Çukurova Üniversitesi
Mühendislik Fakültesi Dergisi
Çukurova University
Journal of the Faculty of Engineering
ISSN: 2757-9255 CİLT/VOLUME: 41 SAYI/ISSUE: 3 EYLÜL/SEPTEMBER 2026

Petrol Ürünleri İthalatının Tahmininde Geleneksel, Hibrit ve Meta-Sezgisel Yaklaşımlar: SARIMA, RF-LSTM ve DE-HW Modellerinin Karşılaştırılması

Esra KARAKAŞ [1,a], **Menşure Zühal BARAK** [1,b]

[1]*Adana Alparslan Türkeş Bilim ve Teknoloji Üniversitesi, İktisadi, İdari ve Sosyal Bilimler Fakültesi, İşletme Bölümü, Adana, Türkiye*

[a]***ORCID**: 0000-0002-8333-3091; [b]**ORCID**: 0009-0002-3993-513X*

Makale Bilgileri
Geliş : 02.06.2026
Kabul : 16.07.2026
DOI: 10.21605/cukurovaumfd.1962748

Sorumlu Yazar
Esra KARAKAŞ
ekarakas@atu.edu.tr

Anahtar Kelimeler
Holt-winters
Diferansiyel evrim algoritması
Rastgele orman (RF)
Kısa-uzun vadeli bellek (LSTM)
SARIMA

***Atıf şekli:** KARAKAŞ, E., BARAK, M.Z., (2026). Petrol Ürünleri İthalatının Tahmininde Geleneksel, Hibrit ve Meta-Sezgisel Yaklaşımlar: SARIMA, RF-LSTM ve DE-HW Modellerinin Karşılaştırılması. Çukurova Üniversitesi, Mühendislik Fakültesi Dergisi, 41(3), 545-561.*

ÖZ

Bu çalışma, Türkiye'nin 2030 Sürdürülebilir Kalkınma Amaçları doğrultusunda ekonomik ve çevresel sürdürülebilirlik planlamalarına katkı sağlamak amacıyla, 27.10 GTİP kodlu petrol ürünleri ithalat miktarını 2030 yılına kadar tahmin etmeyi ve farklı tahmin modellerinin performanslarını karşılaştırmayı amaçlamaktadır. 2007–2026 dönemine ait aylık ithalat verileri kullanılarak Mevsimsel Otoregresif Entegre Hareketli Ortalama (SARIMA), Diferansiyel Evrim algoritmasıyla optimize edilmiş Holt-Winters (DE-HW) ve derin öğrenme tabanlı Hibrit Rastgele Orman–Kısa Uzun Vadeli Bellek (RF-LSTM) modelleri uygulanmıştır. Model performansları Kök Ortalama Kare Hata (RMSE), Ortalama Kare Hata (MSE), Ortalama Mutlak Hata (MAD) ve Ortalama Mutlak Yüzde Hata (MAPE) ölçütleriyle değerlendirilmiştir. Bulgular, Hibrit RF-LSTM modelinin eğitim ve doğrulama setlerinde sırasıyla %7 ve %5 MAPE değerleriyle en yüksek tahmin performansını sağladığını göstermiştir. Elde edilen 2030 tahminleri, enerji ithalatı bütçe yönetimi, lojistik planlama ve stratejik rezerv kapasitesinin belirlenmesine yönelik politika kararları için veri temelli bir çerçeve sunmaktadır.

Advanced Time Series Approaches in Petroleum Product Import Modeling: Comparing Hybrid RF-LSTM, SARIMA, and DE-HW Models

Article Info
Received : 02.06.2026
Accepted : 16.07.2026
DOI: 10.21605/cukurovaumfd.1962748

Corresponding Author
Esra KARAKAŞ
ekarakas@atu.edu.tr

Keywords
Holt-winters
Differential evolution algorithm
Random forest (RF)
Long short-term memory (LSTM)
SARIMA

***How to cite:** KARAKAŞ, E., BARAK, M.Z., (2026). Advanced Time Series Approaches in Petroleum Product Import Modeling: Comparing Hybrid RF-LSTM, SARIMA, and DE-HW Models. Cukurova University, Journal of the Faculty of Engineering, 41(3), 545-561.*

ABSTRACT

This study aims to contribute to Türkiye's economic and environmental sustainability planning in line with the 2030 Sustainable Development Goals by forecasting the import volume of petroleum products classified under HS Code 27.10 through 2030 and comparing the performance of different forecasting models. Using monthly import data for 2007–2026, Seasonal Autoregressive Integrated Moving Average (SARIMA), Holt-Winters optimized by the Differential Evolution algorithm (DE-HW), and a deep learning-based Hybrid Random Forest–Long Short-Term Memory (RF-LSTM) model were applied. Model performances were evaluated using Root Mean Square Error (RMSE), Mean Square Error (MSE), Mean Absolute Deviation (MAD), and Mean Absolute Percentage Error (MAPE). The results showed that the Hybrid RF-LSTM model achieved the highest forecasting performance, with MAPE values of 7% and 5% for the training and validation sets, respectively. The forecasts obtained for 2030 provide a data-driven framework for policy decisions concerning energy import budgeting, logistics planning, and strategic reserve capacity determination.

1. GİRİŞ

Türkiye'nin jeolojik yapısı nedeniyle sınırlı yerli fosil yakıt rezervlerine sahip olması, artan enerji talebiyle birlikte özellikle petrol ve rafine petrol ürünlerinin ithalatını enerji arzı açısından önemli bir unsur haline getirmektedir. Nitekim Türkiye'de sanayileşme ve ekonomik büyüme süreci enerji talebini artırırken [1], yerli enerji üretiminin bu talebi karşılamada sınırlı kalması enerji ithalatına olan duyarlılığı artırmaktadır [2,3]. Bu durum, Türkiye'nin ithal rafine petrol ürünlerine olan ihtiyacını artırmakta; enerji arz güvenliği, dış ticaret dengesi ve çevresel sürdürülebilirlik açısından dikkate alınması gereken çok boyutlu bir alan oluşturmaktadır [3]. Enerji talebinin önemli bir kısmının ithalat yoluyla karşılanması, ülke ekonomisi açısından dış kaynaklara duyarlılığı artırmakta ve enerji ithalat maliyetlerinin dikkatle izlenmesini gerekli kılmaktadır. Petrol fiyatlarındaki dalgalanmaların cari işlemler dengesi üzerindeki etkilerini inceleyen çalışmalar da Türkiye gibi enerji ithalatına bağımlı ekonomilerde petrol fiyat şoklarının makroekonomik göstergeler üzerinde önemli etkiler oluşturabileceğini göstermektedir [4,5].

Türkiye'nin küresel petrol piyasalarında fiyatları belirleyen değil, fiyatlardan etkilenen ülkeler arasında yer alması, uluslararası petrol ve rafine ürün fiyatlarındaki değişimlerin ithalat maliyetlerine yansımasına neden olmaktadır. Enerji yoğun ekonomik yapı [6] içerisinde ithalata duyarlılık; cari denge, döviz kuru, üretim maliyetleri ve enflasyon gibi makroekonomik göstergeler üzerinde çeşitli etkiler oluşturabilmektedir. Bu nedenle, enerji ithalatına ilişkin gelişmelerin düzenli olarak izlenmesi ve geleceğe yönelik güvenilir tahminlerin üretilmesi, enerji arz güvenliği ve ekonomik planlama açısından önem arz etmektedir.

Türkiye'de enerji arzı ve petrol ürünleri tedarikinde ithalatın belirgin bir role sahip olması, makroekonomik dinamikler ve ithalat talebinin modellenmesi açısından literatürde önemli bir araştırma alanı oluşturmaktadır. Bu kapsamda yapılan çalışmalar, petrol ve petrol ürünleri talebinin yalnızca fiyat hareketleriyle değil; ekonomik büyüme, ulaştırma faaliyetleri, sektörel enerji kullanımı, döviz kuru ve dış ticaret dengesi gibi çok boyutlu değişkenlerle ilişkili olduğunu göstermektedir. Ediger ve Berk [7], Türkiye'nin ham petrol ithalat politikasını tarihsel bir perspektifle inceleyerek petrol ithalatının ekonomik ve stratejik açıdan önemini vurgulamış ve ithalat stratejisinin belirleyicilerini analiz etmiştir. Petrol ürünleri talebine daha doğrudan odaklanan Solak [8], Türkiye'nin toplam petrol talebi ve ulaştırma sektörü petrol talebi 2012-2020 dönemi için Otoregresif Entegre Hareketli Ortalama (ARIMA) modeli ile tahmin edilmiştir. Benzer şekilde Melikoğlu [9], Türkiye'de benzin, motorin, LPG, biyoetanol ve biyodizel talebini yarı deneye dayalı modellerle tahmin ederek ulaştırma yakıtlarına yönelik talep tahminlerinin enerji planlaması açısından önemini ortaya koymuştur.

Son yıllarda ise petrol ürünleri ve enerji talebinin tahmininde geleneksel ekonometrik modellerin yanında makine öğrenmesi ve yapay zekâ tabanlı yöntemlerin kullanımı artmaktadır. Bu bağlamda, Sahraei ve arkadaşları [10], Türkiye'de 1975–2019 dönemi ulaştırma enerji talebini Çok Değişkenli Uyarlanabilir Regresyon Eğrileri (MARS) yöntemiyle tahmin etmiş; GSYİH, nüfus, araç-km, ton-km, yolcu-km ve petrol fiyatı değişkenlerini model girdileri olarak kullanmıştır. Beş farklı MARS modelinin karşılaştırıldığı çalışmada, petrol fiyatı ve ton-km değişkenlerini içeren modelin en yüksek tahmin performansını sergilediği belirlenmiştir. Ağbulut [11], Türkiye'de ulaştırma kaynaklı enerji talebi ve CO_2 emisyonlarını derin öğrenme, destek vektör makineleri ve yapay sinir ağları yöntemleriyle tahmin etmiş; kişi başına GSYİH, nüfus, araç-kilometre ve yıl değişkenlerini girdi olarak kullanmıştır. Çalışma sonuçları, makine öğrenmesi yöntemlerinin enerji talebi ve emisyon tahmininde yüksek doğruluk sağlayabildiğini ortaya koymuştur. Ek olarak, Hoxha ve arkadaşları [12] ile Çodur [13] ise topluluk öğrenme yöntemleriyle enerji talebi tahmin performansını artırmaya yönelik modeller geliştirmiştir.

Literatürdeki bulgular, petrol ve petrol ürünleri talebinin yalnızca fiyat hareketleriyle değil; ekonomik büyüme, ulaştırma faaliyetleri, sektörel enerji kullanımı, enerji fiyatları ve dış ticaret dengesi gibi çok boyutlu değişkenlerle ilişkili olduğunu göstermektedir. Bu nedenle, petrol ürünleri ithalatının gelecekteki eğiliminin yüksek doğrulukla tahmin edilmesi, enerji arz güvenliği, ithalat planlaması, lojistik süreçlerin yönetimi ve stratejik rezerv kapasitesinin değerlendirilmesi açısından önemli bir araştırma alanı oluşturmaktadır. Bu bağlamda, 2710 GTİP kodu kapsamında yer alan petrol yağları ve bitümenli minerallerden elde edilen yağlar ile bu ürünleri içeren müstahzarların ithalatına yönelik güvenilir öngörülerin elde edilmesi, Türkiye'nin enerji ithalat yapısının daha ayrıntılı biçimde analiz edilmesine katkı sağlayacaktır.

