

ANKARA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

YÜKSEK LİSANS TEZİ

MEDİKAL SEKTÖRÜNDE MAKİNE ÖĞRENMESİ ALGORİTMALARI
İLE TALEP ÖNGÖRÜSÜ VE STOK YÖNETİMİ

Zehra DEMİRTAŞ

İSTATİSTİK ANABİLİM DALI

ANKARA
2026

Her hakkı saklıdır

ÖZET

Yüksek Lisans Tezi

MEDİKAL SEKTÖRÜNDE MAKİNE ÖĞRENMESİ ALGORİTMALARI İLE TALEP ÖNGÖRÜSÜ VE STOK YÖNETİMİ

Zehra DEMİRTAŞ

Ankara Üniversitesi
Fen Bilimleri Enstitüsü
İstatistik Anabilim Dalı

Danışman: Doç. Dr. Sibel AÇIK KEMALOĞLU

Medikal sektörde tedarik ve üretim sürekliliğinin zorunluluğu ile artan maliyet baskıları, etkin stok yönetimini kritik hale getirmiştir. Bu tez çalışmasında, medikal sektörde faaliyet gösteren bir işletmenin 9 kritik hammaddesine ilişkin 2025 yılı aylık tüketim miktarlarını Makine Öğrenmesi (ML) yöntemleriyle öngörmeyi ve bu öngörülere göre etkin stok yönetimi parametrelerini öngörmek amaçlanmıştır.

Çalışmada 2021–2024 dönemine ait satış, üretim, fire ve stok gibi operasyonel veriler kullanılmıştır. Gelecek döneme ait bağımsız değişkenlerin doğrudan gözlemlenememesi nedeniyle, iki aşamalı hibrit bir modelleme yaklaşımı benimsenmiştir. İlk aşamada, bağımsız değişkenler Mevsimsel Entegre Otoregresif Hareketli Ortalamalar Modeli (SARIMA) ve Nonlineer Otoregresif Zaman Serisi (NAR) yöntemleri ile tahmin edilmiş; bu iki yaklaşımın karşılaştırılması sonucunda, daha düşük hata değerleri ve daha tutarlı öngörüler sağladığı belirlenen NAR yöntemi tercih edilerek elde edilen tahminler ikinci aşamada girdi olarak kullanılmıştır. Bu kapsamda Gradyan Artırmalı Regresyon, Rastgele Orman Regresyonu ve Aşırı Gradyan Artırma Regresyonu modelleri kurulmuş; modellerin başarımı geriye dönük test yaklaşımı ile R^2 , $RMSE$ ve $MAPE$ ölçütleri kullanılarak değerlendirilmiştir.

Uygulama sonuçları, ML yöntemlerinin, özellikle Gradient Boosting Regresyonu'nun, hammaddelerin büyük bir kısmında yüksek açıklayıcılık ($R^2 > 0.90$) ve düşük hata oranlarıyla üstün performans sergilediğini göstermiştir. Tüketim serileri düzensiz (kesikli talep) olan hammaddelerde dahi modellerin ana tüketim eğilimini başarıyla yakaladığı tespit edilmiştir. Çalışmanın önemli pratik katkılarından biri, modelin tahmin hatası olan $RMSE$ değerinin doğrudan talep belirsizliğinin standart sapması olarak kullanılmasıdır. Bu metodolojik yaklaşımla, %95 hizmet seviyesine göre her hammadde için Güvenlik Stoğu (SS) ve Yeniden Sipariş Noktası (ROP) parametreleri bilimsel bir temelde hesaplanmıştır.

Geliştirilen ML tabanlı yaklaşım, kritik hammadde yönetiminin sezgisel değil veri temelli stratejik planlama ile yürütülebileceğini göstermekte ve benzer üretim ortamları için uygulanabilir bir çerçeve sunmaktadır.

Ocak 2026, 89 sayfa

Anahtar Kelimeler: Talep öngörüsü, Makine öğrenmesi, Stok yönetimi, Gradyan artırma regresyon, Tıbbi cihaz sektörü, Stok kontrol modelleri

ABSTRACT

Master Thesis

DEMAND FORECASTING AND INVENTORY MANAGEMENT WITH MACHINE LEARNING ALGORITHMS IN THE MEDICAL SECTOR

Zehra DEMİRTAŞ

Ankara University
Graduate School of Natural and Applied Science
Department of Statistics

Supervisor: Assoc. Prof. Dr. Sibel AÇIK KEMALOĞLU

The necessity of supply and production continuity in the medical sector, coupled with increasing cost pressures, has rendered effective inventory management critical. This thesis aims to forecast the monthly consumption quantities of nine critical raw materials for a medical enterprise in 2025 using Machine Learning (ML) methods and to determine effective inventory management parameters based on these forecasts.

The study is based on operational data from 2021 to 2024, covering sales, production, wastage, and inventory. To address the challenge of unobservable future independent variables, a two-stage hybrid modeling framework was implemented. Initially, independent variables were estimated using Seasonal Autoregressive Integrated Moving Average (SARIMA) and Nonlinear Autoregressive (NAR) models. The NAR method was ultimately chosen to provide inputs for the second stage, as it demonstrated superior performance in terms of lower error values and forecast consistency. Subsequently, Gradient Boosting Regression, Random Forest Regression, and XGBoost Regression models were constructed, with their performance validated through backtesting using R^2 , $RMSE$ and $MAPE$ metrics.

Application results demonstrate that ML methods, particularly Gradient Boosting Regression, exhibit superior performance with high explanatory power ($R^2 > 0.90$) and low error rates for most raw materials. It was observed that the models successfully captured the primary consumption trends even for raw materials with irregular (intermittent) demand patterns. A significant practical contribution of this study is the utilization of the model's prediction error ($RMSE$) directly as the standard deviation of demand uncertainty. Through this methodological approach, Safety Stock (SS) and Reorder Point (ROP) parameters for each raw material were calculated on a scientific basis, targeting a 95% service level.

The developed ML-based approach demonstrates that critical raw material management can be conducted through data-driven strategic planning rather than intuition, providing a viable framework for similar production environments.

January 2026, 89 pages

Keywords: Demand forecasting, Machine learning, Stock management, Gradient boosting regression, Medical device industry, Stocks Control Models

TEŞEKKÜR

Yüksek lisans tez çalışmam süresinde desteğini esirgemeyen ve önerileri ile beni yönlendiren, katkı sağlayan değerli danışman hocam Doç. Dr. Sibel AÇIK KEMALOĞLU' na teşekkürlerimi sunarım.

Ayrıca, eğitim hayatım boyunca her zaman yanımda olan, desteğini ve anlayışını esirgemeyen aileme sonsuz teşekkür ederim.

Zehra DEMİRTAŞ
Ankara, Ocak 2026

İÇİNDEKİLER

TEZ ONAY SAYFASI

ETİK.....	i
ÖZET.....	ii
ABSTRACT	iii
TEŞEKKÜR	iv
KISALTMALAR DİZİNİ	vii
ŞEKİLLER DİZİNİ	viii
ÇİZELGELER DİZİNİ	ix
1. GİRİŞ	1
2. TALEP VE STOK YÖNETİMİ İLE İLGİLİ GENEL BİLGİLER.....	8
2.1 Talep ve Talep Öngörüsü	8
2.2 Talep Öngörüsünde İzlenen Aşamalar	8
2.3 Talep Öngörüsünde Kullanılan Yaklaşımlar	9
2.4 Stok Yönetimi	11
2.4.1 Stok çeşitleri.....	12
2.4.2 Stok yönetim sürecinin faydaları.....	12
2.4.3 Stok yönetiminde temel kavramlar	13
3. MAKİNE ÖĞRENMESİ.....	16
3.1 Denetimsiz Öğrenme.....	17
3.2 Pekiştirmeli Öğrenme	17
3.3 Denetimli Öğrenme	18
3.3.1 Gradyan Artırmalı Regresyon Algoritması (GBR)	18
3.3.2 Aşırı Gradyan Artırma Regresyon Algoritması (XGBoost)	21
3.3.3 Rastgele Orman Regresyon Algoritması (RF).....	22
3.3.4 Nonlineer Otoregresif Zaman Serisi (NAR)	24
3.4 Model Performans Ölçütleri	28
4. ZAMAN SERİSİ ANALİZİ	30
4.1 Zaman Serisi Bileşenleri	30
4.2 Zaman Serisi Modelleri	32
4.2.1 Otoregresif Model (AR).....	32
4.2.2 Hareketli Ortalama Modeli (MA).....	33
4.2.3 Otoregresif Hareketli Ortalamalar Modeli (ARMA)	34
4.2.4 Entegre Otoregresif Hareketli Ortalamalar Modeli (ARIMA)	34

4.2.5 Mevsimsel Entegre Otoregresif Hareketli Ortalamalar Modeli(SARIM).....	35
4.3 Durağanlık Analizi ve Birim Kök Testleri.....	36
4.3.1 Durağanlık kavramı ve önemi	36
4.3.2 Birim kök yaklaşımı.....	37
4.3.3 Dickey–Fuller (DF) ve Genişletilmiş Dickey–Fuller (ADF) testleri.....	37
5. UYGULAMA.....	39
5.1 Veri Toplama Süreci ve Veri Setinin Yapısı.....	40
5.1.1 Veri toplama süreci.....	40
5.1.2 Veri setinin yapısı.....	41
5.2 Veri Ön İşleme.....	41
5.3 Modelleme Yaklaşımı ve Eğitim Stratejisi.....	42
5.4 Modelleme Sonuçları ve Değerlendirme	45
5.5 2025 Yılı Talep Öngörü Sonuçları.....	47
5.5.1 SARIMA analizi uygulaması.....	48
5.5.2 Nonlineer Otoregresif Zaman Serisi analizi uygulaması.....	53
5.6 Öngörü Sonuçlarının Stok Yönetimine Uygulanması	63
6. SONUÇ.....	66
KAYNAKLAR	70
EKLER.....	75
EK 1 SARIMA ANALİZİ UYGULAMASI.....	76
EK 2 STOK YÖNETİMİ HESAPLAMALARI	86
ÖZGEÇMİŞ.....	89

KISALTMALAR DİZİNİ

ML	: Machine Learning (Makine Öğrenmesi)
ANN	: Artificial Neural Network (Yapay Sinir Ağları)
RF	: Random Forest Regression (Rastgele Orman Regresyonu)
KNN	: K-Nearest Neighbor (K-En Yakın Komşu)
SVR	: Support Vector Regression (Destek Vektör Regresyon)
RMSE	: Root Mean Square Error (Kök Ortalama Hata Kare)
R^2	: Coefficient of Determination (Belirlilik Katsayısı)
MAE	: Mean Absolute Error (Ortalama Mutlak Hata)
MAPE	: Mean Absolute Percentage Error (Ortalama Mutlak Yüzde Hatası)
XGBoost	: Extreme Gradient Boosting Regression (Aşırı Gradyan Artırma Regresyonu)
CatBoost	: Categorical Boosting (Kategorik Artırma)
LightGBM	: Light Gradient Boosting Machine (Hafif Gradyan Artırma Makinesi)
MSE	: Mean Square Error (Ortalama Karesel Hata)
GBR	: Gradient Boosting Regressor (Gradyan Artırmalı Regresyon)
AI	: Artificial Intelligence (Yapay Zekâ)
SVM	: Support Vector Machine (Destek Vektör Makine)
SS	: Safety Stock (Güvenlik Stoğu)
ROP	: Reorder Point (Yeniden Sipariş Noktası)
ARIMA	: Autoregressive Integrated Moving Average (Entegre Otoregresif Hareketli Ortalama Modeli)
EOQ	: Economic Order Quantity (Ekonomik Sipariş Miktarı)
NAR	: Nonlinear Autoregressive Time Series (Nonlinear Otoregresif Zaman Serisi)
NARX	: Nonlinear Autoregressive Model with Exogenous Inputs (Dışsal Girdili Doğrusal Olmayan Otoregresif Model)
AR	: Autoregressive (Otoregresif Model)
MA	: Moving Average (Hareketli Ortalama Model)
ARMA	: Autoregressive Moving Average (Otoregresif Hareketli Ortalamalar Model)
SARIMA	: Seasonal Autoregressive Integrated Moving Average (Mevsimsel Entegre Otoregresif Hareketli Ortalamalar Model)
DF	: Dickey–Fuller
ADF	: Augmented Dickey–Fuller (Genişletilmiş Dickey–Fuller)
Kg	: Kilogram
AIC	: Akaike Information Criterion (Akaike Bilgi Kriteri)

ŞEKİLLER DİZİNİ

Şekil 2.1 Stok yönetimi süreci	11
Şekil 5.1 Elastromer hammaddesi için 2025 yılı gerçekleşen ve öngörülen tüketim karşılaştırması.....	59
Şekil 5.2 Acetal hammaddesi için 2025 yılı gerçekleşen ve öngörülen tüketim karşılaştırması	59
Şekil 5.3 PC hammaddesi için 2025 yılı gerçekleşen ve öngörülen tüketim karşılaştırması	60
Şekil 5.4 ABS 3864 hammaddesi için 2025 yılı gerçekle eşen ve öngörülen tüketim karşılaştırması	60
Şekil 5.5 PC ABS-IMS hammaddesi için 2025 yılı gerçekleşen ve öngörülen tüketim karşılaştırması	61
Şekil 5.6 PC ABS hammaddesi için 2025 yılı gerçekleşen ve öngörülen tüketim karşılaştırması	61
Şekil 5.7 PC Violet hammaddesi için 2025 yılı gerçekleşen ve öngörülen tüketim karşılaştırması	62
Şekil 5.8 Moblen hammaddesi için 2025 yılı gerçekleşen ve öngörülen tüketim karşılaştırması	62
Şekil 5.9 PA66 GFR30 hammaddesi için 2025 yılı gerçekleşen ve öngörülen tüketim karşılaştırması.....	63

ÇİZELGELER DİZİNİ

Çizelge 3.1 ML yöntemleri için hiperparametre değerleri.....	27
Çizelge 5.1 Modelde kullanılan bağımlı ve bağımsız değişkenler	41
Çizelge 5.2 ML modellerine ait hiperparametre ayarları	45
Çizelge 5.3 Hammadde bazında makine öğrenmesi modellerinin karşılaştırmalı performans analizi	46
Çizelge 5.4 Hammadde bazında nihai olarak seçilen makine öğrenmesi modelleri.....	46
Çizelge 5.5 Bağımsız değişkenlere ait Genişletilmiş Dickey–Fuller (ADF) testi sonuçları (orijinal seri)	50
Çizelge 5.6 Elastomer bağımsız değişkenleri için seçilen sarıma modelleri ve hata metrikleri	51
Çizelge 5.7 Hammaddelere ait bağımsız değişkenler için seçilen sarıma modelleri	52
Çizelge 5.8 Elastomer hammaddesi için NAR ve SARIMA modellerinin öngörü performans metriklerinin karşılaştırılması	55
Çizelge 5.9 Acetal hammaddesi için NAR ve SARIMA modellerinin öngörü performans metriklerinin karşılaştırılması.....	56
Çizelge 5.10 PC hammaddesi için NAR ve SARIMA modellerinin öngörü performans metriklerinin karşılaştırılması.....	56
Çizelge 5.11 ABS 3864 hammaddesi için NAR ve SARIMA modellerinin öngörü performans metriklerinin karşılaştırılması	56
Çizelge 5.12 PC ABS-IMS hammaddesi için NAR ve SARIMA modellerinin öngörü performans metriklerinin karşılaştırılması	56
Çizelge 5.13 PC ABS hammaddesi için NAR ve SARIMA modellerinin öngörü performans metriklerinin karşılaştırılması	57
Çizelge 5.14 PC Violet hammaddesi için NAR ve SARIMA modellerinin öngörü performans metriklerinin karşılaştırılması	57
Çizelge 5.15 Moblen hammaddesi için NAR ve SARIMA modellerinin öngörü performans metriklerinin karşılaştırılması	57
Çizelge 5.16 PA66 GFR30 hammaddesi için NAR ve SARIMA modellerinin öngörü performans metriklerinin karşılaştırılması	57
Çizelge 5.17 Hammadde bazında seçilen model ile 2025 yılı aylık öngörülen tüketim miktarları (kg)	58
Çizelge 5.18 2025 yılı yıllık talep değerleri ile öngörülen stok yönetimi parametre değerleri (kg)	65

1. GİRİŞ

Talep, tüketicilerin belirli bir mal veya hizmeti satın alma isteği ile bu isteği karşılayabilecek ekonomik gücünün birleşimi olarak tanımlanmaktadır. Bir ürünün veya hizmetin gelecekteki talep düzeyini belirlemek için talep öngörülerinden yararlanılmakta, bu öngörüler sayesinde üretim miktarı planlanmakta, stok bulundurma gerekliliği değerlendirilmekte ve işletmenin piyasadaki konumu hakkında çıkarımlar yapılabilmektedir. Talep kavramı, işletmelerin gelecekteki üretim ve stok planlamalarında kritik bir rol oynamakta olup, literatürde bu konu işletmelerin stratejik karar süreçlerinin temel bir unsuru olarak değerlendirilmektedir (Bolt, 1994; Hyndman ve Koehler, 2006).

Talep öngörüsü, yalnızca üretim miktarını belirlemekle sınırlı kalmamakta; aynı zamanda üretim planlaması, stok yönetimi ve kaynak tahsisini doğrudan etkileyerek işletmelerin operasyonel süreçlerinde kritik bir rol üstlenmektedir. Doğru öngörüler sayesinde işletmeler, operasyonlarını optimize edebilmekte, maliyetlerini düşürebilmekte ve müşteri memnuniyetini artırabilmektedir. Stok yönetimi ise talep öngörüsünün en önemli tamamlayıcı unsurlarından biridir. Doğru tahminler, stok fazlalığından kaynaklanan depolama maliyetlerini azaltırken, stok yetersizliği sonucu oluşabilecek müşteri kayıplarını da önlemektedir. Bu bağlamda etkin stok yönetimi yalnızca operasyonel verimlilik sağlamakla kalmayıp, aynı zamanda işletmelerin finansal sürdürülebilirliğini ve rekabet gücünü artırmaktadır.

Talep öngörüsü ile stok yönetiminin bütünleşik bir yaklaşımla ele alınması, günümüzün dinamik pazar koşullarında işletmeler için stratejik bir zorunluluk haline gelmiştir. Rekabetin yoğun olduğu günümüz piyasasında, doğru talep öngörülerini yapan işletmeler rakiplerine kıyasla önemli bir avantaj elde etmekte ve sürdürülebilir büyüme için daha sağlam bir temel oluşturmaktadır.

Geleneksel olarak talep öngörülerini, karmaşık yapıları çözmek ve dinamik piyasa eğilimlerini yakalamak amacıyla istatistiksel yöntemlere ve alanında uzman kişilerin deneyimlerine dayanmaktadır. Ancak ML yöntemlerinin yaygınlaşmasıyla, geleneksel

tahmin yaklaşımlarının (regresyon, zaman serisi vb.) ötesine geçilerek, veri içindeki doğrusal olmayan örüntüler ve karmaşık etkileşimler daha etkin biçimde modellenebilir hâle gelmiştir.

Literatür incelendiğinde, ML tabanlı yöntemlerin tedarik zinciri ve üretim planlamasında geleneksel yöntemlere kıyasla üstünlüğünü ortaya koyan kapsamlı çalışmalar mevcuttur.

Kochak ve Sharma (2015), talep tahmininin tedarik zinciri yönetimindeki kritik rolüne dikkat çektikleri çalışmalarında, Yapay Sinir Ağlarının (Artificial Neural Networks-ANN) bu alandaki kullanımını araştırmışlardır. Yazarlar, geleneksel zaman serisi ve regresyon modellerinin doğrusal varsayımlara dayanmaları nedeniyle karmaşık ve doğrusal olmayan ilişkileri açıklamakta yetersiz kaldığını belirtmiş; ANN yaklaşımının ise bu kısıtları aşarak daha düşük hata oranlarıyla başarılı sonuçlar sunduğunu vurgulamışlardır. Bir üretici firmanın 2011-2013 yılları arasındaki aylık satış verileriyle 2014 yılı talep tahmininin yapıldığı çalışmada, model eğitimi MATLAB ortamında Levenberg-Marquardt algoritması kullanılarak gerçekleştirilmiştir. Analiz sonuçları, ANN modelinin yüksek tahmin doğruluğu sağladığını ortaya koymuştur. Sonuç olarak çalışma, ANN'in değişken piyasa koşullarında güvenilir tahminler ürettiğini ve özellikle üretim ile stok planlamasında etkin bir karar destek aracı olarak kullanılabileceğini göstermiştir.

Jadhav vd. (2022) tarafından gerçekleştirilen çalışmada; otomotiv sektöründe üretim planlamasının etkinliğini artırmak amacıyla, hammadde talebinin öngörülmesinde ML algoritmaları kullanılmıştır. Araştırmada, çelik, plastik, alüminyum, kauçuk ve bakır gibi hammaddelerin geçmiş yıllardaki kullanım miktarları temel alınarak, gelecekteki ihtiyaçların tahmini hedeflenmiştir. Modelleme sürecinde, Doğrusal Regresyon (Linear Regression), Çoklu Çıktı Regresyonu (Multi-output Regression), Rastgele Orman Regresyonu (Random Forest Regression-RF) ve K-En Yakın Komşu (K-Nearest Neighbor-KNN) algoritmaları uygulanmış ve modellerin performansı Kök Ortalama Hata Kare (Root Mean Square Error- $RMSE$) ve Belirlilik Katsayısı (Coefficient of Determination- R^2) ölçütleri ile değerlendirilmiştir. Elde edilen bulgulara göre, RF algoritması en yüksek doğruluk ve en düşük hata oranıyla en başarılı yöntem olarak

belirlenmiştir. Çalışmada, geleneksel yöntemlere kıyasla ML tabanlı yaklaşımların daha esnek ve isabetli sonuçlar sunduğu vurgulanmıştır. Bu sayede üreticilerin, üretim planlamasını daha etkin yapabilecekleri, hammadde tedarik süreçlerini iyileştirebilecekleri ve stok maliyetlerini azaltabilecekleri sonucuna varılmıştır.

Akbaş (2022), tedarik zinciri yönetiminde talep öngörüsünün doğruluğunu artırmak amacıyla yapay zekâ tabanlı yöntemlerin uygulanabilirliğini araştırmıştır. Bir tekstil firmasının tarihsel satış verileri üzerinden yürütülen çalışmada, gelecekteki talep düzeylerinin öngörülmesi hedeflenmiştir. Modelleme sürecinde farklı ML algoritmaları uygulanmış; ANN, Destek Vektör Regresyonu (Support Vector Regression -SVR) ve Ağaç Tabanlı Yöntemler karşılaştırılmıştır. Modellerin performansları Ortalama Mutlak Hata (Mean Absolute Error-MAE), *RMSE* ve Ortalama Mutlak Yüzde Hatası (Mean Absolute Percentage Error-MAPE) ölçütleri ile değerlendirilmiştir. Elde edilen bulgular, yapay zekâ tabanlı yaklaşımların geleneksel tahmin yöntemlerine kıyasla daha düşük hata oranları ile daha güvenilir öngörüler sunduğunu göstermiştir. Özellikle ANN algoritmasının farklı ürün gruplarında istikrarlı performans sergilediği; SVR ve Ağaç Tabanlı Yöntemlerin ise kısa vadeli tahminlerde güçlü sonuçlar ortaya koyduğu belirlenmiştir. Çalışmada ayrıca, bu tür ML temelli yöntemlerin tekstil sektöründe stok maliyetlerini azaltma, müşteri şikâyetlerini en aza indirme ve üretim planlamasını iyileştirme açısından önemli katkılar sağladığı vurgulanmıştır.

Sarı vd. (2023), madeni eşya imalat sektöründe faaliyet gösteren bir firmanın ürün grubuna ait geçmiş satış verilerini kullanarak talep tahmini gerçekleştirmiştir. Çalışmada, geleneksel zaman serisi yöntemleri olan Basit Üstel Düzeltme ve Holt-Winters Eklemeli Mevsimsel modeller kullanılmış, ardından bu yöntemlerle elde edilen tahminler ANN modellerine entegre edilerek hibrit yapılar oluşturulmuştur. Toplamda 48 hibrit ANN modeli oluşturulmuş ve en düşük hata oranına sahip model Holt-Winters tabanlı hibrit ANN modeli olmuştur. Çalışma hem geleneksel yöntemlerle hem de ANN yaklaşımıyla yapılan tahminlerin doğruluğunu karşılaştırmalı olarak ortaya koymuş, özellikle hibrit modellerin daha düşük hata oranları sağladığı vurgulanmıştır.

Bayar Serbest (2024), Bursa’da faaliyet gösteren bir tekstil firmasının 2021-2022 yılları arasındaki polyester iplik satış verileri kullanılarak ML algoritmaları ile talep öngörüsü gerçekleştirmiştir. Araştırmada, Karar Ağaçları (Decision Trees), RF, Aşırı Gradyan Artırma Regresyonu (Extreme Gradient Boosting Regression-XGBoost), Kategorik Artırma (Categorical Boosting-CatBoost), Hafif Gradyan Artırma Makinesi (Light Gradient Boosting Machine-LightGBM), Doğrusal Regresyon (Linear Regression) ve Ekstra Ağaçlar Regresyonu (Extra Trees Regressor) gibi çeşitli algoritmalar kullanılmıştır. Model performansları; *MAE*, Ortalama Karesel Hata (Mean Square Error-*MSE*), *RMSE* ve R^2 gibi istatistiksel metrikler yardımıyla değerlendirilmiştir. Hiperparametre optimizasyonu için GridSearch yöntemi uygulanmış, modellerin doğruluğu ise k-katlı çapraz doğrulama yöntemi ile test edilmiştir. Elde edilen bulgular, CatBoost algoritmasının en yüksek tahmin doğruluğunu sağladığını ve bu sayede stok maliyetlerini azaltarak operasyonel verimliliği artırdığını ortaya koymuştur. Çalışma, ML yöntemlerinin tekstil sektöründeki talep öngörüsü süreçlerini daha hassas ve etkin hale getirerek işletmelerin rekabet gücünü artırma potansiyeline sahip olduğunu ortaya koymaktadır.

