T.C.

YILDIZ TEKNİK ÜNİVERSİTESİ

FEN BİLİMLERİ ENSTİTÜSÜ

YENİ BİR METASEZGİSEL ALGORİTMA İLE MAKİNE ÖĞRENMESİ MODELLERİNİN OPTİMİZASYONU

Muhammed Resul AYDIN

DOKTORA TEZİ

Endüstri Mühendisliği Anabilim Dalı

Endüstri Mühendisliği Programı

Danışman

Doç. Dr. Bahadır GÜLSÜN

Mart, 2025

T.C.

YILDIZ TEKNİK ÜNİVERSİTESİ

FEN BİLİMLERİ ENSTİTÜSÜ

YENİ BİR METASEZGİSEL ALGORİTMA İLE MAKİNE ÖĞRENMESİ MODELLERİNİN OPTİMİZASYONU

Muhammed Resul AYDIN tarafından hazırlanan tez çalışması 13.03.2025 tarihinde aşağıdaki jüri tarafından Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü Endüstri Mühendisliği Anabilim Dalı, Endüstri Mühendisliği Programı **DOKTORA TEZİ** olarak kabul edilmiştir.

Doç. Dr. Bahadır GÜLSÜN
Yıldız Teknik Üniversitesi
Danışman

Jüri Üyeleri

Doç. Dr. Bahadır GÜLSÜN, Danışman
Yıldız Teknik Üniversitesi _____

Prof. Dr. Semih ÖNÜT, Üye
Yıldız Teknik Üniversitesi _____

Doç. Dr. İrem OTAY, Üye
İstanbul Bilgi Üniversitesi _____

Prof. Dr. Ali Fuat GÜNERİ, Üye
Yıldız Teknik Üniversitesi _____

Prof. Dr. Berk AYVAZ, Üye
İstanbul Ticaret Üniversitesi _____

Danışmanım Doç. Dr. Bahadır GÜLSÜN sorumluluğunda tarafımca hazırlanan "Yeni Bir Metasezgisel Algoritma ile Makine Öğrenmesi Modellerinin Optimizasyonu" başlıklı çalışmada veri toplama ve veri kullanımında gerekli yasal izinleri aldığımı, diğer kaynaklardan aldığım bilgileri ana metin ve referanslarda eksiksiz gösterdiğimi, araştırma verilerine ve sonuçlarına ilişkin çarpıtma ve/veya sahtecilik yapmadığımı, çalışmam süresince bilimsel araştırma ve etik ilkelerine uygun davrandığımı beyan ederim. Beyanımın aksinin ispatı halinde her türlü yasal sonucu kabul ederim.

Muhammed Resul AYDIN

İmza

Canım Babama

TEŞEKKÜR

Bu tezin hazırlanmasında değerli katkılarını ve rehberliğini esirgemeyen tez danışmanım, kıymetli hocam **Doç. Dr. Bahadır GÜLSÜN**'e sonsuz teşekkür ederim. Ayrıca, tez izleme süreci boyunca değerli yorumları ve yönlendirmeleriyle bana destek olan kıymetli hocalarım **Prof. Dr. Semih ÖNÜT** ve **Doç. Dr. İrem OTAY**'a teşekkürü bir borç bilirim.

Tez sürecinde beni her daim destekleyen, sabır ve sevgileriyle yanımda olan canım **anneme, abilerime**, **aileme** ve özellikle bu zorlu süreçte anlayışı ve desteğiyle yanımda olan sevgili eşim **Betül IŞIK AYDIN'a** gönülden teşekkür ederim. Varlığınız, bu çalışmayı mümkün kılan en büyük motivasyon kaynağı oldu.

Muhammed Resul AYDIN

İÇİNDEKİLER

SİMGE LİSTESİ viii

KISALTMA LİSTESİ ix

ŞEKİL LİSTESİ xi

TABLO LİSTESİ xii

ÖZET xiii

ABSTRACT xv

1 GİRİŞ 1

1.1 Literatür Özeti 5

2 METODOLOJİ 26

2.1 Makine Öğrenmesi Algoritmaları 26

2.1.1 Esktrem Gradyan Arttırma (XGBoost) Algoritması 27

2.2 Metasezgisel Algoritmalar 30

2.2.1 Genetik Algoritmalar (GA) 31

2.2.2 Gri Kurt Optimizasyonu (GWO) 32

2.2.3 Beyaz Köpek Balığı Optimizasyonu (WSO) 33

2.2.4 Yapay Tavşan Optimizasyonu (ARO) 34

2.2.5 Yapay Arı Kolonisi (ABC) 35

2.2.6 Ateş Şahini Optimizasyonu (FHO) 36

2.2.7 ABC-FHO Hibrit Modeli 37

2.3 İstatistiksel Analizler 39

2.3.1 Shapiro-Wilk Testi 39

2.3.2 Mann-Whitney U Testi 40

2.3.3 Performans Ölçüm Metrikleri……...40

3 DENEYSEL ÇALIŞMA **42**

3.1 Deneyin Kurulması 44

3.2 Parametrelerin Ayarlanması 46

3.3 Bulgular ve Analizler 48

4 SONUÇ **59**

KAYNAKÇA **61**

TEZDEN ÜRETİLEN YAYINLAR **69**

SİMGE LİSTESİ

$\hat{y}_i$	Tahmin edilen i. değer
Ω	Ceza katsayısı
γ	Her eklenen yaprak için karmaşıklık maliyetinin temsili
λ	Düzenleme parametresi
T	Ağaç yaprak sayısı
ω	Puan vektörü
Φ	Pertürbasyon katsayısı

KISALTMA LİSTESİ

ABC	Artificial Bee Colony
ABRO	Artificial Bee Rabbit Optimization
ADE	Adaptive Differential Evolution
ALO	Ant Lion Optimization
ANN	Artificial Neural Network
ARIMA	AutoRegressive Integrated Moving Average
ARO	Artificial Rabbits Optimization
AUC	Area Under Curve
BN	Bayesian Network
BOA	Butterfly Optimization Algorithm
CART	Classification and Regression Tree
CCD	Central Composite Design
CNN	Convolutional Neural Network
CSA	Crow Search Algorithm
CSO	Cat Swarm Optimization
DNN	Deep Neural Network
DL	Deep Learning
ELM	Extreme Learning Machine
ELT	Enhanced Learning Technique
FA	Firefly Algorithm
FEM	Finite Element Method
FHO	Fire Hawk Optimizer
FPA	Flower Pollination Algorithm
FRP	Fiber Reinforced Polymer
GA	Genetic Algorithm
CatBoost	Categorical Boosting
GBDT	Gradient Boosting Decision Tree
GBT	Gradient Boosted Trees
GRU	Gated Recurrent Unit
GWO	Grey Wolf Optimizer
HHO	Harris Hawk Optimizer
HO	Hippo Optimization
IHO	Improved Hippo Optimization
JS	Jellyfish Search Algorithm
KH	Krill Herd
LGBM	Light Gradient Boosting Machine
LHS	Latin Hypercube Sampling
LOS	Length of Stay
LSSVM	Least Squares Support Vector Machine
LSTM	Long Short-Term Memory
MAE	Mean Absolute Error
MAPE	Mean Absolute Percentage Error

ML	Machine Learning
MLP	Multi Layers Perceptron
NHP	Number of Hospitalized Patients
NLP	Natural Language Processing
NN	Neural Network
NWP	Numerical Weather Prediction
R^2	Determination coefficient
RF	Random Forest
RMSE	Root Mean Square Error
RSA	Reptile Search Algorithm
SHAP	SHapley Additive exPlanations
SOS	Symbiotic Organisms Search Algorithm
SVM	Support Vector Machine
SVR	Support Vector Regression
TLBO	Teaching-Learning-Based Optimization
VRP	Vehicle Routing Problem
WSO	White Shark Optimizer
WIO	Wolf-Inspired Optimization
XGBoost	Extreme Gradient Boosting

ŞEKİL LİSTESİ

Şekil 2.1 GA sözde kodu **31**
Şekil 2.2 GWO sözde kodu **32**
Şekil 2.3 WSO sözde kodu **33**
Şekil 2.4 ARO sözde kodu **34**
Şekil 2.5 ABC sözde kodu **35**
Şekil 2.6 FHO sözde kodu **36**
Şekil 2.7 ABC-FHO sözde kodu **39**
Şekil 3.1 Veri kümesi 1'e ait satış çizelgesi **42**
Şekil 3.2 Veri kümesi 2'ye ait satış çizelgesi **42**
Şekil 3.3 Veri kümesi 3'e ait satış çizelgesi **43**
Şekil 3.4 Önerilen tahmin modeline ait akış şeması **45**
Şekil 3.5 MAPE değerinin iterasyonlar boyunca dağılım grafikleri **52**
Şekil 3.6 RMSE değerinin iterasyonlar boyunca dağılım grafikleri **52**
Şekil 3.7 MAPE değerinin iterasyonlar boyunca kutu grafikleri **54**
Şekil 3.8 RMSE değerinin iterasyonlar boyunca kutu grafikleri **55**

