

Bir Tarım Makineleri Üreticisi için SARIMA Modeli ile Tahminleme

Şule ERYÜRÜK^{1*}

¹KTO Karatay Üniversitesi Mühendislik ve Doğa Bilimleri Fakültesi Endüstri Mühendisliği Bölümü, Konya

¹<https://orcid.org/0000-0003-2746-1598>

*Sorumlu yazar: sule.eryuruk@karatay.edu.tr

Araştırma Makalesi

Makale Tarihçesi:

Geliş tarihi: 13.09.2024

Kabul tarihi: 15.03.2025

Online Yayınlanma: 16.06.2025

Anahtar Kelimeler:

Tarım makineleri

SARIMA

Zaman serileri analizi

Box-Jenkins modeli

ÖZ

Tarım makineleri üretiminde karşılaşılan en önemli riskler günümüzde iklim değişikliğinden kaynaklı talep zamanlarında ve miktarlarında kayma ve rekabet unsurları olarak değerlendirilebilir. Bu nedenle tarım makineleri üretiminde istatistiksel talep tahmini yapmak elzem bir konu olmuştur. Bu çalışmanın amacı, tarım makineleri sektöründe bir imalatçıdan elde edilen 2011-2021 yılları arasındaki aylık üretim verilerinden yararlanarak gelecek 12 aylık dönemde üreticinin ürettiği en önemli iki ürününe ait üretim miktarlarını tahmin etmek ve gelecek üretim adetlerine dair öneriler geliştirmektir. Tarım makineleri üretimi adedi için gelecek tahmininde bulunurken mevsimselliği yansıtmak adına SARIMA diğer adıyla Box-Jenkins modeli kullanılmıştır. Zaman serilerini analiz etmek için geliştirilen yöntemlerden biri olan SARIMA yöntemi, tek değişkenli zaman serilerini analiz etmek için kullanılan güçlü metotlardandır. Araştırmada, belirlenen iki ürün için SARIMA modelleri arasında en iyi istatistiksel sonuçlar belirtilmiştir. Ürün 1 için SARIMA(1,1,2)(0,1,1) modeli, ürün 2 için ise SARIMA(0,1,1)(1,1,0) modeli en uygun model olarak bulunmuştur. Seçilen iki ürün için belirlenen uygun SARIMA modeline bakarak, üretici için 2022 yılı 12 aylık üretim tahmini ve beklentisi hesaplanmıştır.

Forecasting with SARIMA Model for an Agricultural Machinery Manufacturer

Research Article

Article History:

Received: 13.09.2024

Accepted: 15.03.2025

Published online: 16.06.2025

Keywords:

Agricultural machinery

SARIMA

Time series analysis

Box-Jenkins model

ABSTRACT

The most significant risks encountered in agricultural machinery production today can be considered as shifts in demand times and quantities due to climate change, as well as competitive factors. Therefore, statistical demand forecasting has become an essential issue in the production of agricultural machinery. The aim of this study is to forecast the production quantities of the two most important product produced by a manufacturer in the agricultural machinery sector for the next 12 months using monthly production data from 2011-2021 and to develop recommendations. To reflect seasonality in future forecasts for agricultural machinery production, the SARIMA (Box-Jenkins) model has been employed. The Box-Jenkins method is one of the techniques developed for analyzing time series and is used to analyze univariate time series. In the research, the best statistical results among the SARIMA models for the specified product are indicated. For Product 1, the SARIMA(1,1,2)(0,1,1) model has been identified as the most suitable model, while for Product 2, the SARIMA(0,1,1)(1,1,0) model has been determined to be the best fit. By examining the appropriate SARIMA model determined for the selected two product, the 12-month production forecast and expectations for 2022 have been calculated for the manufacturer.

To Cite: Eryürük Ş. Bir Tarım Makineleri Üreticisi için SARIMA Modeli ile Tahminleme. Osmaniye Korkut Ata Üniversitesi Fen Bilimleri Enstitüsü Dergisi 2025; 8(3): 1146-1168.

1. Giriş

Tarım makinelerinin üretimi, sürdürülebilir tarım uygulamalarını devam ettirmek için hayati öneme sahiptir. Ülkemizde bu üretim, traktörler ve diğer ekipmanlar olarak kategorize edilebilir (TARMAKBİR, 2023). Traktörlerin yanı sıra, diğer tarım makineleri sulama sistemleri, püskürtücüler ve dağıtıcılar, ilaçlama ekipmanları, yükleyiciler, toprak işleme ve gübreleme aletleri, hasat ve harman makineleri ve tarımsal römorkları içerir. Küresel düzeyde, 2016 itibarıyla Türkiye, traktör ihracatında %2 payla 12. sırada ve ekipman ihracatında %0,8 payla 24. sırada yer almaktadır. Küresel ithalata gelince, dünya 2016 yılında 15,5 milyar dolar değerinde traktör ve 26,2 milyar dolar değerinde ekipman ithal etmiştir. Türkiye, %3 pay ile traktör ithalatında 10. sırada ve %1 pay ile ekipman ithalatında 31. sırada yer almaktadır. 2017 yılında Türkiye, 76.324 traktör ve 752.125 parça ekipman üretmiştir. 2016 yılında Türkiye'nin tarım makineleri ihracatına kategori bazında bakıldığında, traktörler %55 ile ilk sırada, toprak işleme, ekim, gübreleme ve bitki bakım ekipmanları %13 ile ikinci sırada ve diğer tarım makineleri (tohum ilaçlama, çit budama, yem hazırlama, ormancılık, kümes ve arıcılık makineleri) %12 ile üçüncü sırada yer almaktadır. İthalatta ise, traktörler %56,5 ile ilk sırada, hasat, harman, biçme, balya ve sınıflandırma ekipmanları %25,6 ile ikinci sırada ve sulama-ilaçlama parçaları-ekipmanları %4,2 ile üçüncü sırada yer almaktadır. (Tarımsal Mekanizasyon Sektör Politika Belgesi, 2018-2022).

Tarım makineleri üretimi ile ilgili tahminleme çalışmaları literatürde oldukça kısıtlıdır, buna nazaran başka alanlarda tahminleme yapmak üzere, bu çalışmada metod olarak kullanılan Mevsimsel Oto Regresyonlu Bütünleştirici Hareketli Ortalama Modelleri (SARIMA) modeli kullanımı oldukça yaygındır. Literatür taraması bölümünde, SARIMA kullanımı ile ilgili yapılan çeşitli akademik araştırmalara odaklanılmıştır. Farklı veri kaynakları kullanılarak elde edilen bulgular, yapılan değerlendirmeler ve tahminlerin önemini vurgulanmaktadır. Vagropoulos ve ark.,(2016) şebekeye bağlı Fotovoltaik (PV) santrallerin elektrik üretimi tahmini için SARIMA modellemesi, SARIMAX modellemesi (dışsal faktörlü SARIMA modellemesi), SARIMA modelinin modifiye edilmiş modellemesi ve ANN tabanlı modellemesini kullanarak bazı simülasyon sonuçları elde etmiştir. Dubey ve ark., (2021) makalelerinde, toplanan akıllı sayaç ölçümü ve ardından (Otoregresif entegre hareketli ortalama) ARIMA, SARIMA ve uzun kısa vadeli bellek (LSTM) kullanılarak günlük bazda enerji tüketiminin tahmini üzerinde veri analitiği sunmuştur. Valipour (2015) çalışmasında, ABD'de uzun vadeli akış tahmini için SARIMA ve ARIMA modellerinin yeteneği araştırmıştır. Divisekara ve ark., (2021) çalışmasında, SARIMA kullanarak kırmızı mercimek fiyatlarını modellemiş ve tahminleme yapmıştır. Bu çalışmada, Saskatchewan.ca'dan elde edilen 2010'dan 2019'a kadar olan sekiz yıllık haftalık veriler ve 521 gözlem kullanılmıştır. Dabral ve Murry (2017) aylık, haftalık ve günlük muson yağış zaman serileri için SARIMA modeli geliştirmiştir. Bu çalışmada geliştirilen SARIMA modelleri kullanılarak 2014-2027 yılları arasındaki 14 yıllık dönem için aylık, haftalık, günlük muson zaman serilerinin tahmini yapılmıştır. Choi ve ark., (2011), makalelerinde, klasik SARIMA yöntemini ve dalgacık dönüşümünü (SW) birleştiren bir hibrit tahmin şeması önermişlerdir. Verilen satış zaman serisinin özelliklerine dayalı olarak satış tahmini yapmak için bir yöntem geliştirmişlerdir.

