

# Türkiye Hurda Demir Çelik İthalatının Gelecek Değerlerinin Derin Öğrenme, Makine Öğrenmesi ve Topluluk Öğrenme Yöntemleri ile Öngörülmesi

(Araştırma Makalesi)

*Forecasting the Future Values of Turkey's Scrap Iron and Steel Imports with Deep Learning, Machine Learning and Ensemble Learning Methods*

Doi: 10.29023/alanyaakademik.1497646

Yunus Emre GÜR<sup>1</sup>, Kâmil Abdullah EŞİDİR<sup>2</sup>

<sup>1</sup> Dr. Arş. Gör., Fırat Üniversitesi, yegur@firat.edu.tr, Orcid No: 0000-0001-6530-0598

<sup>2</sup> Dr., Fırat Kalkınma Ajansı, avdullahesidir@yahoo.com, Orcid No: 0000-0002-8106-1758

## ÖZET

**Anahtar Kelimeler:**  
Hurda Demir Çelik İthalatı, LSTM, Makine Öğrenmesi, Derin Öğrenme, Topluluk Öğrenme, LIME (Local Interpretable Model-agnostic Explanations) Analizi

**Makale geliş tarihi:**  
07.06.2024

**Kabul tarihi:**  
21.09.2024

Bu çalışma, Türkiye'nin hurda demir çelik ithalatını tahmin etmek için LSTM, MLP, Random Forest, SVM, XGBoost ve Doğrusal Regresyon modellerini kapsamlı bir şekilde değerlendirmektedir. Modellerin performansları RMSE, MSE, MAE, MAPE ve R<sup>2</sup> metrikleri kullanılarak ölçülmüştür. LSTM modeli, en iyi tahmin performansını göstererek eğitim setinde RMSE 0,0387, MSE 0,0014, MAE 0,0297, MAPE 0,1261 ve R<sup>2</sup> 0,9631 sonuçlarını elde etmiştir. Gelecek 12 aylık ithalat tahminlerine göre, Nisan 2024'te 773.378.496 USD olan ithalat miktarının Mart 2025'te 1.239.538.176 USD'ye ulaşması beklenmektedir. LIME analizi, modelin hangi bağımsız değişkenlere dayandığını açıklayarak modelin karar verme süreçlerini şeffaf hale getirmektedir. Analiz sonucunda, modelin özellikle "YÜFE" ve "Aylık Demir Çelik İthalatı" gibi değişkenlere yüksek önem verdiği, bu değişkenlerin tahmin sonuçları üzerindeki etkisinin diğer bağımsız değişkenlere göre daha belirgin olduğu tespit edilmiştir. Bu analiz ile her bir bağımsız değişkenin modelin sonuçları üzerindeki etkisi görselleştirilmiş ve değişkenlerin katkı düzeyleri değerlendirilerek modelin hangi özelliklere daha fazla ağırlık verdiği ortaya konulmuştur.

## ABSTRACT

**Keywords:**  
Scrap Iron and Steel Imports, LSTM, Machine Learning, Deep Learning, Ensemble Learning, LIME (Local Interpretable Model-agnostic Explanations) Analysis

This study comprehensively evaluates LSTM, MLP, Random Forest, SVM, XGBoost, and linear regression models to forecast Turkey's scrap iron and steel imports. The performance of the models is measured using RMSE, MSE, MAE, MAPE and R<sup>2</sup> metrics. The LSTM model shows the best forecasting performance, achieving RMSE 0.0387, MSE 0.0014, MAE 0.0297, MAPE 0.1261, and R<sup>2</sup> 0.9631 in the training set. According to import forecasts for the next 12 months, imports are expected to increase from 773,378,496 USD in April 2024 to 1,239,538,176 USD in March 2025. LIME analysis makes the decision-making processes of the model transparent by explaining which independent variables the model is based on. As a result of the analysis, it is determined that the model attaches great importance to variables such as "PPI" and "Monthly Iron and Steel Imports", and the impact of these variables on the forecast results is more significant than other independent variables. With this analysis, the impact of each independent variable on the results of the model is visualized and the contribution levels of the variables are evaluated to reveal which features are given more weight by the model.

## 1. GİRİŞ

Demir ve çelik, birçok endüstriyel sektörün işleyişinde önemli bir girdi olarak yer almakta ve bu sektör, beyaz eşya, otomotiv, gemi inşası, altyapı projeleri ve madencilik gibi birçok mühendislik endüstrisinde kullanılmaktadır (Güner ve Demir, 2022). Ayrıca, demir çeliğin geri dönüştürülmesi hem çevresel hem de ekonomik açıdan önemli faydalar sağlamaktadır (Pauna vd., 2020). Geri kazanım sayesinde doğal kaynaklar korunmakta, metal cevherleri gibi kıt kaynakların kullanımında tasarruf sağlanmaktadır (Çetin ve Filiz, 2023). Entegre tesislerde demir cevheri temel hammadde iken, ark ocaklı tesislerde demir-çelik hurdaları kullanılmakta, bu da çelik üretim süreçlerinde geri dönüşümün kritik bir rol oynadığını göstermektedir (Şeker vd., 2017). Çelik üretimi, bir ülkenin sanayileşme düzeyini ve gelişmişlik seviyesini belirleyen önemli göstergelerden biri olarak kabul edilmektedir (Yücekutlu ve Sanalan, 2015).

Gümrük Tarife İstatistik Pozisyonu (GTIP) kodları, uluslararası ticarete kullanılan standart bir kodlama sistemidir. Her ürün veya mal için farklı bir GTIP kodu bulunmaktadır ve bu kodlar, gümrük beyannameleri ve diğer ticari belgelerde kullanılmaktadır. Hurda demir çelik için 7204 ve 7205 GTIP kodları kullanılmaktadır. 7204; “dökme demirin, demirin veya çeliğin döküntü ve hurdaları; demir veya çelik döküntü ve hurdalarının yeniden ergitilmesi suretiyle, elde edilen külçeler”, 7205; “dökme demir, aynalı demir, demir veya çelikten granül ve tozlar” anlamlarına gelmektedir. Bu çalışmada da, hurda demir çelik ithalat analizi için 7204 nolu GTIP kodu kullanılmıştır. Tablo 1’de yıllara göre hurda demir çelik (Gtip: 7204) ve demir çelik (Gtip: 72) Türkiye dış ticaret verileri ifade edilmiştir. Tablodan anlaşıldığı üzere, 23 yılda ihracat ve ithalat değerlerinde muazzam artışlar gerçekleşmiştir. 2000 yılında Türkiye’nin hurda demir çelik ihracatı 18 milyon USD civarında iken, bu ihracat 2023’de 299 milyon USD’yi aşmıştır.

**Tablo 1. Yıllara Göre Hurda Demir-Çelik ve Demir-Çelik Türkiye Dış Ticaret Verileri**

Yıllar	Hurda Demir Çelik İhracatı (Bin USD)	Hurda Demir Çelik İthalatı (Bin USD)	Demir Çelik İhracatı (Bin USD)	Demir Çelik İthalatı (Bin USD)
2000	18.772	696.618	1.624.131	2.778.433
2001	16.501	477.778	2.069.932	1.797.367
2002	19.303	1.019.286	2.269.813	2.904.980
2003	35.519	1.855.776	2.969.012	4.747.844
2004	67.591	3.013.745	5.359.512	8.031.522
2005	69.136	3.143.293	4.973.475	9.457.831
2006	144.842	3.911.821	6.273.353	11.525.251
2007	182.205	5.591.881	8.372.266	16.182.379
2008	135.336	8.961.208	14.946.358	23.160.241
2009	89.130	4.240.377	7.641.010	11.351.640
2010	165.934	7.122.433	8.740.067	16.120.796
2011	204.197	9.767.305	11.225.329	20.424.235
2012	146.293	9.418.971	11.332.482	19.642.041
2013	137.236	7.511.208	9.918.794	18.690.888
2014	235.185	7.150.484	9.244.173	17.575.890
2015	146.789	4.288.070	6.556.416	14.775.094
2016	147.254	3.962.158	6.180.353	12.575.460
2017	189.148	6.138.232	8.230.403	16.761.929
2018	218.848	7.137.092	11.546.433	18.401.453
2019	163.472	5.615.162	9.926.035	14.680.510
2020	180.370	6.253.157	8.868.853	14.982.175
2021	307.851	11.154.552	17.141.861	27.270.909
2022	293.346	9.740.563	14.645.676	27.568.154
2023	299.846	7.619.883	8.795.677	23.858.895

**Kaynak:** TÜİK, 2024.

Türkiye’nin demir çelik sektöründeki bölgesel ve küresel rekabetçi konumu, uzun yıllara dayanan bir sanayi gelişiminin sonucudur. 1937’de kurulan Karabük Demir Çelik İşletmeleri (KARDEMİR), Türkiye’nin sanayileşme hamlesinde önemli bir adım olmuş, ardından Ereğli Demir Çelik Fabrikası (1965) ve İskenderun Demir Çelik Fabrikası (1977) gibi tesislerle ülkenin üretim kapasitesi artırılmıştır (Naito vd., 2015). Bu kuruluşlar, Türkiye’nin demir çelik endüstrisinin şekillenmesinde ve farklı pazar ihtiyaçlarına etkin bir şekilde yanıt vermesinde önemli

rol oynamıştır. Son yüzyılda demir üretim teknolojilerinde yaşanan ilerlemeler, Türkiye'nin uluslararası rekabet gücünü korumasını sağlamıştır. Özellikle pülverize kömür enjeksiyonu, düşük maliyetli demir kaynaklarının kullanımı ve geri dönüşüm girişimleri gibi yenilikçi teknolojiler, sektörü daha verimli ve çevre dostu hale getirmiştir. Bu teknolojik gelişmelerin yanı sıra, Türkiye'nin hurda demir çelik ithalatı, ülkenin ekonomik büyümesi ve enerji talebi ile yakından ilişkilidir. İthal edilen hurda miktarının doğru tahmin edilmesi, kaynakların verimli kullanımı, maliyetlerin düşürülmesi ve gereksiz ithalatın önlenmesi açısından kritik öneme sahiptir. İthalat yapmak isteyen firmaların, ihtiyaç duyulan ürün miktarlarını ve gereksinimlerini doğru bir şekilde belirlemeleri, sektörün sürdürülebilirliği için hayati önem taşımaktadır (Çubuk, 2021).

Uluslararası hurda demir ve çelik fiyatları, Türkiye'nin hurda ithalatını doğrudan etkileyen en önemli faktörlerden biridir. Düşük uluslararası fiyatlar, Türkiye'nin hurda ithalatını teşvik ederken, yüksek fiyatlar ithalatı kısıtlayabilmektedir (Monjon ve Quirion, 2010). Bununla birlikte, ithal edilen hurda kalitesi de ticaret dinamiklerini önemli ölçüde şekillendirmektedir. Türkiye gibi uzun ürünler üreten ülkeler, daha düşük kalite hurda çelik ithal ederken, Almanya gibi yüksek kaliteli ürünler üreten ülkeler, daha temiz ve yüksek maliyetli hurda ithal etmektedir (Lee ve Sohn, 2015). Bu farklılıklar, hurda fiyatlarındaki değişikliklerin Türkiye'nin çelik ithalatı üzerindeki etkisini belirlemektedir. Hurda demir ve çelik fiyatlarının Türkiye'nin ithalatı üzerindeki etkisi, aynı zamanda döviz kurları ve petrol fiyatları gibi daha geniş ekonomik faktörlerle de bağlantılıdır. Döviz kurlarındaki dalgalanmalar, Türkiye'nin dış ticaret dengesi üzerinde doğrudan etkiler yaratabilir ve bu da ithalat kararlarını etkileyebilir (Polat, 2019). Küresel piyasalardaki bu bağlantılı yapılar, hurda fiyatlarındaki dalgalanmaların çelik ithalatı üzerinde dalgalanma etkileri yaratmasına yol açmaktadır. Enerji verimliliği de çelik endüstrisi için kritik bir öneme sahiptir. Yüksek hurda fiyatları, üreticileri hurda ve erimiş demir kaynak kullanımını optimize etmeye teşvik ederek daha sürdürülebilir üretim yöntemlerini benimsemeye yöneltebilir (Liu vd., 2020). Bu optimizasyon, Türkiye'nin çelik ithalatının miktarını ve niteliğini etkileyerek, ithalat modellerini değiştirebilir. Dolayısıyla, hurda demir ve çelik fiyatları Türkiye'nin çelik ithalatı üzerinde önemli bir etkiye sahiptir. Fiyat dalgalanmaları, sadece çelik üretim maliyetlerini değil, aynı zamanda ticaret modellerini ve genel ekonomik dinamikleri de etkilemektedir. Bu doğrultuda, Türkiye'nin hurda demir-çelik ithalatı üzerine yapılan tahminlerde, sadece fiyatlar ve kalite değişkenleri değil, aynı zamanda küresel ekonomik dalgalanmalar ve enerji piyasalarındaki hareketlilik gibi daha geniş kapsamlı faktörlerin de dikkate alınması gerektiği açıktır. Bu çok yönlü faktörlerin, Türkiye'nin çelik sektöründeki ithalat ve üretim kararlarını nasıl şekillendirdiğini anlamak, sektörün gelecekteki hareketlerini öngörmek açısından son derece önemlidir. Özellikle küresel çelik talebindeki artış veya azalış, Türkiye'nin ithalatını doğrudan etkilemekte, bu da yerli üretim ve ihracat dengelerinde önemli dalgalanmalara yol açabilmektedir. Türkiye'nin çelik endüstrisi gibi stratejik sektörler, küresel tedarik zincirlerinde önemli bir oyuncu olduğundan, uluslararası piyasalardaki fiyat değişikliklerine karşı esneklik gösterebilme kabiliyeti, ekonomik sürdürülebilirlik açısından kritik bir rol oynamaktadır. Dolayısıyla, Türkiye'nin hurda demir-çelik ithalat tahminleri yapılırken, sadece kısa vadeli piyasa hareketlerine değil, aynı zamanda uzun vadeli yapısal değişimlere ve küresel ekonomik göstergelere de odaklanılmalıdır. Bu sayede, sektörün daha proaktif stratejiler geliştirmesi, ekonomik dalgalanmalara karşı dayanıklılık kazanması ve sürdürülebilir bir büyüme sağlanması mümkün olacaktır.