TABLO LİSTESİ

Tablo 1.1 Literatürde incelenen çalışmaların özeti **18**
Tablo 3.1 Çalışmada kullanılan veri setlerine ait özet bilgiler..... **43**
Tablo 3.2 Hiperparametrelerinin alt, üst sınırları ve varsayılan değerleri **47**
Tablo 3.3 Deneysel çalışma için hiperparametrelerinin alt ve üst sınırları..... **48**
Tablo 3.4 Ortalama MAPE ve RMSE değerleri..... **49**
Tablo 3.5 En iyi ve en kötü MAPE değerleri..... **50**
Tablo 3.6 En iyi ve en kötü RMSE değerleri **51**
Tablo 3.7 Algoritmalara ait ortalama çalışma süreleri..... **55**
Tablo 3.8 H0 hipotezinin p-value değerlerine göre sonuçları..... **57**

ÖZET

Yeni Bir Metasezgisel Algoritma ile Makine Öğrenmesi Modellerinin Optimizasyonu

Muhammed Resul AYDIN

Endüstri Mühendisliği Anabilim Dalı
Endüstri Mühendisliği Programı
Doktora Tezi

Danışman: Doç. Dr. Bahadır GÜLSÜN

Tahminleme, gelecekteki eğilimleri öngörebilmek için önemli bir araç olup; mühendislik, finans, sağlık gibi çeşitli alanlarda bilgiye dayalı kararlar alabilmek için kullanılmaktadır. Doğru tahminleme, kaynakların etkin bir şekilde dağıtılması, envanterin yönetilmesi ve kararların bilgiyle desteklenmesi açısından yadsınamaz bir öneme sahiptir. Verilerin giderek daha karmaşık hale gelmesi sebebiyle, makine öğrenimi modelleri, karmaşık veri desenlerini öğrenme ve anlamlandırma yetenekleri sayesinde, güvenilir tahminleme sistemleri oluşturmak için değerli araçlar haline gelmiştir. Bu çalışma, makine öğrenimi algoritmaları ile geliştirilen tahminleme modellerinin optimizasyonunu gerçekleştirmek amacıyla, Yapay Arı Kolonisi (ABC) ve Ateş Şahini Optimizasyonu (FHO) algoritmalarını birleştiren yeni bir metasezgisel algoritma (ABC-FHO) sunmaktadır. İki metasezgisel algoritmanın güçlü yönlerinden yararlanılarak oluşturulan hibrit yaklaşım, tahminlerin doğruluğunu ve güvenilirliğini arttırmaktadır. Bu çalışmanın odağı, yaygın olarak kullanılan bir makine öğrenimi algoritması olan Ekstrem Gradyan Arttırma (XGBoost) ile oluşturulan tahmin modellerinin hiperparametrelerini optimize ederek, makine öğrenimi modellerinin performansını geliştirmektir. Üç

farklı veri seti üzerinde yapılan testler, hibrit ABC-FHO modelinin Genetik Algoritma (GA), Gri Kurt Optimizasyonu (GWO), Yapay Tavşan Optimizasyonu (ARO), Beyaz Köpek Balığı Optimizasyonu (WSO), bağımsız ABC ve bağımsız FHO gibi algoritmalardan daha iyi performans gösterdiğini ortaya koymaktadır. Ayrıca, bu çalışmada FHO, tahminleme modellerinde hiperparametre optimizasyonu için ilk kez uygulanmıştır. İstatistiksel performans metrikleri ve istatistiksel testler kullanılarak değerlendirilen sonuçlar, ABC-FHO algoritmasının üstün performansını doğrulamaktadır. Bu çalışma, tahminleme tekniklerinde önemli bir ilerleme sağlayarak, tahmin modellerinin iyileştirilmesi ve çeşitli alanlarda bilgiye dayalı, daha güvenilir karar alma süreçlerini desteklemek için pratik ve etkili bir çözüm sunmaktadır.

Anahtar Kelimeler: Ekstrem gradyan arttırma algoritması, makine öğrenmesi algoritması, tahmin modeli, metasezgisel algoritmalar, hiperparametre optimizasyonu

ABSTRACT

Optimization of Machine Learning Models Using a Novel Metaheuristic Algorithm

Muhammed Resul AYDIN

Department of Industrial Engineering
Doctor of Philosophy Thesis

Supervisor: Assoc. Prof. Dr. Bahadır GÜLSÜN

Forecasting is a critical tool for predicting future trends and making informed decisions across various fields such as engineering, finance, and healthcare. Accurate forecasting is essential for effectively allocating resources, managing inventory, and supporting better decision-making processes. Due to the increasing complexity of data, machine learning models have become valuable tools for creating reliable forecasting systems, thanks to their ability to learn and interpret complex data patterns. This study presents a novel metaheuristic algorithm that combines the Artificial Bee Colony (ABC) and Fire Hawk Optimizer (FHO) algorithms to enhance the forecasting models success developed using machine learning algorithms. The novel hybrid approach (ABC-FHO), which leverages the strengths of both metaheuristic algorithms, enhances the accuracy and reliability of forecasts. The focus of the research is to enhance the performance of machine learning models by optimizing the hyperparameters of prediction models built using the widely known machine learning algorithm, Extreme Gradient Boosting (XGBoost). Tests conducted on three different datasets reveal that the hybrid model consistently outperforms algorithms such as Genetic Algorithm (GA), Grey Wolf Optimizer (GWO), Artificial Rabbits Optimization (ARO), White Shark Optimizer

(WSO), ABC, and FHO. Furthermore, this study marks the first application of FHO for hyperparameter optimization in forecasting models. Results, evaluated using statistical performance metrics and statistical tests, confirm the superior performance of the ABC-FHO model. This study provides a practical and effective solution for improving forecasting models, thereby supporting better data-driven decision-making processes across various fields.

Keywords: Extreme gradient boosting algorithm, machine learning algorithm, forecasting model, metaheuristic algorithms, hyperparameter tuning

1
GİRİŞ

Talep tahmini, işletmelerin envanter yönetimini verimli bir şekilde yapmalarını, kaynak tahsisini optimize etmelerini ve kârlılığı artırmalarını sağlayarak, rekabet avantajı sağlamada önemli bir rol oynar. Talep fazlalığını veya eksikliğini önleyebilmek, israfı azaltmaya ve müşteri memnuniyetini artırmaya olanak sağlar. Doğru satış tahminleri, özellikle dalgalı talep desenlerinin ve mevsimsel değişimlerin olduğu sektörlerde üretim, personel planlaması ve lojistik süreçlerinde bilgiye dayalı kararlar alınmasına yardımcı olur. İleri düzey tahmin yöntemlerini başarıyla kullanan işletmeler, pazar taleplerini daha iyi karşılayabilir, müşteri memnuniyetini artırabilir ve sürekli değişen koşullarda rekabetçi kalabilir.

Makine öğrenimi, karmaşık ve dinamik ortamlarda tahmin doğruluğunu artırma potansiyeli ile tahminleme çalışmalarında giderek daha yaygın bir şekilde kullanılmaktadır. Büyük ve karmaşık veri setlerini analiz etme kapasitesine sahip makine öğrenimi modelleri, mevsimsel veya promosyonel satışlar gibi tahminleme görevlerinde etkili çözümler sunmaktadır (J. Huber ve Stuckenschmidt, 2020). Örneğin, çok katmanlı algılayıcılar (MLP), destek vektör regresyonu (SVR) ve yapay sinir ağları (ANN) gibi yöntemler, tahmin doğruluğunda ve veri işleme kapasitesinde kayda değer iyileştirmeler sağlamıştır (Choi vd., 2024).