Bu çalışma, 2007–2026 dönemine ait aylık ithalat verilerine dayanarak 2710 GTİP kodlu petrol ürünleri ithalatının tahmin edilmesine odaklanmaktadır. Bu kapsamda, ARIMA/SARIMA gibi geleneksel zaman serisi yöntemlerinin yanı sıra meta-sezgisel optimizasyon temelli DE-HW modeli ve makine öğrenmesi tabanlı hibrit RF-LSTM modeli karşılaştırılarak tahmin performansı açısından en uygun modelin belirlenmesi amaçlanmaktadır. Karşılaştırmalı değerlendirme sonucunda öne çıkan model kullanılarak, 2030 yılına kadar Türkiye'nin petrol ürünleri ithalat eğilimlerine ilişkin güvenilir öngörüler elde edilmesi hedeflenmektedir. Çalışmanın, enerji ithalatı planlaması, lojistik yönetimi, dış ticaret politikalarının şekillendirilmesi ve stratejik rezerv kapasitesinin optimizasyonu süreçlerinde karar vericilere veri temelli katkı sunması beklenmektedir.

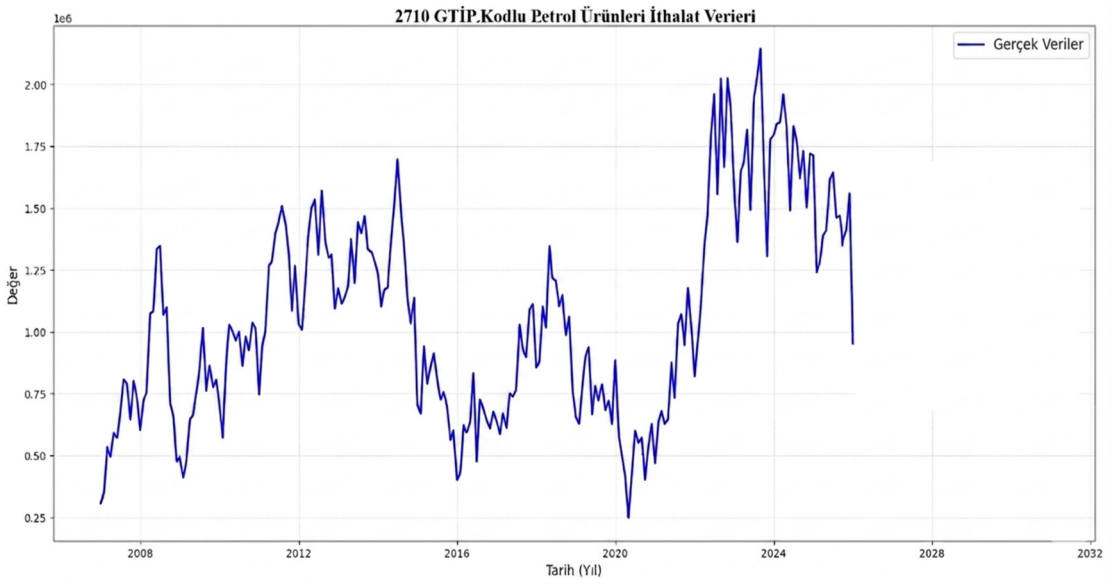
2. MATERYAL VE YÖNTEM

2.1. Veri Seti

Bu çalışmada, Türkiye'nin petrol ürünleri ithalatı, 27.10 GTİP kodu kapsamında incelenmiştir. Uyumlaştırılmış Sistem (Harmonised System-HS), uluslararası ticarette malların tanımlanması ve kodlanması için kullanılan uluslararası standartlaştırılmış bir ürün adlandırmasıdır. GTİP, Gümrük Tarife İstatistik Pozisyonu'nun kısaltmasıdır. Uluslararası ticarette eşyaların tanımlanması, sınıflandırılması ve vergilendirilmesi için kullanılan 12 haneli rakamsal koddur. Türkiye'de Gümrük Tarife Cetveli'nde yer alan bu kodlar, ithalat ve ihracat işlemlerinde ürünlerin doğru vergilendirilmesini sağlar.

GTİP 27.10, Türkiye'nin enerji ithalatı açısından stratejik öneme sahip ürünleri temsil etmektedir. 27.10 GTİP kodu, petrol yağlarını ve bitümenli minerallerden elde edilen yağları kapsamaktadır (ham yağlar hariç). Bu ürünlerin içerisinde ağırlık itibariyle en az %70 oranında petrol yağı veya bitümenli minerallerden elde edilen yağ bulunması esastır. Bu tarife pozisyonunun temel alt kırılımları şunlardır: 2710.12 kodu, hafif yağlar ve bunların müstahzarlarını (örneğin benzin ve beyaz ispirto) kapsamaktadır; 2710.19 kodu, orta ve ağır yağlar ile bunların müstahzarlarını (örneğin gaz yağı, motorin, fuel-oil, madeni yağlar) içermektedir; 2710.20 kodu, biyodizel içeren petrol yağları ve bitümenli minerallerden elde edilen yağları kapsar; 2710.91 ve 2710.99 kodları ise atık yağları, poliklorlu bifeniller veya terfeniller içerenler dahil olmak üzere kapsamaktadır. Ayrıca, 2710.11 alt kalemi ham petrolü (crude petroleum oils), 2710.12 petrol kokları ve bitümenli minerallerden elde edilen yağları, 2710.19 ise diğer ham petrol türevlerini temsil etmektedir [14].

Bu kapsamda veri setini oluşturan ithalat değerleri, Trademap web sitesi üzerinden 5 Nisan 2026 tarihinde alınmıştır. Çalışmada, Türkiye'nin tüm dünya ile olan ticaret akışları dikkate alınarak, 2007 Ocak – 2026 Ocak dönemine ait aylık 2710 GTİP kodlu petrol ürünlerinin ithalat değerleri (USD) derlenmiştir [15] (Şekil 1).



Şekil 1. 2007 Ocak – 2026 Ocak dönemine ait aylık 2710 GTİP kodlu petrol ürünlerinin ithalat değerleri

2.2. Tahmin Metotları

Zaman serisi tahmin çalışmalarında, verilerin içerdiği doğrusal ve doğrusal olmayan dinamik yapıların birlikte modellenmesi literatürde önemli bir araştırma problemi olarak ele alınmaktadır. Bu çalışmada, ithalat verilerinin taşıdığı eğilim, mevsimsellik ve karmaşık örüntüler gibi farklı yapısal özellikleri daha kapsamlı biçimde değerlendirebilmek amacıyla geleneksel, hibrit ve evrimsel optimizasyon destekli tahmin yöntemlerini içeren çok yönlü bir metodolojik çerçeve benimsenmiştir. Veri setlerinin yapısal özelliklerinin farklılaşabilmesi nedeniyle, birden fazla tahmin yönteminin karşılaştırmalı olarak kullanılması, model performanslarının daha sağlıklı biçimde değerlendirilmesine ve uygun model seçiminin desteklenmesine katkı sağlamaktadır.

Bu doğrultuda, zaman serilerindeki doğrusal yapıları ve mevsimsel örüntüleri modelleyebilme yeteneğinden dolayı geleneksel bir referans model olarak Mevsimsel ARIMA/SARIMA modeli kullanılmıştır. Verilerdeki doğrusal olmayan ilişkileri ve zamansal bağımlılıkları daha esnek biçimde ele alabilmek amacıyla ise Rastgele Orman (RF) ve Uzun Kısa Süreli Bellek (LSTM) yaklaşımlarını bir araya getiren RF-LSTM hibrit modeli çalışmaya dahil edilmiştir. Bu yaklaşımda RF, değişkenler arasındaki doğrusal olmayan ilişkileri ve etkileşimleri değerlendirebilen ağaç tabanlı bir topluluk öğrenmesi yöntemi olarak kullanılırken, LSTM ardışık zaman bağımlılıklarını ve uzun dönemli örüntüleri öğrenebilme kapasitesiyle modele katkı sağlamaktadır.

Ayrıca, mevsimsel değişimleri modellemede yaygın olarak kullanılan Holt-Winters (HW) yönteminin parametre tahmin sürecini iyileştirmek ve yerel optimuma takılma olasılığını azaltmak amacıyla, sürekli arama uzaylarında etkin çözümler üretebilen evrimsel bir optimizasyon algoritması olan Diferansiyel Evrim (DE) algoritması ile katsayıları optimize edilen DE-HW hibrit modeli de kullanılmıştır. Böylece çalışmada ARIMA/SARIMA, RF-LSTM ve DE-HW hibrit modelleri aynı veri seti üzerinde karşılaştırmalı olarak değerlendirilmiştir. Bu metodolojik çerçeve, istatistiksel, makine öğrenme temelli ve evrimsel optimizasyon destekli yaklaşımların tahmin performanslarının bütüncül biçimde incelenmesine olanak tanımaktadır.

2.2.1. ARIMA/SARIMA Metodu

SARIMA/ARIMA (Otoregresif Bütünleşik Hareketli Ortalama) modelleri, zaman serilerinin modellenmesi ve tahmin edilmesinde yaygın olarak kullanılan istatistiksel araçlardır. Bu modellerin geliştirilmesi genellikle Box–Jenkins metodolojisi doğrultusunda yürütülmektedir. Söz konusu metodoloji, zaman serisinin temel yapısını yeterli düzeyde temsil eden uygun bir ARIMA(p,d,q) modelinin belirlenmesini amaçlamaktadır ve model tanımlama, parametre tahmini, tanısal kontrol ve öngörüleme olmak üzere dört temel aşamadan oluşmaktadır.

Model tanımlama aşamasında öncelikle serinin durağanlığı incelenir. ARIMA modelleri durağan bir seri varsayımına dayandığından, serinin ortalaması veya varyansı zaman içinde değiştiğinde diğer bir ifade ile seri durağan değilse fark alma işlemi uygulanır. d ile gösterilen fark alma derecesi, Genişletilmiş Dickey–Fuller (ADF) testi gibi birim kök testleri ve/veya serinin otokorelasyon yapısının incelenmesi yoluyla belirlenir. [16,17]. Durağanlık sağlandıktan sonra ikinci aşama, seriyi en uygun biçimde temsil edecek model yapısının belirlenmesidir. Bu aşamada, serinin AR(p), MA(q), ARMA/ARIMA ya da mevsimsel örüntü içermesi durumunda SARIMA yapılarından hangisiyle daha uygun biçimde modellenebileceği değerlendirilir. Bunun için seriye ait otokorelasyon fonksiyonu (ACF) ve kısmi otokorelasyon fonksiyonu (PACF) grafikleri incelenerek, farklı ARIMA ve SARIMA modellerine ilişkin teorik örüntülerle karşılaştırılır. Böylece, tahmin sürecinde kullanılabilecek başlangıç modeli sezgisel olarak belirlenmiş olur. Temel ARIMA(p,d,q) modeli aşağıdaki matematiksel eşitlik ile ifade edilmektedir [18].

$$Z_t = \delta + \phi_1 Z_{t-1} + \phi_2 Z_{t-2} + \cdots + \phi_p Z_{p-1} + \epsilon_t - \theta_1 \epsilon_{t-1} - \theta_2 \epsilon_{t-2} - \cdots - \theta_q \epsilon_{t-q} \quad (1)$$

Burada Z_t, t zamanındaki zaman serisi değerini; Z_{t-1}, …, Z_{t-p} ise serinin gecikmeli değerlerini göstermektedir. δ, sabit terimi ifade ederken, p ve q sırasıyla otoregresif (AR) ve hareketli ortalama (MA) bileşenlerinin derecelerini belirtmektedir. φ_1, …, φ_p katsayıları otoregresif parametreleri; θ_1, …, θq katsayıları ise hareketli ortalama parametrelerini göstermektedir. t zamanındaki hata terimi ε_t ile gösterilirken, ε_{t-1}, …, ε_t–q ifadeleri gecikmeli hata terimlerini ifade etmektedir.

