BİR OTOMOTİV SEKTÖRÜ İŞLETMESİNDE YEDEK PARÇA TALEP TAHMİN ANALİZİ

İLKNUR CORE

T.C.
BURSA ULUDAĞ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

BİR OTOMOTİV SEKTÖRÜ İŞLETMESİNDE YEDEK PARÇA TALEP TAHMİN ANALİZİ

İlknur CORE
0009-0004-1643-4564

Dr. Öğr. Üyesi Mehmet AKANSEL
0000-0002-4924-7587
(Danışman)

YÜKSEK LİSANS
ENDÜSTRİ MÜHENDİSLİĞİ ANABİLİM DALI

BURSA – 2024

Her Hakkı Saklıdır

ÖZET

Yüksek Lisans Tezi

BİR OTOMOTİV SEKTÖRÜ İŞLETMESİNDE YEDEK PARÇA TALEP TAHMİN ANALİZİ

İlknur CORE

Bursa Uludağ Üniversitesi
Fen Bilimleri Enstitüsü
Endüstri Mühendisliği Anabilim Dalı

Danışman: Dr. Öğr. Üyesi Mehmet AKANSEL

Otomotiv yedek parça taleplerinin tahmini sektördeki işletmelerin temel bir sorunu olarak değerlendirilmektedir. Stok seviyelerinin ve üretim planlarının doğru biçimde belirlenmesi, üretim verimliliğinin artırılması ve müşteri taleplerinin zamanında karşılanması hayati önem taşır. Bu nedenle, yedek parça talebi üzerine yapılan tahminler, otomotiv üreticileri için stratejik kararların alınmasında temel bir rol oynamaktadır. Talep tahmini, üretim kapasitesinin belirlenmesi ve tedarik zincirinin yönetilmesi için önemli bir kılavuz sağlar. Bu bağlamda, doğru talep tahmini, otomotiv sektöründeki işletmelerin rekabet avantajı elde etmesine ve sürdürülebilir başarıya ulaşmasına yardımcı olur.

Bu çalışmada, Türkiye'deki bir otomotiv sektöründe yedek parça talep tahmini için çeşitli yöntemler karşılaştırılmıştır. 2018 yılının 3. ayında seri üretimine başlanan bir projenin 60 aylık sürecinde elde edilen veriler üzerinden analiz gerçekleştirilmiştir. Daha önceki literatür taramaları, talep tahmini için zaman serileri ve makine öğrenme yöntemlerinin yaygın olarak kullanıldığını ve yedek parça talep tahmini alanında bu yöntemlere yönelik birçok çalışmanın olduğunu ortaya koymuştur. Yaygın biçimde kullanılan istatistiksel tahmin yöntemlerinden biri olan ARIMA zaman serisi yöntemi ve NNAR (Nonlinear Autoregressive) ve MLP (Multilayer Perceptron) adlı makine öğrenmesi yöntemleri en iyi tahmin yöntemini belirlemek ve 6 aylık yedek parça talep tahminlerini elde etmek için kullanılmıştır. Yapılan analizler sonucunda, projenin farklı versiyonları için MLP yönteminin bir örnek veride ve NNAR yönteminin ise iki örnek veride en iyi tahmin yöntemi olduğu belirlenmiştir. Bu çalışmanın sektördeki işletmelere ve araştırmacılara, yedek parça talep tahmini süreçlerinde kullanılacak yöntemleri seçmede bir rehberlik sağlaması hedeflenmiştir.

Anahtar Kelimeler: Yedek parça, talep tahmini, zaman serisi, MLP, NNAR, yapay sinir ağları **2024, viii + 87 sayfa.**

ABSTRACT

MSc Thesis

An Analysis of Spare Parts Demand Forecasting in the Automotive Sector Company

İlknur CORE

Bursa Uludağ University

Graduate School of Natural and Applied Sciences

Department of Industrial Engineering

Supervisor: Dr. Mehmet AKANSEL

The prediction of automotive spare parts demand is considered a fundamental issue for businesses in the industry. Accurately determining stock levels and production plans is crucial for increasing production efficiency and meeting customer demands in a timely manner. Therefore, forecasts of spare parts demand play a key role in strategic decision-making for automotive manufacturers. Demand forecasting serves as an important guide for determining production capacity and managing the supply chain. In this context, accurate demand forecasting helps businesses in the automotive sector achieve a competitive advantage and sustainable success.

This study compares various methods for forecasting spare parts demand in the automotive sector in Turkey. An analysis was conducted using data collected over a 60-month period from a project that began mass production in the third month of 2018. Previous literature reviews have revealed that time series and machine learning methods are widely used for demand forecasting, with many studies focused on these methods in the field of spare parts demand forecasting. The ARIMA time series method, a commonly used statistical forecasting method, along with machine learning methods such as NNAR (Nonlinear Autoregressive) and MLP (Multilayer Perceptron), were utilized to determine the best forecasting method and to obtain 6-month spare parts demand forecasts. The analysis results indicated that the MLP method was the best forecasting method for one sample datasets and the NNAR method for two sample datasets for different versions of the project. This study aims to provide guidance to businesses and researchers in the industry on selecting methods to use in spare parts demand forecasting processes.

Key words: Spare Parts, Demand Forecasting, Time Series, MLP, NNAR, Artificial Neural Networks **2024, viii + 87 pages.**

TEŞEKKÜR

Tez çalışmam ve yüksek lisans eğitimim süresince değerli bilgi ve tecrübeleri ile bana yol gösteren danışmanım Sayın Dr. Öğr. Üyesi Mehmet Akansel'e teşekkürlerimi sunarım.

Tüm eğitim hayatım boyunca maddi ve manevi desteklerini hiçbir zaman esirgemeyen sevgili aileme en içten teşekkürlerimi sunarım.

İlknur CORE

12/07/2024

İÇİNDEKİLER

ÖZET..... i
ABSTRACT.....ii
TEŞEKKÜR.....iii
SİMGELER ve KISALTMALAR DİZİNİ.....v
ŞEKİLLER DİZİNİ.....vi
ÇİZELGELER DİZİNİ.....viii
1. GİRİŞ..... 1
2. KAYNAK ARAŞTIRMASI.....2
3. MATERYAL VE YÖNTEM.....8
3.1. Zaman Serisi Yöntemleri.....9
3.2. Yapay Sinir Ağları.....15
4. BULGULAR.....22
4.1. Tahmin Yöntemlerinin R ile Uygulanması.....23
4.2.Talep Tahmin Sonuçları.....63
5. TARTIŞMA VE SONUÇ.....68
KAYNAKLAR.....69
EKLER.....72
EK 1.TAHMİN YÖNTEMİNDE KULLANILAN GEÇMİŞ TALEP.....72
DEĞERLERİ.....72
EK 1. TAHMİN YÖNTEMİNDE KULLANILAN GEÇMİŞ TALEP DEĞERLERİ...73
EK 2. SP1 İÇİN ARIMA İLE TALEP TAHMİNİ R KODLARI.....75
EK 3. SP2 İÇİN ARIMA İLE TALEP TAHMİNİ R KODLARI.....77
EK 4. SP3 İÇİN ARIMA İLE TALEP TAHMİNİ R KODLARI.....79
EK 5. SP1 İÇİN MLP İLE TALEP TAHMİNİ R KODLARI.....81
EK 6. SP2 İÇİN MLP İLE TALEP TAHMİNİ R KODLARI.....82
EK 7. SP3 İÇİN MLP İLE TALEP TAHMİNİ R KODLARI.....83
EK 8. SP1 İÇİN NNAR İLE TALEP TAHMİNİ R KODLARI.....84
EK 9. SP2 İÇİN NNAR İLE TALEP TAHMİNİ R KODLARI.....85
EK 10. SP3 İÇİN NNAR İLE TALEP TAHMİNİ R KODLARI.....86
ÖZGEÇMİŞ.. 87

SİMGELER ve KISALTMALAR DİZİNİ

Simgeler	Açıklama
p	Otokorelasyon (AR) modelinin derecesi
d	Fark alma işlem sayısı
q	Hareketli ortalama (MA) modelinin derecesi
P	Mevsimsel otokorelasyon (SAR) modelinin derecesi
D	Mevsimsel fark alma işlem sayısı
Q	Mevsimsel hareketli ortalama (SMA) modelinin derecesi
k	Gizli katmandaki düğüm sayısı
m	Mevsimsel periyodun uzunluğu

Kısaltmalar	Açıklama
MLP	Çok Katmanlı Algılayıcı
NNAR	Doğrusal Olmayan Otoregresif Sinir Ağı
ARIMA	Otokorelasyonlu Entegre Hareketli Ortalama
SP1	Yedek Parça 1. versiyon
SP2	Yedek Parça 2. versiyon
SP3	Yedek Parça 3. versiyon
XGBoost	Aşırı Gradyan Artırma
RC	Tekrarlayan Sinir Ağı
LightGBM	Hafif Gradyan Artırma Makinesi
LSTM	Uzun Kısa Süreli Bellek
Pbands	Olasılık Bantları
YSA	Yapay Sinir Ağları
RNN	Tekrarlayan Sinir Ağları
K-S	Kolmogrov-Simirnov

ŞEKİLLER DİZİNİ

		Sayfa
Şekil 3.1.	Çalışma adımlarını gösteren akış şeması	8
Şekil 3.2.	Çok Katmanlı İleri Beslemeli Yapay Sinir Ağı	16
Şekil 4.1.	Uygulan işlemlere ait akış şeması	23
Şekil 4.2.	SP1 için zaman serisi grafiği	24
Şekil 4.3.	SP1 için ACF grafiği	25
Şekil 4.4.	SP1 için PACF grafiği	26
Şekil 4.5.	SP1 Durağanlık test değerleri	26
Şekil 4.6.	SP1 Fark serisi durağanlık test değerleri	27
Şekil 4.7.	Farkı alınan SP1 için ACF grafiği	27
Şekil 4.8.	Farkı alınan SP1 için PACF grafiği	28
Şekil 4.9.	SP1 için hata dağılım grafikleri	28
Şekil 4.10.	SP1 Mevsimsellik testi sonucu	28
Şekil 4.11.	SP1 model uyum test istatistiği değerleri	30
Şekil 4.12.	SP1 tahmin sonuçlarının hata dağılım grafikleri	30
Şekil 4.13.	SP1 Orijinal seri ve tahmin serisinin dağılım grafiği	31
Şekil 4.14.	SP2 için zaman seri grafiği	31
Şekil 4.15.	SP2 için ACF grafiği	32
Şekil 4.16.	SP2 için PACF grafiği	33
Şekil 4.17.	SP2 Durağanlık test değerleri	33
Şekil 4.18.	SP2 Fark serisi durağanlık test değerleri	33
Şekil 4.19.	Farkı alınan SP2 için ACF grafiği	34
Şekil 4.20.	Farkı alınan SP2 için PACF grafiği	34
Şekil 4.21.	SP2 için hata dağılım grafikleri	35
Şekil 4.22.	SP2 Mevsimsellik testi sonucu	35
Şekil 4.23.	SP2 model uyum test istatistiği değerleri	37
Şekil 4.24.	SP2 Tahmin serisinin hata dağılım grafiği	37
Şekil 4.25.	SP2 Orijinal seri ve tahmin serisinin dağılım grafiği	38
Şekil 4.26.	SP3 için zaman seri grafiği	38
Şekil 4.27.	SP3 için ACF grafiği	39
Şekil 4.28.	SP3 için PACF grafiği	39
Şekil 4.29.	SP3 Durağanlık test değerleri	40
Şekil 4.30.	SP3 Fark serisi durağanlık test değerleri	40
Şekil 4.31.	Farkı alınan SP3 için ACF grafiği	41
Şekil 4.32.	Farkı alınan SP3 için PACF grafiği	41
Şekil 4.33.	SP3 Mevsimsellik testi sonucu	42
Şekil 4.34.	SP3 model uyum test istatistiği değerleri	43
Şekil 4.35.	SP3 Tahmin serisinin hata dağılım grafiği	43
Şekil 4.36.	SP3 Orijinal seri ve tahmin serisinin dağılım grafiği	44
Şekil 4.37.	SP1 MLP sinir ağı grafiği	45
Şekil 4.38.	SP1 MLP model çıktısı	46
Şekil 4.39.	SP1 yakınsama Grafiği (MAPE)	46
Şekil 4.40.	SP1 Orijinal seri ve MLP tahmin serisinin dağılım grafiği	47
Şekil 4.41.	SP2 MLP sinir ağı grafiği	48
Şekil 4.42.	SP2 MLP model çıktısı	49
Şekil 4.43.	SP2 yakınsama Grafiği (MAPE)	49
Şekil 4.44.	SP2 Orijinal seri ve MLP tahmin serisinin dağılım grafiği	50

Şekil 4.45.	SP3 MLP sinir ağı grafiği	52
Şekil 4.46.	SP3 MLP model çıktısı	52
Şekil 4.47.	SP3 yakınsama Grafiği (MAPE)	53
Şekil 4.48.	P3 Orijinal seri ve MLP tahmin serisinin dağılım grafiği	54
Şekil 4.49.	SP1 NNAR model çıktısı	56
Şekil 4.50.	SP1 yakınsama Grafiği (MAPE)	56
Şekil 4.51.	SP3 Orijinal seri ve NNAR tahmin serisinin dağılım grafiği	57
Şekil 4.52.	SP2 NNAR model çıktısı	59
Şekil 4.53.	SP2 yakınsama Grafiği (MAPE)	59
Şekil 4.54.	SP2 Orijinal seri ve NNAR tahmin serisinin dağılım grafiği	60
Şekil 4.55.	SP3 NNAR model çıktısı	61
Şekil 4.56.	SP3 yakınsama Grafiği (MAPE)	62
Şekil 4.57.	SP3 Orijinal seri ve NNAR tahmin serisinin dağılım grafiği	63

ÇİZELGELER DİZİNİ

		Sayfa
Çizelge 4.1.	SP1 ARIMA(p,1,q)(P,0,Q)$_{12}$ hata değerleri	29
Çizelge 4.2.	SP1 için 6 aylık tahmin değerleri	29
Çizelge 4.3.	SP2 ARIMA(p,1,q)(P,0,Q)$_{12}$ hata değerleri	36
Çizelge 4.4.	SP2 için 6 aylık tahmin sonuçları	36
Çizelge 4.5.	SP3 ARIMA(p,1,q)(P,0,Q)$_{12}$ hata değerleri	42
Çizelge 4.6.	SP3 6 aylık tahmin sonuçları	42
Çizelge 4.7.	SP1 MLP Hiper parametre MAPE Değerleri Tablosu	45
Çizelge 4.8.	SP1 MLP test verisi ile tahmin hata değerleri	46
Çizelge 4.9.	SP1 (MLP) 6 aylık tahmin değerleri	47
Çizelge 4.10.	SP2 MLP Hiperparametre MAPE Değerleri Tablosu	48
Çizelge 4.11.	SP2 MLP t test verisi ile tahmin hata değerleri	49
Çizelge 4.12.	SP2 (MLP) 6 aylık tahmin değerleri	50
Çizelge 4.13.	SP3 MLP Hiperparametre MAPE Değerleri Tablosu	51
Çizelge 4.14.	SP3 MLP test verisi ile tahmin hata değerleri	52
Çizelge 4.15.	SP3 (MLP) 6 aylık tahmin değerleri	53
Çizelge 4.16.	SP1 NNAR Hiperparametre MAPE Değerleri Tablosu	55
Çizelge 4.17.	SP1 NNAR test verisi ile tahmin hata değerleri	56
Çizelge 4.18.	SP1 (NNAR) 6 aylık tahmin değerleri	57
Çizelge 4.19.	SP2 NNAR Hiperparametre MAPE Değerleri Tablosu	58
Çizelge 4.20.	SP2 NNAR test verisi ile tahmin hata değerleri	59
Çizelge 4.21.	SP2 (NNAR) 6 aylık tahmin değerleri	60
Çizelge 4.22.	SP3 NNAR Hiperparametre MAPE Değerleri Tablosu	61
Çizelge 4.23.	SP3 NNAR test verisi ile tahmin hata değerleri	62
Çizelge 4.24.	SP3 (NNAR) 6 aylık tahmin değerleri	63
Çizelge 4.25	SP1-SP2-SP3 serileri için yöntemlerin karşılaştırılması (MAPE ölçütü ile)	63
Çizelge 4.26.	SP1 tahmin ve gözlemlenen değerlerin karşılaştırılması (MAPE ölçütü ile)	64
Çizelge 4.27.	SP2 tahmin ve gözlemlenen değerlerin karşılaştırılması (MAPE ölçütü ile)	65
Çizelge 4.28.	SP3 tahmin ve gözlemlenen değerlerin karşılaştırılması (MAPE ölçütü ile)	66
Çizelge 4.29.	En iyi tahmin yöntemlerinin verdiği talep tahmin değerleri	67

1. GİRİŞ

Talep tahmini, işletmelerin ürün ve hizmet taleplerini önceden belirleyerek arz talep dengesini sağlama, stok yönetimi ve üretim planlaması gibi stratejik kararları etkileyen kritik bir unsurdur. Gelişmiş bilgi sistemleri, anlık bilgi paylaşımları ve sürekli güncellenen tahmin bilgileri, talep tahminindeki hataları azaltmaya yardımcı olmaktadır. Ayrıca, talep tahmininin doğru yapılması, müşteri memnuniyetini artırabilir, işletmelerin rekabet avantajını sürdürmesine katkı sağlayabilir ve talep riskini azaltarak işletmelerin daha etkin bir şekilde yönetilmesine olanak tanır (Çıkmak ve ark., 2021).

Talep tahmini, tedarik zinciri yönetiminde kritik bir rol oynayarak planlama, kapasite ve envanter kontrol kararları üzerinde önemli bir etkiye sahiptir. Doğru tahmin edilmeyen talep miktarları işletme için gereksiz envanter birikimine veya müşteri taleplerini karşılamakta yetersiz kalmaya yol açabilir, bu da işletme maliyetlerini artırabilir. Bu nedenle, son müşteri talebinin belirsiz olduğu durumlarda, doğru bileşen taleplerini tahmin etmek ve maliyetleri azaltmak için çok değişkenli yaklaşımlar önem arz etmektedir (Gonçalves ve ark., 2021).

Otomotiv endüstrisi, dünya ekonomisinin en büyük sektörlerinden biridir ve aynı zamanda güçlü bir istihdam çarpanına sahiptir. Talep tahmini, tedarik zinciri yönetimi için kritik bir unsurdur, çünkü bu tahminler, otomotiv endüstrisinin tedarik zinciri ve üretim organizasyonunu doğrudan etkiler (Rožanec ve ark., 2021).

Talep tahminleri, üreticilere ve distribütörlere, yedek parça tedarik zincirini etkili bir şekilde yönetme ve müşteri beklentilerini karşılama konusunda önemli bilgiler sağlar. Otomotiv sektöründeki yedek parça talep tahmini, orijinal ekipman üreticileri (OEM) ve bağımsız distribütörler için kritik bir unsurdur. Doğru yedek parça tahmini, üretim süreçlerinin iyileştirilmesine, envanter maliyetlerinin düşürülmesine ve müşteri memnuniyetinin artırılmasına olanak tanır. Ayrıca, değişen pazar koşullarına hızlı bir şekilde uyum sağlanmasına yardımcı olur (Achetoui ve ark., 2019).

Otomotiv yedek parça talep tahmini, tedarik zinciri yönetimindeki zorlukları ele almak ve müşteri taleplerini karşılamak için vazgeçilmezdir. Doğru ve güncel tahminler, talep dalgalanmalarına uyum sağlama ve rekabet avantajı elde etme imkânı sunar. Bu nedenle, sektörde faaliyet gösteren şirketlerin talep tahmini süreçlerine odaklanmaları önemli bir gereksinim haline gelmiştir (Achetoui ve ark., 2019).

Mevsimsel talep değişimleri, ürün çeşitliliği ve rekabetin sürekli evrimi, otomotiv şirketlerinin talebe yönelik planlama yapmasını gerektirir. Uzun teslim süreleri ve hızla değişen ürün özellikleri, doğru tahminleri elde etmeyi zorlaştırabilir. Bu bağlamda, otomotiv sektöründe talebe yönelik planlama, operasyonel etkinlikleri artırarak müşteri taleplerine hızlı ve doğru bir şekilde yanıt vermesini hedefler (Erturun ve Dursun, 2022).

Gelecekteki talebin doğru biçimde tahmin edilebilmesi üreticilere ürünleri için pazar payı hedefleri belirleme, tedarik süreci kapsamında stratejik karar alma ve gerekli kaynakları tahsis etme imkânı sağlar. Doğru talep tahminleri, stok fazlalığı veya yokluğu sorunlarını azaltır ve tedarik zinciri verimliliğini artırır. Talep tahminlerinin iyileştirilmesi için gerekli verilerin zamanında ve etkin biçimde toplanması gereklidir. Bu süreçte teknolojik olarak mümkün olan otomasyon, dijitalleşme ve veri paylaşımı yöntemleri kullanılabilir (Rožanec ve ark., 2021).

İkinci bölümde, yedek parça talep tahmini için yapılan çeşitli çalışmalardan bahsedilirken, farklı yöntemlerin etkinliği ve gelecekteki araştırmalara yönelik vurgular ele alınmıştır. Üçüncü bölümde, yedek parça talep tahmini için kullanılmış olan yöntemler, modeller ve kullanılan parametrelere ait açıklamalar bulunmaktadır. Dördüncü bölümde, yedek parça versiyonları için en uygun yöntem ve model kullanılarak elde edilen tahmin sonuçları sunulmuş ve değerlendirilmiştir. Beşinci bölümde ise, çalışma kapsamında elde edilen bulgular özetlenmiş ve bu bulguların yedek parça talep tahmini üzerindeki etkileri tartışılmıştır. Ayrıca, gelecekte yapılacak araştırmalar için öneriler sunulmuştur.

2. KAYNAK ARAŞTIRMASI

Zhang (2003), zaman serisi analizi ve tahmininin önemini vurgulayarak, ARIMA ve yapay sinir ağlarının bu alandaki rolünü ele almaktadır. Bu çalışmada, ARIMA ve yapay sinir ağlarını birleştiren bir hibrit model önerilmektedir. Hibrit modelin farklı veri ilişkilerini bulmayı sağlayarak karmaşık durumlarda tahmin performansını artırabileceği belirtilmiştir. Ayrıca, benzer modeller yerine farklı modellerin birleştirilmesinin daha etkili bir yöntem olabileceği vurgulanmaktadır. Hibrit modelin tahmin belirsizliğini azaltarak ve verilere uyum sağlayarak daha iyi sonuçlar verebileceği gösterilmiştir.

Şahin ve ark. (2013), havacılık yedek parça taleplerini tahmin etmek için Croston tabanlı ve Yapay Sinir Ağları (ANN) yöntemlerini kullanarak ortaya çıkan sonuçları karşılaştırmaktadır. Bulgular, yeni girdi değişkenleri ile Yapay Sinir Ağı modellerinin Croston tabanlı modelleri tahmin performansı açısından geride bıraktığını göstermektedir. Buna karşılık, Croston tabanlı Leven ve Segerstedt modeli, basit bir seçenek olarak önerilmektedir. Gelecekteki değerlerin en isabetli biçimde tahmin edilmesi istendiğinde yapay sinir ağları kapsamındaki MLP modelinin tercih edilmesi önerilmektedir. Düzensiz talepler için Croston tabanlı yöntemler etkili olsa da taleplerin rastsallığı arttığında yapay sinir ağlarının daha iyi bir tahmin aracı haline geldiği sonucuna varılmaktadır.

De Melo Menezes ve ark. (2015), yedek parça talep tahminlerinin çeşitli yöntemlerle elde edilen sonuçlarını sunmaktadır. İstatistiksel yöntemlerin (ARIMA ve Croston) her veri seti için tam doğrulukla tahmin oluşturamadığı sonucuna varılmıştır. Yapay sinir ağlarının (MLP ve RC) ise istatistiksel yöntemlere göre daha kesin tahminler sağladığı gözlemlenmiştir. Özellikle RC'nin yüksek ve düşük talep değerlerini tahmin etmedeki başarısı dikkat çekicidir. Bu sonuçlar, yapay sinir ağlarının yedek parça talep tahmini gibi karmaşık problemleri çözme yeteneğini vurgulamaktadır.

Vargas ve Cortés (2017), otomobil yedek parça tedarik zinciri için en uygun maliyeti veren tahmin yöntemlerini incelemiştir. Literatürde başarılı örnekleri bulunan ANN yöntemleri umut verici bulunmuş ve örnek dönemde iyi bir uyum sağlamıştır. Buna karşılık, gelecek dönemler için ANN performansı düşmüş ve istikrarlı olmamıştır. Diğer yandan, ARIMA modelleri genel olarak en iyi performansı sergilemiş ve tahminlerde istikrarlı sonuçlar vermiştir.

Amirkolaii ve ark. (2017), iş jeti yedek parça tedarik zincirlerinde karşılaşılan düzensiz ve belirsiz talep desenlerini daha doğru tahmin etmeye odaklanmaktadır. Geleneksel tahmin yöntemlerinin bu tür taleplere uygun olmadığı ve veri tabanlı yapay sinir ağı temelli yöntemlerin daha iyi sonuçlar sağlayabileceği vurgulanmaktadır. Araştırma sonuçları, iş jeti yedek parça tedarik zincirlerinde yapay sinir ağlarının (YSA) özellikle birden fazla özelliği tek bir parça ile kullanıldığında en iyi tahmin doğruluğunu sağladığını göstermektedir. Ayrıca, talep tahmin yöntemlerinin her bir parça veya talep sınıfı için ayrı ayrı seçilmesinin hesaplama maliyetlerini ve karmaşıklığı azaltabileceği vurgulanmaktadır.

Kim ve ark. (2017), tüketici ürünlerinin ömrünün sona erdiği dönemde yedek parça talep tahmini sorununa odaklanmaktadır. Özellikle tüketici ürünleri için yedek parça talebi, tüketicilerin davranışları, fiyatlandırma ve ürünün kalan değeri gibi faktörlere bağlı olarak değişmektedir. Bu sorunu çözmek için kurulu taban (installed base) kavramı önerilmekte ve bu kavram farklı ürün özellikleri ve tüketici pazarı dinamikleri için uygun kurulu taban türleri kullanarak uygulanmaktadır. Elde edilen sonuçlar, bu yöntemin geçmiş talep yapılarına kıyasla daha hassas tahminler sağladığını göstermektedir. Bu metodoloji, üreticilere yedek parça üretimi kararları konusunda daha bilinçli ve veri destekli kararlar alma imkânı sunmakta ve bu da tüketici ürünleri endüstrisinde yedek parça yönetimi için önemli bir katkı sağlamaktadır.