Sistla vd. (2024) çalışmasında, üretim sektöründe talep öngörüsünde ML yöntemlerinin uygulanabilirliğini incelemiştir. Çalışmada, geleneksel zaman serisi ve regresyon temelli yöntemlerin doğrusal varsayımlar nedeniyle karmaşık ve doğrusal olmayan talep yapılarında sınırlı kaldığı vurgulanmış; bu sınırlamaların aşılması amacıyla, ANN (RNN, LSTM, CNN), RF, Gradyan Artırmalı Regresyon (Gradient Boosting Regressor-GBR) gibi ML ve derin öğrenme algoritmaları değerlendirilmiştir. Uygulamada, otomotiv, elektronik, ilaç ve hızlı tüketim malları sektörlerinden alınan örnekler üzerinden vaka çalışmaları sunulmuş; model performansları *MAE*, *RMSE* ve *MAPE* gibi hata metrikleri ile analiz edilmiştir. Bulgular, ML temelli yöntemlerin geleneksel yaklaşımlara kıyasla tahmin hatalarını %30’a kadar azaltabildiğini, stok maliyetlerini düşürdüğünü ve müşteri hizmet seviyelerini artırdığını göstermiştir. Bununla birlikte, veri kalitesi, model yorumlanabilirliği, yüksek hesaplama gereksinimleri ve aşırı öğrenme riskleri uygulamadaki temel zorluklar olarak belirlenmiştir. Çalışma, ML yöntemlerinin üretim sektöründe talep tahminini geliştirerek işletmelere rekabet avantajı sağlayabileceğini ve

gelecekte hibrit modeller ile açıklanabilir yapay zekâ yaklaşımlarının önem kazanacağına dikkat çekmiştir.

Abbasi vd. (2024), Pakistan'daki ventilatör dağıtım firmalarının stok yönetimi ve talep tahminine yönelik sorunlarını çözmek amacıyla ANN tabanlı bir model geliştirmiştir. 2019–2024 dönemine ait veriler kullanılarak oluşturulan yapay sinir ağı modeli, satış tahminlerinde yaklaşık %90 doğruluk başarısı göstermiştir. Çalışmada, kredili satışlar ile satış hacmi arasında pozitif, iade oranları ile ise negatif korelasyon tespit edilmiştir. Elde edilen sonuçlar, ANN'in doğrusal olmayan karmaşık ilişkileri başarıyla modelleyebildiğini ve tıbbi cihaz lojistiğinde etkin bir araç olarak kullanılabileceğini ortaya koymuştur.

Turgay (2025), talep öngörüsünün tedarik zinciri yönetimindeki kritik rolüne odaklandığı çalışmada, tahmin doğruluğunu artırmak adına yapay zekâ tabanlı yöntemlerin uygulanabilirliğini araştırmıştır. Yazar, geleneksel zaman serisi ve regresyon yöntemlerinin doğrusal varsayımlara dayanması nedeniyle karmaşık ve doğrusal olmayan ilişki yapılarında yetersiz kaldığını belirtmiştir. Bu kısıtları aşmak amacıyla çalışmada; SVR, ANN, Karar Ağaçları, RF, XGBoost ve LSTM gibi ML algoritmaları kullanılmıştır. Perakende sektörüne ait tarihsel satış verileriyle oluşturulan modellerin performansları *RMSE*, *MAE* ve *MAPE* hata metrikleri üzerinden değerlendirilmiştir. Elde edilen bulgular, özellikle LSTM ve XGBoost algoritmalarının kısa vadeli tahminlerde yüksek doğruluk sağladığını; RF modelinin ise farklı ürün gruplarında istikrarlı performans sergilediğini göstermiştir. Çalışma, ML temelli tahminleme yöntemlerinin değişken talep yapılarında güvenilir öngörüler sunarak üretim ve stok planlamasında etkili bir karar destek aracı olarak kullanılabileceğini ortaya koymuştur.

Kagalwala vd. (2025) tarafından yapılan çalışmada; tedarik zinciri yönetiminde talep öngörüsünün kritik rolü vurgulanmış, bu süreci geliştirmek amacıyla Yapay Zekâ (Artificial Intelligence-AI) ve ML tabanlı tahmine dayalı analitiklerin kullanımı araştırılmıştır. Geleneksel tahmin yöntemlerinin hızlı değişen pazar koşullarını ve dışsal belirsizlikleri yakalamakta yetersiz kaldığı ifade edilmiş; Derin Öğrenme (LSTM, RNN), Destek Vektör Makineleri (Support Vector Machines-SVM) ve RF gibi algoritmaların bu

sınırlamaları aşarak daha düşük hata oranlarıyla daha güvenilir tahminler sağladığı belirtilmiştir. Çalışmada, çeşitli sektörlerle ait literatür ve uygulama örnekleri sistematik olarak incelenmiş; yapay zekâ tabanlı tahmin yöntemlerinin stok tükenmesi ve fazla stok riskini azalttığı, işletmelere talep dalgalanmalarına %30–40 daha hızlı tepki verme olanağı sunduğu ve operasyonel maliyetleri %10–15 oranında düşürdüğü vurgulanmıştır. Araştırma, veri kalitesi, yüksek başlangıç yatırım maliyetleri ve etik sorunların uygulamadaki başlıca sınırlılıklar olduğunu ortaya koyarken, hibrit modeller, blockchain tabanlı veri güvenliği ve açıklanabilir AI gibi yeni yaklaşımların bu alanda önemli fırsatlar sunacağını ifade etmiştir. Çalışma, AI ve ML tabanlı talep tahminlerinin işletmeler için yalnızca bir rekabet avantajı değil, aynı zamanda sürdürülebilir tedarik zinciri yönetimi için bir gereklilik olduğunu göstermektedir.

Literatür taraması, ML temelli talep öngörüsü çalışmalarının farklı sektörlerde yaygın olarak uygulandığını ve bu yöntemlerin geleneksel istatistiksel modellere kıyasla daha yüksek tahmin doğruluğu sunduğunu ortaya koymaktadır. Bununla birlikte, mevcut araştırmaların büyük bir bölümü nihai ürün talebine odaklanmış durumdadır. Tıbbi cihaz üretiminde kullanılan hammaddelerin tüketim dinamiklerini bütüncül bir yaklaşımla ele alan çalışmalar ise literatürde oldukça sınırlıdır. Bu eksiklikten hareketle bu tez çalışmasında; üretim fire adetleri, yurtiçi ve yurtdışı satış adetleri, stok seviyeleri ve dönemsel tüketim örüntüleri gibi sektöre özgü operasyonel değişkenlerin hammadde tüketimi üzerindeki etkilerinin analiz edilmesi hedeflenmektedir.

Çalışmanın temel amacı, tıbbi cihaz üreten bir işletmenin operasyonel değişkenleri dikkate alınarak, bir sonraki yılda tüketilecek hammadde miktarını yüksek doğrulukla öngörmektir. Böylece işletmenin yıl sonunda stoklarında bulundurması gereken optimal hammadde miktarının belirlenmesi ve stok yönetiminin etkinleştirilmesi amaçlanmıştır. Modelleme sürecinde, “Hammadde Tüketim Miktarı” bağımlı değişken olarak ele alınırken; “Yurtdışı Satış Adedi”, “Yurtiçi Satış Adedi”, “Fire Adedi”, “Aylık Stokta Kalan” ve “Üretim Adedi” ise bağımsız değişkenler olarak modele dahil edilmiştir. Analizlerde 2021–2024 yılları arasına ait aylık hammadde tüketim verileri kullanılarak farklı ML modelleri denenmiştir. Veri setinin %75’ini oluşturan 2021–2023 dönemi eğitim verisi, geri kalan %25’ini oluşturan 2024 yılı ise test verisi olarak ayrılmıştır.

Böylece modellerin geleceği tahmin etme performansı, geçmiş gerçek değerler üzerinden değerlendirilmiştir. Analiz sürecinde veri temizleme, zaman serisi özelliklerinin oluşturulması, model eğitimi ve performans değerlendirme adımları sistematik bir biçimde uygulanmıştır.

Uygulama aşamasında; veri setindeki doğrusal olmayan karmaşık ilişkileri ve zaman serisi örüntülerini modellemedeki yüksek başarıları nedeniyle, topluluk öğrenmesi (ensemble learning) temelli üç gelişmiş yöntem olan GBR, RF ve XGBoost tercih edilmiştir. 2025 yılı için öngörüler, özyinelemeli (recursive) tahmin yaklaşımı kullanılarak gerçekleştirilmiştir. Bu yöntemde bir ay için üretilen öngörü değeri, bir sonraki ayın giriş özelliklerini oluşturmak için kullanılmış ve böylece 12 aylık ileriye dönük öngörü süreci adım adım tamamlanmıştır.

Modellerin başarısı R^2 , $RMSE$ ve $MAPE$ gibi performans ölçütleriyle değerlendirilmiş; her bir hammadde için en yüksek tahmin doğruluğunu sağlayan model, 2025 yılı nihai tüketim öngörülerinde esas alınmıştır.

Çalışmanın kapsamı salt talep öngörüsü ile sınırlı tutulmamış, elde edilen ML çıktılarının stok yönetimi süreçlerine entegrasyonu da sağlanmıştır. Bu bağlamda, medikal sektörün kritik tedarik gereksinimleri dikkate alınarak %95 hizmet seviyesi ve 15 günlük sabit tedarik süresi varsayımları altında; modellerin test aşamasındaki $RMSE$ değerleri talep belirsizliği olarak kullanılmış ve her hammadde için Güvenlik Stoğu (Safety Stock-SS) ile Yeniden Sipariş Noktası (Reorder Point-ROP) seviyeleri hesaplanmıştır. Böylece işletme, stok politikalarını geçmiş dönem ortalamaları yerine model destekli ve risk odaklı bir yapıya kavuşturmuştur. Bu yapıyla tez çalışması hem ilgili literatürdeki boşluğu doldurmayı hem de tıbbi cihaz sektöründeki stok yönetimi uygulamalarına yönelik veriye dayalı, güvenilir ve uygulanabilir katkılar sunmayı hedeflemektedir.

Tüm analiz ve modellemeler Python (3.13.7) ile Spyder IDE üzerinde gerçekleştirilmiştir.

2. TALEP VE STOK YÖNETİMİ İLE İLGİLİ GENEL BİLGİLER

2.1 Talep ve Talep Öngörüsü

Son yıllarda tıbbi cihazlar, tıpta yenilikçi uygulamaların hayata geçirilmesinde ve hasta bakım kalitesinin artırılmasında kritik bir rol üstlenmektedir. Tanı koyma, hastalıkların önlenmesi, izlenmesi ve tedavisi süreçlerinde kullanılan cihaz, ekipman ve malzemeleri kapsayan geniş bir ürün yelpazesine sahiptir. Bu yönüyle tıbbi cihaz sektörü, sağlık hizmetlerinin sürdürülebilirliğinde ve etkinliğinde stratejik bir konumda yer almaktadır (Amaral vd. 2024). Bu stratejik rol, tıbbi cihaz üreticilerinin yalnızca yüksek kaliteli ürünler geliştirmesini değil, aynı zamanda müşteri ihtiyaçlarını zamanında karşılayabilmek için doğru ve güvenilir talep öngörülleri yapmalarını da zorunlu kılmaktadır. Pazar talebine hızlı yanıt verebilen üretici firmalar, bir yandan hasta sağlığının korunmasına katkı sağlarken diğer yandan sektörde sürdürülebilir bir rekabet avantajı elde etmektedir.

Talep öngörüsü, işletmelerin kısa ve uzun vadeli hedeflerine ulaşabilmesi için stratejik karar süreçlerinde başvurdukları temel araçlardan biridir (Bolt, 1994). Gelecekteki talebi belirlemek için geçmiş veriler, uzman görüşleri ve deneyimlerden yararlanılır; bu süreçte bilimsel ve ölçülebilir teknikler kullanılır (Akbaş, 2022). Ancak talep öngörülleri çalışmalarında kullanılan yöntemlerin sonuçları her zaman sınırlı bir doğruluk oranına sahiptir. Bu durumun altını çizen Adıyaman (2007), hiçbir tahminin %100 kesinlik taşımadığını ifade etmektedir. Tahminlerin geçerliliği hem kullanılan modelin özelliklerine hem de bu modelden elde edilen verilerin doğruluğuna bağlı olarak değişmektedir.

2.2 Talep Öngörüsünde İzlenen Aşamalar

Etkin bir talep öngörü süreci genellikle aşağıdaki adımları izlemektedir:

- **Talebi Etkileyen Unsurların Analizi:** Talep öngörüsüne başlamadan önce işletmenin stratejik hedefleri, ürünün özellikleri, rakip firmaların piyasadaki durumu, genel

ekonomik koşullar ve teknolojik gelişmeler değerlendirilmelidir. Bu faktörlerin her birinin talep üzerinde farklı bir ağırlığı bulunmaktadır ve analiz edilmesi gerekmektedir (Bolt, 1994).

- **Veri Toplama:** Öngörüyü etkileyecek unsurlar belirlendikten sonra, bunlara ilişkin veriler sistematik biçimde toplanmalıdır. Kullanılacak veriler geçmiş satış kayıtları, stok hareketleri, istatistiksel raporlar gibi göstergelerden elde edilebilir. Verilerin güvenilirliği ve kapsamı, yapılan tahminin kalitesini doğrudan belirlemektedir (Bolt, 1994; Pilinkienė, 2008).
- **Öngörü Döneminin Belirlenmesi:** Talep öngörü sürecinde dönem kritik bir adımdır. Geleneksel olarak tahmin zaman aralığı kısa (1–3 ay), orta (3 ay–2 yıl) ve uzun dönem (iki yıldan fazla) olarak sınıflandırılmaktadır. Kısa ve orta vadeli tahminlerde basit nicel yöntemler, örneğin basit hareketli ortalama ve üssel düzeltme uygulanırken; uzun vadeli öngörülerde regresyon ve ekonometrik modellerin kullanılması daha uygun görülmektedir (Pilinkienė, 2008).
- **Öngörü Yönteminin Seçilmesi ve Hata Ölçümü:** Talep öngörü yöntemleri genel olarak nitel ve nicel olmak üzere ikiye ayrılmaktadır. Nicel yöntemler istatistiksel ve matematiksel verilere dayanırken, nitel yöntemler daha çok uzman görüşleri ve deneyimlere dayalıdır. Literatürde en güvenilir yaklaşımın bu iki yöntemin birlikte kullanılması olduğu belirtilmektedir (Bolt, 1994; Pilinkienė, 2008; Hyndman ve Koehler, 2006).
- **Sonuçların Geçerliliğinin Değerlendirilmesi:** Yapılan tahmin sonuçları, gerçekleşen değerlerle karşılaştırılarak doğruluk seviyesi incelenmeli ve sapmaların nedenleri araştırılmalıdır.

Bu çalışmada, tıbbi cihaz sektöründeki hammadde talebine ilişkin tahminler yapılırken yukarıda belirtilen aşamalar izlenecek ve yöntem seçimi bu kriterlere göre değerlendirilecektir.

2.3 Talep Öngörüsünde Kullanılan Yaklaşımlar

Talep tahmin yöntemleri literatürde genellikle nitel ve nicel olmak üzere iki ana grupta sınıflandırılmaktadır. Nitel yöntemler, daha çok uzman görüşleri ve deneyimlere dayalı

oldukları için sübjektif özellik taşıırken; nicel yöntemler geçmiş dönem verilerini kullanarak matematiksel ve istatistiksel modeller aracılığıyla geleceğe yönelik öngörüler yapılmasına olanak sağlamaktadır (Kocadağ ve Şahin, 2020).

Nitel yöntemler, geçmiş verilerin yetersiz olduğu ya da hiç bulunmadığı durumlarda öne çıkan tahmin yaklaşımlarıdır. Bu yöntemlerde geleceğe yönelik öngörüler, uzmanların bilgi ve deneyimlerinden veya tüketici eğilimlerini yansıtan pazar araştırmaları ve anketlerden elde edilen verilerden yararlanılarak yapılmaktadır. Özellikle yeni ürünlerin pazara sunulması gibi belirsizliğin yüksek olduğu senaryolarda nitel yöntemler işletmelere yol gösterici bir araç olarak kullanılmaktadır (Pehlivanoğlu, 2023).

Veriye dayalı bir yaklaşıma sahip olan nicel yöntemler, geçmiş dönem kayıtlarının istatistiksel olarak değerlendirilmesiyle geleceğe dair tahminler geliştirmeyi amaçlar. Sayısal verilere dayalı olduklarından, sübjektif etkilerden uzak ve daha nesnel çıktılar sunmaktadırlar.

Literatürde yaygın olarak kullanılan nicel yöntemler arasında zaman serisi modelleri (Hareketli Ortalamalar, Üstel Düzeltme Yöntemleri, Entegre Otoregresif Hareketli Ortalamalar Modeli (Autoregressive Integrated Moving Average-ARIMA), nedensel modeller (Regresyon Analizleri, Ekonometrik Yaklaşımlar) ve son yıllarda giderek önem kazanan AI ve ML tabanlı algoritmalar yer almaktadır (Sarı, 2016). Bu yöntemler, özellikle büyük ölçekli ve karmaşık veri setlerinin analiz edilmesinde işletmelere önemli avantajlar sağlamaktadır.

Son yıllarda yapılan çalışmalar, klasik istatistiksel yöntemlerin doğrusal varsayımlar nedeniyle karmaşık ve doğrusal olmayan veri yapılarında yetersiz kalabildiğini göstermektedir. Bu sınırlamaların üstesinden gelmek amacıyla, SVR, ANN, RF ve XGBoost gibi ML algoritmaları talep tahmininde yaygın olarak kullanılmaya başlanmıştır (Jadhav vd. 2022; Turgay, 2025). Yapılan uygulamalarda, bu algoritmaların klasik yöntemlere kıyasla daha yüksek doğruluk oranı sunduğu ve özellikle kısa vadeli tahminlerde başarılı sonuçlar verdiği görülmektedir.

Bu araştırmanın uygulama bölümünde yalnızca nicel yöntemlerden yararlanılmış, talep tahminleri istatistiksel ve matematiksel modeller ile desteklenmiştir.

2.4 Stok Yönetimi

İşletmelerde stok, üretim ve hizmet süreçlerinde kullanılan tüm kaynakları ifade etmektedir (Li, 2007). Stok yönetimi, yalnızca üretimin sürekliliğini sağlamakla kalmaz; aynı zamanda müşteri hizmet düzeyini ve nakit akışını da doğrudan etkileyen stratejik bir unsurdur (Mesjasz-Lech, 2011; Plinere vd. 2015; Kourentzes vd. 2020). Yetersiz stok seviyeleri üretim aksamalarına ve müşteri kayıplarına yol açarken, fazla stok ise depolama maliyetlerinin artmasına neden olmaktadır. Bu nedenle güvenlik stoğu, ekonomik sipariş miktarı ve yeniden sipariş noktası gibi kavramlar stok yönetiminde kritik rol oynamaktadır. Stok yönetimi süreci genel hatlarıyla şekil 2.1’de özetlenmiştir.



Şekil 2.1 Stok yönetimi süreci

Talep öngörüsü ise stok seviyelerinin doğru belirlenmesi için temel girdi niteliğindedir ve bu bağlamda öngörülerin güvenilirliği büyük önem taşır. Ayrıca, etkin stok yönetimi yalnızca maliyetlerin azaltılmasına değil, aynı zamanda müşteri taleplerinin zamanında karşılanmasına ve işletmenin rekabet gücünün artırılmasına da katkı sağlamaktadır (Purshottam, 2024).

2.4.1 Stok çeşitleri

İşletmelerde stok yönetiminin etkin bir şekilde uygulanabilmesi için stok kalemlerinin belirli kriterlere göre sınıflandırılması gerekmektedir. Literatürde stoklar genellikle fonksiyonlarına göre aşağıdaki kategoriler altında ele alınmaktadır (Kaya, 2020; Tanrıverdi, 2010):

Hammaddeler, üretim sürecine doğrudan giren ve işlenerek değer kazanan temel girdilerdir. Hammaddeler, mamul üretiminin ilk aşamasını oluşturur.

Yarı Mamuller, üretim işlemleri tamamlanmamış olup iş istasyonlarında veya ara depolarda bekleyen ürünlerdir. Bu grupta yer alan varlıklar henüz mamul haline gelmemiştir.

Hazır Parçalar, genellikle dış tedarikçilerden sağlanan ve nihai ürünün belirli bir bölümünü oluşturan bileşenlerdir.

Yardımcı Malzemeler, mamulde doğrudan yer almayan; bakım parçaları, yapıştırıcılar, yağlayıcılar ve temizlik malzemeleri gibi üretim sürecini destekleyen unsurlardan oluşmaktadır.

Mamul Stokları, üretim süreci tamamlanmış ve satışa hazır hale getirilmiş ürünlerdir. İşletmenin pazara sunduğu nihai çıktı bu kategoride yer almaktadır.

2.4.2 Stok yönetim sürecinin faydaları

Stokların düzenli olarak izlenmesi, işletme yönetiminin en temel unsurlarından biridir. Bu nedenle etkin stok yönetimi büyük önem taşımaktadır. Yetersiz bir stok kontrolü, işletmelerde üretim duraksamalarına ve ciddi mali kayıplara yol açabileceği gibi, teslimatların gecikmesine bağlı olarak müşteri memnuniyetini de olumsuz etkileyebilir.

Literatürde, stok seviyelerinin etkin biçimde belirlenebilmesi için yalnızca klasik modellerin (örneğin Ekonomik Sipariş Miktarı) yeterli olmadığı, talep, tedarik süresi, tedarikçi güvenilirliği ve maliyet unsurlarını birlikte dikkate alan daha kapsamlı yaklaşımların kullanılması gerektiği belirtilmektedir. Bu durum, stok yönetiminde güvenilir talep tahminlerinin ve çok boyutlu değerlendirmelerin önemini ortaya koymaktadır (Ali vd. 2011).

İşletmelerin stok yönetiminde karşılaştıkları sorunları çözebilmesi ve etkin bir sistem kurabilmesi için, sürecin merkezinde yer alan kavramların ayrıntılı biçimde değerlendirilmesi gereklidir.

2.4.3 Stok yönetiminde temel kavramlar

Stok yönetiminin etkinliğini sağlayabilmek için bazı temel kavramların doğru anlaşılması gerekmektedir. Bu kavramlar, işletmelerin hangi seviyede stok bulunduracağına ve sipariş kararlarını nasıl alacağına yön vermektedir. Literatürde bu kavramların başında güvenlik stoğu, ekonomik sipariş miktarı ve yeniden sipariş noktası gelmektedir (Tanrıverdi, 2010; Ali vd. 2011).

Güvenlik Stoğu (Safety Stock-SS): SS, talep değişkenliği ve tedarik süresindeki belirsizliklere karşı elde tutulan ek stok miktarıdır. Doğru hesaplanan güvenlik stoğu, stok yetersizliği riskini azaltırken hizmet seviyesini yükseltmektedir (Tanrıverdi, 2010). Güncel literatürde, güvenlik stoğunun özellikle değişken talep yapılarında stok yönetiminin ayrılmaz bir parçası olduğu ifade edilmektedir (Ardiananta ve Basri, 2024).

SS formülü:

$$SS = Z \times \sqrt{LT} \times \sigma_d \quad (2.1)$$

biçimindedir. Burada,

- Z : Hizmet seviyesi katsayısı,
- LT : Tedarik süresi,
- σ_d : Talep standart sapması,

olarak tanımlanmaktadır (Ardiananta ve Basri, 2024).

Yeniden Sipariş Noktası (Reorder Point-ROP): Stok seviyelerinin belirli bir noktaya düştüğünde sipariş verilmesi gerekir. Bu seviye yeniden sipariş noktası olarak tanımlanır ve doğru hesaplandığında işletmelerin üretim ve satış süreçlerinin aksamadan devam etmesini sağlar (Ardiananta ve Basri, 2024).

ROP formülü:

$$ROP = d \times LT + SS \quad (2.2)$$

biçimindedir. Burada;

- LT : Tedarik süresi,
- d : Ortalama talept,

olarak tanımlanmaktadır (Ardiananta ve Basri, 2024).

Ekonomik Sipariş Miktarı (Economic Order Quantity-EOQ): Stok yönetiminde en temel kavramlardan biri EOQ olup, sipariş maliyetleri ile stok bulundurma maliyetleri arasında denge kurarak toplam maliyetleri en aza indirmeyi amaçlayan klasik bir modeldir. EOQ, işletmelerin gereğinden fazla stok maliyetine katlanmasını önlerken, aynı zamanda stok yetersizliği riskini azaltmaktadır. Bu nedenle EOQ modeli, stok kontrolünde en yaygın kullanılan yöntemlerden biri haline gelmiştir (Ardiananta ve Basri, 2024).

Klasik EOQ formülü:

$$EOQ = \sqrt{\frac{2DS}{h}} \quad (2.3)$$

biçimindedir. Burada;

- D : Yıllık talep (birim),
- S : Sipariş başına maliyet,

- h : Birim başına yıllık stok bulundurma maliyeti,

olarak tanımlanmaktadır (Ardiananta ve Basri, 2024).

Bu kavramlar işletmelerin stok yönetiminde doğru kararlar alabilmesi için temel oluşturmakta olup, çalışmanın ilerleyen bölümlerinde talep tahmini sonuçlarıyla ilişkilendirilmiştir.

3. MAKİNE ÖĞRENMESİ

Makine öğrenmesi, bilgisayarların önceden tanımlanmış kurallara bağlı kalmadan, veri içindeki örüntüleri ve ilişkileri kendiliğinden keşfetmesine imkân tanıyan bir yapay zekâ yaklaşımıdır. Bu çerçevede amaç, geçmiş gözlemlerden elde edilen bilgileri kullanarak gelecekteki olayları tahmin etmek veya verileri uygun kategorilere ayıracak karar mekanizmaları geliştirmektir. ML modelleri, girdiler ile çıktılar arasındaki ilişkiyi verinin yapısına en uygun şekilde tanımlayacak parametreleri öğrenir ve bunu yaparken istatistiksel çıkarım ile optimizasyon prensiplerinden yararlanır (Bishop, 2006).

ML sürecinin temelini, modelin eğitildiği bir veri kümesi oluşturur. Eğitim sırasında model, tahminleri ile gerçek değerler arasındaki farkı ölçen bir maliyet fonksiyonunu en aza indirmeye çalışır. Ancak öğrenmenin temel hedefi, yalnızca eğitim verisine kusursuz uyum bir yapı kurmak değildir; asıl amaç, daha önce hiç görülmemiş veriler üzerinde de kabul edilebilir doğrulukla sonuç üretebilmektir. Bu nedenle makine öğrenmesinde “genelleme yeteneği” kritik bir ölçüttür. Eğitim sürecinde modelin parametreleri güncellenirken aşırı uyum (overfitting) ve yetersiz uyum (underfitting) gibi sorunları önleyici yöntemler kullanılır. Bu denge, başarılı bir tahmin modeli oluşturmanın en önemli aşamalarından biridir.