Makine öğrenmesi algoritmaları arasında sıkça tercih edilen XGBoost, literatürdeki birçok başarılı uygulamasıyla öne çıkmaktadır. Örneğin, Ben Jabeur vd. (2024 tarafından yapılan çalışmada, rastgele ormanlar (RF) ve ANN gibi algoritmaları tahmin görevlerinde geride bırakarak üstün bir performans sergilemiştir. Özellikle karmaşık, doğrusal olmayan desenleri yakalamadaki başarısıyla yağış tahmini gibi alanlarda diğer algoritmalara nazaran belirgin bir avantaj sağlamıştır (Mishra vd., 2024). Bunun yanı sıra, perakende talep tahmininde daha yüksek doğruluk elde ederek ve tahmin hatalarını önemli ölçüde azaltarak diğer algoritmalardan ayrışmıştır (X. Zhang vd., 2021; Massaro vd., 2021). Ayrıca, perakende ve e-ticaret sektörlerindeki büyük ölçekli tahmin sorunlarını güvenilir bir şekilde çözme

kapasitesiyle etkinliğini bir kez daha kanıtlamıştır (Panarese vd., 2021). Finansal tahminleme üzerine yapılan bir çalışmada, XGBoost'un CatBoost (Categorical Boosting) ve LightGBM (Light Gradient Boosting Machine) gibi modern boosting algoritmalarına kıyasla daha başarılı sonuçlar sunduğu gösterilmiştir. (Jabeur vd., 2021). Ayrıca, makine öğrenmesi modellerinin risk tahmin süreçlerindeki etkinliğini inceleyen bir çalışma, XGBoost'un, LightGBM ve CatBoost'a kıyasla farklı veri setlerinde karmaşık ve doğrusal olmayan ilişkileri başarıyla ele aldığını, bu yönüyle güvenilir bir algoritma olduğunu vurgulamaktadır (Jain ve Singh, 2024).

Hiperparametre optimizasyonu, makine öğrenimi modellerinin performansını artırmak ve bilinmeyen veri kümelerine genelleme yeteneğini geliştirmek için göz önüne alınması gereken kritik bir süreçtir. Hiperparametrelerin doğru bir şekilde ayarlanması, modellerin doğruluğunu ve güvenilirliğini artırırken, yanlış seçimler modelin performansını sınırlayabilir (Arnold vd., 2024). Bu nedenle, hiperparametre optimizasyonuna yönelik ileri düzey yöntemlerin geliştirilmesi, tahminleme modellerinin doğruluğunu ve dayanıklılığını artırmak için büyük bir fırsat sunmaktadır.

Metasezgisel algoritmalar, hiperparametre optimizasyonunda etkili araçlar olarak literatüre kazandırılmış ve geleneksel yöntemlere kıyasla daha üstün bir performans sunmuştur. Bu algoritmalar, geniş ve karmaşık arama alanlarını etkili bir şekilde keşfetmeleriyle öne çıkmaktadır. Son yıllarda, hiperparametre optimizasyonunda metasezgisel algoritmaların kullanımı, farklı alanlardaki tahmin modellerinin performansını önemli ölçüde artırmıştır. Örneğin, güneş enerjisi tahmininde GA tabanlı yaklaşımlar, uzun kısa vadeli bellek (LSTM) ağlarının doğruluğunu artırmış ve hiperparametrelerin optimize edilmesiyle tahmin hatalarını önemli ölçüde azaltmıştır (Dhake vd., 2023). Benzer şekilde, destek vektör makineleri (SVM) ile uyarlanabilir diferansiyel evrim (ADE) kombinasyonu, hiperparametre ayarlarında daha yüksek doğruluk ve daha iyi yakınsama oranları sağlamıştır (Zulfiqar vd., 2022).

Kombinatoryal optimizasyon problemlerinde, ABC algoritması çok yönlülüğünü kanıtlamış, özellikle montaj hattı dengeleme ve biyoinformatik gibi alanlarda rekabetçi sonuçlar elde etmiş ve çoklu alanlarda uygulanabilirliğini doğrulamıştır (Kaya vd., 2022). Ayrıca, GWO algoritması da hiperparametre optimizasyonu

görevlerinde etkinliğini göstermiş, özellikle karmaşık makine öğrenimi modellerinde model doğruluğunu artırmış ve kayıp oranlarını azaltmıştır (Mohakud ve Dash, 2021). Başka bir çalışmada ise FHO, keşif ve sömürü arasındaki dengeyi sağlayarak uzun optimizasyon süreçlerinde başarılı sonuçlar sunmuştur (Abd Elaziz vd., 2023).

Bireysel metasezgisel algoritmalar genellikle belirli sınırlarla karşılaşırken, bu algoritmaların hibritleştirilmesi bu sınırlamaları aşmada etkili bir yaklaşım sunmaktadır. Metasezgisel algoritmaların hibritleştirilmesi sayesinde, özellikle tek bir algoritmanın yetersiz kalabileceği karmaşık optimizasyon senaryolarında başarılı sonuçlar elde edilmiştir. (Abd Elaziz vd., 2023). Örneğin, WSO ile ARO gibi algoritmaların hibritleştirilmesi, fotovoltaik parametre çıkarımında üstün performans sağlamış ve arama verimliliğini artırmıştır (Çetinbaş vd., 2023). Benzer şekilde, ABC ile sürüngen arama algoritması (RSA) gibi yaklaşımların hibritleştirilmesi, tahmin görevlerinde keşif ve sömürü arasındaki dengeyi artırmıştır (Al-Shourbaji vd., 2022).

Literatürün sistematik bir şekilde incelenmesi ve 'No Free Lunch' teoreminde belirtilen, mevcut algoritmaların tüm problem sınıflarında üstün performans gösteremeyeceği gerçeği (Wolpert ve Macready, 1997), yeni ve yenilikçi algoritmaların literatüre kazandırılmasının gerekliliğini ortaya koymuştur. Bu çalışma, ABC ve FHO algoritmalarını bu bağlam ışığında hibritleştirerek, hiperparametre optimizasyonu için yenilikçi bir yaklaşım sunmaktadır. Önerilen yaklaşım, yalnızca akademik literatüre katkı sağlamakla kalmayıp, aynı zamanda gerçek dünya satış tahmini görevleri için pratik bir çözüm sunmaktadır.

Bu çalışmanın temel amacı, ABC ve FHO algoritmalarının her birinin güçlü yönlerini alarak birleştirmek ve hiperparametre optimizasyonu için yenilikçi bir metasezgisel yöntem geliştirmektir. Çalışma, XGBoost gibi makine öğrenmesi algoritmalarının performansını artırmayı, tahmin doğruluğunu iyileştirmeyi ve veri kümelerine genelleme yeteneğini geliştirmeyi hedeflemektedir. Ayrıca, tüm algoritmalar detaylı bir şekilde karşılaştırılmış ve elde edilen sonuçlar, araştırmacıların ve uygulayıcıların literatüre son yıllarda kazandırılmış metasezgisel algoritmalar hakkında bilgi sahibi olmalarını sağlayacak şekilde sunulmuştur. Bu kapsamda, önerilen hibrit algoritmanın diğer metasezgisel

yöntemlere kıyasla üstün performans gösterdiği ayrıntılı bir şekilde ortaya konulmuştur.

Bu tez, makine öğrenimi algoritmalarının hiperparametre optimizasyonunda, metasezgisel yaklaşımların kullanılabilirliğini araştırmaktadır. Tahminleme modellerine odaklanan çalışma, optimizasyon problemleri için daha etkili çözümler sunmayı amaçlayan yeni bir hibrit algoritma önermektedir. Özellikle, literatürde yaygın olarak kullanılan GA, GWO ve ABC gibi algoritmalar ile ARO, WSO ve hiperparametre optimizasyonunda daha önce kullanılmamış olan FHO gibi, literatüre son yıllarda kazandırılmış algoritmaların performansı incelenmiş ve değerlendirilmiştir. Çalışma, tahmin modelleri başta olmak üzere geniş bir yelpazede uygulanabilirliği olan bir karar destek sisteminin geliştirilmesini kapsamaktadır.

Bu çalışmada, literatür detaylı bir şekilde incelenmiş ve hiperparametre optimizasyonu için yenilikçi bir hibrit metasezgisel yöntem geliştirilmiştir. Literatür incelemesi, giriş bölümündeki akışa paralel olarak üç farklı grupta gerçekleştirilmiştir. İlk grupta, tahmin çalışmalarında makine öğrenmesi algoritmalarının kullanımı ele alınmıştır. İkinci grupta, metasezgisel algoritmaların makine öğrenimi algoritmalarını optimize etmedeki rolü ve özellikle hiperparametre optimizasyonundaki etkisi incelenmiştir. Üçüncü grupta ise hibrit ve literatüre yakın zamanda kazandırılan metasezgisel algoritmaların, makine öğrenimi algoritmalarında ve hiperparametre optimizasyonundaki kullanımı detaylı bir şekilde değerlendirilmiştir.

Literatürden elde edilen bulgular doğrultusunda, ABC ve FHO algoritmalarının güçlü yönlerini birleştirerek yeni bir hibrit algoritma geliştirilmiştir. Bu hibrit algoritma, geniş arama alanlarını etkili bir şekilde keşfetme ve sömürme arasındaki dengeyi sağlama özelliklerine sahiptir.