Silva ve ark. (2019), NNAR (Neural Network Autoregressive) algoritmasını kullanarak mevsimsel turizm talebi verileri üzerinde tahminler yapmıştır. Ancak bu tahminlerin yetersiz olduğu gözlemlenmiştir. Bu nedenle, tahminlerin doğruluğunu artırmak için

gürültüyü azaltma yöntemi olarak "denoised" önerilmiştir. Çalışma kapsamında, on Avrupa ülkesinin aylık turizm talebi verileri üzerinde NNAR modelleri hem ham veriye hem de "düzeltme" işleminden geçmiş (Tekil Spektrum Analizi ile gürültüsüzleştirilmiş) veriye uygulanmıştır. Ardından, elde edilen tahminler karşılaştırılmıştır. Daha sonra, "düzeltme" işleminden geçmiş NNAR tahminleri parametrik ve nonparametrik referans tahmin modelleriyle karşılaştırılmıştır. Çalışma, mevsimsellik hipotezine karşı olarak, "düzeltme" işleminin NNAR tahminlerinin doğruluğunu artırmada istatistiksel olarak anlamlı bir etkisi olduğunu göstermiştir. Bu bulguyla, NNAR tahmin yeteneklerini geliştirmede temel etkenin mevsimsellik değil gürültü olduğu öne sürülmüştür.

Van der Auweraer ve ark. (2019), yedek parça talep tahminine ilişkin yapılan araştırmaların tarihsel talep verilerini kullanarak yedek parça talebini sınıflandırma ve tahmin etme yöntemlerine odaklandığını, ancak neden-sonuç ilişkisi tahmin tekniklerine daha az dikkat ettiğini belirtmektedir. Kurulu taban bilgisi kullanımının son yıllarda arttığı, bu bilginin büyük miktarda verinin mevcut ve analiz edilmesini gerektirmesinin bu artışta etkili olduğu ifade edilmektedir. Ayrıca, kurulu taban bilgisi kullanımının, ürün yaşam döngüsünün başlangıç ve son aşamalarında daha etkili olduğu vurgulanmaktadır.

Turrini ve Meissner (2019), yedek parça envanter yönetiminin, doğru dağılımın seçilmesinin kritik bir unsur olduğunu ve bu konunun literatüre önemli bir katkı sağladığını belirtmiştir. Araştırmanın sonuçları, geleneksel Kolmogorov-Smirnov (K-S) testinin envanter performansını artırmak amacıyla uygun bir araç olmadığını vurgulamakta ve değiştirilmiş K-S testinin daha etkili sonuçlar sunduğunu ortaya koymaktadır. Ayrıca, doğru dağılım seçiminin sadece etkin bir envanter performansı için değil, maliyet tasarrufu için de önemli olduğu vurgulanmıştır. Bu nedenle, doğru dağılımın seçilmesi, envanter performansını iyileştirmek isteyenler için bir öncelik olmalıdır.

Pawar ve Tiple (2019), yedek parça taleplerinin doğru tahmin edilmesini sağlayan bir model geliştirmeye odaklanmaktadır. Yedek parça talep tahmini için makine öğrenmesi ve yapay sinir ağı yaklaşımlarını kullanarak anti-uçak füzelerinin yedek parça talebinin

tahmin edilmesine yönelik yeni bir yöntem sunmaktadır. Ekonomik sipariş miktarı (ESM) kavramını dahil ederek bütçeyi dikkate alırken en uygun ürün miktarlarını sipariş etmeyi önermektedir. XGBoost ve MLP'nin diğer makine öğrenim yöntemleri karşısında üstün olduğu sonuçları elde edilmiştir.

Ma ve ark. (2021), otomobil yedek parça talebinin derin öğrenme algoritmaları kullanılarak tahmin edilmesini ele almaktadır. Beş farklı derin öğrenme modeli, geleneksel makine öğrenme algoritması olan LightGBM ile karşılaştırılmıştır. Çinli bir otomobil üreticisinin satış sonrası servis departmanından gelen gerçek veriler kullanılarak yapılan deneyler, derin öğrenme modellerinin otomobil yedek parça talebi tahminini etkili bir şekilde çözebileceğini göstermektedir. Bu modeller arasında LSTM en iyi sonuçları vermiş ve dengeli bir performans için önerilmiştir. Derin öğrenme modelleri, otomobil yedek parça talebi tahmininde diğer geleneksel yöntemlere kıyasla daha yüksek potansiyele sahiptir ve ağ yapısındaki uyarlamalar sayesinde daha etkin tahminler elde edilebilmektedir.

Chandriah ve Naraganahalli (2021), yedek parça talebi tahminini geliştirmek amacıyla Tekrarlayan Sinir Ağları (RNN) ve Uzun Kısa Vadeli Hafıza (LSTM) kullanarak yeni bir yöntem sunmaktadır. Yedek parça talebi, organizasyonlar için maliyeti azaltma ve stok yokluğunu önleme açısından hayati bir öneme sahiptir. Bu yöntem, satış verilerini kullanarak RNN-LSTM ve güncellenmiş Adam algoritması ile eğitmektedir. Güncellenmiş Adam algoritması, LSTM ağırlıklarını güncelleyerek düşük hata ve yüksek doğruluk seviyelerine ulaşmayı amaçlar. Ayrıca, bu yöntem stok hacmini azaltarak yedek parça yönetimini iyileştirir ve talep tahminlerinde daha yüksek doğruluk elde etmeye çalışır. Araştırma sonuçları, mevcut yöntemlere kıyasla önerilen RNN ve LSTM yaklaşımının etkili bir şekilde performans gösterdiğini ve yedek parça talebini başarıyla tahmin ettiğini göstermektedir.

Kolková ve Ključnikov (2021), işletmelerin satın alma planlaması ve üretim süreçlerini düzenleme gereksinimlerini ve bu alandaki zorlukları ele almaktadır. Geleneksel istatistiksel yöntemlere alternatif olarak, Pbands teknik göstergesinin kısa vadeli talep

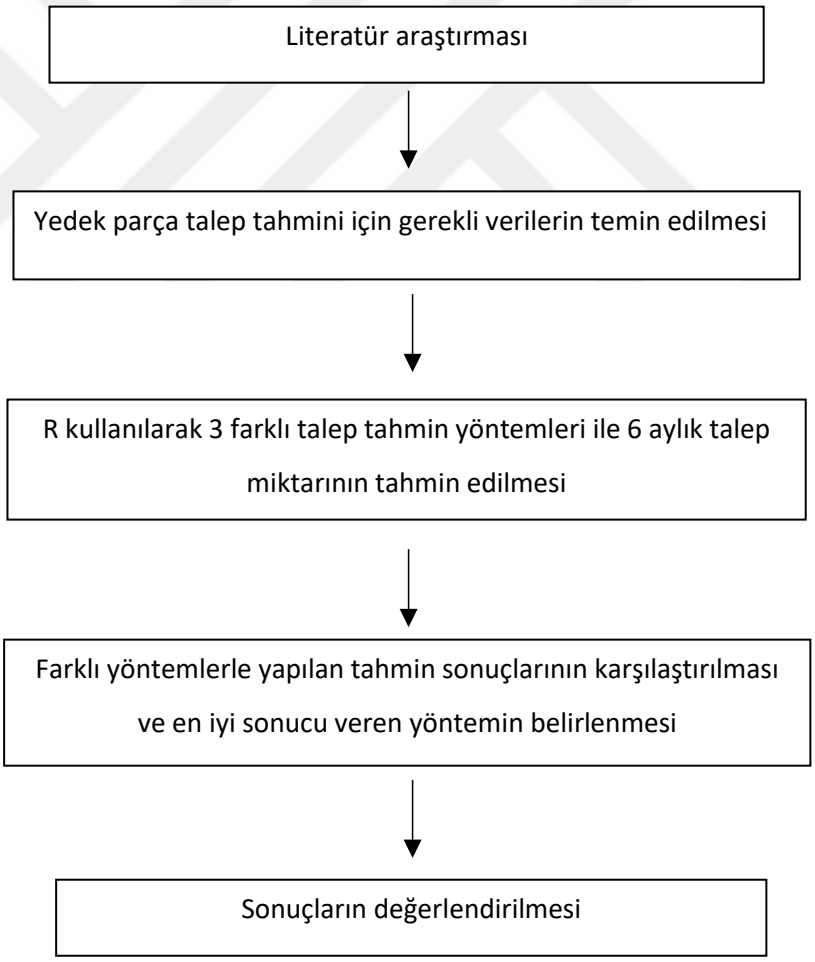
değişikliklerini tahmin etme yeteneği üzerinde odaklanılmıştır. Çalışmanın sonuçları, Pbands yaklaşımının karmaşık istatistiksel yöntemlerin yerine kullanılabileceğini ve hızlı, basit ve etkili bir talep tahmini sağladığını göstermektedir. Buna karşılık, bu yöntemin uzun vadeli eğilim tahminleri için uygun olmadığı belirtilmiştir. Araştırma, işletmelerin talep tahminlerini geliştirmek ve hızlandırmak için teknik analiz yöntemlerine daha fazla dikkat edilmesi gerektiğini vurgulamaktadır.

Kmiecik ve ark. (2022), işletmelerin karar alma süreçlerini iyileştirmek için gelişmiş talep tahmin sistemlerini kullanmanın önemini vurgulamaktadır. Özellikle otomotiv üreticisi bir vaka çalışmasına odaklanarak, ARIMA, ELM (Extreme Learning Machine) ve NNAR (Neural Network Autoregressive) gibi çeşitli tahmin algoritmaları değerlendirilmiştir. Sonuçlar, ELM algoritmasının diğerlerine göre daha yüksek doğruluk sağladığını göstermektedir. ARIMA modellerinin ise zayıf performans sergilemesi nedeniyle geçmiş satış verilerinin tamamı yerine geçen yılın aynı dönemine ait verileri temel almanın daha uygun olacağı öne sürülmektedir.

Stragliotto ve ark. (2023), uzun vadeli planlamanın şirketler için kritik öneme sahip olduğunu ve doğru tahminlerin başarılı sonuçlar elde etmede belirleyici olduğunu vurgulamaktadır. Bir aylık sipariş tahmininde üç farklı modelin (Mevsimsel Otoregresif Bütünleşik Hareketli Ortalama, Yapay Sinir Ağı Otoregresif ve Prophet model) performansı incelenmiştir. Veri analizi ile veri setindeki karakteristikler belirlenmiş ve her modelin performansı, RMSE (Kök Ortalama Kare Hatası) ve MAPE (Ortalama Mutlak Yüzde Hatası) ve İlişkisel Hata gibi ölçütler kullanılarak değerlendirilmiştir. Modellerin kabul edilebilir düzeyde performans gösterdiği ve belirsizlik düzeyinin de değerlendirildiği belirtilmiştir.

3. MATERYAL VE YÖNTEM

Bu çalışma, Türkiye'deki bir otomotiv yan sanayi şirketinin üç farklı versiyonunu içeren bir projenin yedek parça talep tahminini ele almaktadır. Otomotiv endüstrisindeki hızlı değişimlere ayak uydurmak, stok yönetimini iyileştirmek ve üretim süreçlerini daha verimli hale getirmek amacıyla yapılan bu araştırma, şirketin sürdürülebilirlik ve rekabet avantajını artırmayı hedeflemektedir. Yedek parça talep tahmininin doğru ve etkili bir şekilde yapılması hem maliyetleri azaltacak hem de müşteri memnuniyetini artıracaktır. Bu bağlamda, çalışmanın kapsamı, yöntemleri ve beklenen katkıları ayrıntılı bir şekilde ele alınacaktır. Çalışma için izlenen adımlar Şekil 3.1'de gösterilmektedir:



Şekil 3.1. Çalışma adımlarını gösteren akış şeması

3.1. Zaman Serisi Yöntemleri

Basit Üstel Düzleştirme Yöntemi: Basit Üstel Düzleştirme yöntemi, geçmiş dönem değerlerinin gelecek dönem değerleri üzerinde üstel biçimde azalan etkiye sahip olduğu varsayımına dayalı olarak hesaplama yapar. Bu yöntem, mevsimsellik ve eğilim içeren verileri ele alamaz. Bir sonraki dönem değeri tahmin edilirken, geçmiş ve tahmin edilen veriler farklı ağırlıklarla toplanır ve tahmin hatasını en düşük düzeye indiren α değeri seçilir (Makridakis ve ark., 1998).

$$\bar{Y}_{t+1} = \alpha Y_t + (1- \alpha)\bar{Y}_t \quad (3.1)$$

$\bar{Y}_{t+1}$: Bir sonraki dönem için belirlenen tahmin değeri

Y_t: Mevcut dönemin gerçek değeri

$\bar{Y}_t$: Mevcut dönem için belirlenen tahmin değeri

α: Düzleştirme katsayısı (smoothing constant), $(0 < \alpha < 1)$

Holt Yöntemi: Basit Üstel Düzleştirme Yöntemi'ne kıyasla daha karmaşıktır çünkü eğilimi de hesaba katar (Makridakis ve ark., 1998). Bu yöntemde iki katsayı kullanılır: α değeri ortalama düzey ve β değeri ise eğilim tahmini için kullanılır.

$$L_t = \alpha\, Y_t + (1- \alpha)\, (L_{t-1}+T_{t-1}) \quad (3.2)$$

$$T_t = \beta\, (L_t - L_{t-1}\,) + (1 - \beta)\, T_{t-1} \quad (3.3)$$

$$\bar{Y}_{t+p} = L_t \; + pT_t \quad (3.4)$$

L_t: Ortalama düzey tahmini

α: Düzleştirme katsayısı, $(0 < \alpha < 1)$

Y_t: t dönemindeki gerçek değer

β: Eğilim tahmini için düzleştirme katsayısı, $(0 < \beta < 1)$

T_t: Eğilim tahmini değeri

p: Tahmin edilecek dönem sayısı

$\bar{Y}_{t+p}$: p dönem sonrası için belirlenen tahmin değeri

Winter Yöntemi: Winter Yöntemi, zaman serisi analizinde karmaşık olarak bilinen bir yöntemdir. Bu karmaşıklık, yöntemin verideki mevsimsellik ve eğilim gibi özellikleri ele alması nedeniyle formülündeki denklem sayısının fazla olmasından kaynaklanır. Winter Yöntemi'nde üç katsayı bulunur: α, ortalama düzey için; β, eğilim tahmini için ve γ, mevsimsellik tahmini için kullanılan düzleştirme katsayısıdır (Makridakis ve ark. 1998).

$$L_t = \alpha\frac{Y_t}{S_{t-s}} + (1-\alpha)\,(L_{t-1} + T_{t-1}) \tag{3.5}$$

$$T_t = \beta(L_t - L_{t-1})\,(1-\beta)\,T_{t-1} \tag{3.6}$$

$$S_t = \gamma\frac{Y_t}{L_t} + (1-\gamma)S_{t-s} \tag{3.7}$$

$$\bar{Y}_{t+p} = (L_t + pT_t)S_{t+p-s} \tag{3.8}$$

L_t: Ortalama düzey tahmini,

α: Düzleştirme katsayısı ($0 < \alpha < 1$),

Y_t: t dönemindeki gerçek değer,

β: Eğilim tahmini için düzleştirme katsayısı, ($0 < \beta < 1$)

T_t: t anındaki eğilim bileşenini ifade eder.

γ: Mevsimsellik tahmini için düzleştirme katsayısı, ($0 < \gamma < 1$)

S_t: Mevsimsel çarpan tahmini

p: Tahmin edilecek dönem sayısı

s: Mevsim uzunluğu

$\bar{Y}_{t+p}$= *p* dönem sonrası için belirlenen tahmin değeri

Box – Jenkins Modelleri: Otoregresif modeller 1926 yılında ilk kez Yule tarafından, hareketli ortalama modeller ise 1937'de Slutsky tarafından önerilmiştir. 1938 yılında Wold otoregresif modeller ile hareketli ortalama modellerini birleştirerek otoregressif hareketli ortalama yöntemini geliştirmiştir (Makridakis ve Hibon,1997). Box-Jenkins modelleri üstel düzleştirme yöntemlerinin genelleştirilmiş halidir.

Box-Jenkins modellerinin uygulanması için serinin eğilimden ve mevsimsellikten arındırılması gerekmektedir. Kısacası serinin durağan olması gerekmektedir (Kadılar ve Öncel Çekim, 2020). Durağan olan veya durağan hale dönüştürülen serinin ACF (Otokorelasyon Fonksiyonu) ve PACF (Kısmi Otokorelasyon Fonksiyonu) grafiklerine göre model belirlenmektedir. Belirlenen model ile ortaya çıkan tahmin verileri ve gerçek verilerin grafiği çizilerek uyumuna bakılmaktadır. Bununla beraber elde edilen tahmin serisinin alt ve üst değerleri ile orijinal serinin grafiği birlikte çizilerek değer aralığı içinde kalıp kalmadığı belirlenir (Kadılar ve Öncel Çekim, 2020).

Son adım olarak hataların akgürültü olup olmadığı ACF ve PACF grafikleri ile belirlenir. Box-Ljung gibi test sonuçları ile de hataların akgürültü olup olmadığı belirlenebilir (Kadılar ve Öncel Çekim, 2020). Yukarıda bahsedilen Box-Jenkins modelini tanımlamak için kullanılan zaman serisi bileşenleri kısaca aşağıdaki gibi açıklanabilir.

Durağanlık: Zaman serisi analize başlamadan önce her zaman serinin durağan olup olmadığına bakılmalıdır. Durağan olmayan serilerle elde edilen sonuçlar doğru sonuçları vermemektedir. Güçlü durağan serinin dağılım fonksiyonu zaman içinde değişmemelidir. Güçlü durağan serilerde aşağıdaki eşitlik her zaman sağlanmalıdır (Kadılar ve Öncel Çekim, 2020):

$$F(Z_{t1,}Z_{t2}, \dots, Z_{tT}) = F(Z_{t1+k,}Z_{t2+k}, \dots, Z_{tT+k}) \tag{3.9}$$

Her zaman bu eşitliğin sağlanması oldukça zordur. Bu nedenle durağanlık tanımı zayıf durağanlık olarak ele alınmalıdır. Eğer seri durağan ise beklenen değeri ve varyansı sabit, kovaryansı da zamandan bağımsız ve sadece gecikme sayısına bağlı olmalıdır (Kadılar ve Öncel Çekim, 2020). Bu yüzden

$$E(Z_t) = \mu \tag{3.10}$$

$$V(Z_t) = \sigma^2 \tag{3.11}$$

$$Cov(Z_t, Z_{t+k}) = \gamma_k \tag{3.12}$$

Burada,

E(Z_t): Zaman serisi Z_t 'nin beklenen değeri (ortalaması)

Z_t: t anındaki zaman serisi değeri

μ: Zaman serisinin uzun vadeli ortalama değeri (beklenen değeri)

V(Z_t): Zaman serisi Z_t 'nin varyansı

σ^2:Zaman serisinin varyansı

N: Toplam veri sayısı

Cov(Z_t, Z_{t+k}): t ve t+k zaman noktalarındaki zaman serisi değerleri arasındaki kovaryans

γ_k : t anındaki kovaryans değeri

k: İki zaman noktası arasındaki zaman farkı

eşitliklerinin hepsi sağlanmalıdır.

Serinin durağan olup olmadığı ACF grafiğinden anlaşılabilir, ancak sadece grafik yorumu ile durağanlık sonucuna varılması her zaman güvenilir olmayacağından birim kök testleri ile durağanlık araştırılmalıdır. Durağanlık için en yaygın olarak kullanılan birim kök testi Dickey-Fuller testidir. Dickey-Fuller testi, zaman serisinin durağanlık özelliğini değerlendirmek için β katsayısını ve test istatistiğini kullanır. Eğer test istatistiği belirli kritik değerlerin altında ise ve "*p*" değeri anlamlılık düzeyinden küçükse, zaman serisi durağan olarak kabul edilir.

$H_0: \beta = 1$ Seride birim kök vardır. (Seri durağan değildir.)

$H_1: \beta < 1$ Seride birim kök yoktur. (Seri durağandır.)

Mevsimsellik: Zaman serisi analizde ilk adım olan durağan kontrolü yapıldıktan sonra seride mevsimsellik var ise seriyi mevsimsellikten arındırmak gerekmektedir. ACF grafiğinden serinin mevsimsel olup olmadığına bakılır. Bu aşamada, ACF grafiğiyle tespit edilemeyen mevsimsellik durumlarında, mevsimsellik testi olan Kruskal-Wallis testi gibi istatistiksel testlerle doğrulanır. Kruskal-Wallis değeri aşağıdaki formül ile hesaplanır.

$$KW = \frac{12}{T(T+1)} \sum_{i=1}^{s} \frac{R_i^2}{t_i} - 3(T-1) \tag{3.13}$$

Bu formülde yer alan;

T = Örneklem büyüklüğü

R_i = i. periyottaki sıra sayılarının toplamı

$t_i = i$. periyottaki dönem sayısı

S = periyot sayısı

Mevsimsellik tespiti için yapılan işlemler bir hipotez testi olarak düzenlenebilir. Buna göre,

H_0: Seride mevsimsellik yoktur.

H_1: Seride mevsimsellik vardır.

Kruskal Wallis testinde KW istatistik değeri $\chi^2_{\left(\frac{\alpha}{2};s-1\right)}$ tablo değeri ile karşılaştırılır. KW değeri tablo değerinden büyükse yokluk hipotezi reddedilir ve seride mevsimsel dalgalanma vardır denir (Kadılar ve Öncel , 2020)

Akgürültü Serisi: Eğer bir seri akgürültü ise aşağıdaki koşulları sağlamalıdır:

$$E(Z_t) = \mu \tag{3.14}$$

$$V(Z_t) = \sigma^2 \tag{3.15}$$

$$Cov(Z_t, Z_{t+k}) = 0 \tag{3.16}$$

Bu koşulların durağanlık koşullarından tek farkı kovaryans teriminin sıfır olmasıdır. Akgürültü serisinin tüm gecikmelerinde otokorelasyon ve kısmi otokorelasyon değerleri önemsizdir. Hataların akgürültü olup olmadığını ve modelin kalitesini değerlendirmek için Box-Ljung test istatistiği olarak adlandırılan

$$Q = T(T+2)\sum_{i=1}^{k}\frac{r_i^2}{T-i} \quad (3.17)$$

formülü ile hesaplanmaktadır. Burada "Q", Box-Ljung test istatistiğini, "T" zaman serisinin toplam gözlem sayısını, "r_i" i. otokorelasyon katsayısını, "k" test edilen maksimum gecikme sayısını, "$\sum_{i=1}^{k}\frac{r_i^2}{T-i}$" i değişkeni 1'den k'ye kadar iterasyon yapılarak otokorelasyonların karesinin ağırlıklandırılmış toplamını ifade eder. Bu test değeri $\frac{\alpha}{2}$ = 0,025 önemlilik düzeyindeki χ_k^2 tablo değeri karşılaştırılır. Box-Jenkins modelleri mevsimsel ve mevsimsel olmayan olarak ikiye ayrılmaktadır (Kadılar ve Öncel, 2020).

Mevsimsel Olmayan Box-Jenkins Modelleri: ARIMA(*p, d, q*) biçiminde gösterilmektedir.

p: Otokorelasyon (AR) modelinin derecesini,

d: Fark alma işlem sayısını ve

q: Hareketli ortalama (MA) modelinin derecesini göstermektedir. ARIMA(*p, d, q*) modeli aşağıdaki eşitlik ile tanımlanmaktadır:

$$\left(1-\phi_1 B-\phi_2 B^2-\cdots-\phi_p B^p\right)(1-B)^d Z_t = \left(1-\theta_1 B-\theta_2 B^2-\cdots\theta_q B^q\right)\varepsilon_t \quad (3.18)$$

***Mevsimsel Box-Jenkins Modelleri*:** ARIMA(*p, d, q*)(*P, D, Q*) şeklinde ifade edilmektedir.

P: Mevsimsel otokorelasyon (SAR) modelinin derecesini,

D: Mevsimsel fark alma işlem sayısı ve

Q: Mevsimsel hareketli ortalama (SMA) modelinin derecesini göstermektedir. (Kadılar ve Öncel Çekim, 2020)

ARIMA(*p, d, q*)(*P, D, Q*) modeli aşağıdaki eşitlik ile tanımlanmaktadır:

$$\left(1-\phi_1 B-\phi_2 B^2-\cdots-\phi_p B^p\right)\left(1-\Phi_1 B^s-\Phi_2 B^{2s}-\cdots-\Phi_p B^{ps}\right)(1-B)^d(1-B^s)^D Z_t =$$

$$\left(1-\theta_1 B-\theta_2 B^2-\cdots\theta_q B^q\right)\left(1-\Theta_1 B^s-\Theta_2 B^{2s}-\cdots-\Theta_Q B^{Qs}\right)\varepsilon_t \quad (3.19)$$

3.2. Yapay Sinir Ağları

Makine Öğrenmesi (ML), istatistik, matematik ve mantık tekniklerini kullanarak desenleri çıkarmayı ve bu desenleri görünmeyen verilere uygulamayı amaçlayan bir yapay zekâ alt dalıdır. Denetimli, denetimsiz, yarı denetimli ve takviyeli öğrenme gibi çeşitli yöntemlere sahip olan ML, büyük veri ve hesaplama kapasitesindeki ilerlemelerle birlikte önemli gelişmeler kaydetmiştir (Iman ve ark., 2021).

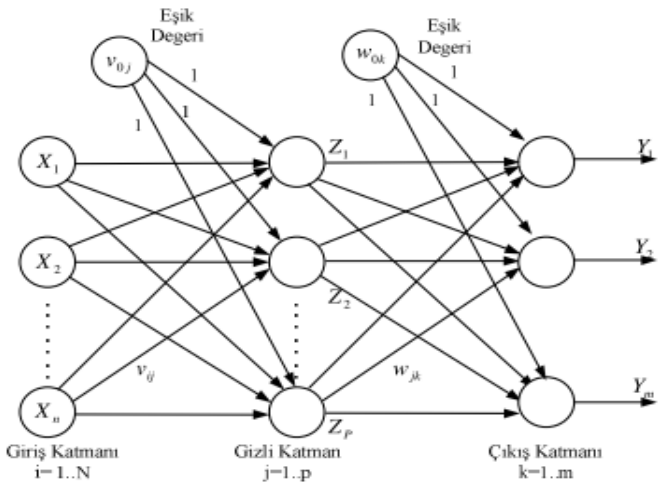
ML modelleri genellikle doğrusal ve doğrusal olmayan olmak üzere iki kategoride değerlendirilir. Doğrusal modeller, basit veri desenlerini içerir ve regresyon veya sınıflandırma gibi görevler için lineer fonksiyonları kullanabilir. Doğrusal olmayan yapıdaki veri setleri ve özellikle XOR problemi gibi doğrusal olmayan problemler için bu modeller yetersiz kalabilir. Bu noktada, Yapay Sinir Ağları (YSA), özellikle doğrusal olmayan desenleri başarıyla tanımlayabilen bir teknik olarak öne çıkar. YSA, bu karmaşık problemleri çözmek için geliştirilen bir yapay zekâ formudur (Iman ve ark., 2021).

Ayrıca, ML'de aşırı uyum riskini azaltmak amacıyla eğitim veri setinin doğrulama setine bölünmesi ve çapraz doğrulama gibi teknikler kullanılabilmektedir. Doğrusal olmayan veri setleri, özellikle büyük veri setlerindeki gereksiz özellikler gibi ek zorluklar sunabilir. Buna karşılık, bu tür sorunlara karşı çözümler arasında özellik seçimi, birleştirme ve çıkarma gibi teknikler bulunmaktadır. Bu gelişmeler sayesinde ML'nin karmaşık veri setleri üzerinde daha etkili ve doğru sonuçlar elde etmesi mümkün hale gelmiştir (Iman ve ark., 2021).