Güncel literatürde ML yalnızca yüksek doğruluk sağlayan modeller üretme hedefiyle değil, aynı zamanda modellerin karar süreçlerini daha tutarlı, yorumlanabilir ve istatistiksel açıdan güvenilir kılan ilkeli yaklaşımlarla ele alınmaktadır. ML modellerinde belirsizliğin nicel olarak değerlendirilmesi, model karmaşıklığı ile uyum başarımının dengelenmesi ve veri gürültüsünün sistematik biçimde ele alınması uzun vadede çok daha güvenilir sonuçlar doğurmaktadır (Raykov ve Saad, 2021). Bu bakış açısı; regresyon, sınıflandırma, kümelenme, anormallik tespiti ve boyut indirgeme gibi geniş bir uygulama alanına sahip ML teknikleri için ortak bir metodolojik temel oluşturur.

Makine öğrenmesinin giderek daha fazla önem kazanmasının temel sebeplerinden biri, büyük ve karmaşık veri setleri ile çalışabilmesidir. Günümüz işletmeleri, üretimden müşteri davranışlarına kadar birçok noktada yüksek hacimli veri üretmektedir. Bu veriler

tek başına anlam ifade etmese de ML algoritmaları sayesinde bu veri kümelerinden eğilimler, ilişkiler ve geleceğe yönelik öngörüler üretmek mümkün hâle gelmektedir. Böylece ML, karar verme süreçlerinin veri temelli yürütülmesini destekleyerek işletmelere operasyonel avantaj sağlar.

Literatürde ML yöntemleri, öğrenme türlerine göre 3 ana başlık altında incelenmektedir.

3.1 Denetimsiz Öğrenme

Denetimsiz öğrenme, ML algoritmalarının, herhangi bir ön bilgi veya etiket olmaksızın, veri setlerindeki gizli kalıpları ve ilişkileri ortaya çıkarmasına odaklanır. Hedef değişkenlerin yokluğu nedeniyle, bu sistemler otomatik olarak çalışır ve kullanıcılar için güçlü bir veri keşif aracı haline gelir. Bu öğrenme paradigması genellikle verileri benzerliklerine göre gruplandıran kümeleme algoritmalarını ve veri boyutunu azaltan boyut indirgeme tekniklerini içerir. Müşteri davranışlarını gruplandırma (segmentasyon), anormal veri noktalarını belirleme (anomali tespiti) ve belgeleri organize etme gibi çeşitli alanlarda uygulanmaktadır. Bu yöntemin en büyük avantajı, maliyetli ve zaman alıcı etiketleme sürecine olan bağımlılığını ortadan kaldırmasıdır (Bojja, 2025).

3.2 Pekiştirmeli Öğrenme

Pekiştirmeli öğrenme, bir yapay zekâ modelinin çevresiyle etkileşim kurarak karar vermeyi öğrendiği bir ML yaklaşımıdır. Bu yöntemde model, her eyleminden sonra bir ödül veya ceza şeklinde geri bildirim alır. Amaç, zaman içinde toplam ödülü en yüksek seviyeye çıkaracak davranışları geliştirmektir. Ajan/model, neyin doğru olduğunu doğrudan öğrenmez; bunun yerine farklı seçenekleri deneyerek en iyi stratejiyi kendi başına keşfeder.

3.3 Denetimli Öğrenme

Denetimli öğrenme, tahmin edici modeller oluşturmak için etiketli veri kümelerinden yararlanan bir makine öğrenme tekniğidir. Bu süreçte, algoritma girdi verilerini ve bunlara karşılık gelen bilinen çıktıları (etiketleri) analiz eder. Bu sayede, girdi ve çıktı arasındaki ilişkileri haritalandırarak, daha önce karşılaşılmamış yeni verilere dair doğru tahminler yapabilecek bir model geliştirir. Denetimli öğrenme genellikle sürekli çıktılar için regresyon ve kategorik çıktılar için sınıflandırma olmak üzere iki ana kategoriye ayrılır. Bu yaklaşım, tıbbi teşhis, kredi riski değerlendirmesi ve görüntü tanıma gibi birçok alanda etkili çözümler sunar (Bojja, 2025).

Tez çalışmasının ana amacını gerçekleştirmek üzere çalışmanın uygulama kısmında denetimli öğrenme algoritmaları kullanılmıştır. Denetimli öğrenme yöntemleri, girdi ve çıktı arasındaki ilişkileri modellemek için güçlü araçlar sunmakla birlikte, zaman serilerinde gözlenen ardışık bağımlılık yapısı bu yöntemlerin doğrudan uygulanmasını zorlaştırmaktadır. Zaman serilerinin ML algoritmaları ile tahmin edilebilmesi için önce serinin zamansal yapısının gecikme değişkenleri, mevsimsellik bileşenleri ve türetilmiş özellikler aracılığıyla modele aktarılması gerekir. Bu dönüşümü sağlayan yaklaşımlardan biri NAR modelleme yöntemidir. NAR, zaman bağımlılığını regresyon çerçevesine taşıyarak seriyi denetimli öğrenme algoritmalarının işleyebileceği bir forma dönüştürür. Bu dönüşüm sonrasında GBR, XGBoost ve RF gibi güçlü ML algoritmaları, nonlineer ilişkileri ve karmaşık örüntüleri yakalayıp tahmin performansını artırmada etkin şekilde kullanılabilir. Bu nedenle, tez kapsamında hem NAR yaklaşımının teorik temeli hem de kullanılan ML algoritmalarının yapısı aşağıda ayrıntılı biçimde ele alınmıştır.

3.3.1 Gradyan Artırmalı Regresyon Algoritması (GBR)

Boosting yaklaşımı, tek başına sınırlı performansa sahip birçok basit modelin, art arda ve birbirini tamamlayacak şekilde bir araya getirilmesine dayanan bir topluluk (ensemble) yöntemidir. GBR ise bu fikri, kayıp fonksiyonunun gradyan bilgisiyle birleştirilerek regresyon problemleri için optimize eder.

GBR, önceki modelin yaptığı hataları ardışık olarak düzelten zayıf öğreniciler (ağaçlar) ekleyerek sistemin yanlılığını (bias) düşürmeyi ve böylece yüksek doğrulukta bir öngörü elde etmeyi hedefler.

Uygulamada çoğunlukla temel öğrenici olarak sığ (derinliği düşük) karar ağaçları kullanılır; bu ağaçlar tek başına güçlü modeller olmasalar da ardışık biçimde eklendiklerinde oldukça esnek ve başarılı bir tahmin modeli elde edilmektedir.

GBR, hedef fonksiyonu adım adım iyileştiren eklemeli bir yapı kurar. İlk adımda, tüm veri setini kaba hatlarıyla temsil eden basit bir başlangıç modeli $F_0(x)$ seçilir. Daha sonra her iterasyonda, mevcut modelin ürettiği hata terimleri hesaplanır ve bu hataları açıklamaya yönelik yeni bir regresyon ağacı $h_m(x)$ eğitilir. Böylece M iterasyon sonunda oluşturulan nihai tahmin fonksiyonu

$$F_M(x) = F_0(x) + \sum_{m=1}^M \rho_m h_m(x) \quad (3.1)$$

şeklinde yazılabilir; burada ρ_m , m . ağacın modele katkısını ölçekleyen katsayıyı, $h_m(x)$ ise zayıf bir karar ağacını göstermektedir.

GBR, her adımda seçilen kayıp fonksiyonu azaltmaya çalışır. Bunu yaparken, kayıp fonksiyonunun mevcut modele göre türev bilgisi kullanılarak her gözlem için bir “hata yönü” hesaplanır ve yeni ağaç bu hata yönünü takip edecek şekilde eğitilir. Böylece parametreler üzerinde değil, doğrudan tahmin fonksiyonunun kendisi üzerinde, kayıp fonksiyonunun en hızlı azalacağı yöne doğru küçük ama sistematik adımlar atan bir gradyan iniş süreci gerçekleştirilmiş olur.

Yöntem, model karmaşıklığı uygun şekilde kontrol edilmediği takdirde aşırı uyuma (overfitting) eğilimli olabilir. Bu nedenle gradient boosting’de bir dizi hiperparametre kullanılarak modelin karmaşıklığı sınırlandırılır. En temel kontrol mekanizması öğrenme oranıdır (ν , learning rate). Bu parametre, her iterasyonda yapılan güncelleme adımını

küçülten bir "büzülme" (shrinkage) faktörü olarak çalışır (Friedman, 2001). Matematiksel olarak bu süreç aşağıdaki şekilde formüle edilir:

$$F_m(x) = F_{m-1}(x) + v h_m(x) \quad (3.2)$$

Küçük bir öğrenme oranı, her iterasyonda daha küçük güncellemeler yapılmasına neden olur; bu da daha fazla sayıda ağaç (M) gerektirse de genellikle daha iyi genelleme performansı sağlar. Bunun yanında:

- Ağaç derinliği (max_depth),
- Yaprak düğümde bulunması gereken asgari gözlem sayısı,
- Örnek alt örnekleme oranı (subsample)

gibi hiperparametreler, ağaçların ifade gücünü sınırlayarak modelin karmaşık yapılar aşırı uyum göstermesini engeller. Literatürde gradient boosting ailesine ait algoritmaların hiperparametre ayarlarına oldukça duyarlı olduğu, buna karşılık XGBoost, LightGBM ve CatBoost gibi çağdaş türevlerin ek düzenleme terimleri ve örnekleme stratejileri sayesinde hem genelleme başarımını hem de eğitim hızını iyileştirdiği belirtilmektedir (Bentéjac vd. 2021).

Bu tez kapsamında GBR, Python ortamında scikit-learn kütüphanesindeki GradientBoostingRegressor sınıfı aracılığıyla uygulanmıştır. Modeller, medikal sektörde kullanılan kritik hammaddelerin (örneğin Elastomer, ABS 3864, PC vb.) aylık tüketim miktarlarını geçmiş dönem verilerine dayanarak öngörmek amacıyla eğitilmiştir. Farklı öğrenme oranı, ağaç derinliği ve ağaç sayısı kombinasyonları denenmiş; elde edilen tahminler $MAPE$, $RMSE$ ve R^2 gibi hata metrikleri üzerinden karşılaştırılarak en uygun hiperparametre yapıları belirlenmiştir.

3.3.2 Aşırı Gradyan Artırma Regresyon Algoritması (XGBoost)

XGBoost, regresyon problemleri için kullanılan güçlü bir denetimli makine öğrenimi tekniğidir (Zhang vd. 2021). Bu algoritma, temelinde GBR çerçevesini barındırır ve zayıf öğrencileri aşamalı olarak birleştirerek daha güçlü tahmin modelleri oluşturur (Ravindran ve Gopalakrishnan, 2018).

XGBoost da Gradient Boosting ailesinin bir üyesi olarak, ardışık hataları düzelterek modelin sistemik yanlılığını minimize etme prensibine dayanır; ancak bunu ek düzenlileştirme terimleri ve optimizasyon teknikleriyle daha güvenilir bir şekilde gerçekleştirir.

XGBoost, her yeni modelin (karar ağacı) bir önceki modelin geride bıraktığı hataları toplayıcı (additive) bir yaklaşımla düzeltmeyi amaçladığı ardışık bir eğitim süreci izler (Putatunda ve Rama, 2018). Regresyon görevlerinde nihai tahmin, eğitilen K adet bireysel ağacın tahminlerinin toplanmasıyla elde edilir (Safhi vd. 2024).

XGBoost, tahmin $\hat{y}_i$ elde etmek için aşağıdaki toplamsal modeli kullanır:

$$\hat{y}_i = \sum_{k=1}^K f_k(x_i) \quad (3.3)$$

Burada i , eğitim veri setindeki örneği, x_i özellik vektörünü ve f_k ise k 'inci karar ağacını temsil etmektedir (Safhi vd. 2024).

XGBoost'un başarısı, modelin karmaşıklığını kontrol eden düzenleme (regularization) terimlerini doğrudan amaç fonksiyonuna dahil etmesinden kaynaklanır (Tayır, 2025).

XGBoost'un başarısı, geleneksel Gradyan Artırma (Gradient Boosting) yaklaşımlarına göre daha titiz bir amaç fonksiyonu kullanması ve bu fonksiyonu ikinci dereceden Taylor serisi açılımı ile optimize etmesinden kaynaklanır (Safhi vd. 2024). Modelin temel amacı, eğitimin her aşamasında aşağıdaki iki bileşeni eş zamanlı olarak minimize etmektir:

1. Eğitim Kaybı (Training Loss): Bu bileşen, modelin tahminleri $\hat{y}_i$ ile verideki gerçek değerler y_i arasındaki farkı, yani hatayı ölçer. Regresyon görevlerinde, bu kayıp genellikle *MSE* metrikleri üzerinden hesaplanır. Amaç, modelin mevcut verilere mümkün olduğunca iyi uymasını sağlamaktır (Tayır, 2025).
2. Düzenleme Terimi (Regularization Term): Bu bileşen, modelin karmaşıklığını cezalandırır ve aşırı öğrenmeyi önlemek için kritik öneme sahiptir. Düzenleme, ağacın derinliği ve yaprak düğümlerindeki ağırlıkların mutlak büyüklüğü (L1 ve L2 normları) gibi parametreleri kontrol altında tutar. Düzenleme teriminin eklenmesi, modelin yalnızca eğitim verilerine değil, genelleme yeteneğine odaklanmasını sağlar.

Dolayısıyla, XGBoost sürekli olarak en düşük toplam sonucu veren ağaç yapılarını aramaktadır; bu toplam sonuç, hata payı ile modelin karmaşıklığının cezasının birleşimidir. Bu denge, modelin yüksek doğrulukla tahmin yaparken aynı zamanda yeni verilere etkin bir şekilde uyum sağlamasına olanak tanır (Kutlu, 2024; Zhang vd. 2021).

3.3.3 Rastgele Orman Regresyon Algoritması (RF)

RF, karar ağacı modellerini temel alan ve öngörü doğruluğunu artırmak için kullanılan bir topluluk öğrenmesi yöntemidir (Salman vd. 2024). RF yöntemi hem sınıflandırma hem de regresyon problemleri için kullanılabilir. RF, temel olarak birçok zayıf öğrenicinin (tek tek karar ağaçları) tahminlerini bir araya getirerek, tek bir güçlü ve daha genelleştirilebilir bir model oluşturma prensibine dayanır (Prova, 2024). Burada amaç, tek bir karmaşık ağaç yerine çok sayıda görece basit ağacın bir araya gelmesiyle genelleme hatasını azaltmak ve aşırı uyum (overfitting) riskini düşürmektir. RF, topluluk öğrenmesi yaklaşımları arasında özellikle modelin varyansını (aşırı uyumdan kaynaklanan oynaklığı) düşürerek tahmin gücünü artırmaya odaklanır.

RF algoritması, iki düzeyde rastgelelik içeren çok sayıda karar ağacından oluşan bir orman yapısı üzerine kuruludur. İlk aşamada, her bir karar ağacı, orijinal eğitim

kümesinden yerine koymalı örnekleme (bootstrap) ile çekilen rastgele bir alt küme üzerinde eğitilir; böylece her ağaç veri setinin farklı bir örneklemini görür. İkinci aşamada ise, her düğümde yapılacak bölünme işlemi için tüm açıklayıcı değişkenler yerine, değişkenlerin rastgele seçilen bir alt kümesi dikkate alınır. Bu iki mekanizma, ağaçlar arasındaki korelasyonu azaltarak topluluğun çeşitliliğini artırmakta ve ağaç çıktılarının ortalaması alınırken tahmin varyansının azalmasına katkı sağlamaktadır. Teorik ve deneysel çalışmalar, ormandaki ağaç sayısı arttıkça rastgele orman algoritmasının genelleme hatasının belirli bir sınır değere yakınsadığını ve yeterince büyük ağaç sayıları için ek ağaçların performansı bozmadığını ortaya koymaktadır (Bentéjac vd. 2021).

Bu tez çalışmasında RF, sürekli bir hedef değişkenin, yani kritik hammaddelere ait aylık tüketim miktarlarının tahmini için regresyon modeli olarak kullanılmıştır. Regresyon bağlamında rastgele orman, her biri eğitim verisinin farklı bir alt kümesi ve özellik alt uzayı üzerinde eğitilmiş çok sayıda karar ağacından oluşmakta; topluluğun nihai tahmini ise bu ağaçların ürettiği sayısal çıktıların ortalaması ile elde edilmektedir.

Matematiksel olarak, n adet ağaç içeren bir rastgele orman modelinde, bir gözlem X için tahmin edilen $\hat{y}$ değeri şu şekilde ifade edilmektedir:

$$\hat{y} = \frac{1}{n} \sum_{i=1}^n T_i(X) \quad (3.4)$$

burada $T_i(X)$, i . karar ağacının ilgili girdiye ilişkin tahminini göstermektedir. Bu yapı sayesinde rastgele orman, doğrusal olmadığı bilinen ya da biçimsel olarak tanımlanması güç olan ilişkileri, açık bir fonksiyonel form varsayımına ihtiyaç duymadan modelleyebilmektedir (Kutlu, 2024).

RF'nin davranışı, karar ağaçlarının karmaşıklığını ve çeşitliliğini kontrol eden bazı temel hiperparametreler aracılığıyla ayarlanmaktadır. Bunlar arasında; ormandaki ağaç sayısı, her ağacın maksimum derinliği, yaprak düğümde bulunması gereken asgari gözlem sayısı yer almaktadır. Literatürde, özellikle ağaç sayısının yeterince büyük tutulması ve ağaç derinliği ile yaprak başına minimum gözlem sayısının sınırlandırılmasıyla, farklı türde

regresyon problemlerinde aşırı uyumdan kaçınarak dengeli bir tahmin performansı elde ettiği gösterilmiştir. Pek çok çalışmada olduğu gibi, bu tezde de hiperparametrelerin seçimi, doğrulama performansını eniyilemeye yönelik sistematik bir deneme–yanılma süreci üzerinden gerçekleştirilmiştir.

Bu tez kapsamında RF, Python ortamında scikit-learn kütüphanesindeki RandomForestRegressor sınıfı kullanılarak uygulanmıştır.

3.3.4 Nonlinear Otoregresif Zaman Serisi (NAR)

Zaman serisi verilerinde gözlenen ilişkiler çoğu durumda doğrusal modellerle tam olarak temsil edilemeyebilir. Özellikle operasyonel, ekonomik ve üretim temelli serilerde geçmiş değerler arasındaki bağımlılık yapısı dinamik, asimetrik ve nonlinear özellikler gösterebilmektedir. Bu nedenle literatürde, serinin gelecekteki değerinin kendi geçmiş gözlemlerinin doğrusal olmayan bir fonksiyonu olarak ifade edildiği NAR modeller geliştirilmiştir. Stokastik nonlinear dinamik süreçleri genel olarak aşağıdaki biçimde ifade edilir:

$$x_{t+1} = f(x_t, x_{t-1}, \dots, x_{t-p}) + s(x_t)e_t \quad (3.5)$$

Burada x_t serinin t anındaki değerini, p kullanılan gecikme sayısını, $f(\cdot)$ serinin doğrusal olmayan ortalama dinamiklerini temsil eden bilinmeyen fonksiyonu, $s(x_t)e_t$ terimi ise duruma bağlı (koşullu) hata bileşenini ifade etmektedir. t zaman indeksini göstermekte olup model, zaman serisinin teorik olarak tüm zaman noktalarında ($t \in \mathbb{Z}$) tanımlandığı varsayımı altında ifade edilmiştir. Bu yapı, ortalama denklemi bakımından nonlinear otoregresif modellere karşılık gelmektedir. Bu tez kapsamında, koşullu varyans terimi sadeleştirilerek NAR modeli aşağıdaki biçimde ele alınmıştır:

$$x_t = f(x_{t-1}, x_{t-2}, \dots, x_{t-p}) + e_t \quad (3.6)$$

Burada x_t serinin t anındaki değeri, p kullanılan gecikme sayısı, $f(.)$ doğrusal olmayan dönüşümü temsil eden bilinmeyen fonksiyon ve e_t hata terimidir. Bu yaklaşım, özellikle doğrusal olmayan dinamiklere sahip zaman serilerinin tahmininde, doğrusal modellere kıyasla çok daha yüksek bir esneklik sunmakta; doğrusal olmayan yapıların daha doğru ve etkin bir şekilde yakalanabilmesine olanak tanıyarak tahmin performansını önemli ölçüde artırmaktadır (Mizrach, 2006).

Zaman serisi yalnızca kendi geçmişine değil, aynı zamanda dışsal değişkenlere de bağlı olduğunda model Dışsal Girdili Doğrusal Olmayan Otoregresif Model (Nonlinear Autoregressive Model with Exogenous Inputs-NARX) biçimine dönüşmektedir. NARX modeli aşağıdaki gibi ifade edilmektedir:

$$x_t = f\left(x_{t-1}, x_{t-12}, \dots, z_{t-1}^{(1)}, z_{t-1}^{(2)} \dots\right) + e_t \quad (3.7)$$

Burada z_{t-k} modele dışsal etki yapan bağımsız değişkenleri göstermektedir. ML ve derin öğrenme temelli zaman serisi çalışmalarında, geçmiş gecikmeler ve dışsal faktörlerin birlikte kullanıldığı bu yapı geniş biçimde benimsenmektedir (Nabipour vd. 2020, Lin vd.1996).

Bu modeldeki bilinmeyen $f(.)$ fonksiyonu doğrudan tanımlanmamış; bunun yerine GBR algoritması aracılığıyla veri üzerinden öğrenilmiştir. GBR, karar ağaçlarını ardışık şekilde optimize ederek doğrusal olmayan ilişkilerin modellenmesini sağlayan güçlü bir ML yöntemidir. Gecikme temelli özellik çıkarımı ve Boosting algoritmalarının birlikte kullanıldığı çalışmalar, bu yaklaşımın zaman serisi tahmin performansını artırdığını göstermektedir (Borrero ve Mariscal, 2023; Zhang vd. 2021).

Bu tez kapsamında, 2025 yılı için üretim, stok seviyesi, yurtiçi satış, yurtdışı satış ve fire miktarı gibi bağımsız değişkenlerin tahmin edilebilmesi amacıyla her bir seri için aşağıdaki otoregresif zaman serisi özellikleri oluşturulmuştur:

- Bir dönem gecikmesi: x_{t-1}

- On iki dönem gecikmesi (mevsimsellik): x_{t-12}
- Üç aylık hareketli ortalama:

$$\bar{x}_{t-1}^{(3)} = \frac{x_{t-1} + x_{t-2} + x_{t-3}}{3} \quad (3.8)$$

- Takvim değişkenleri: ay (m_t) ve yıl (y_t)

Bu bileşenler bir araya getirildiğinde kullanılan model aşağıdaki forma sahiptir:

$$x_t = f(x_{t-1}, x_{t-12}, \bar{x}_{t-1}^{(3)}, m_t, y_t) + e_t \quad (3.9)$$

Bu yapı hem genel NAR modelleriyle hem de gecikmelerden ve dışsal değişkenlerden yararlanan NARX modelleriyle uyumludur. Gecikme terimlerinin ve takvimsel özelliklerin ML algoritmalarıyla birlikte kullanılmasının zaman serisi performansını artırdığı farklı çalışmalarda gösterilmiştir (Zhang vd. 2021).

Özyinelemeli Tahmin: 2025 yılı için ardışık 12 ay tahmini, özyinelemeli (recursive) tahmin yöntemi ile gerçekleştirilmiştir. Bu yöntemde model ilk olarak bir adım ileri tahmin üretir ve bu tahmin daha sonraki tahminlerin girdisi hâline gelir.

İlk adım:

$$\hat{x}_{t+1} = f(x_t, x_{t-11}, \bar{x}_t^{(3)}, m_{t+1}, y_{t+1}) \quad (3.10)$$

İkinci adım:

$$\hat{x}_{t+2} = f(\hat{x}_{t+1}, x_{t-10}, \bar{x}_{t+1}^{(3)}, m_{t+2}, y_{t+2}) \quad (3.11)$$

Genel form:

$$\hat{x}_{t+h} = f(\hat{x}_{t+h-1}, x_{t+h-12}, \bar{x}_{t+h-1}^{(3)}, m_{t+h}, y_{t+h}) \quad (3.12)$$

Özyinelemeli tahmin tekniği hem ML hem derin öğrenme tabanlı zaman serisi çalışmalarında yaygın şekilde kullanılmaktadır (Borrero ve Mariscal, 2023; Nabipour vd. 2020).

Bu çalışmada nonlinear otoregresif model yapısının kullanılması, üretim ve stok gibi operasyonel serilerin doğrusal olmayan, gecikmeli ve mevsimsel dinamikler içermesi nedeniyle gereklidir. Bununla birlikte, 2025 yılı için 12 aylık ileri tahmin yapılırken geleceğe ait gecikme değerleri gözlenemediğinden modelin her ayı bir önceki tahmine dayanarak hesapladığı özyinelemeli (recursive) tahmin yaklaşımı uygulanmıştır. Dolayısıyla nonlinear model serinin yapısal özelliklerini öğrenmeyi sağlarken, özyinelemeli yöntem çok adımlı tahmin sürecini mümkün kılmakta; her iki yaklaşım birlikte kullanılarak modelin hem doğrusal olmayan ilişkileri yakalaması hem de geleceğe yönelik ardışık tahminler üretebilmesi sağlanmaktadır.

ML modellerinin performansı, modelin yapısını ve öğrenme davranışını kontrol eden hiperparametre seçimlerinden doğrudan etkilenmektedir. Bu nedenle, çalışmada kullanılan GBR, XGBoost ve RF modellerine ait temel hiperparametreler ve bu hiperparametrelerin neyi ifade ettiği çizelge 3.1’de özetlenmiştir.