SARIMA modeli ise zaman serisi analizinde yaygın olarak kullanılan ARIMA modelinin bir uzantısıdır. SARIMA modelleri, analiz edilen zaman serisinin mevsimsellik göstermesi durumunda özellikle kullanışlıdır. Mevsimsellik, verilerde haftalık, aylık, üç aylık veya yıllık gibi sabit aralıklarla tekrarlanan örüntüleri ifade etmektedir. Mevsimsel olmayan ARIMA modellerinden farklı olarak SARIMA modelleri, serideki trend ve rassal dalgalanmalar gibi mevsimsel olmayan bileşenlerin yanı sıra verinin mevsimsel yapısını da dikkate almaktadır. SARIMA modelinin genel gösterimi $SARIMA\ (p,d,q)(P,D,Q)_S$ şeklindedir. Burada p otoregresif (AR) terimin derecesini, d fark alma derecesini ve q hareketli ortalama (MA) terimin derecesini ifade etmektedir. Benzer şekilde P, Dve Q sırasıyla mevsimsel otoregresif, mevsimsel fark alma ve mevsimsel hareketli ortalama derecelerini; S ise mevsimsel periyodu göstermektedir [18].

Uygun model yapısı belirlendikten sonra ARIMA modelinin parametreleri tahmin edilir. Modelin özelliklerine ve kullanılan yazılıma bağlı olarak parametre tahmini genellikle en çok olabilirlik tahmini veya en küçük kareler tahmini gibi yöntemlerle gerçekleştirilmektedir [19]. Tahmin aşamasını takiben, seçilen modelin zaman serisinin temel yapısını yeterli düzeyde açıklayıp açıklamadığını değerlendirmek amacıyla tanısal kontroller yapılır. Hata terimlerine ilişkin tanısal incelemeler genellikle grafiksel ve istatistiksel araçlar kullanılarak yürütülmektedir. Ljung–Box Q testi, hata otokorelasyonlarının seçilen gecikmeler boyunca anlamlı olup olmadığını değerlendirmek için yaygın biçimde kullanılmaktadır. Q istatistiğiyle ilişkili p değerinin 0,05'in altında olması, hata terimlerinde otokorelasyonun devam ettiğini gösterir. Böyle bir durumda model yeniden gözden geçirilmeli ve uygun bir model elde edilinceye kadar alternatif model yapıları değerlendirilmelidir [18]. Ayrıca hata terimlerine ait ACF ve PACF grafikleri ile normallik testleri tamamlayıcı tanısal araçlar olarak kullanılabilir [20,21].

Mevcut model doğrulandıktan sonra gelecek dönemlere ilişkin öngörülerin üretilmesinde kullanılabilir. Alternatif ARIMA /SARIMA modellerinin tahmin performansı genellikle AIC ve BIC gibi bilgi kriterleri ile RMSE, MAE veya MSE gibi hata ölçütleri birlikte kullanılarak değerlendirilmektedir. Bu kriterler, araştırmacıların alternatif model yapılarını karşılaştırmasına ve hem yeterli uyum sağlayan hem de güvenilir tahmin performansı sunan modeli seçmesine yardımcı olmaktadır [16,22].

2.2.2. Diferansiyel Evrim Algoritması ile Optimize Holt Winters (DE-HW) Metodu

Holt-Winters yöntemi (üçlü üstel düzeltme), zaman serisi verilerini tahmin etmek için tasarlanmış, temel ve yaygın olarak uygulanan seviye, trend ve mevsimsellik içeren zaman serileri için geliştirilmiş bir tahmin metodudur. Karmaşık zaman serilerini yorumlamada güçlü olan bu metod, düzey, eğilim ve mevsimsellik bileşenlerini geçmiş verilerden ayrıştırma ve bu bileşenleri geçmiş gözlemlerin ve tahminlerin ağırlıklı ortalamalarını kullanarak özyinelemeli olarak güncelleme yeteneğine sahiptir. Bu metodoloji, ekonomik göstergeler ve enerji talebinden halk sağlığı gözetimine ve endüstriyel üretime kadar farklı alanlardaki veri setleri için kısa ve orta vadeli tahminlerde sağlam ve hesaplama açısından oldukça etkili bir yöntemdir [23].

Holt–Winters yöntemi seviye, trend ve mevsimsellik bileşenleri ile modellenmektedir. Seviye düzeltme parametresi (α): Zaman serilerindeki rastgele faktörlerin (yani gürültünün) etkisini azaltmaya yardımcı olur. Trend düzeltme parametresi (β): Mevcut dönem ile bir sonraki dönem arasında temel düzeyde meydana gelmesi beklenen değişimi temsil eder. Mevsimsellik düzeltme parametresi (γ): Zaman serisi verilerinin her P döneminde tekrar eden bir davranış gösterme eğilimini ifade eder. Toplamsal ve çarpımsal iki temel çeşidi vardır [23]. Bu çalışmada verinin yapısı nedeni ile toplamsal model kullanılmıştır. Toplamsal model:

Seviye:

$$L_t = \alpha(Y_t - S_{t-m}) + (1-\alpha)(L_{t-1} + T_{t-1}) \quad (2)$$

Trend:

$$T_t = \beta(L_t - L_{t-1}) + (1-\beta)T_{t-1} \quad (3)$$

Mevsimsellik:

$$S_t = \gamma(Y_t - L_t) + (1-\gamma)S_{t-m} \quad (4)$$

İleriye dönük h dönemlik tahmin:

$$\hat{Y}_{t+h} = L_t + hT_t + S_{t+h-m[(h-1)/m]} \quad (5)$$

denklemde m mevsimsel uzunluk ve k=(h−1)/m ifade etmektedir [23].

Holt–Winters yönteminde seviye, trend ve mevsimsellik bileşenleri 0 ile 1 arasında herhangi bir değeri almaktadır. Ancak çözüm kümesinin 0 ile 1 arasında sonsuz olması en uygun optimum katsayının hesaplanması oldukça zor bir problem haline gelmektedir. Sonsuz çözüm kümesinde en iyi olduğu çözümü arama yöntemi optimizasyon tekniklerinden meta heuristikler ile daha hızlı bulunabilmektedir. Bu çalışmada Holt-Winters modelindeki α (seviye), β (trend) ve γ (mevsimsellik) katsayılarının optimizasyonunda en etkili yöntemlerden biri olarak kabul edilen Diferansiyel Evrim Algoritması (DE) kullanılmıştır.

Holt-Winters parametre optimizasyon problemi doğrusal olmayan, karmaşık hata yüzeyine sahip ve çok sayıda yerel minimum içeren bir yapı göstermektedir. Klasik optimizasyon yöntemleri çoğu zaman yerel minimumlarda takılı kalabilirken, DE algoritması popülasyon tabanlı küresel arama mekanizması sayesinde çözüm uzayını geniş biçimde tarayarak daha düşük hata değerlerine ulaşabilmektedir. Özellikle zaman serisi tahmin problemlerinde kullanılan MSE, RMSE ve MAPE gibi hata fonksiyonlarının türevlenmesinin zor veya kararsız olduğu durumlarda algoritmanın gradyan bilgisine ihtiyaç duymadan çalışması Diferansiyel Evrim Algoritması için önemli avantaj sağlamaktadır [23]. Algoritmada yer alan mutasyon, çaprazlama ve seçim mekanizmaları sayesinde farklı parametre kombinasyonlarını sürekli güncellemesi, Holt-Winters modelinin veri setine özgü en uygun katsayılarını belirlemesini kolaylaştırmaktadır. Ayrıca algoritmanın keşif ve yoğunlaştırma arasında denge kurabilmesi, özellikle sezonsallık içeren zaman serilerinde daha hızlı yakınsama ve daha yüksek tahmin doğruluğu elde edilmesine katkı sağlamaktadır.

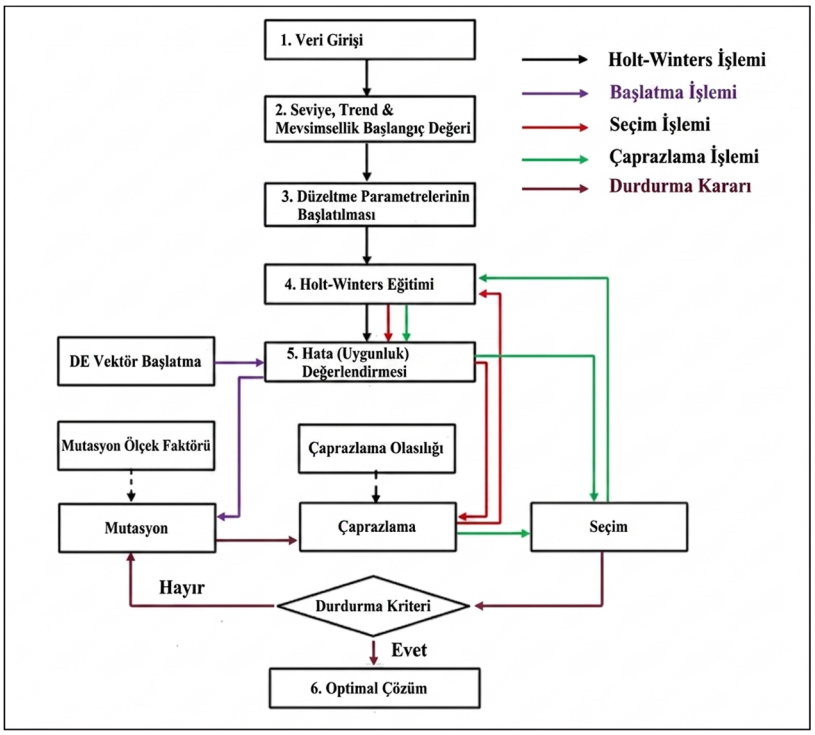
Literatürde Direransiyel Evrim algoritmasının sürekli optimizasyon problemlerinde oldukça güçlü bir küresel optimizasyon yöntemi olduğunu belirtirken, DE'nin karmaşık hata yüzeylerinde gerçek değerli parametre optimizasyonunda başarılı sonuçlar verdiğini göstermiştir [24]. Bu parametrelerin uygun seçilmemesi tahmin doğruluğunu ciddi şekilde düşürmektedir. Bu nedenle çalışma kapsamında parametre optimizasyonu problemi bir minimizasyon problemi olarak ele alınmıştır. Amaç fonksiyonu RMSE değerinin hata oranının minimizasyonudur:

Amaç Fonksiyonu

$$\text{Min } \left(\frac{1}{T} * \sum_i^T (F_i - Y_i)^2\right)^{1/2} \quad \text{i=P,……..T} \tag{6}$$

Kısıtlar:

$$0 \leq [\alpha i, \beta i, \gamma i] \leq 1 \tag{7}$$



Şekil 2. Differansiyel evrim algoritmasının Holt winters katsayılarını hesaplama algoritma akışı

Şekil 2 de gösterildiği üzere algoritma geliştirilen DE-HW Optimizasyonu algoritması parametre özellikleri ise öncelikle 3 parametreye (α (seviye), β (trend) ve γ (mevsimsellik)) göre ayarlanmıştır. Parametrelerin arama uzayında değer sınırları ise [0.0, 1.0]'dir. Başlangıç popülasyon büyüklüğü her bir parametre için 15 toplamda 45'dir. Algoritma maximum iterasyon ya da nesil sayısı olarak 100 belirlenmiştir. Çaprazlama Oranı (CR = 0.7), Mutasyon Faktörü (F = 0.5 - 1.0), Durma Toleransı (tol = 0.01) ve Mutasyon Stratejisi (best1bin) olarak belirlenmiştir.