Yapay sinir ağları, insan sinir sistemini taklit eden basit modellerdir. İnsan sinir sistemi üç milyar nöron içerirken, yapay sinir ağı modelleri basit ve biyolojik nöronların zayıf bir örneğidir. Buna karşılık, birkaç nöron içeren yapay sinir ağları, gerçek dünya verileri için başarılı tahmin sonuçları verebilir. Bu ağlar, doğrusal olmayan ve veri tabanlı modeller olarak kullanıldığında, klasik regresyon gibi yöntemlere göre daha iyi sonuçlar elde etme potansiyeline sahiptir. Çok katmanlı algılayıcı (MLP) modelleri, zaman serilerinden tahmin almak için yaygın olarak tercih edilen yapay sinir ağları arasındadır (Eğrioğlu ve ark., 2017).

MLP (Çok Katmanlı Algılayıcı): Yapay sinir ağlarının temel yapı taşlarından biridir ve birçok karmaşık öğrenme probleminde etkili bir şekilde kullanılır. MLP, doğrusal olmayan fonksiyonları öğrenme kapasitesi sayesinde, veri içindeki karmaşık ilişkileri modelleyebilir.MLP, birden fazla katmandan oluşan bir yapıya sahiptir. Bu katmanlar, girdilerin ağ boyunca ileriye doğru beslenmesi prensibiyle çalışır. Üç katmandan oluşmaktadır:

- *Girdi Katmanı (Input Layer):* Bu katman, ağın dış dünyadan aldığı girdileri temsil eder. Her bir nöron, bir girdi değişkenine karşılık gelir.
- *Gizli Katmanlar (Hidden Layers):* Girdi katmanı ile çıktı katmanı arasında yer alan bir veya daha fazla katmandan oluşur. Gizli katmanlardaki nöronlar, doğrusal olmayan aktivasyon fonksiyonları kullanarak girdileri işler ve karmaşık örüntüleri öğrenir.
- *Çıktı Katmanı (Output Layer)*: Bu katman, ağın son çıktısını üretir. Sınıflandırma problemlerinde, çıktı katmanındaki nöron sayısı sınıf sayısına eşittir. Regresyon problemlerinde ise çıktı katmanında genellikle tek bir nöron bulunur.



Şekil 3.2 Çok Katmanlı İleri Beslemeli Yapay Sinir Ağı

MLP'nin her bir nöronu, bir ağırlıklı toplam ve bir aktivasyon fonksiyonu kullanarak girdileri işler (Kaynar ve Taştan,2009). Bir nöronun matematiksel temsili şu şekildedir:

$$y=f\left(\sum_{i=1}^{n}\omega_i x_i+b\right) \quad (3.20)$$

Burada:

y: Nöronun çıktısı

f: Aktivasyon fonksiyonu

ω_i: Girdi değerleri ile çarpılan ağırlıklar

x_i: Girdi değerleri

b: Bias terimi

Bias terimi b nöronun çıktısını doğru yönde kaydırmak için kullanılır. Örneğin, bir nöronun aktivasyon fonksiyonu sıfıra yakın olmasına karşın bias terimi sayesinde nöronun çıktısı sıfırdan farklı bir değer alabilir. Aktivasyon fonksiyonları da şu şekilde sıralanmaktadır:

Sigmoid Fonksiyonu: $\sigma(x) = \frac{1}{1+e^{-x}}$

Yaygın olarak kullanılır, ancak kaybolan gradyan sorununa yol açabilir.

Tanjant Hiperbolik Fonksiyon (tanh): $\tanh(x) = \frac{2}{1+e^{-2x}} + 1$

Sigmoid fonksiyonuna benzer, ancak çıktılar -1 ile 1 arasında yer alır.

ReLU (Rectified Linear Unit): $\mathrm{ReLU}(x) = \max(0, x) = \frac{x+|x|}{2}$

Doğrusal olmayan yapısı sayesinde öğrenmeyi hızlandırır ve kaybolan gradyan sorununu azaltır.

MLP'lerde bilgi akışı ileri besleme (feedforward) prensibine dayanır. Bu süreç, ağın her bir katmanında hesaplamalar yaparak girdileri çıktı katmanına taşır. Aşağıdaki adımlarla özetlenebilir:

1. Girdi katmanındaki her bir nöron, girdi değerlerini alır ve gizli katmana iletir.
2. Gizli katmanlardaki nöronlar, girdileri ağırlıklı toplam ve aktivasyon fonksiyonları aracılığıyla işler ve çıktıları bir sonraki katmana iletir.
3. Bu süreç, çıktı katmanına ulaşana kadar devam eder ve ağın son çıktısı elde edilir.

MLP'lerin öğrenme süreci, geri yayılım (backpropagation) algoritması ile gerçekleştirilir. Bu algoritma, ağırlıkların ve bias terimlerinin nasıl güncelleneceğini belirler ve hata fonksiyonunu minimize eder. Temel adımlar şunlardır:

- *İleri Besleme*: Girdi verileri ağdan geçirilerek tahmin edilen çıktı elde edilir.
- *Hata Hesaplama:* Tahmin edilen çıktı ile gerçek çıktı arasındaki fark (hata) hesaplanır. Hata fonksiyonu olarak genellikle Ortalama Kare Hatası (MSE) veya Çapraz-Entropi Kaybı kullanılır. Çapraz-entropi kaybı, modelin öngördüğü olasılık dağılımları ile gerçek sınıf etiketleri arasındaki uzaklığı ölçerek, modelin doğruluğunu değerlendirir.
- *Geri Yayılım*: Hata, zincirleme türevler kullanılarak ağ boyunca geri yayılır. Bu süreç, her bir ağırlığın gradyanının hesaplanmasını sağlar.
- *Ağırlık Güncelleme*: Öğrenme hızına bağlı olarak ağırlıklar ve sapma terimleri güncellenir. Genellikle Stokastik Gradyan İnişi (SGD) veya onun türevleri kullanılır.

MLP'lerin eğitiminde, veri kümesi genellikle eğitim ve doğrulama setlerine ayrılır. Eğitim seti, modelin öğrenmesi için kullanılırken, doğrulama seti modelin performansını değerlendirmek için kullanılır. Bu süreç, modelin aşırı uyum (overfitting) yapmasını önler ve genelleme yeteneğini artırır.

NNAR (Otoregresif Sinir Ağı): NNAR modelinin tarihsel gelişimi, yapay sinir ağları (YSA) ve otoregresif yapıların zaman serileri analizindeki evrimiyle yakından ilişkilidir. Yapay sinir ağlarının ilk gelişimi 1940'larda başlamış olsa da NNAR gibi karmaşık yapıların kullanımı, özellikle bilgisayar gücünün artması ve yeni öğrenme algoritmalarının geliştirilmesiyle 1980'lerden itibaren yaygınlaşmıştır. Bu dönemde, NNAR modeli gibi sinir ağı tabanlı yöntemler, zaman serilerinin dinamik yapısını daha iyi anlamak ve tahmin etmek için etkili araçlar olarak kabul görmüştür.

NNAR modeli, karmaşık zaman serileri üzerinde etkili tahminler yapmak için kullanılan bir yapay zekâ yöntemidir. Bu model, tek değişkenli girdilere sahip bir beslemeli sinir ağı

olarak tasarlanmıştır ve gecikme (lag) 1'den p'ye değerleri içerir. Bu yöntem, geçmiş verilerin yanı sıra mevcut durumu da dikkate alarak gelecekteki değerleri tahmin etmek için kullanılır. Mevsimsel dalgalanmalar içeren veriler için uyarlanmış NNAR modeli de bulunmaktadır. Bu model, mevsimsel gecikmeleri ve periyodun uzunluğunu dikkate alarak tahminler yapabilir. NNAR, parametrelerinde durağanlık elde etmek için herhangi bir kısıtlama getirmez ve esnek bir yapıya sahiptir. Bu sayede, çeşitli zaman serileri verileri üzerinde geniş bir uygulama alanına sahiptir (Pontoh ve ark., 2022).

NNAR modelinin adaptasyonu, özellikle mevsimsel dalgalanmaları olan zaman serileri için yapılan çalışmalarla güçlenmiştir. Bu modeller, mevsimsel etkileri ve periyodik örüntüleri dikkate alarak daha hassas tahminler yapabilme yeteneğine sahiptirler. NNAR modelinin mevsimsel olmayan zaman serilerinde, mevsimsel bileşeni dikkate almadığı için model daha basit ve daha az karmaşıktır. Bu, modelin daha hızlı eğitilmesini ve uygulanmasını sağlamaktadır.

Otoregresif Sinir Ağı (NNAR) modeli, NNAR(p, k) olarak belirtilen bu modelde k, gizli katmandaki düğüm sayısını temsil ederken p, gecikmeleri (lag) ifade eder (Pontoh ve ark., 2022). Mevsimsel dalgalanma olan veriler için uyarlanmış model, NNAR(p, P, k)$_m$ modeli olarak belirtilir. Burada P, mevsimsel gecikmeleri ve m mevsimsel periyodun uzunluğunu temsil eder. Mevsimsel veriler için uyarlanmış NNAR modeli, ARIMA(p, 0,0)(P, 0, 0)$_m$ modeline benzer (Pontoh ve ark., 2022).

Genel olarak NNAR $(p, P, k)_m$ modeli $(y_{t-1}, y_{t-2}, \dots, y_{t-p}, y_{t-m}, y_{t-2m}, \dots, y_{t-pm})$ girdisine ve gizli katmanda k nörona sahiptir. Bir NNAR$(p, P, k)_m$ modeli, durağanlığı sağlamak için parametreler üzerinde kısıtlamalar olmaksızın, bir ARIMA(p,0,0)$(P, 0,0)_m$ modeline eşdeğerdir.

R programında nnetar() fonksiyonu, bir NNAR(p, P, k) modelini uygular.Eğer “p” ve “P” değerleri belirtilmezse, bunlar otomatik olarak seçilir. Mevsimsel olmayan zaman serileri için, varsayılan olarak doğrusal AR(p) modeli için en uygun gecikme sayısı (AIC'ye göre)

kullanılır. Mevsimsel zaman serileri için ise varsayılan değerler P=1 olarak belirlenir ve "p" mevsimsel olarak düzeltilmiş verilere uygun doğrusal modelden seçilir. Eğer k belirtilmemişse, k=(p+P+1)/2 olarak ayarlanır (Hyndman ve Athanasopoulos,2018).

3.3 Hata Tahmin Ölçütleri

Talep tahmin yöntemleri, geçmiş verileri kullanarak gelecekteki değerleri tahmin etmek için kullanılır. Bu tahminlerin ne kadar doğru olduğunu belirlemek için literatürde çeşitli hata analiz yöntemleri bulunmaktadır. Bu yöntemler, gerçekleşen ve tahmin edilen değerler arasındaki farkları değerlendirir ve tahmin yöntemlerinin performansını karşılaştırmak için önemlidir. Ancak hangi hata analiz yönteminin en uygun olduğu, kullanılan veri setine, tahminin amacına ve yönteme göre değişebilir (Kayalı,2024). Her çalışmada en doğru sonucu elde etmek için farklı hata analiz yöntemlerinin aynı anda kullanılması gerekebilir. Literatürde yapay sinir ağı ve ARIMA gibi yöntemlerle yapılan tahmin çalışmalarında sıkça kullanılan hata tahmin ölçütleri aşağıdaki gibidir:

- **Ortalama Hata (ME - Mean Error):** ME, tahmin edilen değerlerin gerçek değerlerden ortalama sapmasını gösterir. Formülü şu şekildedir:

$$ME= \frac{\sum_{i=1}^{n}(Y_i-\hat{Y}_i)}{n} \tag{3.21}$$

- **Kök Ortalama Kare Hata (RMSE - Root Mean Squared Error):** RMSE, tahmin edilen ve gerçek değerler arasındaki farkın karelerinin ortalama değerinin kareköküdür. Formülü:

$$RMSE= \sqrt{\frac{\sum_{i=1}^{n}(Y_i-\hat{Y}_i)^2}{n}} \tag{3.22}$$

- **Ortalama Mutlak Hata (MAE - Mean Absolute Error):** MAE, tahmin edilen ve gerçek değerler arasındaki mutlak farkların ortalama değerini ifade eder. Formülü:

$$MAE= \frac{\sum_{i=1}^{n}|Y_i-\hat{Y}_i|}{n} \tag{3.23}$$

- **Ortalama Kare Hata (MSE - Mean Squared Error):** MSE, tahmin edilen ve gerçek değerler arasındaki farkların karelerinin ortalama değerini ifade eder. Formülü:

$$\text{MSE}= \frac{\sum_{i=1}^{n}(Y_i-\hat{Y}_i)^2}{n} \tag{3.24}$$

- **Yüzde Mutlak Hata Oranı (MPE - Mean Percentage Error):** MPE, tahmin edilen ve gerçek değerler arasındaki yüzde hataların ortalama değerini ifade eder. Formülü:

$$\text{MPE}=\frac{100}{n}\sum_{i=1}^{n}\frac{(Y_i-\hat{Y}_i)}{Y_i}x100 \tag{3.25}$$

- **Yüzde Mutlak Hata Oranı (MAPE - Mean Absolute Percentage Error):** MAPE, tahmin edilen ve gerçek değerler arasındaki yüzde mutlak farkların ortalama değerini ifade eder. Formülü:

$$\text{MAPE}=\frac{100}{n}\sum_{i=1}^{n}\frac{|Y_i-\hat{Y}_i|}{Y_i}x100 \tag{3.26}$$

- **Ortalama Ayarlanmış Kare Hata (MASE - Mean Absolute Scaled Error):** MASE, tahmin modelinin performansını bir referans model ile karşılaştırarak ölçer. Formülü:

$$\text{MASE}=\frac{\frac{1}{h}\sum_{i=n+1}^{n+h}|Y_i-\hat{Y}_i|}{\frac{1}{n-1}\sum_{i=2}^{n}|Y_i-\hat{Y}_{i-1}|} \tag{3.27}$$

Hata ölçütlerinin formüllerde bahsedilen ;

Y_i:Gerçek değer

$\hat{Y}_i$: Tahmin edilen değer

n: gözlem sayısı

h: Tahmin edilen dönem sayısıdır.

4. BULGULAR

Bu çalışmada, 2018 Ocak ayından itibaren seri üretimi tamamlanan ve 15 yıllık yedek parça dönemine giren 3 versiyonlu bir otomotiv projesinin yedek parça talep tahmini için veriler toplanmıştır. Veriler, Türkiye'deki bir otomotiv şirketinden, Şubat 2018 ile Şubat 2023 arasındaki dönemde aylık olarak toplanmıştır ve toplamda 60 gözlem içermektedir. Versiyonlar "SP (spare parts)" olarak adlandırılmış ve SP1, SP2 ve SP3 olarak tanımlanmıştır. Bu veriler, gelecekteki talep tahminleri ve planlama çalışmaları için önemli bir temel oluşturmaktadır.

Talep tahminine başlamadan önce, veriler analiz edilerek talep tahmini için kullanılabilir hale getirilmiştir. Zaman serilerinde, talep tahmini için verilerin kullanılmadan önce durağanlık ve mevsimsellik kontrol edilmiş ve R uygulamasında istatistiksel testlerle doğrulanmıştır. En yaygın olarak kullanılan talep tahmini yöntemleri arasında zaman serileri ve yapay sinir ağları bulunmaktadır. Hata tahmin ölçütleri kullanılarak en küçük hatayı veren model seçilmiş ve bu model kullanılarak tahmin yapılmıştır.

Talep tahmininde en çok kullanılan yöntemlerden olan yapay sinir ağları, R uygulamasındaki standart yapay sinir ağları paketleri aracılığıyla ile MLP ve NNAR yöntemleri temel alınarak uygulanmıştır. R yazılımının standart sürümünde kurulu bulunan yöntemlerle, en uygun sonucu veren parametreler belirlenmiştir. Talep tahmininde kullanılan bu üç yöntemden elde edilen hata tahmin ölçütleri karşılaştırılmış ve en uygun yöntem ve modele karar verilmiştir.

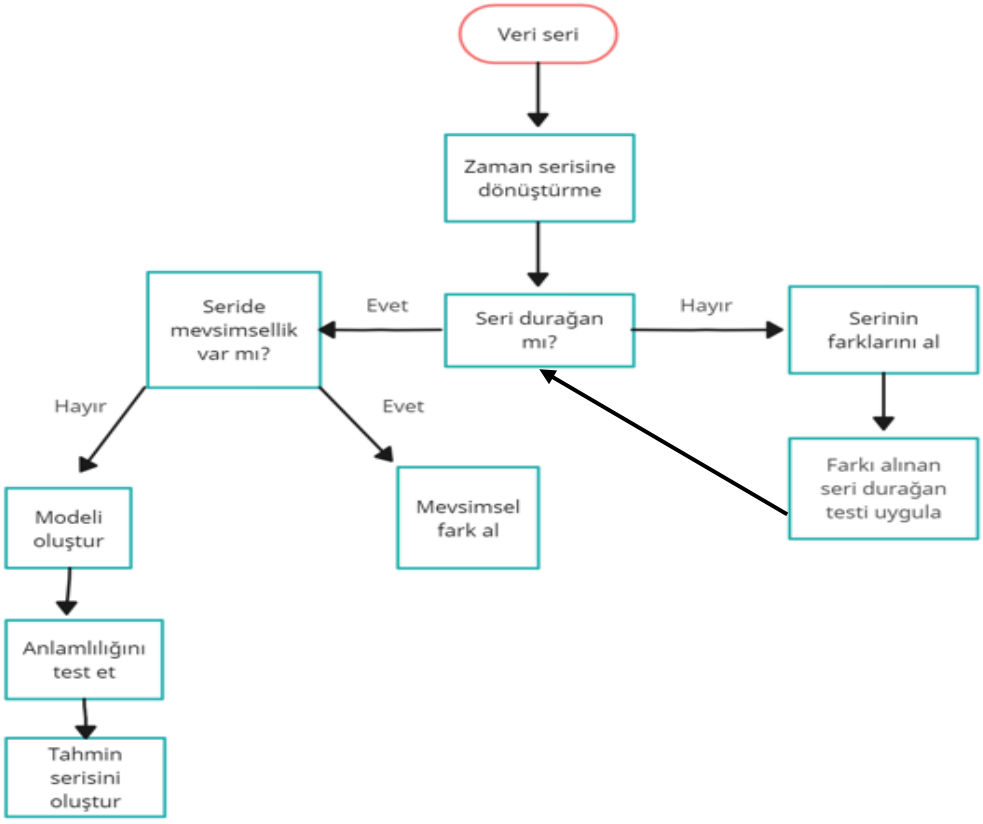
Karar verilen modeller üzerinde gelecek 6 ay için yedek parça talep tahminleri oluşturulmuştur. 6 aylık tahmin verilerinin hataların normal dağılıp dağılmadığı kontrol edilmiş ve istatistiksel testler ile doğrulanmıştır.

Otomotiv sektöründe yedek parça talep tahminine ait veriler EK 1.'de verilmiştir.

4.1. Tahmin Yöntemlerinin R ile Uygulanması

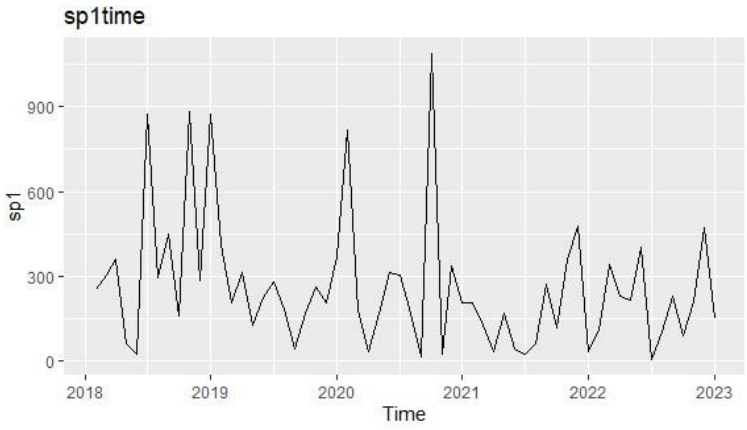
Türkiye'deki bir otomotiv işletmesinde üretilen bir projenin üç farklı versiyonu adım adım incelenecektir. Her bir versiyon için sonuçlar elde edip bunların tahmin verilerinin anlamlılıklarına bakıp uygunluğu test edilecektir. Bahsedilen tüm yöntemlerin uygulaması için R programı kullanılmıştır. ARIMA ile yapılacak olacak tahminler için *forecast* ve *tseries* paketleri, MLP ile yapılacak olan tahminler için *forecast, tseries ve nnfor* paketleri ve NNAR ile yapılacak olan tahminler için de *forecast, tseries ve nnetar* paketleri kullanılmıştır.

Üç farklı versiyon için ARIMA modeli seçim adımlarını ve tahmin sonuçlarını veren R script kodları EK 2, EK 3 ve EK 4'te, MLP modeline ait seçim adımlarını ve tahmin sonuçları veren R script kodları EK 5, EK 6 ve EK 7'de, NNAR modeli ait seçim adımlarını ve tahmin sonuçları veren R script kodları EK 8, EK 9 ve EK 10'da verilmiştir.



Şekil 4.1. Veriler üzerinde uygulanan işlemlere ait akış şeması

Yedek parça versiyon 1 (SP1) için ARIMA ile talep tahmini: Zaman serileri ile talep tahminine başlamadan önce serinin zaman serisi grafiği çizilir. Zaman serisi grafiği verilerin dağılım biçimi hakkında temel bilgi verir. SP1 için çizilen zaman serisi grafiği Şekil 4.2.'de verilmiştir.

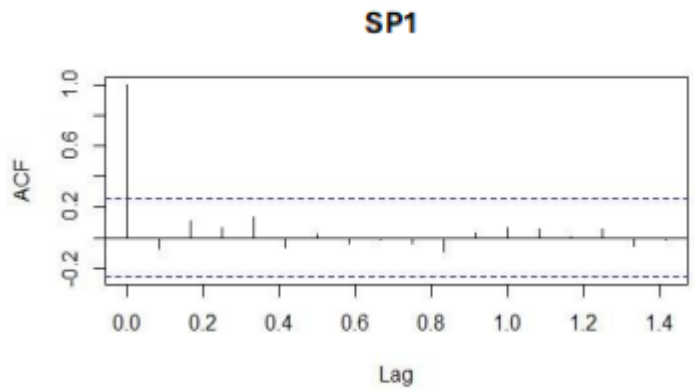


Şekil 4.2. SP1 için zaman serisi grafiği

Grafik, zaman boyunca değişen bir veri setini temsil ettiği görünmektedir. Her nokta, belirli bir zaman noktasında kaydedilen bir değeri temsil eder. Veri seti oldukça dalgalıdır. Bazı zamanlarda büyük artışlar ve azalmalar meydana gelirken, diğer zamanlarda daha istikrarlı bir seyir izlenmektedir. Veri setinde belirgin bir eğilimin bulunmadığı görülmektedir. Genel olarak, veri seti oldukça çeşitli ve belirsiz bir desene sahiptir. Belirli bir model veya dönemsel bir davranışın açıkça tanımlanamayacağı değerlendirilmektedir.

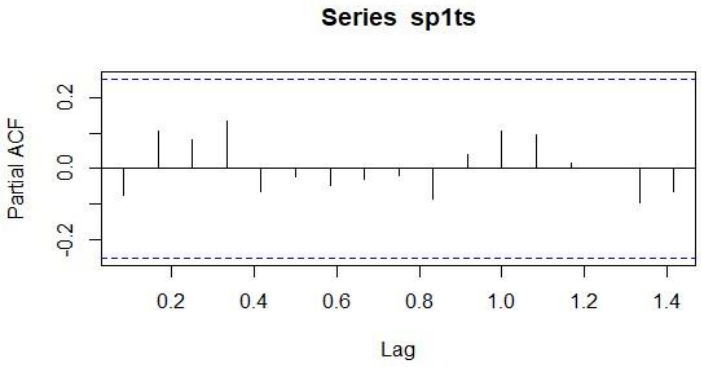
Modelin yapısı belirlenirken ACF ve PACF grafikleri çizilip incelenir. Eğer PACF grafiğindeki ilişki düzeyleri hızla düşüp ACF grafiğindeki ilişki düzeyleri ise yavaşça azalıyorsa, otoregresif (AR) bir yapı olduğu belirlenmiş olur. Buna karşılık, PACF grafiğinde ilişki düzeyi yavaşça azalırken ACF grafiğindeki ani bir şekilde azalıyorsa, bu durum hareketli ortalama (MA) modelinin geçerli olabileceğine işaret eder. Hem ACF hem de PACF grafiğindeki ilişki düzeylerinin yavaşça azaldığı durumda ise, otoregresif hareketli ortalama (ARMA) modelinin daha uygun olacağı anlaşılır.

ACF grafiği, otokorelasyonun zaman serisi içindeki farklı zaman gecikmelerine bağlı olarak nasıl değiştiğini gösterir. Şekil 4.3.'teki grafik incelendiğinde, otokorelasyonun zamanla azaldığı ve giderek daha az belirgin hale geldiği görülmektedir. Bu durum, veri setindeki değerler arasındaki ilişkinin zamanla zayıfladığını göstermektedir. İlk birkaç zaman gecikmesinde belirgin bir otokorelasyon görülmekle birlikte, zaman gecikmesi arttıkça otokorelasyonun giderek azaldığı ve sıfıra yaklaştığı gözlenmektedir. Bu bilgi, modelleme veya tahmin etme sürecinde zaman serisinin nasıl ele alınacağı konusunda önemli ipuçları sağlar ve otokorelasyonun belirlenmesinde yardımcı olabilir. Sadece ilk gecikme anlamlı olduğu için serinin durağan olup olmadığı net değildir.



Şekil 4.3. SP1 için ACF grafiği

Yedek parça versiyon-1 (SP1) için PACF grafiğine bakıldığı zaman seride gecikme olmadığı görülmüştür. PACF grafiği, zaman serisindeki kısmi otokorelasyonun zaman gecikmelerine bağlı olarak nasıl değiştiğini gösterir. PACF grafiğinde gecikme olmaması, zaman serisindeki herhangi bir zaman gecikmesinin istatistiksel olarak anlamlı bir şekilde kısmi otokorelasyona sahip olmadığını gösterir. Bu durum, zaman serisinin önceki zaman noktalarıyla güçlü bir ilişki içermediğini veya bu ilişkinin diğer değişkenler tarafından açıklanabileceğini gösterebilir.