Tüm bu bilgiler ışığında, Türkiye'nin hurda demir-çelik ithalatını etkileyen faktörler dikkate alarak gelecekteki ithalat miktarlarını doğru bir şekilde öngörmek, sanayi planlaması ve ekonomik politikaların belirlenmesi açısından büyük önem taşımaktadır. Bu çalışmanın amacı, Türkiye'nin hurda demir-çelik ithalatını en doğru şekilde tahmin edebilecek modelin geliştirilmesidir. Bu doğrultuda, derin öğrenme (LSTM, MLP), makine öğrenmesi (Linear Regression, SVM) ve topluluk öğrenme yöntemleri (XGBoosting, Random Forest) kullanılarak farklı modeller yapılmış, bu modeller arasından en iyi performans gösteren tahmin modeli belirlenerek, Türkiye'nin hurda demir-çelik ithalatının gelecek değerleri tahmin edilmiştir. Çalışmada kullanılan bu yenilikçi yaklaşım, literatürde önemli bir boşluğu doldurmada ve mevcut tahmin yöntemlerine kıyasla daha doğru ve güvenilir sonuçlar sağlamaktadır. Sonuç olarak, bu çalışma hem akademik literatüre hem de uygulamalı sanayi çalışmalarına önemli katkılar sağlayarak, hurda demir-çelik ithalatı tahminlerinde kullanılabilecek yeni yaklaşımlar sunmakta ve gelecek araştırmalar için bir referans noktası oluşturmaktadır.

## 2. LİTERATÜR İNCELEMESİ

Gelecekteki hurda demir çelik ithalatının tahmin edilmesi, ekonomik ve endüstriyel planlamalar açısından büyük önem taşımaktadır. Bu bağlamda, yapay zekâ ve veri analizi tekniklerinin kullanımı giderek artmaktadır. Bu bölümde, derin öğrenme, makine öğrenmesi ve topluluk öğrenme yöntemlerinin kullanıldığı çalışmalar incelenerek, mevcut literatürdeki önemli bulgular ve bu çalışmanın literatüre olan katkıları tartışılacaktır.

Hurda demir ve çelik ithalatı tahmini, tedarik zinciri yönetimi, stok yönetimi, malzeme ihtiyaç planlaması ve üretim planlaması gibi birçok alanda önemlidir. Tahmin yapmak için zaman serileri, makine öğrenmesi, topluluk ve derin öğrenme yöntemleri kullanılarak hurda demir ve çelik ithalat tahmini ve bu ithalat ve ihracatla yakından ilgili olan alanlarla ilgili birçok araştırma yapılmıştır.

Albayrak (2011), dünya genelindeki demir çelik hurdası hareketlerini analiz ederek, 2020 yılı için tahminlerde bulunmuştur. Bu çalışma, sektörel talep projeksiyonları açısından önemlidir. Bulum (2015), Türkiye'nin çelik üretim ve tüketim miktarlarını ARIMA ve Gri Model yöntemleriyle tahmin etmiş ve küresel kriz öncesi dönemde Holt metodunun daha başarılı sonuçlar verdiğini ortaya koymuştur. Bu çalışmalar, modelleme yöntemlerinin geçerliliğini destekleyerek bu alandaki literatüre katkı sağlamaktadır. Taşdemir (2018), Türkiye'de kur değişimlerinin demir-çelik sektörü ihracat ve ithalatı üzerindeki etkilerini ADF Birim Kök ve Engle-Granger Koentegrasyon testleriyle analiz etmiş ve kur değişimlerinin bu sektör üzerinde önemli bir etkisi olduğunu belirlemiştir. Meng vd. (2018) ise enerji yönetimi ve talep yanıtı için makine öğrenimi algoritmalarının etkinliğini vurgulamış, bu yöntemlerin enerji tahminlerinde kritik öneme sahip olduğunu ortaya koymuştur. Jiang vd. (2019), çelik üretim süreçlerinde çelik verimini tahmin etmek için destek vektör regresyonu (SVR) modelinin diğer makine öğrenimi modellerine göre üstün olduğunu belirlemiş ve bu alan için en uygun algoritmanın seçilmesinin önemini vurgulamıştır. Ryll ve Seidens (2019), finansal piyasa tahmininde makine öğrenimi algoritmalarının geleneksel yöntemlere göre daha başarılı olduğunu tespit etmişlerdir. Özemre ve Kabadurmuş (2020), ihracat hacimlerini tahmin etmek için Random Forest (RF) ve Yapay Sinir Ağları (YSA) kullanmış ve bu yöntemlerin ticaret sonuçlarını öngörmedeki etkinliğini göstermiştir. Wang (2022), blok zinciri güvenliği ve ticaret tahmini için PSO ile optimize edilmiş hibrit RVM modelini geliştirerek, bu modelin ticaret hacimlerini doğru bir şekilde tahmin edebildiğini ortaya koymuştur. Güner ve Demir (2022), Türkiye'nin demir-çelik ithalatını YSA ile tahmin etmiş ve bu yöntemle tutarlı öngörüler elde etmişlerdir. Moalem vd. (2023) ise temel metal endüstrisinde elektrik tedarik zinciri için derin öğrenmeye dayalı bir tahmin yaklaşımı sunmuş, bu modelin tedarik zinciri yönetiminde kritik bir rol oynadığını vurgulamıştır. Buna ek olarak, LSTM modelleri çeşitli alanlarda ithalat ve ihracat tahmini için yaygın olarak kullanılmaktadır. Mao vd. (2022) ve diğer araştırmacılar, LSTM'nin lojistik, ekonomi ve çevre tahminleri gibi farklı alanlarda başarılı uygulamalarını göstermiştir. Kakade vd. (2022) ise GARCH ve LSTM'yi birleştirerek emtia piyasası oynaklığını tahmin eden hibrit bir model geliştirmiş ve bu modelin piyasaların farklı yönlerini yakalamadaki başarısını vurgulamıştır. Wang vd. (2023) ise mısır mahsulü tahminleri için CNN-LSTM modelini kullanarak tarımsal tahminlerde bu hibrit yaklaşımın faydalarını ortaya koymuştur. Genel olarak, LSTM modelleri, uzun vadeli bağımlılıkları yakalama ve sıralı verilerden karmaşık örüntüleri öğrenme becerisiyle çeşitli tahmin alanlarında üstün performans sergilemektedir.

Bununla birlikte, LSTM modelleri, ithalat ve ihracat tahminleri de dahil olmak üzere birçok tahmin çalışmasında yaygın olarak kullanılmaktadır. Mao vd. (2022), LSTM modellerinin çevre, ekonomi ve lojistik gibi farklı alanlarda başarılı sonuçlar verdiğini belirtmiştir. Örneğin, Dhakal vd. (2020), LSTM'yi partikül madde (PM2.5) seviyelerini tahmin etmek için kullanmış ve modelin çevresel tahminlerde yüksek doğruluk sağladığını göstermiştir. Mussumeci ve Coelho (2020), Brezilya'da dang salgınlarını tahmin etmek için LSTM'yi uygulamış ve bu modelin LASSO ve Random Forest gibi diğer makine öğrenimi yaklaşımlarına üstünlük sağladığını bulmuştur. Lei vd. (2021), hisse senedi volatilité tahmininde metin madenciliği ve LSTM'yi birleştirerek geleneksel ekonometrik modellere kıyasla daha iyi performans elde etmiştir. Bu çalışmalar, LSTM'nin finansal verilerdeki karmaşık ilişkileri yakalama ve doğru tahminler yapma potansiyelini ortaya koymaktadır. Si (2024) tarafından yapılan çalışmalar da LSTM'nin geleneksel zaman serisi tahmininde umut verici sonuçlar verdiğini göstermektedir. Yu vd. (2022), lojistikte ihracat ürünlerinin rekabet gücünü tahmin etmek için geliştirdikleri SALSTM algoritmasının, LSTM'nin doğruluğunu artırma yeteneğini vurgulamaktadır. Roy vd. (2022), tarımsal tahminlerde LSTM ve Bi-LSTM modellerinin uygulanabilirliğini ortaya koyarken, Zhou vd. (2022) ise LSTM ile LightGBM modellerini birleştirerek enerji tahminlerinde hibrit modellerin doğruluğunu artırmada etkin olduğunu kanıtlamıştır.

LSTM modelleri, tahmin yeteneklerini geliştirmek için diğer tekniklerle entegre edilmiştir. Kakade vd. (2022), emtia piyasası getiri oynaklığını tahmin etmek için GARCH ve LSTM'yi birleştirerek hibrit bir model geliştirmiş ve bu yaklaşımın volatilité tahminlerinde yüksek doğruluk sağladığını göstermiştir. Benzer şekilde, Wang vd. (2023), mısır mahsulü tahmini için CNN-LSTM modelini önererek, CNN'nin özellik çıkarma yeteneklerini LSTM'nin zaman serisi işleme becerisi ile birleştirmenin tarımsal tahminlerde faydalı olduğunu ortaya koymuştur. Genel olarak, LSTM modelleri, ithalat ve ihracat tahminlerinin yanı sıra diğer çeşitli alanlarda da başarılı sonuçlar vermektedir. Araştırmacılar, LSTM'nin uzun vadeli bağımlılıkları yakalama ve karmaşık örüntüleri öğrenme kapasitesinden faydalanarak, farklı alanlarda önemli tahmin doğruluğu sağlamışlardır. LSTM'nin esnek yapısı, diğer tekniklerle entegrasyonu ve karmaşık ilişkileri doğru bir şekilde yakalama yeteneği, bu modeli tahmin çalışmalarında güçlü bir araç haline getirmektedir. Literatürde, genellikle genel ekonomik ve ticari tahminler için LSTM ve diğer yapay zeka teknikleri kullanılmışken, spesifik olarak hurda demir çelik ithalat tahmini alanında yapılan çalışmalar sınırlıdır. Araştırmalar genel çelik üretim ve tüketim tahminlerine odaklanmış, ancak hurda demir çelik ithalatı üzerinde spesifik bir modelleme çalışması yapılmamıştır. Bu çalışma, LSTM modelinin hurda demir çelik ithalatı gibi spesifik bir ekonomik veri setinde nasıl uygulanabileceğini ve bu modelin diğer makine öğrenimi modellerine kıyasla üstün performansını ortaya koymaktadır. Ayrıca, modelin karar mekanizmalarının LIME analizi ile açıklanması, sonuçların şeffaflığını ve anlaşılabilirliğini artırmaktadır. Bu açıdan bakıldığında, çalışma, hurda demir çelik ithalat tahminleri konusunda literatürdeki boşluğu doldurarak, sektörel planlama ve

stratejik karar verme süreçlerine önemli katkılar sunmaktadır. Ayrıca, bağımsız değişkenlerin LSTM modeli ile tahmin edilerek veri setine dahil edilmesi ve bu şekilde gelecekteki ithalat değerlerinin öngörülmesi, literatürdeki diğer çalışmalardan farklı olarak, daha bütüncül ve entegre bir tahmin yaklaşımı sunmaktadır.

### 3. ARAŞTIRMANIN METODOLOJİSİ

Bu bölümde, Türkiye'nin hurda demir çelik ithalatının gelecekteki değerlerini tahmin etmek amacıyla kullanılan derin öğrenme, makine öğrenmesi ve topluluk öğrenme yöntemlerinin uygulanma süreci ayrıntılı olarak açıklanacaktır. Alt başlıklarda, veri toplama, ön işleme, kullanılan yazılım ve donanım, model eğitimi ve model değerlendirme süreçleri açıklanmıştır.

#### 3.1. Veri Seti

Bu çalışmada kullanılan veriler, Türkiye İstatistik Kurumundan (TÜİK) ve Türkiye Cumhuriyet Merkez Bankasından (TCMB) edinilmiştir. Veri seti Ocak 2000 ile Mart 2024 yılları arasındaki 291 aylık dönemi kapsamaktadır. 7 adedi bağımsız değişkene ve bir adedi de bağımlı değişkene ait olmak üzere, toplamda her değişkene ait 291 adet veri girdisi bulunmaktadır. Bağımlı değişken, Türkiye hurda demir çelik aylık ithalat değeridir (USD). Bağımsız değişkenler sırasıyla; aylık ortalama Amerikan Doları Kuru (TL), aylık Türkiye ihracatı (USD), aylık Türkiye ithalatı (USD), ana demir çelik ve ferro alaşımlar için YÜFE, aylık hurda demir çelik ihracatı (USD), aylık demir çelik ihracatı (USD) ve aylık demir çelik ithalatıdır (USD). Tablo 2'de veri setinde kullanılan değişkenlere ilişkin açıklamalar detaylı bir şekilde sunulmaktadır.