Geliştirilen ABC-FHO algoritması, XGBoost algoritmasının hiperparametrelerini optimize etmek için üç farklı veri seti üzerinde test edilmiştir. Performansı, diğer metasezgisel algoritmalarla karşılaştırılarak, doğruluk ve güvenilirlik açısından üstünlüğü detaylı bir şekilde ortaya konulmuştur. Elde edilen sonuçlar, istatistiksel performans metrikleri ile ölçülmüş ve istatistiksel testler kullanılarak tesadüfi olmadığı doğrulanmıştır.

1.1 Literatür Özeti

Literatürdeki çalışmalar, giriş bölümündeki akışa paralel bir şekilde, üç farklı grupta incelenmiştir. İlk grupta, tahmin çalışmalarında makine öğrenmesi algoritmalarının, özellikle XGBoost algoritmasının kullanımı ele alınmıştır. İkinci grupta, metasezgisel algoritmaların makine öğrenmesi algoritmalarını optimize etmedeki rolü, özellikle hiperparametre optimizasyonundaki etkisi vurgulanmıştır. Üçüncü grupta ise, hibrit ve literatüre yakın zamanda kazandırılan metasezgisel algoritmaların, makine öğrenmesi algoritmaları ve özellikle hiperparametre optimizasyonundaki kullanımı detaylı bir şekilde incelenmiştir.

L. Guo vd. (2023), karmaşık ve doğrusal olmayan veri yapılarını tahmin etmede geleneksel yöntemlerin yetersiz kaldığını belirtmiş ve bu nedenle makine öğrenimi yöntemlerini tercih etmişlerdir. Makine öğrenimi yaklaşımları, doğrusal olmayan ve değişken fiyat yapılarını modelleme kabiliyetleri ile öne çıkmaktadır. Çalışmalarında, çeşitli makine öğrenimi algoritmalarını karşılaştırarak en uygun tahmin yöntemini belirlemişlerdir. Bu çalışma, makine öğrenimi yaklaşımlarının satış tahminlerinde sağladığı avantajları ve karar alma süreçlerini güçlendirme potansiyelini açık bir şekilde ortaya koymaktadır.

Y. Mahmoudian vd. (2023), makine öğrenimi ve derin öğrenimin hastane yatak kapasitesi tahmininde kullanımını incelemişlerdir. Çalışmalarında, hasta kalış süresi (LOS) ve hasta sayısı (NHP) gibi faktörleri analiz ederek gelecekteki kapasite ihtiyaçlarını tahmin etmişlerdir. Elde edilen sonuçlar, makine öğrenimi yöntemlerinin sağlık hizmetlerinde kaynak planlaması için güçlü bir araç olduğunu ortaya koymaktadır.

Valipour vd. (2024), Amerika Birleşik Devletleri'nin farklı iklim bölgelerinde günlük yağış tahmini için makine öğrenimi tekniklerini incelemişlerdir. Çalışmalarında, 1995-2019 yılları arasındaki veriler kullanılarak çeşitli makine öğrenimi modelleri uygulanmış ve bu modeller karşılaştırılmıştır. Elde edilen sonuçlar, makine öğrenimi yaklaşımlarının, karmaşık iklim koşullarında yağış tahmini için etkili bir araç olduğunu göstermektedir.

Malik vd. (2023) çevrimiçi girişimcilik eğitimi sırasında öğrencilerin uyum düzeyini tahmin etmek için makine öğrenimi yöntemlerini kullanmışlardır. Çalışmada, Kaggle'dan alınan bir eğitim veri seti ile RF, sınıflandırma ve regresyon

ağacı (CART), sinir ağları (NN) ve Bayes ağı (BN) gibi algoritmalar uygulanmıştır. Ayrıca, uyum tahmininde doğruluk oranını artırmak için özelleştirilmiş bir topluluk modeli (ensemble model) önerilmiştir. Bu model, öğrencilerin ihtiyaçlarını belirlemeye ve öğrencilere özelleştirilmiş destek sunmak isteyen eğitimcilere ve kurumlara etkili bir araç sunmaktadır. Sonuçlar, çevrimiçi girişimcilik eğitiminde teknolojinin etkili kullanımını destekler niteliktedir.

Von Bloh vd. (2023) Brezilya'nın soya fasülyesi hasatını tahmin etmek amacıyla makine öğrenimi modellerinin kullanımını incelemişlerdir. Çalışmada, 2001-2020 yıllarına ait iklim verileri kullanılarak Ridge regresyonu, RF, gradyan arttırma ağaçları (GBT), ANN ve LSTM gibi çeşitli modeller ile bir topluluk modeli (ensemble) uygulanmıştır. Sonuçlar, ulusal düzeyde ensemble modelin en düşük hata oranına sahip olduğunu ortaya koymuştur. Bu tahmin sistemi, özellikle sezonun sonlarına doğru artan doğruluk oranıyla, hasattan önce gıda tedarik zinciri kararlarını desteklemek için etkili bir araç sunmaktadır.

Peláez-Rodríguez vd. (2024) çalışmalarında, Madrid ve Barselona'da bisiklet paylaşımı ile Madrid teleferik yolcu akışı için talep tahmini gerçekleştirmişlerdir. Çalışmada; meteorolojik, takvimsel, geçmiş veriler ve benzer olaylar olmak üzere dört farklı tahmin girdisi ile makine öğrenimi ve derin öğrenme modelleri kurulmuştur. 12 farklı regresyon yöntemi değerlendirilmiş ve eksik veri sorunlarıyla etkili bir şekilde başa çıkılmıştır. Sonuçlar, makine öğrenimi ve derin öğrenme yöntemlerinin yeşil ulaşım sorunlarında etkili bir çözüm sunduğunu ve şehir içi hareketliliği optimize etme potansiyeline sahip olduğunu ortaya koymuştur.

Sarwar vd. (2023) , Suudi Arabistan'ın doğu bölgesinde elektrik tüketimi ve karbon emisyonu tahmini için makine öğrenimi yöntemlerini incelemişlerdir. Çalışmada, SVR ve ANN gibi makine öğrenimi yaklaşımlarının, geleneksel regresyon modellerine kıyasla doğruluk açısından üstün olduğu belirlenmiştir. Elektrik tüketimi ve karbon emisyonu tahmininde, en düşük hata oranlarıyla SVR öne çıkmıştır. Çalışma, enerji fiyatlarının artırılmasının enerji verimliliğini teşvik edebileceğini ve olumsuz çevresel etkileri azaltabileceğini vurgulamaktadır. Elde edilen sonuçlar, enerji tüketim politikalarını iyileştirmek ve sürdürülebilir büyümeyi desteklemek için önemli fikirler sunmaktadır.

Elalem vd. (2023), kısa ömürlü yeni ürünlerin satış tahminleri için bir makine öğrenimi tabanlı model önermişlerdir. Bu model, az miktarda veriyle tahmin doğruluğunu artırmak amacıyla, önceki benzer ürünlere dayalı zaman serisi kümelenmesi ve veri artırma tekniklerini kullanmaktadır. Çalışmada, ARIMAX gibi geleneksel istatistiksel yöntemler ile derin sinir ağları (DNN), LSTM, kapılı tekrarlayan ünite (GRU) ve evrişimsel sinir ağları (CNN) gibi derin öğrenme yöntemlerinin performansı karşılaştırılmıştır. Bulgular, kısa vadede ARIMAX'in daha yüksek doğruluk sağladığını, ancak DNN'lerin gürültüye karşı daha dayanıklı olduğunu ortaya koymuştur. Çalışma, özellikle kısa ömürlü yeni ürünler için makine öğrenimi tekniklerinin tahmin doğruluğunu artırma potansiyeline dikkat çekmektedir.

Rohaan vd. (2022) , B2B satış tahmini için gözetimli makine öğrenimi ve doğal dil işleme (NLP) tekniklerini uygulamışlardır. Çalışmada, yedek parça talep verileri kullanılarak tekliflerin satış olasılığı değerlendirilmiş ve satış potansiyeline göre önceliklendirme yapılmıştır. Elde edilen sonuçlar, manuel sürece kıyasla yaklaşık %155'lik bir performans artışı sağlamış ve B2B satış tahminine yapay zeka entegrasyonu için kılavuz niteliğinde bir yöntem sunmuştur.