Şekil 4.4. SP1 için PACF grafiği

ACF grafiğine göre, ilk gecikme, durağanlık testi yapılması gerektiğini işaret eder. Birim kök testlerinde olan Dickey-Fuller ile serinin durağan olup olmadığını test edilir. Bu testin sonucunda ADF istatistiği, *p* değeri ve kritik değerler elde edilir. *p* değeri, hipotez testinde önemli bir rol oynar. Genellikle, *p* değeri olarak adlandırılan bir eşik değerle alfa (hata kabul düzeyi) karşılaştırılır (alfa değeri genellikle 0,05 olarak kabul edilir). Eğer *p* değeri, alfa değerinden küçükse, temel hipotez reddedilir ve zaman serisinin durağanlık özelliğine sahip olduğu kabul edilir.

```
Augmented Dickey-Fuller Test

data:  sp1ts
Dickey-Fuller = -3.4206, Lag order = 3, p-value = 0.06113
alternative hypothesis: stationary
```

Şekil 4.5. SP1 Durağanlık test değerleri

Şekil 4.5.'de gösterilen durağanlık testine göre *p* değeri 0,05'ten büyük olduğu için seri durağan değildir. Serinin durağan hale gelmesi için ardışık terimlerin birbirinden farkı hesaplanır. Farkı alınan serinin durağanlık kazanıp kazanmadığı ADF test istatistiği ile incelenir.

```
Augmented Dickey-Fuller Test

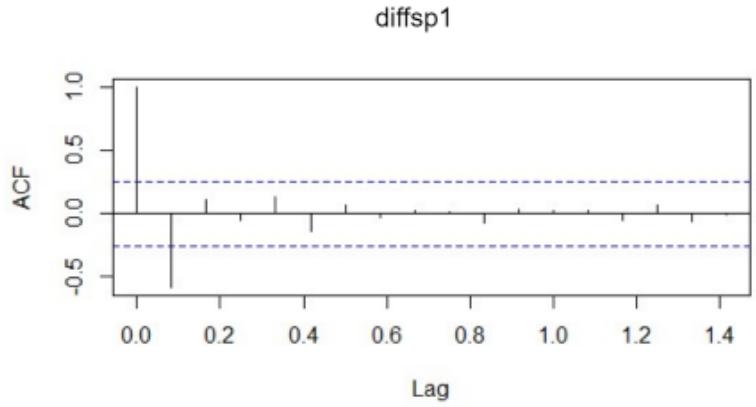
data:  diffsp1
Dickey-Fuller = -5.6775, Lag order = 3, p-value = 0.01
alternative hypothesis: stationary

Warning message:
In adf.test(diffbasic) : p-value smaller than printed p-value
```

Şekil 4.6. SP1 Fark serisi durağanlık test değerleri

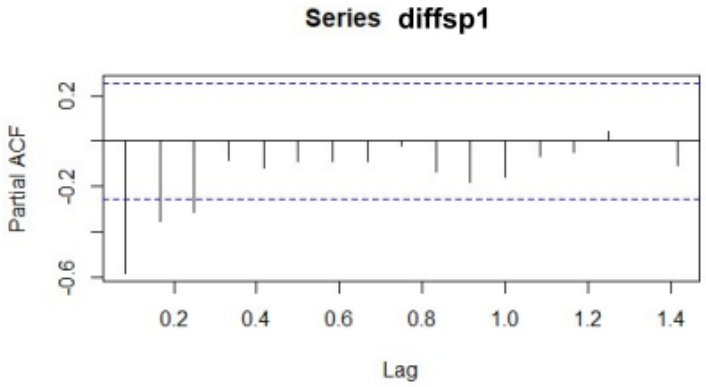
Farkı alınan serinin ADF test istatistiği değeri 0,05'ten küçük olduğu için fark serisinin durağan hale geldiği görülür. Serinin bir kez farkı alınarak durağanlık sağlandığı için *d*=1 olarak kabul edilir.

Birinci dereceden farkı alınan serinin tekrar ACF ve PACF grafikleri çizilir. Önceki veri setindeki ACF grafiğine kıyasla, 1. dereceden fark alındıktan sonra otokorelasyonun daha hızlı azaldığı ve daha belirgin bir şekilde düşük değerlere ulaştığı görülür. Bu durum, verinin fark alındıktan sonra daha durağan hale geldiğini gösterir.

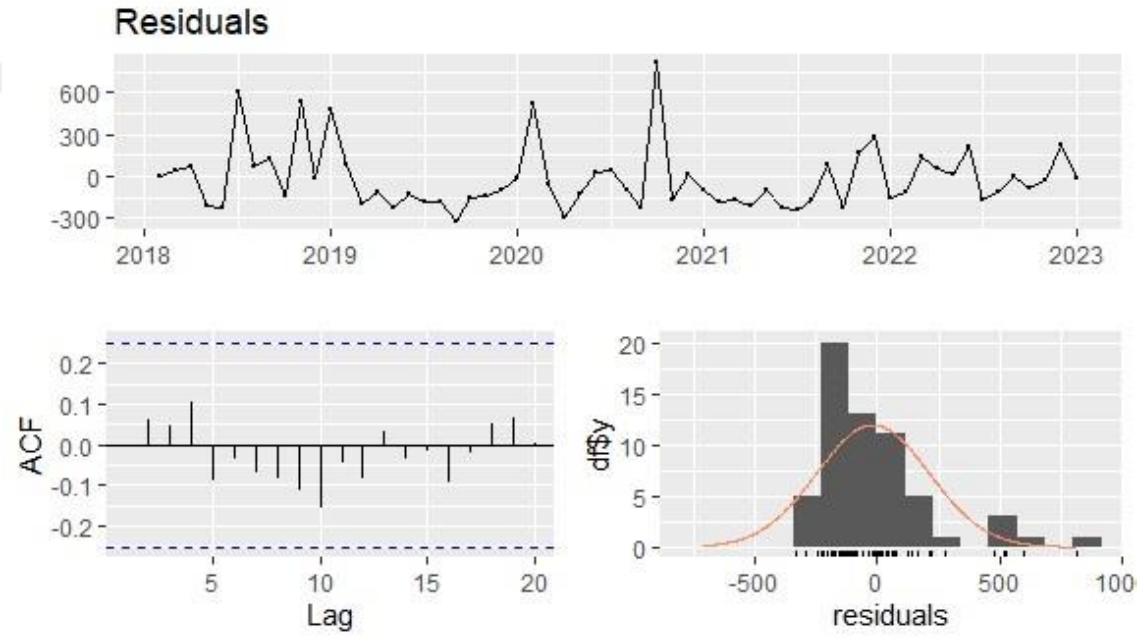


Şekil 4.7. Farkı alınan SP1 için ACF grafiği

Önceki veri setindeki PACF grafiği ile karşılaştırıldığında, 1. dereceden fark alındıktan sonra kısmi otokorelasyonun daha hızlı azaldığı ve daha belirgin bir şekilde düşük değerlere ulaştığı görülmektedir.



Şekil 4.8. Farkı alınan SP1 için PACF grafiği



Şekil 4.9. SP1 için hata dağılım grafikleri

Farkı alınan serinin hatalarının normal dağıldığı Şekil 4.9. üzerinde görülmektedir. Serinin durağanlık kazandığı görüldükten sonra mevsimsellik etkisinin olup olmadığı incelenir. ACF ve PACF grafiklerde seride mevsimsellik olmadığı görülmektedir. Bunun yanında, mevsimsellik test istatistiği olan Kruskal-Wallis testi ile kesin sonuca ulaşılır.

```
Test used:  Kruskall Wallis

Test statistic:  0.29
P-value:  0.9792464
```

Şekil 4.10. SP1 Mevsimsellik testi sonucu

Kruskal-Wallis testine göre, *p* değeri alfa değerinden büyük olduğu için farkı alınan zaman serisinin mevsimsellik özelliğine sahip olmadığı sonucuna varılmıştır. Mevsimsel farkını almaya gerek yoktur olmadığından D = 0 kabul edilir. Yapılan durağanlık ve mevsimsellik testleri ile ARIMA d ve D parametreleri bulunmuştur. Geliştirilen model bu aşamada ARIMA(p,1,q)(P,0,Q)$_{12}$ şeklinde simgelenebilmektedir. Nihai modeli oluşturma sürecinde incelenen model seçeneklerinin hata değerleri Çizelge 4.1.'de gösterilmektedir:

Çizelge 4.1. SP1 ARIMA(p,1,q)(P,0,Q)$_{12}$ hata değerleri

	ME	**RMSE**	**MAE**	**MPE**	**MAPE**	**MASE**
ARIMA(2,1,1)(1,0,0)	-21,39	228,75	171,05	-207,69	232,25	0,71
ARIMA(2,1,1)(1,0,0)	-20,92	227,89	170,35	-201,03	225,64	0,71
ARIMA(1,1,1)(1,0,0)	-19,86	229,36	170,96	-204,07	228,72	0,71
ARIMA(1,1,1)(0,0,1)	-19,20	228,67	170,72	-197,60	**222,51**	0,71
ARIMA(0,1,1)(1,0,0)	-23,12	231,34	170,63	-220,58	243,71	0,71
ARIMA(0,1,1)(0,0,1)	-22,50	230,52	170,39	-213,03	236,42	0,71

Çizelge 4.1.'e göre, ARIMA(2,1,1)(1,0,0) modeli en düşük RMSE ve MAE değerleri ile en iyi performansı sergilerken, ARIMA(1,1,1)(0,0,1) modeli en düşük MAPE ile en doğru tahminleri yapmaktadır. En düşük MPE değeri ise ARIMA(1,1,1)(0,0,1) modelinde bulunur. Tüm modellerin MASE değeri 0,71 olup, performansları benzer görünmektedir. MAPE, tahmin hatalarını yüzdelik olarak ifade ettiği için farklı veri setleri arasında karşılaştırmayı ve model performansını değerlendirmeyi kolaylaştırır. En düşük MAPE hata değerini veren ARIMA(1,1,1)(0,0,1) modeline göre 6 aylık tahmin değerleri R programında *forecast* paketiyle Çizelge 4.2'deki gibi elde edilmektedir.

Çizelge 4.2. SP1 için 6 aylık tahmin değerleri

Yıl	**Ay**	**Tahmin Değerleri**
2023	Mart	211
2023	Nisan	242
2023	Mayıs	226
2023	Haziran	221
2023	Temmuz	255
2023	Ağustos	191

Ljung -Box testi, bir zaman serisinde otokorelasyonun var olup olmadığını kontrol eden istatistiksel bir testtir. Bu test ile modellerin anlamlılığı ölçülür. Ljung-Box testi aşağıdaki hipotezleri kullanır:

H_0: Artıklar bağımsız olarak dağıtılmıştır.

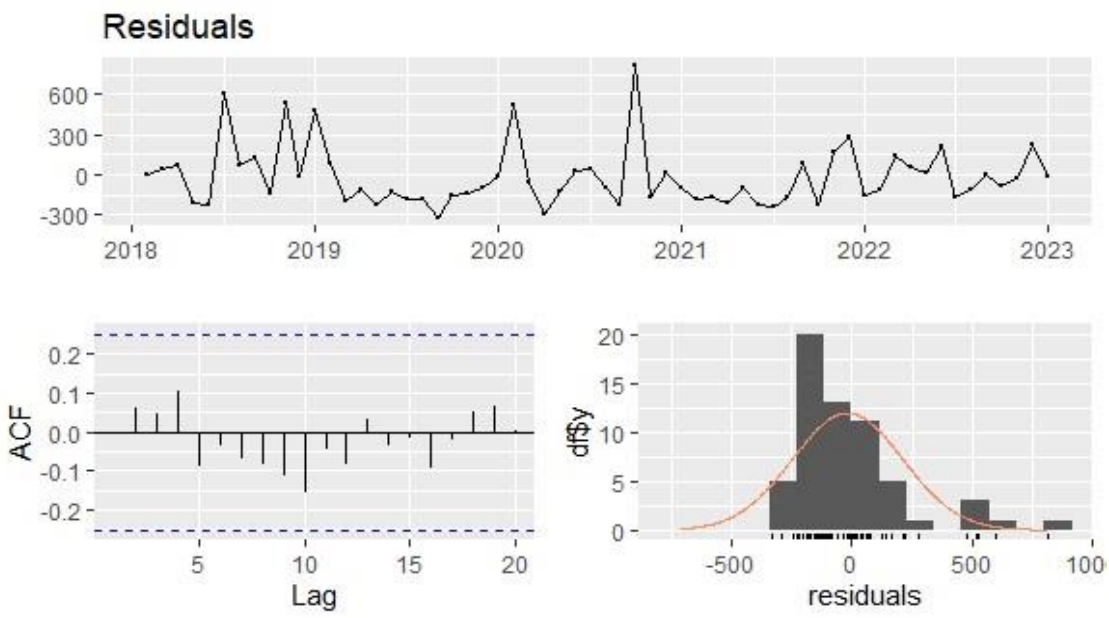
H_1: Artıklar bağımsız olarak dağıtılmaz; seri korelasyon sergiler.

Ljung-Box testi sonucunun p değerinin 0,05'ten büyük çıkması, modelin hatalarında istatistiksel olarak anlamlı bir otokorelasyon bulunmadığına işaret eder. Bu durum, modelin hatalarının rastgele olduğunu ve modelin verilere iyi uyum sağladığını göstermektedir. Otokorelasyonun olmaması, modelin güvenilirliğini artırır ve modelin güçlü bir tahmin aracı olduğu değerlendirilir. En anlamlı bulunan SP1 modeline Ljung-Box testi uygulandığı zaman, p değerinin 0,05'ten büyük olduğu ve serinin artıklardan bağımsız olduğu görülmüştür.

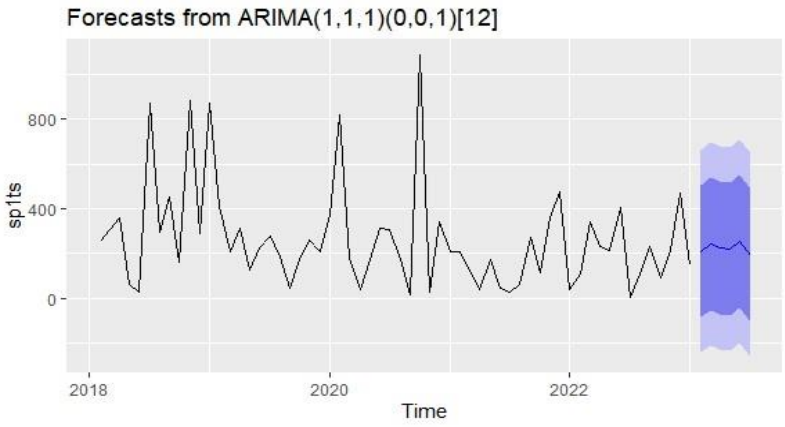
```
Ljung-Box test

data:  Residuals from ARIMA(1,1,1)(0,0,1)[12]
Q* = 6.039, df = 9, p-value = 0.736
Model df: 3.   Total lags used: 12
```

Şekil 4.11. SP1 model uyum test istatistiği değerleri

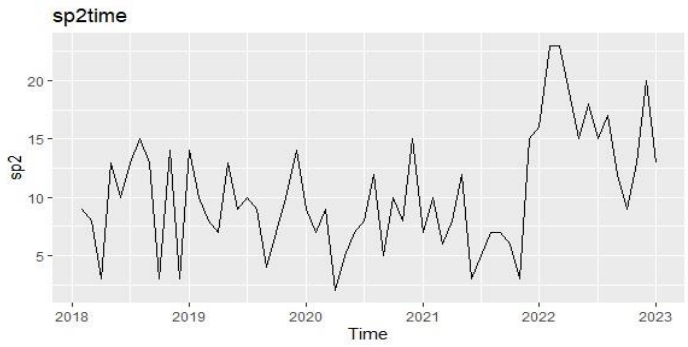


Şekil 4.12. SP1 tahmin sonuçlarının hata dağılım grafikleri



Şekil 4.13. SP1 Orijinal seri ve tahmin serisinin dağılım grafiği

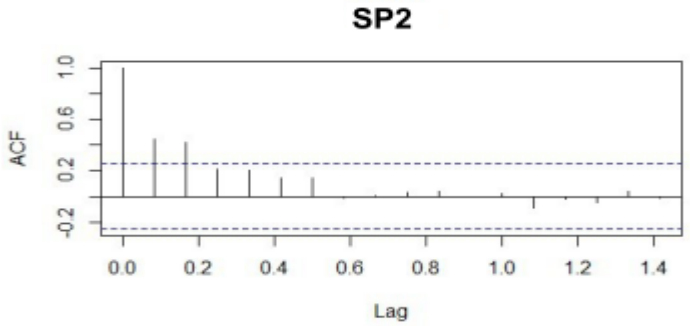
Yedek parça versiyon 2 (SP2) için ARIMA ile talep tahmini: SP2 verisi için Şekil 4.1'de verilen adımlar uygulanmıştır. SP2 zaman serisi grafiğinde, verilerin zamanla nasıl değiştiğini gösteren bir eğilim bulunmaktadır. Başlangıçta düşük değerlerle başlayan zaman serisinde, zamanla artış ve azalışlar gözlemlenmektedir. Bu, verinin belirli bir dönemde daha değişken olduğunu göstermektedir. Grafikteki dalgalanmalar, verinin belirli dönemlerde istikrarsız olduğunu ve dış faktörlerden etkilenebileceğine işaret edebilir. Örneğin, 20. ay civarında yaşanan büyük artış, dikkate değer bir olayın veya değişkenin varlığını gösterebilir. Grafikte, belirli bir noktada verinin yüksek bir değere ulaştığı ve ardından bir düşüş yaşadığı dikkat çekicidir. Bu tür olaylar, dikkate alınması gereken özel durumlar veya verideki anormallikler olabilir. İlerideki analiz aşamalarında bu temel tespitler test edilmektedir.



Şekil 4.14. SP2 için zaman serisi grafiği

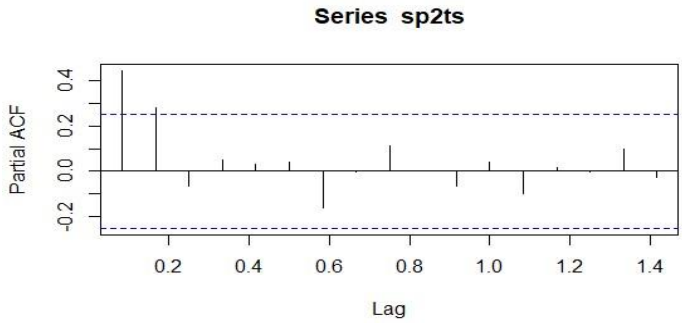
ACF grafiğinde sağından soluna doğru hareket edildiğinde, korelasyonun zaman aralıklarında nasıl değiştiği görülmüştür. İlk lag ‘de (0'da), zaman serisinin kendisi ile olan korelasyonunun 1 olduğunu görülmüştür. Bu, her değerin kendisiyle mükemmel bir korelasyona sahip olduğunu gösterir. Grafikte birkaç lag sonrasında (özellikle 1 ve 2 lag değerlerinde) korelasyon hızla azalır. Bu, bir zaman noktasındaki değerin bir sonraki ve sonraki birkaç zaman noktası ile olan korelasyonunun zayıfladığını gösterir. Bu, verinin büyük ölçüde rastgele olduğunu veya belirgin bir yapıya sahip olmadığını düşündürebilir.

Sonuç olarak, ACF grafiği incelendiğinde, verinin belirli bir desene sahip olmadığı ve genellikle korelasyonun düşük olduğu görülmektedir. Bu durum, zaman serisindeki değerlerin birbiriyle güçlü bir ilişki içinde olmadığını ve belirli bir eğilim veya desene sahip olmadığını düşündürmektedir.



Şekil 4.15. SP2 için ACF grafiği

İkinci adım olan PACF grafiği incelendiğinde, PACF değerlerinin ilk birkaç lag ‘da belirgin olduğunu görülmüştür. Özellikle seri, 1 ve 2 lag ‘da yüksek PACF değerlerine sahiptir. Bu, zaman serisinin önceki birkaç değeriyle belirli bir ilişkinin olduğunu gösterir. Ancak, lag değerleri arttıkça, PACF değerlerinin hızla düştüğü görülmüştür. Dolayısıyla, zaman serisinin belirli bir lag değerindeki kısmi korelasyonu, diğer lag değerlerinin etkilerini kontrol ettikten sonra güçlü veya zayıf olarak belirlenebilir. İlk birkaç lag ‘da güçlü bir ilişki, daha sonrakilerde ise zayıf bir ilişki olduğu anlaşılır.



Şekil 4.16. SP2 için PACF grafiği

SP2 PACF grafiği incelendiğinde, ilk iki gecikmenin olduğu ve seriyi eğilimden arındırmak gerektiği görülmektedir. ADF test istatistiği ile durağanlık testi yapılır.

```
Augmented Dickey-Fuller Test

data:  sp2ts
Dickey-Fuller = -2.7411, Lag order = 3, p-value = 0.2752
alternative hypothesis: stationary
```

Şekil 4.17. SP2 Durağanlık test değerleri

P değerinin alfa (0,05)'dan büyük olması nedeniyle zaman serisinin durağan olmadığına karar verilir. Bu durum, zaman serisinin istatistiksel olarak durağan olmadığını ve zaman içinde belirli bir eğilim veya yapısal değişikliklerin olabileceğini gösterir. Bu durumda, zaman serisinin durağan hale getirilmesi veya durağanlık özelliklerinin elde edilmesi için SP2 serisinin farkı alınır. Farkı alınan seriye ADF testi uygulanır ve serinin durağan hale gelip gelmediği kontrol edilir.

```
Augmented Dickey-Fuller Test

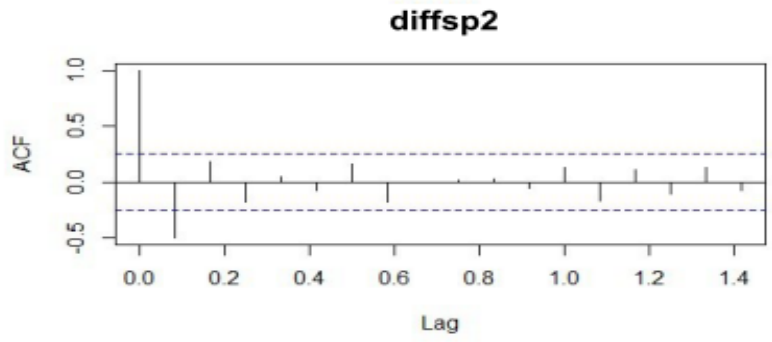
data:  diffbezel
Dickey-Fuller = -4.9622, Lag order = 3, p-value = 0.01
alternative hypothesis: stationary

Warning message:
In adf.test(diffbezel) : p-value smaller than printed p-value
```

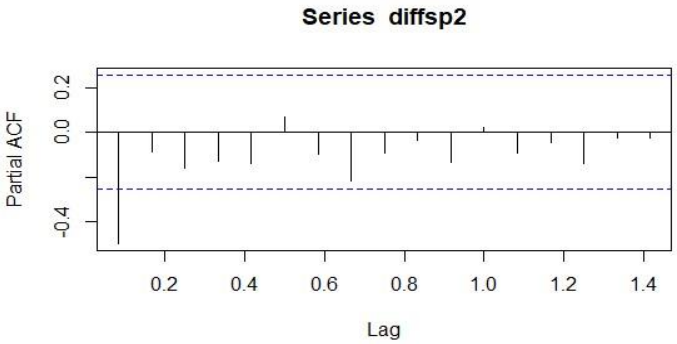
Şekil 4.18. SP2 Fark serisi durağanlık test değerleri

p değeri 0,05'ten küçük olduğu için, fark alınmış zaman serisinin durağan olduğu kabul edilir. Bu durum, verilerin 1. dereceden farkının alınmasıyla zaman serisinin durağanlık

özelliğinin arttığını gösterir. Bu aşamada, zaman serisinin daha istikrarlı olduğunu ve gelecekteki analizler veya tahminler için daha güvenilir bir temel sağladığı görülmüştür. Serinin farkı alındığından dolayı $d = 1$ kabul edilir.

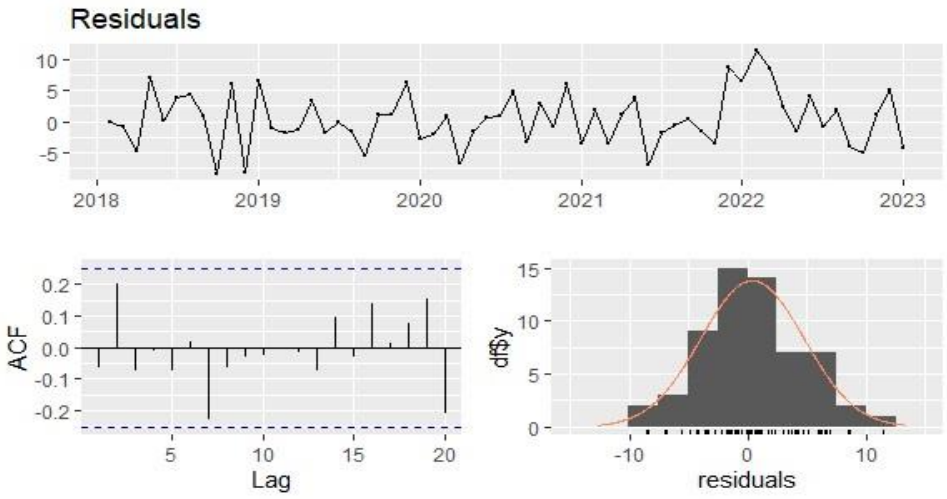


Şekil 4.19. Farkı alınan SP2 için ACF grafiği



Şekil 4.20. Farkı alınan SP2 için PACF grafiği

Farkı alınan serinin ACF ve PACF grafikleri üzerinde değerlendirme yapılır. Farkı alınan serinin ACF grafiği incelendiğinde, lag değerlerine bağlı olarak korelasyonun nasıl değiştiğini görülmüştür. İlk lag ‘da (0'da), fark alınmış verinin kendisiyle olan korelasyonunun 1 olduğunu görülmüştür, bu beklenen bir sonuçtur. Buna karşılık, lag değerleri arttıkça, korelasyon hızla düşer. Bu durum, fark alınmış verinin zaman içindeki korelasyonunun azaldığını ve zaman serisinin daha durağan hale geldiğini gösterir. Bu durum, zaman serisindeki eğilimin ve diğer yapısal özelliklerin başarıyla kaldırıldığına işaret eder.



Şekil 4.21. SP2 için hata dağılım grafikleri

SP2 serisi için hataların normal dağıldığı Şekil 4.21.'de görülmektedir. Serinin durağanlık kazandığı belirlendikten sonra mevsimsellik etkisi olup olmadığı incelenir. ACF ve PACF grafiklerinde seride mevsimsellik olmadığı görülmektedir. Bunun yanında, mevsimsellik test istatistiği olan Kruskal-Wallis testi ile doğru sonuca ulaşılır.

```
Test used:  Kruskall Wallis

Test statistic:  1.73
P-value:  0.1446716
```

Şekil 4.22. SP2 Mevsimsellik testi sonucu

Kruskal-Wallis istatistiği 1,73 olarak bulunmuştur ve *p* değeri test istatistiğine karşılık gelen anlamlılık düzeyinde (genellikle $\alpha = 0{,}05$) hesaplanmıştır. Bu durumda, *p* değerinin yüksek olması ($p > 0{,}05$) gruplar arasında istatistiksel olarak anlamlı bir farkın olmadığını gösterir. Dolayısıyla, verilerin mevsimler arasında istatistiksel olarak anlamlı bir farklılık göstermediği sonucuna varılmıştır. SP2 serisinde mevsimsellik olmadığı için $D = 0$ kabul edilir. Yapılan durağanlık ve mevsimsellik testleri ile ARIMA d ve D parametreleri bulunmuştur. Geliştirilen model bu aşamada ARIMA(p,1,q)(P,0,Q)$_{12}$ şeklinde simgelenebilmektedir.