Çizelge 3.1 ML yöntemleri için hiperparametre değerleri

<i>ML Modeli</i>	<i>Hiperparametre</i>	<i>Açıklama</i>
GBR	Ağaç Sayısı (n_estimators)	Kurulan ardışık ağaçların toplam sayısı
	Öğrenme Oranı (learning_rate)	Her yeni ağacın katkı büyüklüğü
	Maksimum Derinlik (max_depth)	Her ağacın karmaşıklık seviyesi
XGBoost	Ağaç Sayısı (n_estimators)	Boosting iterasyon sayısı
	Öğrenme Oranı (learning_rate)	Her iterasyonun güncelleme adımı
	Maksimum Derinlik (max_depth)	Ağaçların derinliği
	L2 Düzenleştirme terimi (reg_lambda)	Ağırlıkların büyüklüğünü cezalandıran terim
RF	Ağaç Sayısı (n_estimators)	Ormandaki ağaç adedi
	Yaprak Başına Asgari Örnek (min_samples_leaf)	Bir yaprakta bulunması gereken minimum örnek sayısı
	Maksimum Derinlik (max_depth)	Her ağacın büyüme sınırı

İlgili hiperparametrelerin çalışmada kullanılan sayısal değerleri uygulama bölümünde sunulmaktadır.

3.4 Model Performans Ölçütleri

Bu çalışmada geliştirilen tahmin modellerinin başarısı, üç farklı performans ölçütü kullanılarak değerlendirilmiştir. Tahmin hatasının büyüklüğünü ölçmek amacıyla *RMSE* ve *MAPE*, modelin veriyle uyumunu değerlendirmek için ise R^2 değeri hesaplanmıştır. *RMSE* ve *MAPE*, tahminlerin gerçek değerlere ne kadar yaklaştığını; R^2 ise bağımlı değişkendeki değişimin ne kadarının model tarafından açıklandığını göstermektedir. Bu sayede, modeller hem hata düzeyi hem de açıklayıcılık açısından birlikte değerlendirilmiştir. Bu model performansları matematiksel olarak aşağıdaki formüllerin yardımıyla hesaplanır;

MAPE, her bir gözlem için tahmin hatasının büyüklüğünü gerçek değere göre yüzde cinsinden ifade eden bir hata ölçüsüdür. Önce gerçek değer ile tahmin edilen değer arasındaki fark alınır, bu farkın mutlak değeri gerçek değere oranlanır ve tüm gözlemler için elde edilen bu yüzde hataların ortalaması alınır. Son adımda 100 ile çarpılarak toplam hata yüzdesi elde edilir. Aykırı değerlerin sınırlı olduğu serilerde tahmin modellerini değerlendirmede en sık başvuru olan ölçütlerden biridir. *MAPE*'nin yüksek olması, modelin daha fazla yüzde hata ürettiğini ve dolayısıyla tahmin performansının zayıf olduğunu göstermektedir.

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| * 100 \quad (3.12)$$

Burada y_i , i 'inci gerçek çıktı değerini; $\hat{y}_i$, i 'inci tahmin edilen çıktı değerini; n ise toplam gözlem sayısını göstermektedir (Güçlükol, 2020).

RMSE, *MSE*'nin karekökü olarak tanımlanan bir hata ölçüsüdür. Önce gerçek ve tahmin edilen çıktı değerleri arasındaki farkların karelerinin ortalaması alınır ve bu ortalamanın karekökü hesaplanır. Kare ve karekök işlemleri nedeniyle *RMSE* her zaman sıfır veya

pozitif bir deęer alır. Daha yüksek $RMSE$, daha yüksek tahmin hatası ve daha kötü model performansı anlamına gelmektedir.

$$RMSE = \sqrt{MSE} = \sqrt{\frac{1}{n} \sum_{t=1}^n e_t^2} \quad (3.13)$$

R^2 , modelin performansını temel bir modele kıyasla deęerlendiren bir uyum ölçüsüdür. Öncelikle tahmin modeli için hesaplanan MSE , tüm çıktı deęerlerini yalnızca gerçek deęerlerin ortalamasıyla tahmin eden temel modelin MSE deęerine bölünür. Bu oran 1’den çıkarılarak R^2 deęeri elde edilir. Temel model burada, en basit tahmin yaklaşımı olan “her gözlem için ortalamayı tahmin etme” stratejisini temsil etmektedir. R^2 deęeri teorik olarak $-\infty$ ile 1 arasında deęişebilir; deęerin 1 olması veya 1’e yaklaşması modelin başarılı olduğuna, negatif olması ise modelin temel ortalama tahmininden daha kötü performans sergilediğine işaret eder.

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (\bar{y} - y_i)^2} \quad (3.14)$$

4. ZAMAN SERİSİ ANALİZİ

İstatistiksel açıdan, seri terimi, belirli bir esasa göre sıralanmış gözlemlerden oluşan veri kümelerini ifade etmektedir. Bu bağlamda, zaman serisi ise; gözlem değerlerinin zaman birimleri (gün, hafta, ay, yıl, vb.) dikkate alınarak kronolojik bir düzen içinde organize edilmesiyle oluşturulan serilere verilen addır (Duru, 2007). Bu tür seriler, trend, mevsimsellik ve rastlantısal bileşenleri bir arada barındırdığından, analiz süreci yalnızca öngörü üretmekle sınırlı kalmayıp aynı zamanda serinin dinamiklerini ayrıştırarak derinlemesine yorumlama imkânı da sunar (Güngör vd. 2025).

Zaman serisi analizi, ekonomi, finans, istatistik, mühendislik, tıp ve doğa bilimleri gibi oldukça geniş bir uygulama alanına sahiptir. Bu yöntemin kullanıldığı başlıca uygulama alanları arasında, ekonomide makroekonomik göstergelerin takibi ve tahmini, finasta piyasa fiyatlarının öngörüsü, enerji bilimlerinde dönemsel talep tahminleri ve tıp alanında hastalık yayılımının zaman içindeki seyri bulunmaktadır. Günlük hayatta ise; hava sıcaklıklarının değişimi, elektrik tüketim profilleri veya bir web sitesinin aylık ziyaretçi sayıları gibi veriler, zaman serisi analizine konu olmaktadır.

Zaman serisi analizi, verinin zamana bağlı yapısını ve dinamiklerini incelemesi sebebiyle, diğer veri analizi yaklaşımlarından ayrılır. Bu kendine özgü perspektif, yöntemin özellikle geleceğe yönelik öngörü problemlerinde kritik bir rol oynamasını sağlamaktadır.

Talep tahmini problemlerinde zaman serisi yaklaşımları, planlama ve stok düzeyi optimizasyonu gibi operasyonel kararlarda doğrudan kullanılabildiği için önemli bir karar destek aracı olarak ele alınmaktadır (Güngör vd. 2025).

4.1 Zaman Serisi Bileşenleri

Genel kabul görmüş zaman serisi ayrışım modeline göre, bir serinin değerleri dört temel faktörün etkileşiminden oluşur: uzun dönemli trend (eğilim), mevsimsel bileşen, belirli

bir frekansı olmayan konjonktürel (döngüsel) hareketler ve düzensiz (rastgele) değişimler.

Trend (Eğilim), zaman serisinde uzun vadede gözlemlenen artış veya azalış yönündeki genel hareketliliği ifade eder. Serinin değerlerinde, incelenen periyot boyunca istikrarlı ve sürekli bir yukarı veya aşağı yönlü kaymayı temsil eder. Bu bileşen; nüfus artışı, teknolojik gelişmeler veya piyasa tercihlerindeki kalıcı değişiklikler gibi makroekonomik veya yapısal faktörlerden kaynaklanır (Box vd. 1994). Trendin varlığı, genellikle serinin durağan olmamasının bir göstergesidir ve öngörü modelleri oluşturulmadan önce dikkate alınması gereken en önemli dinamiklerden biridir.

Mevsimsel bileşen, serinin bir yıldan daha kısa ve sabit zaman aralıklarında (örneğin; mevsimler, aylar, haftanın günleri veya günün saatleri) kendisini tekrarlayan düzenli ve periyodik değişimlerdir. Bu bileşen, iklimsel koşullar, resmî tatiller, okul dönemleri veya takvim bazlı alışkanlıklar gibi tekrarlayan olaylardan etkilenir. Mevsimsellik, özellikle talep öngörüsü çalışmalarında, öngörü doğruluğunu artırmak için mutlaka modellenmesi ve seriden ayrıştırılması gereken kritik bir faktördür (Hyndman ve Athanasopoulos, 2018).

Konjonktürel (Döngüsel) bileşen, genellikle ekonomik faaliyetlere bağlı olarak ortaya çıkan ve süresi bir yıldan uzun olan, ancak periyodu kesin olarak belirlenemeyen dalgalanmalardır. Bu bileşen, genellikle ekonomik genişleme ve daralma dönemleri gibi iş çevrimleriyle ilişkilidir. Mevsimselliğin aksine, döngüsel bileşenin ne zaman başlayıp biteceği veya süresi kesin değildir; bu belirsizlik, analitik modellemede diğer bileşenlere göre daha zorlayıcıdır (Hamilton, 1994).

Düzensiz (Rastgele) bileşen, trend, mevsimsellik ve döngüsel bileşenler ayrıştırıldıktan sonra seride kalan, tamamen öngörülemez ve düzensiz dalgalanmalardır. Bu bileşenler; doğal afetler, siyasi şoklar, beklenmedik olaylar veya ölçüm hataları gibi kısa süreli ve ani etkilerden kaynaklanır. Rastlantısal bileşen, analiz edilecek bir yapıya sahip değildir ve modelleme sırasında genellikle "gürültü" veya hata terimi olarak ele alınır (Box vd. 1994).

Bu bileşenler serinin yapısını açıklarken, bir sonraki adım bu yapıyı yakalayabilecek uygun zaman serisi modelini seçmektir.

4.2 Zaman Serisi Modelleri

Zaman serisi tahmin modelleri, bir serinin geçmişteki gözlem değerlerini kullanarak gelecekteki davranışını öngörmeyi amaçlayan istatistiksel yöntemlerdir. Bu modeller, serinin içindeki otokorelasyon ve kısmi otokorelasyon yapılarını analiz ederek geleceğe yönelik tahminler üretir (Duru, 2007; Box vd. 1994).

4.2.1 Otoregresif Model (AR)

Otoregresif süreçler, serinin şimdiki değerini (y_t), geçmişteki kendi değerlerinin doğrusal bir fonksiyonu olarak açıklar. Bu, serinin geçmişteki gözlemlerinin gelecekteki değerlerini etkilediği varsayımına dayanır (Hamilton, 1994).

Bir p dereceli AR(p) modelinin genel matematiksel gösterimi:

$$y_t = c + \varphi_1 y_{t-1} + \varphi_2 y_{t-2} + \dots + \varphi_p y_{t-p} + e_t \quad (4.1)$$

biçimindedir. Burada:

- y_t : Serinin t anındaki değeri,
- c : Sabit terim (Ortalama),
- φ_i : i . gecikmedeki otoregresif katsayılar,
- e_t : Beyaz gürültü hata terimi,
- P : Modelin derecesi,

olarak tanımlanır.

4.2.2 Hareketli Ortalama Modeli (MA)

Hareketli Ortalama süreçleri, serinin şimdiki değerini, mevcut ve geçmiş dönemlerdeki stokastik hata terimlerinin (beyaz gürültü şoklarının) doğrusal bir kombinasyonu olarak ifade eder (Duru, 2007). Bu, serideki ani şokların etkisinin kısa bir süre sonra ortadan kalktığı varsayımına dayanır.

Bir q dereceli $MA(q)$ modelinin genel matematiksel gösterimi:

$$y_t = \mu + e_t + \theta_1 e_{t-1} + \theta_2 e_{t-2} + \dots + \theta_q e_{t-q} \quad (4.2)$$

biçimindedir. Burada:

- y_t : Serinin t anındaki değeri,
- μ : Serinin ortalaması,
- e_t : t anındaki beyaz gürültü hata terimi,
- θ_i : i . gecikmedeki hareketli ortalama katsayıları,
- q : Modelin derecesi,

olarak tanımlanır.

Zaman serisi modellerinde (özellikle Box–Jenkins yaklaşımında) süreçteki rastgele dalgalanmaları temsil eden hata terimi e_t için genellikle beyaz gürültü varsayımı yapılır. Buna göre e_t dizisi zaman boyunca ilişkisiz, beklenen değeri sıfır olan ve varyansı zamana göre değişmeyen (σ^2) rassal şoklardan oluşur; bu durum çoğunlukla $e_t \sim WN(0, \sigma^2)$ gösterimiyle ifade edilir (Hyndman ve Athanasopoulos, 2018; Gültekin 2022).

Bu çerçevede, hareketli ortalama (MA) türü modellerin en temel örneklerinden biri de yalnızca bu rastgele şoklardan oluşan beyaz gürültü serisidir.

4.2.3 Otoregresif Hareketli Ortalamalar Modeli (ARMA)

ARMA modelleri, durağan zaman serilerinin modellenmesinde kullanılan ve otoregresif (AR) yapı ile hareketli ortalama (MA) yapısını birlikte içeren doğrusal stokastik modellerdir. Bu yaklaşımda serinin herhangi bir t anındaki değeri, belirli sayıda geçmiş gözlem değeri ile geçmiş hata terimlerinin doğrusal birleşimi şeklinde ifade edilir. AR kısmı serideki “kalıcılığı/bağımlılığı” yakalarken, MA kısmı geçmiş dönemlerde oluşan rassal hataların etkisini modele taşır (Box vd. 1994).

$ARMA_{(p,q)}$ modeli p dereceden AR ve q dereceden MA bileşeninin birleşimidir. Modelin matematiksel gösterimi:

$$y_t = \sum_{i=1}^p \varphi_i y_{t-i} + \sum_{j=1}^q \theta_j e_{t-j} + e_t \quad (4.3)$$

$ARMA_{(p,q)}$ modelinde hesaplanması gereken parametre sayısı $p + q + 2$ tanedir. Bunlardan p tanesi φ (otoregresyon) parametresi, q tanesi θ (hareketli ortalama) parametresi, bir tanesi ortalama değer μ ve bir tanesi de δ_a^2 ' dir.

4.2.4 Entegre Otoregresif Hareketli Ortalamalar Modeli (ARIMA)

ARIMA modeli, durağan olmayan zaman serilerinin modellenmesinde kullanılan ve durağanlaştırma amacıyla fark alma (integrated) bileşenini içeren doğrusal bir zaman serisi yaklaşımıdır. Temel fikir; önce serinin gerekli derecede farkı alınarak durağanlık sağlanması, ardından elde edilen durağan seri üzerinde ARMA yapısının kurulmasıdır. Bu nedenle ARIMA, “fark alınmış seri için ARMA modeli” şeklinde de yorumlanabilir (Duru, 2007).

Durağan hale getirilen (farkı alınmış) seri üzerinde kurulan modele $ARIMA_{(p,d,q)}$ denir. Burada p otoregresif (AR) derecesini, q hareketli ortalama (MA) derecesini, d ise fark alma derecesini ifade eder.

Genel olarak d 'inci fark, gecikme operatörü ile

$$\varphi(L)(1-L)^d y_t = \theta(L)e_t \quad (4.4)$$

şeklinde ifade edilir.

Bu dönüşümden sonra serisinin $ARMA_{(p,q)}$ yapısına uyduğu varsayılır ve genel $ARIMA_{(p,d,q)}$ modeli (farkı alınmış seri üzerinden) şu şekilde ifade edilir:

$$(1 - \sum_{i=1}^p \varphi_i L^i)(1-L)^d y_t = (1 + \sum_{j=1}^q \theta_j L^j) e_t \quad (4.5)$$

4.2.5 Mevsimsel Entegre Otoregresif Hareketli Ortalamalar Modeli (SARIMA)

SARIMA modeli, klasik ARIMA modelinin, veri setindeki mevsimsel (periyodik) değişkenliği de yakalamak üzere genişletilmiş halidir (Kumari ve Muthulakshmi, 2024). Bu model, hem mevsimsel olmayan (p, d, q) hem de mevsimsel (P, D, Q) bileşenlerini içerir.

SARIMA modeli, $SARIMA(p, d, q)(P, D, Q)_s$ şeklinde gösterilir ve matematiksel olarak gecikme operatörleri (L) kullanılarak ifade edilir:

SARIMA modelinin matematiksel gösterimi:

$$\Phi_P(L^s)\varphi_p(L)\Delta_s^D\Delta^d y_t = \theta_Q(L^s)\theta_q(L)e_t \quad (4.6)$$

biçimindedir. Burada:

- (p, d, q) : Mevsimsel olmayan AR, Entegrasyon ve MA dereceleri,
- (P, D, Q) : Mevsimsel AR, Mevsimsel Entegrasyon ve Mevsimsel MA dereceleri,
- s : Mevsimsel periyot (Örn: aylık veride $s = 12$),

- $\varphi_p(L), \theta_q(L)$: Mevsimsel olmayan polinomlar,
 $\Phi_P(L^s), \Theta_Q(L^s)$: Mevsimsel polinomlar,
 $\Delta^d y_t$: Mevsimsel olmayan d . dereceden fark alma,
 $\Delta_s^D y_t$: Mevsimsel D . dereceden fark alma,

olarak tanımlanır.

Bu matematiksel yapı, modelin hem kısa vadeli (mevsimsel olmayan) hem de uzun vadeli (mevsimsel) bağımlılıkları tek bir çatı altında modellemesini sağlar (Kumari ve Muthulakshmi, 2024).

4.3 Durağanlık Analizi ve Birim Kök Testleri

4.3.1 Durağanlık kavramı ve önemi

Box–Jenkins türü zaman serisi modelleri, serinin istatistiksel özelliklerinin zaman içinde değişmediği durağan stokastik süreç varsayımı üzerine kuruludur. Durağanlık, en temel düzeyde serinin beklenen değerinin sabit olması ve varyansının zaman içinde değişmemesi fikriyle açıklanabilir. Durağan olmayan serilerde (örn. trend veya güçlü mevsimsellik içeren serilerde) model parametrelerinin kararlı tahmini zorlaşabileceğinden, model kurulmadan önce serinin durağanlaştırılması gerekir (Duru, 2007).

Durağanlık kontrolünde ilk aşamada serinin zaman grafiği incelenerek belirgin trend ve mevsimsel yapı olup olmadığına dair ön değerlendirme yapılır. Bununla birlikte yalnızca görsel inceleme her zaman kesin karar vermeye yeterli olmayabilir; bu nedenle durağanlık analizi çoğunlukla istatistiksel testlerle desteklenir (Hyndman ve Athanasopoulos, 2018).

4.3.2 Birim kök yaklaşımı

Zaman serilerinde durağan olmamanın önemli bir nedeni, seride stokastik trend bulunmasıdır. Bu durum çoğu zaman serinin birim kök içermesiyle ilişkilendirilir. Özellikle AR bileşeni içeren süreçlerde durağanlık, parametrelerin sağladığı matematiksel koşullara bağlıdır. Bir AR sürecinin durağan kabul edilebilmesi için karakteristik polinomun köklerinin birim çemberin dışında yer alması (eşdeğer olarak köklerin mutlak değerlerinin 1'den büyük olması) beklenir. Bu koşul sağlandığında, geçmiş dönem şoklarının etkisi zamanla sönümlenir ve seri ortalama/varyans açısından daha kararlı bir yapı gösterir (Duru, 2007).

Bu teorik koşul, uygulamada çoğu zaman “seride birim kök var mı?” sorusuna indirgenerek ele alınır. Birim kökün varlığı, serinin kalıcı şoklar üretmesine ve durağan olmama eğilimi göstermesine yol açabileceğinden, durağanlık değerlendirmesi çoğunlukla birim kök testleriyle yapılır (Ryan vd. 2025).

4.3.3 Dickey–Fuller (DF) ve Genişletilmiş Dickey–Fuller (ADF) testleri

Zaman serilerinde durağanlığın değerlendirilmesine yönelik birçok yaklaşım bulunmakla birlikte, uygulamada en sık başvurulanan yöntemlerden biri birim kök testleridir. Durağanlık, serinin istatistiksel özelliklerinin zaman boyunca “istikrarlı” kalmasıyla ilgilidir; durağan olmama durumunda ise özellikle trendin (deterministik ya da stokastik) doğru tanımlanmaması, modelleme ve çıkarım aşamalarında yanıltıcı sonuçlar üretebilir. Bu nedenle serideki durağan olmama mekanizmasının anlaşılması ve buna uygun biçimde fark alma (differencing) veya trend giderme (detrending) gibi yöntemlerin seçilmesi kritik görülmektedir (Ryan vd. 2025; Schmal, 2024).

Dickey–Fuller yaklaşımı, serinin en basit haliyle bir AR(1) yapı üzerinden temsil edilebileceği varsayımından hareketle birim kökün varlığını sınar. Bu çerçevede seri aşağıdaki gibi yazılabilir:

$$y_t = \rho y_{t-1} + u_t \quad (4.7)$$

Bu modelde birim kök durumu $\rho=1$ ile ilişkilidir ve bu durum genellikle serinin durağan olmadığını ifade eder. Uygulamada testin kurulumu daha açık hale getirilebilmesi için denklem fark formuna dönüştürülür:

$$\Delta y_t = (\rho - 1)y_{t-1} + u_t \quad (4.8)$$

Burada $\Delta y_t = y_t - y_{t-1}$ ve $\gamma = \rho - 1$ tanımıyla model

$$\Delta y_t = \gamma y_{t-1} + u_t \quad (4.9)$$

şeklini alır. Bu gösterim üzerinden DF testinde temel hipotez çoğunlukla $H_0: \gamma = 0$ (birim kök var ve durağan değil) biçiminde kurulur; alternatif hipotez ise durağanlık lehinedir (Schmal, 2024).

Pratik veri uygulamalarında hata terimlerinin ardışık bağımlılık (otokorelasyon) içerebilmesi nedeniyle DF'nin basit formu yetersiz kalabildiğinden, test gecikmeli fark terimleriyle genişletilir ve Augmented Dickey–Fuller (ADF) biçimi elde edilir. ADF’de temel fikir, otokorelasyonu azaltmak amacıyla Δy_t ’nin gecikmelerini modele ekleyerek birim kök sınavasını daha güvenilir hale getirmektir. ADF regresyonu genellikle aşağıdaki gibi ifade edilir:

$$\Delta y_t = \alpha + \beta t + \gamma y_{t-1} + \sum_{i=1}^k \delta_i \Delta y_{t-i} + e_t \quad (4.10)$$

Bu modelde birim kök sınavası yine γ katsayısı üzerinden yapılır. Ayrıca ADF’de yokluk hipotezi durağan olmama (birim kökün varlığı) şeklinde kurulduğu için, H_0 ’ın reddedilememesi “birim kök kesin vardır” demekten ziyade “birim kökün varlığı dışlanamadı” şeklinde daha temkinli yorumlanmalıdır (Schmal, 2024).

5. UYGULAMA

Rekabetin yoğun olduğu piyasa koşullarında, şirketlerin operasyonel verimlilik sağlaması ve stratejik üstünlük kazanması büyük ölçüde geleceği okuyabilme becerisine dayanır. Bu noktada, talep öngörüsü kritik bir rol oynar. İşletmeler, talep öngörüsü uygulamalarından faydalanarak potansiyel belirsizliklere karşı proaktif bir duruş sergiler, müşteri ihtiyaçlarını zamanında ve eksiksiz şekilde karşılar ve tüm üretim ile lojistik akışlarını en verimli yolla planlar. Bu nedenle, söz konusu uygulamalar bir kuruluşun gelecekteki yönünü belirlemesi için hayati öneme sahiptir.

Bu tez çalışması, medikal sektörde faaliyet gösteren bir işletmenin 9 adet kritik hammaddesine ait tüketim dinamiklerini ML yöntemleriyle analiz etmeye odaklanmaktadır. Çalışmanın temel amacı, bu hammaddelerin 2025 yılı tüketimini öngörerek söz konusu yıl için daha verimli stok yönetimi planlaması yapılmasına katkı sağlamaktır. Bu kapsamda, 2021-2024 dönemini kapsayan geçmiş veriler, yapılandırılmış veri biçiminde işletmeden temin edilmiştir. Ham veriler ön işleme sürecinden geçirilerek modellemeye uygun hale getirilmiştir. 2025 yılı tüketim öngörülerini üretilmeden önce, geliştirilecek ML modellerinin geleceğe yönelik tahmin performansının değerlendirilmesi amacıyla geriye dönük test (backtesting) uygulanmıştır. Bu kapsamda, veri seti zamansal sıraya göre ayrılmış; yaklaşık %75'lik bölümü olan 2021–2023 dönemi eğitim seti, kalan yaklaşık %25'lik kısmı olan 2024 yılı ise test seti olarak kullanılmıştır. Modeller 2021–2023 verileri üzerinde eğitilmiş ve sonrasında 2024 yılı için tahminler üretmiştir. Elde edilen tahminler, 2024 yılının gerçek tüketim değerleriyle karşılaştırılarak *RMSE*, *MAPE* ve R^2 metrikleri hesaplanmış, böylece modellerin öngörü gücü doğrulanmıştır. Bu doğrulama sonucunda performansı yeterli bulunan modeller, 2025 yılına ait tüketim öngörülerinin üretilmesinde kullanılmıştır.

Tüm analiz ve modellemeler Python (3.13.7) ile Spyder IDE üzerinde gerçekleştirilmiştir.

5.1 Veri Toplama Süreci ve Veri Setinin Yapısı

5.1.1 Veri toplama süreci

Bu tez çalışmasında kullanılan veri seti, medikal sektörde faaliyet gösteren işletmenin 1 Ocak 2021 ile 31 Aralık 2024 tarihleri arasındaki 4 yıllık (48 aylık) kayıtlarını kapsamaktadır. Veriler, işletmenin farklı departmanlarından manuel olarak ve Excel formatında temin edilmiş, ardından analiz için tek bir yapıda birleştirilmiştir.

Çalışmanın temelini oluşturan verilerin toplanma süreci çok kaynaklı bir yapıya sahiptir:

- Satış ve Fire Verileri: Yurtiçi Satış Adedi, Yurtdışı Satış Adedi ve Fire Adedi değişkenleri, işletme içinde belirli sorumlulara atanmış olan KPI (Anahtar Performans Göstergesi) takip dosyalarından temin edilmiştir. Bu KPI'lar ilgili sorumlular tarafından 3'er aylık periyotlarla raporlansa da bu çalışma için gerekli veriler söz konusu dosyalardan aylık bazda çekilmiştir.
- Üretim Verileri: Üretim adedi her ay sonunda üretim müdürü tarafından tutulan üretim emirlerine ait Excel dosyalarından elde edilmiştir.
- Stok Verileri: Aylık stokta kalan değişkeni, her ay sonunda depo bölümü tarafından gerçekleştirilen fiili stok sayım sonuçlarından alınmıştır.