Haselbeck vd. (2022) , bahçecilik ürünlerinin satış tahmininde makine öğrenimi yöntemlerinin geleneksel yöntemlere üstünlüğünü incelemişlerdir. Çalışmada, mevsimsellik, ani talep değişiklikleri ve dışsal faktörlerin etkilerini içeren veri setleri üzerinde dokuz makine öğrenimi yöntemi ile üç klasik tahmin yöntemi karşılaştırılmıştır. Sonuçlar, özellikle çoklu mevsimler içeren veri setlerinde makine öğrenimi yöntemlerinin üstün olduğunu göstermiştir. XGBoost, en düşük hata oranıyla öne çıkmış ve özellikle dışsal faktörlerin (örneğin hava durumu ve tatil verileri) modele eklenmesiyle, tahmin performansının arttığı tespit edilmiştir. Bu bulgular, makine öğrenimi tabanlı yöntemlerin bahçecilik sektöründe karar verme süreçlerine önemli katkılar sağlayabileceğini göstermektedir.

Abbasimehr vd. (2023), yenilenebilir enerji tüketimini tahmin etmek için XGBoost ve derin öğrenme modellerini birleştiren iki aşamalı bir yöntem önermişlerdir. İlk aşamada XGBoost, zaman serisi verilerinden elde edilen özelliklerin önemini belirlemek amacıyla kullanılmıştır. İkinci aşamada ise, bu özellikler derin öğrenme modellerine entegre edilerek tahmin doğruluğu artırılmıştır. Çalışma, XGBoost'un

özellik seçimi ve zaman serisi modellemelerinde etkili bir araç olduğunu ve tahmin performansını belirgin şekilde artırdığını ortaya koymuştur.

Dong vd. (2023), Çin'deki farklı iklim bölgelerinde günlük yağış tahmini için XGBoost modelini kullanarak sayısal hava tahmini (NWP) verilerinde sapma düzeltme çalışması yapmışlardır. Çalışmada, tekil ve çoklu meteorolojik faktörler kullanılarak yapılan tahminlerde, XGBoost'un istatistiksel yöntemlere kıyasla daha yüksek doğruluk sağladığı belirlenmiştir. Özellikle, XGBoost'un çoklu faktör düzeltmesi, kısa vadeli tahmin performansını artırarak model doğruluğunu önemli ölçüde iyileştirmiştir. Bu bulgular, XGBoost'un meteorolojik veri modelleme süreçlerinde etkili bir araç olduğunu göstermektedir.

L. Zhang vd. (2023), elektrik sistemlerinde ataleti tahmin etmek amacıyla XGBoost modelini kullanmış ve modelin açıklanabilirliğini Shapley katkı açıklamaları (SHAP) yöntemi ile analiz etmişlerdir. Çalışma, meteorolojik veriler ve enerji üretim verileri gibi özellikleri kullanarak, XGBoost'un kısa vadeli sistem ataleti tahminlerinde yüksek doğruluk sağladığını ortaya koymuştur. SHAP analizi, XGBoost'un tahmin sonuçlarının açıklanabilirliğini artırarak modelin karar verme süreçlerini anlamayı kolaylaştırmıştır. Sonuçlar, XGBoost'un enerji sistemlerinin kararlılığını sağlama ve olası riskleri önleme konusundaki potansiyelini vurgulamaktadır.

Z. Wang vd. (2024), ultraince niobyum şeritlerin mekanik özelliklerini tahmin etmek için bir XGBoost modeli geliştirmişlerdir. Çalışmada, süreç parametreleri, mikro yapı özellikleri ve mekanik özellikler arasındaki ilişkiler analiz edilerek yüksek tahmin doğruluğu sağlanmıştır. Diğer modellerle yapılan karşılaştırmalarda, XGBoost en düşük hata oranlarını ve en yüksek genel performansı göstermiştir. XGBoost ile geliştirilen bu tahmin modeli, süreç optimizasyonunda ve malzeme özelliklerinin tahmininde etkili bir araç olarak vurgulanmıştır.

Liu vd. (2024), müşteri kaybını önlemeye yönelik tahminlerde XGBoost algoritmasının kullanımını ve hiperparametre optimizasyonuyla model performansının artırılmasını incelemişlerdir. Çalışmada, XGBoost algoritması Bayes optimizasyonuyla birleştirilerek, müşteri kaybı tahminlerinde karlılık odaklı bir yaklaşım sunulmuştur. XGBoost'un sınıf ağırlıkları gibi hiperparametrelerinin

optimize edilmesiyle tahmin doğruluğu ve sonucunda karlılık artırılmıştır. Telekom, e-ticaret ve bankacılık gibi farklı sektörlerden elde edilen veriler üzerinde test edilen modelin üstün performans sağladığı görülmüştür.

F. Huber vd. (2022), uzaktan algılama verilerine dayalı tarımsal verim tahmini için XGBoost algoritmasını kullanan bir yöntem önermişlerdir. Çalışma, geleneksel istatistiksel yöntemler ve derin öğrenme modelleriyle karşılaştırıldığında, XGBoost'un üstün performans sergilediğini ortaya koymuştur. Özellikle SHAP analizi ile XGBoost'un önemli özellikleri belirleme kabiliyeti vurgulanmıştır. Bu bulgular, XGBoost'un tarımsal verim tahminlerinde güvenilir ve etkili bir araç olduğunu göstermektedir.

Literatür incelemesinin ikinci kısmında; hiperparametre optimizasyonunun, makine öğrenmesi algoritmalarının performansı üzerine etkileri ele alındıktan sonra, hiperparametre optimizasyonunda metasezgisel algoritmaların kullanımı araştırılmıştır.

Arnold vd. (2024), makine öğrenimi modellerinin performansını artırmada hiperparametre optimizasyonunun önemini vurgulamışlardır. Çalışmada, hiperparametrelerin modelin genelleme kabiliyeti üzerindeki etkileri incelenmiş ve optimizasyon süreçlerinin doğru bir şekilde gerçekleştirilmemesi durumunda hatalı sonuçlar elde edilebileceği belirtilmiştir. Hiperparametre optimizasyonunun sistematik ve şeffaf bir şekilde yapılmasının gerekliliği vurgulanmış, bu süreçte şebeke arama (grid search), rastgele arama (random search) ve Bayes optimizasyonu gibi yöntemlerin etkili olduğu ifade edilmiştir. Ayrıca, hiperparametre ayarlarının raporlanmasının, diğer araştırmacıların sonuçları çoğaltabilmesi ve güvenilirlik oluşturulması için kritik bir önem taşıdığı ortaya konulmuştur.

Probst vd. (2018), hiperparametre optimizasyonunun makine öğrenimi modelleri üzerindeki etkisini sistematik bir şekilde incelemişlerdir. Çalışma, hiperparametrelerin model performansını artırmada kritik bir rol oynadığını ve yanlış ayarlandığında tahmin doğruluğunun önemli ölçüde düşebileceğini ortaya koymuştur. Hiperparametre optimizasyonunun etkili bir şekilde gerçekleştirilmesi için teorik bir çerçeve sunan araştırma, yaygın olarak kullanılan altı farklı makine öğrenimi algoritması üzerinde büyük ölçekli bir kıyaslama çalışması yürütmüştür.

Elde edilen bulgular, optimal hiperparametrelerin seçilmesiyle model doğruluğunun artırılabileceğini ve yanlış ayarların model performansını önemli ölçüde olumsuz etkileyebileceğini göstermiştir.

Yang ve Shami (2020), makine öğrenimi modellerinde hiperparametre optimizasyonunun önemini ele almışlardır. Hiperparametrelerin doğru bir şekilde ayarlanmasının model performansını doğrudan etkilediği ve farklı veri kümeleri için farklı optimum değerlere sahip olabileceği vurgulanmıştır. Çalışmada, hiperparametre optimizasyonu için şebeke arama, rastgele arama, Bayes optimizasyonu ve metasezgisel algoritmalar gibi yöntemler tartışılmıştır. Ayrıca, hiperparametre optimizasyonunun yalnızca model performansını artırmakla kalmayıp, aynı zamanda araştırma sonuçlarının tekrarlanabilirliğini ve güvenilirliğini güçlendirdiği belirtilmiştir.