Nihai modeli oluşturma sürecinde incelenen model seçeneklerinin hata değerleri Çizelge 4.3.'te gösterilmektedir:

Çizelge 4.3. SP2 ARIMA(p,1,q)(P,0,Q)$_{12}$ hata değerleri

	ME	**RMSE**	**MAE**	**MPE**	**MAPE**	**MASE**
ARIMA(1,1,0)(1,0,0)	0,13	4,41	3,65	-22,69	52,06	0,86
ARIMA(0,1,1)(0,0,1)	0,24	4,35	3,41	-23,45	49,32	0,80
ARIMA(0,1,1)(1,0,0)	0,23	4,34	3,42	-23,39	49,44	0,81
ARIMA(0,1,1)(1,0,1)	0,23	4,34	3,43	-23,37	49,51	0,81
ARIMA(1,1,1)(0,0,1)	0,39	4,33	3,41	-22,76	**48,93**	0,81
ARIMA(1,1,1)(1,0,1)	0,38	4,33	3,42	-22,70	49,01	0,81

Çizelge 4.3. göre, ARIMA modelleri arasında, en düşük MAPE değeri ile ARIMA(1,1,1)(0,0,1) en iyi performansı sergilemektedir ve aynı zamanda en düşük RMSE ve MAE değerlerine sahiptir. En düşük MASE değeri ile ARIMA(0,1,1)(0,0,1) modeli öne çıkmaktadır. En düşük MAPE hata değerini veren ARIMA(1,1,1)(0,0,1) modeline göre 6 aylık tahmin değerleri R programında *forecast* paketiyle hesaplanmış ve Çizelge 4.4'te verilmiştir.

Çizelge 4.4. SP2 serisi için 6 aylık tahmin sonuçları

Yıl	**Ay**	**Tahmin Değerleri**
2023	Mart	16
2023	Nisan	16
2023	Mayıs	16
2023	Haziran	15
2023	Temmuz	16
2023	Ağustos	15

Ljung-Box testinin bir zaman serisinde otokorelasyonun olup olmadığını belirleyen istatistiksel bir test olduğu, bir önceki seri için yapılan uygulama sırasında ifade edilmiştir. Ljung-Box hipotezi:

H_0: Artıklar bağımsız olarak dağıtılmıştır.

H_1: Artıklar bağımsız olarak dağıtılmaz; seri korelasyon sergiler.

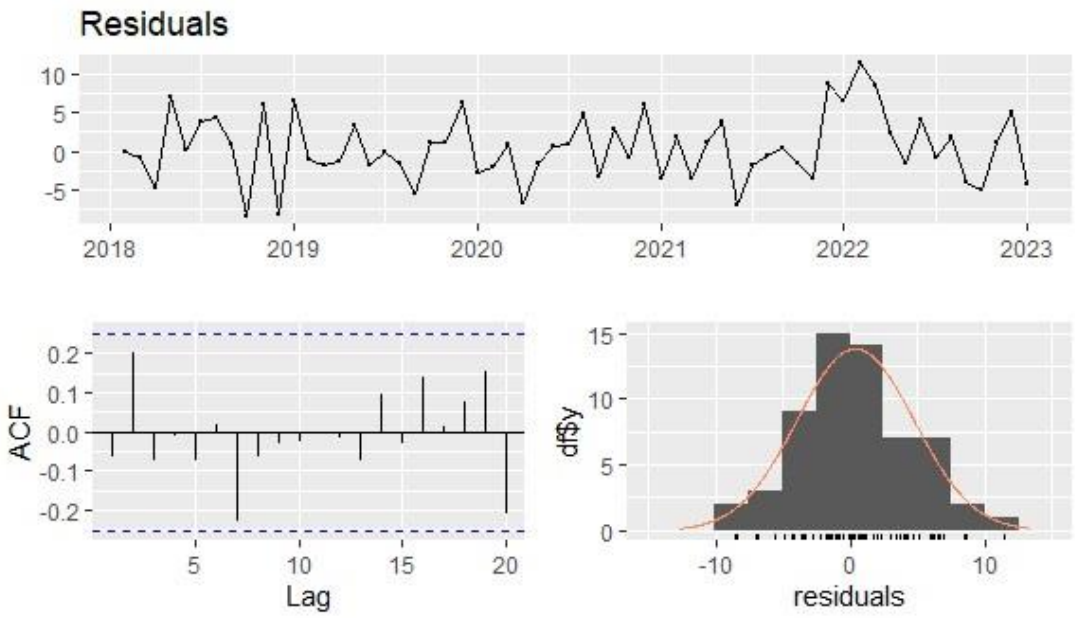
Hesaplanan *p* değeri (0,8013), 0,05 anlamlılık düzeyinden çok büyük olduğu için, otokorelasyonun olmadığı sonucuna varılmıştır. Bu durum, modelin hatalarının bağımsız ve rastgele olduğunu gösterir. Dolayısıyla, kullanılan ARIMA(1,1,0)(1,0,0) modelinin hatalarının otokorelasyon yapısının rastgele olduğu saptanmıştır.

```
Ljung-Box test

data:  Residuals
Q* = 7.7906, df = 12, p-value = 0.8013

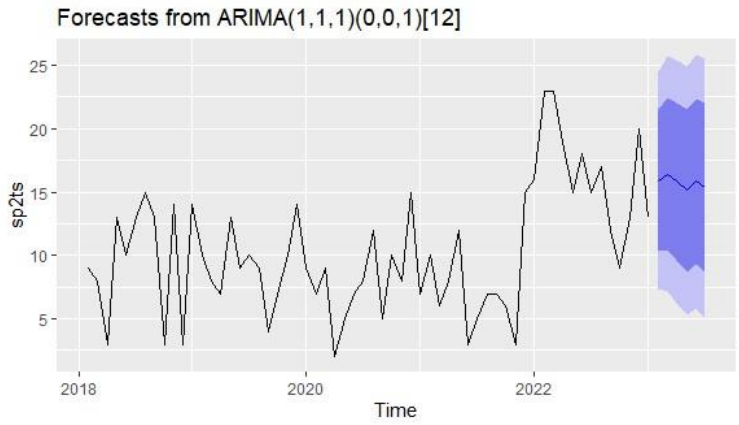
                Model df: 0.   Total lags used: 12
```

Şekil 4.23. SP2 model uyum test istatistiği değerleri



Şekil 4.24. SP2 tahmin serisinin hata dağılım grafiği

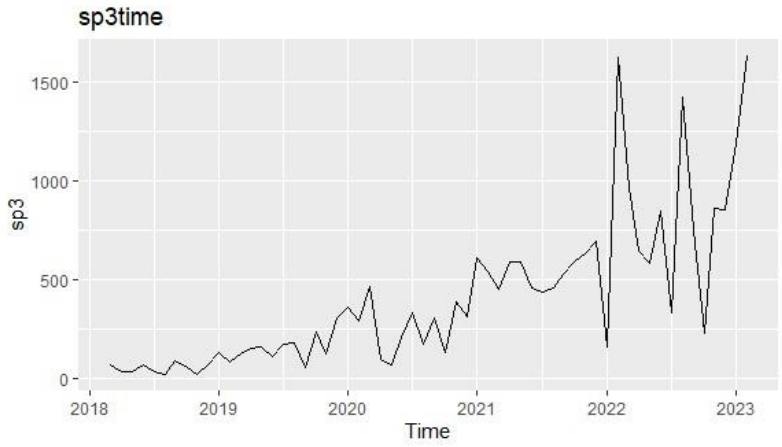
Modelin ürettiği tahmin hatalarının normal dağıldığı ve seçilen katsayılarının anlamlı olduğu Şekil 4.24.'te gösterilmektedir.



Şekil 4.25. SP2 Orijinal seri ve tahmin serisinin dağılım grafiği

Orijinal seri ile tahmin serisinin dağılımı Şekil 4.25.'te gösterilmektedir.

Yedek parça versiyon 3 (SP3) için ARIMA ile talep tahmini: SP3 verisi için Şekil 4.1.'de tanımlanan adımlar uygulanmıştır. İlk adım olan zaman serisi grafiği ile model seçimine başlanılmıştır. SP3 için çizilen zaman serisi grafiği Şekil 4.26.'daki gibidir:

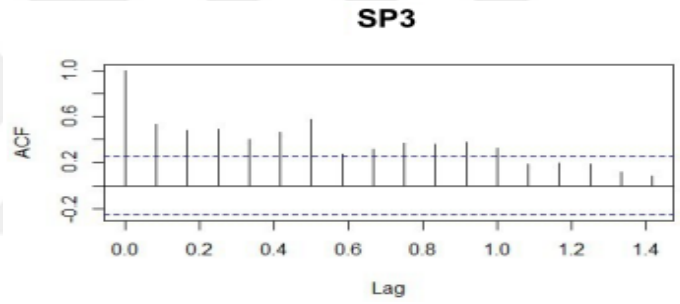


Şekil 4.26. SP3 için zaman seri grafiği

Bazı dönemlerde veri değerlerinde belirgin dalgalanmalar ve artışlar görülürken, diğer dönemlerde daha kararlı bir davranış gözlemlenmektedir. Grafiğe göre, veri setinin genel eğilimi zamanla artmaktadır, ancak bu artış bazı dönemlerde kesintiye uğramaktadır. Örneğin, indeksler 50. ay civarında bir düşüş eğilimi gösterirken, indeksler 60 civarında bir artış göstermektedir. Bu dalgalanmaların belirli bir nedeni olup olmadığını anlamak

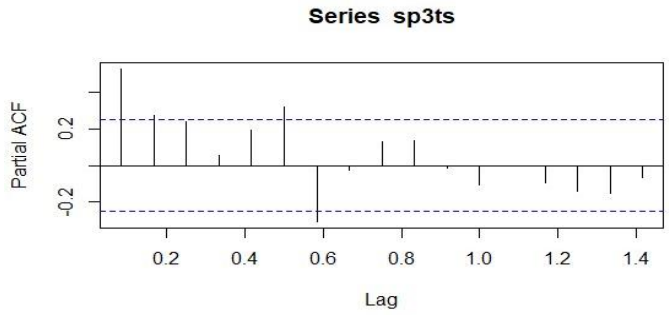
için daha fazla inceleme gerekebilir. Bununla birlikte, bu grafik genel eğilimi ve dönemsel dalgalanmaları göstermektedir.

Serinin ACF grafiği çizildiğinde grafiğin genel eğilimi, 0 dışındaki gecikme zamanlarında otokorelasyon değerlerinin yavaşça azaldığını göstermektedir. Bu, zaman serisinin önceki zaman noktalarındaki değerlerle gelecek değerleri arasında zayıflayan bir ilişkiye sahip olduğunu gösterir. Grafikte bazı gecikme zamanlarında yüksek otokorelasyon değerleri göze çarpmaktadır. Bu, zaman serisinin belirli zaman noktalarında kendisiyle güçlü bir ilişkiye sahip olduğunu gösterir. Bu yüksek otokorelasyon değerleri, zaman serisinin belirli bir zaman aralığında daha öngörülebilir olduğunu ve geçmiş verilere dayalı tahminlerin daha doğru olabileceğini düşündürmektedir.



Şekil 4.27. SP3 için ACF grafiği

SP3 için gecikmelerin fazla olduğu serinin durağan olmadığı sonucuna varılmıştır.



Şekil 4.28. SP3 için PACF grafiği

SP3 PACF grafiğine göre grafikteki gecikmeler seriye mevsimsellik ve durağanlık testi yapılması gerektiğini göstermektedir. ACF grafiğindeki ilk dört gecikme seride eğilim

olduğunu da gösterdiği üst yorumlarda ifade edilmiştir. İstatistiksel olarak durağanlık testi uygulanmıştır:

```
Augmented Dickey-Fuller Test

data:  sp3ts
Dickey-Fuller = -3.7159, Lag order = 3, p-value = 0.06103
alternative hypothesis: stationary
```

Şekil 4.29. SP3 Durağanlık test değerleri

Durağanlık testine göre *p* değeri 0,05'ten büyük olduğu için serinin durağan olmadığı anlaşılır. Seriyi eğilimden arındırmak için farkını alınır. Farkı alınan seriye durağanlık testi yapıldığı zaman farkı alınan serinin durağanlık kazandığı görülmüştür.

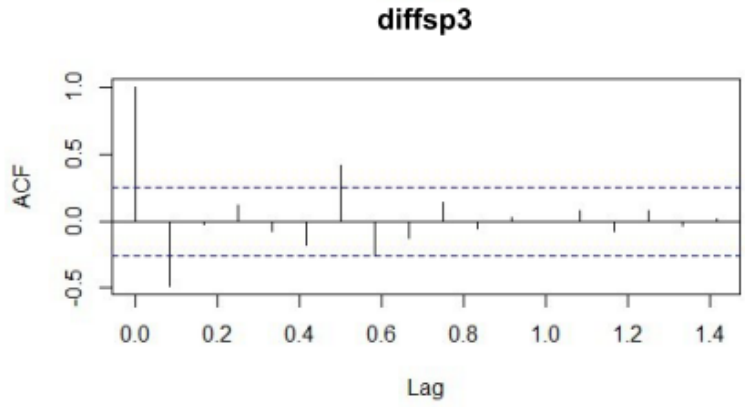
```
Augmented Dickey-Fuller Test

data:  diffsp3
Dickey-Fuller = -5.2085, Lag order = 3, p-value = 0.01
alternative hypothesis: stationary

Warning message:
In adf.test(diffmca) : p-value smaller than printed p-value
```

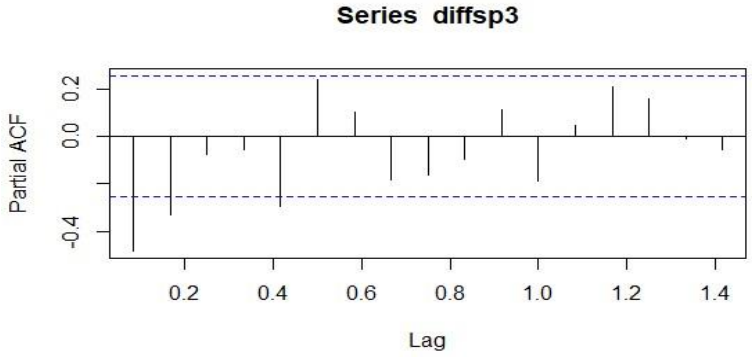
Şekil 4.30. SP3 Fark serisi durağanlık test değerleri

Farkı alınan seri için çizilen ACF grafiği, zaman serisinin birinci dereceden farkının otokorelasyon fonksiyonunu gösterir. Birinci dereceden fark alındığı için, bu grafik aslında birinci dereceden fark serisinin otokorelasyonunu göstermektedir. Grafiğin genel eğilimi, 0 dışındaki gecikme zamanlarında otokorelasyonun yavaşça azaldığını gösterir. Bu durum, birinci dereceden fark serisinin önceki zaman noktalarındaki değerlerle gelecek değerleri arasında zayıflayan bir ilişkiye sahip olduğunu gösterir. Model seçimi ve parametrelerin ayarlanması gibi adımlar için daha ayrıntılı bir inceleme gerekebilir.



Şekil 4.31. Farkı alınan SP3 için ACF grafiği

Farkı alınan seri için çizilen PACF grafiğinde, gecikmelerin kaybolduğunu görülmüştür. Grafiğin genel eğilimi, 0 dışındaki gecikme zamanlarında kısmi otokorelasyonun yavaşça azaldığını göstermektedir. Bu, birinci dereceden fark serisinin önceki zaman noktalarındaki değerlerle gelecek değerleri arasında zayıflayan bir ilişkiye sahip olduğunu gösterir. Bu durum, birinci dereceden fark serisinin belirli zaman aralıklarında kendisiyle güçlü bir ilişkiye sahip olduğunu ve diğer gecikme zamanlarından bağımsız olarak daha öngörülebilir olduğunu göstermektedir.



Şekil 4.32. Farkı alınan SP3 için PACF grafiği

Serinin durağan hale gelmesi için sadece 1. dereceden farkı alındığından $d = 1$ olarak kabul edilir. Serinin durağanlık kazandığını test ettikten sonra mevsimsellik etkisi olup olamadığı test edilir. ACF ve PACF grafiklerde seride mevsimsellik olmadığı görülmektedir. Bunun yanında, mevsimsellik test istatistiği olan Kruskal-Wallis testi ile doğru sonuca ulaşılır.

```
Test used:  Kruskall Wallis
Test statistic:  0.61
P-value:  0.8003472
```

Şekil 4.33. SP3 Mevsimsellik testi sonucu

Kruskal-Wallis testi sonuçlarına göre, *p* değeri alfa değerinden büyük olduğu için farkı alınan zaman mevsimsellik özelliğine sahip olmadığı sonucuna varılmıştır. Mevsimsel farkını almaya gerek olmadığından $D = 0$ kabul edilir. Yapılan durağanlık ve mevsimsellik testleri ile ARIMA d ve D parametreleri bulunmuştur. Geliştirilen model bu aşamada ARIMA(p,1,q)(P,0,Q)$_{12}$ şeklinde simgelenebilmektedir. Nihai modeli oluşturma sürecinde incelenen model seçeneklerinin hata değerleri Çizelge 4.5.'de gösterilmektedir:

Çizelge 4.5. SP3 ARIMA(p,1,q)(P,0,Q)$_{12}$ hata değerleri

	ME	**RMSE**	**MAE**	**MPE**	**MAPE**	**MASE**
ARIMA(1,1,0)(1,0,0)	32,53	288,70	176,17	-27,97	66,57	0,90
ARIMA(1,1,2)(1,0,0)	40,89	229,41	142,55	-17,10	53,16	0,73
ARIMA(1,1,2)(0,0,1)	40,74	231,14	142,41	-17,27	**53,04**	0,73
ARIMA(1,1,1)(0,0,1)	64,12	256,03	158,20	-14,00	56,03	0,81
ARIMA(1,1,1)(1,0,0)	62,45	251,61	156,43	-13,87	56,19	0,80
ARIMA(1,1,0)(0,0,1)	33,08	288,98	176,03	-27,80	66,40	0,90

Çizelge 4.5. göre, ARIMA modelleri arasında, en düşük MAPE değeri ile ARIMA(1,1,2)(0,0,1) modeli en iyi performansı sergilemektedir ve aynı zamanda en düşük MAE ve MASE değerine sahiptir. En iyi performans gösteren ARIMA(1,1,2)(0,0,1) modeline göre 6 aylık tahmin değerleri R programında hesaplanmış ve Çizelge 4.6.'da verilmiştir.

Çizelge 4.6. SP3 6 aylık tahmin sonuçları

Yıl	**Ay**	**Tahmin Değerleri**
2023	Mart	1048
2023	Nisan	1012
2023	Mayıs	1026
2023	Haziran	1100
2023	Temmuz	1036
2023	Ağustos	1246

Seçilen en anlamlı modelin artıklarının bağımsız olarak dağılım dağılmadığı Ljung-Box testi hipotezi ile test edilmiştir:

H_0: Artıklar bağımsız olarak dağıtılmıştır.

H_1: Artıklar bağımsız olarak dağıtılmaz; seri korelasyon sergiler.

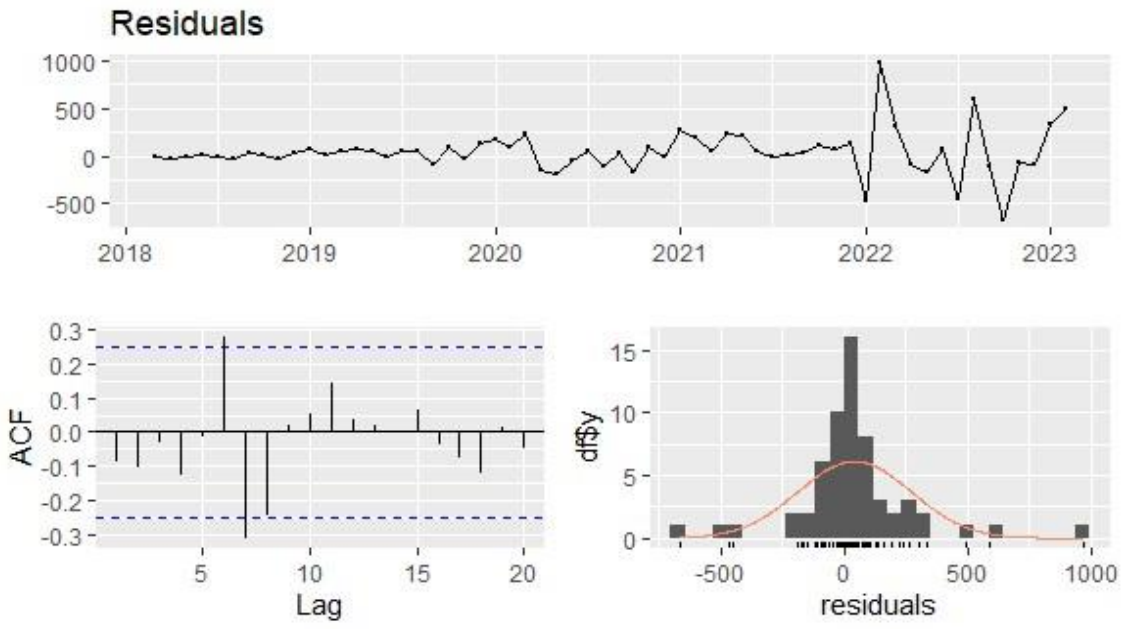
Ljung-Box test sonucuna göre *p* değeri (0,05499), 0,05 anlamlılık düzeyinden büyük olduğu için, otokorelasyonun bulunmadığı sonucuna varılmıştır. Bu durum, modelin hatalarının bağımsız ve rastgele olduğunu gösterir. Dolayısıyla, ARIMA(1,1,2)(0,0,1) modelinin tahmin hatalarının rastgele olduğunu anlaşılmaktadır.

```
Ljung-Box test

data:  Residuals
Q* = 20.698, df = 12, p-value = 0.05499

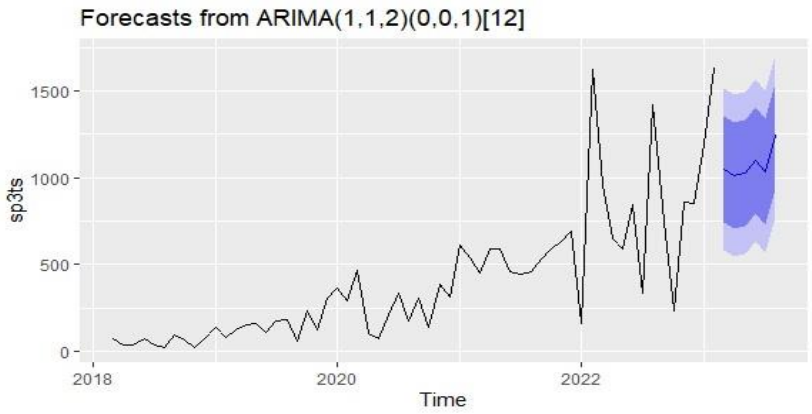
Model df: 0.   Total lags used: 12
```

Şekil 4.34. SP3 model uyum test istatistiği değerleri



Şekil 4.35. SP3 Tahmin serisinin hata dağılım grafiği

Modelin ürettiği tahmin hatalarının normal dağıldığı ve seçilen katsayılarının anlamlı olduğu Şekil 4.35.'te gösterilmektedir.



Şekil 4.36. SP3 Orijinal seri ve tahmin serisinin dağılım grafiği

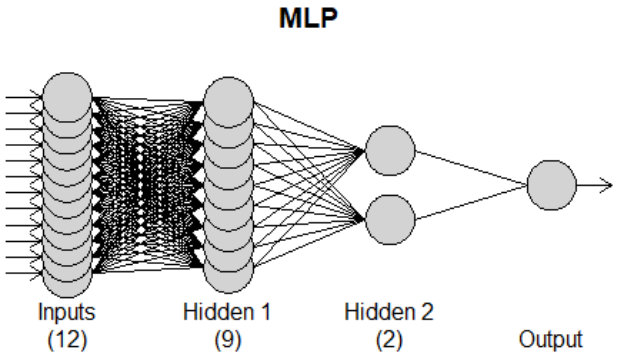
Yedek parça versiyon-1 için (SP1) MLP uygulaması: SP1 versiyonu için R programında MLP modeli *nnfor* paketi kullanılarak veriler işlenmiştir. Verilerin %90'ı eğitim verisi, %10'u test verisi olarak ayrılmıştır. İki gizli katmanlı ağ yapısı daha karmaşık veri setlerinde daha iyi performans göstermektedir.

Tek değişkenli zaman serisi verileri için yapay sinir ağındaki girdiler serideki gecikme sayılarından(lag) elde edilmektedir. SP1 serisinde, eğitim verisindeki gecikmeler R programında *nnfor* paketiyle hesaplanmış ve "12" olarak belirlenmiştir. Literatürde, gizli katmanlardaki nöron sayısı gibi hiperparametrelerin geniş bir aralıkta denendiği ve performans değerlendirmeleri için ağırlıklı olarak kullanıldığı görülmektedir. Gizli katmanlarda kaç tane gizli nöron olacağını belirleyebilmek için, 1. gizli katmanda 1'den 10'a kadar, 2. gizli katmanda ise 1'den 10'a kadar nöron sayıları kullanılarak toplamda 100 farklı ağ yapısı denenmiştir. Geniş nöron sayısı aralığı, modelin farklı nöron sayılarında nasıl performans gösterdiğini kapsamlı bir şekilde değerlendirmeyi sağlar ve aşırı öğrenme riskini azaltarak en uygun yapı seçimini kolaylaştırır.100 farklı ağ yapısından elde edilen MAPE hata ölçütü ile Çizelge 4.7'de verilmiştir.

Çizelge 4.7.SP1 MLP Hiperparametre MAPE Değerleri Tablosu

MAPE(SP1)		2.gizli katmandaki nöron sayısı									
		1	**2**	**3**	**4**	**5**	**6**	**7**	**8**	**9**	**10**
1.gizli katmandaki nöron sayısı	**1**	96,80	101,60	105,00	106,60	107,00	104,10	111,90	107,00	105,50	115,10
	2	67,00	33,87	29,10	34,98	42,00	44,92	39,28	43,66	32,93	46,31
	3	14,00	14,32	14,60	18,30	13,40	13,18	14,86	14,53	17,53	17,66
	4	6,60	6,44	7,86	8,15	11,20	12,08	9,31	11,29	16,61	16,17
	5	4,01	7,12	4,87	6,07	6,77	6,28	10,21	9,19	13,18	8,36
	6	3,44	2,85	5,55	5,74	4,55	6,63	6,37	8,06	4,92	9,74
	7	3,16	3,95	3,73	5,56	4,58	6,58	6,83	7,94	6,81	8,54
	8	2,10	2,49	3,07	4,13	4,36	4,79	5,01	6,61	8,76	6,63
	9	1,69	**1,66**	2,76	2,93	4,32	3,69	5,46	5,80	5,63	9,46
	10	2,04	2,90	2,78	2,53	3,69	4,07	6,36	5,17	4,09	6,48

En düşük MAPE değerini veren 1. gizli katmandaki nöron sayısı 9, 2. katmandaki nöron sayısı 2 olan model en uygun MLP modeli seçilmiştir. Elde edilen yapay sinir ağı yapısı Şekil 4.37.'de verilmiştir.



