



Tedarik Zincirinde Hibrit Talep Tahmin Modeli Önerisi: Çelik Sektörü Uygulaması

Orhan Torkul¹, Erhan Kor², Merve Şişçi^{3*}

^{1, 2, 3} Endüstri Mühendisliği Bölümü, Sakarya Üniversitesi, Sakarya, Türkiye
torkul@sakarya.edu.tr, erheng@outlook.com, mervesisci@sakarya.edu.tr

Öz

Uzun imalat süreleri, süreç içi stokların yüksek olması ve tezgahlardan yararlanma oranlarının düşük olması üretim sistemlerinde karşılaşılan önemli planlama problemlerindedir. Bunların içerisinde, imalat sürelerinin uzun olması dolayısıyla sipariş gecikmelerinin meydana gelmesi önemli problem alanlarından birisidir. Bu çalışmada, çelik sektöründe sipariş gecikmelerinin sebepleri araştırılarak bunların ortadan kaldırılması ile tedarik zincirinde sürekliliğin sağlanması için bir talep tahmini modeli önerisi geliştirilmesi amaçlanmıştır. Önerilen model, ürünler için ihtiyaç duyulan ve sipariş gecikmelerinde birincil derecede önemli olan hammadde ve yarı mamulün ihtiyaç duyulan zamanda ve miktarda belirlenebilmesi için nitelik seçimi ve makine öğrenmesi algoritmalarına dayalı hibrit bir yapıdadır. Geçmiş dönem satış miktarlarının yanı sıra enerji maliyetleri, çelik hammadde fiyatı ve Euro/Dolar paritesi modele bağımsız değişkenler olarak dahil edilmiştir. Talep tahmin modellerinin geliştirilmesinde en ilgili özelliklerin belirlenebilmesi amacıyla 6 farklı nitelik seçimi yöntemi uygulanmıştır. Modeller 3 farklı makine öğrenmesi algoritması ile eğitilmiştir. Geliştirilen modeller çelik sektöründe faaliyet gösteren bir firmanın 4 ürününün 89 aylık verileri üzerinde uygulanmıştır. Deneysel sonuçlara göre, nitelik seçimi yöntemlerinin genel olarak tahmin modellerinin performansını arttırdığı sonucuna ulaşılmıştır. Geliştirilen modeller çelik sektöründe faaliyet gösteren bir firmanın 4 ürününün 89 aylık verileri üzerinde uygulanmıştır. Deneysel sonuçlara göre, nitelik seçimi yöntemlerinin genel olarak tahmin modellerinin performansını arttırdığı sonucuna ulaşılmıştır. Geliştirilen modeller çelik sektöründe faaliyet gösteren bir firmanın 4 ürününün 89 aylık verileri üzerinde uygulanmıştır. Deneysel sonuçlara göre, nitelik seçimi yöntemlerinin genel olarak tahmin modellerinin performansını arttırdığı sonucuna ulaşılmıştır.

Anahtar Kelimeler: Talep Tahmini, Makine Öğrenmesi, Nitelik Seçimi, Optimizasyon Algoritmaları.

A Proposal of Hybrid Demand Forecasting Model in Supply Chain: Steel Industry Application

Abstract

Long manufacturing times, high in-process stocks and low machine utilization rates are important planning problems encountered in production systems. Among these, order delays due to long manufacturing times are one of the important problem areas. In this study, it is aimed to investigate the reasons for order delays in the steel industry and to develop a demand forecasting model proposal to eliminate them and ensure continuity in the supply chain. The proposed model has a hybrid structure based on feature selection and machine learning algorithms in order to determine the raw materials and semi-finished products needed for products and which are of primary importance in order delays, at the required time and quantity. In addition to past sales amounts, energy costs, steel raw material price and Euro/Dollar parity were included in the model as independent variables. In order to determine the most relevant features in development of demand forecasting models, 6 different feature selection methods were applied. The models were trained with 3 different machine learning algorithms. The developed models were applied on 89-month data of 4 products of a company operating in the steel industry. According to the experimental results, although it was concluded that feature selection methods generally increased performance of forecasting models, it was evaluated that combination of feature set and demand forecasting method showing the most appropriate forecasting performance for each product differed. By the agency of the developed models, 93.6%, 94.7%, 90.3% and 91.5% prediction accuracy values were achieved for products, respectively.

Keywords: Demand Forecasting, Machine Learning, Feature Selection, Optimization Algorithms.

* Sorumlu yazar.
E-posta adresi: mervesisci@sakarya.edu.tr

Alındı : 29 Ocak 2024
Revizyon : 11 Mart 2024
Kabul : 18 Nisan 2024

1. Giriş (Introduction)

Günümüzde meydana gelen hızlı değişimler nedeniyle, işletmelerin gelecekteki süreçler için tahmin çalışmaları gerçekleştirmeleri varlıklarını devam ettirebilmeleri için temel bir ihtiyaç haline gelmiştir (Güven, 2020). Müşteri hacimlerindeki büyümeler ve teknolojiye gelişmeler gibi sebeplerle pazar talebine hızlı cevap verebilmek ve müşteriler için sürdürülebilir bir tedarik zinciri sağlayabilmek hayati bir önem taşımaktadır (Keung vd., 2021). Etkili bir tedarik zinciri yönetimi yüksek rekabetli bir ortamda bile işletmenin sürekliliğini güvence altına alabilmektedir. Ancak, özellikle çelik üretimi yapan firmalar, pazar ve talep dalgalanmaları ile karşı karşıya kalabilmektedir (Lee vd., 1997). Bununla birlikte, değişken müşteri talebi tedarik zinciri yönetimini istikrarsızlaştırmakta ve envanter yönetiminde zorluklar oluşturmaktadır. Ürünlerin müşteriye teslimatının zamanında yapılamaması sadece stok seviyelerini etkileyip ek maliyetlere sebep olmakla kalmamakta, aynı zamanda müşterinin beklentisinin ve ürün satın alma motivasyonunun düşmesine de neden olabilmektedir. Bu nedenlerden dolayı, özellikle Endüstri 4.0 çağında teslimat gecikmeleri, ele alınması ve çözülmesi gereken önemli sorunlardan birisidir (Keung vd., 2021). Bahsedilen ihtiyaçlar doğrultusunda, talep tahmini ve satış tahmini üreticilerin, dağıtıcıların ve ticaret yapan firmaların en önemli fonksiyonlarından biri haline gelmiştir (Kochak ve Sharma, 2015).

Tedarik zincirindeki esnekliğini ve dayanıklılığını arttırmak, şirketlerin önemli hedefleri arasında yer almaktadır (El Filali vd., 2022). Bu doğrultuda, talep tahmin yöntemleri üretim planlama, maliyet, stok ve teslimat süreleri gibi birçok konuda önemli avantajlar sunmaktadır. Talep ve tedarik dengesi sağlanarak envanter fazlalığının veya yetersizliğinin azaltılması ile firma karlılığının artışı sağlanabilmektedir (Kochak ve Sharma, 2015). Bu nedenle, literatürde minimum tahmin hatasına sahip talep tahmin modellerinin geliştirilmesi üzerinde yoğun bir şekilde çalışılmaktadır. Geleneksel tahmin yöntemlerinde çok sayıda insan faktörü ve yüksek miktarda hata bulunmaktadır. Aynı zamanda hata toleransları da düşüktür. Bu da doğru tahmin sonuçları almayı zorlaştırmaktadır (Xu ve Wang, 2022). Bazı çalışmalarda (Feizabadi, 2022), geleneksel tahmin yöntemleri ile karşılaştırıldığında makine öğrenmesi modellerinin daha iyi tahmin performansı gösterdiği kanıtlanmıştır.

Makine öğrenmesi modellerinin geliştirilmesinde nitelik seçimi, ilgili özellikleri seçmek ve gürültülü ve alakasız olanları kaldırmak için kritik bir süreç olarak kabul edilmektedir (Elgamal vd., 2020). Talep tahmini konusunun bir alt kümesi olduğu regresyon problemlerinde minimum sayıda özelliğin seçimi hesaplama karmaşıklığını azaltırken, optimum özelliğin seçimi regresyon modellerinin doğruluğunu korumaya yardımcı olur (Ismael vd., 2021). Özellikle en iyi

çözümleri sağlamak için popülasyonun değerli bilgisinden yararlanma özelliğine sahip olan evrimsel algoritmalar, özellik optimizasyonu problemleriyle başa çıkmadaki performanslarından dolayı son yirmi yılda oldukça başarı elde etmektedir (Thawkar, 2022). Bu çalışmada, çelik imalat sektörüne ait ürünler için nitelik seçimi ve makine öğrenmesi algoritmalarına dayanan talep tahmin modellerinin geliştirilmesi amaçlanmıştır. Aynı zamanda nitelik seçimi için uyarlanan ve doğadan ilham alan 6 sarmalayıcı optimizasyon algoritmasının talep tahmin modellerinin performansları üzerindeki etkisinin incelenmesi hedeflenmiştir. Bu hedefler doğrultusunda, çelik sektöründe faaliyet gösteren bir firmadan alınan ve çeşitli nitelik oluşturma işlemleri ile elde edilen veri setleri üzerinde, Parçacık Sürüşü Optimizasyonu Algoritması, Harris Şahinleri Optimizasyonu Algoritması, Gri Kurt Optimizasyonu Algoritması, Yusufçuk Optimizasyonu Algoritması, Genetik Optimizasyonu Algoritması ve Yerçekimi Arama Optimizasyonu Algoritması olmak üzere 6 nitelik seçimi yöntemi ile tahmin modellerinde etkili nitelikler belirlenmiştir. Belirlenen 4 ürün için tüm nitelikler ve nitelik seçimi yöntemleri ile belirlenen nitelikler kullanılarak lineer regresyon, yapay sinir ağları ve karar ormanı algoritmaları ile 84 farklı talep tahmini modeli geliştirilmiş ve modellerin performansları karşılaştırılmıştır.