Chikkakrishna ve ark., (2019) çalışmalarında, R yazılımında SARIMA ve Facebook PROPHET paketi kullanarak kısa vadeli trafik tahmini yapmaktadır. Milenković ve ark., (2018) makalelerinde, Sırp demiryolları ağında gerçekleştirilen aylık yolcu sayımlarından oluşan tarihsel verilere dayanarak Ocak 2004- Haziran 2014 dönemlerini kapsayan zaman serisini tahmin etmek için SARIMA yöntemini uygulamıştır. He ve ark., (2021) makalelerinde, günlük frekansta turist talebi verilerini tahmin etmek için bir SARIMA–CNN–LSTM modelini tanıtmış ve bu model geleneksel çerçevede modellemesi zor olan doğrusal ve doğrusal olmayan veri özelliklerinin karışımını göstermiştir. Oliveira (2016)'nın çalışmasının amacı, 2016-2018 yılları arasında Brezilya pazarındaki tarım traktörlerine olan talebi tahmin etmek olmuştur. Bunun için zaman serisi ekonometrisi teknikleri, ARIMA ve SARIMA ve SARIMAX kullanmıştır. Akusta (2024), çalışmasında, Türkiye'deki aylık gayrimenkul satışlarını analiz etmek ve gelecekteki satışları tahmin etmek amacıyla SARIMA modelini kullanmaktadır. Bu çalışmada Türkiye İstatistik Kurumu (TÜİK) tarafından sağlanan 01/2013-03/2023 tarihleri arasındaki aylık konut satış verilerini kullanmıştır. Loganathan ve Ibrahim (2010) çalışmalarında Box Jenkins SARIMA modelini kullanarak Malezya'ya gelen uluslararası turist sayısını tahmin etmiştir. Komori-Zevallos ve ark., (2023) makalelerinde, bir üretim KOBİ'sinde SARIMAX ve DSS kullanarak yalın 4.0 uygulamalarının talep tahmininin bütünleşik bir modelinin geliştirilmesini amaçlamıştır. Envanter, atık, eski ürünler ve üretkenlik gibi etkilenecek değişkenlerin belirlenmesine olanak sağlayarak modeli doğrulamak için gıda üretim sektöründe bir vaka çalışması yapmıştır. Sharma ve ark., (2023) makalelerinde, zaman serisi modellerini kullanarak orta vadeli güç yükünü tahmin etmeyi ve tarımda güç tahmini için önemli özellikleri tanımlamayı amaçlamıştır. SARIMA, yıl içindeki en yoğun sezonu bulmak için kullanılmıştır. Önen (2023) çalışmasında 2010-2022 yıllarına ait olan ticari gelen-giden toplam uçak hareket sayısı, Devlet Hava Meydanları İşletmesinden (DHMİ) gelen- giden toplam yolcu sayısı, Birleşik Devletler Enerji Bilgi İşletmesinden Ham Petrol Alış Fiyatı ve TUIK'ten Gayri Safi Milli Hasıla (GHSY) değerlerini kullanarak Box-Jenkins metoduna dayalı SARIMA modellemesi ve daha sonra modele dışsal değişkenleri ilave edilerek ARIMAX modeliyle toplam yolcu sayısı tahminlemesi yapmıştır. Ashutosh ve ark., (2021), toplanan akıllı sayaç ölçümleri üzerinde veri analitiği gerçekleştirmiş ve ardından günlük enerji tüketimini tahmin etmek için ARIMA, SARIMA ve uzun kısa süreli bellek (LSTM) yöntemlerini kullanmışlardır. Liu ve ark., (2022) çalışmalarında, transformatör yağındaki çözünmüş gaz konsantrasyonunu tahmin etmek için SARIMA, ARIMA ve LSTM modellerini incelemiş ve SARIMA modelinin diğer yöntemlere göre daha doğru ve kararlı sonuçlar verdiğini ortaya koymuştur. Megha ve ark., (2023) çalışmalarında, zaman serisi modelleri kullanarak orta vadeli yük tahmini yapmayı ve tarımda güç tahmini için önemli özellikleri belirlemeyi amaçlamaktadır. Zaman serisi modeli, yıl içerisindeki zirve sezonu belirlemek için kullanılırken, XGBoost tekniği yük tahmini yapmak için kullanılmıştır. Peng ve ark., (2018) çalışmalarında, SARIMA tekniklerini kullanarak 1951'den 2017'ye kadar Çin'in Nanjing kentindeki aylık ortalama sıcaklığı analiz etmiştir. 1951'den 2014'e kadar olan veriler eğitim seti olarak kullanılırken, 2015'ten 2017'ye kadar olan veriler test seti olarak kullanılmıştır. Model seçimi ve tahmin doğruluğunun ayrıntılı bir açıklaması sunulmuştur.

Sonuçlar, önerilen araştırma yaklaşımının iyi tahmin doğruluğu elde ettiğini göstermektedir. Çevik ve Yürekli (2003) aylık akım serisinin modellenmesinde 361 adet ARIMA(p,d,q)(P,D,Q) modeli kullanmıştır. Uygun modelin seçiminde, ARIMA(p,d,q) (P,D,Q) modellerinden hesaplanan kalıntıların bağımsız olup olmadıkları göz önüne alınmıştır. Bu amaçla her model için Ljung-Box istatistikleri ve bunların dağılımı için olasılık değerleri saptanmıştır. Aylık akım serisi için, olasılık değeri %5'ten daha büyük olan modeller uygun kabul edilmiştir.