Şekil 4.37. SP1 MLP sinir ağı grafiği

SP1 için MLP ağ yapısı 12 girdi değişkeni ve MLP (9,2) modeli ile en iyi performansı sergilemiştir. R yazılımı analiz çıktısı Şekil 4.38.'deki verilmiştir.

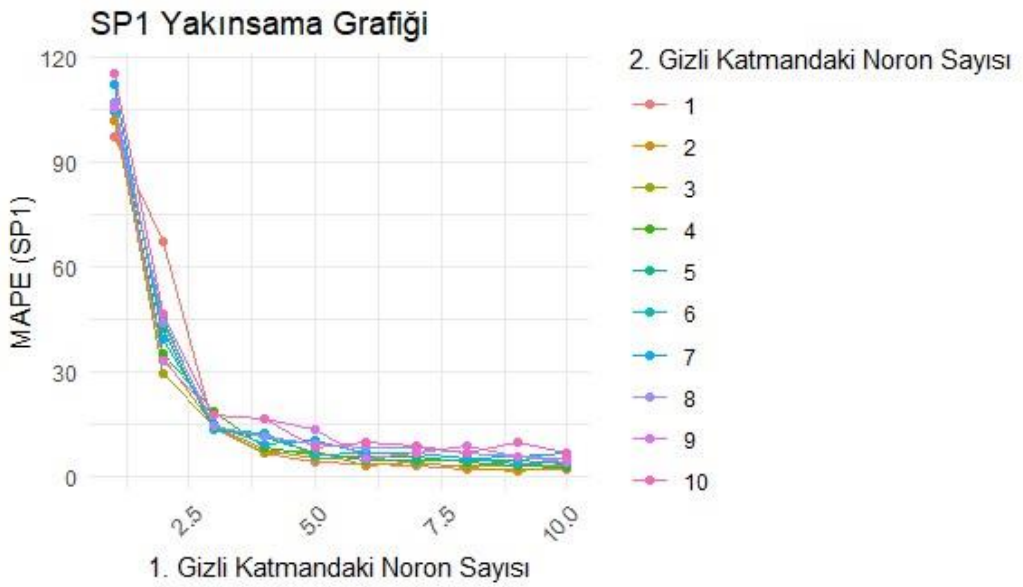
MLP fit with (9,2) hidden nodes and 20 repetitions.
Series modelled in differences: D1.
Univariate lags: (1,2,3,4,5,6,7,8,9,10,11,12)
Forecast combined using the median operator.
MSE: 3.6219.

Şekil 4.38. SP1 MLP model çıktısı

MLP yönteminin SP1 zaman serisi için test seti üzerindeki tahmin performansı çeşitli hata ölçütlerine göre Çizelge 4.8.'de gösterilmiştir.

Çizelge 4.8.SP1 MLP test verisi ile tahmin hata değerleri

	ME	**RMSE**	**MAE**	**MPE**	**MAPE**	**MASE**
MLP (SP1)	0,07	1,90	1,31	0,69	1,29	0,01



Şekil 4.39. SP1 yakınsama Grafiği (MAPE)

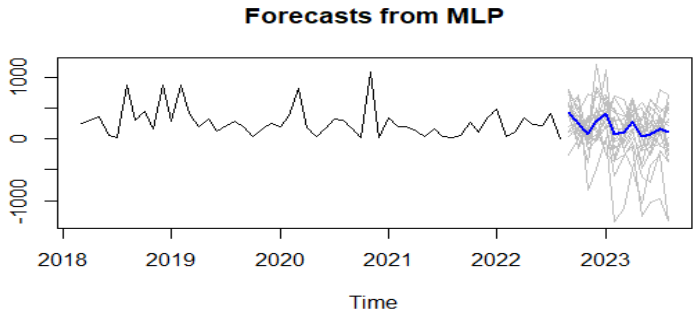
Şekil 4.39.'da, gizli katman sayısının modelin performansını önemli ölçüde etkilediği görülmektedir.Gizli katman sayısı arttıkça MAPE değerlerinin düştüğünü göstermektedir. Özellikle birinci gizli katman sabit tutulduğunda, ikinci gizli katmanın eklenmesi ile MAPE değerlerinde belirgin bir azalma sağlandığı gözlenmiştir.

MLP yöntemi kullanılarak SP1 zaman serisi için gelecek 6 ay süresince ortaya çıkacağı tahmin edilen değerler Çizelge 4.9.'de gösterilmektedir.

Çizelge 4.9. SP1 (MLP) 6 aylık tahmin değerleri

Yıl	Ay	Tahmin Değerleri
2023	Mart	122
2023	Nisan	140
2023	Mayıs	288
2023	Haziran	296
2023	Temmuz	153
2023	Ağustos	407

Orijinal seri ile birlikte tahmin sonuçlarını içeren dağılım grafiği Şekil 4.40.'ta verilmektedir.



Şekil 4.40. SP1 Orijinal seri ve MLP tahmin serisinin dağılım grafiği

Yedek parça versiyon-2 için MLP uygulaması: SP2 verisinde, SP1'de izlenen adımların aynısı uygulanmıştır. Veriler, %90 eğitim ve %10 test verisi olarak ikiye ayrılmıştır. Tek değişkenli zaman serisi verilerinde, yapay sinir ağı girdileri serideki gecikme sayılarından (lag) elde edilmiştir ve bu gecikmeler eğitim verisinde SP1'de olduğu gibi R programında *nnfor* paketi kullanılarak hesaplanmış ve "1" olarak belirlenmiştir.

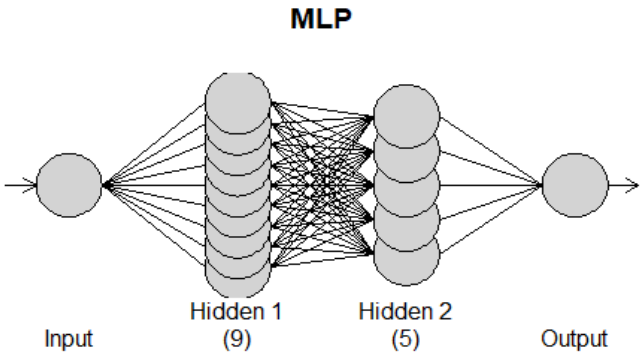
Modelin hiperparametreleri de SP1'deki yöntemle benzer bir şekilde ayarlanmıştır. Bu bağlamda, gizli katmanlardaki nöron sayıları geniş bir aralıkta değerlendirilmiştir. 1. gizli katmanda nöron sayıları 1'den 10'a kadar, 2. gizli katmanda ise 1'den 10'a kadar

değiştirilmiş ve toplamda 100 farklı ağ yapısı test edilmiştir. Bu hiperparametre ayarları, modelin farklı nöron yapılarındaki performansını detaylı bir şekilde değerlendirmek ve aşırı öğrenme riskini minimize ederek en uygun yapıyı seçmek amacıyla kullanılmıştır.100 farklı ağ yapısından elde edilen MAPE hata ölçütü ile Çizelge 4.10'de verilmiştir.

Çizelge 4.10.SP2 MLP Hiperparametre MAPE Değerleri Tablosu

MAPE(SP2)		**2.gizli katmandaki nöron sayısı**									
		1	**2**	**3**	**4**	**5**	**6**	**7**	**8**	**9**	**10**
1.gizli katmandaki nöron sayısı	**1**	49,83	49,82	49,78	49,82	49,81	49,80	49,83	49,79	49,81	49,80
	2	49,29	48,93	49,33	49,62	49,20	49,40	49,76	49,60	49,64	49,77
	3	46,51	47,33	46,49	45,32	49,17	48,65	49,30	48,97	49,46	49,35
	4	45,76	46,48	48,59	43,65	48,24	48,90	48,82	49,39	49,33	48,92
	5	44,12	43,18	46,18	48,83	48,86	49,06	47,65	48,49	48,86	47,38
	6	44,12	44,84	42,93	47,04	48,64	48,72	46,24	48,14	48,70	49,51
	7	43,78	42,18	41,90	41,51	46,62	44,91	47,60	48,32	48,97	49,01
	8	43,54	40,77	40,43	44,09	48,91	45,13	47,89	47,79	49,05	48,75
	9	44,51	47,36	44,80	45,12	**39,97**	49,34	49,20	44,95	47,43	48,53
	10	40,98	44,26	41,22	40,82	42,09	48,55	48,48	48,22	47,92	48,50

En düşük MAPE değerini veren 1. gizli katmandaki nöron sayısı 9, 2. gizli katmandaki nöron sayısı 5 olan model en uygun MLP modeli seçilmiştir. Elde edilen yapay sinir ağı yapısı Şekil 4.41.'de verilmiştir.



Şekil 4.41. SP2 MLP sinir ağı grafiği

SP2 için MLP ağ yapısı 1 girdi değişkeni ve MLP (9,5) modeli ile en iyi performansı sergilemiştir. R yazılımı analiz çıktısı Şekil 4.42.'de verilmiştir:

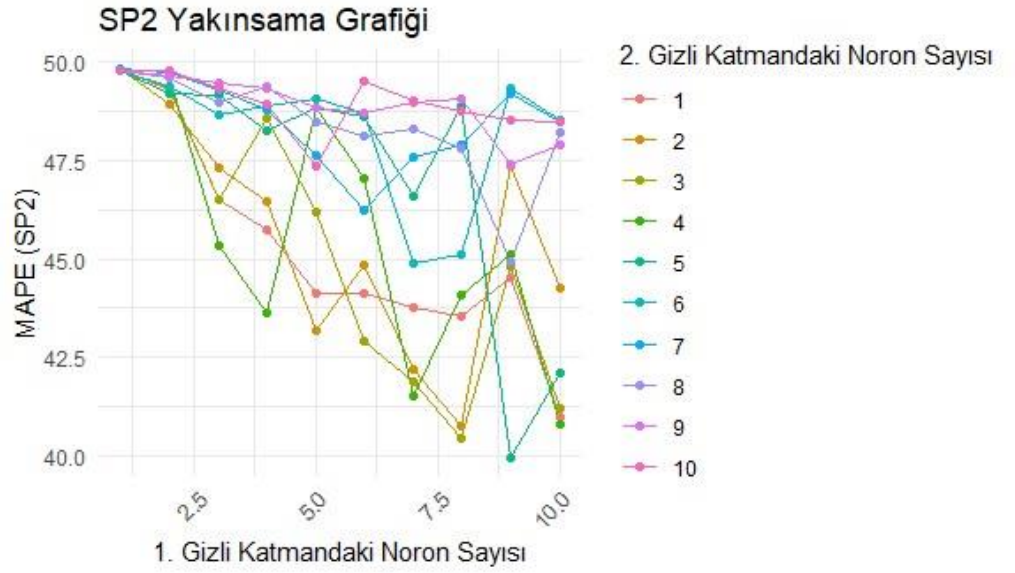
```
MLP fit with (9,5) hidden nodes and 20 repetitions.
Series modelled in differences: D1.
Univariate lags: (1)
Forecast combined using the median operator.
MSE: 15,2448.
```

Şekil 4.42. SP2 MLP model çıktısı

MLP yönteminin SP2 zaman serisi test seti üzerindeki tahmin performansı çeşitli hata ölçütlere göre Çizelge 4.11.'de gösterilmiştir.

Çizelge 4.11. SP2 MLP test verisi ile tahmin hata değerleri

	ME	**RMSE**	**MAE**	**MPE**	**MAPE**	**MASE**
MLP (SP2)	0,01	3,97	3,08	6,88	41,73	0,69



Şekil 4.43. SP2 yakınsama Grafiği (MAPE)

Şekil 4.43.'e göre, 1. ve 2. katmanların kombinasyonları modelin performansında önemli farklılıklar yaratmaktadır. Varyasyonlar, bazı katman kombinasyonlarının modelin doğruluğunu artırırken diğerlerinin performansı düşürdüğünü göstermektedir. Modelin

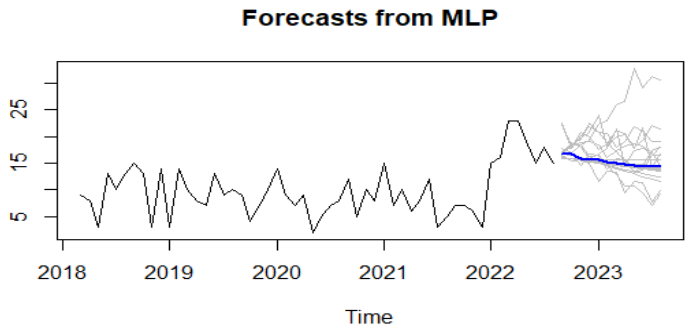
optimizasyonu için, en düşük MAPE değerine sahip katman kombinasyonlarının belirlenmesi kritik öneme sahiptir.

MLP yöntemi kullanılarak SP2 zaman serisi için gelecek 6 ay süresince ortaya çıkacağı tahmin edilen değerler Çizelge 4.12.'de gösterilmektedir:

Çizelge 4.12.SP2 (MLP) 6 aylık tahmin değerleri

Yıl	Ay	Tahmin Değerleri
2023	Mart	16
2023	Nisan	15
2023	Mayıs	15
2023	Haziran	15
2023	Temmuz	16
2023	Ağustos	14

Orijinal serinin ile birlikte tahmin sonuçlarını içeren dağılım grafiği Şekil 4.44.'te verilmektedir.



Şekil 4.44. SP2 Orijinal seri ve MLP tahmin serisinin dağılım grafiği

Yedek parça versiyon-3 için MLP uygulaması: SP3 verisinde, SP1 ve SP2 verisinde izlenen adımların aynısı uygulanmıştır. Veriler, %90 eğitim ve %10 test verisi olarak ikiye ayrılmıştır. Tek değişkenli zaman serisi verilerinde, yapay sinir ağı girdileri serideki gecikme sayılarından (lag) elde edilmiştir ve bu gecikmeler eğitim verisinde SP1'de

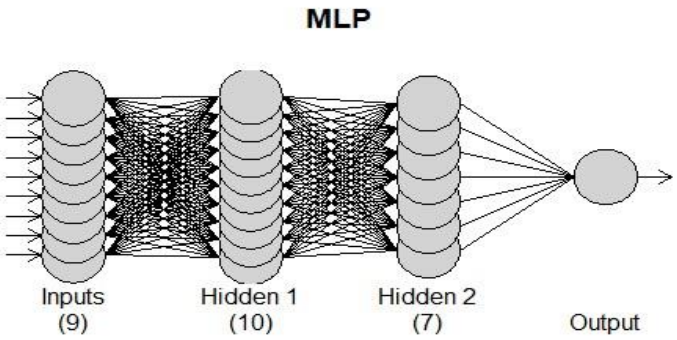
olduğu gibi R programında *nnfor* paketi kullanılarak hesaplanmış ve 9 olarak belirlenmiştir.

Modelin hiperparametreleri de SP1 ve SP2'deki yöntemlere benzer bir şekilde ayarlanmıştır. Bu bağlamda, gizli katmanlardaki nöron sayıları geniş bir aralıkta değerlendirilmiştir. 1. gizli katmanda nöron sayıları 1'den 10'a kadar, 2. gizli katmanda ise 1'den 10'a kadar değiştirilmiş ve toplamda 100 farklı ağ yapısı test edilmiştir. Bu hiperparametre ayarları, modelin farklı nöron yapılarındaki performansını detaylı bir şekilde değerlendirmek ve aşırı öğrenme riskini minimize ederek en uygun yapıyı seçmek amacıyla kullanılmıştır.100 farklı ağ yapısından elde edilen MAPE hata ölçütü ile Çizelge 4.13.'te verilmiştir.

Çizelge 4.13.SP3 MLP Hiperparametre MAPE Değerleri Tablosu

MAPE(SP3)		**2.gizli katmandaki nöron sayısı**									
		1	**2**	**3**	**4**	**5**	**6**	**7**	**8**	**9**	**10**
1.gizli katmandaki nöron sayısı	**1**	88,03	82,53	82,46	83,04	82,26	81,70	82,33	82,18	82,32	81,85
	2	62,57	55,59	59,54	56,26	58,90	58,17	62,36	57,03	54,29	58,43
	3	48,41	52,22	52,95	49,71	55,26	55,22	53,13	52,17	52,95	55,97
	4	44,81	47,43	42,86	38,07	36,69	44,87	44,52	44,31	46,20	45,95
	5	38,98	36,27	34,22	39,58	36,52	35,26	43,11	42,93	47,18	44,15
	6	26,43	31,74	36,96	33,43	30,33	38,25	33,09	31,01	34,34	44,96
	7	27,16	30,10	32,87	29,74	26,83	37,84	28,48	31,06	31,18	29,90
	8	25,69	22,32	23,94	33,43	29,95	29,47	26,52	36,68	27,23	29,25
	9	29,35	24,89	25,08	26,32	25,73	25,40	26,13	28,90	27,96	28,58
	10	21,90	24,08	26,45	27,17	23,75	27,62	**20,25**	33,21	32,34	26,43

En düşük MAPE değerini veren 1. gizli katmandaki nöron sayısı 10, 2. gizli katmandaki nöron sayısı 7 olan model en uygun MLP modeli seçilmiştir. Elde edilen yapay sinir ağı yapısı Şekil 4.45.'de verilmiştir.



Şekil 4.45. SP3 MLP sinir ağı grafiği

SP3 için MLP ağ yapısı 1 girdi değişkeni ile MLP (10,7) modeli ile en iyi performansı sergilemiştir. R yazılımı analiz çıktısı Şekil 4.46.'da verilmiştir:

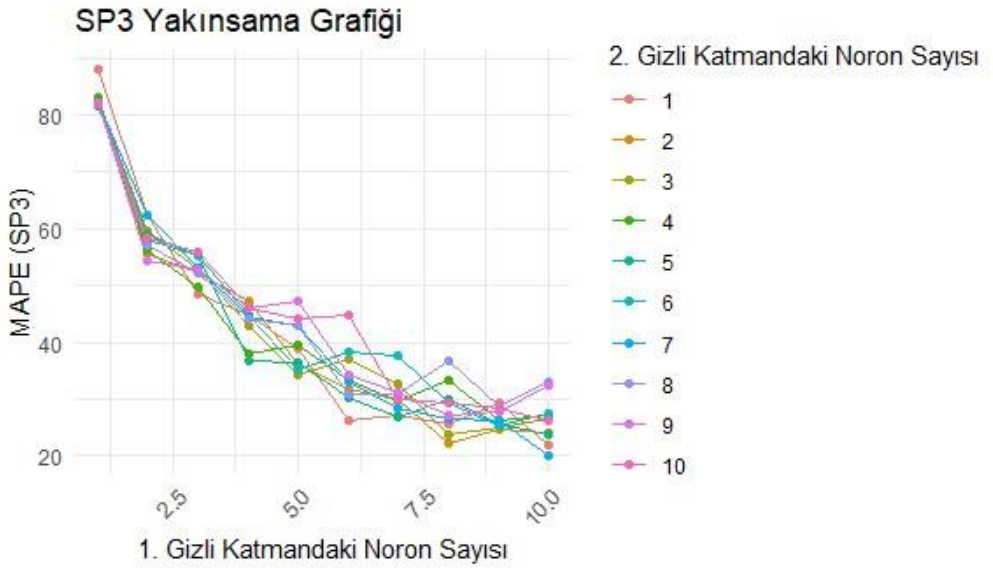
```
MLP fit with (10,7) hidden nodes and 20
repetitions.
Series modelled in differences: D1.
Univariate lags: (1,2,3,4,5,7,8,9,12)
Forecast combined using the median operator.
MSE: 1793.3999
```

Şekil 4.46. SP3 MLP model çıktısı

MLP yönteminin SP3 zaman serisi test seti üzerindeki tahmin performansı çeşitli ölçütlere göre Çizelge 4.14.'de gösterilmiştir.

Çizelge 4.14.SP3 MLP test verisi ile tahmin hata değerleri

	ME	**RMSE**	**MAE**	**MPE**	**MAPE**	**MASE**
MLP (SP3)	0,57	42,35	30,83	-10,92	49,98	0,18



Şekil 4.47. SP3 yakınsama Grafiği (MAPE)

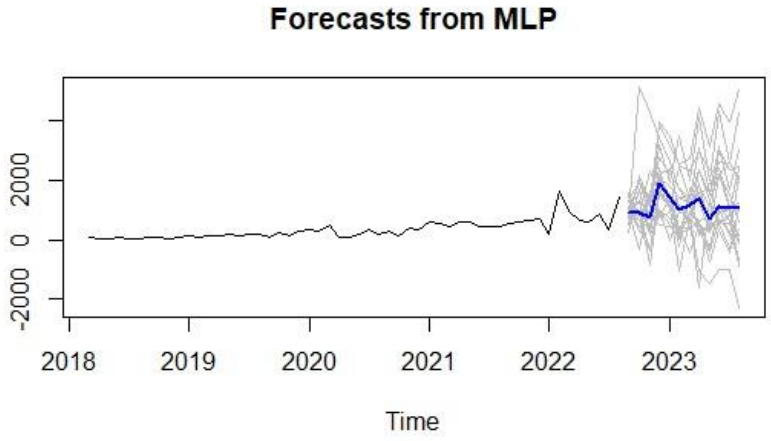
Şekil 4.47.'ye göre, 1. ve 2. katmanlar başlangıçta yüksek hata oranlarına sahipken, eğitim süreci ilerledikçe bu oranlar belirgin şekilde azalıyor. Her iki katmanda da belirli bir noktadan sonra hata oranları stabil hale geliyor, bu da modelin başarılı bir şekilde öğrenme gerçekleştirdiğini gösteriyor.

MLP yöntemi kullanılarak SP3 zaman serisi için gelecek 6 ay süresince ortaya çıkacağı tahmin edilen değerler Çizelge 4.15.'te gösterilmektedir:

Çizelge 4.15.SP3 (MLP) 6 aylık tahmin değerleri

Yıl	Ay	Tahmin Değerleri
2023	Mart	1176
2023	Nisan	1367
2023	Mayıs	713
2023	Haziran	1095
2023	Temmuz	1047
2023	Ağustos	1063

Orijinal serinin ile birlikte tahmin sonuçlarını içeren dağılım grafiği Şekil 4.48.'de verilmiştir.



Şekil 4.48. SP3 Orijinal seri ve MLP tahmin serisinin dağılım grafiği

Yedek parça versiyon 1 (SP1) için NNAR uygulaması: SP1 zaman serisi, R programında *nnetar* paketi kullanılarak analiz edilmiştir. Veriler, %90 eğitim ve %10 test verisi olarak ikiye ayrılmıştır. Bu süreçte, modelin tahmin performansını arttırmak amacıyla öğrenme oranı ve gizli katmandaki nöron sayısı gibi hiperparametreler seçilmiştir. Hiperparametrelerin belirlenmesi için kullanılan yöntemler, model performansını optimize etmek için kritik bir rol oynamıştır.

Öğrenme oranı, modelin ağırlık güncellemelerinin büyüklüğünü belirleyen önemli bir parametredir. Literatürde belirtildiği gibi, " Öğrenme oranını ayarlamak genellikle, elle seçilen oranların yüksek veya düşük olmasının modelin performansını etkilediği bir süreçtir. Bu oranın çok yüksek seçilmesi, modelin amaç fonksiyonu açısından sapmasına ve çok düşük seçilmesi ise yavaş öğrenmeye yol açar (Zeiler,2012)". SP1 NNAR modeli analizi üç farklı öğrenme oranı (0.001, 0.01, 0.1) ile test edilmiştir. Her öğrenme oranının model performansı üzerindeki etkileri değerlendirilmiş ve en uygun öğrenme oranı belirlenmiştir.

Gizli katmandaki nöron sayısı, modelin öğrenme kapasitesini ve doğrusal olmayan ilişkileri öğrenme yeteneğini etkiler. Gizli katmandaki nöron sayısının belirlenmesi için,literatürde ağırlıklı olarak kullanılan nöron sayıları (1'den 10'a kadar) denenmiş ve her kombinasyonun model performansı üzerindeki etkileri incelenmiştir. Bu testler

sonucunda, her öğrenme oranı için MAPE değerleri hesaplanmış ve hangi nöron sayısının ve öğrenme oranının en iyi performansı sağladığı belirlenmiştir.

Hiperparametre seçimi süreci, modelin tahmin doğruluğunu en üst düzeye çıkarmak ve genel performansını optimize etmek için önemli bir temel oluşturmaktadır. Her bir kombinasyon için elde edilen MAPE değerleri Çizelge 4.16'da sunulmuştur.

Çizelge 4.16.SP1 NNAR Hiperparametre MAPE Değerleri Tablosu

MAPE(SP1)		Öğrenme oranı		
		0,001	**0,01**	**0,1**
Gizli katmandaki nöron sayısı	**1**	190,24	195,07	207,20
	2	164,44	189,60	204,13
	3	153,42	164,26	203,99
	4	146,52	164,01	199,30
	5	139,68	156,26	201,98
	6	142,21	169,60	200,03
	7	141,65	158,27	193,14
	8	129,57	157,91	196,26
	9	**125,67**	159,08	198,21
	10	129,07	159,32	199,93

Çizelge 4.16.'da verilen sonuçlara göre, SP1 zaman serisi analizi için en düşük MAPE değeri, gizli katmanda 9 nöron bulunan ve öğrenme oranı 0.001 olarak ayarlanan modelle elde edilmiştir. Bu kombinasyon, modelin tahmin doğruluğunu en üst düzeye çıkaran optimal hiperparametre olduğunu göstermektedir.

NNAR modelinde, *p* ve *P* parametrelerinin seçimi önemlidir. *p* değeri, gecikmeleri (lag sayısı) ifade eder. Başka bir deyişle, p, modelin geçmiş verilerdeki kaç adet gecikmeyi dikkate alacağını belirler. *nnetar* fonksiyonu NNAR modelinde p değerini 1 olarak belirlemiştir. Bu seçim, ACF grafiğinde yalnızca bir gecikmenin anlamlı olduğunu yansıtır. Şekil 4.3'te, SP1 zaman serisine ait ACF grafiğinde sadece bir gecikme anlamlı olduğu görülmektedir.

P parametresi ise mevsimsel etkilerin dikkate alınma derecesini belirler. Modelde P=1 olarak bulunmuştur, bu da modelin mevsimsel bileşenlere minimal düzeyde

odaklandığını ve mevsimsel etkileri göz ardı ederek performansını optimize etmesine olanak tanır. NNAR model R çıktısı Şekil 4.49.'da gösterilmektedir.