Çalışmanın geri kalanı şu şekilde düzenlenmiştir: Bölüm 2’de literatürde bulunan talep tahmini çalışmaları incelenmektedir. Bölüm 3’te, talep tahmini modellerinin geliştirilmesi için çalışmada kullanılacak olan yöntemler sunulmaktadır. Bölüm 4’te çalışmada önerilen talep tahmini metodolojisinin çelik imalatı sektörüne ait ürünlerden elde edilen veriler üzerinde uygulaması gerçekleştirilmektedir. Bölüm 5’te ise sonuçlar ve tartışma yer almaktadır.

2. Literatür (Literature)

Üretim planlamasına temel oluşturan talep tahmini (Küek ve Freitag, 2021), tedarik zincirindeki belirsizliklerin azaltılması ve böylece tedarik zinciri performansının iyileştirilmesinde kritik bir rol üstlenmektedir. Dolayısıyla talep tahmini enerji, sağlık, otomotiv, tekstil, e-ticaret ve perakende dahil olmak üzere birçok alanda üzerinde yoğun bir şekilde çalışılan bir konudur. Bu bölümde talep tahmini üzerine yapılan çalışmalar incelenmektedir.

Merkuryeva vd. (2019), toptancıdan dağıtıcıya ilaç ürünlerinde örnek olay üzerinden talep tahmin çalışması gerçekleştirmişlerdir. Modeller basit hareketli ortalama, lineer regresyon ve sembolik regresyon yöntemleriyle geliştirilmiştir. Modellerin karşılaştırılması sonucu sembolik regresyon yönteminin en uygun yöntem olduğu sonucuna varılmıştır. Türk ve Kiani (2019), yapmış oldukları çalışmada, Türkiye’deki toplam beyaz eşya satışlarını tahmin etmek için 2007-2015 dönemine ait beyaz eşya satış verilerini kullanarak yapay sinir ağları ve regresyon modelleri geliştirmişlerdir. Fanoodi

vd., (2019) çalışmasında, sağlık sistemindeki tedarik zincirinde kan trombosit taleplerinin tahmin edilmesi amaçlanmıştır. Sekiz farklı kan trombosit için 2013-2018 yılları arasındaki günlük talep verileri üzerinde yapay sinir ağları ve Otoregresif Entegre Hareketli Ortalama (ARIMA) ile tahmin modelleri oluşturulmuştur. Aydın ve Yazıcıoğlu (2019), bir süpermarketin kasap reyonunda 3 farklı et türü için Ocak 2017- Aralık 2018 dönemindeki haftalık satış verileri ile talep tahmin modelleri oluşturmuşlardır. Modellerin oluşturulmasında ARIMA ve yapay sinir ağları yöntemlerini kullanmışlardır. Modellerin tahmin performanslarının karşılaştırılması sonucunda yapay sinir ağları modelinin daha iyi tahmin gücüne sahip olduğu gözlemlenmiştir. Torun ve Deste (2021) çalışmasında, Samsun Devlet Hastanesi Ortopedi Bölümü'nde en fazla ihtiyaç duyulan 9 farklı sağlık malzemesine ait 2015-2018 yılları arasındaki verileri kullanarak talep tahmini çalışması gerçekleştirilmiştir. Modellerin geliştirilmesinde kullanılan yöntemler Hareketli Ortalama, Üstel Düzeltme, Holt'un Doğrusal Yöntemi, Çarpımsal Holt-Winters, Toplamsal Holt-Winters ve Basit Doğrusal Regresyon yöntemleri olmuştur. Tavukçu ve Sennaroğlu (2021) çalışmasında, iş makineleri için yedek parça satışı yapan bir firmadaki stok siparişlerinin tahmin değerlerini elde etmek için 36 aylık talep verileri kullanılmıştır. Hareketli Ortalama, Holt-Winters Metodu ve ARIMA yöntemleri ile tahminler gerçekleştirilmiştir. Mohan vd. (2021), tedarik zincirinde talep tahmini ve rota optimizasyonunu amaçlamışlardır. Depo ürünlerine yönelik talep tahmini modeli için ARIMA yöntemini kullanmışlardır. Kück ve Freitag (2021) çalışmasında, bir imalat şirketinin aylık müşteri taleplerinin tahmini amacıyla K-En Yakın Komşu (KNN) yöntemi kullanılmıştır. Yerel ortalama sabiti, yerel medyan sabiti, dört farklı düzenleme metodu ve çeşitli parametre kombinasyonlarıyla yüksek doğruluk elde edilmesi hedeflenmiştir. Han vd. (2022) çalışmasında, Holt Winters ve Yapay Sinir Ağları yöntemleri kullanılarak Türkiye'deki sıfır otomobil satış değerlerinin tahmin değerleri elde edilmiştir. 2015-2020 arasındaki aylık veriler ve döviz kuru, tüketici güven endeksi, gayrisafı yurt içi hasıla (GSYİH), reel kesim güven endeksi bağımsız değişkenleri kullanılmıştır. İmece ve Beyca (2022) çalışmasında ilaç firmasına ait bir ürün için Holt Winters, Ridge Regresyon, Rastgele Orman ve Aşırı Gradyan Artırma (XGBoost) yöntemlerini ve bu yöntemlerin kombinasyonlarını kullanarak talep tahmini modelleri oluşturulmuştur. Modellerin geliştirilmesinde ve değerlendirilmesinde 2016-2018 yılları arası günlük ürün satış değerleri kullanılmıştır. Feizabadi (2022), yapmış olduğu çalışmada tedarik zinciri performansını iyileştirmek amacıyla Yapay Sinir Ağları ve Dışsal Değişkenli Otoregresif Entegre Hareketli Ortalama (ARIMAX) yöntemlerine dayanan hibrit talep tahmini modelleri geliştirmiştir. Çalışmada çelik imalat firmasından elde edilen veriler kullanılmıştır. Yapılan değerlendirmeler, geleneksel yöntemlere göre yapay zeka tabanlı

yöntemlerin daha iyi tahmin sonuçları verdiğini göstermiştir. El Filali vd. (2022), çalışmalarında elektrik ürünleri üzerine talep tahmini için Tekrarlayan Sinir Ağları, Uzun Kısa Süreli Bellek ve Geçitli Tekrarlayan Birim olmak üzere Yapay Sinir Ağları yöntemlerini karşılaştırmışlardır. Geçitli Tekrarlayan Birim modeli en iyi tahmin sonuçlarını sağlayan model olmuştur. Acı ve Doğansoy (2022) çalışmasında Türkiye'de bulunan bir süpermarketin 2 yıllık e-ticaret verileri kullanılarak ürün satış tahmini gerçekleştirilmiştir. En iyi tahmin performansı gösteren modelin elde edilebilmesi için Yapay Sinir Ağları, Derin Öğrenme, Regresyon Ağacı, Gauss Süreç Regresyonu, Topluluk Öğrenme ve Destek Vektör Regresyonu yapay zeka algoritmaları ile modeller oluşturulmuştur. Orzechowski vd. (2023), elektrikli araçların halka açık şarj istasyonlarındaki şarj taleplerinin bir hafta öncesinden tahmin edilmesini amaçlamışlardır. Çalışmada Yapay Sinir Ağları, ARIMA, Rastgele Orman, Destek Vektör Regresyonu ve K-En Yakın Komşu algoritması ile farklı modeller oluşturulmuştur. Modellerin performansları karşılaştırıldığında Yapay Sinir Ağlarının en iyi performansı sağladığı görülmüştür. Yani ve Amer (2023), yapmış oldukları çalışmada ilaç tedarik zincirinde talep tahmini üzerinde çalışmışlardır. Çalışmada, çok uluslu ilaç şirketlerinden alınan dokuz farklı ürünün verileri kullanılmıştır. Tahmin modelleri için Gradyan Artırma Ağaçları, Rasgele Orman, Lineer Regresyon, Polinomiyal Regresyon, Basit Ağaç ve Ağaç Topluluğu makine öğrenmesi yöntemleri kullanılmıştır.

Bu çalışmada, talep tahmini literatüründe az karşılaşılan çelik sektörüne ait ürünler üzerinde talep tahmini çalışması gerçekleştirilmiştir. Talep tahmini modelleri için Lineer Regresyon, Yapay Sinir Ağları ve Karar Ormanı makine öğrenmesi algoritmaları kullanılmıştır. Modellerin performanslarının artırılması amacıyla optimizasyona dayalı 6 farklı nitelik seçimi yönteminden yararlanılmıştır. Geliştirilen nitelik seçimi-makine öğrenmesi hibrit modellerinin etkinlikleri 4 farklı ürün üzerinde değerlendirilmiştir.

3. Metot (Method)

Bu bölümde çalışmada kullanılan makine öğrenmesi algoritmaları ve nitelik seçimi yöntemleri açıklamalarına yer verilmiştir.

3.1. Makine Öğrenmesi Regresyon Algoritmaları (Machine Learning Regression Algorithms)

3.1.1. Lineer regresyon (Linear regression)

Bağımsız değişken ile bağımlı değişken arasındaki etkileşim ve bağlantının araştırıldığı yöntem regresyon analizidir. Tahmin modelinde bağımlı değişkene etki eden bir bağımsız değişken varsa bu regresyon tek değişkenli regresyon analizi adlandırılmaktadır. Bağımlı değişkene etki eden birden fazla bağımsız

değişkenin olduğu regresyon modeli ise çok değişkenli regresyon analizi olarak bilinmektedir (Korkut, 2019).

Linear regresyon modelinde bağımlı değişkenin Y olduğu varsayılırsa, Y ile X_1, X_2, \dots, X_n ile ifade edilen n adet bağımsız değişken arasındaki ilişki için doğrusal bir denklem oluşturulur. Bu denklem tahmin edilmek istenen bağımlı değişken Y için regresyon denklemidir ve Denklem 1'deki gibi ifade edilebilmektedir (Catal vd., 2019).

$$Y = b_0 + b_1X_1 + b_2X_2 + \dots + b_nX_n + \varepsilon \quad (1)$$

burada, b_1, b_2, \dots, b_n değerleri regresyon katsayılarını, ε ise hata terimini temsil etmektedir.