Literatür taraması sırasında, tarım işletmeciliğini ve çeşitli alanlarını ele alan birkaç bilimsel makale bulunmuş olup, ancak Türkiye’de yayınlanan ve Türkiye'deki tarım makinelerinin talep tahminini ele alan bilimsel makale bulunamamıştır. Tarım makineleri sektöründe SARIMA metodu ile zaman serileri tahminlemesi yapan çalışma olmadığından bu çalışma bu boşluğu dolduracaktır. Literatürde SARIMA modeli kullanılarak tahminleme yapan daha birçok makale bulunmaktadır. Buna karşın tarım makineleri sektöründe üretim verilerinin tahminlenmesi için SARIMA modeli kullanan bir makale görülmemiştir. Makalenin ilerleyen bölümlerinde öncelikle çalışmada kullanılan materyallerin özellikleri ve araştırma sürecinde uygulanan metotlar ayrıntılı bir şekilde açıklanacaktır. Bu açıklamaların ardından, araştırma sonucunda elde edilen bulgular sistematik bir şekilde sunulurken, verilerin analizine dayalı temel çıkarımlar ortaya konulacaktır. Bulguların aktarılmasından sonra, çalışmanın tartışma bölümünde elde edilen sonuçlar literatürdeki benzer çalışmalarla karşılaştırılacak ve bulguların anlamı üzerine detaylı bir değerlendirme yapılacaktır. Tartışma sürecinin ardından, çalışmanın temel çıktıları özetlenerek, araştırmanın amaçları doğrultusunda ulaşılan sonuçlar kapsamlı bir şekilde değerlendirilecektir. Son olarak, araştırmanın genel çerçevesi gözden geçirilerek, elde edilen sonuçların alana katkıları, olası sınırlılıkları ve gelecekte yapılabilecek çalışmalar için öneriler sunulacaktır.

.

2. Materyal ve Metot

ARIMA

Bu çalışmada gelecek 12 ay için talep tahmini yapılacağından genellikle daha uzun dönemli tahminler için uygun olan yöntemlerden ARIMA yönteminin kullanılmasının nedenleri üzerinde durulmuştur. ARIMA, zaman serisi verilerindeki eğilimleri ve desenleri tahmin etmek için kullanılan güçlü bir istatistiksel modelleme tekniğidir. ARIMA modeli, zaman üzerinde eşit aralıklı ve tek değişkenli zaman serisi verilerini analiz eder ve tahmin eder. Verilerin yalnızca mevcut ve geçmiş gözlemlerini kullanır, dolayısıyla ekonometrik veya regresyon modelleri gibi diğer tahmin modellerinde olduğu gibi dışsal değişkenlere ihtiyaç duymaz.

Adından da anlaşılacağı gibi ARIMA modeli, otoregresif (AR) model ile hareketli ortalama (MA) modelinin bütünleşmiş bir kombinasyon modelidir. Entegrasyon, durağan olmayan verileri fark alarak veya loglayarak durağan hale getirmesi anlamına gelir. Matematiksel model aşağıdaki açıklandığı gibi temsil edilmektedir (Wei, 1989).

Y_t durağan zaman serisi verileri ise, yani bunların ortalaması ve varyansı tüm t için sabittir ve iki gözlemin otokorelasyonu yalnızca zaman gecikmesine bağlıdır.

AR modeli şu şekilde tanımlanır (1) :

$$Y_t = \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + a_t \quad (1)$$

Burada

ϕ_i = AR modelinin parametreleri ($i=1,2,\dots,p$)

a_t = ilişkisiz, sıfır ortalamalı ve sabit varyansa sahip bir hata terimi olarak tanımlanmıştır.

MA modeli şu şekilde tanımlanır (2):

$$Y_t = a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q} \quad (2)$$

θ_i = MA modelinin parametreleri ($i=1,2,\dots,q$)

ARMA modeli bu iki modelin kombinasyonu şeklindedir (3). Genel gösterimi şu şekildedir;

$$Y_t = \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q} \quad (3)$$

Y_t 'nin durağan olmaması durumunda, uygun derecede ardışık fark alma veya loglama kullanılarak durağan hale getirilebilir (4). $\nabla^d Y_t$ derecesi d farkıyla durağan bir veri serisi ise, bir ARIMA modeli

$$\nabla^d Y_t = \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q} \quad (4)$$

olarak temsil edilir.

SARIMA

Denklem (4)'te verilen ARIMA modeli durağan olmayan ve mevsimsel olmayan zaman serisi verileri için olduğundan, Box ve Jenkins mevsimselliği ele almak için ARIMA modeline SARIMA modu adı verilen bir genelleme önerilmiştir. ARIMA (p, d, q)_t olarak tanımlanırken SARIMA (p, d, q)(P, D, Q)_t olarak gösterilmektedir.

p burada mevsimsel olmayan AR teriminin derecesi, yani geçmiş değerlerin sayısını, d, mevsimsel olmayan fark alma işleminin derecesini, yani seriyi sabit hale getirmek için gereken fark alma sayısını ve q ise mevsimsel olmayan MA teriminin derecesi, yani hata terimlerinin sayısını temsil etmektedir. (P, D, Q) ise burada mevsimsel AR teriminin derecesi, yani geçmiş değerlerin sayısını, D, mevsimsel fark alma işleminin derecesini, yani seriyi sabit hale getirmek için gereken fark alma sayısını ve Q ise mevsimsel MA teriminin derecesi, yani hata terimlerinin sayısını temsil etmektedir.

$$\Phi_p(B^m)\varphi(B)\nabla_s^D\nabla^d x_t = \theta_Q(B^m)\theta(B)w_t \quad (5)$$

Denklem (5)'te;

x_t : Durağan olmayan zaman serisi

w : Gauss beyaz gürültü

$\Phi_p(B^m)$: Mevsimsel bileşenin otoregresif bileşen

$\theta_Q(B^m)$: Trend bileşeninin farklılaşan bileşenlerini gösterir.

B : Geri kaydırma operatörü

$\varphi(B)$: Trend bileşenin polinomlarla temsili

$\theta(B)$: Hareketli ortalamanın polinomlarla temsildir.

SARIMA modelinin analizinde, model artıklarının bağımsız olup olmadığını anlamak ve modelin varsayımlara uygunluğunu değerlendirmek için çeşitli yöntemler kullanılmaktadır. Bu bağlamda, Ljung-Box ki-kare istatistikleri, artıkların otokorelasyon fonksiyonu (ACF) ve artıkların kısmi otokorelasyon fonksiyonu (PACF) temel analiz araçlarıdır. Bu analizlerin sonuçları, modelin doğruluğunu ve güvenilirliğini değerlendirme açısından kritik öneme sahiptir.

Bir ARIMA analizini yorumlamak için aşağıdaki adımları tamamlamak gereklidir.

- Adım 1: Modeldeki her terimin anlamlı olup olmadığı belirlenmeli.
- Adım 2: Modelin verilere ne kadar iyi uyduğu belirlenmeli.
- Adım 3: Modelinizin analizin varsayımlarını karşılayıp karşılamadığı belirlenmeli.

Adım 1: Modeldeki her terimin anlamlı olup olmadığı belirlenmeli

Yanıt ile modeldeki her terim arasındaki ilişkinin istatistiksel olarak anlamlı olup olmadığını belirlemek için, sıfır hipotezini değerlendirmek üzere her terim için p değeri önem seviyesiyle karşılaştırılmalıdır. Sıfır hipotezi, terimin 0'dan anlamlı bir şekilde farklı olmadığını; bu, terim ile yanıt arasında bir ilişki olmadığını gösterir. Genellikle, 0,05'lik bir önem seviyesi (α veya alfa olarak gösterilir) iyi sonuç verir. 0,05'lik bir önem seviyesi, terim 0'dan anlamlı bir şekilde farklı olduğunda, terimin 0'dan anlamlı bir şekilde farklı olmadığını sonucuna varma riskinin %5 olduğunu gösterir.

p değeri anlamlılık düzeyinden büyükse, katsayının istatistiksel olarak anlamlı olduğu sonucuna varılamaz. Modeli, bu terim olmadan yeniden düzenlemek gereklidir.