2.2.3. Hibrit RF-LSTM Metodu

Bu çalışmada derin öğrenme tekniklerinin tahmin çalışmalarındaki yüksek performansları nedeni ile bu çalışmaya dâhil edilmiştir. Petrol verileri gibi yüksek değişkenlik, doğrusal olmayan dinamikler ve küresel şoklara bağlı düzensiz dalgalanmalar içeren zaman serilerinin tahmininde geleneksel doğrusal modeller yetersiz kalabilmektedir. Bu çalışmada tercih edilen hibrit RF-LSTM yöntemi; Rastgele Orman (RF) algoritmasının çok boyutlu veri yapılarındaki karmaşık etkileşimleri çözme ve aşırı öğrenmeyi engelleme gücünü, Uzun Kısa Süreli Bellek (LSTM) ağlarının zamansal ardışık bağımlılıkları ve uzun vadeli trendleri yakalama kabiliyetiyle birleştirmektedir. Literatürde, makine öğrenmesi ve derin öğrenmenin bu tür hibrit kombinasyonlarının, enerji piyasalarındaki ani yapısal kırılmaları ve karmaşık kalıpları modellemede tekil tahmin yöntemlerine kıyasla anlamlı derecede daha yüksek doğrusal kararlılık ve düşük hata payı sunduğu ortaya konmuştur [25].

Rastgele Orman (Random Forest-RF), Leo Breiman tarafından geliştirilen, karar ağaçlarına dayalı topluluk öğrenme yöntemidir ve hem sınıflandırma hem de regresyon problemlerinde yaygın olarak kullanılmaktadır [26]. RF'nin temel amacı, torbalama örnekleme yöntemiyle oluşturulan çok sayıdaki bağımsız karar ağacının çıktılarının regresyon problemlerinde ortalama alınarak birleştirilmesi sayesinde verideki yüksek varyansı azaltmak ve tek bir karar ağacında görülebilen aşırı uyum problemini önlemektir [27]. Özellikle zaman serisi tahmini gibi yüksek değişkenlik içeren veri setlerinde, her bir karar ağacından elde edilen tahminlerin bir araya getirilmesi modelin genelleme performansını artırmakta, aykırı değerlere karşı daha dayanıklı ve kararlı sonuçlar üretmesini sağlamaktadır. RF tahmin süreci matematiksel olarak aşağıdaki şekilde ifade edilmektedir [26]:

$$\widehat{Y_{RF}} = \frac{1}{\mathrm{B}}\sum_{b=1}^{B} T_b(x;\circledast_b) \tag{8}$$

Burada:

- $\widehat{Y_{RF}}$: RF modelinin nihai tahmin değeridir.
- B : Ormandaki karar ağacı sayısını ifade eder (*bu çalışmada B = 100'dür?).*
- $T_b(x;\circledast_b)$: Geri koymalı örnekleme yöntemiyle elde edilen $\circledast_b$ parametresine sahip b'inci karar ağacının, x girdisi için ürettiği tahmindir.

Uzun Kısa Vadeli Bellek-LSTM yöntemi, RNN (Tekrarlayan Yapay Sinir Ağı) modelinin özelleşmiş bir türüdür. LSTM sinir ağları, tekrarlayan yapay sinir ağları (RNN) ile benzer bir mimariyi paylaşsalar da, önemli avantajlar sunan benzersiz bir yapay sinir ağı sınıfını temsil ederler. Önceki bir adımın çıktısını bir sonraki adımın girdisi olarak kullanan standart RNN'ler, ardışık adımlarla ilerler ve kısa vadeli bellekleri ile sınırlıdırlar. Bu özellik, onları doğal dil işleme ve zaman serisi analizi gibi ardışık veri problemlerini çözmede etkili kılar. Ancak, uzun vadeli bağımlılıkları öğrenme ve akılda tutma konusundaki sınırlılıkları nedeniyle, ağın işleyişinin erken aşamalarında kritik bilgiler sıklıkla kaybolabilmektedir.

LSTM mimarisi, geleneksel RNN'lerde bulunan bu zorlu kayıp senaryolarının üstesinden gelmek için özel olarak tasarlanmıştır. LSTM hücrelerinin tasarımı, bilgi akışını düzenleyen ve kontrol eden "kapıları" içerir. Bu yapı içinde, unutma kapısı hücre durumu içindeki hangi bilgilerin tutulacağını veya atılacağını belirlerken, girdi kapısı hücreye yeni bilgilerin ne kadarının ekleneceğine karar verir. Ardından hücre durumu bu kararlara göre güncellenerek bilginin uzun vadeli bellekte saklanması sağlanır. Son olarak, çıktı kapısı güncellenmiş hücre durumuna dayanarak gizli durumu (h_t) üretir ve bu durum bir sonraki adıma girdi olarak aktarılır.

Bir Uzun Kısa Vadeli Bellek (LSTM) hücresinin dinamik durumu dört temel bileşen tarafından tanımlanır: girdi kapısı (i_t), unutma kapısı (f_t), çıktı kapısı (o_t) ve hücre durumu (C_t). Bu kapılar; önceki gizli durumu

(h_{t-1}) ve mevcut girdi vektörünü (x_t) dahil ederek, sigmoid (σ) ve hiperbolik tanjant (tanh) aktivasyon fonksiyonları kullanılarak formüle edilir [28]. Bu çalışmadaki modelin çıktısı ise $\widehat{Y_{LSTM}}$'dir. Bu ilişkiler aşağıdaki formüllerle ifade edilir:

a) *Unutma Kapısı* f_t, bir önceki hücre durumundan C_{t-1}'den hangi bilgilerin kaldırılacağına karar verir:

$$f_t = \sigma\,(W_f[h_{t-1}, x_t\,] + b_f) \tag{9}$$

b) *Girdi Kapısı* i_t *ve Aday Durum* $\widetilde{C_t}$, hücre durumunda hangi yeni bilgilerin depolanıp depolanmayacağını belirler:

$$i_t = \sigma\,(W_i[h_{t-1}, x_t\,] + b_i) \tag{10}$$

$$\widetilde{C_t} = \tanh(W_c[h_{t-1}, x_t\,] + b_c) \tag{11}$$

c) *Hücre Durum Güncelleme* C_t, eski hücre durumunu yeni hücre durumuna günceller:

d)

$$C_t = f_t * C_{t-1} + i_t * \widetilde{C_t} \tag{12}$$

e) *Çıktı Kapısı* o_t *ve Gizli Durum* h_t, güncellenmiş hücre durumuna göre çıktıyı belirler:

f)

$$o_t = \sigma\,(W_o[h_{t-1}, x_t\,] + b_o) \tag{13}$$

$$h_t = o_t \odot \tanh(C_t) \tag{14}$$

σ sigmoid aktivasyon fonksiyonunu, W ve *b* eğitim süreci boyunca ağırlık ve bias matrislerini temsil etmektedir.

Zaman serisi verileri genellikle uzun vadeli eğilim (trend) ve döngüsel dalgalanmalar (artıklar/residuals) içerir [25]. Derin öğrenme modellerinin (özellikle LSTM) doğrudan zaman indeksiyle eğitilmesi, geleceğe yönelik tahminlerinde modelin trendi ezberlemesine ve aşırı uyum göstermesine neden olmaktadır.

Bu çalışmada, zaman serisi verilerindeki doğrusal olmayan eğilimleri modellemek ve ana sinyalden ayrıştırmak amacıyla [25] , karar ağaçlarına dayalı bir topluluk öğrenme yöntemi olan Rastgele Orman (RF) algoritması kullanılmıştır. RF algoritması, hem sınıflandırma hem de regresyon problemlerinde yüksek boyuttaki karmaşık veri setleriyle çalışırken sergilediği kararlı performans ile bilinmektedir. Algoritmanın temel amacı, çok sayıda bağımsız karar ağacı inşa ederek bunların çıktılarını birleştirmek, böylece tek bir karar ağacının barındırdığı aşırı uyum riskini ve varyansı minimize etmektir.

Hibrit model çerçevesinde, zaman serisinin barındırdığı yapının LSTM tarafından iyi öğrenilmesi gerekmektedir ancak bu yöntemin eğitim veri setini ezberlemesine neden olmaktadır. LSTM yönteminin veri setini ezberlenmesini önlemek amacıyla bir "trend çıkarma" işlemi uygulanmıştır. Zaman serisinin indeks değerleri bağımsız değişken, serinin gözlem değerleri ise bağımlı değişken olarak kurgulanmıştır. Trend bileşeninin başarılı bir şekilde izole edilmesi için kullanılan RF modelinde hiperparametreler; ağaç sayısı (B) 100 ve maksimum ağaç derinliği 6 olarak belirlenmiştir.

Rastgele Orman (RF) modeline ait ağaç sayısı (B) 100 ve maksimum ağaç derinliği 6 hiperparametreleri, literatürdeki çalışmalar incelenerek ve kural tabanlı yaklaşımlar dikkate alınarak seçilmiştir. RF modellerinde ağaç sayısının 64 ila 128 arasında seçilmesinin asimptotik varyansı dengelemek ve kararlı tahminler üretmek için yeterli olduğu, 100 ağaç değerinin optimum başarım sağladığı gösterilmiştir [29]. Önceki çalışmalar, RF' de derinlik parametresinin doğrudan model karmaşıklığını kontrol ettiğini ve sınırlı derinliğin bir düzenlileştirme işlevi görerek varyansı düşürdüğünü göstermiştir. Bu nedenle bu çalışmada RF'de maksimum ağaç derinliğin 6 sınırlandırılması ise zaman serisi ayrıştırma üzerine yapılan çalışmalar dikkate alınarak karar verilmiştir [30].