3.1.2. Yapay sinir ağları (Artificial neural networks)

Yapay sinir ağları yoğun bir şekilde birbirine bağlı yapılar ile eldeki verilerin işlendiği sistemler olarak tanımlanabilmektedir. Eğitim aşamasında önceki olayların örneklerine dayalı genelleştirme yoluyla bilgi edindikten sonra test aşamasında hiç deneyimlemediği ya da gelecekte meydana gelmesi olası bir tahmin gerçekleştirir (Gökler, 2020). Birçok sinir hücresinin birleşmesiyle yapay sinir ağları oluşur. Sinir hücresi yapay sinir ağlarında işlem yapan en küçük birimdir. Sonuç ise bir araya gelen birçok sinir hücresinin ortak sonucu olarak elde edilmektedir. Yapay sinir ağları hücrelerin birbirine bağlanmasıyla oluşur ve hücreler arasında bulunan bağlantılar ağırlıklar ile meydana getirilmektedir. Yapay sinir hücreleri arasındaki bağlantının kuvvetini ağırlıklar belirlemektedir. Yapay sinir ağının kurulabilmesi için en az birer adet giriş katmanı, gizli katman ve çıkış katmanı bulunmalıdır. Gizli katmanlar girişteki verilerin yorumlanması ve çıkışa iletilmesinde görev alır. Gizli katmanlarda işlem gören giriş verileri çıktı katmanına aktarılmaktadır. Bir yapay sinir ağı modelinde n adet giriş katmanı ve n adet çıkış katmanı olabilir (Güven, 2020).

3.1.3. Karar ormanı (Decision forest)

Açıklayıcı değişkenlerin kullanımıyla bağımlı bir değişkenin tahmini için kullanılan yöntemlerden birisi olan karar ağaçları kök, dallar ve yapraklardan oluşmaktadır. Başlangıç düğüm noktası olan kök kullanılan performans ölçütüne göre veriyi en iyi şekilde bölen değişkendir. Kök genel olarak ağaç oluşturma algoritması tarafından belirlenen kurala göre ikili dallara ayrılır ve bu dallar kendi içlerinde başka dallara ayrılabilir. Tüm bu ayrılmış dallar yaprak adı verilen terminal düğümlerde son bulmaktadır. Yaprak düğümlerindeki değerler çıktıyı temsil etmektedir (Spiliotis, 2022).

Ancak basit karar ağaçları ile eğitilen modeller aşırı uyum sorunu ile sonuçlanabilmektedir. Karar Ormanı algoritması çok sayıda karar ağacı oluşturulmasını içeren bir topluluk makine öğrenmesi tekniğidir. Tek karar ağaçlarına kıyasla topluluk modelleri, daha yüksek doğruluk sağlar (Chidroop ve Moharir, 2020). Karar

Ormanı modeli geliştirilirken, her karar ağacı değerlendirilir. Tüm karar ağaçlarından elde edilen sonuçlar belirlenerek yeni veriler puanlanır. Karar Ormanı Regresyonunda her karar ağacı tarafından tahmin edilen sayısal değerlerin ortalaması hesaplanarak nihai tahmin edilen sonuç elde edilmiş olur (Mohammed vd. 2023).

3.2. Nitelik seçimi (Feature selection)

Nitelik seçimi, gereksiz ve önemsiz özellikleri özellik kümesinden çıkartarak makine öğrenmesi modelinin performansını artırmayı amaçlayan bir veri ön işleme aşamasıdır (Bansal vd., 2022). Bu çalışmada, nitelik seçimi için Parçacık Sürüsü Optimizasyonu, Harris Şahinleri Optimizasyonu, Gri Kurt Optimizasyonu, Yusufçuk Optimizasyonu, Genetik Optimizasyonu ve Yerçekimi Arama Optimizasyonu algoritmalarından faydalanılmıştır.

3.2.1. Parçacık sürüsü optimizasyonu (PSO) algoritması (Particle swarm optimization algorithm)

Kuş sürülerinin davranışından esinlenen Parçacık Sürüsü Optimizasyonu algoritması 1995 yılında R Eberhart ve J Kennedy tarafından önerilmiştir (Kennedy, 2010). Parçacık sürüsü optimizasyonunda belirli sayıdaki parçacık bir fonksiyon ya da problemdeki arama boşluğuna yerleştirilir ve her bir parçacık amaç fonksiyonunu kendi bulunduğu konumda değerlendirir. Her bir parçacık sürüdeki bir veya daha fazla üye ile birlikte geçmiş en uygun konumlarını birleştirerek boşluktaki hareketlerini belirler. Tüm parçacıkların hareketi tamamlanınca bir sonraki iterasyon başlar. Nihayetinde yiyeceğe yönelmekte olan bir kuş sürüsünde olduğu gibi sürü optimum uygunluk fonksiyonuna yakın hareket etmeye başlar (Poli vd., 2007).

3.2.2. Harris şahinleri optimizasyonu (HŞO) algoritması (Harris hawk optimization algorithm)

Heidari vd. (2019) tarafından tanımlanan Harris Şahinleri Optimizasyonu (HŞO) algoritması Harris şahinlerinin doğada sürpriz saldırı adı verilen avlanma ve işbirlikçi eylemlerine dayanmaktadır. HŞO, bir grup şahinin, avın yerini takip etmek için çeşitli takip stillerini kullanarak işbirliği yaptığı popülasyona dayalı bir algoritma olarak sınıflandırılır. Burada şahin grubunun her biri bir aday çözümü avın yeri ise en uygun aday çözümü temsil etmektedir (Thaher ve Arman, 2020). Harris Şahinleri Optimizasyonu şahinlerin keşfetme ve açığa çıkarma taktiklerinden esinlenerek elde edilmiş fazlardan oluşan topluluk tabanlı degradesiz bir tekniktir. Keşif fazında takım üyeleri rastgele konumlara geçerler iki farklı strateji ile keşif aşamasını gerçekleştirebilirler. Açığa çıkarma fazında ise avların kaçış eğilimlerinden kaynaklı olarak dört farklı kovalama stratejisi önerilmiştir. Avın kaçışının başarılı ya da başarısız olması durumuna göre

sert ya da yumuşak kuşatma stratejisi belirlenmektedir. Avın kalan enerjisi de göz önünde bulundurularak yumuşak ya da sert kuşatma döngüleri devam eder ve avın yorgun düşmesi ile hedefe ulaşılır (Heidari vd., 2019).

3.2.3. Gri kurt optimizasyonu (GKO) algoritması (Grey wolf optimization algorithm)

Gri Kurt Algoritması Mirjalili vd. (2014) tarafından kurt sürülerinin avlarını yakalama süreçlerinin canlandırmasını yansıtacak şekilde sunulmuştur. Bu süreçler avlarını takip etme, çevreleme ve ava saldırma aşamalarını içermektedir. Algoritma nispeten az kontrol parametreleri içermektedir ve uygulaması kolaydır. Gri kurt sürülerindeki sosyal hiyerarşiyi yansıtacak şekilde uygunluk değerini elde etmek amacıyla bir çözüm, alt çözüm ve de üçüncü bir çözüm olacak bulunmaktadır. Algoritmada bu çözümler sırasıyla alfa, beta ve delta olarak adlandırılmaktadır (Zeng vd., 2022).

3.2.4. Yusufçuk optimizasyonu (YO) algoritması (Dragon fly optimization algorithm)

Yusufçuk Optimizasyonu, yusufçukların eşsiz avlanma ve göç etme davranışlarından esinlenerek oluşturulmuştur. Avlanan sürü davranışı diğer bilinen adıyla statik sürü davranışı, küçük sürü gruplarının ani adım değişiklikleri ve yerel hareketleriyle tanımlanmaktadır. Göçsel sürü davranışı ise aynı zamanda dinamik sürü olarak bilinmektedir ve tek bir yönde giden yüksek sayıdaki yusufçuğu ifade eder. Statik ve dinamik kavramları Yusufçuk Algoritmasının açığa çıkarma ve keşif kapasitelerini belirtmektedir. Ayırışma, dizilme, birlikte durma, dikkat dağıtma ve yiyeceğe çekim gibi öğeler içeren davranış tanımlanmaktadır. Her bir yusufçuk arama boşluğundaki bir çözüme karşılık gelir ve bu beş farklı öge ile sürü hareketi belirlenir (KS ve Murugan, 2017).

3.2.5. Genetik optimizasyonu (GO) algoritması (Genetic optimization algorithm)

Genetik Optimizasyon algoritmaları doğal biyolojik süreçlerin adapte edilmesi ile elde edilen hesaplama yöntemlerinden biridir. Genetik optimizasyonu çoklu çözüm vektörlerini aynı anda sürekli değerlendirmesi


ayrıcılığıyla geleneksel yöntemlerden daha avantajlıdır. Genetik algoritmalar rastgele oluşturulmuş ve topluluğa karşılık gelen karar vektörlerinden oluşmaktadır. Her bir karar vektörü grup pürüzlülük değerleri ve talep ayarlama faktörleri içeren karar değişkenleri setinden oluşmaktadır. Her bir karar vektörü ikili sayılardan oluşmaktadır ve karar değişkeni değeri ikili sayı sistemine göre çevrilmektedir. İkili dizi setinin üst ve alt limitleri karar değişkeninin muhtemel en küçük varyasyonunu kontrol eder. Karar değişkeni değerleri ikili sisteme dönüştürülür ve ikili sistemden tekrar eski haline dönüştürülebilmektedir. İkili sistem kodlaması sayesinde karar vektörü 0 ve 1'lerden oluşan ikili diziyi indirgenebilmektedir. Elde bulunan karar vektörlerinden uygunluk fonksiyonuna göre alt karar vektörleri seti seçilir. Bir karar vektörü popülasyonu seçildiğinde çaprazlama ya da mutasyon operasyonlarıyla yeni bir karar vektörü popülasyonu oluşturulur (Lingireddy ve Ormsbee, 2002).