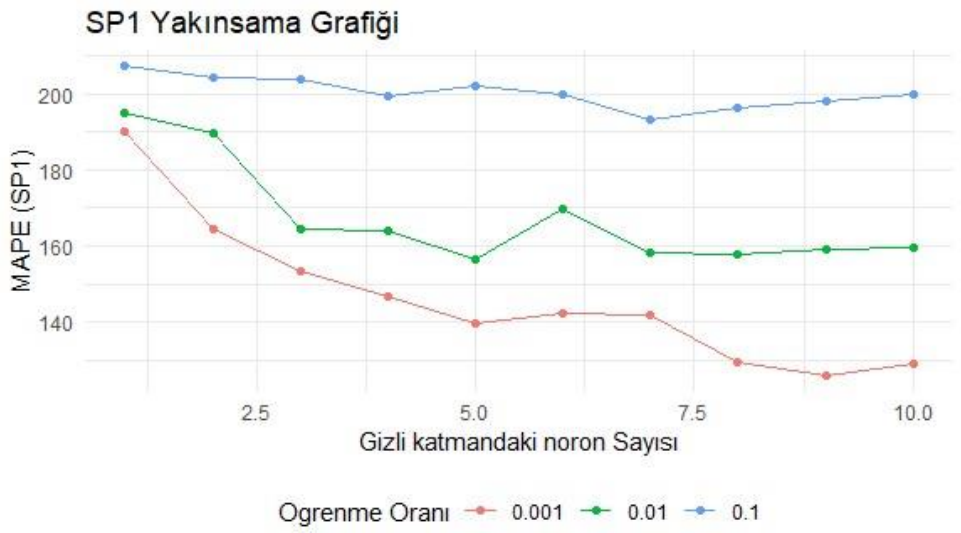
```
Forecast method: NNAR(1,1,9)[12]
Model Information:
Average of 20 networks, each of which is
a 2-9-1 network with 37 weights
options were - linear output units
```

Şekil 4.49.SP1 NNAR model çıktısı

NNAR yönteminin SP1 test serisi için sağladığı tahmin performansı çeşitli ölçütlere göre Çizelge 4.17'te gösterilmektedir:

Çizelge 4.17. SP1 NNAR test verisi ile tahmin hata değerleri

	ME	RMSE	MAE	MPE	MAPE	MASE
NNAR (SP1)	0,04	139,04	86,81	-107,77	129,59	0,42



Şekil 4.50. SP1 yakınsama Grafiği (MAPE)

Şekil 4.50.'ye göre, gizli katmandaki nöron sayısının ve öğrenme oranlarının model performansı üzerindeki etkilerini açıkça ortaya koymaktadır. Nöron sayısının artırılması, MAPE değerlerinde belirgin bir iyileşmeye yol açmaktadır.

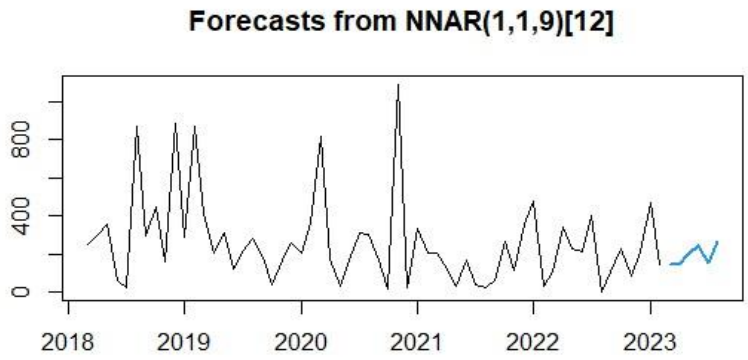
Öğrenme oranlarının etkileri ise , 0,001 öğrenme oranı ile MAPE değerleri en düşük seviyede kalmıştır. Bu oran, modelin en iyi performansı gösterdiğini ve tahmin hatalarının minimum seviyede olduğunu ortaya koymaktadır. 0,01 öğrenme oranı, en düşük öğrenme oranı kadar etkili değildir. 0,1 öğrenme oranı ise MAPE değerlerini artırmış ve modelin performansını olumsuz etkilemiştir. Bu sonuçlar, model performansını optimize etmek için düşük öğrenme oranının tercih edilmesi gerektiğini ve nöron sayısının artırılmasının doğruluğu artırdığını vurgulamaktadır.

NNAR yöntemi kullanılarak SP1 zaman serisi için gelecek 6 ay süresince ortaya çıkacağı tahmin edilen değerler Çizelge 4.18'te gösterilmektedir:

Çizelge 4.18. SP1 (NNAR) 6 aylık tahmin değerleri

Yıl	Ay	Tahmin Değerleri
2023	Mart	147
2023	Nisan	144
2023	Mayıs	203
2023	Haziran	244
2023	Temmuz	157
2023	Ağustos	263

SP1 orijinal serisi için elde edilen en iyi NNAR modelinin tahmin sonuçları ile orijinal serinin dağılımı Şekil 4.51.'de verilmiştir.



Şekil 4.51. SP1 Orijinal seri ve NNAR tahmin serisinin dağılım grafiği

Yedek parça versiyon-2 için NNAR uygulaması: SP2 zaman serisi analizi, SP1 veri setindeki aynı yöntemler kullanılarak gerçekleştirilmiştir. Veriler, %90 eğitim ve %10 test verisi olarak ikiye ayrılmıştır. Bu kapsamda, modelin tahmin performansını artırmak amacıyla öğrenme oranı ve gizli katmandaki nöron sayısı gibi hiperparametreler üzerinde benzer testler yapılmıştır. Öğrenme oranı ve gizli katmandaki nöron sayısı için uygulanan adımlar, SP1 veri setinde olduğu gibi, modelin performansını optimize etmek amacıyla kullanılmıştır.

SP2 verisi için de SP1 veri setinde kullanılan aynı öğrenme hızları (0.001, 0.01, 0.1) ve gizli katmandaki nöron sayıları (1'den 10'a kadar) kombinasyonları test edilmiştir. Her öğrenme oranı ve nöron sayısı kombinasyonunun model performansına etkileri değerlendirilmiştir. Her bir kombinasyon için elde edilen MAPE değerleri Çizelge 4.19.'da verilmiştir.

Çizelge 4.19.SP2 NNAR Hiperparametre MAPE Değerleri Tablosu

MAPE(SP2)		Öğrenme oranı		
		0,001	**0,01**	**0,1**
Gizli katmandaki nöron sayısı	**1**	40,55	40,69	41,56
	2	37,09	37,58	39,20
	3	31,82	32,62	36,01
	4	28,85	29,99	34,03
	5	23,04	23,94	33,13
	6	18,40	19,85	32,80
	7	15,32	17,62	32,40
	8	13,09	17,34	32,59
	9	10,40	14,53	32,56
	10	**8,37**	13,29	32,60

Çizelge 4.19.'da verilen sonuçlara göre, SP2 zaman serisi analizi için en düşük MAPE değeri, gizli katmanda 10 nöron bulunan ve öğrenme oranı 0.001 olarak ayarlanan modelle elde edilmiştir. Bu kombinasyon, modelin tahmin doğruluğunu en üst düzeye çıkaran optimal hiperparametre olduğunu göstermektedir.

En düşük MAPE değerine sahip NNAR(2,1,10) modeli olmuştur. R çıktısı Şekil 4.52.'de verilmiştir. Modelde, p=2 ve P=1 otomatik olarak bulunmuştur. *p* değerinin 2 olması anlamlı gecikme sayısının(lag) 2 olduğunu göstermektedir. *P* değerinin 1 olması ise mevsimsel etkilerin minimum düzeyde tutulduğunu göstermektedir.

```
Forecast method: NNAR(2,1,10)[12]
Model Information:

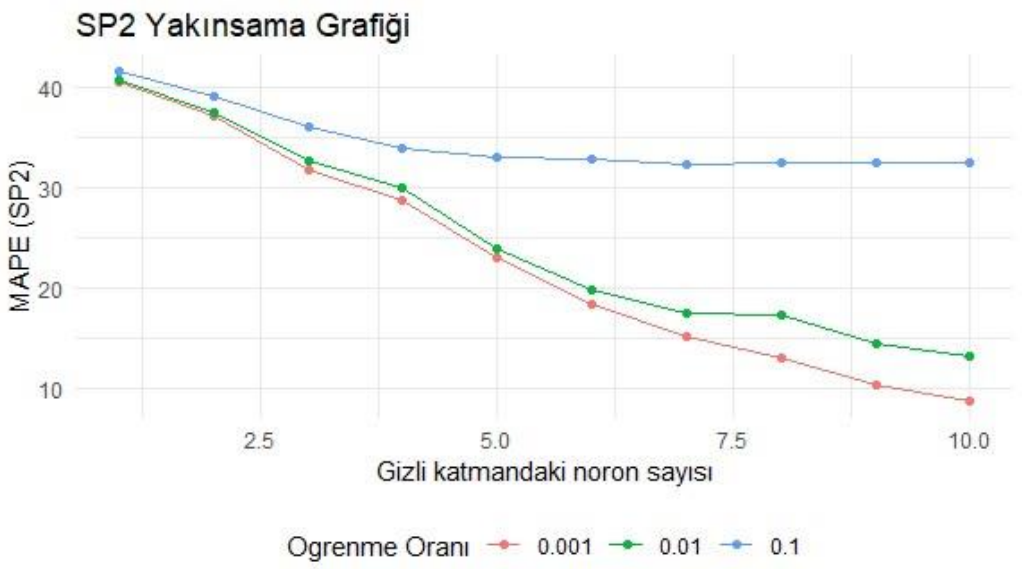
Average of 20 networks, each of which is
a 3-10-1 network with 51 weights
options were - linear output units
```

Şekil 4.52. SP2 NNAR model çıktısı

NNAR yönteminin SP2 test serisi için sağladığı tahmin performansı çeşitli ölçütlere göre Çizelge 4.20.'te gösterilmektedir:

Çizelge 4.20. SP2 NNAR test verisi ile tahmin hata değerleri

	ME	**RMSE**	**MAE**	**MPE**	**MAPE**	**MASE**
NNAR (SP2)	0,01	0,85	0,56	-3,82	8,60	0,11



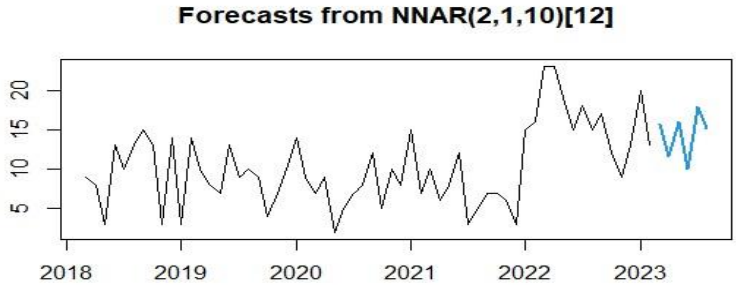
Şekil 4.53. SP2 yakınsama Grafiği (MAPE)

Şekil 4.53.'e göre, SP2 veri setinde gizli katmandaki nöron sayısının artışıyla MAPE değerlerinin azaldığını göstermektedir; en düşük MAPE değeri nöron sayısının 10 olduğu durumda (8,73) elde edilmiştir. 0,001 ve 0,01 öğrenme oranları yakın performans göstermiştir fakat nöron sayısının artmasıyla 0,001 en iyi performansa sahip olmuştur. 0,1 öğrenme oranı ise MAPE değerlerini artırmış ve modelin doğruluğunu olumsuz etkilemiştir.SP2 için elde edilen en iyi NNAR modeli ile 6 aylık tahmin değerleri elde edilmiştir ve bu değerler Çizelge 4.21.'de listelenmiştir.

Çizelge 4.21. SP2 (NNAR) 6 aylık tahmin değerleri

Yıl	Ay	Tahmin Değerleri
2023	Mart	13
2023	Nisan	11
2023	Mayıs	16
2023	Haziran	10
2023	Temmuz	18
2023	Ağustos	10

Elde edilen tahmin sonuçları ile orijinal serinin dağılımı Şekil 4.54.'te verilmektedir:



Şekil 4.54. SP2 Orijinal seri ve NNAR tahmin serisinin dağılım grafiği

Yedek parça versiyon-3 için NNAR uygulaması SP3 zaman serisi analizi, SP1 ve SP2 veri setlerindeki aynı yöntemler kullanılarak gerçekleştirilmiştir. Veriler, %90 eğitim ve %10 test verisi olarak ikiye ayrılmıştır.Bu kapsamda, modelin tahmin performansını artırmak amacıyla öğrenme oranı ve gizli katmandaki nöron sayısı gibi hiperparametreler üzerinde benzer testler yapılmıştır. Öğrenme oranı ve gizli katmandaki nöron sayısı için uygulanan adımlar, SP1 ve SP2 veri setinde olduğu gibi, modelin performansını optimize etmek amacıyla kullanılmıştır.

SP3 verisi için de SP1 ve SP2 veri setlerinde kullanılan aynı öğrenme hızları (0.001, 0.01, 0.1) ve gizli katmandaki nöron sayıları (1'den 10'a kadar) kombinasyonları test edilmiştir. Her öğrenme oranı ve nöron sayısı kombinasyonunun model performansına etkileri değerlendirilmiştir. Her bir kombinasyon için hesaplanan MAPE değerleri Çizelge 4.22.'de sunulmuştur.

Çizelge 4.22.SP3 NNAR Hiperparametre MAPE Değerleri Tablosu

MAPE(SP3)		Öğrenme oranı		
		0,001	**0,01**	**0,1**
Gizli katmandaki nöron sayısı	**1**	64,45	61,16	60,43
	2	37,56	42,52	43,84
	3	29,62	30,60	40,34
	4	19,46	23,49	37,88
	5	12,77	19,31	37,09
	6	9,50	17,09	36,83
	7	7,34	13,95	36,85
	8	5,21	13,52	36,86
	9	4,55	13,12	37,09
	10	**4,24**	12,06	36,76

Çizelge 4.22.'de verilen sonuçlara göre, SP3 zaman serisi analizi için en düşük MAPE değeri, gizli katmanda 10 nöron bulunan ve öğrenme oranı 0.001 olarak ayarlanan modelle elde edilmiştir. Bu kombinasyon, modelin tahmin doğruluğunu en üst düzeye çıkaran optimal hiperparametre olduğunu göstermektedir.

En düşük MAPE değerine sahip NNAR(7,1,10) modeli olmuştur. R çıktısı Şekil 4.55.'te verilmiştir. Modelde, p=7 ve P=1 otomatik olarak bulunmuştur. *p* değerinin 7 olması anlamlı gecikme sayısının(lag) 7 olduğunu göstermektedir. *P* değerinin 1 olması ise mevsimsel etkilerin minimum düzeyde tutulduğunu göstermektedir.

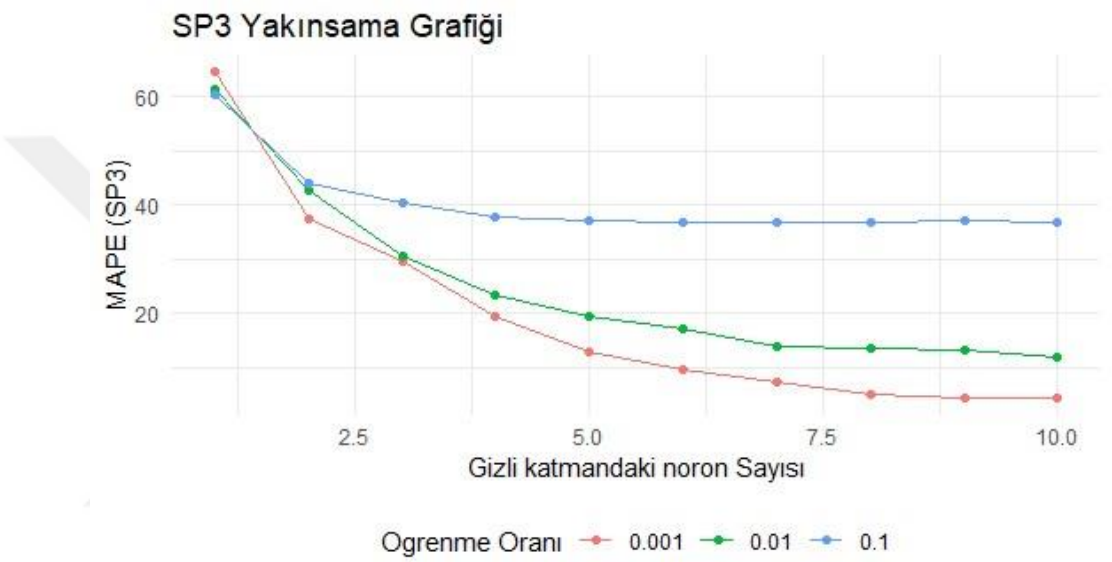
```
Forecast method: NNAR(7,1,10)[12]
Model Information:
Average of 20 networks, each of which is
a 8-10-1 network with 101 weights
options were - linear output units
```

Şekil 4.55. SP3 NNAR model çıktısı

NNAR yönteminin SP3 zaman serisi için sağladığı tahmin performansı çeşitli ölçütlere göre Çizelge 4.23.'te gösterilmektedir.

Çizelge 4.23. SP3 NNAR test verisi ile tahmin hata değerleri

	ME	**RMSE**	**MAE**	**MPE**	**MAPE**	**MASE**
NNAR (SP3)	-0,11	10,63	4,96	-2,23	4,10	0,02



Şekil 4.56. SP3 yakınsama Grafiği (MAPE)

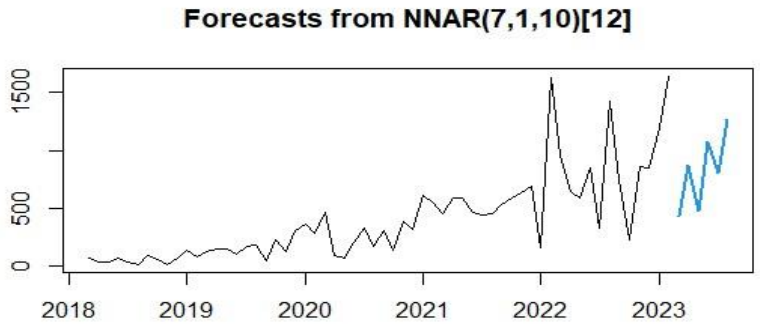
Şekil 4.56.'e göre, düşük öğrenme oranı olan 0,001, gizli katmandaki nöron sayısı arttıkça MAPE değerlerinde önemli bir azalma sergileyerek en iyi performansı göstermektedir. Özellikle 10 nöronlu gizli katmanda MAPE değeri 4,24'e kadar düşmektedir. Orta öğrenme oranı olan 0,01 de daha dengeli bir performans sergilemekte olup, nöron sayısı arttıkça MAPE değerleri düzenli bir şekilde azalmaktadır. Yüksek öğrenme oranı olan 0,1 ise diğer öğrenme oranlarına göre kötü performans sergilemiştir. En iyi performans, düşük öğrenme oranı (0,001) ve yüksek nöron sayısı (10) kombinasyonu ile elde edilmiştir. Bu bulgular, öğrenme oranının model performansı üzerindeki etkisini ve gizli katmandaki nöron sayısının önemini vurgulamaktadır.

SP3 için elde edilen en iyi NNAR modeli ile 6 aylık tahmin değerleri elde edilmiştir ve bu değerler Çizelge 4.24'te listelenmiştir.

Çizelge 4.24.SP3 (NNAR) 6 aylık tahmin değerleri

Yıl	Ay	Tahmin Değerleri
2023	Mart	504
2023	Nisan	760
2023	Mayıs	1121
2023	Haziran	1073
2023	Temmuz	743
2023	Ağustos	1274

SP3 orijinal serisi ile elde edilen en iyi NNAR modelinin tahmin sonuçları ile orijinal serinin dağılımı Şekil 4.57.'de verilmiştir.



Şekil 4.57. SP3 Orijinal seri ve NNAR tahmin serisinin dağılım grafiği

4.2.Talep Tahmini Sonuçları

Yedek parçaların üç farklı versiyonu için üç ayrı yöntem uygulanmış ve elde edilen hata değerleri Çizelge 4.25.'te sunulmuştur. Bu hata değerleri, her yöntemin ne kadar başarılı olduğunu belirlemek için kullanılmış ve Ortalama Mutlak Yüzde Hatası (MAPE) ölçütü ile hesaplanmıştır.

Çizelge 4.25. SP1-SP2-SP3 serileri için yöntemlerin karşılaştırılması (MAPE ölçütü ile)

	SP1	SP2	SP3
ARIMA	222,51	48,93	53,03
MLP	**1,29**	41,73	49,97
NNAR	129,59	**8,60**	**4,10**

Bu verilere göre:

- SP1 serisi için en düşük hata oranı MLP yöntemi ile elde edilmiştir (1,29).
- SP2 ve SP3 serileri için en düşük hata oranı NNAR yöntemi ile elde edilmiştir (SP2 için 8,60 ve SP3 için 4,10).

Çizelge 4.25.'da yer alan model performans hata ölçütleri, genellikle modeller arasında karşılaştırma yapmak için daha uygundur. Her bir tahminin spesifik olarak ne kadar doğru sonuç verdiğini göstermek için gözlemlenen değerlerle tahmin değerleri kıyaslanmalıdır. Her bir versiyona ait aylık talep değerleri ve gözlemlenen değerler karşılaştırılmış ve Çizelge 4.26.'da gösterilmiştir:

Çizelge 4.26. SP1 için tahminsel ve gerçek değerlerin karşılaştırılması (MAPE ölçütü ile)

Yıl	Ay	ARIMA Tahmini	MLP Tahmini	NNAR Tahmini	Gözlenen Değerler	ARIMA Mutlak yüzdesel sapma (%)	MLP Mutlak yüzdesel sapma (%)	NNAR Mutlak yüzdesel sapma (%)
2023	Mart	211	122	147	99	113,13	**23,23**	48,48
2023	Nisan	242	140	144	72	236,11	**94,44**	100,00
2023	Mayıs	226	288	203	356	36,52	**19,10**	42,98
2023	Haziran	221	296	244	260	15,00	13,85	**6,15**
2023	Temmuz	255	153	157	181	40,88	15,47	**13,26**
2023	Ağustos	191	407	263	349	45,27	**16,62**	24,64
Ortalama		224,33	234,33	193	219,50	81,15	**30,45**	39,25

MLP Yöntemi, aylık hata oranlarına bakıldığında, genellikle diğer yöntemlere göre daha düşük MAPE değerlerine sahiptir.Bu da MLP'nin gözlemlenen değerlere en yakın tahminleri ürettiğini gösterir. Mart ayında %23,23, Nisan ayında %94,44, Mayıs ayında %19,10 ve Ağustos ayında %16,62 hata oranlarıyla diğer yöntemlere göre daha iyi performans sergilemiştir.

*ARIMA Yöntemi,*ortalama MAPE değeri %81,15 ile MLP ve NNAR yöntemlerine göre daha yüksek hata oranlarına sahiptir. Aylık hata oranlarına bakıldığında, bazı aylarda oldukça yüksek hata oranlarına sahiptir (Mart %113,13, Nisan %236,11). Bu durum,

ARIMA yönteminin bazı dönemlerde ciddi tahmin hataları yapabileceğini göstermektedir.

NNAR Yöntemi, genel olarak MLP yöntemine kıyasla daha yüksek hata oranlarına sahiptir. Haziran ayında %6,15 ve Temmuz ayında %13,26 hata oranı MLP yönteminden daha iyi performans sergilemiştir. Ancak, ARIMA yönteminden daha iyi bir performans sergilemektedir.

SP1 serisinin tahminlerinde MLP yönteminin tercih edilmesi, özellikle gözlemlenen değerlere en yakın tahminleri üretme eğilimi gösterdiği için tahmin doğruluğunu artırabilir ve hata oranlarını minimize edebilir. Bu durum, işletmelerin daha güvenilir envanter yönetimi ve üretim planlaması yapmalarına yardımcı olabilir.

Çizelge 4.27. SP2 tahmin ve gözlemlenen değerlerin karşılaştırılması (MAPE ölçütü ile)

Yıl	Ay	ARIMA Tahmini	MLP Tahmini	NNAR Tahmini	Gözlenen Değerler	ARIMA Mutlak yüzdesel sapma (%)	MLP Mutlak yüzdesel sapma (%)	NNAR Mutlak yüzdesel sapma (%)
2023	Mart	16	16	13	12	33,33	33,33	**8,33**
2023	Nisan	16	15	11	18	**11,11**	16,67	38,89
2023	Mayıs	16	15	16	9	77,78	**66,67**	77,78
2023	Haziran	15	15	10	11	36,36	36,36	**9,09**
2023	Temmuz	16	16	18	20	20,00	20,00	**10,00**
2023	Ağustos	15	14	10	11	36,36	27,27	**9,09**
Ortalama		15,67	15,17	13,00	13,50	35,82	33,38	**25,53**

NNAR Yöntemi, ortalama MAPE değeri %25,53 ile en düşük hata oranına sahiptir. Bu yöntem, çoğu ayda en doğru tahminleri yaparak diğer modellere göre daha iyi bir performans sergilemiştir.

MLP yöntemi, %33,38 ortalama MAPE değeri ile orta seviyede bir performans göstermiştir. Ortalama bazında orta seviye performans sergilemiş olsa NNAR modeli göre aylık bazda yüksek kalmıştır.

ARIMA Yöntemi, ARIMA yöntemi %35,82 toplam MAPE değeri ile en yüksek hata oranına sahiptir. Ortalama tahmin bazında diğer yöntemlere göre kötü performanslar sergilemesiyle beraber aylık bazda da genel olarak diğer yöntemlere göre geride kalmıştır.

SP2 serisinin tahminlerinde NNAR yönteminin tercih edilmesi, aylık bazda daha doğru tahminler elde edilmesine olanak tanıyabilir, böylece işletmeler envanter yönetimi ve üretim planlaması süreçlerinde daha güvenilir kararlar alabilir.

Çizelge 4.28. SP3 tahmin ve gözlemlenen değerlerin karşılaştırılması (MAPE ölçütü ile)

Yıl	Ay	ARIMA Tahmini	MLP Tahmini	NNAR Tahmini	Gözlenen Değerleri	ARIMA Mutlak yüzdesel sapma (%)	MLP Mutlak yüzdesel sapma (%)	NNAR Mutlak yüzdesel sapma (%)
2023	Mart	1.048	1176	504	759	38,08	54,94	**33,60**
2023	Nisan	1.012	1367	760	582	73,88	134,88	**30,58**
2023	Mayıs	1026	713	1121	1044	**1,72**	31,70	7,38
2023	Haziran	1100	1095	1073	866	27,02	26,44	**23,90**
2023	Temmuz	1036	1047	743	685	51,24	52,85	**8,47**
2023	Ağustos	1246	1063	1274	1403	11,19	24,23	**9,19**
Ortalama		1.078,00	1.076,83	900,83	889,83	33,86	54,17	**18,85**

NNAR yöntemi, toplam MAPE değeri %18,85 ile en düşük hata oranına sahiptir. Bu yöntem, Mayıs ayı hariç diğer aylarda diğer yöntemlere üstün performans sergilemiştir. Mayıs ayında ARIMA göre yüksek kalsa da çok yüksek MAPE oranına sahip değildir.