Adım 2: Modelin verilere ne kadar iyi uyduğu belirlenmeli

Modelin verilere ne kadar iyi uyduğunu belirlemek için ortalama kare hatası (MS) kullanılmalıdır. Daha küçük değerler daha iyi uyan bir modeli gösterir.

Adım 3: Modelin, analizin varsayımlarını karşılayıp karşılamadığı belirlenmeli

Modelin kalıntıların bağımsız olduğu varsayımlarını karşılayıp karşılamadığını belirlemek için Ljung-Box ki-kare istatistiklerini, kalıntıların otokorelasyon fonksiyonunu (ACF) ve kalıntıların kısmi otokorelasyon fonksiyonunu (PACF) kullanılır. Varsayım karşılanmazsa, model verilere uymayabilir ve sonuçları yorumlarken veya diğer modelleri değerlendirirken dikkatli olunmalıdır.

Ljung-Box testi, model artıklarının bağımsızlık varsayımını test etmek için kullanılan bir yöntemdir. Bu testte, artıkların otokorelasyonlarının sıfır olup olmadığı hipotezi (H_0 : Artıklar bağımsızdır) test edilir. Test sonuçlarına ait p-değerleri, seçilen anlamlılık düzeyi (genellikle $\alpha = 0,05$) ile karşılaştırılır.


Eğer p-değeri $> \alpha$ ise, artıkların bağımsız olduğu sonucuna varılır ve bu da modelin bağımsızlık varsayımını karşıladığını gösterir. Eğer p-değeri $\leq \alpha$ ise, bağımsızlık hipotezi reddedilir ve model artıklarının bağımsız olmadığı anlaşılır. Bu durumda, modelin iyileştirilmesi gerekebilir. Artıkların otokorelasyon fonksiyonu (ACF), zaman serisi artıklarındaki otokorelasyonları belirlemek için kullanılan bir araçtır. ACF grafiği, her bir gecikme için otokorelasyon katsayılarını görselleştirir ve bu gecikmelerdeki anlamlılık düzeyini kontrol eder. Eğer ACF'de anlamlı bir otokorelasyon yoksa, artıkların bağımsız olduğu sonucuna varılır. Mevsimsel olmayan daha yüksek gecikmelerde bir veya iki anlamlı otokorelasyon görülebilir. Ancak, bu tür otokorelasyonlar genellikle rastgele hatalardan

kaynaklanır ve modelin bağımsızlık varsayımını ihlal ettiğine dair kesin bir işaret değildir. Artıkların kısmi otokorelasyon fonksiyonu (PACF), belirli bir gecikmede diğer gecikmelerin etkisini kontrol ederek otokorelasyonun doğrudan etkisini ölçer. PACF, özellikle artıkları daha ayrıntılı bir şekilde incelemek ve modelin uygunluğunu değerlendirmek için kullanılır. Eğer PACF’de anlamlı bir korelasyon yoksa, artıkların bağımsız olduğu sonucuna varılabilir. Ancak, ACF’de olduğu gibi, daha yüksek mevsimsel olmayan gecikmelerde bir veya iki anlamlı korelasyon görülebilir. Bu durum, genellikle rastgele hatalardan kaynaklanır ve varsayımın karşılanmadığını doğrudan göstermez. Artıkların analizinde anlamlı otokorelasyonların varlığı, genellikle modelin iyileştirilmesi gerektiğine işaret eder. Ancak, ACF ve PACF grafikleri incelenirken mevsimsel olmayan daha yüksek gecikmelerde görülen az sayıdaki anlamlı korelasyonlar, rastgele hatalara bağlanabilir. Bu tür durumlarda, bağımsızlık varsayımının ihlal edilmediği varsayılabilir. Ancak, anlamlı otokorelasyonlar yaygın ve sistematik bir şekilde gözleniyorsa, modelin daha iyi bir şekilde yeniden yapılandırılması veya alternatif bir model kullanılması gerekebilir.

3. Bulgular ve Tartışma

Bir işletmenin iki ana ürünü olan iki farklı tarım makinesinin üretim tahmini amacıyla, işletmeden erişilen 2011-2021 yılları arasındaki aylık üretim adetleri kullanılmıştır.


Ürün 1 ve ürün 2’nin serilerinin otokorelasyon (ACF) ve kısmi otokorelasyon (PACF) fonksiyonlarından faydalanılmış, ürünlerin mevcut zaman serilerinin fark alınmadan önce durağan olup olmadığı kontrol edilmiş ve trend, mevsimsellik gibi sahip olabileceği davranışları belirlemek adına serinin grafikleri oluşturulmuştur. Öncelikle, iki ürünün serileri için bahsedilen durağanlık ve desenlerle ilgili olarak zaman serisi grafikleri Şekil 1’de verilmiştir.



Şekil 1. Ürün 1 ve ürün 2’nin aylık üretim adedi zaman serisi (2011-2021)


Şekil 1 incelendiğinde ürün 1 ve ürün 2 serilerinde bir artış ya da azalış eğilimine (trend) rastlanmamaktadır ancak belirli ay aralıklarında kendini tekrarlayan döngüler olabileceği fark edilmektedir. Bu durumda mevsimsel etkilerden bahsetmek mümkündür. Her bir yılın 12 aylık verilerini

içeren zaman serisi grafiğinden (Şekil 2) faydalanarak mevsimsel etkileri daha net görebilmemiz mümkündür.



Şekil 2. Her yıl için aylık ürün 1 ve ürün 2 üretim adetleri zaman serisi


Şekil 2’de Ürün 1 için Mart, Nisan, Ekim ve Kasım aylarında diğer aylara göre daha çok üretim olduğu görülmektedir. Ürün 2 için ise üretimin diğer aylara nazaran yüksek olduğu aylar Nisan, Mayıs ve Haziran ayları olduğu görülmektedir. Bu şekiller ışığında, mevcut zaman serisinin mevsimsel etki davranışına sahip olduğuna dair genel bir bilgi elde edilmiştir. MINITAB paket programından faydalanılarak detaylı analiz yapabilmek ve geçerli SARIMA modelini belirleyebilmek adına ürün 1 ve ürün 2 için elde edilen %5 anlamlılık sınırları içinde otokorelasyon (ACF) fonksiyonu Şekil 3’de verilmiştir.