3.2.6. Yerçekimi arama optimizasyonu (YAO) algoritması (Gravitational optimization algorithm)

Yerçekimi Arama Optimizasyon Algoritması Newton'un kütle çekim teorisinden esinlenerek ortaya çıkarılmıştır. Kütle çekim teorisinde kuvvet kütle ile doğru orantı ve uzaklığın karesi ile ters orantı olacak şekilde tanımlanmaktadır. Yerçekimi arama algoritmasında tanımlanmış olan parçacıklar pozisyon, kütle, aktif ve pasif yerçekimi olmak üzere dört farklı özellik taşımaktadır. Problemin çözümü parçacığın pozisyonu ile sağlanmaktadır ve kütleler uygunluk fonksiyonuna göre belirlenebilmektedir. Her bir kütle çekim kanunu ve hareket kanunu olmak üzere iki kanuna tabidir (Yadav ve Deep, 2013).

4. Uygulama (Implementation)

Bu çalışmada, nitelik seçimi yöntemleri ve makine öğrenmesi algoritmalarının hibrit kullanımı ile talep tahmin modelleri geliştirilmiştir. Çalışmanın metodolojisi Şekil 1'de verilmektedir. Şekilde görüldüğü gibi çalışma 5 temel adımdan oluşmaktadır. Bu adımlar veri toplama, veri ön işleme, nitelik seçimi, tahmin modellerinin geliştirilmesi ve modellerin karşılaştırılması ve seçimidir.



Şekil 1. Çalışmanın metodolojisi (Methodology of the study)

4.1. Veri toplama (Data collection)

Bu çalışmada talep tahmini modellerinin geliştirilmesi için kullanılacak olan veriler ana bileşeni çelik olan ürünlerin taleplerini doğrudan ya da dolaylı olarak etkileyen parametreler arasından seçilmiştir. İlk değişken olarak çelik sektöründe ürün satışı yapan büyük ölçekli uluslararası bir şirketten gerçek satış verileri elde edilmiştir. Bu veriler Nisan 2016 ve Ağustos 2023 tarihleri arasında 4 ürüne ait 89 aylık satış miktarı verilerinden oluşmaktadır. Ürünlerin seçimi aşamasında, ürün yelpazesinde satış miktarı en fazla olan ve sipariş dalgalanması nispeten az olan ürünlerin

seçilmesine dikkat edilmiştir. Ürünler çalışmada A ürünü, B ürünü, C ürünü ve D ürünü olarak isimlendirilmiştir.

Ürünlerin imalatında kullanılan hammaddelerin uluslararası düzeyde dolar bazında işlem görmesi ve satışlarının euro bazında yapılması nedeniyle euro/dolar paritesi bağımsız değişkenlerden biri olarak seçilmiştir. Bu bağımsız değişkene ait veriler anlık finansal verilerin sağlandığı bir web sitesinden elde edilmiştir. Diğer taraftan, ürünlerin maliyetinin yaklaşık olarak %80 kadarının hammadde kaynaklı olması ve ürünlerdeki ana bileşenin çelik olması nedeniyle çelik fiyatı, veri setine bağımsız değişken olarak eklenmiştir. Çelik fiyatı

verileri ise satış verileri gibi firma veritabanından elde edilmiştir. Ürünlerin maliyetinde hammadde ve euro bazında yapılan makine yatırım bedelinden sonra en önemli maliyet kaleminin enerji maliyeti olması sonucu bir diğer bağımsız değişken olarak enerji maliyeti kullanılmıştır.

4.2. Veri ön işleme (Data preprocessing)

Çalışmanın bu aşamasında nitelik oluşturma, aykırı verilerin temizlenmesi, normalizasyon ve veri dönüştürme olmak üzere dört veri ön işleme süreci gerçekleştirilmiştir.

4.2.1. Nitelik oluşturma (Feature generation)

Bu adımda, talep tahmini modellerinde kullanılmak üzere sipariş miktarı, enerji maliyeti, çelik hammadde fiyatı ve euro/dolar paritesi değişkenlerine ek olarak kayan pencereler, kayan pencere istatistikleri, birinci derece farkı nitelik oluşturma işlemleri yardımı ile bir, iki ve üç ay önceki sipariş miktarları, son üç ayın siparişlerinin ortalaması, enerji maliyetindeki değişim, çelik fiyatındaki değişim ve sipariş miktarındaki değişim olmak üzere 7 farklı değişken elde edilmiştir.

Kayan Pencere: Gecikme değişkenleri, geçmişte olanların geleceğe ilişkin bir tür içsel bilgiyi etkileyebileceği veya içerebileceği varsayımına dayanarak oluşturuldukları için yararlı olduğu düşünülen önceki zaman adımlarındaki değerlerdir. Veri setine gecikme değişkenleri ekleme işlemine kayan pencere yöntemi adı verilmektedir (Lazzeri, 2020). Bu çalışmada her bir ürünün sipariş miktarı niteliğine 3 pencere genişliğine sahip kayan pencereler yöntemi uygulanarak 1 ay önceki sipariş miktarı, 2 ay önceki sipariş miktarı ve 3 ay önceki sipariş miktarı değişkenleri elde edilmiştir.

Kayan Pencereler İstatistikleri: Bir zaman serisi veri setinde kayan pencereler istatistikleri oluşturmanın temel amacı, örneğin kendisini ve örnekten önceki ve sonraki belirli sayıda örneği içeren bir aralık tanımlayarak belirli bir veri örneğinden elde edilen değerlere ilişkin istatistikleri hesaplamaktır (Lazzeri, 2020). Bu çalışmada, sipariş miktarı niteliğine en popüler kayan pencereler istatistiklerinden olan hareketli ortalama istatistiği uygulanarak son üç ayın siparişlerinin ortalaması niteliği elde edilmiştir. Kayan pencere aralığı örneğin kendisinden önceki 3 ay olarak seçilmiştir.

Birinci Derece Farkı: Bir zaman serisi niteliğinin birinci derece farkı, zaman serisi niteliğinin her birim zaman adımı arasındaki değişim oranı olarak tanımlanabilmektedir. Birinci derece fark ile birlikte, bir zaman serisinin eğimi belirlenebilir, belirli aykırı değerlerin varlığı gibi zaman serisi hakkında ek bilgi edinilebilir. $X = \{x_1, x_2, \dots, x_t\}$ olarak verilen bir zaman serisi değişkeni Denklem (2) kullanılarak birinci derece farkına dönüştürülebilir (Tan vd., 2022).

$$X' = \{x_t - x_{t-1}\} \quad (2)$$

Bu çalışmada enerji maliyeti, çelik hammadde fiyatı ve sipariş miktarı niteliklerine birinci derece fark dönüşümü uygulanarak enerji maliyetindeki değişim, çelik fiyatındaki değişim ve sipariş miktarındaki değişim değişkenleri elde edilmiştir.

A ürünü, B ürünü, C ürünü ve D ürünü için elde edilen veri setlerindeki niteliklere ait istatistiksel özellikler Tablo 1'de sunulmaktadır. Burada, enerji maliyeti, çelik hammadde fiyatı, euro/dolar paritesi, bir, iki ve üç ay önceki sipariş miktarları, son üç ayın siparişlerinin ortalaması, enerji maliyetindeki değişim, çelik fiyatındaki değişim ve sipariş miktarındaki değişim bağımsız değişkenler iken sipariş miktarı bağımlı değişkendir. Euro/dolar paritesi, enerji maliyeti, enerji maliyetindeki değişim, çelik fiyatı ve çelik fiyatındaki değişim değişkenlerindeki değerler 4 veri seti için aynı değerleri almaktadır. Sipariş miktarı, 1 ay önceki sipariş miktarı, 2 ay önceki sipariş miktarı, 3 ay önceki sipariş miktarı, son 3 ayın siparişlerinin ortalaması ve sipariş miktarındaki değişim değişkenleri değerleri ise ürünlere göre değişkenlik göstermektedir. Tabloda bulunan benzersiz veriler sütunu bir nitelikte bulunan birbirinden farklı değer sayısını belirtmektedir.

4.2.2. Aykırı verilerin temizlenmesi (Removing outliers)

Modellerin geliştirilmesinde kullanılacak olan veri setlerinde, veri setlerindeki gürültülerin azaltılması ve geliştirilecek modellerin uç değerlerden olumsuz etkilenmesinin önlenmesi amacıyla aykırı değer temizleme işlemi gerçekleştirilmiştir. Aykırı değerlerin temizlenmesinde yüzdelik dilim kullanılarak üst tepe ve alt tepe değerlerin kırılarak niteliğin ortalama değeri ile değiştirilmesi yöntemi temel alınmıştır. Üst eşik yüzdelik dilim 95, alt eşik yüzdelik dilim ise 5 olarak belirlenmiştir.

4.2.3. Veri dönüştürme (Data transformation)

Tablo 1 incelendiğinde 4 veri setinde kullanılan ortak niteliklerden enerji maliyeti ve çelik fiyatı değişkenlerinin oldukça farklı değer aralıklarında değerler aldığı görülmektedir. Modellerin performansını iyileştirmek amacıyla bu niteliklerin ortak bir ölçekte değerler almalarını sağlamak için bu çalışmada veri dönüştürme yöntemlerinden birisi olan MinMax normalizasyon işlemi uygulanmıştır. En yaygın kullanılan normalizasyon yöntemlerinden birisi olan MinMax normalizasyon yöntemi değerleri oldukça büyük aralıkta değişen verileri daha küçük aralığa dönüştürür (Özçelik vd., 2021). X normalize edilmek istenen nitelik değeri, X_n normalize edilmiş yeni değer, X_{\min} niteliğin minimum değeri ve X_{\max} niteliğin maksimum değeri olmak üzere MinMax normalizasyon işleminin formülasyonu Denklem (3)'te verilmektedir.