Metasezgisel algoritmalar, optimizasyon problemlerinde global çözüme ulaşmada genellikle üstün performans gösteren yöntemlerdir. Geleneksel optimizasyon yöntemlerinin yerel minimumlarda sıkışma olasılığına karşın, metasezgisel algoritmalar daha geniş bir arama alanını keşfederek global optimum çözüme ulaşabilir. Özellikle karmaşık ve gürültülü veri ortamlarında, bu algoritmaların esnekliği önemli bir avantaj sağlamaktadır. GA, ABC ve ARO gibi doğadan ilham alan yöntemler, iteratif stratejilerle çözümleri optimize eder. Bu algoritmalar, mühendislik problemleri, makine öğrenimi modellerinin hiperparametre optimizasyonu ve finansal veri analizi gibi çeşitli alanlarda kullanılmaktadır. Örneğin, ARO algoritması, doğadaki tavşanların keşif ve gizlenme davranışlarından ilham alarak tasarlanmıştır. Bu algoritma, keşif ve sömürü aşamalarını kullanarak arama alanındaki en iyi çözümü bulmayı hedefler. Metasezgisel algoritmalar, daha önce çözülmesi zor olan mühendislik ve optimizasyon problemlerine yenilikçi yaklaşımlar sunmaktadır (Gülmez, 2023).

Alhaddad vd. (2022), makine öğrenimi modellerinin Fiber Takviyeli Polimer (FRP) malzemelerinin kalite kontrolündeki rolünü ve metasezgisel optimizasyon algoritmalarının bu süreçteki etkinliğini ele almışlardır. Çalışmada, FRP'nin çekme özelliklerini tahmin etmek amacıyla bir ANN modeli geliştirilmiş ve bu model ABC algoritması ile optimize edilmiştir. Optimizasyon sonucunda, FRP'nin mekanik özelliklerinde önemli iyileştirmeler sağlanmıştır. Bu yöntem, yalnızca FRP'nin

kalitesini artırmakla kalmamış, aynı zamanda baskı ve malzeme parametrelerini optimize ederek maliyet ve zaman tasarrufu sağlamıştır.

Cui (2023), metasezgisel algoritma olarak ABC algoritmasını kullanarak bir CART modelini optimize etmiştir. Çalışmada, modelin karar düğümleri ve budama işlemleri optimize edilerek daha düşük hata oranları ve daha yüksek tahmin doğruluğu elde edilmiştir. Hiperparametre optimizasyonu sonucunda, eğitim veri setindeki hata oranı %5,19 oranında azaltılmış ve tahmin doğruluğu %99,26'ya ulaşmıştır. ABC algoritması, problem özelliklerine uygun en iyi parametre kombinasyonunu belirlemek için kullanılmış ve bu sayede modelin genel performansı önemli ölçüde artırılmıştır (Cui, 2023).

A. Mahmoudian vd. (2023), GA'dan faydalanarak dört farklı ağaç tabanlı makine öğrenimi modeli üzerinde hiperparametre optimizasyonu gerçekleştirmişlerdir. Çalışmada, GA ile optimize edilen modellerin bağ mukavemeti ve beton-cam elyaf takviyeli polimer mat ankraj arayüzündeki başarısızlık modlarını tahmin etme doğruluğu artırılmıştır. Optimizasyon süreci sonucunda, XGBoost modeli R^2 değerinde %4'lük bir artışla en iyi iyileştirmeyi sağlamıştır. Bu çalışma, hiperparametre optimizasyonunun makine öğrenimi modellerinin performansını önemli ölçüde artırabileceğini göstermektedir.

Haq vd. (2022), GA ve PSO yöntemleriyle entegre edilmiş makine öğrenimi modellerini, biyokömür verimini tahmin etmek ve iyileştirmek amacıyla geliştirmişlerdir. Çalışmada, bu yöntemler ML modellerinin mimarisini geliştirmek ve hiperparametre seçimlerini optimize etmek için kullanılmıştır. PSO destekli model, %99 R^2 (determinasyon katsayısı) ve 2.33 RMSE (kök ortalama kare hata) değerleriyle diğer modelleri geride bırakarak en yüksek doğruluk oranına ulaşmıştır. Bu bulgular, hiperparametre optimizasyonunun ve özellik seçiminin, makine öğrenimi modellerinin performansını önemli ölçüde artırabileceğini göstermektedir.

Yi vd. (2023), GA ve ANN kullanarak doğal havalandırmayı optimize etmek için bir yöntem geliştirmişlerdir. Çalışmada, GA, pencere kanadı ve duvar parametrelerini optimize ederek iç mekandaki rüzgar akışını artırmak için kullanılmıştır. Optimizasyon süreci sonucunda, iç mekan rüzgar hızında önemli bir artış elde edilmiştir. New York, Chicago ve Los Angeles'ta yapılan testler, optimize

edilmiş kanat ve duvar konfigürasyonlarının doğal havalandırmayı sırasıyla 5.8 kat, 4.9 kat ve 4.2 kat artırdığını ortaya koymuştur. Bu çalışma, GA tabanlı optimizasyonun doğal havalandırmayı artırma potansiyelini açıkça göstermektedir.

Razavi-Termeh vd. (2023), GA kullanarak iki paralel topluluk makine öğrenimi algoritması (Bagging ve Rastgele Orman) optimize etmişlerdir. Çalışmada, GA, bu algoritmaların hiperparametrelerini optimize ederek en iyi parametre kombinasyonlarını seçmiş ve sel hassasiyet haritalarının doğruluğunu artırmıştır. Optimizasyon sonucunda, Bagging-GA modeli %93.5 AUC (eğri altında kalan alan) ve en düşük RMSE değerleriyle en iyi performansı göstermiştir. Bu çalışma, metasezgisel algoritmaların makine öğrenimi modellerinin doğruluğunu artırmadaki potansiyelini açıkça ortaya koymaktadır.

Chou vd. (2022), denizanası arama (JS) algoritması ve sembiyotik organizma arama (SOS) algoritmalarını, XGBoost ile kurulan modelin hiperparametrelerini optimize etmek amacıyla kullanmışlardır. Çalışmada, yaygın olarak bilinen algoritmalar yerine nispeten yeni olan bu algoritmalar tercih edilerek, XGBoost'un doğruluk ve genelleme performansının artırılması hedeflenmiştir. JS algoritması, denizanası davranışlarından ilham alırken, SOS algoritması doğadaki simbiyotik ilişkileri temel almıştır. Her iki algoritma da keşif ve sömürü dengesini sağlayarak global optimuma ulaşmayı amaçlamıştır. Özellikle SOS-XGBoost modeli, %63.16 oranında RMSE ve %43.72 MAPE (ortalama mutlak yüzde hata) oranında iyileştirmesi ile dikkat çekmiştir.

Selcuk ve Tang (2023), metasezgisel algoritmalarla desteklenen bir ANN modelini, betonun farklı karışım tasarımlarını kullanarak basınç dayanımını tahmin etmek için optimize etmişlerdir. Çalışmada; GA, ateşböceği algoritması (FA) ve PSO gibi algoritmalar, ANN modelinin hiperparametrelerini optimize etmek amacıyla kullanılmıştır. Bu metasezgisel yaklaşımlar, modelin doğruluğunu artırmak ve farklı beton türleriyle karışım tasarımları arasındaki geniş değişkenlikleri ele almak için uygulanmıştır. Hiperparametre optimizasyonu ve boyut azaltma yöntemleriyle modelin doğruluğu önemli ölçüde artırılmıştır. Bu model, özellikle karışım tasarımı hakkında az bilgi bulunan yapılar için uygulanabilirliğiyle öne çıkmaktadır. Çalışma, metasezgisel algoritmaların beton dayanımı tahmini gibi mühendislik problemlerinde etkili bir çözüm sunduğunu ortaya koymaktadır.

Gandam vd. (2024), biyokütle ön işleme optimizasyonu için hibrit metasezgisel algoritmalar ve yapay sinir ağlarını birleştirmişlerdir. Çalışmada, sodyum bikarbonat ($NaHCO_3$) kullanılarak yapılan kimyasal ön işlem, merkezi bileşik tasarım (CCD) ile optimize edilmiş ve ardından çeşitli metasezgisel algoritmalardan faydalanarak, örneğin; öğretme-öğrenme tabanlı optimizasyon (TLBO), PSO ve GA ile ANN hiperparametre optimizasyonu gerçekleştirilmiştir. Hibrit ANN modelleri, CCD sonuçlarını doğrulamak ve biyokütle dönüşüm verimliliğini artırmak amacıyla kullanılmıştır. TLBO-ANN modeli, en yüksek doğruluğu sağlayarak CCD'den elde edilen sonuçları aşmıştır. Çalışmada, hibrit modellerin performansı TLBO > GA > PSO şeklinde sıralanmıştır. Bu sonuçlar, metasezgisel algoritmaların ANN ile entegrasyonunun biyokütle ön işlemlerini optimize etmede etkili bir yöntem olduğunu göstermektedir.