**Tablo 2. Çalışmada Kullanılan Veri Setine İlişkin Açıklamalar**

Özellik	Açıklama	Ulaşılabilir Link
Aylık Amerikan Dolar Kuru (TL)	İlgili ayda Amerikan Doları'nın Türk Lirası karşısındaki ortalama döviz kuru değerini belirtir.	<a href="https://evds2.tcmb.gov.tr/index.php?evds/serieMarket">https://evds2.tcmb.gov.tr/index.php?evds/serieMarket</a>
Aylık Türkiye İhracatı (USD)	Türkiye'nin belirli bir ayda gerçekleştirdiği toplam ihracat tutarını ifade eder.	<a href="https://biruni.tuik.gov.tr/medas/?locale=tr">https://biruni.tuik.gov.tr/medas/?locale=tr</a>
Aylık Türkiye İthalatı (USD)	Türkiye'nin belirli bir ayda gerçekleştirdiği toplam ithalat tutarını ifade eder.	<a href="https://biruni.tuik.gov.tr/medas/?locale=tr">https://biruni.tuik.gov.tr/medas/?locale=tr</a>
YÜFE	Yurt içi üretici fiyat endeksi, belirli bir ayda üretici fiyatlarındaki değişimi ölçen bir endekstir.	<a href="https://biruni.tuik.gov.tr/medas/?locale=tr">https://biruni.tuik.gov.tr/medas/?locale=tr</a>
Aylık Hurda Demir Çelik İhracatı (USD)	Türkiye'nin belirli bir ayda gerçekleştirdiği hurda demir çelik ihracatı miktarını ifade eder.	<a href="https://biruni.tuik.gov.tr/medas/?locale=tr">https://biruni.tuik.gov.tr/medas/?locale=tr</a>
Aylık Demir Çelik İhracatı (USD)	Türkiye'nin belirli bir ayda gerçekleştirdiği demir çelik ihracatı miktarını ifade eder.	<a href="https://biruni.tuik.gov.tr/medas/?locale=tr">https://biruni.tuik.gov.tr/medas/?locale=tr</a>
Aylık Demir Çelik İthalatı (USD)	Türkiye'nin belirli bir ayda gerçekleştirdiği demir çelik ithalatı miktarını ifade eder.	<a href="https://biruni.tuik.gov.tr/medas/?locale=tr">https://biruni.tuik.gov.tr/medas/?locale=tr</a>
Aylık Hurda Demir Çelik İthalatı (USD)	Türkiye'nin belirli bir ayda gerçekleştirdiği hurda demir çelik ithalatı miktarını ifade eder.	<a href="https://biruni.tuik.gov.tr/medas/?locale=tr">https://biruni.tuik.gov.tr/medas/?locale=tr</a>

#### 3.2. Veri Ön İşlem

Toplanan verilerin analiz öncesinde, varsa eksik değerlerin temizlenmesi ve dönüştürülmesi gerekmektedir. Toplanan verilerde eksik değer bulunmamaktadır. Veriler, Python'un Pandas paketi kullanılarak bir Excel dosyasından içe aktarılmıştır. Ardından, veri çerçevesi bağımsız değişkenlere (X) ve bağımlı değişkene (Y) bölünmüştür. Veriler, ön işleme aşamasının bir parçası olarak min-max ölçeklendirme kullanılarak standartlaştırılmıştır. Bu, makine öğrenimi ve veri analizinde özellikleri belirli bir aralıkta, tipik olarak 0 ile 1 arasında yeniden ölçeklendirmek için yaygın olarak kullanılan bir veri ön işleme tekniğidir. Bu ölçeklendirme yöntemi, tüm özelliklerin analize eşit şekilde katkıda bulunmasını ve ölçeği nedeniyle belirli bir özelliğin modele hakim olmamasını sağlamak için gereklidir. İşlem, özelliğin minimum değerinin çıkarılmasını ve ardından maksimum ve minimum değerler arasındaki fark olan özelliğin aralığına bölünmesini içermektedir (Ampomah vd., 2021). Özellikle LSTM gibi derin öğrenme modellerinde, verilerin belirli bir aralıkta olması modelin stabilitesini ve performansını olumlu yönde etkileyecektir. Denklem 1'de bu ölçeklendirme gösterilmektedir.

$$x_{scaled} = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (1)$$

Alternatif olarak kullanılabilir Z-score standardizasyonu (standartlaştırma) yöntemi ise verilerin ortalamasını 0'a, standart sapmasını 1'e getirmeyi amaçlamaktadır. Z-score standardizasyonu, özellikle verilerin normal dağılıma sahip olduğu durumlarda avantajlıdır. Ancak, bu çalışmada kullanılan LSTM modelinde, zaman serisi verilerinin belirli bir aralıkta normalize edilmesi modelin daha iyi performans göstermesine olanak tanımaktadır. Ayrıca, Z-score standardizasyonu, verilerin uç değerlerine daha duyarlı olabileceği için, zaman serisi verilerinde ani dalgalanmalar yaşayan değişkenlerde modelin performansını olumsuz etkileyebilir. Bu nedenlerle, Min-Max ölçeklendirme yöntemi, bu çalışmanın bağlamında daha uygun görülmüş ve tercih edilmiştir.

### 3.3. Yazılım ve Donanım

Bu çalışmada, veri analizi, modelleme ve görselleştirme işlemleri için Python 3.6 programlama dili kullanılmıştır. Veri manipülasyonu ve analizi için Pandas, sayısal hesaplamalar için NumPy, makine öğrenmesi modellerinin eğitimi ve değerlendirilmesi için Scikit-Learn, derin öğrenme modellerinin oluşturulması ve eğitilmesi için TensorFlow ve Keras, topluluk öğrenme modeli için XGBoost, veri görselleştirme için ise Matplotlib ve Seaborn kütüphanelerinden yararlanılmıştır. Araştırmanın verimli ve etkili bir şekilde yürütülmesi için yüksek işlem gücüne sahip bir kişisel bilgisayar kullanılmıştır. Bu bilgisayar, Intel Core i7 bir işlemci, 16 GB RAM, 512 GB SSD depolama kapasitesi ile donatılmıştır. Derin öğrenme modellerinin eğitim sürecini hızlandırmak amacıyla NVIDIA GeForce RTX 3080 GPU kullanılmıştır. Bu yazılım ve donanım altyapısı, araştırmanın başarılı bir şekilde tamamlanmasını sağlamıştır.

### 3.4. Tahmin Modelleri

Bu çalışmada, Türkiye'nin hurda demir çelik ithalatını tahmin etmek için çeşitli derin öğrenme, makine öğrenmesi ve topluluk öğrenme yöntemleri kullanılmıştır. Derin öğrenme modelleri arasında LSTM (Long Short Term Memory) ve MLP (Multi-Layer Perceptron) yer almaktadır. LSTM modeli, zaman serisi verilerinin analizinde uzun dönemli bağımlılıkları öğrenme yeteneğine sahip olması nedeniyle tercih edilmiştir (Yan, 2023). LSTM hücreleri, giriş, unutma ve çıkış kapılarından oluşur (Haq vd., 2022) ve hücre durumu güncelleme süreçleri Denklem 2-7'de gösterildiği gibi ifade edilmektedir:

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (2)$$

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (3)$$

$$\tilde{C}_t = \tanh(W_C \cdot [h_{t-1}, x_t] + b_C) \quad (4)$$

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \quad (5)$$

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (6)$$

$$h_t = o_t * \tanh(C_t) \quad (7)$$

Burada  $f_t$ , unutma kapısı;  $i_t$ , giriş kapısı;  $\tilde{C}_t$ , yeni hücre durumu;  $C_t$ , hücre durumu;  $o_t$ , çıkış kapısı ve  $h_t$  ise hücre çıkışıdır.  $W_f, W_i, W_C, W_o$  ağırlık matrisleri ve  $b_f, b_i, b_C, b_o$  ise bias terimleridir.

MLP ise tam bağlı katmanlardan oluşan ve doğrusal olmayan ilişkileri öğrenme kapasitesine sahip bir yapay sinir ağı modelidir (Silva vd., 2020). MLP'nin bir katmanındaki nöronların hesaplaması Denklem 8'deki gibi ifade edilmektedir:

$$a^{(l)} = f(W^{(l)}a^{(l-1)} + b^{(l)}) \quad (8)$$

Burada  $a^{(l)}$ ,  $l$  katmanındaki aktivasyon;  $W^{(l)}$ ,  $l$  katmanındaki ağırlık matrisi;  $b^{(l)}$ ,  $l$  katmanındaki bias terimi ve  $f$ , aktivasyon fonksiyonudur.

Bununla birlikte, makine öğrenmesi modelleri olarak, Linear Regression ve SVM (Support Vector Machine) kullanılmıştır. Linear Regression, bağımsız değişkenler ve bağımlı değişken arasında doğrusal bir ilişki kurar (Adhikari, 2022). Linear Regression modeli Denklem 9'daki gibi tanımlanır:

$$y = X\beta + \epsilon \quad (9)$$

Burada  $y$ , bağımlı değişken vektörü;  $X$ , bağımsız değişkenler matrisi;  $\beta$ , regresyon katsayıları vektörü ve  $\epsilon$ , hata terimidir. Regresyon katsayıları, en küçük kareler yöntemi ile Denklem 10'da gösterildiği gibi tahmin edilmektedir:

$$\hat{B} = (X^T X)^{-1} X^T y \quad (10)$$

SVM, veri noktalarını tahmin etmek için hiperdüzlemler kullanan bir denetimli öğrenme algoritmasıdır (Muthukrishnan ve Kalaivani, 2023). SVR, bir marj içinde hataları tolere ederek veri noktalarını tahmin etmeyi amaçlar (Cheng ve Tsai, 2022). SVR'nin optimizasyon problemi Denklem 11'deki gibi tanımlanmaktadır:

$$\begin{cases} \text{Min. } \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^n \xi_i \\ \text{sub. t. } \begin{cases} y_i - \omega \Phi(x_i) - b \leq \varepsilon + \xi_i \\ -y_i + \omega \Phi(x_i) + b \leq \varepsilon + \xi_i^* \\ \xi_i, \xi_i^* \geq 0 \end{cases} \end{cases} \quad (11)$$

Burada  $\omega$ , ağırlık vektörü;  $b$ , bias terimi;  $\xi_i$  ve  $\xi_i^*$ , hata terimleri;  $C$ , ceza parametresi ve  $\varepsilon$ , marj genişliğidir. Topluluk öğrenme yöntemlerinden biri olan XGBoost (Extreme Gradient Boosting), birçok zayıf öğrenicinin birleşiminden güçlü bir model oluşturur (Ding, 2023). XGBoost'un temel formülü Denklem 12'deki gibidir:

$$\hat{y}_i = \sum_{k=1}^K f_k(x_i) \quad (12)$$

Burada  $K$ , zayıf öğrenici sayısı ve  $f_k$ ,  $k$  zayıf öğrenici tarafından yapılan tahmindir. XGBoost, her iterasyonda mevcut modelin hatalarını azaltmak için yeni bir model ekler (Man, 2023) ve bu süreç Denklem 13'te gösterildiği şekilde ifade edilmektedir:

$$L(t) = \sum_{i=1}^n l(y_i, \hat{y}_i^{(t-1)} + f_t(x_i)) + \Omega(f_t) \quad (13)$$

Burada  $L(t)$ ,  $t$  iterasyonundaki kayıp fonksiyonu;  $l$ , hata fonksiyonu ve  $\Omega$ , model karmaşıklık ceza terimidir.

Random Forest, birçok karar ağacının birleşiminden oluşur (Norouzi vd., 2015) ve her bir ağacın tahminleri ortalaması alınarak nihai tahmin elde edilir (Kulkarni ve Sinha, 2012). Her bir karar ağacı,  $h(x, \theta_k)$  ile gösterilir ve Random Forest tahmini Denklem 14'teki gibi ifade edilmektedir:

$$\hat{y} = \frac{1}{K} \sum_{k=1}^K h(x, \theta_k) \quad (14)$$

Burada  $K$ , karar ağacı sayısı;  $x$ , giriş vektörü ve  $\theta_k$ ,  $k$  karar ağacı için rastgele seçilen parametrelerdir.

Bu modellerin her biri, Türkiye hurda demir çelik ithalatını tahmin etmek için kullanılmıştır. Tüm modeller için hiperparametre ayarları Random Search (Rastgele Arama) algoritması ile yapılmıştır ve Tablo 3'te her bir model için belirlenen ayarlar gösterilmiştir. Random Search algoritması, özellikle makine öğrenimi ve derin öğrenme bağlamlarında hiperparametre optimizasyonu alanında yaygın olarak tanınan bir yöntemdir. Belirli bir ızgaradaki tüm hiperparametre değerleri kombinasyonlarını kapsamlı bir şekilde değerlendiren ızgara arama gibi daha geleneksel yöntemlere bir alternatif olarak hizmet etmektedir. Buna karşılık, Random Search, hiperparametreleri belirli sayıda iterasyon boyunca önceden tanımlanmış bir dağılımdan örnekleyerek tatmin edici çözümler bulmak için daha keşifsel bir yaklaşıma olanak sağlamaktadır (Shin vd., 2023). Bu örnekleme tekniği, özellikle yüksek boyutlu uzaylarda optimum hiperparametre yapılandırılmalarının daha verimli bir şekilde keşfedilmesini sağlayabilir (Alanezi, 2023).

**Tablo 3. Random Search Algoritması ile Optimizasyon Sonucu Modellerin Belirlenen Hiperparametreleri**

Random Forest	Linear Regression	LSTM	SVR	XGBoost	MLP
n_estimators:300	Preset: Linear	Units:150	Kernel: rbf	Sub_sample:6	Activation: ReLU
max depth: 30	Terms: Linear	Optimizer: rmsprop	Epsilon: 0,01	n_estimators: 200	Alpha: 0,01783
min samples split: 2	Robust option: Off	Epochs: 100	C: 1	max_depth: 5	Hidden layer sizes:(200,100)
min samples leaf: 1	Fit_intercept: True	Dropout rate: 0,3	Max_iter: 1000	learning rate: 0,15	Learning rate: constant
max features: log2	Random state: 42	Batch size: 16	Tol: 1e-3	colsample_bytree: 1,0	Learning_rate_init:0,00096
bootstrap: True		Random state: 42	Shrinking: True	min_child_weight: 1	Max_iter: 1500
Random state: 42			Cache_size: 200	gamma: 0	Optimizer: Adam
criterion: gini			Verbose: False	reg_alpha: 0	Loss Function: Mean Squared Error
			Random state: 42	reg_lambda: 1	Batch_size: 32
				scale_pos_weight: 1	Beta_1: 0,9
				Random state: 42	Beta_2: 0,999
					Epsilon: 1e-8
					Early stopping: False
					Tol: 1e-4
					Random state: 42

### 3.5. Model Değerlendirme

Veri seti, modellerin eğitimi ve değerlendirilmesi amacıyla %80 eğitim ve %20 test olacak şekilde bölünmüştür. Bu bölünme, eğitim setinin model parametrelerini öğrenmesine olanak tanırken, test seti modelin daha önce görmediği veriler üzerindeki performansını değerlendirmek için kullanılmıştır. Bu bölümlendirme işlemi sırasında random state parametresi kullanılmıştır. Random state parametresi, veri setinin her seferinde aynı şekilde bölünmesini sağlayarak, modellerin tahmin performanslarının tutarlı ve karşılaştırılabilir olmasını sağlamıştır (Ferrari vd., 2018). Modellerin genelleştirilebilirliğini değerlendirmek için 15 katlı k-fold çapraz doğrulama kullanılmıştır. Çapraz doğrulama, veri setinin k eşit parçaya bölünmesi ve her bir parçanın bir kez test seti, kalan k-1 parçanın ise eğitim seti olarak kullanılması ile gerçekleştirilir (Moon vd., 2020). Bu süreç, her model için toplam 15 kez tekrarlanmış ve her tekrarda farklı bir parça test seti olarak kullanılmıştır. k-fold çapraz doğrulama,

modelin performansını veri setinin farklı bölümlerinde değerlendirmeyi ve genelleştirilebilirliğini artırmayı amaçlar (Naseem vd., 2019). Bununla birlikte, modellerin eğitim, test ve çapraz doğrulama performanslarını değerlendirmek için MSE (Ortalama Karesel Hata), MAE (Ortalama Mutlak Hata), MAPE (Ortalama Mutlak Yüzde Hata), RMSE (Ortalama Karesel Hata Kökü) ve  $R^2$  (Determinasyon Katsayısı) gibi farklı değerlendirme ölçütleri kullanılmıştır. Bu ölçütlerin matematiksel hesaplamaları sırasıyla Denklem 15-19'da gösterilmiştir.