Tablo 1. A ürünü, B ürünü, C ürünü ve D ürünü veri setlerinin istatistiksel özellikleri (Statistical properties of product A, product B, product C and product D datasets)

Nitelikler		Ortalama	Medyan	Min	Maks	Standart Sapma	Benzersiz Veriler	Eksik Veriler
Ortak Nitelikler	Eur/Dolar paritesi	1.132	1.13	0.98	1.24	0.056	25	0
	Enerji maliyeti	98.52	88	56	192	31.8	51	0
	Enerji maliyetindeki değişim	0.21	-2	-31	71	13.3	32	0
	Çelik fiyatı	679.1	591	332	1520	269.6	67	0
	Çelik fiyatındaki değişim	6.53	0	-259	264	72.04	44	0
A Ürünü	Sipariş miktarı	16322	14560	3952	39728	8170	67	0
	1 ay önceki sipariş miktarı	6479	14768	3952	39728	8124	67	0
	2 ay önceki sipariş miktarı	16596	15184	3952	39728	8102	67	0
	3 ay önceki sipariş miktarı	16668	15184	3952	39728	8054	67	0
	Son 3 ay sipariş ortalaması	16581	16085	7259	29328	6082	75	0
	Sipariş miktarındaki değişim	116.5	0	-24752	25168	9113	69	0
B Ürünü	Sipariş miktarı	1997	1841	479	7614	953	88	0
	1 ay önceki sipariş miktarı	1993	1841	479	7614	961	88	0
	2 ay önceki sipariş miktarı	2004	1841	479	7614	953	88	0
	3 ay önceki sipariş miktarı	2015	1850	479	7614	944	88	0
	Son 3 ay sipariş ortalaması	2004	1936	696	3880	747	89	0
	Sipariş miktarındaki değişim	-11	29	-5773	5732	1032	86	0
C Ürünü	Sipariş miktarı	12344	11756	1249	23913	4679	89	0
	1 ay önceki sipariş miktarı	12398	11901	1249	23913	4647	89	0
	2 ay önceki sipariş miktarı	12466	11945	1249	23913	4597	89	0
	3 ay önceki sipariş miktarı	12408	11945	1249	23913	4664	89	0
	Son 3 ay sipariş ortalaması	12424	12787	6969	18845	2474	88	0
	Sipariş miktarındaki değişim	68	-142	-20411	17793	7240	89	0
D Ürünü	Sipariş miktarı	1819	1704	561	9080	1000	88	0
	1 ay önceki sipariş miktarı	1831	1711	561	9080	995	88	0
	2 ay önceki sipariş miktarı	1835	1711	561	9080	994	88	0
	3 ay önceki sipariş miktarı	1845	1723	561	9080	990	88	0
	Son 3 ay sipariş ortalaması	1837	1779	677	5051	759	89	0
	Sipariş miktarındaki değişim	3.51	-35	-6306	6988	1115	84	0

$$X_n = \frac{X - X_{min}}{X_{maks} - X_{min}} \quad (3)$$

Veriler arasındaki dengesizliklerin ve çarpıklıkların giderilmesinde kullanılan yöntemlerden birisi de doğal logaritma (Ln) dönüşümdür. Çok geniş veri aralıklarında daha küçük olan değerler büyük değerler tarafından bastırılabilir. Ln dönüşümü aykırı değerlerin dağılımdaki ağırlığını azaltır. Bu sayede dağılımda simetri tekrar elde edilmiş olur (Sauro ve Lewis, 2016). Modelin eğitiminde kullanılan gerçek sipariş miktarı değerlerinin aralığı çok geniş olduğundan verilerde çarpık dağılımın giderilerek normal dağılıma yakın bir dağılım izlemesi için logaritmik dönüşüm gerçekleştirilmiştir.

Eğitim veri seti ile tahmin veri seti arasındaki sabit ve dinamik durumun dengelenmesi ve modelin daha doğru genelleme yapılabilmesi için veri öteleme yöntemleri tercih edilmektedir (Huyen, 2022). Bu çalışmada tahmin modellerinin gerçek değerlere daha yakın tahminler sağlayabilmesi için matematiksel öteleme işlemi gerçekleştirilmiştir. Eğitim veri setinde Ln dönüşümü gerçekleştirilmiş gerçek sipariş miktarı değerlerine, niteliğin ortalama sapma değerine yakın bir değer çıkartılması işlemi uygulanmıştır. Bu değer A ürünü için 0.15, B ve C ürünleri için 0.30, D ürünü için ise 0.38'dir.

4.3. Nitelik seçimi (Feature selection)

Bu çalışmada, ürün veri setlerindeki sipariş miktarı değişkeninin tahmin edilmesinde en ilgili özelliklerin belirlenmesi için Parçacık Sürüsü Optimizasyonu, Harris Şahinleri Optimizasyonu, Gri Kurt Optimizasyonu, Yusufçuk Optimizasyonu, Genetik Optimizasyonu ve Yerçekimi Arama Optimizasyonu algoritmalarının faydalanılmıştır. Algoritmaların tüm nitelikler üzerinde uygulanması adımları Spyder 3.1 geliştirme ortamında Python programlama dili ile açık kaynaklı 'zoofs' kütüphanesi yardımıyla yürütülmüştür. Uygulamada optimizasyon algoritmaları için kullanılan parametreler ve değerleri Tablo 2'de sunulmaktadır.

Optimizasyon algoritmalarının uygulanmasında 'LightGBM' Python kütüphanesinden (LightGBM, 2023) yararlanılarak LightGBM makine öğrenmesi regresyon modeli kullanılmıştır. Model parametrelerinden iterasyon sayısı 100, öğrenme oranı 0.1 ve yaprak sayısı 31 olarak belirlenmiştir. Uygulama sonucunda optimizasyon yöntemlerinin sunduğu nitelik seçimleri Tablo 3'te gösterilmiştir. Niteliğin ilgili optimizasyon algoritması çıktısında yer alması durumu 'X' işareti ile belirtilmiştir.

Tablo 2. Nitelik seçimi algoritmaları için kullanılan parametreler (Parameters used for feature selection algorithms)

Nitelik Seçimi Algoritması	Parametre	Değer
Parçacık Sürüş Optimizasyonu	iterasyon sayısı	1000
	popülasyon büyüklüğü	20
	ilk ivme katsayısı	2.0
	ikinci ivme katsayısı	2.0
	ağırlık parametresi	0.9
	amaç fonksiyonu	Hata kareleri ortalaması performans ölçütünün minimizasyonu
Harris Şahinleri Optimizasyonu	iterasyon sayısı	250
	popülasyon büyüklüğü	20
	amaç fonksiyonu	Hata kareleri ortalaması performans ölçütünün minimizasyonu
Gri Kurt Optimizasyonu	beta	0.5
	iterasyon sayısı	1000
	popülasyon büyüklüğü	20
Yusuçuk Optimizasyonu	metot	1
	amaç fonksiyonu	Hata kareleri ortalaması performans ölçütünün minimizasyonu
	iterasyon sayısı	1000
	popülasyon büyüklüğü	20
Genetik Optimizasyonu	metot	ikinci dereceden
	amaç fonksiyonu	Hata kareleri ortalaması performans ölçütünün minimizasyonu
	iterasyon sayısı	1000
	popülasyon büyüklüğü	20
	seçici baskı	2
Yerçekimi Arama Optimizasyonu	elitizm	3
	mutasyon oranı	0.05
	amaç fonksiyonu	Hata kareleri ortalaması performans ölçütünün minimizasyonu
	iterasyon sayısı	15
	popülasyon büyüklüğü	50
	yerçekimi kuvveti sabiti	100
Yerçekimi Arama Optimizasyonu	mesafe sabiti	0.5
	amaç fonksiyonu	Hata kareleri ortalaması performans ölçütünün minimizasyonu


Tablo 3. Optimizasyon yöntemleri tarafından seçilen nitelikler (Features selected by optimization methods)

Nitelikler	PSO	HŞO	GKO	YO	GO	YAO
Euro/Dolar paritesi	X	X	X	X	X	
Enerji maliyeti	X	X		X	X	X
Enerji maliyetindeki değişim		X			X	
Çelik fiyatı		X	X		X	X
Çelik fiyatındaki değişim	X	X	X	X	X	X
1 ay önceki sipariş miktarı	X	X	X	X		
2 ay önceki sipariş miktarı	X	X	X	X		X
3 ay önceki sipariş miktarı			X			X
Son 3 ay sipariş ortalaması		X	X		X	X
Sipariş miktarındaki değişim		X	X		X	X

Tablo 3 incelendiğinde, PSO, HŞO, GKO, YO, GO ve YAO algoritmaları tarafından sırasıyla 5, 9, 8, 5, 7 ve 7 adet bağımsız niteliğin seçildiği görülmektedir. Çelik fiyatındaki değişim bağımsız değişkeni tüm nitelik seçimi optimizasyon algoritmaları tarafından sipariş miktarının tahmin edilmesinde etkili bir değişken olarak bulunmuştur. Genel olarak değerlendirildiğinde ise Euro/Dolar paritesi, enerji maliyeti 1 ay önceki sipariş miktarı, 2 ay önceki sipariş miktarı değişkenleri 5 optimizasyon algoritması tarafından etkili bulunmuştur.

4.4. Makine öğrenmesi modellerinin geliştirilmesi (Development of machine learning models)

Çalışmada, A, B, C ve D olarak isimlendirilen 4 farklı ürün veri seti üzerinde tüm bağımsız değişkenlerin kullanılması ile ve Parçacık Sürüsü Optimizasyonu, Harris Şahinleri Optimizasyonu, Gri Kurt Optimizasyonu, Yusufçuk Optimizasyonu, Genetik Optimizasyonu ve Yerçekimi Arama Optimizasyonu algoritmaları ile seçilen niteliklerin kullanılması ile olmak üzere Lineer Regresyon, Yapay Sinir Ağları ve Karar Ormanı algoritmaları kullanılarak 84 (4 ürün X 7 nitelik seçimi durumu X 3 algoritma) adet talep tahmini modeli geliştirilmiştir. Tahmin modellerinin geliştirilmesinde ve test edilmesinde Microsoft Azure Machine Learning (ML) Studio ortamından yararlanılmıştır. Azure ML Studio ortamında tahmin modeline ait mimari yapı Şekil 2’de gösterilmiştir.