Nematzadeh vd. (2022) çalışmalarında, GA ve GWO gibi metasezgisel algoritmaları, makine öğrenimi ve derin öğrenme modellerinin hiperparametrelerini optimize etmek amacıyla kullanmışlardır. Çalışmada, biyomedikal ve biyolojik veri setleri üzerinde geniş bir uygulama yelpazesinde hiperparametre optimizasyonu gerçekleştirilmiştir. Önerilen yöntem, hiperparametrelerin daha iyi kombinasyonlarını bularak tüm denemelerde model performansını artırmıştır. Sonuçlar, GWO'nun GA'ya göre daha hızlı yakınsama sağladığını ve daha iyi sonuçlar verdiğini göstermiştir. Ayrıca, metasezgisel algoritmaların, özellikle parametre alanının geniş olduğu durumlarda daha etkili olduğunu tespit etmişlerdir.

Ben Seghier vd. (2023) çalışmalarında; PSO, karınca aslanı optimizasyonu (ALO), GWO ve harris şahin optimizasyonu (HHO) gibi metasezgisel algoritmaları, en küçük kareler destek vektör makinesi (LSSVM) modelinin hiperparametre optimizasyonu için kullanmışlardır. Çalışmada, hücresel çelik kirişlerin yan-torsiyon burkulma direncini tahmin etmek amacıyla büyük bir sonlu elemanlar yöntemi (FEM) veri seti temel alınmıştır. Hiperparametre optimizasyonu sürecinde, bu algoritmalar kullanılarak LSSVM model parametrelerinin optimal kombinasyonları bulunmuş ve deneme-yanılma yöntemine gerek kalmadan daha yüksek doğruluk elde edilmiştir. Bu yaklaşım, modelin genelleme performansını artırarak mühendislik problemlerinde daha güvenilir tahminler sağlamıştır. Çalışma, metasezgisel algoritmaların, geniş parametre alanına sahip olduğu durumlarda etkili çözümler sunduğunu vurgulamaktadır.

Ngo vd. (2022), GWO ile desteklenen ve SVR içeren hibrit bir model olan Kurt İlhamlı Algoritma (WIO)-SVR'nin, ticari olmayan binalarda enerji tüketimi tahmini üzerindeki başarısını incelemişlerdir. Önerilen model, SVR'nin hiperparametrelerini optimize etmek için GWO'nun doğadan esinlenen güçlü algoritmasını kullanmıştır. Bu yaklaşım, makine öğrenimi modellerinin performansını artırmada etkili bir yöntem sunmaktadır. Araştırma bulguları, WIO-SVR modelinin, SVR ve RF gibi geleneksel makine öğrenimi modellerine kıyasla tahmin doğruluğunu büyük ölçüde artırdığını göstermiştir. Model, RMSE ve MAE (ortalama mutlak hata) gibi hata ölçütlerinde %442 ile %1207.9 arasında iyileştirme sağlamıştır. Özellikle, enerji tüketimi verilerini işlemek için kullanılan SVR'nin performansı, GWO ile optimize edilerek büyük oranda geliştirilmiştir. Model, 12 farklı bina türünde test edilmiş ve özellikle ofis binalarında üstün performans sergilemiştir. Bu çalışma, metasezgisel algoritmaların güçlü yönlerini vurgularken, hibrit yaklaşımların karmaşık enerji tüketimi tahminlerinde daha etkili ve verimli çözümler sunabileceğini ortaya koymaktadır.

Korkmaz ve Akgüngör (2021), geleneksel algoritmalar yerine yenilikçi metasezgisel algoritmaların kullanılmasının önemini vurgulamışlardır. Bu algoritmalar, özellikle karmaşık ve çok boyutlu problemler için daha yüksek doğruluk ve performans sunmaktadır. Örneğin, çiçek tozlaşma algoritması (FPA) ve karga arama algoritması (CSA), doğrusal, üstel ve güç modellerinde diğer algoritmalara kıyasla üstün performans sergileyerek %99 doğruluk ile yolcu talebi tahmini yapabilmiştir. Nispeten yeni olan bu metasezgisel algoritmalar, literatürde yaygın olarak kullanılmakta olup ancak yavaş yakınsama veya yerel en iyi çözümlerde takılma gibi sınırlamaları olan algoritmaların bu durumunu aşmak için geliştirilmişlerdir. Bu algoritmaların hibrit yaklaşımlarla birleştirilerek daha iyi sonuçlar elde edilebilmesi, onları daha esnek ve uygulanabilir hale getirmektedir. Çalışma, FPA, ABC, CSA, kril sürüsü (KH) ve kelebek optimizasyon algoritması (BOA) gibi doğadan ilham alan algoritmaların yolcu talebi tahmininde geleneksel yöntemlere göre daha etkili olduğunu göstermiştir. Bunun yanı sıra, bu yeni algoritmaların avantajları ve zayıflıkları değerlendirilerek hava taşımacılığı talep tahmininde sağladıkları katkılar ortaya konulmuştur.

Literatür özetinin üçüncü kısmında ise; hibrit veya literatüre yakın zamanda kazandırılan metasezgisel algoritmaların, makine öğrenimi algoritmalarında ve

hiperparametre optimizasyonundaki kullanımı detaylı bir şekilde değerlendirilmiştir.

Ouhame vd. (2020), GWO ve ABC algoritmalarını birleştiren hibrit bir yöntemi, bulut bilişim ortamında kaynak tahsisini optimize etmek için uygulamışlardır. Önerilen hibrit model, GWO'nun avlanma davranışlarından türetilen keşif ve sömürü mekanizmalarını, ABC'nin yerel arama stratejileriyle birleştirerek daha dengeli bir kaynak yönetimi sağlamayı hedeflemiştir. Yerel arama süreci ve uygunluk fonksiyonundaki iyileştirmeler sayesinde, kaynak tahsisi sırasında enerji tüketimi, ağ kararlılığı ve ağ yürütme süresi optimize edilmiştir. Sonuçlar, önerilen hibrit modelin, yük dengeleme ve kaynak tahsisinde diğer modellere göre %1,25 daha verimli olduğunu ortaya koymuştur. Çalışma, metasezgisel algoritmaların ve hibrit yaklaşımların bulut bilişim gibi karmaşık ortamlardaki optimizasyon problemlerine etkili çözümler sunduğunu göstermektedir.

Davoodi vd. (2019), ABC ve GA birleşiminden oluşan hibrit bir modeli, Araç Rotalama Problemi (VRP) için uygulamışlardır. Çalışmada, ABC algoritması keşif sürecini optimize etmek için kullanılırken, GA bu çözümleri daha da iyileştirmek amacıyla modele entegre edilmiştir. Hibrit model, keşif (exploration) ve sömürü (exploitation) süreçlerini dengeli bir şekilde gerçekleştirerek rotaların toplam uzunluğunu minimize etmeyi başarmıştır. Sonuçlar, ABC algoritmasında izci arıların üretim yönteminin çözümün yakınsama hızı ve kalitesi üzerinde önemli bir etkisi olduğunu göstermiştir. Özellikle, izci arıların en yakın komşu yöntemi ile üretilmesi, GA'nın da kullanıldığı durumlarda en iyi sonuçları sağlamıştır. Ancak, rastgele yöntem kullanıldığında çözüm kalitesinde belirgin bir düşüş gözlenmiştir. Bu çalışma, hibrit metasezgisel algoritmaların optimizasyon problemlerinde etkili bir yaklaşım sunduğunu ve hiperparametre optimizasyonu gibi alanlarda geniş bir uygulama potansiyeline sahip olduğunu ortaya koymaktadır.

Lee ve Hashim (2023), ABC ve ARO algoritmalarını birleştiren hibrit bir yöntem olan Yapay Arı Tavşan Optimizasyonu (ABRO) algoritmasını önermişlerdir. ABC algoritması, keşif (exploration) aşamasında güçlü bir küresel arama yeteneği sunarken, ARO algoritması sömürü (exploitation) aşamasında yüksek hız ve etkinlik sağlamaktadır. ABRO, her iki algoritmanın güçlü yönlerini birleştirerek optimizasyon sürecinde daha yüksek hassasiyet ve hızlı yakınsama özellikleri sunmayı başarmıştır. Çalışmada kullanılan test fonksiyonları ve IEEE-26 otobüs

sistemi üzerindeki analizler, ABRO algoritmasının hem ABC'ye hem de ARO'ya kıyasla daha iyi sonuçlar verdiğini göstermiştir. Özellikle, enerji tüketimi ve maliyetlerin azaltılmasında etkili olmuş ve farklı senaryolarda üstün performans sergilemiştir. Bu bulgular, hibrit metasezgisel algoritmaların, hiperparametre optimizasyonu gibi karmaşık problemlerde güçlü bir çözüm sunduğunu ortaya koymaktadır.