$$MSE = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (15)$$

$$MAE = \frac{\sum_{i=1}^n |t_i - g_i|}{n} = \frac{\sum_{i=1}^n e_i}{n} \quad (16)$$

$$MAPE = \frac{\sum_{t=1}^n \frac{u_t}{\bar{y}_t}}{n} \times 100 \quad (17)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{N}} \quad (18)$$

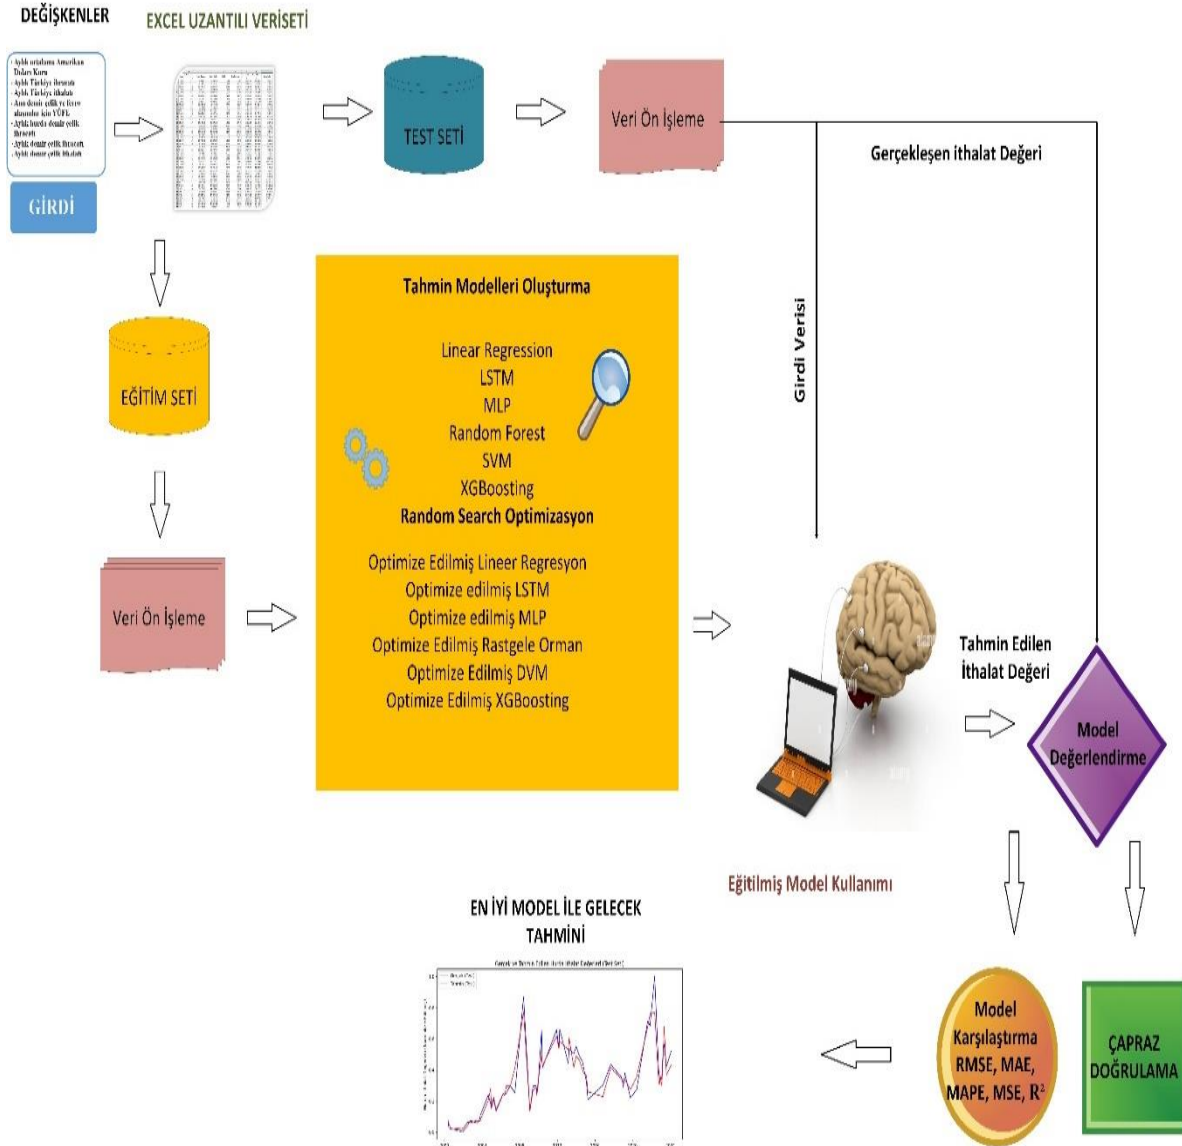
$$R^2 = 1 - \frac{\sum_i (y_i - \hat{y}_i)^2}{\sum_i (y_i - \mu)^2} \quad (19)$$

Temel bir metrik olan MSE, tahmin edilen ve gerçek değerler arasındaki karesel farkların ortalamasını hesaplar. Tahminlerin gerçek değerlerden ortalama karesel sapmasının bir ölçüsünü sağlar (Tyass vd., 2023). Öte yandan MAE, tahmin edilen ve gerçek değerler arasındaki mutlak farkların ortalamasını hesaplar ve farkların karesini almadan hata büyüklüğünün daha sezgisel bir şekilde anlaşılmasını sağlar (Bilgili vd., 2022). Bir diğer önemli metrik olan MAPE, gerçek değerlere göre tahmin edilen ve gerçek değerler arasındaki yüzde farkını hesaplar. Göreceli bir doğruluk ölçüsü sunarak hatanın yüzde cinsinden yorumlanmasını kolaylaştırır (Metlek vd., 2021). MSE'nin karekökü olan RMSE, tahmin hatalarının standart sapmasının bir ölçüsünü sağlayarak MSE ve MAE'nin faydalarını birleştirir ve kareleme etkisi nedeniyle büyük hatalara daha fazla ağırlık verir (Truong vd., 2021). RMSE, tahminlerdeki daha büyük hataların cezalandırılmasında özellikle yararlıdır. Belirleme katsayısı olarak da bilinen  $R^2$ , bir regresyon modelindeki bağımsız değişkenlerden tahmin edilebilen bağımlı değişkendeki varyansın oranını ölçer. Bu değer 0 ile 1 arasında değişir ve 1 mükemmel uyumu gösterir (Elias vd., 2011).  $R^2$ , regresyon analizinde modelin ortalama etrafındaki veri noktalarının değişkenliğini ne kadar iyi açıkladığını değerlendirmek için çok önemli bir ölçüttür.

### 3.6. Önerilen Yaklaşım

Bu çalışmada, Türkiye'nin hurda demir çelik ithalat değerlerini tahmin etmede hangi modelin en başarılı tahmin performansını sergilediğini belirlemek ve bu model ile gelecek tahmini yapmak amaçlanmaktadır. Bu yaklaşım, tahmin doğruluğunu artırmak ve finansal analiz süreçlerini optimize etmek için tasarlanmıştır. Veri toplama, ön işleme ve model eğitimi adımları titizlikle planlanmış ve yürütülmüştür. Ayrıca, modellerin performansını değerlendirmek için çeşitli göstergeler kullanılmıştır. Bu bağlamda, önerilen yöntemin genel organizasyonu ve işleyişine ilişkin bir açıklama, kapsamlı bir analizin dayandırılacağı bir şema aracılığıyla verilmektedir. Bu şema Şekil 1'de gösterilmektedir.






Şekil 1. Önerilen Yaklaşım

Şekil 1’de gösterilen şemada, hurda demir çelik ithalatını tahmin etmek için çok aşamalı ve sistematik bir süreç izlenmektedir. Başlangıçta aylık ortalama Amerikan Doları Kuru, aylık Türkiye ihracatı, aylık Türkiye ithalatı, ana demir çelik ve ferro alaşımlar için YÜFE, aylık hurda demir çelik ihracatı, aylık demir çelik ihracatı ve aylık demir çelik ithalatı gibi bağımsız değişkenler kullanılarak kapsamlı bir veri kümesi oluşturulmuştur. Bu değişkenlerin, birbirinden bağımsızlığını ve aralarında çoklu doğrusal bağıntının (multicollinearity) olup olmadığını tespit etmek amacıyla korelasyon analizi ve VIF (Variance Inflation Factor) analizi yapılmıştır. Korelasyon analizi, iki veya daha fazla değişken arasındaki ilişkinin gücünü ve yönünü değerlendirmek için kullanılan istatistiksel bir yöntemdir. Korelasyon analizinin en önemli yönlerinden biri, -1 ile 1 arasında değişen korelasyon katsayılarını kullanarak değişkenler arasındaki ilişkinin derecesini ölçme yeteneğidir. 1’e yakın bir katsayı güçlü bir pozitif korelasyona işaret eder, yani bir değişken arttıkça diğeri de artma eğilimindedir. Tersine, -1’e yakın bir katsayı, bir değişkendeki artışın diğesinde azalmaya karşılık geldiği güçlü bir negatif korelasyona işaret eder. Katsayının 0 civarında olması ise korelasyon olmadığını gösterir (Karacv vd., 2023). VIF analizi, regresyon analizinde bağımsız değişkenler arasındaki çoklu bağlantıyı tespit etmek için kullanılan istatistiksel bir yöntemdir. Çoklu doğrusallık, bir regresyon modelindeki iki veya daha fazla yordayıcı değişkenin yüksek korelasyona sahip olması durumunda ortaya çıkar ve bu da katsayıların güvenilir olmayan tahminlerine yol açarak standart hataları şişirebilir. VIF, çoklu doğrusallık nedeniyle bir regresyon katsayısının varyansının ne kadar arttığını ölçer. Spesifik olarak, tahmin ediciler ilişkili olduğunda tahmin edilen katsayıların varyansının, tahmin ediciler ilişkili olmadığında katsayıların varyansına oranı olarak hesaplanır. Bazı araştırmacılar 5 gibi daha yumuşak bir eşik değeri önermekle birlikte, 10’dan büyük bir VIF değeri genellikle önemli çoklu doğrusallığın göstergesi olarak kabul edilir (Naimi vd., 2013; Setiawati vd., 2023).

Korelasyon ve VIF analizleri sonucunda, modeldeki değişkenler arasında ciddi bir bağımlılık problemi olmadığı tespit edilmiş ve mevcut değişkenlerin tümü modellemeye dahil edilmiştir. Daha sonra, bu değişkenler kullanılarak oluşturulan veri setinin %80'i eğitim, %20'si de test setlerine ayrılmış ve her set modellemeye hazır olmak için bir dizi veri ön işlem prosedüründen geçmiştir. Modelleme aşamasında çeşitli derin öğrenme, makine öğrenimi ve topluluk öğrenme yöntemleri kullanılmaktadır. Bu modeller arasında Rastgele Orman, Doğrusal Regresyon, XGBoost, MLP, LSTM ve SVM yer almaktadır. Ek olarak, modellere her modelin performansını artırmaya yardımcı olan random serach optimizasyonu uygulanarak en iyi hiperparametreler belirlenmeye çalışılmıştır. Eğitim verileri, modellerin eğitiminde kullanılmış ve daha sonra tahminler üreten bir teste uygulanmıştır. Bu şekilde, yapılan tahminler gerçek ithalat değerleriyle karşılaştırılmıştır. Ayrıca, modellerin birbirlerine göre ne kadar iyi performans gösterdiğini ve modellerin hurda demir çelik ithalat değerini ne kadar doğru tahmin ettiğini değerlendirmek için RMSE, MAE, MAPE, MSE ve R<sup>2</sup> gibi değerlendirme metrikleri kullanılmıştır. Bununla birlikte, çapraz doğrulama tekniği de uygulanarak modellerin genelleme yetenekleri değerlendirilmiştir. Bu aşamalardan sonra en iyi model seçilmiş ve bu eğitilmiş model ile bağımsız değişkenler de dahil olmak üzere, gelecek 12 aylık hurda demir çelik ithalat değerleri tahmin edilmiştir.

#### 4. BULGULAR

Bu bölümde, bağımlı değişken ve bağımsız değişkenler arasındaki bağımsızlığı ve doğrusal ilişkileri tespit edebilmek amacıyla gerçekleştirilen korelasyon analizi sonuçları ve VIF analizi sonuçlarına yer verilmiştir. Şekil 2'de gösterilen korelasyon matrisi, "Aylık Hurda Demir Çelik İthalatı" ve diğer bağımsız değişkenler arasındaki doğrusal ilişkileri göstermektedir.



Şekil 2. Korelasyon Matrisi Sonuçları

Korelasyon matrisi incelendiğinde, "Aylık Hurda Demir Çelik İthalatı" bağımlı değişkeni ile en yüksek pozitif korelasyonun %81 oranında "Aylık Demir Çelik İthalatı" değişkeni arasında olduğu görülmektedir. Bu, hurda


demir çelik ithalatının, demir çelik ithalatıyla yakından ilişkili olduğunu göstermektedir. Diğer yandan, “Aylık Hurda Demir Çelik İthalatı” ile “Aylık Türkiye İhracatı”, “Aylık Türkiye İthalatı”, “Aylık Hurda Demir Çelik İhracatı” ve “Aylık Demir Çelik İhracatı” değişkenleri arasındaki korelasyonlar nispeten düşük olup, sırasıyla %16, %34, %14 ve %21 oranındadır. Bu durum, bu değişkenlerin hurda demir çelik ithalatı üzerindeki etkilerinin daha sınırlı olabileceğini düşündürmektedir. Özellikle, “Aylık Amerikan Dolar Kuru (TL)” ve “YÜFE” değişkenleri ile “Aylık Hurda Demir Çelik İthalatı” arasında sırasıyla %12 ve %9'luk düşük bir korelasyon bulunması, döviz kuru dalgalanmalarının ve genel fiyat seviyelerinin hurda demir çelik ithalatına doğrudan bir etkisinin sınırlı olabileceğini işaret etmektedir. Bu sonuçlar, modelleme çalışmalarında bu değişkenler arasındaki ilişkilerin daha detaylı incelenmesi gerektiğini ortaya koymaktadır. Bununla birlikte, gerçekleştirilen VIF analizi sonuçlarında, her bir bağımsız değişkenin diğer bağımsız değişkenlerle olan çoklu doğrusal bağıntısı ölçülmüş ve bu sonuçlar Tablo 4’te gösterilmiştir.