Şekil 2. Azure ML Studio tahmin modeli mimarisi (Azure ML Studio prediction model architecture)

Muraina (2022), makine öğrenmesi algoritmalarının tahmin doğruluğunu artırmak için en uygun veri seti bölme oranını belirlemek amacıyla gerçekleştirdiği çalışmada en yüksek doğruluğu sağlayan oranın %90 (eğitim veri seti) - %10 (test veri seti) olduğu sonucuna varmıştır. Bu çalışmada da, 4 ürün veri setindeki verilerin %90’ı (80 aylık veriler) eğitim, %10’u (9 aylık veriler) test veri seti olarak kullanılmıştır. Her bir veri seti için deneme-yanılma yöntemi ile belirlenen

algoritma eğitim parametreleri ve değerleri Tablo 4’te gösterilmiştir.

4.5. Performans değerlendirme (Performance evaluation)

Literatürde talep tahmin çalışmalarında geliştirilen modellerin değerlendirilmesi ve karşılaştırılması amacıyla kullanılan birçok performans değerlendirme kriteri bulunmaktadır. Bu çalışmada modellerin performanslarının değerlendirilmesinde ortalama mutlak yüzde hata (MAPE), hata kareleri ortalaması (MSE), hata kareleri ortalamasının karekökü (RMSE), ortalama mutlak hata (MAE) ve tahmin doğruluğu ölçütleri kullanılmıştır. Performans ölçütlerinin formülleri sırasıyla Denklem 4-8’de verilmektedir (Yaşar vd., 2021; Demircioğlu Diren vd., 2020; Feizabadi, 2022; Chicco vd., 2021; Kacar, 2024).

$$MAPE = \frac{100}{n} \sum_{i=1}^n \left| \frac{Y_i - \hat{Y}_i}{Y_i} \right| \quad (3)$$

$$MSE = \frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 \quad (4)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2} \quad (5)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |Y_i - \hat{Y}_i| \quad (6)$$

$$\text{Tahmin doğruluğu(\%)} = 1 - MAPE \quad (7)$$

Burada, n, test veri setindeki toplam veri noktası sayısıdır, Y_i i. örneğin satış miktarının gerçek değeridir ve \hat{Y}_i i. örneğin satış miktarının tahmin edilen değeridir.

4.6. Deneysel sonuçlar (Experimental results)

Tablo 5’te A ürünü için geliştirilen talep tahmini modellerinin performans ölçütü değerleri verilmektedir. Deneysel sonuçlara göre, tüm performans ölçütü değerlerinde en düşük değerleri sağlayan model tüm bağımsız nitelikler ile geliştirilen Yapay Sinir Ağları modeli olmuştur. Modelin test edilmesi ile elde edilen MAPE, RMSE, MSE ve MAE değerleri sırası ile %6.4, 609, 370505 ve 502’dir. Lineer Regresyon Algoritması ile geliştirilen modeller incelendiğinde, PSO, HŞO, GKO, YO, GO, YAO algoritmaları olmak üzere tüm nitelik seçimi yöntemlerinin uygulanmasıyla elde edilen modeller tüm niteliklerin kullanılması ile geliştirilen modellerden daha iyi performans göstermişlerdir. MAPE değerlerine göre, PSO algoritması %4.1, HŞO algoritması %1, GKO algoritması %6.2, YO algoritması %4, GO algoritması %0.4, YAO algoritması ise %6.5 oranında iyileştirme sağlamıştır. Karar Ormanı algoritması ile geliştirilen modellerin sonuçları analiz edildiğinde ise GO nitelik seçimi yönteminin tüm performans ölçütü değerleri açısından modellerin performanslarını geliştirdiği anlaşılmaktadır. Bu iyileştirme MAPE değerinin %10.9’dan %8.6’ya, RMSE değerinin 955’ten 819’a, MSE değerinin 912785’ten 670423’e, MAE değerinin ise 831’den 693’e düşmesiyle elde edilmiştir.

Tablo 4. Modellerde kullanılan parametreler ve değerleri (Parameters and values used in the models)

Algoritma	Parametre	A Ürünü	B Ürünü	C Ürünü	D Ürünü
Lineer Regresyon	Çözüm metodu	En küçük kareler	En küçük kareler	En küçük kareler	En küçük kareler
	L2 düzenleme ağırlığı	0.001	0.001	0.001	0.001
Yapay Sinir Ağları	Gizli düğüm noktası sayısı	8	8	8	8
	Öğrenme oranı	0.002	0.001	0.001	0.003
	Öğrenme iterasyon sayısı	12000	12000	30000	12000
	İlk öğrenme ağırlığı	0.01	0.01	0.05	0.01
	Momentum değeri	0.2	0.5	0.4	0.2
	Normalize yöntemi	Min-Maks	Min-Maks	Min-Maks	Min-Maks
Karar Ormanı	Yeniden örnekleme yöntemi	Torbalama	Torbalama	Torbalama	Torbalama
	Karar ağacı sayısı	8	8	8	8
	Karar ağaçlarının maksimum derinliği	32	32	32	32
	Düğüm başına rastgele bölünme sayısı	298	256	256	128
	Yaprak düğümü başına minimum örnek sayısı	1	1	1	2

B ürünü için geliştirilen modellerin test edilmesi ile elde edilen performans ölçütü değerleri Tablo 6'da sunulmuştur. Değerler incelendiğinde en düşük MAPE ve MAE sonuçlarını sırasıyla %5.3 ve 66 değerleri ile HŞO algoritması ile seçilen nitelikler üzerinde eğitilen Lineer Regresyon modelinin verdiği görülmektedir. En düşük RMSE ve MSE sonuçlarını ise 92 ve 8523 değerleri ile YAO algoritması ile seçilen nitelikler üzerinde eğitilen Lineer Regresyon modeli sağlamıştır. HŞO nitelik seçimi yönteminin uygulanmasının Yapay Sinir Ağları ve Karar Ormanı algoritmaları ile geliştirilen modellerin tüm performans ölçütleri açısından performansını geliştirdiği anlaşılmaktadır.

C ürünü için geliştirilen modellerin performans ölçütü değerleri Tablo 7'de görülmektedir. Modeller

arasında MAPE, RMSE, MSE ve MAE olmak üzere dört performans ölçütü açısından sırasıyla %9.7, 949, 900005 ve 747 değerleri ile en iyi tahmin sonuçlarını sağlayan model GO nitelik seçimi yöntemi ile seçilen nitelikler üzerinde eğitilen Yapay Sinir Ağları modeli olmuştur. Lineer Regresyon algoritması ile eğitilen modeller incelendiğinde, GKO nitelik seçimi yöntemi hariç tüm nitelik seçimi yöntemlerinin tüm performans kriterleri açısından daha düşük değerler elde edilmesini sağladığı görülmektedir. Karar Ormanı algoritması ile eğitilen modellerin sonuçları ise modellerin eğitiminde tüm niteliklerin kullanımının en düşük performans ölçütü değerlerini verdiğini göstermektedir.

Tablo 5. A ürünü için geliştirilen modellerin performans ölçütü değerleri (Performance criterion values of the models developed for product A)

Model	Nitelik	MAPE	RMSE	MSE	MAE
Lineer Regresyon	Tüm Nitelikler	%17.1	1629	2652351	1420
	PSO	%13	1223	1496453	997
	HŞO	%16.1	1503	2259167	1314
	GKO	%10.9	1044	1089916	892
	YO	%13.1	1225	1500479	1004
	GO	%16.7	1561	2437814	1363
	YAO	%10.6	1148	1317273	912
Yapay Sinir Ağları	Tüm Nitelikler	%6.4	609	370505	502
	PSO	%13	1315	1727909	1087
	HŞO	%10.5	856	732871	825
	GKO	%12.7	1065	1134921	984
	YO	%13	1315	1727909	1087
	GO	%7.8	905	818922	646
	YAO	%13.9	1180	1393143	1065
Karar Ormanı	Tüm Nitelikler	%10.9	955	912785	831
	PSO	%15.7	1501	2252368	1203
	HŞO	%13.2	1223	1495537	982
	GKO	%10.2	1030	1059897	845
	YO	%15.7	1501	2253574	1204
	GO	%8.6	819	670423	693
	YAO	%11.7	1067	1138510	876

Tablo 6. B ürünü için geliştirilen modellerin performans ölçütü değerleri (Performance criterion values of the models developed for product B)

Model	Nitelik	MAPE	RMSE	MSE	MAE
Lineer Regresyon	Tüm Nitelikler	% 5.8	94	8861	70
	PSO	% 14	189	35526	170
	HŞO	%5.3	99	9699	66
	GKO	% 6.2	101	10097	74
	YO	% 14	189	35526	170
	GO	% 6.7	100	9941	78
	YAO	% 5.9	92	8523	70
Yapay Sinir Ağları	Tüm Nitelikler	% 7.4	99	9787	85
	PSO	% 15.6	204	41616	187
	HŞO	% 6.2	93	8692	74
	GKO	% 7.6	110	12089	89
	YO	% 15.6	204	41616	187
	GO	% 7.2	97	9455	81
	YAO	% 8.0	114	12961	93
Karar Ormanı	Tüm Nitelikler	% 8.1	112	12486	95
	PSO	% 16.4	213	45328	196
	HŞO	% 6.1	98	9657	74
	GKO	% 8.6	120	14327	100
	YO	% 16.4	213	45328	196
	GO	% 9.3	129	16604	111
	YAO	% 9.9	140	19624	117

Tablo 8’de D ürünü veri seti üzerinde eğitilip test edilen modeller için elde edilen performans değerlendirme kriterleri değerleri verilmiştir. MAPE ölçütü açısından en iyi performansı %8.5 değeri ile GO nitelik seçimi algoritması ve Karar Ormanı algoritmasının hibrit kullanımı ile geliştirilen modelin sağladığı görülmüştür. En düşük RMSE, MSE ve MAE ölçütü değerlerini ise 141, 19736 ve 88 değerleri ile tüm nitelikler üzerinde eğitilen Yapay Sinir Ağları modeli vermiştir.