Analizlerde kullanılan hammadde tüketim değerleri, fiili üretim adetlerinin ürün reçetelerinde tanımlı birim kullanım miktarları üzerinden hammadde bazına indirgenmesiyle elde edilmiştir.

Farklı veri kaynaklarından elde edilen tüm bilgiler önce yıl, ay ve ürün kodu temelinde tek bir veri setinde birleştirilmiştir. Daha sonra, her kritik hammadde için ayrı bir model kurulacağı için bu birleşik veri seti hammadde türüne göre yeniden ayrıştırılmıştır. Böylece her biri 48 aylık kayıt içeren ve yalnızca ilgili hammaddeye ait zaman serisi bilgilerini barındıran 9 bağımsız veri seti oluşturulmuştur.

5.1.2 Veri setinin yapısı

Analiz ve modelleme için oluşturulan bu 9 ayrı veri setinin her biri, 48 aylık zaman serisi kayıtlarını içermektedir. Veri setleri, bir adet bağımlı (hedef) değişken ve beş adet bağımsız (açıklayıcı) değişkenden oluşmaktadır. Bu tez çalışmasında kullanılan tüm değişkenler, nitelikleri ve tanımlamaları ile çizelge 5.1'de özetlenmiştir.

Çizelge 5.1 Modelde kullanılan bağımlı ve bağımsız değişkenler

<i>Değişken Türü</i>	<i>Değişken Adı</i>	<i>Tanımı</i>
Bağımlı Değişken (Hedef)	Hammadde Tüketimi	Fiili üretim adetlerinin ürün reçetelerinde tanımlı birim kullanım miktarları üzerinden hammadde bazına indirgenmesi (kg).
Bağımsız Değişken (Açıklayıcı)	Yurtdışı Satış Adedi	İlgili ay içinde yurtdışına satılan nihai ürün (adet).
Bağımsız Değişken (Açıklayıcı)	Yurtiçi Satış Adedi	İlgili ay içinde yurtiçine satılan nihai ürün (adet).
Bağımsız Değişken (Açıklayıcı)	Fire Adedi	Üretim sürecinde veya sonrasında oluşan fire miktarı (adet).
Bağımsız Değişken (Açıklayıcı)	Aylık Stokta Kalan	Ay sonunda depoda fiili olarak sayılan nihai ürün stok miktarı (adet).
Bağımsız Değişken (Açıklayıcı)	Üretim Adedi	İlgili ay içinde üretilen ürün (adet).

Çizelge 5.1'de görüldüğü üzere, hammadde tüketimi (kg) hedef değişkeni öngörülme istenirken; satış adetleri, fire, stok ve üretim adetleri bu tüketimi etkileyen açıklayıcı faktörler olarak modele dahil edilmiştir.

5.2 Veri Ön İşleme

ML modellerinin başarısı, büyük ölçüde kullanılan verinin kalitesine bağlıdır. Ham veri setleri, modellerin performansını olumsuz etkileyebilecek eksik değerler, tutarsızlıklar veya farklı formatlar içerebilir. Ham veri setleri, modellemeye uygun hale getirilmek amacıyla veri ön işleme adımlarından geçirilmiştir.

Veri setleri zaman bilgisini ‘Yıl’ ve ‘Ay’ şeklinde ayrı sütunlarda tutmaktadır. Bu iki sütun birleştirilmiş ve özel bir fonksiyon aracılığıyla aylık frekansa sahip bir zaman serisi indeksine dönüştürülmüştür.

Ham veri setlerindeki yıl ve ay sütunları tam sayıya dönüştürülmüş ve tüm nicel değişkenler (yurt içi satış adedi, yurt dışı satış adedi vb.) sayısal tipine dönüştürülmüştür.

Veri ön işleme sürecinin ilk adımı olarak, çalışma kapsamındaki veri setleri (2021-2024) eksik gözlem (missing value) açısından incelenmiştir. Hem bağımlı değişken hem de bağımsız değişkenler üzerinde yapılan kontrolde herhangi bir eksik veriye rastlanmamıştır.

Veri ön işleme adımları kapsamında, model performansını olumsuz etkileyebilecek potansiyel aykırı değerlerin tespiti amacıyla veri seti incelenmiştir. Hammadde tüketim verileri analiz edildiğinde, özellikle yüksek adetli üretimin gerçekleştiği aylarda yüksek seviyelere ulaşan istatistiksel olarak aşırı (extreme) değerlerin varlığı gözlemlenmiştir.

Yapılan detaylı incelemede, bu yüksek değerli gözlemlerin veri giriş hatası, ölçüm hatası veya bir anomali olmadığı; aksine, incelenen döneme ait gerçek ve geçerli üretim süreçlerinin doğal bir sonucu olduğu tespit edilmiştir. Bu değerler, veri setinin doğal değişkenliğinin önemli bir parçasını oluşturmakta ve hammadde talebindeki zirve (peak) noktaları temsil etmektedir. Bu nedenle, söz konusu gözlemler aykırı değer olarak ele alınmamış ve veri setinin bütünlüğünü korumak, modelin bu kritik talep dalgalanmalarını da öğrenerek daha doğru öngörüler üretebilmesini sağlamak amacıyla analizden çıkarılmamıştır.

5.3 Modelleme Yaklaşımı ve Eğitim Stratejisi

Bu tez çalışmasının temel amacı, medikal sektörde faaliyet gösteren işletmenin 9 kritik hammaddesine ait tüketim dinamiklerini ML yöntemleri ile analiz ederek 2025 yılı

tüketimini öngörmektir. Her bir hammadde farklı ürünlerde kullanıldığı için, bu 9 kritik hammadde için birbirinden bağımsız 9 model geliştirilmiştir.

Geliştirilen modellerin başarımını artırmak ve 2025 yılı analizlerinde kullanılacak nihai algoritmalara karar vermek amacıyla, öncelikle 2021-2024 dönemi üzerinde sistematik bir geriye dönük test (backtesting) stratejisi uygulanmıştır. Bu strateji kapsamında veri seti kronolojik olarak ikiye ayrılmıştır: Toplam 48 aylık verinin %75'lik bölümü (1 Ocak 2021- 31 Aralık 2023 arası 36 ay) eğitim seti olarak; kalan %25'lik bölümü (1 Ocak 2024- 31 Aralık 2024 arası 12 ay) ise test seti olarak kullanılmıştır. Bu aşamada, modellerin 2024 yılı için ürettiği tahminler ile aynı yılın fiili tüketim verileri karşılaştırılmış; *MAPE* ve R^2 metrikleri bazında en düşük hatayı ve en yüksek açıklayıcılığı sunan modeller, 2025 yılı analizleri için referans kabul edilmiştir.

Modellerin geçmiş performansı 2024 verisi üzerinde doğrulandıktan sonra, çalışmanın temel hedefi olan 2025 yılı hammadde tüketim öngörülerinin üretilmesi aşamasına geçilmiştir. Ancak öngörme anında 2025 yılına ait bağımsız değişkenlerin fiili değerleri mevcut olmadığından iki aşamalı hibrit bir yaklaşım benimsenmiştir. Bu kurguda öncelikle 2025 yılına ait girdi değişkenleri ayrı zaman serisi modelleriyle öngörülmüş; ikinci aşamada ise elde edilen bu veriler kullanılarak nihai hammadde tüketim değerlerine ulaşılmıştır.

Bu kapsamda her bir bağımsız değişken, bağımsız bir zaman serisi problemi olarak ele alınmıştır. Gelecek dönem (2025) değerlerinin öngörülmesinde öncelikle klasik zaman serisi analiz yöntemlerinden biri olan SARIMA modeli uygulanmış ve öngörüler elde edilmiştir.

Ardından, verideki nonlineer ilişkileri yakalama kapasitesini artırmak ve daha güçlü genelleme performansı sağlamak amacıyla, NAR yapısı üzerinden öğrenme yapabilen ML tabanlı bir model geliştirilmiştir. Bu aşamada algoritma olarak GBR tercih edilmiştir. Modelin zaman serisi dinamiklerini daha iyi temsil edebilmesi amacıyla, geleneksel analizlerden türetilen lag_1, lag_12 ve roll_mean_3 (3 aylık hareketli ortalama) gibi

yapay özellikler modele dahil edilmiş ve 2025 yılının 12 aylık değerleri özyinelemeli bir strateji ile üretilmiştir.

2025 yılı analizlerinde kullanılacak en uygun öngörü yöntemini belirlemek ve modellerin tahmin performanslarını kıyaslamak amacıyla; klasik SARIMA yöntemi ile ML tabanlı NAR yaklaşımının sonuçları karşılaştırılmıştır. Performans değerlendirmesi kapsamında *RMSE* ve *MAPE* metrikleri hesaplanmıştır. Dokuz hammaddenin büyük kısmında NAR hem *RMSE* hem *MAPE* açısından SARIMA'ya göre daha düşük hata üretmiştir (Çizelge 5.8–5.16).

Bu doğrulama sonucunda, nihai tüketim/talep modeline girdi olarak kullanılacak 2025 bağımsız değişken setinin (X_{2025}) oluşturulmasında daha yüksek başarımlı gösteren NAR yaklaşımı tercih edilmiş ve bu veriler ikinci aşamadaki tüketim öngörü modelinde girdi olarak kullanılmıştır.

İkinci adımda, 2025 yılı hammadde tüketimini öngörmek için GBR, RF ve XGBoost Regresyonundan oluşan ana ML modelleri, öncelikle 2021-2024 verisinin tamamı kullanılarak eğitilmiştir. Ardından, R^2 skoruna göre en iyi performans gösteren nihai modele, bir önceki adımda oluşturulan X_{2025} seti girdi olarak verilmiş ve 2025 yılı aylık hammadde tüketim öngörülleri elde edilmiştir.

Modellerin geriye dönük test (backtesting) aşamalarında kullanılacak olan nihai hiperparametre değerleri, farklı parametre kombinasyonlarının backtesting aşamasındaki performansları karşılaştırılarak yapılmış ve en iyi sonucu veren hiperparametre yapısı tercih edilmiştir.

9 adet veri seti için hiperparametre yapısı değerleri çizelge 5.2'de verildiği gibi belirlenmiştir.

Çizelge 5.2 ML modellerine ait hiperparametre ayarları

<i>ML Modeli</i>	<i>Hiperparametre</i>	<i>Değer</i>
GBR	Ağaç Sayısı	700
	Öğrenme Oranı	0.05
	Maksimum Derinlik	3
XGBoost	Ağaç Sayısı	600
	Öğrenme Oranı	0.05
	Maksimum Derinlik	6
	Düzenleştirme terimi	1.0
RF	Ağaç Sayısı	500
	Yaprak Başına Asgari Örnek	2
	Maksimum Derinlik	8

5.4 Modelleme Sonuçları ve Değerlendirme

Bu bölümde, Bölüm 5.3'te açıklanan geriye dönük test stratejisinin çıktıları sunulmuştur.

Modellerin 2025 yılı için üreteceği tahminlerin güvenilirliğini ve geçerliliğini ampirik olarak kanıtlamak amacıyla, 5.3 bölümünde açıklanan geriye dönük test stratejisi uygulanmıştır. Yukarıda detayları verilen hiperparametre setleri ile yapılandırılan ve veri setinin %75'lik bölümü (2021-2023 dönemi) ile eğitilen ve %25'lik bölümü (2024 dönemi) ile test edilen GBR, RF ve XGBoost modellerinin karşılaştırmalı performans metrikleri çizelge 5.3'te sunulmuştur.

Geriye dönük test ve değerlendirme adımları Python ortamında yürütülmüş; veri işleme süreçlerinde pandas ve NumPy, ML modellerinin kurulmasında scikit-learn (GradientBoostingRegressor, RandomForestRegressor) ve XGBoost Regresyonu için xgboost kütüphanelerinden yararlanılmış, performans ölçütlerinin hesaplanmasında scikit-learn.metrics kullanılmıştır.

Modellerin güvenilirliğini belirlemek amacıyla birincil karar metriği olarak *MAPE* belirlenmiştir.

Çizelge 5.3 Hammadde bazında makine öğrenmesi modellerinin karşılaştırmalı performans analizi

<i>Hammadde Adı</i>	<i>Makine Öğrenmesi Modeli</i>	<i>R²</i>	<i>RMSE</i>	<i>MAPE</i>
Elastromer	GBR	0.966	1.498	5.22
	RF	0.963	1.560	5.57
	XGBoost	0.926	2.205	7.76
Acetal	GBR	0.909	13.965	4.13
	RF	0.817	19.816	6.48
	XGBoost	0.824	19.453	9.47
PC	GBR	0.847	66.175	8.02
	RF	0.834	69.185	8.41
	XGBoost	0.612	105.644	12.24
ABS 3864	GBR	0.351	226.926	12.69
	RF	0.774	133.865	7.50
	XGBoost	0.354	226.502	11.64
PC ABS-IMS	GBR	0.818	157.728	8.47
	RF	0.881	127.487	7.29
	XGBoost	0.334	301.498	16.12
PC ABS	GBR	0.900	38.473	4.65
	RF	0.799	54.481	6.89
	XGBoost	0.715	64.854	13.68
PC Violet	GBR	0.973	9.326	7.87
	RF	0.938	14.198	10.37
	XGBoost	0.896	18.300	14.89
Moblen	GBR	0.649	5.182	5.08
	RF	0.923	2.419	5.43
	XGBoost	0.953	1.893	3.47
PA66 GFR30	GBR	0.854	5.522	6.10
	RF	0.903	4.505	5.80
	XGBoost	0.724	7.580	11.11

Çizelge 5.3 incelendiğinde model performanslarının hammaddeye göre farklılaştığı görülmektedir. *MAPE* değerinin en düşük ve *R²* değerinin en yüksek olduğu model, her bir hammadde için “seçilen model” olarak belirlenmiş; bu seçimlere ilişkin sonuçlar aşağıdaki çizelge 5.4’te özetlenmiştir.

Çizelge 5.4 Hammadde bazında nihai olarak seçilen makine öğrenmesi modelleri

<i>Hammadde Adı</i>	<i>ML Modeli</i>	<i>R²</i>	<i>RMSE</i>	<i>MAPE</i>
Elastromer	GBR	0.966	1.498	5.22
Acetal	GBR	0.909	13.965	4.13
PC	GBR	0.847	66.175	8.02
ABS 3864	RF	0.774	133.865	7.50
PC ABS-IMS	RF	0.881	127.487	7.29
PC ABS	GBR	0.900	38.473	4.65
PC Violet	GBR	0.973	9.326	7.87
Moblen	XGBoost	0.953	1.893	3.47
PA66 GFR30	RF	0.903	4.505	5.80

Seilen bu modeller, ilgili hammaddelerin 2025 yılı talep ngrlerinin retilmesinde nihai ngr modeli olarak kullanılmıřtır.

Bununla birlikte, ABS 3864 ve PC hammaddelerinde gzlemlenen grece dřk R^2 deęerleri ile yksek *MAPE* oranlarının, bu iki kalemin veri yapısındaki istatistiksel zorluklardan kaynaklandıęı deęerlendirilmektedir. Detaylı incelemeler sonucunda, sz konusu hammaddelere ait tketim serilerinin “kesikli talep” olarak adlandırılan bir yapı sergiledięi grlmřtr. Bu yapı, talebin dzenli bir akıř izlememesi; bazı aylarda tketime sıfıra yaklařtıęı, izleyen dnemlerde ise sipariř bazlı retim dinamikleri nedeniyle ani ve ok yksek sıramaların ortaya ıkması řeklinde karakterize edilmektedir.

Bu denli yksek oynaklık karřısında modelin, sz konusu ani zirve ve dip noktalarını “ezberlemek” yerine serinin ana eęilimini yakalamayı tercih etmesi, istatistiksel aıdan ařırı ęrenme (overfitting) riskinden kaındıęını gstermektedir. Bařka bir ifadeyle, modelin verideki rastlantısal grlty deęil, temelindeki sistematik rnty ęrendięi anlařılmaktadır. Dolayısıyla, modelin bu zorlu veri yapısında dahi ana trend ynn bařarıyla tespit etmesi, iřletme planlaması aısından ani talep řoklarına karřı ařırı tepki vermeyen, daha kararlı ve gvenilir bir temel senaryo sunduęunu ortaya koymaktadır.

5.5 2025 Yılı Talep ngr Sonuları

Blm 5.4’te, farklı ML algoritmalarının 2024 test verisi zerindeki performansı karřılařtırılmıř ve her hammadde iin en bařarılı modeli belirleyen analizler tamamlanmıřtır. Blm 5.5’te ise 2025 yılı nihai hammadde tketime ngrmek iin bağımsız deęiřkenlerin ngrlmesinde kullanılan yntemler ve bu yntemlerin karřılařtırmalı sonuları sunulmuřtur. Bu iki yntemden en iyi performansı gsteren yntem belirlenerek, 2025 yılı hammadde tketime ngrlmřtr.

5.5.1 SARIMA analizi uygulaması

Bu tezin ikinci aşamasında, hammadde ihtiyaç planlamasında temel belirleyici olan beş temel bağımsız değişkenin ("Yurt Dışı Satış Adedi", "Yurt İçi Satış Adedi", "Fire Adedi", "Aylık Stokta Kalan" ve "Üretim Adedi") 2025 yılına ait aylık öngörüler üretilmiştir. 9 kritik hammadde için kullanılan tüm veri setlerinin aylık frekansta olması ve 12 dönemlik belirgin mevsimsel örüntüler sergilemesi nedeniyle, mevsimsel bileşenleri açık biçimde modelleyebilen SARIMA yaklaşımı tercih edilmiştir.

SARIMA uygulaması Python programlama dilinde gerçekleştirilmiştir. Veri hazırlama ve manipülasyon aşamalarında Pandas ve NumPy kütüphanelerinden yararlanılmış; serilerin durağanlık analizleri statsmodels kütüphanesinde yer alan Genişletilmiş Dickey-Fuller (ADF) testi ile gerçekleştirilmiştir. Model kurma aşamasında statsmodels.tsa.statespace modülü, modellerin başarımını ölçen hata metriklerinin hesaplanmasında ise scikit-learn (sklearn.metrics) kütüphanesi kullanılmıştır.

Elde edilen SARIMA sonuçları, çalışmanın ilerleyen aşamalarında uygulanacak olan ve serilerin nonlinear dinamiklerini modelleyen NAR yöntemi ile karşılaştırmalı analize tabi tutulmuştur. Böylelikle, her bir bağımsız değişken için tahmin hatasını minimize eden en uygun modelleme yaklaşımının belirlenmesi hedeflenmiştir.

Tüm seriler aylık olduğundan mevsimsellik periyodu $s = 12$ olarak sabitlenmiştir. Modelleme aşamasında, serilerin varyansını dengelemek ve sıfır değerlerde log dönüşümünü mümkün kılmak amacıyla bağımsız değişkenlere $\ln(x + 1)$ dönüşümü uygulanmıştır; öngörüler raporlanmadan önce $e^y - 1$ ile tekrar orijinal ölçeğe geri dönüştürülmüştür.

SARIMA modellemesinde kullanılan bütünleşik bileşenler, mevsimsel olmayan trendi temsil eden d ve mevsimsel bileşenleri temsil eden D olmak üzere iki ayrı düzeyde ele alınır. Bu parametrelerin belirlenmesi amacıyla durağanlık analizleri aşağıdaki sırayla gerçekleştirilmiştir:

Orijinal Serinin İlk Durağanlık Kontrolü: Öncelikle, orijinal seriye ADF testi uygulanmıştır. Bu, serinin genel durağanlık karakteri hakkında ilk izlenimi edinmek için yapılmıştır.

- Durağanlık Durumu: ADF testinin sonucunda $p < 0.05$ ise, birim kökün varlığı tespit edilmemiş ve SARIMA modelinin durağanlık koşulu sağlandığı için $d = 0$ alınmıştır.
- Durağan Olmama Durumu: ADF testinin sonucunda $p \geq 0.05$ ise, birim kökün varlığı tespit edilmiş ve SARIMA modelinin durağanlık koşulunu sağlamak amacıyla birinci fark alma işlemi uygulanmıştır ve $d = 1$ alınmıştır.

Her bir bağımsız değişken serisi için ($s = 12$), ADF testi sonucu belirlenen d değeri ile en iyi model parametrelerini (p, q, P, D, Q) bulmak üzere Grid Search yöntemi kullanılmıştır.

Mevsimsel olmayan bileşenler için $p \in \{0, 1, 2\}$, $q \in \{0, 1, 2\}$ ve mevsimsel bileşenler için $P \in \{0, 1\}$, $D \in \{0, 1\}$, $Q \in \{0, 1\}$ aralıkları sistematik olarak taranmıştır. Her bir seri için kurulan model kombinasyonlarının uygunluğu Akaike Bilgi Kriteri (Akaike Information Criterion-AIC) ile değerlendirilmiş ve ilgili seri için en düşük AIC değerine sahip model en uygun model olarak seçilmiştir. Seçilen modellerin 2024 yılı test verileri üzerindeki tahmin başarısı *RMSE* ve *MAPE* metrikleri ile hesaplanmıştır.

Nihai aşamada, her bir bağımsız değişken serisi için seçilen en uygun SARIMA modeli, tüm mevcut veri (2021–2024) üzerinde yeniden eğitilmiş ve 2025 yılının 12 ayı için öngörü değerleri üretilmiştir.

Aşağıda çizelge 5.5'te Elastromer hammaddesine ait 5 adet bağımsız değişken için gerçekleştirilen ADF analizi sonuçları verilmiştir.

Çizelge 5.5 Bağımsız değişkenlere ait Genişletilmiş Dickey–Fuller (ADF) testi sonuçları (orijinal seri)

<i>Bağımsız Değişken</i>	<i>Genişletilmiş Dickey-Fuller (ADF) Testi Sonuçları</i>
Yurt Dışı Satış Adedi	<pre> ----- ADF TESTİ ----- Değişken: Yurt Dışı Satış Adeti Seri: ModelOlcek ADF istatistiği : -7.2273 p-değeri : 0.0000 Kritik değerler : %1=-3.5778 %5=-2.9253 %10=-2.6008 Sonuç : DURAĞAN (H0 reddedildi, p<=0.05) [Yurt Dışı Satış Adeti] Seri durağan → d=0. </pre>
Yurt İçi Satış Adedi	<pre> ----- ADF TESTİ ----- Değişken: Yurt İçi Satış Adeti Seri: ModelOlcek ADF istatistiği : -7.9931 p-değeri : 0.0000 Kritik değerler : %1=-3.5778 %5=-2.9253 %10=-2.6008 Sonuç : DURAĞAN (H0 reddedildi, p<=0.05) [Yurt İçi Satış Adeti] Seri durağan → d=0. </pre>
Fire Adedi	<pre> ----- ADF TESTİ ----- Değişken: Fire Adeti Seri: ModelOlcek ADF istatistiği : -6.9118 p-değeri : 0.0000 Kritik değerler : %1=-3.5778 %5=-2.9253 %10=-2.6008 Sonuç : DURAĞAN (H0 reddedildi, p<=0.05) [Fire Adeti] Seri durağan → d=0. </pre>
Aylık Stokta Kalan Adedi	<pre> ----- ADF TESTİ ----- Değişken: Aylık Stokta Kalan Seri: ModelOlcek ADF istatistiği : -2.8642 p-değeri : 0.0497 Kritik değerler : %1=-3.5813 %5=-2.9268 %10=-2.6015 Sonuç : DURAĞAN (H0 reddedildi, p<=0.05) [Aylık Stokta Kalan] Seri durağan → d=0. </pre>
Üretim Adedi	<pre> ----- ADF TESTİ ----- Değişken: Üretim Adeti Seri: ModelOlcek ADF istatistiği : -5.5345 p-değeri : 0.0000 Kritik değerler : %1=-3.5778 %5=-2.9253 %10=-2.6008 Sonuç : DURAĞAN (H0 reddedildi, p<=0.05) [Üretim Adeti] Seri durağan → d=0. </pre>

ADF testi sonrasında elastomer hammaddesine ait bütün bağımsız değişkenlerin fark alınmadan durağan çıktığı görülmüştür.

Durağanlık analizini takiben, beş bağımsız değişken için en uygun SARIMA modeli her bir seri özelinde en düşük AIC kriterine göre belirlenmiştir. Elastomer hammaddesine ait

bağımsız değişkenler için SARIMA modelleri ve AIC sonuçları çizelge 5.6'da sunulmuştur.

Çizelge 5.6 Elastomer bağımsız değişkenleri için seçilen SARIMA modelleri ve hata metrikleri

<i>Bağımsız Değişken</i>	<i>Model</i>	<i>AIC</i>
Yurt Dışı Satış Adedi	<i>SARIMA</i> (2,0,2)(0,1,0) ₁₂	66
Yurt İçi Satış Adedi	<i>SARIMA</i> (1,0,0)(0,1,0) ₁₂	58
Fire Adedi	<i>SARIMA</i> (0,0,2)(0,1,0) ₁₂	49
Aylık Stokta Kalan Adedi	<i>SARIMA</i> (2,0,0)(0,1,0) ₁₂	27
Üretim Adedi	<i>SARIMA</i> (0,0,1)(0,1,0) ₁₂	25

Bu sonuçlar doğrultusunda, Elastomer hammaddesine ait her bir bağımsız değişken için en uygun SARIMA modeli seçilmiştir. Aynı analiz akışı (orijinal seri ADF testi, gerekirse fark alma ile durağanlaştırma ve AIC minimizasyonuna dayalı grid search ile parametre seçimi) çalışmada yer alan diğer 8 kritik hammadde için de birebir uygulanmıştır. EK 1'de 8 kritik hammadde için SARIMA uygulama adımları verilmiştir.

Bu kapsamda, her hammadde için beş bağımsız değişkenin her biri ayrı bir zaman serisi olarak ele alınmış; her seri için SARIMA model yapısı belirlenmiş ve model seçim kriteri olarak AIC değeri kullanılmıştır.

Çizelge 5.7'de çalışmada yer alan kritik hammaddeler için seçilen SARIMA model yapıları toplu olarak sunulmuştur.