**Tablo 4. VIF Analizi Sonuçları**


Değişkenler	VIF
Const (sabit terim)	1,003103
Aylık Amerikan Dolar Kuru (TL)	2,973388
Aylık Türkiye İhracatı	2,746065
Aylık Türkiye İthalatı	2,338744
YÜFE	3,015129
Aylık Hurda Demir Çelik İhracatı	1,393874
Aylık Demir Çelik İhracatı	1,743747
Aylık Demir Çelik İthalatı	1,522132

Tablo 4’teki sonuçlara göre, modelde yer alan bağımsız değişkenler arasında çoklu doğrusal bağıntının ciddi bir sorun teşkil etmediği görülmektedir. “YÜFE” değişkeni için VIF değeri 3,015, “Aylık Amerikan Dolar Kuru (TL)” için 2,973, ve “Aylık Türkiye İhracatı” için 2,746 olarak bulunmuş olup, bu değerler orta düzeyde bir bağıntıyı işaret etmekle birlikte, genellikle kabul edilebilir sınırlar içindedir. Diğer değişkenlerin VIF değerleri 1,5 ile 2,3 arasında değişmekte olup, bu da düşük düzeyde bir çoklu doğrusal bağıntının varlığını göstermektedir. Özellikle, 5’in üzerinde bir VIF değerine sahip hiçbir değişkenin bulunmaması, bağımsız değişkenler arasında ciddi bir doğrusal bağıntı olmadığını ve bu durumun regresyon modeli üzerinde olumsuz bir etkisinin olmayacağını göstermektedir (Setiawati vd., 2023). Dolayısıyla, modelde yer alan tüm değişkenler, çoklu doğrusal bağıntının model tahminlerini bozmayacağı bir güven düzeyinde birlikte kullanılabilir. Bununla birlikte, daha yüksek VIF değerlerine sahip olan değişkenlerin modelde kullanılması sırasında dikkatli olunmalı ve bu değişkenlerin gereksiz yere modelde tekrar eden bilgi sağlayıp sağlamadığı değerlendirilmelidir. Bu sonuçlar, modelin genelleme yeteneğinin korunacağını ve tahmin gücünün yüksek kalacağını göstermektedir.


Bu analizler sonucunda oluşturulan veri seti, ön işlem adımlarından geçirilip, eğitim ve test setlerine ayrıldıktan sonra makine öğrenimi, derin öğrenme ve topluluk öğrenme tekniklerinin hurda demir çelik ithalat tahminindeki performansları değerlendirilmiştir. Lineer Regresyon, LSTM, XGBoost, MLP, Random Forest, SVM ve XGBoost modelleri eğitim setindeki veriler kullanılarak eğitilmiştir. Eğitim performanslarının karşılaştırılmasından sonra, sonuçlar kıyaslanma amacıyla  $R^2$  ve MAE, RMSE, MAPE ve MSE kullanılarak ölçülmüştür. Eğitim sonuçlarının tahmin grafiği Şekil 3’te gösterilirken, Tablo 5 eğitim sonuçlarının metrik ölçümlerini sunmaktadır.




(a) Linear Regression Modeli




(b) LSTM Modeli




(c) MLP Modeli



(d) Random Forest Modeli



(e) SVM Modeli



(f) XGBoosting Modeli

**Şekil 3. Modellerin Eğitim Sonuçlarına İlişkin Tahmin Grafikleri**


Şekil 3'te, Linear Regression, LSTM, MLP, Random Forest, SVM ve XGBoosting modellerinin eğitim seti üzerindeki tahmin performansları karşılaştırılmaktadır. Her bir alt grafik, modelin gerçek ve tahmin edilen hurda demir çelik ithalat değerlerini zaman serisi boyunca göstermektedir. Grafikler, tüm modellerin genel trendi yakalama yeteneğine sahip olduğunu, ancak her modelin tahmin doğruluğunda farklılıklar gösterdiğini ortaya koymaktadır. Linear Regression ve SVM modelleri, veri setinin değişkenliklerini ve ani dalgalanmalarını yakalamakta diğer modellere göre daha sınırlı kalmıştır. LSTM ve MLP modelleri, zaman serisi verilerindeki uzun dönemli bağımlılıkları daha iyi öğrenerek daha doğru tahminler sağlamıştır. Random Forest ve XGBoost modelleri ise veri setinin karmaşıklığını ve dalgalanmalarını yakalamada oldukça başarılı olmuştur. Özellikle LSTM

modelinin gerçek değerlerle olan yakın uyumu, bu modelin zaman serisi verilerindeki performansını vurgulamaktadır. Bu sonuçlar, derin öğrenme ve topluluk öğrenme yöntemlerinin hurda demir çelik ithalatı tahmininde yüksek performans sağladığını göstermektedir.


**Tablo 5. Modellerin Eğitim Sonuçlarının Metrik Ölçümleri**

	Linear Regression	LSTM	MLP	Random Forest	SVM	XGBoost
RMSE	0,0583	0,0387	0,0571	0,0227	0,0394	0,0007
MSE	0,0034	0,0014	0,0032	0,0005	0,0015	0,0003
MAE	0,0454	0,0297	0,0440	0,0166	0,0277	0,0006
MAPE	0,1784	0,1261	0,0641	0,0006	0,1079	0,0039
R <sup>2</sup>	0,9163	0,9631	0,9197	0,9873	0,9616	0,9999

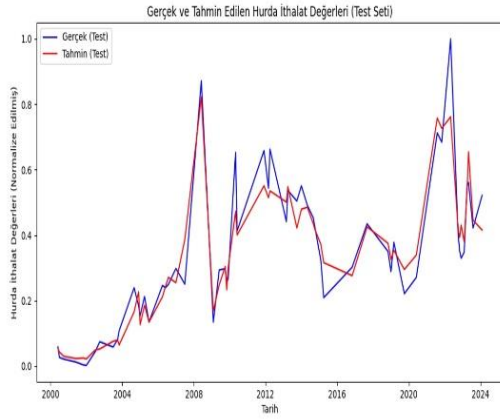
Tablo 5, Linear Regression, LSTM, MLP, Random Forest, SVM ve XGBoost modellerinin eğitim sonuçlarını RMSE, MSE, MAE, MAPE ve R<sup>2</sup> metrikleri açısından karşılaştırmaktadır. XGBoost modeli, tüm metriklerde en düşük hata oranlarına ve en yüksek R<sup>2</sup> değerine ulaşarak en üstün performansı sergilemiştir. Özellikle, XGBoost modelinin RMSE değeri 0,0007 MSE değeri 0,0003 ve MAE değeri 0,0006 olup, R<sup>2</sup> değeri 0,9999 ile neredeyse mükemmel bir uyum göstermiştir. Random Forest modeli de oldukça düşük hata oranları ve yüksek R<sup>2</sup> değeri (0,9873) ile dikkat çekmektedir. LSTM modeli, zaman serisi verilerindeki uzun dönemli bağımlılıkları öğrenme kapasitesi sayesinde düşük RMSE (0,0387) ve yüksek R<sup>2</sup> (0,9631) değerleri ile öne çıkmıştır. Buna karşılık, Linear Regression ve MLP modelleri diğer modellere kıyasla daha yüksek hata oranlarına sahip olup, sırasıyla R<sup>2</sup> değerleri 0,9163 ve 0,9197 olarak belirlenmiştir. SVM modeli ise makul bir performans sergilemiş, ancak hata oranları LSTM ve Random Forest modellerine göre biraz daha yüksek kalmıştır. Bu sonuçlar, özellikle XGBoost ve Random Forest modellerinin hurda demir çelik ithalatı tahmininde üstün performans gösterdiğini, LSTM modelinin de zaman serisi analizlerinde güçlü bir alternatif olduğunu göstermektedir. Aşağıdaki Şekil 4, modellerin test seti üzerindeki tahmin grafiklerini göstermektedir.




(a) Linear Regression




(b) LSTM Modeli



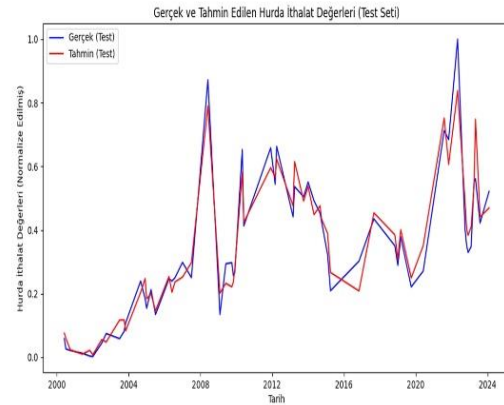
(c) MLP Modeli



(d) Random Forest Modeli



(e) SVM Modeli



(f) XGBoost Modeli

**Şekil 4. Modellerin Test Sonuçlarına İlişkin Tahmin Grafikleri**

Şekil 4'te, Linear Regression, LSTM, MLP, Random Forest, SVM ve XGBoost modellerinin test seti üzerindeki tahmin performansları karşılaştırılmaktadır. Grafiklerde, her modelin gerçek ve tahmin edilen hurda demir çelik ithalat değerleri zaman serisi boyunca gösterilmiştir. Bu grafikler, modellerin genel trendleri yakalama kapasitelerini ve test seti üzerindeki performanslarını değerlendirmektedir. LSTM ve Random Forest modelleri, gerçek verilerle yüksek uyum göstererek tahmin doğruluğunda öne çıkmaktadır. Özellikle LSTM modeli, zaman serisi verilerindeki ani dalgalanmaları ve uzun dönemli bağımlılıkları etkin bir şekilde yakalamıştır. XGBoost modeli de gerçek değerlerle güçlü bir uyum sağlayarak dikkat çekmektedir. Buna karşılık, Linear Regression ve

SVM modelleri, veri setinin değişkenliklerini ve dalgalanmalarını yakalamada diğer modellere göre daha sınırlı performans sergilemiştir. MLP modeli ise doğrusal olmayan ilişkileri öğrenme kapasitesine rağmen, bazı ani değişikliklerde zorluklar yaşamıştır. Genel olarak, grafikler, derin öğrenme ve topluluk öğrenme yöntemlerinin hurda demir çelik ithalatı tahmininde üstün performans gösterdiğini ve bu modellerin test seti üzerindeki doğruluğunu vurgulamaktadır. Tablo 6’da modellerin test sonuçlarının metrik ölçümleri gösterilmektedir.

**Tablo 6. Modellerin Test Sonuçlarının Metrik Ölçümleri**

	Linear Regression	LSTM	MLP	Random Forest	SVM	XGBoost
RMSE	0,0646	0,0343	0,0639	0,0689	0,0497	0,0560
MSE	0,0041	0,0012	0,0040	0,0047	0,0025	0,0031
MAE	0,0447	0,0275	0,0451	0,0462	0,0374	0,0381
MAPE	0,1561	0,1092	0,1879	0,1802	0,1333	0,1769
R <sup>2</sup>	0,9141	0,9628	0,9158	0,9022	0,9232	0,9354

Tablo 6’deki sonuçlara göre, LSTM modeli, en düşük RMSE (0,0343) ve MAE (0,0275) değerleri ile test setinde en iyi performansı göstermiştir ve yüksek bir R<sup>2</sup> değeri (0,9628) ile veriyi iyi bir şekilde açıkladığını ortaya koymaktadır. XGBoost modeli de düşük hata oranları ve yüksek R<sup>2</sup> değeri (0,9354) ile dikkat çekmektedir, ancak LSTM'nin gerisinde kalmıştır. Random Forest modeli, makul bir performans sergilemiş ancak RMSE (0,0689) ve MAE (0,0462) değerleri LSTM ve XGBoost modellerinden daha yüksek olmuştur. MLP ve Linear Regression modelleri de test setinde iyi performans göstermiştir, ancak diğer modellere göre daha yüksek hata oranlarına sahiptir. SVM modeli, R<sup>2</sup> değeri (0,9232) ile yüksek performans sergilemiş, ancak MAPE (0,1333) ve MAE (0,0374) değerleri bazı diğer modellerin gerisinde kalmıştır. Bu sonuçlar, LSTM ve XGBoost modellerinin hurda demir çelik ithalatı tahmininde üstün performans gösterdiğini, özellikle LSTM'nin test setindeki en düşük hata oranlarına ve en yüksek doğruluğa sahip olduğunu göstermektedir.

Bununla birlikte, bu çalışmada, modellerin performansını daha güvenilir ve genelleştirilebilir bir şekilde değerlendirebilmek amacıyla 15 katlı çapraz doğrulama yöntemi uygulanmıştır. Çapraz doğrulama, modelin yeni ve görülmemiş veriler üzerindeki performansını tahmin etmede daha doğru sonuçlar elde etmeyi sağlamaktadır. Bu yöntem, veri setinin farklı alt kümelerini kullanarak modelin eğitilmesine ve test edilmesine olanak tanır, böylece veri setinin tamamından maksimum verimi almaya yardımcı olur. Ayrıca, çapraz doğrulama, modelin aşırı uyum yapıp yapmadığını tespit etmeye yardımcı olur, çünkü modelin farklı veri alt kümelerinde tutarlı performans gösterip göstermediğini kontrol eder. Performans değerlendirmesi sırasında, çapraz doğrulama sonuçları modelin ortalama performansını ve performans değişkenliğini değerlendirerek modelin ne kadar istikrarlı ve güvenilir olduğunu anlamaya imkân tanır. Ayrıca, farklı modellerin performanslarını objektif ve tarafsız bir şekilde karşılaştırmak için kullanılır, böylece modeller arasında adil bir karşılaştırma yapılabilir. Bu nedenlerden dolayı, 15 katlı çapraz doğrulama yönteminin kullanılması, model performanslarını daha güvenilir bir şekilde değerlendirmeyi ve en iyi model seçiminin daha sağlam bir temele oturtulmasını sağlamıştır. Tablo 7’de modellerin 15 katlı çapraz doğrulama sonuçlarına ilişkin metrik ölçümleri gösterilmiştir.