Şekil 3’te A, B, C ve D olmak üzere 4 ürün için test veri setinde bulunan gerçek siparişleri ile MAPE ölçütü açısından en iyi performansı sağlayan makine

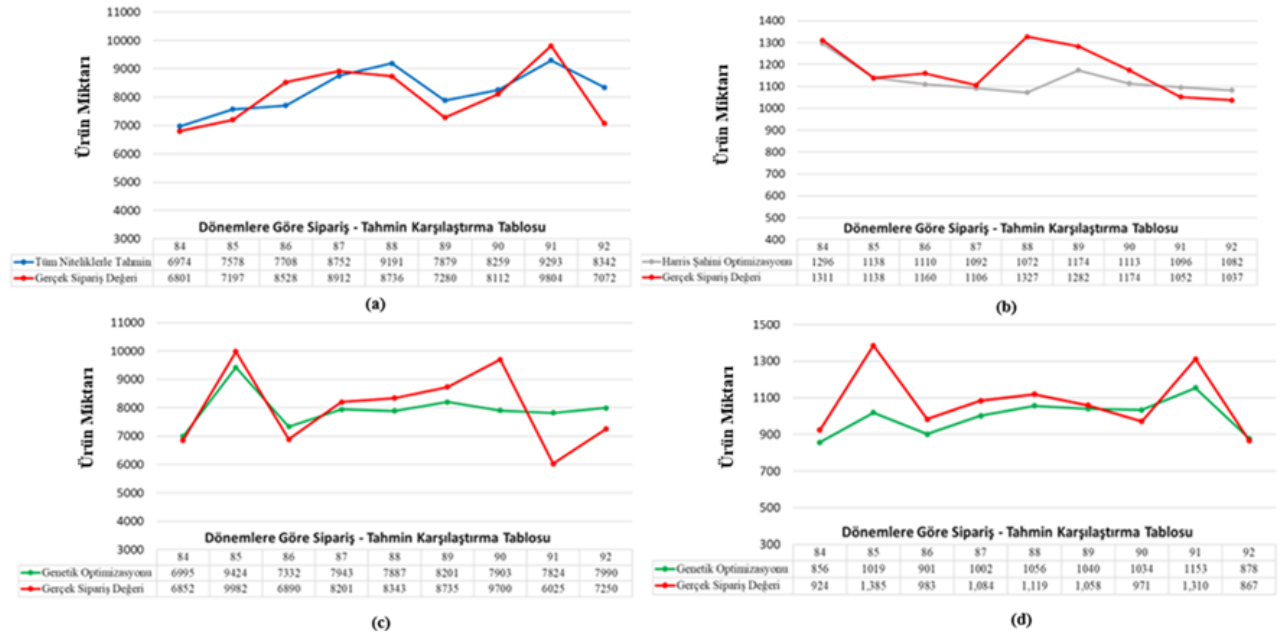
öğrenmesi modellerinin tahmin sonuçlarının karşılaştırmalı değerleri sunulmaktadır. Burada, A ürünü için en iyi model tüm nitelikler üzerinde eğitilmiş Yapay Sinir Ağları modeli (Şekil 3(a)), B ürünü için HO nitelik seçimi yöntemi ile seçilen nitelikler üzerinde eğitilen Lineer Regresyon modeli (Şekil 3(b)), C ürünü için GO nitelik seçimi yöntemi ile seçilen nitelikler üzerinde eğitilen Yapay Sinir Ağları modeli (Şekil 3(c)), D ürünü için ise GO nitelik seçimi yöntemi ile seçilen nitelikler üzerinde eğitilen Karar Ormanı modelidir (Şekil 3(d)). Değerler incelendiğinde, 4 modelin de test veri seti üzerindeki gözlemler için oldukça düşük tahmin hataları ile sonuçlandıkları görülmektedir.

Tablo 7. C ürünü için geliştirilen modellerin performans ölçütü değerleri (Performance criterion values of the models developed for product C)

Model	Nitelik	MAPE	RMSE	MSE	MAE
Lineer Regresyon	Tüm Nitelikler	% 19.1	1666	2776053	1404
	PSO	% 14.6	1288	1659965	1019
	HŞO	% 17.7	1493	2228261	1295
	GKO	% 21.1	1822	3318907	1532
	YO	% 14.6	1288	1659965	1019
	GO	% 17.6	1468	2153954	1270
	YAO	% 14.8	1399	1957631	1037
Yapay Sinir Ağları	Tüm Nitelikler	% 10.3	1023	1045607	776
	PSO	% 10.3	1061	1125004	842
	HŞO	% 14.8	1410	1986669	1097
	GKO	% 11.2	1301	1691307	847
	YO	% 10.3	1061	1125004	842
	GO	%9.7	949	900005	747
	YAO	% 19.1	1746	3049300	1340
Karar Ormanı	Tüm Nitelikler	% 11.6	1115	1244014	842
	PSO	% 18.4	1722	2965791	1322
	HŞO	% 16.9	1438	2067333	1232
	GKO	% 14.1	1381	1906241	1007
	YO	% 18.4	1721	2960334	1321
	GO	% 16.6	1649	2720632	1244
	YAO	% 18.9	1630	2656749	1368

Tablo 8. D ürünü için geliştirilen modellerin performans ölçütü değerleri (Performance criterion values of the models developed for product D)

Model	Nitelik	MAPE	RMSE	MSE	MAE
Lineer Regresyon	Tüm Nitelikler	%18.1	259	66805	207
	PSO	%23.5	321	102987	265
	HŞO	%18.1	260	67497	208
	GKO	%16.9	252	63530	194
	YO	%23.5	321	102987	265
	GO	%15.1	213	45350	171
	YAO	%14.3	218	47455	164
Yapay Sinir Ağları	Tüm Nitelikler	%10	141	19736	88
	PSO	%32.2	395	156375	362
	HŞO	%10.8	166	27451	122
	GKO	%13.2	188	35154	147
	YO	%32.2	395	156375	362
	GO	%10.6	149	22256	118
	YAO	%28.9	356	126449	323
Karar Ormanı	Tüm Nitelikler	%15.3	213	45478	157
	PSO	%25.2	327	106611	281
	HŞO	%19.6	239	56978	196
	GKO	%19.5	260	67752	206
	YO	%25.2	327	106611	281
	GO	%8.5	143	20549	100
	YAO	%11.1	156	24299	110



Şekil 3. En iyi modellerin tahmin sonuçları ile gerçek sipariş değerlerinin karşılaştırılması (a) A ürünü (b) B ürünü (c) C ürünü (d) D ürünü (Comparison of prediction results of the best models and actual order values (a) Product A (b) Product B (c) Product C (d) Product D)

5. Sonuçlar (Conclusions)

Üretim planlarındaki gecikmelerin önlenmesi için hammaddenin ve yarı mamulün belirlenen miktarda bulundurulması özellikle çelik sektöründe planların gerçekleşmesinde önemli bir etkiye sahiptir. Bu doğrultuda, tedarik zincirinde sürekliliğin sağlanması ve müşteriye teslim tarihlerinin gerçekleşmesinde talep tahmin modellerinin önemi göz ardı edilemez. Tedarik zinciri yönetiminin önemli bir süreci olan talep tahmini üzerine gerçekleştirilen çalışmalarda ortak amaç yüksek doğruluğa sahip bir tahmin modelinin geliştirilerek işletmelere fayda sağlamaktır. Bu çalışmada, çelik

sektöründeki ürünlerin satış miktarları için yüksek doğrulukta tahmin değerleri elde edebilmek amacıyla, optimizasyon yöntemlerine dayalı nitelik seçimi yöntemlerinin makine öğrenmesi algoritmaları ile hibrit kullanımını içeren talep tahmin modelleri geliştirilmiştir. Nitelik seçimi yöntemleri olarak Parçacık Sürüsü Optimizasyonu, Harris Şahinleri Optimizasyonu, Gri Kurt Optimizasyonu, Yusufçuk Optimizasyonu, Genetik Optimizasyonu ve Yerçekimi Arama Optimizasyonu olmak üzere 6 optimizasyon algoritması kullanılmıştır. Modellerin geliştirilmesinde yararlanılan makine öğrenmesi algoritmaları ise Yapay Sinir Ağları, Karar Ormanı ve Lineer Regresyon

algoritmaları olmuştur. Modeller çelik sektöründe faaliyet gösteren bir firmanın 4 ürününe ait gerçek verileri üzerinde eğitilerek test edilmiştir. Geliştirilen modeller MAPE, MAE, RMSE ve MSE performans ölçütlerine göre değerlendirilmiştir. Algoritmalar ile geliştirilen modellerin ortalama doğruluk değerleri incelendiğinde, yapay sinir ağlarıyla geliştirilen modellerin ortalama %91.9, karar ormanı yöntemi ile geliştirilen modellerin ortalama %91.3, lineer regresyon yöntemiyle geliştirilen modellerin ortalama %87.3 doğruluk değerine ulaştığı gözlemlenmiştir. Ancak, elde edilen sonuçlara göre, her bir ürün için farklı nitelik kombinasyonlarının ve farklı makine öğrenmesi yöntemlerinin üstün performans gösterdiği sonucuna ulaşılmıştır. Sonuç olarak, ürünler için en iyi tahmin performansı gösteren modeller %90.3-%94.7 arasında doğruluk değerleri sağlamıştır. Daha yüksek tahmin doğruluğu elde etmek amacıyla, gelecek çalışmalarda farklı metasegisel nitelik seçimi yöntemleri ile derin öğrenmeye dayalı regresyon algoritmalarının uygulanması planlanmaktadır.