Çizelge 5.7 Hammaddelere ait bağımsız değişkenler için seçilen SARIMA modelleri

<i>Hammadde Adı</i>	<i>Bağımsız Değişken</i>	<i>Model</i>	<i>AIC</i>
Elastromer	Yurt Dışı Satış Adedi	SARIMA (2, 0, 2)(0, 1, 0) ₁₂	66
	Yurt İçi Satış Adedi	SARIMA (1, 0, 0)(0, 1, 0) ₁₂	58
	Fire Adedi	SARIMA (0, 0, 2)(0, 1, 0) ₁₂	49
	Aylık Stokta Kalan Adedi	SARIMA (2, 0, 0)(0, 1, 0) ₁₂	27
	Üretim Adedi	SARIMA (0, 0, 1)(0, 1, 0) ₁₂	25
Acetal	Yurt Dışı Satış Adedi	SARIMA (1, 0, 1)(0, 1, 0) ₁₂	72
	Yurt İçi Satış Adedi	SARIMA (0, 0, 2)(1, 0, 0) ₁₂	59
	Fire Adedi	SARIMA (2, 0, 2)(0, 1, 1) ₁₂	24
	Aylık Stokta Kalan Adedi	SARIMA (1, 0, 0)(0, 1, 0) ₁₂	29
	Üretim Adedi	SARIMA (0, 1, 0)(0, 1, 0) ₁₂	53
PC	Yurt Dışı Satış Adedi	SARIMA (0, 0, 0)(1, 1, 1) ₁₂	24
	Yurt İçi Satış Adedi	SARIMA (0, 0, 0)(0, 1, 0) ₁₂	45
	Fire Adedi	SARIMA (1, 1, 2)(0, 1, 0) ₁₂	17
	Aylık Stokta Kalan Adedi	SARIMA (2, 1, 0)(1, 1, 1) ₁₂	11
	Üretim Adedi	SARIMA (0, 1, 0)(1, 0, 0) ₁₂	46
ABS 3864	Yurt Dışı Satış Adedi	SARIMA (2, 0, 1)(1, 1, 1) ₁₂	19
	Yurt İçi Satış Adedi	SARIMA (2, 1, 1)(0, 1, 0) ₁₂	35
	Fire Adedi	SARIMA (0, 1, 2)(1, 1, 1) ₁₂	8
	Aylık Stokta Kalan Adedi	SARIMA (0, 1, 1)(1, 1, 1) ₁₂	4
	Üretim Adedi	SARIMA (0, 0, 2)(1, 1, 0) ₁₂	9
PC ABS - IMS	Yurt Dışı Satış Adedi	SARIMA (0, 0, 2)(0, 1, 1) ₁₂	56
	Yurt İçi Satış Adedi	SARIMA (2, 1, 2)(0, 1, 1) ₁₂	29
	Fire Adedi	SARIMA (1, 0, 2)(0, 1, 1) ₁₂	75
	Aylık Stokta Kalan Adedi	SARIMA (1, 0, 2)(0, 1, 1) ₁₂	-10
	Üretim Adedi	SARIMA (0, 1, 2)(1, 1, 1) ₁₂	46
PC ABS	Yurt Dışı Satış Adedi	SARIMA (0, 0, 1)(0, 1, 0) ₁₂	81
	Yurt İçi Satış Adedi	SARIMA (2, 1, 1)(0, 0, 1) ₁₂	69
	Fire Adedi	SARIMA (1, 0, 2)(0, 1, 0) ₁₂	63
	Aylık Stokta Kalan Adedi	SARIMA (1, 0, 0)(0, 1, 1) ₁₂	6
	Üretim Adedi	SARIMA (1, 0, 0)(0, 1, 0) ₁₂	76
PC Violet	Yurt Dışı Satış Adedi	SARIMA (0, 0, 2)(1, 1, 1) ₁₂	73
	Yurt İçi Satış Adedi	SARIMA (0, 1, 2)(1, 1, 1) ₁₂	102
	Fire Adedi	SARIMA (1, 0, 2)(0, 1, 1) ₁₂	119
	Aylık Stokta Kalan Adedi	SARIMA (0, 0, 2)(1, 1, 1) ₁₂	73
	Üretim Adedi	SARIMA (0, 1, 2)(0, 1, 1) ₁₂	69
Moblen	Yurt Dışı Satış Adedi	SARIMA (0, 1, 1)(1, 0, 0) ₁₂	46
	Yurt İçi Satış Adedi	SARIMA (1, 0, 1)(0, 1, 0) ₁₂	63
	Fire Adedi	SARIMA (0, 0, 0)(0, 1, 0) ₁₂	91
	Aylık Stokta Kalan Adedi	SARIMA (0, 0, 2)(1, 1, 1) ₁₂	12
	Üretim Adedi	SARIMA (2, 0, 0)(0, 1, 0) ₁₂	58
PA66 GFR30	Yurt Dışı Satış Adedi	SARIMA (2, 0, 0)(1, 0, 1) ₁₂	88
	Yurt İçi Satış Adedi	SARIMA (2, 1, 0)(0, 1, 1) ₁₂	25
	Fire Adedi	SARIMA (1, 1, 0)(1, 0, 1) ₁₂	17
	Aylık Stokta Kalan Adedi	SARIMA (0, 1, 1)(0, 0, 0) ₁₂	-3
	Üretim Adedi	SARIMA (0, 0, 1)(0, 1, 1) ₁₂	1

SARIMA modeli ile elde edilen tahmin sonuçları incelendiğinde, hata metriklerinin (*RMSE* ve *MAPE*) hammadde türlerine ve değişkenlerin sergilediği dinamiklere göre farklılık gösterdiği görülmektedir. Üretim ve satış adetlerindeki *MAPE* değerlerinin, fire ve stok adetlerine göre nispeten daha yüksek olduğu gözlemlenmiştir. Bu durum, üretim ve satış verilerinin dışsal faktörlerden (pazar dalgalanmaları, sipariş iptalleri vb.) daha fazla etkilendiğini ve serilerdeki oynaklığın daha yüksek olduğunu göstermektedir.

Çalışmanın bir sonraki aşamasında doğrusal olmayan ilişkileri modelleyebilen nonlinear otoregresif zaman serisi yaklaşımı SARIMA ile karşılaştırılacaktır.

5.5.2 Nonlinear Otoregresif Zaman Serisi analizi uygulaması

Nihai hammadde tüketimi öngörüsü için kullanılan bağımsız değişkenlerin ("Yurt Dışı Satış Adedi", "Yurt İçi Satış Adedi", "Fire Adedi", "Aylık Stokta Kalan" ve "Üretim Adedi") 2025 yılına ait öngörüler, nonlinear otoregresif bir yaklaşımla, her bir değişken serisi için ayrı ayrı gerçekleştirilmiştir.

Bu süreç, tarihsel zaman serisi verilerinin nonlinear bir makine öğrenimi modeli ile ilişkilendirilerek geleceğe dönük olarak özyinelemeli (recursive) tahmin edilmesini içerir.

Geleneksel zaman serisi modellerinin (ARIMA/SARIMA) yakalamakta zorlandığı karmaşık trendleri, ani kırılmaları ve nonlinear ilişkileri daha doğru modelleyebilmek amacıyla otoregresif çerçevede GBR algoritması kullanılmıştır. GBR, geçmiş gözlemler ile gelecekteki gözlemler arasındaki karmaşık bağımlılıkları öğrenme yeteneği nedeniyle tercih edilmiştir.

Her bir bağımsız değişken serisi (örneğin "Yurt Dışı Satış Adedi"), kendisinin geçmiş değerleri kullanılarak zenginleştirilmiştir. Modelin zamansal bağımlılıkları yakalaması için aşağıdaki özellikler oluşturulmuştur:

- **Ay ve Yıl Bilgisi ($x_{ay}, x_{yıl}$):** Uzun vadeli trendleri ve sabit yıllık mevsimsellik etkilerini yakalamak amacıyla ilgili aya ve yıla karşılık gelen numerik değerler modele dâhil edilmiştir.
- **Bir Aylık Gecikme (lag_1):** Serinin bir önceki aydaki gerçekleşen veya tahmin edilen değeri (x_{t-1}).
- **On İki Aylık Gecikme (lag_12):** Serinin bir önceki yılın aynı aydaki değeri (x_{t-12}). Bu özellik, yıllık döngüsel mevsimselliğin etkisini modellemek için kritik öneme sahiptir.
- **Üç Aylık Hareketli Ortalama (roll_mean_3):** Serinin son üç ayının ortalaması ($\frac{x_{t-1}+x_{t-2}+x_{t-3}}{3}$). Bu, serideki kısa vadeli dalgalanmaları ve anlık gürültüyü yumuşatarak ana trendi yakalamayı kolaylaştıran bir özelliktir.

Her bir bağımsız değişken serisi için (örneğin "Yurt İçi Satış Adeti"), tarihsel veriler (2021-2024 dönemi) kullanılarak ayrı bir GBR modeli eğitilmiştir. Eğitim sonrasında, 2025 yılına ait 12 aylık tahminler özyinelemeli (recursive) bir döngü ile elde edilmiştir. Bu döngü aşamaları aşağıdaki gibidir:

Başlangıç Noktası (Ocak 2025): 2025 yılının ilk ayı olan ocak ayı tahmini yapılırken, gecikmeli özellikler (lag_1, lag_12, roll_mean_3) için gerekli olan tüm değerler 2024 yılının gerçekleşmiş, tarihsel verilerinden sağlanmıştır.

Zincirleme Tahmin (Şubat-Aralık 2025): Şubat 2025 tahmini yapılırken kullanılan lag_1 değeri, Ocak 2025 için model tarafından üretilen tahminden alınmıştır. Benzer şekilde, kayar ortalama (roll_mean_3) gibi diğer özellikler de serinin artık hem gerçekleşmiş geçmiş değerlerini hem de modelin kendi öngörülerini içeren genişletilmiş bir zaman serisi üzerinden hesaplanmıştır.

Bu özyinelemeli yapı, modelin bir sonraki adımı tahmin etmek için sürekli olarak bir önceki adımda ürettiği tahmini kullanmasını sağlar. Böylece, 2025 yılının tamamına ait bağımsız değişkenlerin tahmini serileri oluşturularak, nihai hammadde tüketimi öngörüsünü yapacak ana model için gerekli olan gelecek dönem bağımsız değişken matrisi (X_{2025}) elde edilmiştir.

2025 yılı öngörülerinin üretilebilmesi için, nihai modele girdi sağlayan bağımsız değişkenler iki farklı yöntemle tahmin edilmiştir: NAR ve SARIMA modelidir. Her iki yöntem, 2024 yıl sonuna kadarki verilerle eğitilerek 2025 yılı için öngörüler üretmiştir.

Bu aşamada, bağımsız değişkenlere ait 2025 Ocak–Eylül gerçekleşen değerleri kullanılarak NAR ve SARIMA öngörülerini karşılaştırılmıştır.

Bu kritik karşılaştırma, modellerin sadece geçmiş veriye ne kadar uyduğunu değil, gerçek dünya öngörü başarısını da doğrulanmış veriler üzerinden kesin bir şekilde ölçmemizi sağlamıştır. Algoritmaların 2025 öngörü performansları, temel hata metrikleri olan *RMSE* ve *MAPE* değerleri incelenerek değerlendirilmiş ve nihai olarak her bir hammadde için en uygun öngörü yöntemine bu metrikler baz alınarak kararlaştırılmıştır.

Bu çerçevede, her bir hammaddeye ait bağımsız değişkenler için NAR ve SARIMA modellerinin 2025 gerçek değerleri (Ocak-Eylül) ile karşılaştırmalı performanslarını gösteren tablolar çizelge 5.8 - 5.16 arasında sunulmuştur.

Çizelge 5.8 Elastromer hammaddesi için NAR ve SARIMA modellerinin öngörü performans metriklerinin karşılaştırılması

<i>Bağımsız Değişken</i>	<i>NAR</i>		<i>SARIMA</i>	
	<i>RMSE</i>	<i>MAPE</i>	<i>RMSE</i>	<i>MAPE</i>
Yurt Dışı Satış Adedi	468	2.55	533	4.67
Yurt İçi Satış Adedi	213	6.57	769	7.90
Fire Adedi	2	5.32	104	10.44
Aylık Stokta Kalan Adedi	115	5.42	1465	9.27
Üretim Adedi	613	3.97	738	8.70

Çizelge 5.9 Acetal hammaddesi için NAR ve SARIMA modellerinin öngörü performans metriklerinin karşılaştırılması

<i>Bağımsız Değişken</i>	<i>NAR</i>		<i>SARIMA</i>	
	<i>RMSE</i>	<i>MAPE</i>	<i>RMSE</i>	<i>MAPE</i>
Yurt Dışı Satış Adedi	437	4.39	351	8.58
Yurt İçi Satış Adedi	181	4.23	1924	10.35
Fire Adedi	2	3.11	17	4.89
Aylık Stokta Kalan Adedi	962	7.26	637	8.30
Üretim Adedi	211	5.21	636	9.70

Çizelge 5.10 PC hammaddesi için NAR ve SARIMA modellerinin öngörü performans metriklerinin karşılaştırılması

<i>Bağımsız Değişken</i>	<i>NAR</i>		<i>SARIMA</i>	
	<i>RMSE</i>	<i>MAPE</i>	<i>RMSE</i>	<i>MAPE</i>
Yurt Dışı Satış Adedi	173	4.53	2848	9.94
Yurt İçi Satış Adedi	152	3.96	3617	9.40
Fire Adedi	14	5.01	75	7.05
Aylık Stokta Kalan Adedi	460	2.60	4510	9.07
Üretim Adedi	358	6.59	474	9.49

Çizelge 5.11 ABS 3864 hammaddesi için NAR ve SARIMA modellerinin öngörü performans metriklerinin karşılaştırılması

<i>Bağımsız Değişken</i>	<i>NAR</i>		<i>SARIMA</i>	
	<i>RMSE</i>	<i>MAPE</i>	<i>RMSE</i>	<i>MAPE</i>
Yurt Dışı Satış Adedi	283	6.08	1383	9.57
Yurt İçi Satış Adedi	106	6.47	651	9.06
Fire Adedi	25	9.68	100	11.77
Aylık Stokta Kalan Adedi	407	5.46	940	10.75
Üretim Adedi	674	6.97	974	9.20

Çizelge 5.12 PC ABS-IMS hammaddesi için NAR ve SARIMA modellerinin öngörü performans metriklerinin karşılaştırılması

<i>Bağımsız Değişken</i>	<i>NAR</i>		<i>SARIMA</i>	
	<i>RMSE</i>	<i>MAPE</i>	<i>RMSE</i>	<i>MAPE</i>
Yurt Dışı Satış Adedi	176	3.85	215	8.03
Yurt İçi Satış Adedi	223	8.58	5215	8.67
Fire Adedi	5	8.89	47	9.79
Aylık Stokta Kalan Adedi	234	2.70	1716	7.47
Üretim Adedi	438	1.56	756	8.68

Çizelge 5.13 PC ABS hammaddesi için NAR ve SARIMA modellerinin öngörü performans metriklerinin karşılaştırılması

<i>Bağımsız Değişken</i>	<i>NAR</i>		<i>SARIMA</i>	
	<i>RMSE</i>	<i>MAPE</i>	<i>RMSE</i>	<i>MAPE</i>
Yurt Dışı Satış Adedi	94	5.38	2180	6.24
Yurt İçi Satış Adedi	59	4.16	871	6.13
Fire Adedi	2	9.74	44	7.73
Aylık Stokta Kalan Adedi	265	2.96	687	9.84
Üretim Adedi	342	3.37	674	7.42

Çizelge 5.14 PC Violet hammaddesi için NAR ve SARIMA modellerinin öngörü performans metriklerinin karşılaştırılması

<i>Bağımsız Değişken</i>	<i>NAR</i>		<i>SARIMA</i>	
	<i>RMSE</i>	<i>MAPE</i>	<i>RMSE</i>	<i>MAPE</i>
Yurt Dışı Satış Adedi	56	1.32	1343	7.11
Yurt İçi Satış Adedi	61	2.45	178	6.28
Fire Adedi	2	1.79	26	7.92
Aylık Stokta Kalan Adedi	480	4.29	957	7.32
Üretim Adedi	141	1.72	336	6.07

Çizelge 5.15 Moblen hammaddesi için NAR ve SARIMA modellerinin öngörü performans metriklerinin karşılaştırılması

<i>Bağımsız Değişken</i>	<i>NAR</i>		<i>SARIMA</i>	
	<i>RMSE</i>	<i>MAPE</i>	<i>RMSE</i>	<i>MAPE</i>
Yurt Dışı Satış Adedi	145	2.23	627	7.65
Yurt İçi Satış Adedi	176	2.91	762	7.13
Fire Adedi	2	1.91	28	6.63
Aylık Stokta Kalan Adedi	709	4.16	956	6.27
Üretim Adedi	212	2.50	740	4.78

Çizelge 5.16 PA66 GFR30 hammaddesi için NAR ve SARIMA modellerinin öngörü performans metriklerinin karşılaştırılması

<i>Bağımsız Değişken</i>	<i>NAR</i>		<i>SARIMA</i>	
	<i>RMSE</i>	<i>MAPE</i>	<i>RMSE</i>	<i>MAPE</i>
Yurt Dışı Satış Adedi	119	4.45	842	7.33
Yurt İçi Satış Adedi	98	5.73	913	7.71
Fire Adedi	4	8.28	98	9.71
Aylık Stokta Kalan Adedi	248	2.86	811	8.12
Üretim Adedi	328	4.41	1850	7.88

Yukarıdaki çizelge 5.8 - 5.16 arasında sunulan karşılaştırmalı performans metrikleri incelendiğinde, NAR yaklaşımının SARIMA modeline kıyasla genel olarak üstün bir öngörü başarısı sergilediği görülmektedir.

Özellikle *MAPE* değerleri baz alındığında, NAR modelinin tutarlı bir şekilde daha düşük hata oranları elde ettiği tespit edilmiştir. *RMSE* metriklerinde de benzer bir trend gözlemlenmiş, NAR modelinde kullanılan *RMSE* değerleri, SARIMA'ya göre belirgin ölçüde düşük tutmayı başarmıştır. Bu durum, NAR modelinin 2025 yılı gerçekleşen değerlere daha yakın tahminler ürettiğini göstermektedir.


Bu bulgular doğrultusunda, 2025 yılı bağımsız değişken öngörülerinin oluşturulmasında NAR yaklaşımı tercih edilmiştir. NAR yöntemi ile öngörülen bu girdiler kullanılarak 2025 yılı hammadde tüketim talep modeli çalıştırılmış ve 9 kritik hammadde için 2025 yılına ait aylık tüketim miktarı öngörülerinde elde edilmiştir. Üretilen öngörü değerleri çizelge 5.17'de sunulmuştur.

Çizelge 5.17 Hammadde bazında seçilen model ile 2025 yılı aylık öngörülen tüketim miktarları (kg)


Ay	Elastromer	Acetal	PC	ABS 3864	PC ABS-IMS	PC ABS	PC Violet	Moblen	PA66 GFR30
Oca.	30.32	131.85	863.63	1453.86	1564.18	193.22	74.25	20.19	53.05
Şub.	23.86	93.25	787.81	1321.13	723.64	139.94	77.35	23.88	55.67
Mar.	10.32	122.62	544.88	1466.64	874.20	359.14	130.10	25.92	83.37
Nis.	24.29	85.26	652.66	1443.51	900.52	242.96	118.45	35.05	52.67
May.	12.53	169.02	487.81	1389.02	1542.71	354.08	118.11	30.12	69.50
Haz.	12.90	77.06	547.45	1473.73	898.28	208.55	110.00	31.29	44.02
Tem.	31.12	182.69	838.10	1398.92	1380.59	242.82	113.45	31.33	34.34
Ağu.	12.30	108.07	888.98	1490.74	1381.58	301.50	107.64	29.07	44.00
Eyl.	31.83	162.64	940.67	1484.69	623.55	307.92	115.54	28.84	42.90
Eki.	27.16	82.68	901.13	1505.47	1315.76	208.58	109.31	24.92	43.98
Kas.	10.32	113.56	947.05	1816.65	883.78	111.43	253.18	20.49	31.01
Ara.	22.55	92.59	576.44	1817.59	1138.43	90.06	83.84	32.17	36.54

Çizelge 5.17'de sunulan 2025 yılı kilogram bazlı öngörüler, 9 kritik hammadde için beklenen talep seyrini ortaya koymaktadır. Bu stratejik çıktıların etkinliğini bilimsel bir zeminde değerlendirmek adına, 2025 yılının ilk aylarında gerçekleşen fiili tüketim değerleri ile modelin ürettiği öngörülen talep değerlerinin karşılaştırmalı analizi büyük


önem taşımaktadır. Aşağıdaki verilen şekillerde modelin pratik uygulamadaki performansını detaylıca incelememizi sağlamaktadır.




Şekil 5.1 Elastomer hammaddesi için 2025 yılı gerçekleşen ve öngörülen tüketim karşılaştırması




Şekil 5.2 Acetal Hammaddesi için 2025 yılı gerçekleşen ve öngörülen tüketim karşılaştırması




Şekil 5.3 PC Hammaddesi için 2025 yılı gerçekleşen ve öngörülen tüketim karşılaştırması




Şekil 5.4 ABS 3864 Hammaddesi için 2025 yılı gerçekleşen ve öngörülen tüketim karşılaştırması




Şekil 5.5 PC ABS-IMS Hammaddesi için 2025 yılı gerçekleşen ve öngörülen tüketim karşılaştırması




Şekil 5.6 PC ABS Hammaddesi için 2025 yılı gerçekleşen ve öngörülen tüketim karşılaştırması



Şekil 5.7 PC Violet Hammaddesi için 2025 yılı gerçekleşen ve öngörülen tüketim karşılaştırması



Şekil 5.8 Moblen Hammaddesi için 2025 yılı gerçekleşen ve öngörülen tüketim karşılaştırması



Şekil 5.9 PA66 GFR30 Hammaddesi için 2025 yılı gerçekleşen ve öngörülen tüketim karşılaştırması

Şekil 5.4'te verilen ABS 3864 hammaddesine ait grafik, bu hammaddenin tüketimindeki doğal dalgalanmaları yansıtmaktadır. Geçmiş yıllarda tüketim düzenli bir yapı göstermediği için model, bazı ayları doğru tahmin ederken bazı aylarda gerçek değerlerden sapmaktadır. Bunun nedeni modelin öğrenme kapasitesindeki bir yetersizlikten ziyade; veri setinin doğasında var olan düzensizliğin ve sipariş bazlı üretim dinamiklerinin bir sonucudur. Özellikle ani artış veya düşüşlerin olduğu aylarda fark oluşması normaldir ve veri yapısıyla tamamen tutarlıdır.

Çizelge 5.17'de sunulan 2025 yılı hammadde tüketim öngörü değerleri, kendi başlarına bir sonuç olmaktan ziyade, işletmenin proaktif kararlar alabilmesi ve etkin stok yönetimi stratejileri geliştirebilmesi için stratejik birer karar destek girdisi niteliği taşımaktadır.

5.6 Öngörü Sonuçlarının Stok Yönetimine Uygulanması

Bu tez çalışmasının nihai hedeflerinden biri, Bölüm 5.5'te elde edilen ML temelli talep öngörülerinin, işletmenin stok yönetimi politikalarını iyileştirmek amacıyla kullanılmasıdır. Bölüm 2.4.3'te tanımlanan teorik stok yönetimi kavramları, bu bölümde

2025 yılı için elde edilen ampirik verilerle birleştirilerek işletmeye yönelik somut parametreler hesaplanmıştır.

Hesaplamalara başlamadan önce, işletmenin operasyonel verileri gerektiren bazı temel varsayımların yapılması zorunludur:

1. Hizmet Seviyesi (Z): Medikal sektörün kritikliği göz önünde bulundurularak, stokluz kalmama (stock-out) riskini minimize etmek amacıyla %95 hizmet seviyesi hedeflenmiştir. Bu seviye, standart normal dağılım tablosunda $Z = 1.65$ katsayısına karşılık gelmektedir.
2. Tedarik Süresi: Hammaddelerin ortalama tedarik süresi, analiz kolaylığı açısından tüm kalemler için 15 gün olarak varsayılmıştır.
3. Stok Maliyetleri (S ve h): EOQ formülünün gerektirdiği sipariş başına maliyet (S) ve birim başına yıllık stok bulundurma maliyeti (h) verileri, işletmenin muhasebe kayıtlarına özel olup bu tezin kapsamı dışındadır. Bu nedenle, EOQ hesaplaması bu çalışmanın kısıtları dahilinde yer almamaktadır. Çalışma, talep öngörüsü modelinin doğrudan etkilediği SS ve ROP parametrelerine odaklanmıştır.

Stok yönetimi hesaplamalarında, SS formülü için gerekli olan talep değişkenliğinin standart sapması (σ) olarak, modelin 2024 test seti üzerindeki *RMSE* değeri temel alınmıştır.

RMSE aylık ölçekli bir hata ölçüsü olduğu için, 15 günlük tedarik süresi aylık birime çevrilmiş; ortalama ay uzunluğu 30.42 gün kabul edilmiş ve stok yönetimi hesaplamalarında $LT_{ay} = \frac{15}{30.42}$ olarak kullanılmıştır.

Bu metodolojik tercihin temel nedeni şudur: güvenlik stoğunun amacı, model tarafından zaten yakalanan ve öngörülen sistematik dalgalanmalara (mevsimsellik, trend vb.) karşı değil, yalnızca öngörülemeyen (rastgele) talep şoklarına karşı koruma sağlamaktır.

Elastromer hammaddesi için güvenlik stoğunun ve yeniden sipariş noktalarının hesaplanmaları aşağıda verilmiştir;

$$SS = Z \times \sqrt{LT} \times \sigma_d = 1.65 \times \sqrt{\frac{15}{30.42}} \times 1.498 \cong 1.74 \quad (5.1)$$

$$ROP = d \times LT + SS = 0.68 \times 15 + 1.74 \cong 11.99 \quad (5.2)$$

Aynı metodoloji, 9 kritik hammaddenin tamamına uygulanmıştır. Her bir hammaddeye ait ayrıntılı ara adımlar ve hesaplamalar EK 2’de, özet sonuçlar ise çizelge 5.18’de sunulmuştur.