Şekil 3. Ürün 1 ve ürün 2 ‘nin otokorelasyon fonksiyonu

Ürün 1 için zaman serisinin ilk gecikmesine ve onbirinci, onikinci gecikmesine ait otokorelasyon değerlerinin oldukça büyük olduğu görülmektedir. Dolayısıyla serinin durağan olmadığı, aradaki gecikme değerlerinin yavaş yavaş azalmasıyla anlaşılmaktadır. Ayrıca, ACF grafiğinde sinüse benzeyen dalgalanmalar var ise mevsimsel etkinin varlığından bahsetmek söz konusu olabilecektir. Serinin durağan hale gelmesi için yapılması gereken şey, seri tarafından ihtiyaç duyulan miktar kadar farkını almaktır. Ürün 1’in ACF grafiğine baktığımızda birinci dereceden fark almak mevsimsel etkiyi yok etmeyeceğinden ötürü bu yapılan işlem seriyi durağan hale getirmek için yeterli olmayabilir. Dolayısıyla bir de mevsimsel fark almak gerekebilir. Ürün 2 için de zaman serisinin ilk birkaç gecikmelerinin ve onbirinci, onikinci ve onüçüncü gecikmelerinin otokorelasyon değerlerinin oldukça büyük olduğu görülmektedir ve buna ek olarak diğer otokorelasyon değerleri yavaş yavaş azalmaktadır. Bu iki durum serinin durağan olmadığının göstergesidir. Ayrıca, ACF grafiğinde sinüse benzeyen dalgalanmalar var ise mevsimsel etkinin varlığından bahsetmek söz konusu olabilecektir. Bu durumda, serinin ihtiyaç duyduğu kadar farkının alınması seriyi durağan hale getirmekte faydalı olacaktır. Buna ek olarak, ACF grafiklerinin de gösterdiği şekilde mevcut zaman serilerinde mevsimsel etkilerin varlığı söz konusu olduğundan seriyi durağan hale getirmek için birinci dereceden fark almak yetersiz kalabilir. Bu yüzden


anlaşıldığı üzere en az bir kez mevsimsel fark almak gerekebilir. Şekil 4’de ürün1 ve ürün 2 için birinci dereceden farkı alınmış serilerinin otokorelasyon grafikleri verilmiştir.



Şekil 4. Ürün1 ve ürün 2 için birinci dereceden farkı alınmış serilerin otokorelasyon fonksiyonu

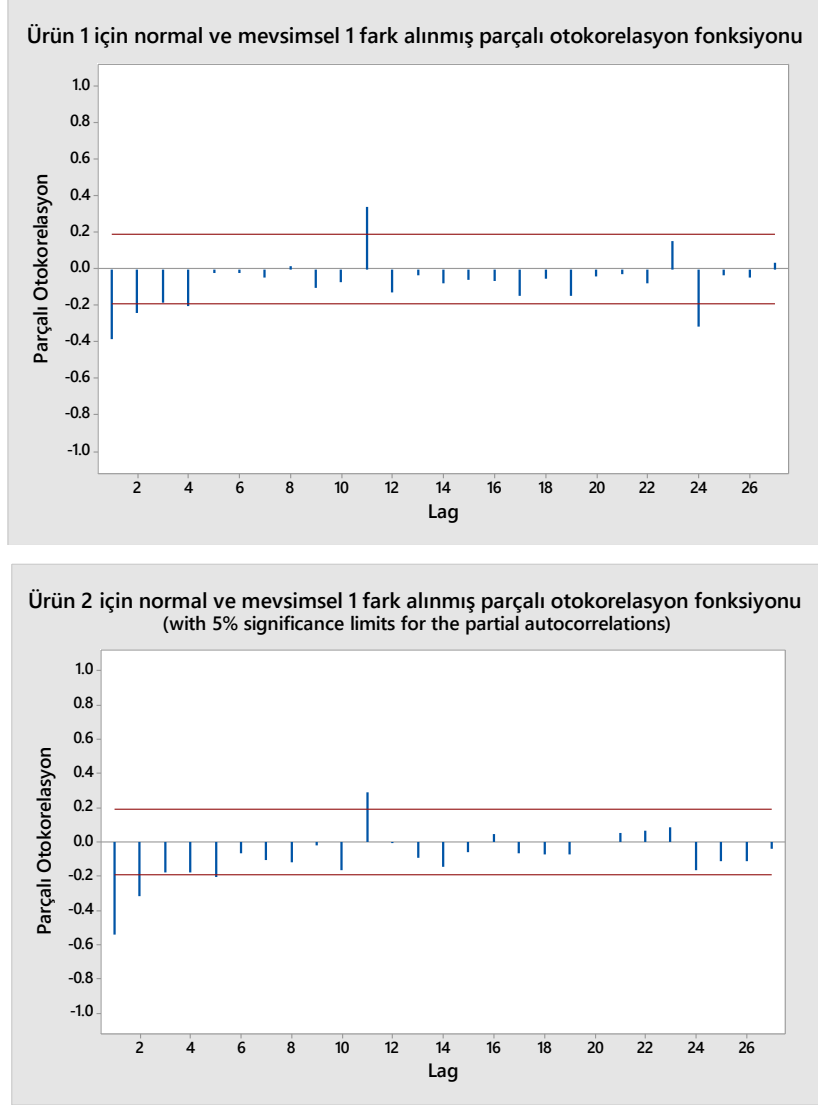
Her bir ürün için birinci dereceden normal farkı alınmış zaman serisinin (ACF) otokorelasyon grafikleri incelendiğinde, ürün 1 için %5 anlamlılık düzeyini dördüncü, dokuzuncu ve onikinci gecikme değerlerine ait otokorelasyon değerlerinin geçtiği göze çarpmaktadır (Şekil 4). Ürün 2 için ise %5 anlamlılık düzeyini beşinci, dokuzuncu, onbir ve onikinci gecikme değerlerine ait otokorelasyon değerlerinin geçtiği gözlenmektedir (Şekil 4). Tüm bunlar iki seriye ait mevsimsellik davranışının da değerlendirmeye alınması gerektiğini gösterir. Bu durumda serileri durağan hale getirmek için birinci dereceden fark ve mevsimsel etki nedeniyle onikinci dereceden fark alınması gerektiğini göstermektedir

(Hanke ve Wichern, 2014). Onikinci farkının alınmasının sebebi Şekil 2’de her iki ürün için de onikişer aylık zaman serilerinin benzer desenler ortaya koymasıştır.



Şekil 5. Ürün 1 ve Ürün 2 için normal düzeyde birinci dereceden ve mevsimsel dereceden farkı alınmış serinin otokorelasyon fonksiyonu

Şekil 5 ve Şekil 6 incelendiğinde, ürün 1 ve ürün 2 serilerinde trend deseni bulunmamakta ve fark alma işlemleri sonucunda serilerin mevsimsel etkilerden kurtularak durağan hale geldiği görülmektedir. Bu nedenle verilerin 1 derece ($D=2$) daha mevsimsel farkı alınmamıştır. ACF grafiği birinci dereceden mevsimsel fark alma işleminde yol gösterici olmuş ve periyod 12 olarak belirlenmiştir. Mevsimsel fark alma sonucunda, verilerin PACF grafikleri de Şekil 6’da verilmiştir.



Şekil 6. Ürün 1 ve ürün 2 için normal düzeyde birinci dereceden ve mevsimsel dereceden farkı alınmış serinin parçalı otokorelasyon fonksiyonu

Öncelikle durağan hale gelen veri setlerinin (p, q, P, Q) olarak belirtilen diğer parametre değerlerinin belirlenebilmesi gerekmektedir. Bunun için model denemeleri yapılmış ve en iyi tahmin modelinin belirlenebilmesi için, yukarıda bahsedilen 3 adımdaki unsurlar incelenmiştir. Ürün 1 için en iyi model SARIMA $(1,1,2)(0,1,1)_{12}$ olarak bulunmuştur.

Ürün 2 için ise en iyi model SARIMA $(0,1,1)(1,1,0)$ olarak bulunmuştur. En iyi modellerin bulunması için en az 10 farklı kombinasyon denemesi yapılmıştır. Ürün 1 ve Ürün 2 için en iyi SARIMA $(p, 1, q)(P, 1, Q)_{12}$ model parametrelerine göre değerlendirme kriteri olan üç adıma göre istenen değerler ile ACF, PACF grafikleri, hata grafikleri ve zaman serisi tahmin grafiği aşağıda sunulmuştur.