Kaynaklar (References)

- Acı, M. ve Doğansoy, G. A. 2022. Makine öğrenmesi ve derin öğrenme yöntemleri kullanılarak e-perakende sektörüne yönelik talep tahmini. Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi, 37(3), 1325-1340.
- Aydın, M. R. ve Yazıcıoğlu, O. 2019. Yapay Sinir Ağları ile Talep Tahmini: Perakende Sektöründe Bir Uygulama. İstanbul Ticaret Üniversitesi Fen Bilimleri Dergisi, 18(35), 43-55.
- Bansal, P., Vanjani, A., Mehta, A., Kavitha, J. C. ve Kumar, S. 2022. Improving the classification accuracy of melanoma detection by performing feature selection using binary Harris hawks optimization algorithm. Soft Computing, 26(17), 8163-8181.
- Catal, C., Kaan, E. C. E., Arslan, B. ve Akbulut, A. 2019. Benchmarking of regression algorithms and time series analysis techniques for sales forecasting. Balkan Journal of Electrical and Computer Engineering, 7(1), 20-26.
- Chidroop, I. ve Moharir, M. 2020. Predicting the Propensity of Order Cancellation in the Ecommerce Domain. International Journal of Research in Engineering, Science and Management, 3(6). s. 658-664.
- Chicco, D., Warrens, M. J., ve Jurman, G. 2021. The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation. PeerJ Computer Science, 7.
- Diren, D. D., Boran, S., ve Cil, I. 2020. Integration of machine learning techniques and control charts in multivariate processes. Scientia Iranica, 27(6), 3233- 3241.
- El Filali, A., El Filali, S. ve Jadli, A. 2022. Application of Deep Learning in the Supply Chain Management: A comparison of forecasting demand for electrical products using different ANN methods. In 2022 International Conference on Electrical, Computer and Energy Technologies (ICECET) (pp. 1-7).
- Elgamal, Z. M., Yasin, N. B. M., Tubishat, M., Alswaitti, M., ve Mirjalili, S. 2020. An improved harris hawks optimization algorithm with simulated annealing for feature selection in the medical field. IEEE access, 8, 186638-186652.
- Fanoodi, B., Malmir, B. ve Jahantigh, F. F. 2019. Reducing demand uncertainty in the platelet supply chain through artificial neural networks and ARIMA models. Computers in biology and medicine, 113, 103415.
- Feizabadi, J. 2022. Machine learning demand forecasting and supply chain performance. International Journal of Logistics Research and Applications, 25(2), 119-142.
- Gökler, S. H. 2020. Kan Bankalarında Talep Tahmini ve Stokastik Stok Yönetimi. Doktora Tezi, Sakarya Üniversitesi.
- Güven, İ. 2020. Perakende Hazır Giyim Endüstrisinde Yapay Zeka Yöntemleri ile Talep Tahmini. Doktora Tezi, Karabük Üniversitesi.
- Han, G., Sönmez, E. F., Avcı, S. ve Aladağ, Z. 2022. Uygun Normalizasyon Tekniği ve Yapay Sinir Ağları Analizi ile Otomobil Satış Tahminlemesi. İşletme Ekonomi ve Yönetim Araştırmaları Dergisi, 5(1), 19-45.
- Heidari, A. A., Mirjalili, S., Faris, H., Aljarah, I., Mafarja, M. ve Chen, H. 2019. Harris hawks optimization: Algorithm and applications. Future generation computer systems, 97, 849-872.
- Huyen, C. 2022. Designing machine learning systems. O'Reilly Media.
- Ismael, O. M., Qasim, O. S. ve Algamal, Z. Y. 2021. A new adaptive algorithm for v-support vector regression with feature selection using Harris hawks optimization algorithm. In Journal of Physics: Conference Series (Vol. 1897, No. 1, p. 012057). IOP Publishing.
- İncece, S. ve Beyca, Ö. F. 2022. Demand Forecasting with Integration of Time Series and Regression Models in Pharmaceutical Industry. International Journal of Advances in Engineering and Pure Sciences, 34(3), 415-425.
- Kacar, İ. 2024. Makine Öğrenimi Kullanarak Bir Mekanik Jiroskobun Yalpalama Tahmininde Zaman Serisi Modeli. Journal of Intelligent Systems: Theory and Applications, 7(1), 14-26.
- Kennedy, J. 2010. Particle swarm optimization. In: Encyclopedia of Machine Learning, 760-766.
- Keung, K. L., Lee, C. K. ve Yiu, Y. H. 2021. A machine learning predictive model for shipment delay and demand forecasting for warehouses and sales data. In 2021 IEEE International Conference on Industrial Engineering and Engineering Management (IEEM). 1010-1014. IEEE.
- Kochak, A. ve Sharma, S. 2015. Demand forecasting using neural network for supply chain management. International journal of mechanical engineering and robotics research, 4(1), 96-104.
- Korkut, D. 2019. Yapay sinir ağları yöntemi ile talep tahmini ve ayakkabı sektörüne uygulaması. Yayımlanmamış Yüksek Lisans Tezi., Hacı Bayram Veli Üniversitesi.
- KS, S. R. ve Murugan, S. 2017. Memory based hybrid dragonfly algorithm for numerical optimization problems. Expert Systems with Applications, 83, 63-78.
- Küçük, M. ve Freitag, M. 2021. Forecasting of customer demands for production planning by local k-nearest neighbor models. International Journal of Production Economics, 231, 107837.

- Lazzeri, F. 2020. Machine learning for time series forecasting with Python. John Wiley & Sons.
- Lee, H. L., V. Padmanabhan ve S. Whang. 1997. "Information Distortion in a Supply Chain: the Bullwhip Effect." *Management Science* 43: 546–558.
- LightGBM. 2023, LightGBM Regressor, Erişim Tarihi:20.12.2023. <https://lightgbm.readthedocs.io/en/latest/pythonapi/lightgbm.LGBMRegressor.html>
- Lingireddy, S. ve Ormsbee, L. E. 2002. Hydraulic network calibration using genetic optimization. *Civil Engineering and Environmental Systems*, 19(1), 13-39.
- Merkuryeva, G., Valberga, A. ve Smirnov, A. 2019. Demand forecasting in pharmaceutical supply chains: A case study. *Procedia Computer Science*, 149, 3-10.
- Mirjalili, S.; Mirjalili, S.M. ve Lewis, A. 2014. Grey wolf optimizer. *Adv. Eng. Softw.* 69, 46–61.
- Mohammed, M., El-Shafie, H. ve Munir, M. 2023. Development and Validation of Innovative Machine Learning Models for Predicting Date Palm Mite Infestation on Fruits. *Agronomy*, 13(2), 494.
- Mohan, B. A., Harshavardhan, B., Karan, S., Shariff, M. J. ve Pranav, M. G. 2021. Demand forecasting and route optimization in supply chain industry using data Analytics. In 2021 Asian Conference on Innovation in Technology (ASIANCON). 1-7. IEEE.
- Muraina, I. 2022. Ideal dataset splitting ratios in machine learning algorithms: general concerns for data scientists and data analysts. In 7th International Mardin Artuklu Scientific Research Conference (pp. 496-504).
- Orzechowski, A., Lugosch, L., Shu, H., Yang, R., Li, W. ve Meyer, B. H. 2023. A data-driven framework for medium-term electric vehicle charging demand forecasting. *Energy and AI*, 14, 100267.
- Özçelik, T. Ö., Kibar, A. ve Bal, M.E., 2021. Sosyal Medyadan Veri Çekme Örnekleri. *Mühendislikte Yapay Zeka ve Uygulamaları 4*, Ed. Gülseçen, S., İnal, M.M., Torkul, O., Uçar, M.K., Sakarya Üniversitesi Yayınları, 79-101.
- Poli, R., Kennedy, J. ve Blackwell, T. 2007. Particle swarm optimization: An overview. *Swarm intelligence*, 1, 33-57.
- Sauro, J. ve Lewis, J. R. 2016. Quantifying the user experience: Practical statistics for user research. Morgan Kaufmann.
- Spiliotis, E. 2022. Decision trees for time-series forecasting. *Foresight*, 1, 30-44.
- Xu, S. ve Wang, S. 2022. Tourism Demand Prediction Model Using Particle Swarm Algorithm and Neural Network in Big Data Environment. *Journal of Environmental and Public Health*, 2022.
- Tan, C. W., Dempster, A., Bergmeir, C. ve Webb, G. I. 2022. MultiRocket: multiple pooling operators and transformations for fast and effective time series classification. *Data Mining and Knowledge Discovery*, 36(5), 1623-1646.
- Tavukçu, A. S. ve Sennaroğlu, B. 2021. Applying Forecasting Methods to Reduce the Cost of Spare Parts Inventory in a Company. *Endüstri Mühendisliği*, 32(3), 396-413.
- Thaher, T., ve Arman, N. 2020. Efficient multi-swarm binary harris hawks optimization as a feature selection approach for software fault prediction. In 2020 11th International conference on information and communication systems (ICICS). 249-254. IEEE.
- Thawkar, S. 2022. Feature selection and classification in mammography using hybrid crow search algorithm with Harris hawks optimization. *Biocybernetics and Biomedical Engineering*, 42(4), 1094-1111.
- Torun, Z. ve DESTE, M. 2021. Sağlık İşletmelerinde Malzeme Yönetiminde Uygun Talep Tahmin Yönteminin Belirlenmesine Yönelik Bir Uygulama. 19 Mayıs Sosyal Bilimler Dergisi, 2(3), 581-613.
- Türk, E. ve Kiani, F. Yapay Sınır Ağları ile Talep Tahmini Yapma: Beyaz Eşya Üretim Planlama Örneği. *İstanbul Sabahattin Zaim Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 1(1), 30-37.
- Yadav, A. ve Deep, K. 2013. Constrained optimization using gravitational search algorithm. *National Academy Science Letters*, 36, 527-534.
- Yani, L. P. E., ve Amer, A. 2023. Demand forecasting accuracy in the pharmaceutical supply chain: a machine learning approach. *International Journal of Pharmaceutical and Healthcare Marketing*, 17(1), 1-23.
- Yaşar, H., Çağıl, G., Torkul, O. ve Şişçi, M. 2021. Cylinder pressure prediction of an HCCI engine using deep learning. *Chinese Journal of Mechanical Engineering*, 34, 1-8.
- Zeng, D., Chen, L., Zhao, S., Ou, J., Yuan, H. ve Wu, T. 2022. An Optimized Grey Wolf Algorithm. In 2022 IEEE International Conference on Sensing, Diagnostics, Prognostics, and Control (SDPC). 200-205. IEEE.