Geliştirilen RF modeli, gözlenen zaman serisi verisi üzerinde eğitilerek makro eğilimi (T_t) hesaplamıştır. Gerçek gözlem değerlerinden (Y_t) bu makro eğilim çıkarılarak saf sinyal, yani kalıntılar/artıklar (R_t) elde edilmiştir [25]:

$$R_t = Y_t - T_t \tag{15}$$

Bu matematiksel operasyon sayesinde, veri setindeki aşırı veya ani dalgalanmalar karşısında dirençli olan RF algoritması, serinin doğrusal olmayan genel gidişatını yakalamış; geriye kalan durağana yakın durağan ve döngüsel sinyal (R_t) ise çok değişkenli LSTM modeline girdi olarak beslenmek üzere hazır hale getirilmiştir.

1. Adım: Zaman serisinin zamansal indeks yapısı kullanılarak (ağaç sayısı, B=100) ve maksimum ağaç derinliği ise 6 olarak belirlendiği parametrelere sahip bir RF Regressor modeli eğitilir ve serinin makro trend bileşeni (T_t) tahmin edilmiştir.
2. Artık Sinyalin hesaplaması ve ölçeklendirme de ise gerçek verilerden RF trend çıktısı çıkarılarak eğilimden arındırılmış artık sinyal (R_t) üretilir. Elde edilen artıklar, ortalaması 0, varyansı 1 olacak şekilde normalize edilmiştir.
3. Çok değişkenli girdi matrisinin oluşturulmasında ise ölçeklendirilmiş artık serisine, zamansal döngüselliği temsil etmek üzere sinüs ve kosinüs dönüşümleri uygulanmış sinüs ve kosinüse bağlı çok değişkenli veri matrisi inşa edilmiştir.
4. Kaydırıcı pencere ve veri bölümlemede ise oluşturulan matris, 24 aylık geriye dönük pencereler halinde katlanarak zaman serisi dizilerine dönüştürülür. Veri seti zamansal bütünlüğü korunarak %80 eğitim ve %20 test (doğrulama) olarak ikiye ayrılmıştır.

Modelin doğruluğunu en üst düzeye çıkarmak ve aşırı uyumu engellemek adına çapraz doğrulama ve parametre optimizasyonu yaklaşımlarına paralel olarak Optuna kütüphanesi entegre edilmiştir. TPE (Tree-structured Parzen Estimator) örnekleyicisi kullanılarak 25 iterasyon boyunca LSTM mimarisinin gizli katman boyutu [16,64], öğrenme oranı [0,001- 0,005] ve ağırlık azaltma [0,0001-0,01] hiperparametreleri optimize edilmiştir. Nihai üretim modelinden elde edilen ölçeklendirilmiş artık tahminleri, ters dönüşüm işlemine tabi tutulmuş ve RF modelinin geleceğe yönelik ürettiği makro trend tahminleri ($T_{gelecek}$) ile matematiksel olarak birleştirilerek nihai tahmin değerlerine ulaşılmıştır. Modelin genelleştirme yeteneği Kök Ortalama Kare Hata (RMSE), Ortalama Kare Hata (MSE), Ortalama Mutlak Yüzde Hata (MAPE) ve Ortalama Mutlak Sapma (MAD) metrikleri kullanılarak kontrol edilmiştir.

2.2.4. Hata Metrikleri

Bu çalışmada tahmin modellerinin performanslarını karşılaştırmak için MAPE, MSE, RMSE ve MAD hata metrikleri kullanılmıştır. Her bir hata metriğinin ölçtüğü ve ele aldığı tahmin kriterleri birbirinden farklıdır. MSE büyük hataları daha çok cezalandırırken, MAPE hataları yüzde olarak ifade etmekte ve MAD ise hataların yönüne bakmaksızın ortalama mutlak hata değeri sunmaktadır. MAPE yüzde cinsinden sunulduğu için, en sezgisel ve anlaşılması kolay öngörü hatası ölçütlerinden biri olarak kabul edilir [31].

MAPE Ortalama Mutlak Yüzde Hata metriğinin formülü aşağıdaki gibidir:

$$\text{MAPE}= \%100/n*\sum_{i=1}^{n}\left|\frac{y_i-\tilde{y}_i}{y_i}\right| \tag{16}$$

MAD, Ortalama Mutlak Sapma, gerçek değerler ile tahmin edilen değerler arasındaki dikey mesafenin (hatanın) yönüne (pozitif/negatif) bakmaksızın büyüklüğünü ölçer ve MAD hata metriğinin formülü aşağıdaki gibidir:

$$\text{MAD}= (1/n)*\sum_{i=1}^{n}|y_i-\tilde{y}_i| \tag{17}$$

MSE Ortalama Kare Hata, hataların karelerini alarak ölçüm yapan metriğin formülü aşağıdaki gibidir:

$$\text{MSE} = \frac{1}{n}\sum_{i=1}^{n}(y_i - \hat{y}_i)^2 \tag{18}$$

RMSE, Kök Ortalama Kare Hata, hataların karelerinin ortalamasının karekökünü alarak ölçüm yapan metriğin formülü aşağıdaki gibidir:

$$\text{RMSE} = \sqrt{\sum_{i=1}^{n} \frac{(y_i - \tilde{y}_i)^2}{n}} \tag{19}$$

Yukarıda belirtilen formüllerde y_i, gerçek değeri; $\tilde{y}_i$, tahmin değeri; n, veri sayısı ifade etmektedir.

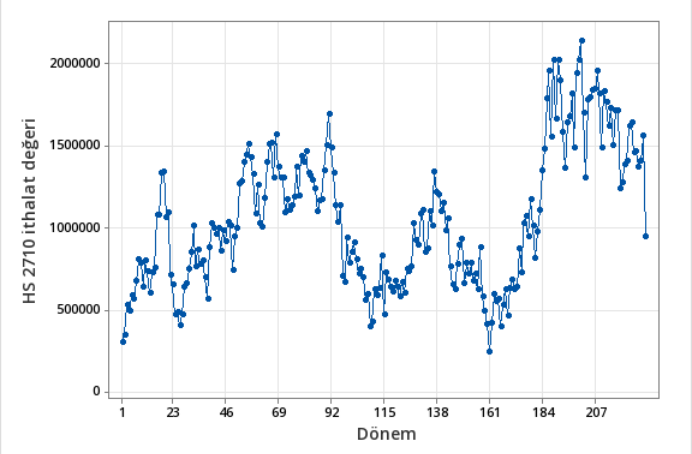
3. BULGULAR VE TARTIŞMA

Bu bölümde, Türkiye'nin GTİP 2710 kodlu ürününe ilişkin aylık ithalat değerlerinin tahmin edilmesi amacıyla ARIMA/SARIMA, DE-HW ve Hibrit RF–LSTM modellerinden elde edilen bulgular sunulmuş ve karşılaştırmalı olarak değerlendirilmiştir. Bu çalışmada önerilen makine öğrenmesi ve meta-sezgisel optimizasyon modellerinin geliştirilmesi, eğitilmesi ve test edilmesi süreçleri; x64 tabanlı çok çekirdekli bir işlemci mimarisi ve 64-bit işletim sistemi altyapısına sahip bir bilgisayar üzerinde gerçekleştirilmiştir. Kodlama ve algoritma entegrasyonu süreçlerinde geliştirme ortamı olarak Visual Studio Code (VS Code) tercih edilmiş olup, tüm sayısal analizler ve modelleme optimizasyonları Python programlama dili kullanılarak yürütülmüştür. Modellerin tahmin performansları MAD, MAPE, MSE ve RMSE hata ölçütleri temelinde incelenmiş; elde edilen sonuçlar doğrultusunda modellerin tahmin başarıları karşılaştırmalı olarak ele alınmıştır.

3.1. ARIMA/SARIMA Modeli Bulguları

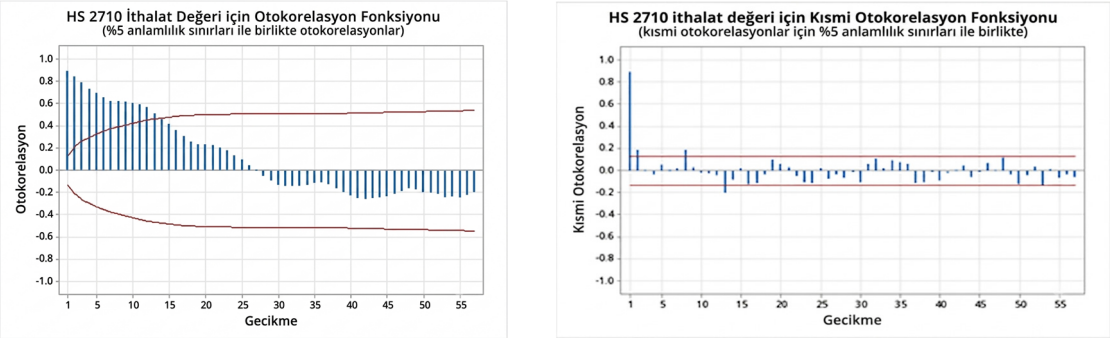
GTİP 2710 kodlu ürüne ilişkin aylık ithalat değerlerine uygun ARIMA modelinin belirlenmesi için Minitab 22 istatistik paket programı kullanılmıştır. Bölüm 2.2.1'de belirtildiği üzere, seri için en uygun ARIMA modelinin belirlenmesinde ilk adım serinin durağanlığının incelenmesidir. Bu amaçla, öncelikle görsel yöntemler kullanılarak bir ön değerlendirme yapılmıştır.

Şekil 3'te sunulan GTİP 2710 petrol ürünleri ithalat değerlerine ait zaman serisi grafiği, serinin dönemler itibarıyla dalgalı bir seyir izlediğini ve belirli dönemlerde artış eğilimi gösterebildiğini ortaya koymaktadır. Grafiksel inceleme, seride olası eğilim ve mevsimsel hareketlerin bulunabileceğine ilişkin ön bir değerlendirme sunmakla birlikte, bu yapıların varlığının istatistiksel testler ve modelleme süreciyle ayrıca doğrulanması gerekmektedir.



Şekil 3. GTİP 2710 ithalat değeri zaman serisi grafiği

Şekil 4'de ise, serinin ACF ve PACF grafikleri verilmiştir. ACF grafiğinde, ilk gecikmelere ait otokorelasyon katsayılarının yüksek olduğu ve gecikme sayısı arttıkça kademeli olarak azaldığı görülmektedir. Bu durum, serinin durağan olmadığını ve trend yapısı içerdiğine dair bilgi vermektedir. PACF grafiğinde ise birinci gecikmede güçlü ve anlamlı bir kısmi otokorelasyon değeri gözlenirken, sonraki gecikmelerin büyük ölçüde anlamlılık sınırları içerisinde kaldığı görülmektedir. Bu bulgular, serinin düzey değerlerinde durağan olmadığını ve ARIMA/SARIMA modellemesi öncesinde fark alma işleminin uygulanması gerektiğini ortaya koymaktadır.



