. (2023). An econometric study of Oregon's log and lumber markets: Estimation of price elasticities using two approaches. *Forest Policy and Economics*, *149*, 102927.

Zhang, D., & Pearse, P. H. (2026). *Forest economics* (Revised and expanded ed.). UBC Press. https://www.ubcpress.ca/forest-economics-revised-and-expanded-edition Erişim tarihi: 19/04/2026.

Zhang, X., Shen, H., Huang, T., Wu, Y., Guo, B., Liu, Z., ... & Ou, G. (2024). Improved random forest algorithms for increasing the accuracy of forest aboveground biomass estimation using Sentinel-2 imagery. *Ecological Indicators*, *159*, 111752.

Zhang, Y., Liu, J., & Shen, W. (2022). A review of ensemble learning algorithms used in remote sensing applications. *Applied Sciences*, *12*(17), 8654.

Zhu, X. J. (2005). *Semi-supervised learning literature survey* (Technical Report No. 1530). University of Wisconsin-Madison.