**Tablo 7. Modellerin 15 Katlı Çapraz Doğrulama Sonuçlarının Metrik Ölçümleri**

	Linear Regression	LSTM	MLP	Random Forest	SVM	XGBoost
RMSE	0,0606	0,0573	0,0592	0,0587	0,0710	0,0630
MSE	0,0037	0,0034	0,0036	0,0036	0,0050	0,0039
MAE	0,0474	0,0424	0,0462	0,0439	0,0464	0,0460
MAPE	0,1832	0,1465	0,2087	0,1678	0,1688	0,1862
R <sup>2</sup>	0,8892	0,9183	0,8898	0,8965	0,8961	0,9006

Tablo 7 sonuçlarına göre, LSTM modeli, en düşük RMSE (0,0573) ve MAE (0,0424) değerleri ile çapraz doğrulamada en iyi performansı göstermiş ve yüksek bir R<sup>2</sup> değeri (0,9183) ile veriyi iyi bir şekilde açıkladığını ortaya koymuştur. XGBoost modeli, benzer şekilde düşük hata oranları ve yüksek R<sup>2</sup> değeri (0,9006) ile dikkat çekmiştir, ancak LSTM'nin gerisinde kalmıştır. Random Forest modeli de düşük RMSE (0,0587) ve MAE (0,0439) değerleri ile sağlam bir performans sergilemiştir. MLP ve Linear Regression modelleri makul performans göstermiş, ancak diğer modellere göre daha yüksek hata oranlarına sahip olmuştur. SVM modeli ise diğer modellere kıyasla daha yüksek hata oranlarına sahip olup, RMSE (0,0710) ve MAPE (0,1688) değerleri ile daha düşük performans göstermiştir. Genel olarak, bu sonuçlar LSTM ve XGBoost modellerinin hurda demir çelik

ithalatı tahmininde çapraz doğrulama sürecinde en güvenilir ve doğru tahminleri sağladığını, Random Forest modelinin de güçlü bir alternatif olduğunu göstermektedir.

LSTM modelinin test seti üzerindeki tahminlerinin açıklanabilirliğini artırmak ve modelin karar mekanizmasını daha iyi anlamak amacıyla LIME (Local Interpretable Model-agnostic Explanations) analizi gerçekleştirilmiştir. LIME, karmaşık modellerin tahminlerini daha anlaşılır hale getirmek için kullanılan bir yöntemdir ve modelin verdiği kararları yerel olarak açıklamaya odaklanır. Bu yöntem, özellikle derin öğrenme modelleri gibi genellikle “kara kutu” olarak nitelendirilen modellerin iç işleyişini anlamak için oldukça faydalıdır (Zafar ve Khan, 2021). LIME, modelin belirli bir veri noktasına verdiği yanıtı anlamak için, o veri noktasının çevresindeki verilerle basit bir model eğiterek tahminleri açıklar (Li, 2024). Bu sayede, LSTM modelinin test seti üzerindeki tahminlerinin hangi bağımsız değişkenler tarafından ne derece etkilendiği ve modelin bu tahminleri yaparken nasıl bir yol izlediği daha net bir şekilde anlaşılabilir. LIME analizi, modelin güvenilirliğini ve doğruluğunu artırmak için önemli bir araç olup, kullanıcıların modelin çıktılarının mantığını kavramalarına yardımcı olur (Torres vd., 2022). Şekil 5’de LSTM modelinin test seti üzerindeki bir tahminini açıklamak için LIME analizinin sonuçları gösterilmektedir.



Şekil 5. LSTM Modelinin Test Seti Üzerindeki LIME Analizi Sonuçları

Şekil 5’deki grafik, belirli bir veri noktası için modelin tahminine en çok katkıda bulunan özellikleri ve bu özelliklerin önem derecelerini görselleştirmektedir. Pozitif ve negatif etkiler, özelliklerin model tahminine olan etkilerini göstermektedir. Grafığe göre, “Demir Çelik İthalat” değişkeni (0,43 < Demir Çelik İthalat <= 0,53) modelin tahminine en yüksek pozitif etkiyi yapmıştır. Bu değişken, modelin tahmin değerini artırmada önemli bir rol oynamıştır. Diğer önemli pozitif etkili değişkenler arasında “YÜFE” (0,03 < YÜFE <= 0,05), “Demir Çelik İhracat” (Demir Çelik İhracat > 0,40) ve “Hurda İhracat” (0,12 < Hurda İhracat <= 0,28) bulunmaktadır. Bu değişkenler de modelin tahminini olumlu yönde etkilemiştir. Öte yandan, “Aylık Dolar Kuru” (0,03 < Aylık Dolar Kuru <= 0,04) değişkeni modelin tahminine negatif bir etki yapmış olup, tahmin değerini düşürmüştür. Bu sonuç, modelin bu değişkenin mevcut değerini göz önünde bulundurarak tahminini aşağı yönlü revize ettiğini göstermektedir. Daha az derecede etkili olan diğer değişkenler ise “Türkiye İthalatı” (0,25 < Türkiye İthalatı <= 0,48) ve “Türkiye İhracatı” (0,25 < Türkiye İhracatı <= 0,47) olarak görülmektedir. Bu değişkenlerin model tahminine olan etkisi sınırlı kalmıştır. Genel olarak, LIME analizi, LSTM modelinin belirli bir veri noktası için hangi değişkenlere ne kadar ağırlık verdiğini ve bu değişkenlerin model tahminine olan etkilerini açık bir şekilde göstermektedir. Bu tür analizler, modelin şeffaflığını artırarak kullanıcıların modelin karar mekanizmasını daha iyi anlamalarına olanak tanımaktadır.

Çalışmanın bundan sonraki aşamasında, hurda demir çelik ithalatına ilişkin gelecek tahmini için en iyi model olarak belirlenen LSTM modeli kullanılmıştır. Ancak, bu tahminlerin gerçekleştirilebilmesi için bağımsız değişkenlerin gelecekteki değerlerine ihtiyaç duyulmuştur. Bu bağlamda, bağımsız değişkenlerin gelecekteki değerleri de mevcut LSTM modeli kullanılarak tahmin edilmiş ve veri setine dahil edilmiştir. Böylece, LSTM modeli ile tahmin edilen bağımsız değişkenler ışığında, gelecek 12 aylık hurda demir çelik ithalat değerleri tahmin



edilmiştir. Bu yaklaşım, modelin zaman serisi verilerindeki bağımlılıkları ve trendleri öğrenme kapasitesinden yararlanarak, daha doğru ve güvenilir tahminler elde edilmesini sağlamıştır. LSTM modeli kullanılarak gerçekleştirilen bağımsız değişkenlerin gelecek 12 aylık tahmin değerleri Tablo 8’de gösterilmiştir.

**Tablo 8. LSTM Modeli ile Bağımsız Değişkenlerin Gelecek 12 Aylık Tahmin Sonuçları**

Dönem	Aylık Dolar Kuru	Türkiye İhracatı	Türkiye İthalatı	YÜFE	Hurda Demir Çelik İhracatı	Demir Çelik İhracatı	Demir Çelik İthalatı
2024-4	32,36	20.004.253.696	26.477.621.248	5.199,83	25.270.616	879.310.208	2.042.181.248
2024-5	33,33	19.377.522.688	25.159.544.832	5.405,83	25.140.330	869.811.072	1.979.635.200
2024-6	34,40	18.841.546.752	23.940.962.304	5.569,02	25.003.246	861.463.872	1.921.762.176
2024-7	35,45	18.396.610.560	22.790.881.280	5.711,53	24.869.270	853.092.992	1.866.697.472
2024-8	36,45	18.030.678.016	21.699.569.664	5.839,64	24.739.186	844.463.616	1.813.519.872
2024-9	37,38	17.730.717.696	20.663.357.440	5.955,47	24.611.940	835.579.968	1.761.657.472
2024-10	38,26	17.485.211.648	19.680.462.848	6.060,01	24.486.346	826.502.528	1.710.714.624
2024-11	39,07	17.284.524.032	18.749.769.728	6.153,88	24.361.506	817.299.840	1.660.411.392
2024-12	39,83	17.120.690.176	17.870.356.480	6.237,60	24.236.812	808.037.504	1.610.552.448
2025-1	40,52	16.987.188.224	17.041.297.408	6.311,65	24.111.914	798.774.208	1.561.011.584
2025-2	41,16	16.878.689.280	16.261.552.128	6.376,45	23.986.664	789.561.728	1.511.715.712
2025-3	41,75	16.790.852.608	15.529.896.960	6.432,46	23.861.060	780.444.544	1.462.634.880

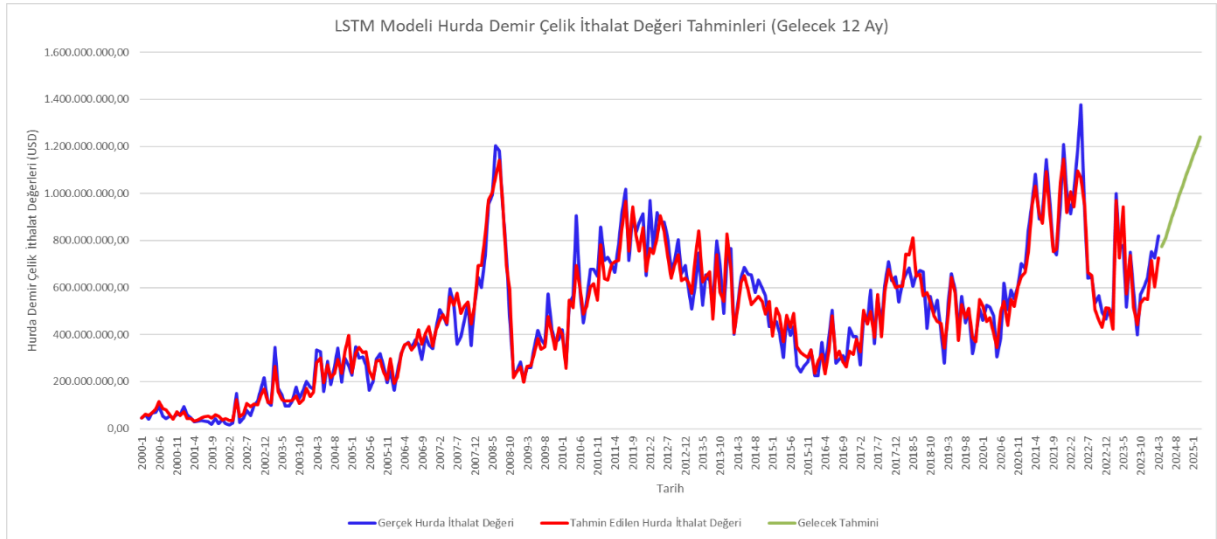
Tablo 8, LSTM modeli kullanılarak bağımsız değişkenlerin 2024 yılının Nisan ayından 2025 yılının Mart ayına kadar olan tahmin edilen değerlerini göstermektedir. Tahmin edilen bağımsız değişkenler arasında aylık dolar kuru, Türkiye ihracatı, Türkiye ithalatı, YÜFE (Tüketici Fiyat Endeksi), hurda demir çelik ihracatı, demir çelik ihracatı ve demir çelik ithalatı yer almaktadır. Genel olarak, LSTM modeli kullanılarak yapılan tahminler, dolar kurunda sürekli bir artış, Türkiye’nin ihracat ve ithalatında azalma, YÜFE’de artış ve hurda demir çelik ile demir çelik ihracatı ve ithalatında azalma eğilimlerini ortaya koymaktadır. Bu tahminler, gelecekteki ekonomik ve ticari planlamalar için önemli bilgiler sunmaktadır.

LSTM modeli kullanılarak bağımsız değişkenlerin gelecek 12 aylık tahmin değerleri elde edildikten sonra, bu tahmin edilen değerler veri setine dahil edilmiştir. Bu adım, modelin gelecekteki hurda demir çelik ithalatını daha doğru bir şekilde tahmin etmesini sağlamaktadır. Gelecek 12 aylık dönem için bağımsız değişkenlerin tahmin edilen değerleri de kullanılarak, LSTM modeli ile hurda demir çelik ithalatı tahmin edilmiştir. Bu yöntem, modelin zaman serisi verilerindeki bağımlılıkları ve trendleri öğrenme kapasitesinden faydalanarak, gelecekteki ithalat değerleri hakkında daha güvenilir ve tutarlı tahminler elde etmeye olanak tanımaktadır. Böylece, elde edilen tahminler, ekonomik ve ticari planlamalar için önemli bilgiler sunarak, karar verme süreçlerini desteklemektedir. Tablo 9’da bu tahmin sonuçları gösterilmektedir.

Tablo 9. LSTM Modeli ile Hurda Demir Çelik İthalatının 12 Aylık Gelecek Tahmini

Dönem	Hurda Demir-Çelik İthalatı (USD)
2024-4	773.378.496
2024-5	810.046.720
2024-6	854.044.288
2024-7	899.588.160
2024-8	945.076.480
2024-9	990.013.312
2024-10	1.034.191.104
2024-11	1.077.477.760
2024-12	1.119.757.952
2025-1	1.160.927.360
2025-2	1.200.885.632
2025-3	1.239.538.176

Tablo 9’da, LSTM modeli kullanılarak 2024 Nisan'dan 2025 Mart'a kadar hurda demir çelik ithalatının tahmin edilen değerleri gösterilmektedir. Sonuçlar, hurda demir çelik ithalatının sürekli bir artış trendi izlediğini ortaya koymaktadır. Nisan 2024'te 773.378.496 USD olarak tahmin edilen ithalat miktarı, her ay düzenli olarak artarak Mart 2025'te 1.239.538.176 USD'ye ulaşmaktadır. Bu sürekli artış trendi, ekonomik büyüme, sanayi talebi ve makroekonomik faktörlerin etkisiyle ilişkilendirilebilir. LSTM modelinin sağladığı bu tahminler, ilgili sektörlerdeki planlama ve strateji geliştirme süreçlerine önemli katkılar sağlayarak, karar alıcılar için değerli bir bilgi kaynağı oluşturabilir. Ek olarak Şekil 6’da LSTM modeli kullanılarak yapılan hurda demir çelik ithalatı tahminlerini ve gelecekteki 12 aylık tahmin değerleri gösterilmiştir. Grafikte, mavi renk gerçek hurda ithalat değerlerini, kırmızı renk model tarafından tahmin edilen geçmiş hurda ithalat değerlerini ve yeşil renk ise LSTM modeli tarafından tahmin edilen gelecek 12 aylık hurda ithalat değerlerini temsil etmektedir.