Tablo 1. Ürün 1 ve ürün 2 için en iyi SARIMA (p, 1, q)(P, 1, Q)₁₂ model parametrelerine göre değerlendirme kriterleri sonuçları

ÜRÜN 1					
SARIMA(1,1,2)(0,1,1)	PARAMETRE DEĞERLERİ			Ljung -Box Ki-Kare	
	TÜR	P DEĞERİ	MSE	LAG	p- değeri
	AR1	0,000	15287	12	0,201
	MA1	0,000		24	0,387
	MA2	0,000		36	0,576
	SMA12	0,000		48	0,626
ÜRÜN 2					
SARIMA(0,1,1)(1,1,0)	TÜR	P DEĞERİ	MSE	Ljung -Box Ki-Kare	
	MA1	0,000	33260	LAG	p- değeri
	MA1	0,000		12	0,915
	SAR12	0,000		24	0,564
				36	0,564
			48	0,664	

Anahtar sonuçlar olarak öncelikle modeldeki her terimin anlamlı olup olmadığını belirlemek adına P katsayısına bakılmalıdır.


Ürün 1 için AR1, MA1, MA2 ve SMA12 Otoregresif terimlerinin p değeri 0,05'lik anlamlılık seviyesinden küçüktür. Otoregresif terim için katsayının istatistiksel olarak anlamlı olduğu sonucuna varılabilir ve bu terimleri modelde tutmamız gereklidir. Yapılan denemeler sonucu en ideal model ilk adıma göre Tablo 1’de verildiği şekildedir.

Ürün 2 için MA1 ve SMA12 Otoregresif terimlerinin p değeri 0,05'lik anlamlılık seviyesinden küçüktür. Otoregresif terim için katsayının istatistiksel olarak anlamlı olduğu sonucuna varılabilir ve bu terimleri modelde tutmamız gereklidir. Yapılan denemeler sonucu en ideal model ilk adıma göre Tablo 1’de verildiği şekildedir.


Adım iki’ye göre önerilen model için ortalama kare hatası ürün 1 için 15283’tür. Bu değer kendi başına çok bilgilendirici değildir, ancak farklı SARIMA modellerinin uyumlarını karşılaştırmak için kullandığımızda en düşük kalan MS değerlerinden biri olduğu görülmektedir.

Adım iki’ye göre bu model için ortalama kare hatası ürün 2 için 33260’tır. Daha önce de belirtildiği şekilde bu değer kendi başına çok bilgilendirici değildir, ancak farklı SARIMA modellerinin uyumlarını karşılaştırmak için kullandığımızda en düşük kalan MS değerlerinden biri olduğu görülmektedir.

Adım üç’e göre Tablo 1’deki sonuçlarda, ürün 1 ve ürün 2 için de Ljung-Box ki-kare istatistikleri için p değerlerinin hepsi 0,05’ten büyüktür.




(a)




(b)

Şekil 7. Ürün 1 PACF(a), ACF(b) grafikleri

Ürün 1 için kalıntıların otokorelasyon fonksiyonu veya kalıntıların kısmi otokorelasyon fonksiyonu için korelasyonların hiçbirisi anlamlı değildir. Modelin kalıntıların bağımsız olduğu varsayımını karşıladığı sonucuna varılabilir (Şekil 7).




(a)



(b)

Şekil 8. Ürün 2 PACF(a), ACF(b) grafikleri

Ürün 2 için kalıntıların otokorelasyon fonksiyonu veya kalıntıların kısmi otokorelasyon fonksiyonu için korelasyonların hiçbirisi anlamlı değildir. Modelin kalıntıların bağımsız olduğu varsayımını karşıladığı sonucuna varılabilir (Şekil 8).




Şekil 9. Ürün 1 için kalıntı grafikleri

Kalıntılar normal dağılımlıysa, kalıntıların normal olasılık grafiği yaklaşık olarak düz bir çizgiyi takip etmelidir. Ürün 1 için kalıntılar normal olasılık grafiğinde yaklaşık olarak düz bir çizgiyi takip etmektedir. Kalıntıların histogramı tüm gözlemler için kalıntıların dağılımını gösterir. Eğer model verilere iyi uyuyorsa, kalıntılar 0 ortalamasına sahip rastgele olmalıdır. Bu yüzden histogram yaklaşık olarak 0 civarında simetrik olmalıdır. Ürün 1 için histogram yaklaşık olarak 0 civarında simetrik denebilir (Şekil 9).


Kalıntıların tarafsız olup olmadığını ve sabit bir varyansa sahip olup olmadığını belirlemek için kalıntılar ve uyumlar grafiği kullanılır. İdeal olan, noktaların 0'ın her iki tarafına rastgele düşmesi ve noktalarda gözle görülebilir bir desen olmamasıdır. Ürün 1 için noktalar 0'ın her iki tarafına rastgele düşmekte ve noktalarda gözle görülebilir bir desen olmamakta denebilir (Şekil 9).

Gözlem periyodu boyunca gözlemlenen değerlerle karşılaştırıldığında uyumların ne kadar doğru olduğunu belirlemek için kalıntılara karşı sıra grafiği kullanılır. Noktalardaki desenler, modelin verilere uymadığını gösterebilir. İdeal olarak, grafikteki kalıntılar merkez çizgisinin etrafına rastgele düşmelidir. Ürün 1 için, grafikteki kalıntılar merkez çizgisinin etrafına rastgele düşmekte denebilir (Şekil 9).



Şekil 10. Ürün 2 için kalıntı grafikleri

Ürün 2 ise için kalıntılar normal olasılık grafiğinde yaklaşık olarak düz bir çizgiyi takip etmektedir. Ürün 2 için yine histogram yaklaşık olarak 0 civarında simetrik denebilir. Kalıntılar ve uyumlar grafiğine göre Ürün 2 için noktalar 0'ın her iki tarafına rassal olarak düşmekte ve noktalarda gözle görülebilir bir desen olmamakta denebilir. Kalıntılara karşı sıra grafiğine göre Ürün 2 için, grafikteki kalıntılar merkez çizgisinin etrafına rastgele düşmekte denebilir (Şekil 10).




Şekil 11. Ürün 1 zaman serisi tahmin grafikleri

Ürün 1 için 100. Aydan itibaren 132. Aya kadar yapılan tahminleri ve 1 ile 120. Aylar arasındaki gerçek değerleri gösteren grafik Şekil 11’de sunulmuştur. Tablo 2 ise 121-132. Aylar için yapılan tahmin değerlerini göstermektedir.

Tablo 2. Ürün 1 için 121-132. ayların tahminleri

Dönem	Tahmin
121	271,617
122	309,051
123	412,566
124	316,868
125	103,796
126	31,138
127	20,460
128	135,802
129	396,204
130	364,494
131	311,626
132	291,552



Şekil 12. Ürün 2 zaman serisi tahmin grafikleri

Ürün 2 için 100. Aydan itibaren 132. Aya kadar yapılan tahminleri ve 1 ile 120. Aylar arasındaki gerçek değerleri gösteren grafik Şekil 12’de sunulmuştur. Tablo 2 ise 121-132. Aylar için yapılan tahmin değerlerini göstermektedir.