Çizelge 5.18 2025 yılı yıllık talep değerleri ile öngörülen stok yönetimi parametre değerleri (kg)

Hammadde Adı	Yıllık Talep	<i>d</i>	<i>SS</i>	<i>ROP</i>
Elastromer	249.50	0.68	1.74	11.99
Acetal	1421.29	3.89	16.18	74.59
PC	8976.61	24.59	76.68	445.58
ABS 3864	18061.95	49.48	155.11	897.38
PC ABS-IMS	13227.22	36.24	147.72	691.30
PC ABS	2760.20	7.56	44.58	158.01
PC Violet	1411.22	3.87	10.81	68.80
Moblen	333.27	0.91	2.19	15.89
PA66 GFR30	591.05	1.62	5.22	29.51

Çizelge 5.18, bu tez çalışmasının somut çıktılarını ve pratik değerini özetlemektedir. Analizler, işletmenin stok politikalarını "geçmiş ortalamalara" göre değil, doğrudan istatistiksel öngörüye ve modelin hata payına (*RMSE*) dayalı olarak belirleyebileceğini kanıtlamıştır.

Çalışmanın en kritik bulgusu ise, işletmenin "stok ne zaman sipariş verilmeli?" sorusuna net bir cevap veren *ROP* parametresidir. Bu bilimsel altyapı, işletmenin hem Bölüm 5.5’te öngörülen ani talep şoklarına karşı korunmasını hem de gereksiz stok maliyetlerinden kaçınmasını sağlayacaktır.

6. SONUÇ

Günümüzün rekabetçi ve regülasyonlarla yoğun şekilde çevrelenmiş medikal sektöründe, kritik hammaddelerin zamanında ve doğru miktarda temin edilmesi; üretim sürekliliği, hasta güvenliği ve maliyet kontrolü açısından stratejik bir öneme sahiptir. Bu bağlamda talep öngörüsü ve stok yönetimi kararlarının sezgisel yaklaşımlardan çıkarılarak veriye dayalı, sistematik yöntemlerle desteklenmesi bir zorunluluk hâline gelmiştir. Bu tez çalışması, medikal sektörde faaliyet gösteren bir işletmenin 9 adet kritik hammaddesine ait tüketim dinamiklerini ML yöntemleri ile modelleyerek, 2025 yılına yönelik hammadde tüketimini öngörmeyi ve stok yönetimi süreçlerine dair uygulanabilir öneriler geliştirmeyi amaçlamıştır.

Çalışmada ilk olarak, işletmenin farklı departmanlarında dağınık hâlde bulunan satış, üretim, fire ve stok verileri bütünleştirilmiş ve analizlerde kullanılan hammadde tüketim değerleri, fiili üretim adetlerinin ürün reçetelerinde tanımlı birim kullanım miktarları üzerinden hammadde bazına indirgenmesiyle elde edilmiştir. Daha sonra hazırlanan veri setleri, ön işleme adımların geçirilmiş ve analize hazır hale getirilmiştir.

Modelleme sürecinde her bir hammadde için ayrı bir ML modeli geliştirilmiştir. Gelecek dönem (2025) bağımsız değişken değerlerinin önceden bilinmemesi nedeniyle iki aşamalı hibrit bir yaklaşım benimsenmiştir. İlk aşamada, 2021–2024 dönemine ait satış, üretim, fire ve stok serileri kullanılarak 2025 yılı bağımsız değişkenleri iki farklı yöntem olan NAR ve SARIMA ile öngörülmüştür. Üretilen 2025 öngörülleri, mevcut 2025 gerçekleşen bağımsız değişken değerleri ile *RMSE* ve *MAPE* metrikleri üzerinden çizelge 5.8-5.16’da karşılaştırılmış; sonuçlar, bağımsız değişkenlerin ileri dönem tahmininde NAR yaklaşımının SARIMA’ya kıyasla daha düşük hata ürettiğini göstermiştir. Bu nedenle, nihai talep/tüketim modeline girdi olarak 2025 bağımsız değişken seti NAR yaklaşımı ile oluşturulmuştur.

İkinci aşamada ise GBR, RF ve XGBoost algoritmaları ile verinin %75’i eğitim ve %25’i test olacak şekilde modeller eğitilmiş; 2024 yılı için geriye dönük (backtest) performans *RMSE*, *MAPE* ve R^2 ölçütleriyle değerlendirilmiştir. çizelge 5.3 verilen karşılaştırmalar

sonucunda, R^2 ve hata metrikleri birlikte dikkate alınarak her bir hammadde özelinde en yüksek performansı sağlayan ML algoritmasıyla ilerlenmesine karar verilmiştir.

Elde edilen bulgular, 9 kritik hammaddenin büyük bir kısmında model performansının hem R^2 hem de *MAPE* açısından kararlarını destekleyecek ölçüde başarılı sonuçlar verdiğini göstermektedir. Analiz edilen 9 kritik hammaddenin R^2 değerlerinin tatmin edici düzeyde olduğu; hata oranlarının ise kabul edilebilir sınırlar içinde kaldığı tespit edilmiştir. ABS 3864 hammaddesinde gözlenen görece düşük R^2 ve daha yüksek *MAPE* değerlerinin temel nedeni, tüketim serilesinin kesikli talep yapısı göstermesidir. Buna rağmen modelin bu hammaddede dahi ana eğilimi yakaladığı ve ani zirve-dip noktalarını aşırı öğrenmeden kaçınacak şekilde dengelediği görülmektedir. Bu sonuç, modelin rastgele dalgalanmaları ezberlemekten ziyade, altta yatan sistematik örüntüyü öğrenebildiğini ve işletme planlaması için makul bir referans senaryosu sunduğunu göstermektedir.

Çalışmanın ikinci aşamasında, 2021–2024 verisinin tamamı kullanılarak seçilen nihai modeller yeniden eğitilmiş ve 2025 yılı için 12 aylık hammadde tüketim öngörülleri üretilmiştir. Öngörülen hammadde tüketim değerleri 2025 yılının mevcut gerçekleşen değerleri ile karşılaştırmalı grafikler halinde sunularak model başarısı doğrulanmıştır.

Talep öngörülerinin stok yönetimi ile entegrasyonu kapsamında, 2025 yılına ait aylık tüketim tahminleri kullanılarak yıllık talep, ortalama günlük talep, SS ve ROP parametreleri hesaplanmıştır. Medikal sektörün kritikliği dikkate alınarak hizmet seviyesi %95 olarak kabul edilmiş ve tüm hammaddeler için 15 günlük sabit tedarik süresi varsayılmıştır.

Model çıktıları esas alınarak yapılan hesaplamalar sonucunda, her bir hammadde için güvenlik stoğu (SS) ve yeniden sipariş noktası (ROP) değerleri belirlenmiştir. Elde edilen bulgulara göre, en yüksek stok gereksinimi ABS 3864 hammaddesinde ortaya çıkmış olup bu hammadde için SS 155,11 kg ve ROP 897,38 kg olarak hesaplanmıştır. Bunu PC ABS-IMS (SS: 147,72 kg; ROP: 691,30 kg) ve PC (SS: 76,68 kg; ROP: 445,58 kg) hammaddeleri izlemektedir.

Orta düzeyde tüketim hacmine sahip hammaddeler arasında yer alan PC ABS için SS 44,58 kg ve ROP 158,01 kg; Acetal için SS 16,18 kg ve ROP 74,59 kg; PC Violet için ise SS 10,81 kg ve ROP 68,80 kg olarak öngörülmüştür.

Talep hacmi ve belirsizlik düzeyi görece düşük olan PA66 GFR30, Moblen ve Elastromer hammaddelerinde ise güvenlik stoğu değerlerinin sırasıyla 5,22 kg, 2,19 kg ve 1,74 kg, yeniden sipariş noktalarının ise 29,51 kg, 15,89 kg ve 11,99 kg seviyelerinde belirlenmesinin %95 hizmet seviyesinin sağlanması açısından yeterli olduğu hesaplanmıştır.

Elde edilen sonuçlar, özellikle yüksek hacimli ve dalgalı tüketime sahip hammaddelerde daha yüksek ROP ve SS seviyelerine ihtiyaç duyulduğunu ortaya koymaktadır. Böylece işletme, stok politikalarını geçmiş dönem ortalamaları veya sezgisel kararlar yerine, model destekli talep öngörülleri ve ölçülmüş hata payları üzerinden tanımlayabilecek bir yapıya kavuşmuştur.

Bununla birlikte, çalışmanın bazı sınırlılıkları bulunmaktadır. Öncelikle analizler tek bir işletmenin 4 yıllık verileri ile sınırlıdır; daha uzun dönemli ve farklı firmaları kapsayan veri setleri ile yapılacak çalışmalar, model genellenebilirliğinin daha güçlü bir şekilde test edilmesini sağlayacaktır. Ayrıca, tedarik süresi, ekonomik sipariş miktarı parametreleri ve stok bulundurma maliyetleri işletmenin muhasebe kayıtlarına özel olduğundan, bu tezde doğrudan maliyet optimizasyonu (EOQ vb.) yapılmamış; odak, talep ve stok seviyelerinin güvenilir şekilde tahmin edilmesine yer verilmiştir. Ayrıca, döviz kuru, hammadde fiyatları, makroekonomik göstergeler vb. gibi dışsal faktörler modele dahil edilmemiştir.

Gelecekteki çalışmalarda veri setinin zaman ve değişken açısından genişletilmesi, model performansını derinleştirecektir. Döviz kuru, tedarik süresi oynaklığı ve talep şokları gibi dışsal değişkenlerin dahil edilmesi tahmin doğruluğunu artırabilir. Ayrıca, farklı firmaları ve daha uzun dönemleri kapsayan verilerle modelin genellenebilirliği güçlendirilebilir.

Sonuç olarak, bu tez çalışması, medikal sektörde kritik hammadde yönetiminin yalnızca operasyonel bir faaliyet değil, aynı zamanda veri temelli stratejik bir karar problemi olduğunu ortaya koymuştur. Geliştirilen ML temelli talep öngörü modeli ve buna bağlı stok yönetimi parametreleri, işletmeye gelecek dönem planlamalarında somut bir yol haritası sunmakta; aynı zamanda benzer nitelikteki üretim işletmeleri için de uygulanabilir bir metodolojik çerçeve önermektedir.

KAYNAKLAR

- Abbasi, M. M., Daniyal, S. M., Abro, A. A., Hussain, D., Amjad, U. and Zahid, N. B. 2024. Applying Neural Networks to Predict Ventilator Demand: A Study of Pakistan's Healthcare Sector. *VFAST Transactions on Software Engineering*, 12(3), 217-229.
- Adıyaman, F. 2007. Talep tahmininde yapay sinir ağlarının kullanılması. Yüksek Lisans Tezi. İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- Akbaş, B. C. 2022. Tedarik zinciri yönetiminde yapay zeka tabanlı talep tahmini: Bir tekstil firmasında uygulama. Yüksek Lisans Tezi. Akdeniz Üniversitesi Sosyal Bilimler Enstitüsü, Antalya.
- Ali, S. M., Paul, S. K., Ahsan, K. and Azeem, A. 2011. Forecasting of optimum raw material inventory level using artificial neural network. *International Journal of Operations and Quantitative Management*, 17(4), 333–348.
- Amaral, C., Paiva, M., Rodrigues, A. R., Veiga, F. and Bell, V. 2024. Global Regulatory Challenges for Medical Devices: Impact on Innovation and Market Access. *Applied Sciences*, 14(20), 9304. <https://doi.org/10.3390/app14209304>.
- Ardiananta, I. and Basri, M. H. 2024. Inventory Management Improvement at PT Inalum, Kuala Tanjung, Sumatra Utara. *European Journal of Business and Management Research*, 9(2), 71–78.
- Bayar Serbest, A. 2024. Makine öğrenmesi ile talep tahmini ve envanter yönetimi. Yüksek Lisans Tezi. Bursa Uludağ Üniversitesi Fen Bilimleri Enstitüsü, Bursa.
- Bentéjac, C., Csörgő, A. and Martínez-Muñoz, G. 2021. A comparative analysis of gradient boosting algorithms. *Artificial Intelligence Review*, 54(3), 1937–1967.
- Bishop, C. M. 2006. *Pattern Recognition and Machine Learning*, Springer, 758 p., U.K.
- Bojja, R. R. 2025. A comparative study of supervised and unsupervised learning approaches. *International Multidisciplinary Research Journal Reviews (IMRJR)*, 2(4), 80–88.
- Bolt, G. 1994. *Market and Sales Forecasting: A Total Approach*. Kogan Page, 350 p., Londra.
- Borrero, J. D. and Mariscal, J. 2023. Elevating Univariate Time Series Forecasting: Innovative SVR-Empowered Nonlinear Autoregressive Neural Networks. *Algorithms*, 16(423). <https://doi.org/10.3390/a16090423>.
- Box, G.E.P., Jenkins, G.M., Reinsel, G.C. and Ljung, G.M. 1994. *Time Series Analysis: Forecasting and Control*. Wiley, 712, Hoboken, 614 p., New Jersey.

- Chen, T. and Guestrin, C. 2016. XGBoost: A Scalable Tree Boosting System. KDD '16: Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, 785–794. doi: 10.1145/2939672.2939785.
- Duru, Ö. 2007. Zaman Serileri Analizinde ARIMA Modelleri ve Bir Uygulama. Yüksek Lisans Tezi, İstanbul Üniversitesi, Sosyal Bilimler Enstitüsü, İstanbul.
- Friedman, J. H. 2001. Greedy function approximation: A gradient boosting machine. The Annals of Statistics, 29(5), 1189–1232.
- Güçlükol, S. 2020. Forecasting Customer Service Demand by Machine Learning with Real Life Implementation. Yüksek Lisans Tezi. Sabancı Üniversitesi, Mühendislik ve Doğa Bilimleri Enstitüsü, İstanbul.
- Gültekin, N. 2022. Türk hava sahasındaki sivil hava trafik yoğunluğunun zaman serileri ve yapay sinir ağları ile analizi. Yüksek Lisans Tezi. Ankara Üniversitesi Fen Bilimleri Enstitüsü, Ankara.
- Güngör, B., Tokgöz, E., Sevinç, A., Kamber, E. and Gümüş, M. 2025. Demand Forecasting for the Furniture Industry with Multivariate Time Series Models. ALKU Journal of Science, 7(2), 111-128.
- Hamilton, J.D. 1994. Time Series Analysis. Princeton University Press, 799 p., Princeton, New Jersey.
- Harris, C. R., Millman, K. J., van der Walt, S. J., Gommers, R., Virtanen, P., Cournapeau, D., Wieser, E., Taylor, J., Berg, S., Smith, N. J., Kern, R., Picus, M., Hoyer, S., van Kerkwijk, M. H. and Oliphant, T. E. 2020. Array programming with NumPy. Nature, 585(7825), 357–362.
- Hunter, J.D. 2007. Matplotlib: a 2D graphics environment. Computing in Science & Engineering, 9, 90–95.
- Hyndman, R. J. and Koehler, A. B. 2006. Another look at measures of forecast accuracy. International Journal of Forecasting, 22(4), 679–688.
- Hyndman, R.J. and Athanasopoulos, G. 2018. Forecasting: Principles and Practice. OTexts, Melbourne, 138 p., Australia.
- Jadhav, A., Pandit, N., Thorat, P., Sonawane, P. and Khokale, S. R. 2022. Raw Material Demand Forecasting in Automobile Industry. Journal of Emerging Technologies and Innovative Research (JETIR), 9(5), 257–261.
- Kagalwala, H., Radhakrishnan, G. V., Mohammed, I. A., Kothinti, R. R. and Kulkarni, N. 2025. Predictive Analytics in Supply Chain Management: The Role of AI and Machine Learning in Demand Forecasting. Advances in Consumer Research, 2(1), 142–149.
- Kaya, N. 2020. Stok Yönetimi. İKSAD Publishing House, 376 p., Erzurum.

- Kocadağ, D. ve Şahin, S. 2020. Sağlık Sektöründe Talep Tahmini Üzerine Literatür Araştırması. Düzce Üniversitesi Sosyal Bilimler Enstitüsü Dergisi (DÜSOBED), 10(1), 99–113.
- Kochak, A. and Sharma, S. 2015. Demand Forecasting Using Neural Network for Supply Chain Management. International Journal of Mechanical Engineering and Robotics Research, 4(1), 96–104.
- Kourentzes, N., Trapero, J. R. and Barrow, D. K. 2020. Optimising forecasting models for inventory planning. International Journal of Production Economics, 225, 107597.
- Kumari, S. and Muthulakshmi, P. 2024. SARIMA model: An efficient machine learning technique for weather forecasting. Procedia Computer Science, 235, 656–670. doi: 10.1016/j.procs.2024.04.064.
- Kutlu, A. A. 2024. Predictive modeling of return occurrence in e-commerce apparel market: A comparative study of logistic regression, LASSO, XGBoost and random forest techniques. Yüksek Lisans Tezi. İhsan Doğramacı Bilkent Üniversitesi, Ankara.
- Li, L. 2007. Supply Chain Management: Concepts, Techniques and Practices: Enhancing Value Through Collaboration. World Scientific Publishing, 372 p., New Jersey, USA.
- Lin, T., Horne, B. G., Tino, P. and Giles, C. L. 1996. Learning long-term dependencies in NARX recurrent neural networks. IEEE Transactions on Neural Networks, 7(6), 1329–1338.
- McKinney, W. 2010. Data structures for statistical computing in Python. S. van der Walt ve J. Millman, Proceedings of the 9th Python in Science Conference, 51–56.
- Mesjasz-Lech, A. 2011. Forecasting of demand for direct production materials as the element of supply logistics of thermal power plants. LogForum, 7(2), 5.
- Mizrach, B. 2006. Nonlinear time series analysis. Working Paper, No. 2006-04. Rutgers University, Department of Economics, New Brunswick, NJ.
- Nabipour, M., Nayyeri, P., Jabani, H., Mosavi, A., Salwana, E. and Shahab, S. 2020. Deep Learning for Stock Market Prediction. Entropy, 22, 840. doi: 10.3390/e22080840.
- Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Dubourg, V., Vanderplas, J., Passos, A., Cournapeau, D., Brucher, M., Perrot, M. and Duchesnay, E. 2011. Scikit-learn: Machine Learning in Python. Journal of Machine Learning Research, 12, 2825–2830.
- Pehlivanoğlu, H. E. 2023. Plastik Sektöründe Yapay Sinir Ağları ve Regresyon Analizi ile Talep Tahmini. Yüksek Lisans Tezi. Kocaeli Üniversitesi Fen Bilimleri Enstitüsü, Kocaeli.

- Pilinkienė, V. 2008. Selection of Market Demand Forecast Methods: Criteria and Application. *Engineering Economics*, 3(58), 19–25.
- Plinere, D. S., Borisov, A. N. and Aleksejeva, L. Y. 2015. Interaction of software agents in the problem of coordinating orders. *Automatic Control and Computer Sciences*, 49(5), 268–276.
- Prova, N. N. I. 2024. Advanced machine learning techniques for predictive analysis of health insurance. *Proceedings of the Second International Conference on Intelligent Cyber Physical Systems and Internet of Things (ICoICI 2024)*, 1166–1170. doi: 10.1109/ICoICI62503.2024.10695988.
- Purshottam, D. 2024. Analysis and Categorization of Inventory Management Procedures. *International Journal for Research Publication and Seminar*, 15(4), 150–152.
- Putatunda, S. and Rama, K. (2018). A comparative analysis of hyperopt as against other approaches for hyper-parameter optimization of XGBoost. In *Proceedings of the 2018 International Conference on Statistical and Machine Learning (SPML '18)* (6–10). Association for Computing Machinery. <https://doi.org/10.1145/3297067.3297080>
- Ravindran, N. J. and Gopalakrishnan, P. 2018. Predictive analysis for healthcare sector using big data technology, In: *Second International Conference on Green Computing and Internet of Things (ICGCIoT)*, 326–331.
- Raykov, Y. P., and Saad, D. 2021. Principled machine learning. *Journal of LATEX Class Files*, 20(X), 1–20.
- Ryan, O., Haslbeck, J. M. B. and Waldorp, L. J. 2025. Non-Stationarity in Time-Series Analysis: Modeling Stochastic and Deterministic Trends. *Multivariate Behavioral Research*, 60(3), 556–588. doi: 10.1080/00273171.2024.2436413.
- Safhi, A. E. M., Dabiri, H., Soliman, A. and Khayat, K. H. 2024. Prediction of self-consolidating concrete properties using XGBoost machine learning algorithm: Rheological properties. *Powder Technology*, 438, 119623. doi: 10.1016/j.powtec.2024.119623.
- Salman, H. A., Kalakech, A. and Steiti, A. 2024. Random forest algorithm overview. *Babylonian Journal of Machine Learning*, 2024, 69–79. <https://doi.org/10.58496/BJML/2024/007>.
- Sarı, M. 2016. Yapay sinir ağları ve bir otomotiv firmasında satış talep tahmini uygulaması. Yüksek lisans tezi. Sakarya Üniversitesi, Fen Bilimleri Enstitüsü, Sakarya.
- Sarı, T., Şensoy, S. R., Nurbaki, A. E. ve Ağaç, İ. A. 2023. Yapay sinir ağları yaklaşımı ile talep tahmini: Madeni eşya imalat sektöründe bir uygulama. *Verimlilik Dergisi*, 57(4), 701–718.

- Schmal, W. B. 2024. Quantitative tools for time series analysis in natural language processing: A practitioners guide.
- Seabold, S. and Perktold, J. 2010. Statsmodels: Econometric and Statistical Modeling in Python. Proceedings of the 9th Python in Science Conference, 92–96.
- Sistla, S. M. K., Krishnamoorthy, G., Jeyaraman, J. and Konidena, B. K. 2024. Machine Learning for Demand Forecasting in Manufacturing. International Journal for Multidisciplinary Research (IJFMR), 6(1), 1–11.
- Tanrıverdi, Y. 2010. Tedarik zinciri ve stok yönetimi üzerine bir uygulama. Yüksek Lisans Tezi. Pamukkale Üniversitesi, Sosyal Bilimler Enstitüsü, Pamukkale.
- Tayır, T. (2025). XGBoost algoritması ile pay piyasası fiyat tahmini: Borsa İstanbul endeksleri üzerinde bir uygulama. Yüksek lisans tezi. Bursa Teknik Üniversitesi, Lisansüstü Eğitim Enstitüsü, Bursa.
- Turgay, G. 2025. Tedarik zincirinde yapay zeka tabanlı talep tahmini ve envanter yönetiminin performansa etkileri. Yüksek Lisans Tezi. Sakarya Üniversitesi İşletme Enstitüsü, Sakarya.
- Zhang, L., Bian, W., Ou, W., Tuo, L. and Wang, Y. 2021. Time series forecast of sales volume based on XGBoost. Journal of Physics: Conference Series, 1873(012067). doi: 10.1088/1742-6596/1873/1/012067.

EKLER

EK 1 Sarıma Analizi Uygulaması

EK 2 Stok Yönetimi Hesaplamaları

EK 1 SARIMA ANALİZİ UYGULAMASI

- Acetal Hammadesine Ait Bağımsız Değişkenlerin Genişletilmiş Dickey–Fuller (ADF) Test Sonuçları (Orijinal Seri)

Bağımsız Değişken	Genişletilmiş Dickey-Fuller (ADF) Testi Sonuçları
Yurt Dışı Satış Adedi	<pre>----- ADF TESTİ ----- Değişken: Yurt Dışı Satış Adeti Seri: ModelOlcek ADF istatistiği : -3.2774 p-değeri : 0.0159 Sonuç : DURAĞAN (H0 reddedildi, p<=0.05) [Yurt Dışı Satış Adeti] Seri durağan → d=0.</pre>
Yurt İçi Satış Adedi	<pre>----- ADF TESTİ ----- Değişken: Yurt İçi Satış Adeti Seri: ModelOlcek ADF istatistiği : -4.1612 p-değeri : 0.0008 Sonuç : DURAĞAN (H0 reddedildi, p<=0.05) [Yurt İçi Satış Adeti] Seri durağan → d=0.</pre>
Fire Adedi	<pre>----- ADF TESTİ ----- Değişken: Fire Adeti Seri: ModelOlcek ADF istatistiği : -7.2153 p-değeri : 0.0000 Sonuç : DURAĞAN (H0 reddedildi, p<=0.05) [Fire Adeti] Seri durağan → d=0.</pre>
Aylık Stokta Kalan Adedi	<pre>----- ADF TESTİ ----- Değişken: Aylık Stokta Kalan Seri: ModelOlcek ADF istatistiği : -5.5851 p-değeri : 0.0000 Sonuç : DURAĞAN (H0 reddedildi, p<=0.05) [Aylık Stokta Kalan] Seri durağan → d=0.</pre>
Üretim Adedi	<pre>----- ADF TESTİ ----- Değişken: Üretim Adeti Seri: ModelOlcek ADF istatistiği : -2.3685 p-değeri : 0.1508 Sonuç : DURAĞAN DEĞİL (H0 reddedilemedi, p>0.05)</pre>

ADF testi sonrasında acetal hammaddesine ait üretim adedi değişkeni durağan çıkmamıştır. Bu değişken birim kök testine tabi tutulur ve ardından tekrardan ADF testi ile durağanlığı kontrol edilir. Durağan çıkan bağımsız değişkenler için d değeri 0 olarak alınmıştır.

ADF Testi Sonucu Birim Kök Testi Uygulaması ve ADF Testinin Tekrarlanması

Bağımsız Değişken	Genişletilmiş Dickey-Fuller (ADF) Testi Sonuçları
Üretim Adedi	<pre> ----- ADF TESTİ ----- Değişken: Üretim Adeti Seri: 1.Fark (ModelOlcek) ADF istatistiği : -5.0110 p-değeri : 0.0000 Sonuç : DURAĞAN (H0 reddedildi, p<=0.05) </pre>

Birim kök testi sonucunda 1. farkı alınan bütün bağımsız değişkenler için durağanlık koşulu sağlanmıştır. Birim kök testine tabi tutulan değişkenler için d değeri 1 olarak alınmıştır.