Şekil 4. GTİP 2710 ithalat değeri ACF ve PACF grafiği

Serinin durağanlığına ilişkin görsel değerlendirmelerin istatistiksel olarak da desteklenmesi amacıyla Genişletilmiş Dickey–Fuller (ADF) birim kök testi uygulanmıştır. ADF testinde sıfır hipotezi (H_0), serinin birim kök içerdiğini ve dolayısıyla durağan olmadığını; alternatif hipotez (H_1), ise serinin durağan olduğunu ifade etmektedir. ADF testine ilişkin sonuçlar Çizelge 1'de sunulmuştur.

Çizelge 1. GTİP 2710 ithalat değerleri serisi için ADF birim kök testi sonuçları

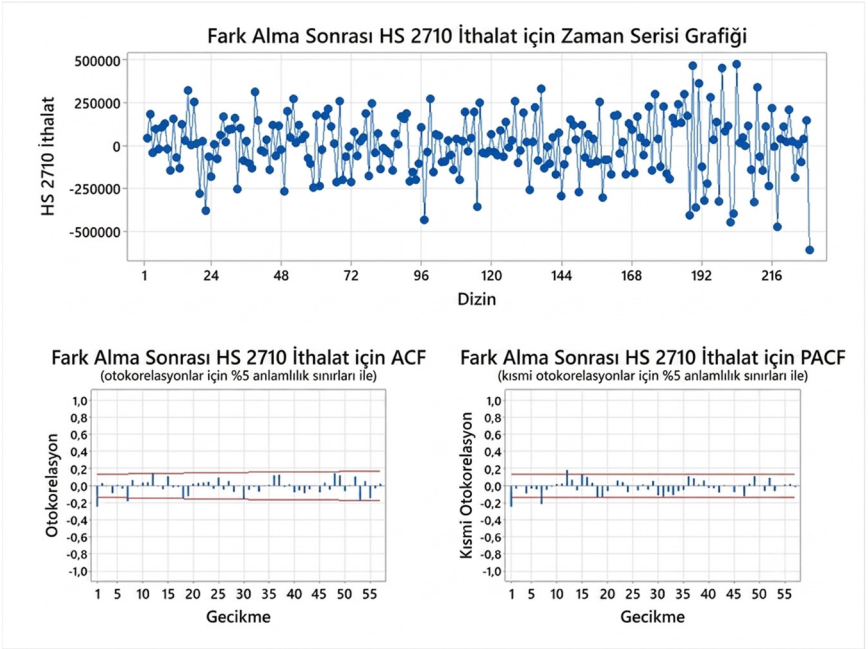
Test istatistiği	Kritik değer(%5)	p-değeri	Karar	Öneri
-2,86987	-2,87436	0,05	H_0 red edilememiştir	Fark alma işlemi uygulanmalıdır

ADF testi sonucunda test istatistiği -2,86987; %5 anlamlılık düzeyindeki kritik değer ise -2,87436 olarak elde edilmiştir. Test istatistiği kritik değerden daha küçük olmadığından sıfır hipotezi reddedilememiştir. Bu nedenle seri düzey değerlerinde durağan kabul edilmemiştir. Bu doğrultuda, modelleme öncesinde serinin durağanlaştırılması amacıyla birinci dereceden fark alma işlemi uygulanmış ve seri durağanlaştırılmıştır.

Durağanlaştırılmış seriye ilişkin ADF testi sonuçları Çizelge 2'de sunulmuş; serinin zaman serisi grafiği ile ACF ve PACF grafikleri ise Şekil 5'de gösterilmiştir.

Çizelge 2. Farkı alınmış GTİP 2710 ithalat değerleri serisine ilişkin adf birim kök testi sonuçları

Test istatistiği	Kritik değer(%5)	p-değeri	Karar	Öneri
-7,007	-2,87436	0,05	H_0 red edilir	Fark alma işlemi uygulamaya gerek yoktur



Şekil 5. Farkı alınmış GTİP 2710 ithalat değerleri serisine ait zaman serisi, ACF ve PACF grafikleri

Fark alma işlemi sonrasında elde edilen durağan seriye ilişkin ADF birim kök testi sonuçları ve serinin zaman serisi, ACF ve PACF grafikleri birlikte değerlendirildiğinde, serinin modelleme için uygun hale geldiği görülmektedir. ACF ve PACF grafikleri, serideki otokorelasyon yapısının belirlenmesi ve uygun ARIMA/SARIMA model bileşenlerinin seçilmesi açısından ön bilgi sağlamaktadır. Bu grafiksel incelemeler ve model denemeleri doğrultusunda, GTİP 2710 ithalat değerleri serisi için en uygun model belirlenmiş ve modele ait parametre tahmin sonuçları Çizelge 4'de sunulmuştur.

Çizelge 4. GTİP 2710 ithalat değerleri serisine ait ARIMA/SARIMA modeli parametre tahmin sonuçları

Test istatistiği	Kritik değer(%5)	p-değeri	Karar	Öneri
AR(1)	-0,2682	0,0660	-4,07	0,000
SMA(12)	-0.2300	0.0692	-3,33	0,001

Nihai model sonuçlarına göre, AR(1) parametresinin katsayısı -0,2682 olup istatistiksel olarak anlamlıdır ($p < 0,05$). Bu bulgu, farkı alınmış GTİP 2710 ithalat değerleri serisinde kısa dönemli otoregresif bir ilişkinin bulunduğunu göstermektedir. Diğer bir ifadeyle, serinin mevcut dönem değerleri üzerinde bir önceki döneme ait değerlerin anlamlı bir etkisi bulunmaktadır. Bununla birlikte, 12 dönemlik mevsimsel hareketli ortalama parametresi SMA(12) de istatistiksel olarak anlamlı bulunmuştur ($p < 0,05$).
Aylık veri yapısında 12 dönemlik gecikme yıllık periyoda karşılık geldiğinden, bu sonuç seride yıllık dönemli mevsimsel hata bileşeninin modele anlamlı katkı sağladığını göstermektedir. ACF ve PACF grafiklerinde güçlü ve düzenli bir mevsimsel yapı belirgin biçimde gözlenmemekle birlikte, SMA(12) parametresinin anlamlılığı seride zayıf ancak istatistiksel olarak dikkate alınması gereken bir mevsimsel etkinin bulunduğunu düşündürmektedir.

Bu nedenle, nihai model seçiminde yalnızca grafiksel incelemeler değil, parametrelerin istatistiksel anlamlılığı ve model uygunluk ölçütleri de birlikte değerlendirilmiştir. Elde edilen bulgular doğrultusunda, GTİP 2710 ithalat değerleri serisinin modellenmesinde AR(1) ve SMA(12) bileşenlerini içeren SARIMA yapısının uygun olduğu sonucuna ulaşılmıştır.

Bir sonraki aşamada, tahmin edilen SARIMA modeline ait hata terimlerinin beyaz gürültü özelliği gösterip göstermediğinin değerlendirilmesi amacıyla tanısal kontroller gerçekleştirilmiştir. Bu kapsamda, model artıklarında otokorelasyon bulunup bulunmadığını test etmek için Ljung–Box Q testi uygulanmıştır. Test sonuçlarına göre 12. ve 24. gecikmelerde elde edilen p-değerleri sırasıyla 0,143 ve 0,066 olup 0,05 anlamlılık düzeyinin üzerindedir. Bu durum, model artıklarında kısa ve orta dönemli gecikmeler açısından istatistiksel olarak anlamlı bir otokorelasyon bulunmadığını göstermektedir. Bu doğrultuda, belirlenen $SARIMA(1,1,0)(0,0,1)_{12}$ modelinin GTİP 2710 ithalat değerleri serisinin tahmininde kullanılabilir nitelikte olduğu değerlendirilmiştir. Önerilen modele ait hata ölçütleri Çizelge 5'de verilmiştir.

Çizelge 5. GTİP 2710 ithalat değerleri serisine ait ARIMA/SARIMA modeli sonuçları

Hata metriği	Değer
MSE	28.856.200.000
RMSE	169.871
MAD	131.391,4
MAPE	%13,72

3.2. DE Optimize Holt-Winters Modeli Bulguları

Zaman serisinin doğrusal olmayan trend ve kararlı mevsimsel yapısını eş zamanlı olarak modelleyebilmek adına Toplamsal Holt-Winters yöntemi uygulanmış; modelin dinamiklerini belirleyen düzeltme parametreleri Diferansiyel Evrim (DE) algoritması ile RMSE objektif fonksiyonu minimize edilerek optimize edilmiştir. Küresel optimizasyon işlemi oldukça hızlı 2 saniye gibi kısa bir sürede yakınsamıştır. Optimizasyon süreci neticesinde elde edilen parametre değerleri şu şekildedir:

- Seviye düzeltme parametresi (α), zaman serilerindeki rastgele faktörlerin (yani gürültünün) etkisini azaltmaya yardımcı olan değer: 0,6272
- Trend düzeltme parametresi (β), Mevcut dönem ile bir sonraki dönem arasında temel düzeyde meydana gelmesi beklenen değişimi temsil eden değer: 0,0219

- Mevsimsellik düzeltme parametresi (γ), zaman serisi verilerinin her dönemde tekrar eden bir davranış gösterme eğilimini ifade eden değer: 0,0639

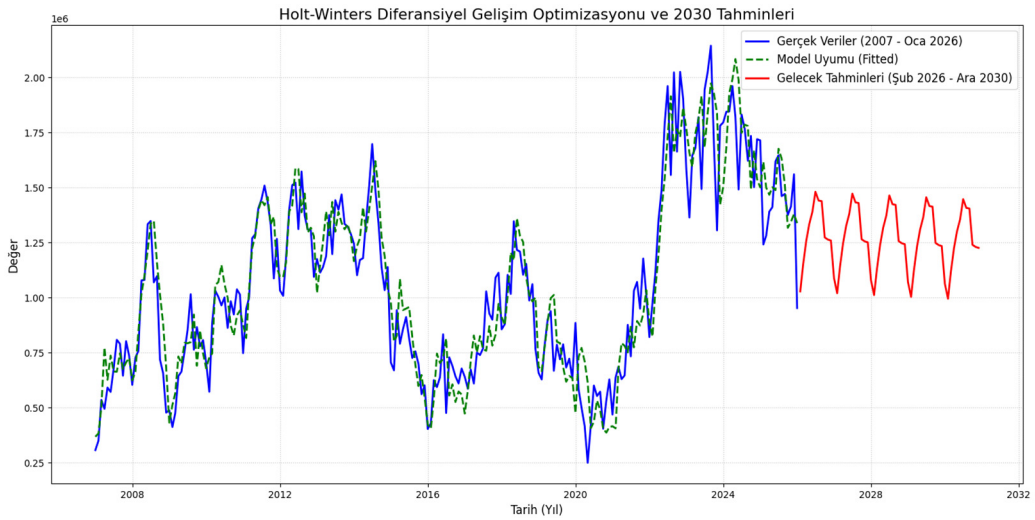
Yüksek bir α değeri (0,6272), modelin petrol ürünleri ithalatındaki güncel değişimlere ve yapısal dalgalanmalara karşı oldukça duyarlı olduğunu ve yakın geçmişteki verilere daha fazla ağırlık verdiğini göstermektedir. Buna karşın, oldukça düşük hesaplanan β (0,0219) ve γ (0,0639) parametreleri, serinin uzun vadeli trend ivmesinin ve mevsimsel kalıplarının zaman içinde ani kırılmalara uğramadan, kararlı ve yumuşatılmış bir yapıda korunduğunu doğrulamaktadır.