Şekil 6. LSTM Modeli ile Hurda Demir Çelik İthalat Değerlerinin Tahminleri ve Gelecek 12 Aylık Öngörüler

## 5. SONUÇ, TARTIŞMA VE ÖNERİLER

Bu çalışmada, Türkiye'nin hurda demir çelik ithalatının gelecekteki değerlerini tahmin etmek amacıyla derin öğrenme, makine öğrenmesi ve topluluk öğrenme yöntemleri kullanılmıştır. LSTM modeli, zaman serisi verilerindeki uzun vadeli bağımlılıkları öğrenme kapasitesi sayesinde en iyi tahmin performansını göstermiştir. LSTM modeli ile, bağımsız değişkenlerin gelecekteki değerleri tahmin edilip yeni veri seti oluşturularak, hurda demir çelik ithalatının gelecek 12 aylık tahminleri yapılmıştır. Sonuçlar, hurda demir çelik ithalatının sürekli artan bir trend izlediğini göstermektedir. Model tahminlerine göre ithalat değerleri Nisan 2024'te 773.378.496 USD, Mart 2025'te 1.239.538.176 USD'ye ulaşacaktır. Bu sonuçlar, ekonominin ne yönde büyüyeceğine ilişkin bilgiler sağlayarak, karar vericiler için önemli bir bilgi kaynağı olabileme potansiyeline sahiptir.

Bu çalışmanın sonuçları, literatürdeki benzer çalışmalarla karşılaştırıldığında, LSTM modelinin özellikle uzun vadeli bağımlılıkları yakalama ve zaman serisi verilerindeki karmaşık örüntüleri öğrenme konusundaki üstün yeteneğini bir kez daha doğrulamaktadır. Tablo 10'da literatürdeki çalışmalar ile bu çalışmanın sonuçları karşılaştırılmaktadır.

**Tablo 10. Literatürdeki Çalışmalarla Mevcut Çalışmanın Sonuçlarının Karşılaştırılması**

Çalışma	Odak Konusu	Model/Method	Sonuçlar ve Bulgular	Mevcut Çalışmadaki Karşılığı
Albayrak (2011)	Çelik üretim ve tüketim tahmini	Çeşitli tahmin modelleri	Çelik üretim ve tüketim tahminlerinde geleneksel yöntemler kullanılmıştır.	Hurda demir çelik ithalat tahminine özgü odak noktası, LSTM modeli kullanımıyla farklılık gösterir.
Bulum (2015)	Çelik üretim ve tüketim tahmini	Çeşitli tahmin modelleri	Çelik üretim ve tüketim tahminlerinde geleneksel yöntemler ve bazı makine öğrenimi yöntemleri kullanılmıştır.	Hurda demir çelik ithalatı üzerine spesifik odaklanma ve LSTM modeliyle farklılık sağlar.
Jiang vd. (2019)	Çelik üretim süreçleri tahmini	SVR	SVR modelinin çelik üretim süreçlerinde üstün performans gösterdiği belirtilmiştir.	Hurda demir çelik ithalat tahmininde LSTM modelinin SVR'ye kıyasla daha yüksek doğruluk sağladığı görülmüştür.
Meng vd. (2018)	Topluluk öğrenme yöntemlerinin etkinliği	Random Forest, XGBoost, ve diğer topluluk yöntemleri	Topluluk öğrenme yöntemlerinin yüksek doğruluk sağladığı vurgulanmıştır.	LSTM modelinin Random Forest ve XGBoost'a kıyasla üstün performans sergilediği gözlemlenmiştir.
Wang (2022)	Topluluk öğrenme yöntemlerinin etkinliği	Random Forest, XGBoost, ve diğer topluluk yöntemleri	Topluluk öğrenme yöntemlerinin zaman serisi verilerinde başarılı olduğu belirtilmiştir.	LSTM modeli, bu çalışmada daha üstün performans göstererek, topluluk öğrenme yöntemlerini geride bırakmıştır.
Ryll ve Seidens (2019)	Finansal piyasa tahmini	Makine öğrenimi algoritmaları	Makine öğrenimi algoritmalarının geleneksel stokastik yöntemlere kıyasla daha başarılı olduğu ortaya konulmuştur.	LSTM modelinin geleneksel yöntemlere kıyasla hurda demir çelik ithalat tahmininde daha yüksek doğruluk sağladığı belirtilmiştir.
Mao vd. (2022), Dhakal vd. (2020), Mussumeci ve Coelho (2020), Lei vd. (2021)	Çeşitli veri setlerinde LSTM modelinin performansı	LSTM	LSTM modelinin çeşitli veri setlerinde ve tahmin görevlerinde üstün performans sergilediği gösterilmiştir.	LSTM modelinin hurda demir çelik ithalatı tahmininde etkinliği ve uygulama alanı genişletilmiştir.

Bununla birlikte, LIME analizi, LSTM modelinin hurda demir çelik ithalatı tahminlerindeki karar mekanizmalarını şeffaf hale getirerek hangi bağımsız değişkenlerin tahminlerde belirleyici rol oynadığını ortaya koymuştur. Analiz sonuçları, demir çelik ithalatı, aylık dolar kuru ve YÜFE gibi modele girdi olarak verilen değişkenlerin model tahminleri üzerinde önemli bir etkiye sahip olduğunu göstermektedir. Bu durum, modelin güvenilirliğini artıracak ve güvenilir tahmin yapılmasını sağlayacak önemli bilgiler elde etmemize yardımcı olmuştur. Ayrıca, LIME analizi, model tarafından üretilen belirli sonuçların nasıl ve neden üretildiğinin yorumlanması için politika yapıcılara yararlı bilgiler sağlamıştır. Özetle, LIME analizi modelin hem akademik araştırmalarda hem de endüstriyel uygulamalarda yorumlanabilirliğini ve ölçeklenebilirliğini artırmıştır.

Bu çalışmanın sonuçlarına dayanarak, hurda demir çelik ithalatı tahminlerinin sektör genelinde karar vericilere sağladığı bilgiler doğrultusunda çeşitli politika ve stratejiler önerilmektedir. İlk olarak, ithalat stratejilerinin optimize edilmesi ve tedarik zincirinin esnek ve sürdürülebilir hale getirilmesi önemlidir. Döviz kuru riskine karşı koruyucu önlemler alınarak maliyet yönetimi güçlendirilmelidir. Gelecekteki ithalat maliyetlerinin doğru tahmini, bütçe planlaması ve maliyet kontrolü açısından kritik öneme sahiptir. Stok düzeylerinin optimize edilmesi ve malzeme ihtiyaç planlamasının etkinleştirilmesi, üretim süreçlerinde kesintisiz malzeme akışını sağlar. Ayrıca, rekabet analizleri yapılarak sektör genelindeki pozisyonun güçlendirilmesi ve yeni pazar fırsatlarının belirlenmesi mümkündür. Endüstriyel ve çevresel politikaların geliştirilmesi, ithalatın düzenlenmesi ve teşvik edilmesi için rehberlik edebilir. Bu öneriler, tahmin edilen verilerin doğru kullanımıyla sektördeki verimliliği artırarak, sürdürülebilir ve rekabetçi bir yapı oluşturulmasına katkı sağlayacaktır. Ek olarak, ileride yapılacak çalışmalar için, hurda demir çelik ithalatı tahminlerinde daha geniş veri setlerinin kullanılması ve farklı makine öğrenmesi tekniklerinin uygulanması önerilmektedir. Özellikle, çeşitli makroekonomik ve sektörel verilerin entegrasyonu, tahminlerin doğruluğunu artırabilir. Ayrıca, modelin karar mekanizmalarının daha iyi anlaşılması için diğer açıklanabilir yapay zeka yöntemlerinin (örneğin, SHAP değerleri) kullanılması faydalı olacaktır. Çalışmanın kısıtlılıkları arasında, veri setinin sınırlı olması ve bazı bağımsız değişkenlerin eksik veya yanıltıcı olabilmesi yer almaktadır. Ayrıca, kullanılan modellerin yalnızca belirli koşullar altında geçerliliği bulunmakta olup, daha geniş ve çeşitli veri setleri ile test edilmesi gerekmektedir. Bu çalışma, Türkiye'nin hurda demir çelik ithalatının gelecekteki değerlerini tahmin etme konusunda literatüre önemli katkılar sunmaktadır. Elde edilen bulgular, sektörel planlama ve stratejik karar verme süreçlerine rehberlik ederek, ekonomik büyüme ve sürdürülebilir kalkınma için değerli bilgiler sağlayacaktır.

## EXTENDED SUMMARY

This study aims to predict the future values of Turkey's scrap iron and steel imports using comprehensive evaluations of deep learning, machine learning, and ensemble learning methods. Predicting scrap iron and steel imports is crucial for economic and industrial planning, supply chain management, inventory management, material requirement planning, and production planning. The increasing use of artificial intelligence and data analysis techniques in this context highlights the importance of accurate and reliable forecasting models.

In this study, LSTM (Long Short-Term Memory), MLP (Multi-Layer Perceptron), Random Forest, SVM (Support Vector Regression), XGBoost, and Linear Regression models were applied to forecast scrap iron and steel imports. The performance of these models was evaluated using metrics such as RMSE (Root Mean Squared Error), MSE (Mean Squared Error), MAE (Mean Absolute Error), MAPE (Mean Absolute Percentage Error), and  $R^2$  (Coefficient of Determination). Among these models, LSTM showed the best performance due to its ability to learn long-term dependencies in time series data.

The data set was divided into 80% training and 20% test sets, and 15-fold cross-validation was used to ensure the generalizability of the models. The models were trained and tested, and the results were compared based on the performance metrics mentioned above. The LSTM model, with its superior performance, was then used to predict the future values of the independent variables, which were incorporated into the data set to forecast the next 12 months of scrap iron and steel imports.

The LSTM model demonstrated the best predictive performance, with an RMSE of 0.0387, MSE of 0.0014, MAE of 0.0297, MAPE of 0.1261, and  $R^2$  of 0.9631 on the training set. The forecast results for the next 12 months indicate a continuous upward trend in scrap iron and steel imports. According to the predictions, the import amount, which is expected to be 773,378,496 USD in April 2024, will reach 1,239,538,176 USD by March 2025. These results suggest that the scrap iron and steel imports will follow a steady increasing trend.

LIME (Local Interpretable Model-agnostic Explanations) analysis was used to elucidate the decision mechanisms of the model, highlighting which independent variables played a decisive role in the predictions. This analysis increases the transparency and reliability of the model by providing insights into its decision-making process.

The results of this study align with those in the literature, reaffirming the superior capability of the LSTM model in capturing long-term dependencies and learning complex patterns in time series data. While studies such as Albayrak (2011) and Bulum (2015) focused on general steel production and consumption forecasts, this study is

unique in its specific focus on scrap iron and steel imports. Moreover, Jiang et al. (2019) found that support vector regression (SVR) performed well in predicting steel production processes, while our study shows that the LSTM model provides higher accuracy in forecasting scrap iron and steel imports.

Although ensemble learning methods like Random Forest and XGBoost have been shown to be effective in studies by Meng et al. (2018) and Wang (2022), the LSTM model outperformed these methods in our study. Additionally, while traditional methods have been effective in financial market forecasting, as shown by Ryll and Seidens (2019), our study demonstrates that the LSTM model can achieve higher accuracy in forecasting scrap iron and steel imports.

The success of LSTM models in various fields, as demonstrated by studies like Mao et al. (2022), Dhakal et al. (2020), Mussumeci and Coelho (2020), and Lei et al. (2021), is extended by our study, showing the efficacy and application of the LSTM model in predicting scrap iron and steel imports.

The findings of this study offer significant insights for industry decision-makers in optimizing import strategies, strengthening cost management, adjusting inventory levels, and conducting competitive analyses. The continuous upward trend in scrap iron and steel imports suggests that decision-makers should focus on enhancing supply chain flexibility and sustainability. Risk management strategies, such as hedging against currency fluctuations, are crucial for stabilizing costs. Additionally, accurate forecasts aid in better budget planning and cost control.

The limitations of this study include the limited data set and potential inaccuracies or biases in some independent variables. Future research should consider larger data sets and the integration of various macroeconomic and sectoral variables to improve forecast accuracy. Furthermore, applying other explainable AI methods, such as SHAP values, could provide deeper insights into the model's decision mechanisms.

This study contributes significantly to the literature by demonstrating the effectiveness and explainability of the LSTM model in forecasting scrap iron and steel imports. The high predictive accuracy of the LSTM model and the supportive role of other machine learning techniques offer valuable insights for sectoral planning and strategic decision-making. By highlighting the continuous upward trend in imports and providing a detailed analysis of the model's decision-making process, this study serves as a valuable resource for economic growth and sustainable development planning.

## KAYNAKÇA

- Adhikari, G. P. (2022). Interpreting the basic results of multiple linear regression. *Scholars' Journal*, 5(1), 22-37. <https://doi.org/10.3126/scholars.v5i1.55775>
- Alanezi, S. T., Krašny, M. J., Kleefeld, C., & Colgan, N. (2023). Differential diagnosis of prostate cancer grade to augment clinical diagnosis based on classifier models with tuned hyperparameters. *Cancers*, 16, 2163 <https://doi.org/10.20944/preprints202311.1822.v1>
- Albayrak, B. A. (2011). *Dünya Hurda Hareketleri ve 2020 Türkiye Projeksiyonu*. Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, s. 5-11.
- Ampomah, E. K., Nyame, G., Qin, Z., Addo, P. C., Gyamfi, E. O., & Gyan, M. (2021). Stock market prediction with gaussian naïve bayes machine learning algorithm. *Informatika*, 45(2). <https://doi.org/10.31449/inf.v45i2.3407>
- Bilgili, M., Keiyinci, S., & Ekinci, F. (2022). One-day ahead forecasting of energy production from run-of-river hydroelectric power plants with a deep learning approach. *Scientia Iranica*, 29(4), 1838-1852. <https://doi.org/10.24200/sci.2022.58636.5825>
- Bulum A. Z. (2015). *Türkiye demir-çelik sektörü için tahmin modelleri önerisi*. Yüksek Lisans Tezi, Karabük Üniversitesi, Fen Bilimleri Enstitüsü, Endüstri Mühendisliği Anabilim Dalı, Karabük.
- Cheng, C., & Tsai, M. (2022). An intelligent time series model based on hybrid methodology for forecasting concentrations of significant air pollutants. *Atmosphere*, 13(7), 1055. <https://doi.org/10.3390/atmos13071055>
- Çetin, B., & Filiz, T. (2023). Küresel hurda demir ticareti ilişkilerinin sosyal ağ analizi yöntemiyle değerlendirilmesi. *Mehmet Akif Ersoy Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 10 (1) , 158-182. DOI: 10.30798/makuiibf.1097376
- Çubuk, M. (2021). *Çok kriterli karar verme yöntemleri ile illerin yatırım ortamlarının karşılaştırılması*. Ankara: Gazi Kitabevi.