- PC Hammadesine Ait Bağımsız Değişkenlerin Genişletilmiş Dickey-Fuller (ADF) Test Sonuçları (Orijinal Seri)

Bağımsız Değişken	Genişletilmiş Dickey-Fuller (ADF) Testi Sonuçları
Yurt Dışı Satış Adedi	<pre> ----- ADF TESTİ ----- Değişken: Yurt Dışı Satış Adeti Seri: ModelOlcek ADF istatistiği : -2.9910 p-değeri : 0.0357 Sonuç : DURAĞAN (H0 reddedildi, p<=0.05) [Yurt Dışı Satış Adeti] Seri durağan → d=0. </pre>
Yurt İçi Satış Adedi	<pre> ----- ADF TESTİ ----- Değişken: Yurt İçi Satış Adeti Seri: ModelOlcek ADF istatistiği : -4.5198 p-değeri : 0.0002 Sonuç : DURAĞAN (H0 reddedildi, p<=0.05) [Yurt İçi Satış Adeti] Seri durağan → d=0. </pre>
Fire Adedi	<pre> ----- ADF TESTİ ----- Değişken: Fire Adeti Seri: ModelOlcek ADF istatistiği : -2.7752 p-değeri : 0.0619 Sonuç : DURAĞAN DEĞİL (H0 reddedilemedi, p>0.05) </pre>
Aylık Stokta Kalan Adedi	<pre> ----- ADF TESTİ ----- Değişken: Aylık Stokta Kalan Seri: ModelOlcek ADF istatistiği : -1.2795 p-değeri : 0.6385 Sonuç : DURAĞAN DEĞİL (H0 reddedilemedi, p>0.05) </pre>
Üretim Adedi	<pre> ----- ADF TESTİ ----- Değişken: Üretim Adeti Seri: ModelOlcek ADF istatistiği : -1.9965 p-değeri : 0.2881 Sonuç : DURAĞAN DEĞİL (H0 reddedilemedi, p>0.05) </pre>

ADF testi sonrasında PC hammaddesine ait fire adedi, aylık stokta kalan adedi ve üretim adedi değişkenleri durağan çıkmamıştır. Bu değişken birim kök testine tabi tutulur ve ardından tekrardan ADF testi ile durağanlığı kontrol edilir. Durağan çıkan bağımsız değişkenler için d değeri 0 olarak alınmıştır.

ADF Testi Sonucu Birim Kök Testi Uygulaması ve ADF Testinin Tekrarlanması

Bağımsız Değişken	Genişletilmiş Dickey-Fuller (ADF) Testi Sonuçları
Fire Adedi	<pre> ----- ADF TESTİ ----- Değişken: Fire Adeti Seri: 1.Fark (ModelOlcek) ADF istatistiği : -13.2140 p-değeri : 0.0000 Sonuç : DURAĞAN (H0 reddedildi, p<=0.05) </pre>
Aylık Stokta Kalan Adedi	<pre> ----- ADF TESTİ ----- Değişken: Aylık Stokta Kalan Seri: 1.Fark (ModelOlcek) ADF istatistiği : -7.2006 p-değeri : 0.0000 Sonuç : DURAĞAN (H0 reddedildi, p<=0.05) </pre>
Üretim Adedi	<pre> ----- ADF TESTİ ----- Değişken: Üretim Adeti Seri: 1.Fark (ModelOlcek) ADF istatistiği : -7.9652 p-değeri : 0.0000 Sonuç : DURAĞAN (H0 reddedildi, p<=0.05) </pre>

Birim kök testi sonucunda 1. farkı alınan bütün bağımsız değişkenler için durağanlık koşulu sağlanmıştır. Birim kök testine tabi tutulan değişkenler için d değeri 1 olarak alınmıştır.

- ABS3864 Hammadesine Ait Bağımsız Değişkenlerin Genişletilmiş Dickey-Fuller (ADF) Test Sonuçları (Orijinal Seri)

Bağımsız Değişken	Genişletilmiş Dickey-Fuller (ADF) Testi Sonuçları
Yurt Dışı Satış Adedi	<pre> ----- ADF TESTİ ----- Değişken: Yurt Dışı Satış Adeti Seri: ModelOlcek ADF istatistiği : -6.8600 p-değeri : 0.0000 Sonuç : DURAĞAN (H0 reddedildi, p<=0.05) [Yurt Dışı Satış Adeti] Seri durağan → d=0. </pre>
Yurt İçi Satış Adedi	<pre> ----- ADF TESTİ ----- Değişken: Yurt İçi Satış Adeti Seri: ModelOlcek ADF istatistiği : -2.7317 p-değeri : 0.0687 Sonuç : DURAĞAN DEĞİL (H0 reddedilemedi, p>0.05) </pre>

Fire Adedi	<pre> ----- ADF TESTİ ----- Değişken: Fire Adeti Seri: ModelOlcek ADF istatistiği : -2.6846 p-değeri : 0.0767 Sonuç : DURAĞAN DEĞİL (H0 reddedilemedi, p>0.05) </pre>
Aylık Stokta Kalan Adedi	<pre> ----- ADF TESTİ ----- Değişken: Aylık Stokta Kalan Seri: ModelOlcek ADF istatistiği : -1.5673 p-değeri : 0.5000 Sonuç : DURAĞAN DEĞİL (H0 reddedilemedi, p>0.05) </pre>
Üretim Adedi	<pre> ----- ADF TESTİ ----- Değişken: Üretim Adeti Seri: ModelOlcek ADF istatistiği : -6.2656 p-değeri : 0.0000 Sonuç : DURAĞAN (H0 reddedildi, p<=0.05) [Üretim Adeti] Seri durağan → d=0. </pre>

ADF testi sonrasında ABS 3864 hammaddesine ait yurt içi satış adedi, fire adedi ve aylık stokta kalan adedi değişkenleri durağan çıkmamıştır. Bu değişken birim kök testine tabi tutulur ve ardından tekrardan ADF testi ile durağanlığı kontrol edilir. Durağan çıkan bağımsız değişkenler için d değeri 0 olarak alınmıştır.

ADF Testi Sonucu Birim Kök Testi Uygulaması ve ADF Testinin Tekrarlanması

Bağımsız Değişken	Genişletilmiş Dickey-Fuller (ADF) Testi Sonuçları
Yurt İçi Satış Adedi	<pre> ----- ADF TESTİ ----- Değişken: Yurt İçi Satış Adeti Seri: 1.Fark (ModelOlcek) ADF istatistiği : -11.4044 p-değeri : 0.0000 Sonuç : DURAĞAN (H0 reddedildi, p<=0.05) </pre>
Fire Adedi	<pre> ----- ADF TESTİ ----- Değişken: Fire Adeti Seri: 1.Fark (ModelOlcek) ADF istatistiği : -12.3782 p-değeri : 0.0000 Sonuç : DURAĞAN (H0 reddedildi, p<=0.05) </pre>
Aylık Stokta Kalan Adedi	<pre> ----- ADF TESTİ ----- Değişken: Aylık Stokta Kalan Seri: 1.Fark (ModelOlcek) ADF istatistiği : -9.1552 p-değeri : 0.0000 Sonuç : DURAĞAN (H0 reddedildi, p<=0.05) </pre>

Birim kök testi sonucunda 1. farkı alınan bütün bağımsız değişkenler için durağanlık koşulu sağlanmıştır. Birim kök testine tabi tutulan değişkenler için d değeri 1 olarak alınmıştır.

- PC ABS-IMS Hammadesine Ait Bağımsız Değişkenlerin Genişletilmiş Dickey–Fuller (ADF) Test Sonuçları (Orijinal Seri)

Bağımsız Değişken	Genişletilmiş Dickey-Fuller (ADF) Testi Sonuçları
Yurt Dışı Satış Adedi	<pre> ----- ADF TESTİ ----- Değişken: Yurt Dışı Satış Adeti Seri: ModelOlcek ADF istatistiği : -4.3223 p-değeri : 0.0004 Sonuç : DURAĞAN (H0 reddedildi, p<=0.05) </pre>
Yurt İçi Satış Adedi	<pre> ----- ADF TESTİ ----- Değişken: Yurt İçi Satış Adeti Seri: ModelOlcek ADF istatistiği : -2.1445 p-değeri : 0.2270 Sonuç : DURAĞAN DEĞİL (H0 reddedilemedi, p>0.05) </pre>
Fire Adedi	<pre> ----- ADF TESTİ ----- Değişken: Fire Adeti Seri: ModelOlcek ADF istatistiği : -4.4834 p-değeri : 0.0002 Sonuç : DURAĞAN (H0 reddedildi, p<=0.05) </pre>
Aylık Stokta Kalan Adedi	<pre> ----- ADF TESTİ ----- Değişken: Aylık Stokta Kalan Seri: ModelOlcek ADF istatistiği : -4.4624 p-değeri : 0.0002 Sonuç : DURAĞAN (H0 reddedildi, p<=0.05) </pre>
Üretim Adedi	<pre> ----- ADF TESTİ ----- Değişken: Üretim Adeti Seri: ModelOlcek ADF istatistiği : -2.4984 p-değeri : 0.1159 Sonuç : DURAĞAN DEĞİL (H0 reddedilemedi, p>0.05) </pre>

ADF testi sonrasında PC ABS-IMS hammaddesine ait yurt içi satış adedi ve üretim adedi değişkenleri durağan çıkmamıştır. Bu değişken birim kök testine tabi tutulur ve ardından tekrardan ADF testi ile durağanlığı kontrol edilir. Durağan çıkan bağımsız değişkenler için d değeri 0 olarak alınmıştır.

ADF Testi Sonucu Birim Kök Testi Uygulaması ve ADF Testinin Tekrarlanması

Bağımsız Değişken	Genişletilmiş Dickey-Fuller (ADF) Testi Sonuçları
Yurt İçi Satış Adedi	<pre> ----- ADF TESTİ ----- Değişken: Yurt İçi Satış Adeti Seri: 1.Fark (ModelOlcek) ADF istatistiği : -13.5828 p-değeri : 0.0000 Sonuç : DURAĞAN (H0 reddedildi, p<=0.05) </pre>
Üretim Adedi	<pre> ----- ADF TESTİ ----- Değişken: Üretim Adeti Seri: 1.Fark (ModelOlcek) ADF istatistiği : -12.0933 p-değeri : 0.0000 Sonuç : DURAĞAN (H0 reddedildi, p<=0.05) </pre>

Birim kök testi sonucunda 1. farkı alınan bütün bağımsız değişkenler için durağanlık koşulu sağlanmıştır. Birim kök testine tabi tutulan değişkenler için d değeri 1 olarak alınmıştır.

- PC ABS Hammadesine Ait Bağımsız Değişkenlerin Genişletilmiş Dickey–Fuller (ADF) Test Sonuçları (Orijinal Seri)

Bağımsız Değişken	Genişletilmiş Dickey-Fuller (ADF) Testi Sonuçları
Yurt Dışı Satış Adedi	<pre> ----- ADF TESTİ ----- Değişken: Yurt Dışı Satış Adeti Seri: ModelOlcek ADF istatistiği : -4.2112 p-değeri : 0.0006 Sonuç : DURAĞAN (H0 reddedildi, p<=0.05) [Yurt Dışı Satış Adeti] Seri durağan → d=0. </pre>
Yurt İçi Satış Adedi	<pre> ----- ADF TESTİ ----- Değişken: Yurt İçi Satış Adeti Seri: ModelOlcek ADF istatistiği : -2.2132 p-değeri : 0.2015 Sonuç : DURAĞAN DEĞİL (H0 reddedilemedi, p>0.05) </pre>
Fire Adedi	<pre> ----- ADF TESTİ ----- Değişken: Fire Adeti Seri: ModelOlcek ADF istatistiği : -5.2668 p-değeri : 0.0000 Sonuç : DURAĞAN (H0 reddedildi, p<=0.05) [Fire Adeti] Seri durağan → d=0. </pre>
Aylık Stokta Kalan Adedi	<pre> ----- ADF TESTİ ----- Değişken: Aylık Stokta Kalan Seri: ModelOlcek ADF istatistiği : -3.0000 p-değeri : 0.0349 Sonuç : DURAĞAN (H0 reddedildi, p<=0.05) [Aylık Stokta Kalan] Seri durağan → d=0. </pre>
Üretim Adedi	<pre> ----- ADF TESTİ ----- Değişken: Üretim Adeti Seri: ModelOlcek ADF istatistiği : -3.3272 p-değeri : 0.0137 Sonuç : DURAĞAN (H0 reddedildi, p<=0.05) [Üretim Adeti] Seri durağan → d=0. </pre>

ADF testi sonrasında PC ABS hammaddesine ait yurt içi satış adedi değişkeni durağan çıkmamıştır. Bu değişken birim kök testine tabi tutulur ve ardından tekrardan ADF testi ile durağanlığı kontrol edilir. Durağan çıkan bağımsız değişkenler için d değeri 0 olarak alınmıştır.

ADF Testi Sonucu Birim Kök Testi Uygulaması ve ADF Testinin Tekrarlanması

Bağımsız Değişken	Genişletilmiş Dickey-Fuller (ADF) Testi Sonuçları
Yurt İçi Satış Adedi	<pre> ----- ADF TESTİ ----- Değişken: Yurt İçi Satış Adeti Seri: 1.Fark (ModelOlcek) ADF istatistiği : -6.8672 p-değeri : 0.0000 Sonuç : DURAĞAN (H0 reddedildi, p<=0.05) </pre>

Birim kök testi sonucunda 1. farkı alınan bütün bağımsız değişkenler için durağanlık koşulu sağlanmıştır. Birim kök testine tabi tutulan değişkenler için d değeri 1 olarak alınmıştır.

- PC Violet Hammadesine Ait Bağımsız Değişkenlerin Genişletilmiş Dickey-Fuller (ADF) Test Sonuçları (Orijinal Seri)

Bağımsız Değişken	Genişletilmiş Dickey-Fuller (ADF) Testi Sonuçları
Yurt Dışı Satış Adedi	<pre> ----- ADF TESTİ ----- Değişken: Yurt Dışı Satış Adeti Seri: ModelOlcek ADF istatistiği : -5.2086 p-değeri : 0.0000 Sonuç : DURAĞAN (H0 reddedildi, p<=0.05) [Yurt Dışı Satış Adeti] Seri durağan → d=0. </pre>
Yurt İçi Satış Adedi	<pre> ----- ADF TESTİ ----- Değişken: Yurt İçi Satış Adeti Seri: ModelOlcek ADF istatistiği : -1.3352 p-değeri : 0.6129 Sonuç : DURAĞAN DEĞİL (H0 reddedilemedi, p>0.05) </pre>
Fire Adedi	<pre> ----- ADF TESTİ ----- Değişken: Fire Adeti Seri: ModelOlcek ADF istatistiği : -3.5781 p-değeri : 0.0062 Sonuç : DURAĞAN (H0 reddedildi, p<=0.05) [Fire Adeti] Seri durağan → d=0. </pre>
Aylık Stokta Kalan Adedi	<pre> ----- ADF TESTİ ----- Değişken: Aylık Stokta Kalan Seri: ModelOlcek ADF istatistiği : -2.8840 p-değeri : 0.0472 Sonuç : DURAĞAN (H0 reddedildi, p<=0.05) [Aylık Stokta Kalan] Seri durağan → d=0. </pre>
Üretim Adedi	<pre> ----- ADF TESTİ ----- Değişken: Üretim Adeti Seri: ModelOlcek ADF istatistiği : -2.9949 p-değeri : 0.0354 Sonuç : DURAĞAN (H0 reddedildi, p<=0.05) [Üretim Adeti] Seri durağan → d=0. </pre>

ADF testi sonrasında PC Violet hammaddesine ait yurt içi satış adedi değişkeni durağan çıkmamıştır. Bu değişken birim kök testine tabi tutulur ve ardından tekrardan ADF testi ile durağanlığı kontrol edilir. Durağan çıkan bağımsız değişkenler için d değeri 0 olarak alınmıştır.

ADF Testi Sonucu Birim Kök Testi Uygulaması ve ADF Testinin Tekrarlanması

Bağımsız Değişken	Genişletilmiş Dickey-Fuller (ADF) Testi Sonuçları
Yurt İçi Satış Adedi	<pre> ----- ADF TESTİ ----- Değişken: Yurt İçi Satış Adeti Seri: 1.Fark (ModelOlcek) ADF istatistiği : -6.8672 p-değeri : 0.0000 Sonuç : DURAĞAN (H0 reddedildi, p<=0.05) </pre>

Birim kök testi sonucunda 1. farkı alınan bütün bağımsız değişkenler için durağanlık koşulu sağlanmıştır. Birim kök testine tabi tutulan değişkenler için d değeri 1 olarak alınmıştır.

- Moblen Hammadesine Ait Bağımsız Değişkenlerin Genişletilmiş Dickey-Fuller (ADF) Test Sonuçları (Orijinal Seri)

Bağımsız Değişken	Genişletilmiş Dickey-Fuller (ADF) Testi Sonuçları
Yurt Dışı Satış Adedi	<pre> ----- ADF TESTİ ----- Değişken: Yurt Dışı Satış Adeti Seri: ModelOlcek ADF istatistiği : -1.4208 p-değeri : 0.5723 Sonuç : DURAĞAN DEĞİL (H0 reddedilemedi, p>0.05) </pre>
Yurt İçi Satış Adedi	<pre> ----- ADF TESTİ ----- Değişken: Yurt İçi Satış Adeti Seri: ModelOlcek ADF istatistiği : -5.6501 p-değeri : 0.0000 Sonuç : DURAĞAN (H0 reddedildi, p<=0.05) [Yurt İçi Satış Adeti] Seri durağan → d=0. </pre>
Fire Adedi	<pre> ----- ADF TESTİ ----- Değişken: Fire Adeti Seri: ModelOlcek ADF istatistiği : -3.3227 p-değeri : 0.0139 Sonuç : DURAĞAN (H0 reddedildi, p<=0.05) [Fire Adeti] Seri durağan → d=0. </pre>

Aylık Stokta Kalan Adedi	<pre> ----- ADF TESTİ ----- Değişken: Aylık Stokta Kalan Seri: ModelOlcek ADF istatistiği : -3.1515 p-değeri : 0.0230 Sonuç : DURAĞAN (H0 reddedildi, p<=0.05) [Aylık Stokta Kalan] Seri durağan → d=0. </pre>
Üretim Adedi	<pre> ----- ADF TESTİ ----- Değişken: Üretim Adeti Seri: ModelOlcek ADF istatistiği : -8.5499 p-değeri : 0.0000 Sonuç : DURAĞAN (H0 reddedildi, p<=0.05) [Üretim Adeti] Seri durağan → d=0. </pre>

ADF testi sonrasında Moblen hammaddesine ait yurt dışı satış adedi değişkeni durağan çıkmamıştır. Bu değişken birim kök testine tabi tutulur ve ardından tekrardan ADF testi ile durağanlığı kontrol edilir. Durağan çıkan bağımsız değişkenler için d değeri 0 olarak alınmıştır.

ADF Testi Sonucu Birim Kök Testi Uygulaması ve ADF Testinin Tekrarlanması

Bağımsız Değişken	Genişletilmiş Dickey-Fuller (ADF) Testi Sonuçları
Yurt Dışı Satış Adedi	<pre> ----- ADF TESTİ ----- Değişken: Yurt Dışı Satış Adeti Seri: 1.Fark (ModelOlcek) ADF istatistiği : -4.6560 p-değeri : 0.0001 Sonuç : DURAĞAN (H0 reddedildi, p<=0.05) </pre>

Birim kök testi sonucunda 1. farkı alınan bütün bağımsız değişkenler için durağanlık koşulu sağlanmıştır. Birim kök testine tabi tutulan değişkenler için d değeri 1 olarak alınmıştır.

- PA66 GFR30 Hammadesine Ait Bağımsız Değişkenlerin Genişletilmiş Dickey–Fuller (ADF) Test Sonuçları (Orijinal Seri)

Bağımsız Değişken	Genişletilmiş Dickey-Fuller (ADF) Testi Sonuçları
Yurt Dışı Satış Adedi	<pre> ----- ADF TESTİ ----- Değişken: Yurt Dışı Satış Adeti Seri: ModelOlcek ADF istatistiği : -5.9114 p-değeri : 0.0000 Sonuç : DURAĞAN (H0 reddedildi, p<=0.05) [Yurt Dışı Satış Adeti] Seri durağan → d=0. </pre>

Yurt İçi Satış Adedi	<pre> ----- ADF TESTİ ----- Değişken: Yurt İçi Satış Adeti Seri: Model01cek ADF istatistiği : -2.6765 p-değeri : 0.0782 Sonuç : DURAĞAN DEĞİL (H0 reddedilemedi, p>0.05) </pre>
Fire Adedi	<pre> ----- ADF TESTİ ----- Değişken: Fire Adeti Seri: Model01cek ADF istatistiği : -2.2085 p-değeri : 0.2032 Sonuç : DURAĞAN DEĞİL (H0 reddedilemedi, p>0.05) </pre>
Aylık Stokta Kalan Adedi	<pre> ----- ADF TESTİ ----- Değişken: Aylık Stokta Kalan Seri: Model01cek ADF istatistiği : -1.4235 p-değeri : 0.5710 Sonuç : DURAĞAN DEĞİL (H0 reddedilemedi, p>0.05) </pre>
Üretim Adedi	<pre> ----- ADF TESTİ ----- Değişken: Üretim Adeti Seri: Model01cek ADF istatistiği : -4.0132 p-değeri : 0.0013 Sonuç : DURAĞAN (H0 reddedildi, p<=0.05) [Üretim Adeti] Seri durağan → d=0. </pre>

ADF testi sonrasında PA66 GFR30 hammaddesine ait yurt içi satış adedi, fire adedi ve aylık stokta kalan adet değişkenleri durağan çıkmamıştır. Bu değişken birim kök testine tabi tutulur ve ardından tekrardan ADF testi ile durağanlığı kontrol edilir. Durağan çıkan bağımsız değişkenler için d değeri 0 olarak alınmıştır.

ADF Testi Sonucu Birim Kök Testi Uygulaması ve ADF Testinin Tekrarlanması

Bağımsız Değişken	Genişletilmiş Dickey-Fuller (ADF) Testi Sonuçları
Yurt İçi Satış Adedi	<pre> ----- ADF TESTİ ----- Değişken: Yurt İçi Satış Adeti Seri: 1.Fark (Model01cek) ADF istatistiği : -19.7438 p-değeri : 0.0000 Sonuç : DURAĞAN (H0 reddedildi, p<=0.05) </pre>
Fire Adedi	<pre> ----- ADF TESTİ ----- Değişken: Fire Adeti Seri: 1.Fark (Model01cek) ADF istatistiği : -5.3659 p-değeri : 0.0000 Sonuç : DURAĞAN (H0 reddedildi, p<=0.05) </pre>
Aylık Stokta Kalan Adedi	<pre> ----- ADF TESTİ ----- Değişken: Aylık Stokta Kalan Seri: 1.Fark (Model01cek) ADF istatistiği : -3.4599 p-değeri : 0.0091 Sonuç : DURAĞAN (H0 reddedildi, p<=0.05) </pre>

Birim kök testi sonucunda 1. farkı alınan bütün bağımsız değişkenler için durağanlık koşulu sağlanmıştır. Birim kök testine tabi tutulan değişkenler için d değeri 1 olarak alınmıştır.

EK 2 STOK YÖNETİMİ HESAPLAMALARI

Bu ek, Bölüm 5.6’da belirtilen stok yönetimi parametrelerinin (SS ve ROP) hesaplanmasında kullanılan formüller, varsayımlar ve hammaddeler için gerçekleştirilen ayrıntılı hesaplamaları içermektedir.

Kullanılacak Formüller;

$$SS = Z \times \sqrt{LT} \times \sigma_d$$

$$ROP = d \times LT + SS$$

Hesaplamalara başlamadan önce, işletmenin operasyonel verileri gerektiren bazı temel varsayımların yapılması zorunludur:

1. Hizmet Seviyesi (Z): %95 hizmet seviyesinde 1.65 katsayısına karşılık gelmektedir.
2. Tedarik Süresi (LT): 15 gün.
3. Aydaki Ortalama Gün Sayısı: $\frac{360}{12} \cong 30.42$
4. Ortalama Talep (d): $\frac{2025 \text{ Yıllık Talep Miktarı (Kg)}}{365}$
5. σ_d : RMSE değeri temel alınmıştır.

9 kritik hammadde için SS ve ROP hesaplamaları aşağıdaki şekildedir.

- Elastromer Hammaddesi:

$$SS = Z \times \sqrt{LT} \times \sigma_d = 1.65 \times \sqrt{\frac{15}{30.42}} \times 1.498 \cong 1.74$$

$$ROP = d \times LT + SS = 0.68 \times 15 + 1.74 \cong 11.99$$

- Acetal Hammaddesi:

$$SS = Z \times \sqrt{LT} \times \sigma_d = 1.65 \times \sqrt{\frac{15}{30.42}} \times 13.965 \cong 16.18$$

$$ROP = d \times LT + SS = 3.89 \times 15 + 16.18 \cong 74.59$$

- PC Hammaddesi:

$$SS = Z \times \sqrt{LT} \times \sigma_d = 1.65 \times \sqrt{\frac{15}{30.42}} \times 66.175 \cong 76.68$$

$$ROP = d \times LT + SS = 24.59 \times 15 + 76.68 \cong 445.58$$

- ABS3864 Hammaddesi:

$$SS = Z \times \sqrt{LT} \times \sigma_d = 1.65 \times \sqrt{\frac{15}{30.42}} \times 133.865 \cong 155.11$$

$$ROP = d \times LT + SS = 49.48 \times 15 + 155.11 \cong 897.38$$

- PC ABS-IMS Hammaddesi:

$$SS = Z \times \sqrt{LT} \times \sigma_d = 1.65 \times \sqrt{\frac{15}{30.42}} \times 127.487 \cong 147.72$$

$$ROP = d \times LT + SS = 36.24 \times 15 + 147.72 \cong 691.30$$

- PC ABS Hammaddesi:

$$SS = Z \times \sqrt{LT} \times \sigma_d = 1.65 \times \sqrt{\frac{15}{30.42}} \times 38.473 \cong 44.58$$

$$ROP = d \times LT + SS = 7.56 \times 15 + 44.58 \cong 158.01$$

- PC Violet Hammaddesi:

$$SS = Z \times \sqrt{LT} \times \sigma_d = 1.65 \times \sqrt{\frac{15}{30.42}} \times 9.326 \cong 10.81$$

$$ROP = d \times LT + SS = 3.87 \times 15 + 10.81 \cong 68.80$$

- Moblen Hammaddesi:

$$SS = Z \times \sqrt{LT} \times \sigma_d = 1.65 \times \sqrt{\frac{15}{30.42}} \times 1.893 \cong 2.19$$

$$ROP = d \times LT + SS = 0.91 \times 15 + 2.19 \cong 15.89$$

- PA66 GFR30 Hammaddesi:

$$SS = Z \times \sqrt{LT} \times \sigma_d = 1.65 \times \sqrt{\frac{15}{30.42}} \times 4.505 \cong 5.22$$

$$ROP = d \times LT + SS = 1.62 \times 15 + 5.22 \cong 29.51$$