DE-HW modelinin geçmiş veriler üzerindeki uyum başarısını ve genelleme yeteneğini ölçmek amacıyla literatürde sıklıkla başvurulan hata metrikleri hesaplanmıştır. Elde edilen istatistiksel sonuçlar Çizelge 6'da sunulmuştur.

Çizelge 6. GTİP 2710 ithalat değerleri serisine ait DE-HW Modeli Sonuçları

Hata metriği	Değer
MSE	26.046.034.698,91
RMSE	161.387,84
MAD	125.340,10
MAPE	%13,70

DE optimize Holt-Winters Modelin ortalama mutlak yüzde hatası (MAPE) %13,70 olarak elde edilmiştir. Petrol piyasası gibi küresel krizlerden, jeopolitik risklerden ve makroekonomik değişimlerden doğrudan etkilenen yüksek değişkenlik gösteren bir veri setinde %13,70'lik bir yüzdesel hata payı, geliştirilen meta-sezgisel tabanlı modelin yüksek doğrulukta kararlı tahminler üretebildiğinin güçlü bir kanıtıdır.



Şekil 6. DE-HW Metodu ile geliştirilmiş GTİP 2710 ithalat değerleri serisine ait gerçek değer ve tahmin değerleri

Optimum parametrelerle çalıştırılan model, Şubat 2026 ile Aralık 2030 arasındaki dönemi kapsayan toplam 59 aylık bir tahmin üretmesi için çalıştırılmıştır. Modelden elde edilen makro düzeydeki yıllık öngörü değerleri Şekil 6'da görselleştirilmiştir. Tahmin çıktıları incelendiğinde, petrol ürünleri ithalatının gelecekteki seyrine dair iki önemli karakteristik bulgu öne çıkmaktadır. Modelin ürettiği sonuçlar incelendiğinde mevsimsel kararlılık vardır Model, geçmiş verilerden öğrendiği mevsimsel döngüyü başarılı bir şekilde geleceğe taşımıştır. Her yılın Temmuz ayında ithalatta zirve noktalarına ulaşılırken, kış aylarında ithalat talebinin dibe vurduğu periyodik dalga yapısı net bir şekilde izlenebilmektedir. Model, 2024 yılı sonrasında veride gözlenen doygunluk ve düşüş eğilimini yakalayarak 2026-2030 aylık tahminlerinin rasyonel bir trend bileşeni olarak yansıtmıştır. Yıllar itibariyle tepe ve dip noktalarının mutlak büyüklüklerinde radikal kırılmalar olmaksızın, uzun vadede hafif seyirli ve dengeli bir gerileme eğilimi öngörülmüştür. Bu kararlı yapı, DE algoritmasının yerel çözümlere takılmadan global optimum parametreleri bularak modelin aşırı öğrenmesini ve gelecek tahminlerinde mantıksız patlamalar yapmasını engellediğini ortaya koymaktadır.

3.3. Hibrit RF-LSTM Modeli Bulguları

Geliştirilen hibrit modelin artık bileşenini tahmin eden çok değişkenli LSTM mimarisinin hiper parametreleri, Bayesyen Optimizasyon tabanlı Optuna algoritması kullanılarak 25 iterasyon boyunca optimize edilmiştir. Yapılan deneysel simülasyonlar sonucunda, en düşük doğrulama hatasını veren optimum mimari yapıyı modelin gizli katmanında 16 nöron kullanılmasına ve ağın 200 epok (eğitim döngüsü) boyunca AdamW optimize edici eşliğinde eğitilmesine karar verilmiştir. Optimizasyon sonucunda en uygun öğrenme oranı 0,001285, regülasyon katsayısı ise 0,000130 olarak belirlenmiştir. RF modelinde ise ağaç sayısı, B=100) ve maksimum ağaç derinliği ise 6 olarak belirlendiği parametrelere sahip bir RF Regressor modeli çalıştırılmıştır.



Şekil 7. Hibrit RF-LSTM Modeli ile geliştirilmiş GTİP 2710 ithalat değerleri serisine ait gerçek değer ve tahmin değerleri

Şekil 7 incelendiğinde başlangıçtan 2026 yılına kadar olan Mavi çizgi (Gerçek veri) ile yeşil/turuncu çizgiler (Modelin tahminleri) neredeyse birebir örtüştüğü görülmektedir. Özellikle 2012 ve 2024'teki büyük zirveleri ve 2016 ile 2020'deki sert düşüşleri model başarıyla yakalamıştır. Zaman serilerindeki bu ani dönüşleri yakalamak modeller için oldukça zordur; Hibrit model burada çok başarılı bir modelleme göstermiştir.

Trend ayrıştırma yaklaşımıyla entegre edilen önerilen hibrit modelin çerçevesinin deneysel bulguları, incelenen zaman çizelgesi boyunca güçlü bir tahmin kabiliyeti ortaya koymaktadır. Modelin performansı, yüksek ölçekli zaman serisi tahminlerinde oynaklık ve doğruluğu değerlendirmek için MSE, RMSE ve MAD nin yanı sıra özellikle standart bir metrik olan Ortalama Mutlak Yüzde Hata (MAPE) kullanılarak da titizlikle test edilmiştir. Elde edilen değerler Çizelge 7'de verilmiştir.

Çizelge 7. GTİP 2710 ithalat değerleri serisine ait Hibrit RF-LSTM Modeli Sonuçları

Hata metriği	Eğitim hata değeri	Doğrulama hata değeri
MSE	5.875.879.172,91	11.301.858.588,80
RMSE	76.654,28	106.310,20
MAD	60.712,13	87.070,82
MAPE	%7,48	%5,45

Yapay Sinir ağlarında tahmin verilerine ait modellerde karşılaşılan en büyük problemlerden biri modelin veriye göre daha az uygun olması ya da modelin veriyi aşırı derecede ezberleyerek olmasıdır. Çizelge 7'de gösterilen değerler incelendiğinde hibrit modelin, %7,48 gibi oldukça düşük bir Eğitim MAPE değeri elde ederek tarihsel veriler içindeki karmaşık zamansal bağımlılıkları ve doğrusal olmayan kalıpları yakalama konusunda oldukça iyi bir başarı göstermiştir. Ayrıca doğrulama MAPE değeri %5,45 olarak kaydedilmiştir. Eğitim ve doğrulama hataları arasındaki çok küçük olan %2 'lik bir fark ise, hibrit modelin aşırı öğrenme riskini başarılı bir şekilde hafiflettiğini ve veri noktaları üzerinde yüksek genelleme yeteneğine sahip olduğunu yapısal olarak kanıtlamaktadır.

4. SONUÇLAR

Bu çalışmada, Türkiye'nin 2710 GTİP kodlu petrol ve petrol ürünleri ithalat verileri kullanılarak, ekonomik açıdan stratejik öneme sahip bu ürün grubunun 2030 yılına kadar olan ithalat değerlerinin tahmin edilmesi amaçlanmıştır. Bu doğrultuda, geleneksel zaman serisi yaklaşımlarından ARIMA/SARIMA modelleri ile meta-sezgisel optimizasyon temelli DE-HW ve makine öğrenmesi tabanlı hibrit RF-LSTM modelleri uygulanmıştır. Geliştirilen modellerin tahmin performansları MSE, RMSE, MAD ve MAPE hata ölçütleri kullanılarak karşılaştırılmış ve böylece 2710 GTİP kodlu petrol ürünleri ithalatı için en uygun tahmin yaklaşımının belirlenmesi hedeflenmiştir. Çizelge 8 'de modellerden elde edilen tahmin hata değerleri, GTİP 2710 (petrol yağları ve bitümenli minerallerden elde edilen yağlar) faslı altındaki ithalat değerlerinin tahmininde geleneksel istatistiksel yaklaşımlar ile modern makine öğrenmesi tabanlı hibrit mimarilerin tahmin performanslarını hata metrikleri ile ortaya konulmuştur.

Çizelge 8. GTİP 2710 ithalat değerleri için ARIMA/SARIMA, DE-HW, Hibrit RF-LSTM Modelleri hata metrikleri

Yöntem/Hata metriği	MSE	RMSE	MAD	MAPE
ARIMA/SARIMA	28.856.200.000,00	169.871,00	131.391,40	%13,72
HW-DE	26.046.034.698,91	161.387,84	125.340,10	%13,70
Hibrit RF-LSTM	11.301.858.588,80	106.310,20	87.070,82	%5,45

Elde edilen bulgular, ARIMA/SARIMA modelinin %13,72 düzeyindeki MAPE ve 28.856.200.000,00 düzeyindeki MSE değeri ile belirli bir tahmin performansı sunduğunu; ancak ithalat verilerinde gözlenen ani dalgalanmalar, yapısal değişimler karşısında hibrit RF-LSTM modeline kıyasla daha sınırlı bir doğruluk düzeyine ulaştığını göstermektedir.

Benzer şekilde, HW-DE modeli de %13,70 MAPE ve 161.387,84 RMSE değerleriyle ARIMA/SARIMA modeline oldukça yakın bir performans sergilemiştir. Bu sonuç, meta-sezgisel optimizasyon desteğiyle geliştirilen HW-DE yaklaşımının geleneksel modellere kıyasla az miktarda da olsa iyileştirici bir katkı sağlayabildiğini, ancak doğrusal olmayan örüntülerin ve zaman içindeki karmaşık bağımlılıkların modellenmesinde geliştirilen hibrit RF-LSTM modelinin daha güçlü bir tahmin performansı ortaya koyduğunu göstermektedir. Önerilen Hibrit RF-LSTM modeli tüm hata ölçütleri açısından diğer modellere kıyasla daha düşük hata değerleri üretmiştir. Modelin MSE değeri 11.301.858.588,80; RMSE değeri 106.310,20; MAD değeri 87.070,82 ve MAPE değeri %5,45 olarak hesaplanmıştır. Bu sonuçlar, RF-LSTM modelinin hem hata büyüklüğü hem de oransal tahmin doğruluğu açısından karşılaştırılan diğer yöntemlere göre daha az hata içeren sonuçlar verdiğini ortaya koymaktadır.

Bu bağlamda elde edilen bulgular, küresel şoklara ve dış ticaret koşullarındaki değişimlere duyarlılık gösteren ithalat serilerinin modellenmesinde, makine öğrenmesi ve derin öğrenme temelli hibrit yaklaşımların geleneksel zaman serisi modellerine kıyasla daha yüksek tahmin performansı sunma potansiyeline sahip olduğunu göstermektedir. Karşılaştırmalı hata ölçütleri dikkate alındığında en düşük hata değerlerini üreten Hibrit RF-LSTM modeli, gelecek dönem tahminleri için uygun model olarak belirlenmiştir. Bu model aracılığıyla 2030 yılına kadar elde edilen tahmin değerleri Çizelge 9'da sunulmuştur.