Tablo 3. Ürün 2 için 121-132.ayların tahminleri

Dönem	Tahmin
121	154,802
122	211,052
123	347,019
124	257,221
125	205,239
126	585,688
127	191,845
128	70,204
129	2,618
130	10,128
131	25,948
132	85,671

Sonuçları kıyaslanacak olursa, Karakaş (2019), Türkiye İhracatçılar Meclisi internet sitesinden elde edilen 2013-2018 yılları arasındaki aylık otomotiv sanayi ihracat geliri verileri kullanarak yaptığı benzer analizler neticesinde, ARIMA (1,2,1)(0,1,1)₁₂ modelinin tahmin için uygun olduğu ortaya konmuştur. Önerilen model kullanılarak 2019 yılı aylık ihracat geliri tahmini elde edilmiştir. Çiftçi ve Sir (2023) bir acil servise başvuru sayısının tahmini amaçlamış ve Ele alınan, mevsimsel özelliklere sahip verilere yönelik olarak, zaman serisi analizi yöntemlerinden SARIMA, Holt-Winters ve ayrıştırma; makine öğrenmesi yöntemlerinden rastgele ağaç ve rastgele orman teknikleri kullanılmıştır. Yapılan analizlerde SARIMA yönteminin, acil servise yapılacak başvuru sayısının tahmin edilmesinde diğer yöntemlere göre daha etkili sonuçlar verdiği görülmüştür. Ayrıca hataların normal dağılım grafiklerini inceleyerek en uygun SARIMA modeline karar vermiştir. Çevik ve Yürekli (2003) ise benzer bir şekilde aylık akım serisinin modellenmesinde 361 adet ARIMA(p,d,q)(P,D,Q) modeli kullanılmıştır. Uygun modelin seçiminde, ARIMA(p,d,q)(P,D,Q) modellerinden hesaplanan kalıntıların bağımsız olup olmadıkları göz önüne alınmıştır. Dabral ve Murry (2017) SARIMA modelinin yeterliliğini, Ljung-Box (Q) istatistik testini kullanılarak doğrulamıştır. Ljung-Box istatistiklerinin p-değerleri kritik değeri ($p = 0.05$) aştığından, SARIMA model kalıntılarında otokorelasyon olduğu yönündeki sıfır hipotezi reddedilmiştir. Analiz sonucunda, kalıntıların rastgele bir yapıya sahip olduğu sonucuna varılmıştır. Martinez-Acosta v.d. (2020), Aylık yağış zaman serileri için SARIMA modelleri geliştirmiştir. En iyi SARIMA modelleri, otokorelasyon fonksiyonu (ACF), kısmi otokorelasyon fonksiyonu (PACF) ve Akaike Bilgi Kriteri (AIC) değerlerinin minimum olmasına dayalı olarak seçilmiştir. Ljung-Box istatistik testi sonucunda, her bir modelin kalıntılarının rastgeleliği ve homojenliği gösterilmiştir. Mombeni v.d. (2013)'in çalışmalarında uygulanan modeller mevsimsel olmasına rağmen, artıklar durağan olmalıdır,

böylece standart güven aralıkları hâlâ geçerli olur. Artık grafikleri herhangi bir düzen göstermemiş olup, bu da uygulanan SARIMA modellerinin yeterli olduğuna dair kanıt sağlamıştır.

4. Sonuç

Tarım makinelerinin üretim adetlerinin zaman serisi analiz yöntemleriyle tahmin edilmesi, işletmelerin üretim kaynaklarını etkili ve doğru bir şekilde planlaması açısından kritik bir öneme sahiptir. Üretim planlamasının doğru tahminlere dayanması hem üretim maliyetlerini optimize etmeye hem de talep karşısında esneklik kazanmaya olanak tanır. Bu bağlamda yapılan çalışmada, zaman serisi analiz yöntemlerinden biri olan SARIMA modeli kullanılarak, bir tarım makineleri üreticisi işletmenin iki önemli ürünü için üretim adetleri tahmin edilmiştir. Çalışmada, tahminleme sonuçları detaylı bir şekilde incelenmiş, model değerlendirme adımları uygulanmış ve her bir ürün için en uygun SARIMA modeli belirlenmiştir. Belirlenen modeller şu şekilde verilebilir.

- **Ürün 1:** SARIMA (1,1,2)(0,1,1)121212
- **Ürün 2:** SARIMA (0,1,1)(1,1,0)121212

Bu modeller, model değerlendirme kriterlerine göre en uygun sonuçları vermiştir. Tahmin edilen üretim adetleri, işletmenin kaynak planlamasına ve talep tahminlerine değerli bir katkı sağlamıştır.

Tarım makinelerinin üretim adetlerinin tahmini üzerine yapılan literatür taramasında, bu çalışmanın SARIMA yöntemi kullanılarak geniş çaplı bir analiz gerçekleştiren ilk çalışma olduğu görülmüştür. Çalışma, özellikle SARIMA gibi zaman serisi analiz yöntemlerinin tarım makineleri üretiminde nasıl etkili bir araç olabileceğini göstermesi açısından önem taşımaktadır. Bunun yanı sıra, bu çalışmanın son yıllarda yaşanan iklim değişikliği verilerini içermesi, tarım sektöründe artan belirsizlikler ve değişkenliklerin daha iyi anlaşılmasına yönelik önemli bir adım olarak değerlendirilmektedir.

İklim değişikliği, tarım sektörü üzerinde ciddi etkiler yaratmakta ve bu durum, tarım makinelerine olan talepte dalgalanmalara neden olabilmektedir. Bu bağlamda, çalışmada kullanılan veri setinin güncel ve değişen çevresel koşulları yansıtması, gelecekteki tahmin modellerine ışık tutacak önemli bir özellik olarak ön plana çıkmaktadır.

Bu çalışmada kullanılan SARIMA modeli, mevcut veri seti ve koşullara uygun en iyi sonuçları vermiştir. Ancak, gelecekte yapılacak çalışmalarla daha uzun bir zaman aralığını kapsayan veri setlerinin analize dahil edilmesi, tahmin sonuçlarının doğruluğunu artırabilir. Özellikle, tarım makinelerinin üretim tahminlerinde farklı model değerlendirme kriterlerinin kullanımı göz önüne alınırsa daha gelişmiş model değerlendirme yöntemlerinin dahil edilmesiyle, mevcut modellerin performansı daha detaylı analiz edilebilir. Makine öğrenmesi ve hibrit yöntemler gibi derin öğrenme yöntemleri veya makine öğrenmesine dayalı algoritmaların SARIMA gibi zaman serisi analiz yöntemleriyle birleştirilmesi, daha güçlü ve esnek tahmin modelleri oluşturabilir. Bu yöntemler, büyük veri setleriyle çalışmaya daha uygun olduğundan, üretim ve talep tahminlerinde gerçeğe daha yakın sonuçlar elde edilebilir.

Gelecekte yapılacak çalışmalar, yalnızca kısa vadeli tahminler değil, aynı zamanda uzun vadeli tahminleri de kapsayacak şekilde genişletilebilir. Bu tür tahminler, işletmelere periyodik kapasite planlaması avantajı sağlayarak üretim altyapısının ve kaynaklarının optimize edilmesini sağlar.