- Dhakal, S., Gautam, Y., & Bhattarai, A. (2020). Exploring a deep lstm neural network to forecast daily pm2.5 concentration using meteorological parameters in kathmandu valley, nepal. *Air Quality, Atmosphere & Health*, 14(1), 83-96. <https://doi.org/10.1007/s11869-020-00915-6>
- Ding, J., & Feng, D. (2023). Feature selection of ground motion intensity measures for data-driven surrogate modeling of structures. *Earthquake Engineering & Structural Dynamics*, 53(3), 1216-1237. <https://doi.org/10.1002/eqe.4068>
- Elias, R., Fang, L., & Wahab, M. (2011). Electricity load forecasting based on weather variables and seasonalities: a neural network approach. *Icassm11*. <https://doi.org/10.1109/icsssm.2011.5959472>
- Ferrat, L. A., Goodfellow, M., & Terry, J. R. (2018). Classifying dynamic transitions in high dimensional neural mass models: a random forest approach. *PLOS Computational Biology*, 14(3), e1006009. <https://doi.org/10.1371/journal.pcbi.1006009>
- Gujarati, D. N. (2003). *Basic econometrics*, McGraw Hill, Newyork.
- Güner, Ş. N., & Demir, H. U. (2022). Yapay sinir ağları ve zaman serileri yöntemi ile demir çelik ithalatı tahmini. *Sakarya İktisat Dergisi*, 11 (3), 389-397.
- Haq, M., Ahmed, A., Khan, I., Gyani, J., Mohamed, A., Attia, E., ... & Mangan, P. (2022). Analysis of environmental factors using ai and ml methods. *Scientific Reports*, 12(1). <https://doi.org/10.1038/s41598-022-16665-7>
- Jiang, S., Xinyue, S., & Zheng, Z. (2019). Gaussian process-based hybrid model for predicting oxygen consumption in the converter steelmaking process. *Processes*, 7(6), 352. <https://doi.org/10.3390/pr7060352>
- Kakade, K., Mishra, A. K., Ghate, K., & Gupta, S. (2022). Forecasting commodity market returns volatility: a hybrid ensemble learning garch-lstm based approach. *Intelligent Systems in Accounting, Finance and Management*, 29(2), 103-117. <https://doi.org/10.1002/isaf.1515>
- Karaev, A. K., Gorlova, O. S., Ponkratov, V. V., Vasyunina, M. L., Masterov, A. I., & Sedova, M. L. (2023). Program-target mechanisms to ensure the fiscal balance of the federal constituent. *Emerging Science Journal*, 7(5), 1517-1533. <https://doi.org/10.28991/esj-2023-07-05-05>
- Kulkarni, V., & Sinha, P. K. (2012). Pruning of random forest classifiers: a survey and future directions. *2012 International Conference on Data Science & Engineering (ICDSE)*. <https://doi.org/10.1109/icdse.2012.6282329>
- Lee, H., & Sohn, I. S. (2015). Global scrap trading outlook analysis for steel sustainability. *Journal of Sustainable Metallurgy*, 1(1), 39-52. <https://doi.org/10.1007/s40831-015-0007-7>
- Lei, B., Liu, Z., & Song, Y. (2021). On stock volatility forecasting based on text mining and deep learning under high-frequency data. *Journal of Forecasting*, 40(8), 1596-1610. <https://doi.org/10.1002/for.2794>
- Li, Y., Jia, Z., Liu, Z., Shao, H., Zhao, W., Liu, Z., ... & Wang, B. (2024). Interpretable intelligent fault diagnosis strategy for fixed-wing uav elevator fault diagnosis based on improved cross entropy loss. *Measurement Science and Technology*, 35(7), 076110. <https://doi.org/10.1088/1361-6501/ad3666>
- Liu, H., Li, Q., Li, G., & Ding, R. (2020). Life cycle assessment of environmental impact of steelmaking process. *Complexity*, 2020, 1-9. <https://doi.org/10.1155/2020/8863941>
- Man, H., Huang, H., Qin, Z., & Li, Z. (2023). Analysis of a sarima-xgboost model for hand, foot, and mouth disease in xinjiang, china. *Epidemiology and Infection*, 151. <https://doi.org/10.1017/s0950268823001905>
- Mao, Y., Pranolo, A., Wibawa, A. P., Utama, A. B. P., & Dwiyanto, F. A. (2022). Robust lstm with tuned-pso and bifold-attention mechanism for analyzing multivariate time-series. *IEEE Access*, 10, 78423-78434. <https://doi.org/10.1109/access.2022.3193643>
- Meng, F., Weng, K., Shallal, B., Chen, X., & Mourshed, M. (2018). Forecasting algorithms and optimization strategies for building energy management & demand response. *Sp 2018*. <https://doi.org/10.3390/proceedings2151133>
- Metlek, S., Kandilli, C., & Kayaalp, K. (2021). Prediction of the effect of temperature on electric power in photovoltaic thermal systems based on natural zeolite plates. *International Journal of Energy Research*, 46(5), 6370-6382. <https://doi.org/10.1002/er.7575>

- Monjon, S., & Quirion, P. (2010). How to design a border adjustment for the european union emissions trading system? *Energy Policy*, 38(9), 5199-5207. <https://doi.org/10.1016/j.enpol.2010.05.005>
- Moon, J., Ke, F., & Sokolikj, Z. (2020). Automatic assessment of cognitive and emotional states in virtual reality-based flexibility training for four adolescents with autism. *British Journal of Educational Technology*, 51(5), 1766-1784. <https://doi.org/10.1111/bjet.13005>
- Mumcu, Z. (2003). *Demir çelik hurda raporu*. İstanbul Ticaret Odası Dış Ticaret Şubesi, s. 1-5.
- Mussumeci, E., & Coelho, F. C. (2020). Large-scale multivariate forecasting models for dengue - lstm versus random forest regression. *Spatial and Spatio-Temporal Epidemiology*, 35, 100372. <https://doi.org/10.1016/j.sste.2020.100372>
- Muthukrishnan, R., & Kalaivani, S. (2023). Robust weighted support vector regression approach for predictive modeling. *Indian Journal of Science and Technology*, 16(30), 2287-2296. <https://doi.org/10.17485/ijst/v16i30.1180>
- Naimi, B., Hamm, N., Groen, T., Skidmore, A. K., & Toxopeus, A. (2013). Where is positional uncertainty a problem for species distribution modelling? *Ecography*, 37(2), 191-203. <https://doi.org/10.1111/j.1600-0587.2013.00205.x>
- Naito, M., Takeda, K., & Matsui, Y. (2015). Ironmaking technology for the last 100 years: deployment to advanced technologies from introduction of technological know-how, and evolution to next-generation process. *ISIJ International*, 55(1), 7-35. <https://doi.org/10.2355/isijinternational.55.7>
- Naseem, M., Chaudhary, K., Sharma, B. N., & Lal, A. G. (2019). Using ensemble decision tree model to predict student dropout in computing science. 2019 *IEEE Asia-Pacific Conference on Computer Science and Data Engineering* (CSDE). <https://doi.org/10.1109/csde48274.2019.9162389>
- Norouzi, M., Collins, M. D., Fleet, D. J., & Kohli, P. (2015). CO<sub>2</sub> forest: improved random forest by continuous optimization of oblique splits. <https://doi.org/10.48550/arxiv.1506.06155>
- Ozemre, M., & Kabadurmuş, Ö. (2020). A big data analytics based methodology for strategic decision making. *Journal of Enterprise Information Management*, 33(6), 1467-1490. <https://doi.org/10.1108/jeim-08-2019-0222>
- Pauna, H., Aula, M., Seehausen, J., Klung, J., Huttula, M., & Fabritius, T. (2020). Optical emission spectroscopy as an online analysis method in industrial electric arc furnaces. *Steel Research International*, 91(11). <https://doi.org/10.1002/srin.202000051>
- Polat, M. (2019). Petrol fiyatlarının ve reel efektif döviz kurunun türkiye'nin dış ticaret dengesine etkileri: sınır testi yaklaşımı. *Maliye Finans Yazıları*, (112), 149-174. <https://doi.org/10.33203/mfy.602961>
- Roy, D. K., Sarkar, T. K., Kamar, S. S. A., Goswami, T., Muktedir, A., Al-Ghobari, H. M., ... & Mattar, M. A. (2022). Daily prediction and multi-step forward forecasting of reference evapotranspiration using lstm and bi-lstm models. *Agronomy*, 12(3), 594. <https://doi.org/10.3390/agronomy12030594>
- Ryll, L., & Seidens, S. (2019). Evaluating the performance of machine learning algorithms in financial market forecasting: a comprehensive survey.. <https://doi.org/10.48550/arxiv.1906.07786>
- Setiawati, F., Ahmad, M. S., & Adiatman, M. (2023). Correlates of dental visits in children with hearing loss: an application of the theory of planned behaviour. *International Journal of Paediatric Dentistry*, 33(3), 259-268. <https://doi.org/10.1111/ipd.13036>
- Shin, S., Kwon, M., Kim, S., & So, H. (2023). Prediction of equivalence ratio in combustion flame using chemiluminescence emission and deep neural network. *International Journal of Energy Research*, 2023, 1-10. <https://doi.org/10.1155/2023/3889951>
- Si, Y., Nadarajah, S., Zhang, Z., & Xu, C. (2024). Modeling opening price spread of shanghai composite index based on arima-gru/lstm hybrid model. *Plos One*, 19(3), e0299164. <https://doi.org/10.1371/journal.pone.0299164>
- Silva, F., Sanz, M., Seixas, J., Solano, E., & Omar, Y. (2020). Perceptrons from memristors. *Neural Networks*, 122, 273-278. <https://doi.org/10.1016/j.neunet.2019.10.013>
- Şeker, M., Memmedov, A., Huseyinov, R., & Koçkanat, S. (2017). Power quality measurement and analysis in electric arc furnace for turkish electricity transmission system. *Elektronika Ir Elektrotehnika*, 23(6). <https://doi.org/10.5755/j01.eie.23.6.19691>

- Taşdelen İ. (2018). *Türkiye'de kur değişimlerinin demir-çelik sektörü dış ticareti üzerine etkisi*. Yüksek Lisans Tezi, Dokuz Eylül Üniversitesi, Sosyal Bilimler Enstitüsü, İktisat Anabilim Dalı, İzmir.
- Torres, G. d. C., Roig-Maimó, M. F., Mascaró-Oliver, M., Alcover, E. A., & Mas-Sansó, R. (2022). Understanding how cnns recognize facial expressions: a case study with lime and cem. *Sensors*, 23(1), 131. <https://doi.org/10.3390/s23010131>
- Truong, N., Ngo, N., & Pham, A. (2021). Forecasting time-series energy data in buildings using an additive artificial intelligence model for improving energy efficiency. *Computational Intelligence and Neuroscience*, 2021, 1-12. <https://doi.org/10.1155/2021/6028573>
- Türkiye Cumhuriyet Merkez Bankası Elektronik Veri Dağıtım Sistemi, (2024), <https://evds2.tcmb.gov.tr/index.php?/evds/serieMarket>, Erişim Tarihi: 07.05.2024.
- Türkiye İstatistik Kurumu, (2024), [www.tuik.gov.tr](http://www.tuik.gov.tr), Erişim Tarihi: 09.05.2024.
- Tyass, I., Khalili, T., Rafik, M., Bellat, A., Raihani, A., & Mansouri, K. (2023). Wind speed prediction based on statistical and deep learning models. *International Journal of Renewable Energy Development*, 12(2), 288-299. <https://doi.org/10.14710/ijred.2023.48672>
- Wang, X., Yu, Y., Zhao, X., Huang, M., & Zhu, Q. (2023). Integrating field images and microclimate data to realize multi-day ahead forecasting of maize crop coverage using cnn-lstm. *International Journal of Agricultural and Biological Engineering*, 16(2), 199-206. <https://doi.org/10.25165/j.ijabe.20231602.7020>
- Wang, Y. (2022). Import and export trade forecasting algorithm based on blockchain security and pso optimized hybrid rvm model. *Security and Privacy*, 6(2). <https://doi.org/10.1002/spy2.218>
- Yan, L., Jia, L., Lu, S., Peng, L., & He, Y. (2023). Lstm-based deep learning framework for adaptive identifying eco-driving on intelligent vehicle multivariate time-series data. *IET Intelligent Transport Systems*, 18(1), 186-202. <https://doi.org/10.1049/itr2.12443>
- Yılmaz, S., Yücer, H. M., & Fidan, Y. (2013). Socio-economic status, job satisfaction and sector visions of the steelworkers: karabuk case study. *Journal of History Culture and Art Research*, 2(3), 259. <https://doi.org/10.7596/taksad.v2i3.271>
- Yu, M., Liu, T., Guan, Z., Sun, Y., Jie, G., Chen, L., ... & He, Y. (2022). Salstm: an improved lstm algorithm for predicting the competitiveness of export products. *International Journal of Intelligent Systems*, 37(9), 6185-6200. <https://doi.org/10.1002/int.22839>
- Yücekutlu, A. Y., & Sanalan A. T. (2015). Elektrik ark ocaklı çelikhane tesislerinin; hava kirlleticileri, emisyon kontrol ve azaltım teknikleri, 6. *Ulusal Hava Kirliliği ve Kontrolü Sempozyumu*, 7-9 Ekim 2015, İzmir.
- Zafar, M. R., & Khan, N. (2021). Deterministic local interpretable model-agnostic explanations for stable explainability. *Machine Learning and Knowledge Extraction*, 3(3), 525-541. <https://doi.org/10.3390/make3030027>
- Zhou, Y., Qi, L., & Xiao, D. (2022). Application of lstm-lightgbm nonlinear combined model to power load forecasting. *Journal of Physics: Conference Series*, 2294(1), 012035. <https://doi.org/10.1088/1742-6596/2294/1/012035>