Çizelge 9. GTİP 2710 ithalat değerleri için en iyi sonucu veren Hibrit RF-LSTM Modeli ile 2030 yılına tahmin değerleri

Aylar/Yıllar	2025	2026	2027	2028	2029	2030
Ocak	*1.713.598*	*952.007*	1.087.538	1.086.019	1.085.080	1.084.666
Şubat	*1.240.566*	1.132.652	1.127.850	1.121.071	1.121.389	1.120.833
Mart	*1.280.841*	1.204.622	1.193.895	1.192.727	1.193.110	1.192.994
Nisan	*1.390.111*	1.221.752	1.214.966	1.217.792	1.217.955	1.218.382
Mayıs	*1.410.276*	1.216.333	1.211.655	1.213.941	1.214.208	1.214.658
Haziran	*1.618.367*	1.208.357	1.206.621	1.207.327	1.207.656	1.207.947
Temmuz	*1.646.163*	1.201.575	1.199.132	1.199.715	1.199.954	1.200.117
Ağustos	*1.460.702*	1.189.957	1.189.852	1.190.334	1.190.486	1.190.562
Eylül	*1.470.063*	1.179.045	1.179.477	1.179.460	1.179.512	1.179.526
Ekim	*1.374.377*	1.168.128	1.168.134	1.168.060	1.168.035	1.168.005
Kasım	*1.413.160*	1.152.135	1.152.427	1.152.156	1.152.078	1.152.012
Aralık	*1.559.565*	1.121.019	1.121.287	1.120.930	1.120.757	1.120.622

Çizelge 9'da sunulan tahmin sonuçlarına göre, 2007 yılında 306.251 düzeyinde gerçekleşen ithalat değerinin, ekonomik büyüme, sanayi üretimindeki artış ve enerji talebindeki genişlemeye paralel olarak 2026 yılı Ocak ayında 952.007 seviyesine ulaştığı görülmektedir. Bu gelişme, petrol ürünlerinin ekonomik faaliyetler içerisindeki önemini ve söz konusu ürünlere yönelik talebin zaman içerisinde artış eğiliminde olduğunu göstermektedir.

Bununla birlikte, genel yükseliş eğiliminin 2019–2020 döneminde zayıfladığı ve bu süreçte ithalat değerlerinin 248.745 seviyesine kadar gerilediği gözlenmektedir. Bu dönemin COVID-19 pandemisiyle örtüşmesi, söz konusu gelişmenin pandemi kaynaklı küresel ekonomik ve ticari koşullarla ilişkili olabileceğini düşündürmektedir. Ancak pandemi sonrası dönemde ekonomik faaliyetlerdeki toparlanma ve küresel ticaret koşullarındaki normalleşmeyle birlikte ithalat hacminde yeniden artış eğilimi ortaya çıkmış ve son altı yıllık dönemde 1.618.367 seviyesine ulaşılmıştır.

2026-2030 dönemine ilişkin tahmin sonuçları da petrol ürünleri ithalatının önümüzdeki yıllarda yüksek seviyelerini koruyabileceğine ve talebin devam eden ekonomik faaliyetlerle uyumlu bir görünüm sergileyebileceğine işaret etmektedir.

Bu çalışmada geliştirilen hibrit RF-LSTM modeli, geçmiş verilerdeki doğrusal olmayan dinamikleri ve dönemsel dalgalanmaları uygun bir şekilde modelleyerek diğer yöntemlere göre daha yüksek doğrulukta gelecek tahminleri üretmiştir. Bununla birlikte, uzun dönemli (2026-2030) petrol ürünleri ithalatı öngörülerinin, yalnızca geçmiş veri örüntülerine bağlı kalmayan bir dizi yapısal ve dışsal faktörün etkisi altında şekillenebileceği göz önünde bulundurulmalıdır. Özellikle petrol ve türevleri (HS 2710), küresel ve bölgesel jeopolitik gelişmeler ile enerji politikalarındaki değişimlere karşı son derece hassastır. Tedarik zincirindeki olası kırılmalar, ticaret rotalarındaki gerilimler veya ulusal stratejik stok politikaları, ithalat hacimlerinde modelin öngördüğü pürüzsüz trendin dışına çıkan ani dalgalanmalara (şoklara) yol açabilir. Diğer taraftan, karbon nötr hedefleri doğrultusunda hız kazanan teknolojik dönüşümler ve elektrikli araçların (EV) yaygınlaşması gibi alternatif enerji kaynaklarına geçiş süreçleri, uzun vadede fosil yakıtlara olan yapısal talebi aşağı yönlü baskılama potansiyeline sahiptir. Sonuç olarak, önerilen yapay zekâ tabanlı model makroekonomik planlama için güçlü ve güvenilir bir temel senaryo sunmakla birlikte; karar vericilerin bu istatistiksel öngörüleri jeopolitik risk senaryoları ve yeşil enerjiye geçiş tahminleri gibi nitel ve dışsal dinamiklerle birlikte, dinamik bir esneklikle değerlendirmesi daha doğru karar almada etkili olacağı düşünülmektedir.

6. KAYNAKLAR

1. Kökyıldırım, A. & Antmen, Z.F. (2024). Determination of financial performance in electric power enterprises with entropy weighted WASPAS analysis method. *Çukurova Üniversitesi Mühendislik Fakültesi Dergisi, 39*(3), 849-860.
2. Erkök, B. & Kütük, Y. (2023). Dependency on imported energy in Turkey: Input-output analysis. *Marmara Üniversitesi İktisadi ve İdari Bilimler Dergisi, 45*(1), 47-70.
3. Ürkmez, İ. & Okyar, M.C. (2022). The effect of renewable energy on energy import dependence: An empirical analysis in Turkey. *Siyasal: Journal of Political Sciences, 31*(2), 443-462.
4. Özlale, Ü. & Pekkurnaz, D.J.E.P. (2010). Oil prices and current account: A structural analysis for the *Turkish Economy. 38*(8), 4489-4496.
5. Yalta, A.Y. & Yalta, A.T. (2017). Dependency on imported oil and its effects on current account. *Energy Sources, Part B: Economics, Planning, Policy, 12*(10), 859-867.
6. Tekin, P. (2022). Çukurova Bölgesi için kısa vadeli yapay zeka tabanlı rüzgar güç tahmini. *Çukurova Üniversitesi Mühendislik Fakültesi Dergisi, 37*(4), 1143-1154.
7. Ediger, V.Ş. & Berk, I. (2011). Crude oil import policy of Turkey: Historical analysis of determinants and implications since 1968. *Energy Policy, 39*(4), 2132-2142.
8. Solak, A.O. (2013). Türkiye'nin toplam petrol talebi ve ulaştırma sektörü petrol talebinin Arima Modeli ile tahmin edilmesi. *Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi, 18*(3), 131-142.
9. Melikoglu, M. (2014). Demand forecast for road transportation fuels including gasoline, diesel, LPG, bioethanol and biodiesel for Turkey between 2013 and 2023. *Renewable Energy, 64*, 164-171.
10. Sahraei, M.A., Duman, H., Codur, M.Y. & Eyduran, E. (2021). Prediction of transportation energy demand: multivariate adaptive regression splines. *Energy, 224*, 120090.

11. Ağbulut, Ü. (2022). Forecasting of transportation-related energy demand and CO2 emissions in Turkey with different machine learning algorithms. *Sustainable Production Consumption, 29*, 141-157.
12. Hoxha, J., Codur, M.Y., Mustafaraj, E., Kanj, H. & El Masri, A. (2023). Prediction of transportation energy demand in Türkiye using stacking ensemble models: Methodology and comparative analysis. *Applied Energy, 350*, 121765.
13. Kayacı Çodur, M. (2024). Ensemble machine learning approaches for prediction of Türkiye's energy *Demand. Energies, 17*(1), 74.
14. Bakanlığı, T.C.T. (2026). TAREKS gümrük tarife istatistik pozisyonu (GTİP) sorgulama ekranı. https://uygulama.gtb.gov.tr/Tara/, Erişim tarihi: 15.05.2026.
15. Centre-ITC, U.T.M.-I.T. (2026), Trade Map - International Trade Statistics. https://www.trademap.org/, Erişim tarihi: 05.04.2026.
16. Makoni, T. & Chikobvu, D. (2023). Assessing and forecasting the long-term impact of the global financial crisis on manufacturing sales in South Africa. *Economies, 11*(6), 158.
17. Nwokike, C.C. & Okereke, E.W. (2021). Comparison of the performance of the SANN, SARIMA and ARIMA models for forecasting quarterly GDP of Nigeria. *Asian Research Journal of Mathematics, 17*(3), 1-20.
18. Hanke, J.E. & Wichern, D.W. (2009). *Business forecasting.* Pearson Education, Last Page.
19. Makoni, T. & Chikobvu, D.J.E. (2023). Assessing and forecasting the long-term impact of the global financial crisis on manufacturing sales in South Africa. *Economies, 11*(6), 158.
20. Dritsakis, N. & Klazoglou, P. (2018). Forecasting unemployment rates in USA using Box-Jenkins methodology. *International Journal of Economics Financial Issues 8*(1), 9.
21. Chand, S. & Kamal, S. (2014). Mixed portmanteau test for diagnostic checking of time series models. *Journal of Applied Mathematics, 2014*(1), 545413.
22. Kibona, S.E. & Mbago, M.C. (2018). Forecasting wholesale prices of maize in Tanzania using Arima Model. *General Letters in Mathematics, 4*(3), 131-141.
23. Ünal, Y.Z., Al-Turki, U.M., Zaim, S., Demirel, Ö.F. & Görener, R. (2015). Developing spreadsheet models of Holt-Winter methods and solving with Microsoft Excel solver and differential evaluation technique: An application to tourism sector. In *2015 International Conference on Industrial Engineering and Operations Management (IEOM)*, IEEE, 1-8.
24. Eltaeib, T. & Mahmood, A. (2018). Differential evolution: A survey and analysis. *Applied Sciences, 8*(10), 1945.
25. Zhang, G.P. (2003). Time series forecasting using a hybrid ARIMA and neural network model. *Neurocomputing, 50*, 159-175.
26. Breiman, L. (2001). Random forests. *Machine learning, 45*(1), 5-32.
27. Akça, Ş. & Şanlı, F.B. (2022). Kıyı çizgisinin makine öğrenmesi tabanlı mean-shift, rastgele orman ve destek vektör makinaları ile belirlenmesi. *Çukurova Üniversitesi Mühendislik Fakültesi Dergisi, 37*(3), 835-842.
28. Ran, X., Shan, Z., Fang, Y. & Lin, C. (2019). An LSTM-based method with attention mechanism for travel time prediction. *Sensors, 19*(4), 861.
29. Oshiro, T.M., Perez, P.S. & Baranauskas, J.A. (2012). How many trees in a random forest?, In *International Workshop on Machine Learning and Data Mining in Pattern Recognition*, Springer, 154-168.
30. Probst, P., Wright, M.N. & Boulesteix, A.L. (2019). Hyperparameters and tuning strategies for random forest. *Wiley Interdisciplinary Reviews: Data Mining Knowledge Discovery, 9*(3), e1301.
31. Aree, S. & Tooprakai, S. (2025). Maintenance decision modeling for solar photovoltaic performance prediction using RMSE and MAPE methods. In *2025 International Technical Conference on Circuits/Systems, Computers, and Communications (ITC-CSCC)*, IEEE, 1-6.