MLP yöntemi, %54,17 toplam MAPE değeri ile diğer yöntemlere göre genel olarak daha yüksek hata oranlarına sahiptir.

ARIMA Yöntemi, %33,86 toplam MAPE değeri ile NNAR yönteminden sonra gelmektedir. Aylık olarak MLP yöntemine göre daha iyi ve NNAR yöntemine göre Mayıs ayı hariç daha kötü performans sergilemiştir.

SP3 serisinde NNAR yönteminin tercih edilmesi, genellikle düşük MAPE değerleriyle istikrarlı bir performans sergilemesi ve diğer yöntemlere göre daha güvenilir tahminler yapması nedeniyle tahmin doğruluğunu önemli ölçüde artırabilir.

Model performans sonuçlarıyla gözlemlenen ve tahmin edilen değerler karşılaştırıldığında elde edilen sonuç, SP1 için MLP, SP2 ve SP3 NNAR modellerinin tercih edilmesi gerektiği sonucuna varılmıştır. Her bir versiyonda hangi modelin daha iyi sonuçlar verdiği belirlenmiş ve Çizelge 4.29'de talep tahmin sonuçları ile birlikte verilmiştir:

Çizelge 4.29. En iyi tahmin yöntemlerinin verdiği talep tahmin değerleri

Aylar	**SP1 (MLP için)**	**SP2 (NNAR için)**	**SP3 (NNAR için)**
Mart-2023	122	13	504
Nisan-2023	140	11	760
Mayıs-2023	288	16	1121
Haziran-2023	296	10	1073
Temmuz-2023	153	18	743
Ağustos-2023	407	10	1274

MLP (Çok Katmanlı Algılayıcı) ve NNAR (Sinir Ağı Otoregresif) gibi yapay sinir ağı modelleri, zaman serilerindeki karmaşıklığı ve doğrusal olmayan ilişkileri daha iyi modelleyebilir. Bu modeller, ARIMA'nın başarısız olduğu durumlarda daha iyi performans gösterebilir. Özellikle zaman serilerinde doğrusallık olmayan yapılar, karmaşıklık veya belirgin trend/mevsimsellik varsa, yapay sinir ağı tabanlı modeller genellikle daha uygun seçenektir.

5. TARTIŞMA VE SONUÇ

Bu çalışma, otomotiv sektöründe yedek parça talep tahmini için farklı tahmin yöntemlerinin performansını değerlendirmeyi amaçlamıştır. Üç farklı veri seti üzerinde ARIMA, MLP ve NNAR yöntemleri uygulanmış ve tahminlerin doğruluğu MAPE değerleri aracılığıyla değerlendirilmiştir. Elde edilen sonuçlar, her bir veri setinin benzersiz özelliklere sahip olduğunu ve bu nedenle tümüne aynı tahmin modelini uygulamanın mümkün olmadığını göstermektedir.

Öncelikle, her bir veri setinin farklı yapı ve dinamiklere sahip olduğu belirlenmiştir. Bu da her veri seti için en uygun tahmin yönteminin farklılık gösterebileceğine işaret etmiştir. Örneğin, SP1 veri seti için en düşük MAPE değeri MLP modeliyle elde edilirken, SP2 ve SP3 veri setleri için en düşük MAPE değerini NNAR modeli sağlamıştır. Bu bulgular, veri setinin özelliklerinin tahmin modeli seçiminde kritik bir rol oynadığını göstermektedir. Sonuçların doğruluğu ve güvenilirliği için daha geniş bir veri seti ve farklı zaman periyotları üzerinde yapılan analizlerin gerçekleştirilmesi gerekmektedir. Özellikle, daha uzun zaman dilimlerini kapsayan veri setleri, mevsimsellik ve eğilim gibi uzun vadeli özelliklerin daha iyi anlaşılmasını sağlayabilir. Gelecekteki çalışmalarda, diğer makine öğrenme algoritmalarının ve tahmin yöntemlerinin de dikkate alınması önerilmektedir. Örneğin, XGBoost, LSTM gibi daha yeni ve güçlü algoritmaların yanı sıra hibrit modellerin kullanımı, tahmin performansını daha da artırabilir. Ayrıca, model performansını artırmak için hiperparametre optimizasyonu ve model doğrulama tekniklerinin de daha kapsamlı bir şekilde incelenmesi önemlidir.

Bu çalışma, Türkiye otomotiv sektöründe yedek parça talep tahmini konusunda kapsamlı bir analiz sunarak literatüre önemli katkılarda bulunmaktadır. Talep tahmini alanında yaygın olarak kullanılan tahmin yöntemlerinin etkinliğini gerçek veriler üzerinde değerlendirmekte ve sektöre özgü sonuçlar ortaya koymaktadır. Daha geniş kapsamlı çalışmaların yapılması, tahmin modellerinin performansının artırılması ve endüstriyel alanlardaki uygulama fırsatlarının geliştirilmesi açısından büyük önem taşımaktadır.

KAYNAKLAR

Achetoui, Z., Mabrouki, C. ve Mousrij, A. (2019). Performance measurement system for automotive spare parts supply chain: a categorization approach. *Journal of Transportation and Logistics*, *4*(1), 31-50. https://doi.org/10.26650/JTL.2018.04.01.03

Amirkolaii, K. N., Baboli, A., Shahzad, M. K. ve Tonadre, R. (2017). Demand forecasting for irregular demands in business aircraft spare parts supply chains by using artificial intelligence (AI). *IFAC-PapersOnLine*, *50*(1), 15221-15226. https://doi.org/10.1016/j.ifacol.2017.08.2371

Chandriah, K. K. ve Naraganahalli, R. V. (2021). RNN/LSTM with modified Adam optimizer in deep learning approach for automobile spare parts demand forecasting. *Multimedia Tools and Applications*, *80*(17), 26145-26159. https://doi.org/10.1007/s11042-021-10913-0

Çıkmak, S. ve Ungan, M. C. (2021). Otomotiv Sektöründeki Tedarik Zinciri Riskleriyle İlgili Bir Araştırma. *Atatürk Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, *25*(4), 1710-1737. https://doi.org/10.53487/ataunisosbil.948617

De Melo Menezes, B. A., de Siqueira Braga, D., Hellingrath, B. ve de Lima Neto, F. B. (2015, October). An evaluation of forecasting methods for anticipating spare parts demand. In *2015 Latin America Congress on Computational Intelligence (LA-CCI)* (pp. 1-6). IEEE. https://doi.org/10.1109/LA-CCI.2015.7435980

Eğrioglu, E., Aladag, C. H., Yolcu, U., Bas, E. ve Dalar, A. Z. (2017). A new neural network model with deterministic trend and seasonality components for time series forecasting. *Advances in time series forecasting*, *2*, 76-92. https://doi.org/10.2174/9781681085289117020006

Erturun, C. ve Dursun, M. (2022). Demand Forecasting for European Automotive Market. *International Journal of Transportation Systems*, *7*.

Gonçalves, J. N., Cortez, P., Carvalho, M. S. ve Frazao, N. M. (2021). A multivariate approach for multi-step demand forecasting in assembly industries: Empirical evidence from an automotive supply chain. *Decision Support Systems*, *142*, 113452. https://doi.org/10.1016/j.dss.2020.113452

Hyndman, Rob J.; Athanasopoulos, George. Forecasting: principles and practice. OTexts, 2018.

Iman, M., Arabnia, H. R. ve Branchinst, R. M. (2021). Pathways to artificial general intelligence: a brief overview of developments and ethical issues via artificial intelligence, machine learning, deep learning, and data science. *Advances in Artificial Intelligence and Applied Cognitive Computing: Proceedings from ICAI'20 and ACC'20*, 73-87. https://doi.org/10.1007/978-3-030-70296-0_6

Kadılar C. ve Öncel Çekim, H., SPSS ve R Uygulamalı Zaman Serileri Analizine Giriş, 3. Baskı, Seçkin Fen Bilimleri, Ankara, 2020

Kayalı, S. (2024). Otomotiv döküm parça talep tahmininin yapay sinir ağları ile modellenmesi ve arıma yöntemi ile karşılaştırmalı analizi (Master's thesis, Sakarya Üniversitesi).

Kaynar, O., ve Taştan, S. (2009). Zaman Serisi Analizinde MLP Yapay Sinir Ağları ve ARIMA Modelinin Karşılaştırılması. Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi, (33), 161-172.

Kim, T. Y., Dekker, R. ve Heij, C. (2017). Spare part demand forecasting for consumer goods using installed base information. *Computers ve Industrial Engineering*, *103*, 201-215. https://doi.org/10.1016/j.cie.2016.11.014

Kmiecik, M. ve Zangana, H. (2022). Supporting of manufacturing system based on demand forecasting tool. *LogForum*, *18*(1). https://doi.org/10.17270/J.LOG.2022.637

Kolková, A. ve Ključnikov, A. (2021). Demand forecasting: an alternative approach based on technical indicator Pbands. *Oeconomia Copernicana*, *12*(4), 1063-1094. https://doi.org/10.24136/oc.2021.035

Ma, Z., Wang, C. ve Zhang, Z. (2021, September). Deep Learning Algorithms for Automotive Spare Parts Demand Forecasting. In *2021 International Conference on Computer Information Science and Artificial Intelligence (CISAI)* (pp. 358-361). IEEE. https://doi.org/10.1109/CISAI54367.2021.00075

Makridakis, S. ve Hibon, M. (1997). ARMA models and the Box–Jenkins methodology. *Journal of forecasting*, *16*(3), 147-163. https://doi.org/10.1002/(SICI)1099-131X(199705)16:3<147::AID-FOR652>3.0.CO;2-X

Wheelwright, S., Makridakis, S. ve Hyndman, R. J. (1998). *Forecasting: methods and applications*. John Wiley ve Sons.

Pawar, N. ve Tiple, B. (2019, July). Analysis on machine learning algorithms and neural networks for demand forecasting of anti-aircraft missile spare parts. In *2019 International Conference on Communication and Electronics Systems (ICCES)* (pp. 854-859). IEEE. https://doi.org/10.1109/ICCES45898.2019.9002411

Pontoh, R. S., Toharudin, T., Ruchjana, B. N., Gumelar, F., Putri, F. A., Agisya, M. N. ve Caraka, R. E. (2022). Jakarta pandemic to endemic transition: forecasting COVID-19 using NNAR and LSTM. *Applied Sciences*, *12*(12), 5771. https://doi.org/10.3390/app12125771

Rožanec, J. M., Kažič, B., Škrjanc, M., Fortuna, B. ve Mladenić, D. (2021). Automotive OEM demand forecasting: A comparative study of forecasting algorithms and strategies. *Applied Sciences*, *11*(15), 6787. https://doi.org/10.3390/app11156787

Silva, E. S., Hassani, H., Heravi, S. ve Huang, X. (2019). Forecasting tourism demand with denoised neural networks. *Annals of Tourism Research*, *74*, 134-154. https://doi.org/10.1016/j.annals.2018.11.006

Stragliotto, F. (2023). Demand Forecasting using SARIMA, Prophet and NNAR.

Sahin, M., Kizilaslan, R. ve Demirel, Ö. F. (2013). Forecasting aviation spare parts demand using croston based methods and artificial neural networks. *Journal of Economic and Social Research*, *15*(2), 1.

Turrini, L. ve Meissner, J. (2019). Spare parts inventory management: New evidence from distribution fitting. *European Journal of Operational Research*, *273*(1), 118-130. https://doi.org/10.1016/j.ejor.2017.09.039

Van der Auweraer, S., Boute, R. N. ve Syntetos, A. A. (2019). Forecasting spare part demand with installed base information: A review. *International Journal of Forecasting*, *35*(1), 181-196. https://doi.org/10.1016/j.ijforecast.2018.09.002

Vargas, C. G. ve Cortés, M. E. (2017). Automobile spare-parts forecasting: A comparative study of time series methods. *International Journal of Automotive and Mechanical Engineering*, *14*(1), 3898-3912. https://doi.org/10.15282/ijame.14.1.2017.7.0317

Zeiler, M. D. (2012). Adadelta: an adaptive learning rate method. *arXiv preprint arXiv*:1212.5701.

Zhang, G. P. (2003). Time series forecasting using a hybrid ARIMA and neural network model. *Neurocomputing*, *50*, 159-175. https://doi.org/10.1016/S0925-2312(01)00702-0

EKLER

EK 1 TAHMİN YÖNTEMİNDE KULLANILAN GEÇMİŞ TALEP DEĞERLERİ
EK 2 SP1 İÇİN ARIMA İLE TALEP TAHMİNİ R KODLARI
EK 3 SP2 İÇİN ARIMA İLE TALEP TAHMİNİ R KODLARI
EK 4 SP3 İÇİN ARIMA İLE TALEP TAHMİNİ R KODLARI
EK 5 SP1 İÇİN MLP İLE TALEP TAHMİNİ R KODLARI
EK 6 SP2 İÇİN MLP İLE TALEP TAHMİNİ R KODLARI
EK 7 SP3 İÇİN MLP İLE TALEP TAHMİNİ R KODLARI
EK 8 SP1 İÇİN NNAR İLE TALEP TAHMİNİ R KODLARI
EK 9 SP2 İÇİN NNAR İLE TALEP TAHMİNİ R KODLARI
EK 10 SP3 İÇİN NNAR İLE TALEP TAHMİNİ R KODLARI

EK 1. TAHMİN YÖNTEMİNDE KULLANILAN GEÇMİŞ TALEP DEĞERLERİ

Yıl	Ay	Yedek Parça versiyon-1	Yedek Parça versiyon-2	Yedek Parça versiyon-3
2018	3	252	9	72
2018	4	306	8	36
2018	5	360	3	36
2018	6	63	13	72
2018	7	27	10	36
2018	8	873	13	18
2018	9	297	15	90
2018	10	450	13	63
2018	11	162	3	18
2018	12	882	14	72
2019	1	288	3	135
2019	2	873	14	81
2019	3	414	10	126
2019	4	206	8	153
2019	5	315	7	156
2019	6	126	13	108
2019	7	225	9	171
2019	8	280	10	180
2019	9	182	9	54
2019	10	45	4	234
2019	11	171	7	126
2019	12	261	10	306
2020	1	207	14	360
2020	2	369	9	289
2020	3	819	7	468
2020	4	180	9	99
2020	5	36	2	72
2020	6	171	5	207
2020	7	315	7	333
2020	8	306	8	171
2020	9	171	12	306
2020	10	18	5	135
2020	11	1089	10	387
2020	12	27	8	315
2021	1	339	15	612
2021	2	207	7	540
2021	3	207	10	450
2021	4	126	6	590

EK 1. TAHMİN YÖNTEMİNDE KULLANILAN GEÇMİŞ TALEP DEĞERLERİ(DEVAM)

Yıl	Ay	Yedek Parça versiyon-1	Yedek Parça versiyon-2	Yedek Parça versiyon-3
2021	5	36	8	588
2021	6	172	12	461
2021	7	45	3	441
2021	8	27	5	459
2021	9	63	7	531
2021	10	270	7	593
2021	11	117	6	632
2021	12	360	3	692
2022	1	477	15	158
2022	2	36	16	1629
2022	3	108	23	965
2022	4	342	23	648
2022	5	232	19	587
2022	6	216	15	846
2022	7	405	18	335
2022	8	5	15	1424
2022	9	106	17	748
2022	10	231	12	229
2022	11	89	9	860
2022	12	211	13	853
2023	1	471	20	1197
2023	2	150	13	1636

EK 2. SP1 İÇİN ARIMA İLE TALEP TAHMİNİ R KODLARI

```
#excelden veri yükleme
class(sp1)
#paket yükleme
library(tseries)
library(tidyverse)
library(forecast)
sp1ts <- ts(sp1,start = c(2018,3),frequency = 12)
autoplot(sp1ts)+ggtitle("sp1time")+ylab("sp1")
acf(sp1ts)
pacf(sp1ts)
adf.test(sp1ts)
diffsp1 <- diff(sp1ts)
acf(diffsp1)
pacf(diffsp1)
adf.test(diffsp1)
install.packages("seastests")
library(seastests)
mevsimtestsp1 <- welch(sp1ts,freq = 12)
mevsimtestsp1
sp1model=auto.arima(sp1ts,ic="aic",trace = TRUE)
sp1model1= arima(sp1ts,order = c(2,1,1),seasonal = c(1,0,0), include.mean =
TRUE)
sp1model1
sp1model2= arima(sp1ts,order = c(2,1,1),seasonal = c(0,0,1), include.mean =
TRUE)
sp1model2
```

EK 2. SP1 İÇİN ARIMA İLE TALEP TAHMİNİ R KODLARI (DEVAM)

```
sp1model3= arima(sp1ts,order = c(1,1,1),seasonal = c(1,0,0), include.mean = TRUE)
sp1model3
sp1model4= arima(sp1ts,order = c(1,1,1),seasonal = c(0,0,1), include.mean = TRUE)
sp1model4
sp1model5= arima(sp1ts,order = c(0,1,1),seasonal = c(1,0,0), include.mean = TRUE)
sp1model5
sp1model6= arima(sp1ts,order = c(0,1,1),seasonal = c(0,0,1), include.mean = TRUE)
sp1model6
library(IMTest)
install.packages("sandwich")
library(sandwich)
library(foreign)
print(summary(sp1model1))
print(summary(sp1model2))
print(summary(sp1model3))
print(summary(sp1model4))
print(summary(sp1model5))
print(summary(sp1model6))
checkresiduals(sp1model4$residuals)
sp1tahmin <- forecast(sp1model4,h=6)
sp1tahmin
sp1tahmin[["mean"]]
autoplot(sp1tahmin)
checkresiduals(sp1tahmin$residuals)
```

EK 3. SP2 İÇİN ARIMA İLE TALEP TAHMİNİ R KODLARI

```
class(sp2)
#paket yükleme
library(tseries)
library(tidyverse)
library(forecast)
sp2ts <- ts(sp2,start = c(2018,3),frequency = 12)
autoplot(sp2ts)+ggtitle("sp2time")+ylab("sp2")
acf(sp2ts)
pacf(sp2ts)
adf.test(sp2ts)
diffsp2 <- diff(sp2ts)
acf(diffsp2)
pacf(diffsp2)
adf.test(diffsp2)
install.packages("seastests")
library(seastests)
mevsimtestsp2 <- welch(sp2ts,freq = 12)
mevsimtestsp2
sp2model=auto.arima(sp2ts,ic="aic",trace = TRUE)
checkresiduals(sp2model$residuals)
sp2model1= arima(sp2ts,order = c(1,1,0),seasonal = c(1,0,0), include.mean = TRUE)
sp2model1
sp2model2= arima(sp2ts,order = c(0,1,1),seasonal = c(0,0,1), include.mean = TRUE)
sp2model2
```

EK 3. SP2 İÇİN ARIMA İLE TALEP TAHMİNİ R KODLARI (DEVAM)

```
sp2model3= arima(sp2ts,order = c(0,1,1),seasonal = c(1,0,0), include.mean = TRUE)
sp2model3
sp2model4= arima(sp2ts,order = c(0,1,1),seasonal = c(1,0,1), include.mean = TRUE)
sp2model4
sp2model5= arima(sp2ts,order = c(1,1,1),seasonal = c(0,0,1), include.mean = TRUE)
sp2model5
sp2model6= arima(sp2ts,order = c(1,1,1),seasonal = c(1,0,1), include.mean = TRUE)
sp2model6
library(IMTest)
install.packages("sandwich")
library(sandwich)
library(foreign)
print(summary(sp2model1))
print(summary(sp2model2))
print(summary(sp2model3))
print(summary(sp2model4))
print(summary(sp2model5))
print(summary(sp2model6))
checkresiduals(sp2model5$residuals)
sp2tahmin <- forecast(sp2model5,h=6)
sp2tahmin
sp2tahmin[["mean"]]
autoplot(sp2tahmin)
checkresiduals(sp2tahmin$residuals)
```

EK 4. SP3 İÇİN ARIMA İLE TALEP TAHMİNİ R KODLARI

```
#excelden veri yükleme
class(sp3)
#paket yükleme
library(tseries)
library(tidyverse)
library(forecast)
sp3ts <- ts(sp3,start = c(2018,3),frequency = 12)
autoplot(sp3ts)+ggtitle("sp3time")+ylab("sp3")
acf(sp3ts)
pacf(sp3ts)
adf.test(sp3ts)
diffsp3 <- diff(sp3ts)
acf(diffsp3)
pacf(diffsp3)
adf.test(diffsp3)
install.packages("seastests")
library(seastests)
mevsimtestsp3 <- welch(sp3ts,freq = 12)
mevsimtestsp3
sp3model=auto.arima(sp3ts,ic="aic",trace = TRUE)
checkresiduals(sp3model$residuals)
sp3model1= arima(sp3ts,order = c(1,1,0),seasonal = c(1,0,0), include.mean = TRUE)
sp3model1
sp3model2= arima(sp3ts,order = c(1,1,2),seasonal = c(1,0,0), include.mean = TRUE)
sp3model2
```

EK 4. SP3 İÇİN ARIMA İLE TALEP TAHMİNİ R KODLARI (DEVAM)

```
sp3model3= arima(sp3ts,order = c(1,1,2),seasonal = c(0,0,1), include.mean = TRUE)
sp3model3
sp3model4= arima(sp3ts,order = c(1,1,1),seasonal = c(0,0,1), include.mean = TRUE)
sp3model4
sp3model5= arima(sp3ts,order = c(1,1,1),seasonal = c(1,0,0), include.mean = TRUE)
sp3model5
sp3model6= arima(sp3ts,order = c(1,1,0),seasonal = c(0,0,1), include.mean = TRUE)
sp3model6
library(IMTest)
install.packages("sandwich")
library(sandwich)
library(foreign)
print(summary(sp3model1))
print(summary(sp3model2))
print(summary(sp3model3))
print(summary(sp3model4))
print(summary(sp3model5))
print(summary(sp3model6))
checkresiduals(sp3model3$residuals)
checkresiduals(sp3model2$residuals)
sp3tahmin <- forecast(sp3model3,h=6)
sp3tahmin
sp3tahmin[["mean"]]
autoplot(sp3tahmin)
checkresiduals(sp3tahmin$residuals)
```

EK 5. SP1 İÇİN MLP İLE TALEP TAHMİNİ R KODLARI

```
#excelden veri yükleme
class(sp1)
#paket yükleme
library(tseries)
library(tidyverse)
library(forecast)
install.packages(nnfor)
library(nnfor)
sp1ts <- ts(sp1,start = c(2018,3),frequency = 12)
mlpsp1.train<- window(sp1ts,end=c(2022,8))
mlpsp1.test<-window(sp1ts,start= c(2022,9))
fit<- mlp(mlpsp1.train,hd=c(9,2))
print(fit)
Tahmin <- forecast(fit,start=c(2023,3))
print(Tahmin)
accuracy(Tahmin,mlpsp1.test)[1,1:5]
summary(fit)
plot(fit)
```

EK 6. SP2 İÇİN MLP İLE TALEP TAHMİNİ R KODLARI

```
#excelden veri yükleme
class(sp2)
#paket yükleme
library(tseries)
library(tidyverse)
library(forecast)
install.packages(nnfor)
library(nnfor)
sp2ts <- ts(sp2,start = c(2018,3),frequency = 12)
mlpsp2.train<- window(sp2ts,end=c(2022,8))
mlpsp2.test<-window(sp2ts,start= c(2022,9))
#iterasyon deneme sonuca göre
fit<- mlp(mlpsp2.train,hd.auto.type = "valid",hd=c(9,5))
print(fit)
Tahmin <- forecast(fit,start=c(2023,3))
print(Tahmin)
accuracy(Tahmin,mlpsp2.test)[1,1:5]
summary(Tahmin)
plot(Tahmin)
```

EK 7. SP3 İÇİN MLP İLE TALEP TAHMİNİ R KODLARI

```
#excelden veri yükleme
class(sp1)
#paket yükleme
library(tseries)
library(tidyverse)
library(forecast)
install.packages(nnfor)
library(nnfor)
sp1ts <- ts(sp1,start = c(2018,3),frequency = 12)
mlpsp1.train<- window(sp1ts,end=c(2022,8))
mlpsp1.test<-window(sp1ts,start= c(2022,9))
fit<- mlp(mlpsp1.train,hd=c(10,7))
print(fit)
Tahmin <- forecast(fit,start=c(2023,3))
print(Tahmin)
accuracy(Tahmin,mlpsp1.test)[1,1:5]
summary(fit)
plot(fit)
```

EK 8. SP1 İÇİN NNAR İLE TALEP TAHMİNİ R KODLARI

```
#excelden veri yükleme
class(sp1)
#paket yükleme
library(tseries)
library(tidyverse)
library(forecast)
install.packages(nnet)
library(nnet)
sp3ts <- ts(sp1,start = c(2018,3),frequency = 12)
modeller<- list()
for (size in 1:10) {
   fit<- nnetar(sp1ts,size = size,decay = c(0.1,0.01,0.001)
 modeladi<-paste("size",size,"decay",decay,sep = "-")
 modeller[[modeladi]]<- fit
}
print(modeller)
fit<- nnetar(sp1ts,size=9,decay = 0.001)
accuracy(fit)
print(fit)
sp1nnetartahmin<-forecast(fit,h=6)
print(sp1nnetartahmin)
summary(sp1nnetartahmin)
plot(sp1nnetartahmin)
```

EK 9. SP2 İÇİN NNAR İLE TALEP TAHMİNİ R KODLARI

```
#excelden veri yükleme
class(sp2)
#paket yükleme
library(tseries)
library(tidyverse)
library(forecast)
install.packages(nnet)
library(nnet)
sp2ts <- ts(sp2,start = c(2018,3),frequency = 12)
modeller<- list()
for (size in 1:10) {
   fit<- nnetar(sp2ts,size = size,decay = c(0.1,0.01,0.001)
 modeladi<-paste("size",size,"decay",decay,sep = "-")
 modeller[[modeladi]]<- fit
}
print(modeller)
fit<- nnetar(sp2ts,size=10,decay = 0.001)
accuracy(fit)
print(fit)
sp2nnetartahmin<-forecast(fit,h=6)
print(sp2nnetartahmin)
summary(sp2nnetartahmin)
plot(sp2nnetartahmin)
```

EK 10. SP3 İÇİN NNAR İLE TALEP TAHMİNİ R KODLARI

```
#excelden veri yükleme
class(sp3)
#paket yükleme
library(tseries)
library(tidyverse)
library(forecast)
install.packages(nnet)
library(nnet)
sp3ts <- ts(sp3,start = c(2018,3),frequency = 12)
modeller<- list()
for (size in 1:10) {
   fit<- nnetar(sp3ts,size = size, decay = c(0.1,0.01,0.001)
 modeladi<-paste("size",size,"decay",decay,sep = "-")
 modeller[[modeladi]]<- fit5
}
print(modeller)
fit<- nnetar(sp3ts,size=10,decay = 0.001)
accuracy(fit)
print(fit)
sp3nnetartahmin<-forecast(fit,h=6)
print(sp3nnetartahmin)
summary(sp3nnetartahmin)
plot(sp3nnetartahmin)
```