Küresel iklim değişikliğinin etkilerinin izlenmesi ile İklim değişikliğinin tarım makineleri üretimi ve talebi üzerindeki etkilerinin analiz edilmesi mümkün hale gelir. Talep dalgalanmalarının yönetilmesi bağlamında belirsiz talepleri karşılamaya yönelik stratejik bir yol haritası oluşturulması olanağı ortaya çıkar.

SARIMA modelinin performansını daha da iyileştirmek için genetik algoritmalar veya farklı optimizasyon yöntemleri kullanılabilir. Bu tür algoritmalar, model parametrelerinin daha etkili bir şekilde belirlenmesini sağlayarak tahmin doğruluğunu artırabilir. Örneğin, mevcut çalışmada kullanılan SARIMA modelleri, bu algoritmalar yardımıyla daha iyi sonuçlar verebilir ve tahmin performansı daha da güçlendirilebilir.

Çalışmada kullanılmayan diğer makine öğrenmesi yöntemlerinin aynı veri seti üzerinde uygulanması, yeni çalışma alanları yaratabilir. Büyük veri setleri, genellikle makine öğrenmesi modelleriyle daha iyi performans gösterdiğinden, bu yöntemlerin SARIMA ile karşılaştırılması ve aralarındaki farkların incelenmesi literatüre değerli katkılar sağlayabilir.

Sonuç olarak, bu çalışma, SARIMA yöntemiyle tarım makineleri üretim tahmini alanında öncü bir analiz sunarken, gelecekteki araştırmalar için yeni yöntemlerin ve daha kapsamlı veri setlerinin kullanılmasının önemini vurgulamaktadır. Bu tür çalışmalar, tarım makineleri sektörünün gelecekteki üretim planlamasına ve stratejik karar alma süreçlerine rehberlik edecek potansiyele sahiptir.

Teşekkür

Makalenin inceleme ve değerlendirme aşamasında yapmış oldukları katkılardan dolayı editör ve hakemlere teşekkür ederiz.

Çıkar Çatışması Beyanı

Makale yazarı herhangi bir çıkar çatışması olmadığını beyan eder.

Araştırmacıların Katkı Oranı Beyan Özeti

Yazar makaleye %100 oranında katkı sağlamış olduğunu beyan eder.

Kaynakça

Akusta A. Konut piyasası trendlerinin çözümlenmesi: Türkiye’de toplam konut satışlarının tahmini. Necmettin Erbakan Üniversitesi Siyasal Bilgiler Fakültesi Dergisi 2024; 6(1): 113-127.

Ashutosh KD., Abhishek K., Vicente GD., Arpit KS., Kishan K. Study and analysis of SARIMA and LSTM in forecasting time series data. Sustainable Energy Technologies and Assessments 2021; 47: 101474

- Box G., Jenkins G. Time series analysis: Forecasting and control. 5th ed.San Francisco: Holden-Day; 1970.
- Chikkakrishna NK., Hardik C., Deepika K., Sparsha N. Short-term traffic prediction using SARIMA and FBPropeth. 16th India Council International Conference (INDICON), 2019, sayfa no: 1-4, India.
- Çevik O., Yürekli K. Mevsimsel ARIMA modeli kullanılarak Yeşilırmak nehri aylık akım serisinin Modellenmesi. Tarım Bilimleri Dergisi 2003; 9(3): 261-268.
- Çiftçi S., Batur Sir GD. Acil servise başvuru sayısının zaman serisi analiz ve makine öğrenmesi yöntemleri ile tahmin edilmesine yönelik bir uygulama. Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi 2023; 29(7): 667-679
- Dabral PP., Murry MZ. Modelling and forecasting of rainfall time series using SARIMA. Environmental Processes 2017; 4: 399-419.
- Dickey DA., Fuller WA. Distributions of the estimators for autoregressive time series with a unit root, Journal of American Statistical Association 1979; 74(366): 427-481.
- Divisekara RW., Jayasinghe GJMSR., Kumari KWSN. Forecasting the red lentils commodity market price using SARIMA models. SN Business & Economics 2021; 1: 20.
- Hanke JE., Wichern D. Business forecasting. England. 9th ed.England: Pearson Education;2014
- He K., Lei J., Chi WDW., Kwok FGT. Using SARIMA–CNN–LSTM approach to forecast daily tourism demand. Journal of Hospitality and Tourism Management 2021; 49: 25-33.
- Karakaş E. Türkiye'nin otomotiv ihracat gelirin ARIMA modeli ile tahmin edilmesi, Journal of Yasar University 2019; 14(55): 318-328.
- Komori-Zevallos AR., Montedoro-Garay FM., Garcia-Lopez YJ., Quiroz Flores JC. A production model based in lean 4.0 principles and machine learning to enhance the productivity of small and medium-sized enterprises (SMEs) in Peru's food manufacturing sector. Proceedings of the Conference on Production Systems and Logistics, Şubat 2023, sayfa no:139-150, Hannover, Germany.
- Liu J., Zhao Z., Zhong Y., Zhao C., Zhang G. Prediction of the dissolved gas concentration in power transformer oil based on SARIMA. Energy Reports 2022; 8(5): 1360-1367.
- Loganathan N., Ibrahim Y. Forecasting international tourism demand in Malaysia using Box Jenkins SARIMA application, South Asian Journal of Tourism and Heritage 2010; 3(2): 50-60.
- Martínez-Acosta L., Medrano-Barboza JP., López-Ramos Á., Remolina López JF., López-Lambraño ÁA. SARIMA approach to generating synthetic monthly rainfall in the Sinú River Watershed in Colombia. Atmosphere 2020; 11(6): 602.
- Megha S., Namita M., Anukram MA., Arun G. Time-series forecasting of power consumption and feature extraction in agriculture sector using machine learning. International Journal of Power and Energy Systems 2023; 43(10).

- Milenković M., Švadlenka L., Melichar V., Bojović N., Avramović Z. SARIMA modelling approach for railway passenger flow forecasting. *Transport* 2018; 33(5): 1113-1120.
- Mombeni HA., Rezaei S., Nadarajah S.. Estimation of water demand in Iran based on SARIMA models. *Environmental Modeling and Assessment*. 2013; 18: 559–565
- Oliveira CDG. Indústria de máquinas agrícolas no Brasil: um modelo para estimação da demanda de tratores para o triênio 2016–2018. Foundation Getúlio Vargas School Of Economics Of São Paul Master tezi, Sao Paul, Brasil, 2016.
- Önen V. Using the ARIMA and ARIMAX methodologies to estimate, model, forecast, and compare airline passenger transportation demand in Türkiye. *Journal of Transportation and Logistics* 2023; 8(2): 242-273.
- Peng C., Aichen N., Duanyang L., Wei J., Bin M. Time series forecasting of temperatures using SARIMA: an example from Nanjing. *IOP Conference Series: Materials Science and Engineering* 2018; 394(5): 052024.
- Vagropoulos SI., Chouliaras GI., Kardakos EG., Simoglou CK., Bakirtzis AG. Comparison of SARIMAX, SARIMA, modified SARIMA and ANN-based models for short-term PV generation forecasting," *IEEE International Energy Conference (ENERGYCON)* 4-8 Nisan 2016, sayfa no: 1-6. Leuven, Belgium
- Valipour M. Long-term runoff study using SARIMA and ARIMA models in the United States. *Meteorological Applications* 2015; 22: 592-598.
- Wei WWS. Time series analysis. Addison Wesley Publishing Company, California, 1989; 478 s.