Z. Makhadmeh vd. (2023), metasezgisel algoritmaların geniş çözüm uzaylarını etkili bir şekilde keşfetme ve sömürü dengesini sağlama yetenekleri sayesinde karmaşık optimizasyon problemlerini çözmek için yaygın olarak kullanıldığını vurgulamışlardır. Özellikle hibrit metasezgisel yaklaşımlar, farklı algoritmaların güçlü yönlerini birleştirerek bireysel yöntemlerin sınırlamalarını aşmayı ve optimizasyon performansını artırmayı hedeflemektedir. Çalışmada, ABC ve PSO algoritmalarını birleştiren hibrit bir yöntem kullanılmıştır. Bu yaklaşım, ABC'nin güçlü keşif yeteneklerini, PSO'nun etkili yerel arama stratejileriyle birleştirerek daha hızlı yakınsamasını ve daha başarılı sonuçlar elde etmesini sağlamıştır. Elde edilen bulgular, hibrit yöntemin yalnızca bireysel metasezgisel algoritmalardan değil, aynı zamanda diğer yöntemlerden de çözüm doğruluğu ve hesaplama verimliliği açısından üstün olduğunu ortaya koymuştur. Bu sonuçlar, karmaşık optimizasyon problemlerini çözmede hibrit yöntemlerin önemini güçlü bir şekilde vurgulamaktadır.

Fontes vd. (2023), hibrit metasezgisel algoritmaların, farklı algoritmaların güçlü yönlerini birleştirerek hiperparametre optimizasyonunda daha hızlı ve etkili çözümler sunmayı hedeflediğini vurgulamışlardır. Çalışmada, GA-PSO ve ABC-PSO gibi hibrit yaklaşımların, keşif ve sömürü arasındaki dengeyi daha iyi sağlayarak arama süreçlerini optimize ettiği belirtilmiştir. Bu hibrit yöntemler, arama uzayında daha verimli hareket ederek daha yüksek doğruluk oranları elde edilmesine olanak tanımaktadır. Bu sonuçlar, hibrit metasezgisel algoritmaların optimizasyon problemlerinde önemli bir avantaj sunduğunu ve arama süreçlerini hem hız hem de doğruluk açısından geliştirdiğini göstermektedir.

S. Makhadmeh vd. (2020), hibrit metasezgisel algoritmaların, farklı algoritmaların güçlü yönlerini birleştirerek optimizasyon problemlerinde daha etkili ve hızlı çözümler sunduğunu vurgulamışlardır. Çalışmada, GWO ve minimum çatışma algoritması birleştirilerek akıllı evlerde enerji yönetimi için hibrit bir yöntem

geliştirilmiştir. GWO, geniş arama uzayını keşfetme (exploration) kapasitesi ile öne çıkarken, minimum çatışma algoritması, yerel arama ve iyileştirme süreçlerinde çözüm kalitesini artırmıştır. Bu hibrit model, enerji maliyetlerini düşürmek, yük dengelemesi yapmak ve kaynak kullanımını optimize etmek amacıyla uygulanmıştır. Elde edilen sonuçlar, hibrit yöntemin, tek başına kullanılan metasezgisel algoritmalara kıyasla daha iyi performans gösterdiğini ve enerji yönetiminde önemli ölçüde maliyet tasarrufu sağladığını ortaya koymuştur.

H. Wang vd. (2024), güneş fotovoltaik (PV) sistemlerinin güç çıktısını tahmin etmek için yenilikçi bir hibrit optimizasyon yaklaşımı olan geliştirilmiş su aygırı optimizasyon (IHO) algoritmasını tanıtmışlardır. IHO, geleneksel su aygırı optimizasyon (HO) algoritmasındaki arama verimliliği, yakınsama hızı ve küresel keşif eksikliklerini gidermek amacıyla geliştirilmiştir. Bu algoritma, latin hiperküp örnekleme (LHS) ile başlangıç popülasyonunda çeşitliliği artırmakta, Jaya algoritması ile çözüm kalitesini iyileştirmekte ve rastgele çaprazlama ile sıralı mutasyon stratejileriyle optimizasyon sürecini hızlandırmaktadır. Araştırmada, IHO algoritması, ekstrem öğrenme makine (ELM) modelinin ağırlıklarını ve nöron eşiklerini optimize etmek için kullanılmıştır. Bu hibrit model, farklı bölgelerde test edilmiş ve tahmin doğruluğunu artırarak genelleme yeteneğini ortaya koymuştur. Sonuçlar, önerilen modelin, ELM, kedi sürüsü optimizasyonu (CSO) destekli ELM ve HO-ELM gibi diğer yöntemlere kıyasla daha üstün bir doğruluk ve stabilite sağladığını göstermiştir. IHO-ELM modeli, hata metriklerinde (MAPE, RMSE, MAE) %17,62 ile %38,5 arasında hata azaltımı sağlayarak önemli iyileştirmeler sunmuştur. Bu çalışma, literatüre yeni sunulan metasezgisel algoritmaların, özellikle yüksek doğruluk ve hızlı yakınsama gerektiren karmaşık problemlerin çözümündeki potansiyelini güçlü bir şekilde vurgulamaktadır.

Tablo 1.1, literatürde incelenen çalışmaların özetini sunmaktadır. Daha önce detaylı olarak ele alınan bu çalışmalar, yıl, konu, kullanılan yöntemler ve elde edilen bulgular açısından tablo halinde derlenmiş olup, araştırma alanındaki mevcut eğilimleri ve metodolojik yaklaşımları özet olarak inceleme imkanı sağlamaktadır.

Tablo 1.1 Literatürde incelenen çalışmaların özeti

Yazar(lar)	**Yıl**	**Konu**	**Yöntem / Algoritma**	**Bulgular**
L. Guo vd.	2023	Karmaşık, doğrusal olmayan satış tahmininde makine öğreniminin etkinliği	Farklı makine öğrenimi (ML) algoritmaları	ML yaklaşımlarının satış tahminlerinde geleneksel yöntemlere kıyasla üstün olduğu ve karar alma süreçlerini güçlendirdiği görülmüştür.
Y. Mahmoudian vd.	2023	Hastane yatak kapasitesi tahmini	Makine öğrenimi, derin öğrenme (DL)	ML ve DL yöntemlerinin, hasta sayısı ve kalış süresi gibi faktörleri analiz ederek, sağlık hizmetleri kaynak planlamasında güçlü bir araç sunduğu tespit edilmiştir.
Valipour vd.	2024	Farklı iklim bölgelerinde günlük yağış tahmini	Makine öğrenimi modelleri (çeşitli algoritmalar)	1995-2019 yıllarına ait verilerle yapılan analizde, ML yöntemlerinin karmaşık iklim koşullarında yağış tahmini için etkili bir çözüm sunduğu gösterilmiştir.
Malik vd.	2023	Çevrimiçi girişimcilik eğitimi sırasında öğrencilerin uyum düzeyi tahmini	RF, CART, NN, BN ve özel bir topluluk (ensemble) modeli	Topluluk modeli uyum tahmininde doğruluk oranını artırmış; bu yaklaşım öğrencilerin ihtiyaçlarını belirlemede ve özelleştirilmiş destek sunmada etkili olduğu gösterilmiştir.
Von Bloh vd.	2023	Brezilya'da soya fasülyesi hasat tahmini	Ridge, RF, GBT, ANN, LSTM ve topluluk (ensemble) modeli	2001-2020 verileriyle yapılan tahminlerde, ensemble modelin ulusal düzeyde en düşük hata oranına sahip olduğu ve hasattan önceki tedarik zinciri kararlarını iyileştirdiği raporlanmıştır.
Peláez-Rodríguez vd.	2024	Bisiklet paylaşımı ve teleferik yolcu akışı talep tahmini (Madrid & Barselona)	ML ve DL modelleri (12 farklı regresyon yöntemi), 4 farklı tahmin girdisi	Eksik veri sorunlarının etkili yönetimi ile makine öğrenimi ve derin öğrenmenin yeşil ulaşım sorunlarında başarılı sonuçlar verdiği tespit edilmiştir.

Tablo 1.1 Literatürde incelenen çalışmaların özeti (devamı)

Sarwar vd.	2023	Elektrik tüketimi ve karbon emisyonu tahmini (Suudi Arabistan)	SVR ve ANN	SVR'ın en düşük hata oranını sağladığı ve enerji tüketim politikalarının iyileştirilmesi ile çevresel etkilerin azaltılabileceği vurgulanmıştır.
Elalem vd.	2023	Kısa ömürlü yeni ürünlerin satış tahmini	ARIMAX, DNN, LSTM, GRU, CNN (derin öğrenme yöntemleri)	Kısa vadede ARIMAX daha yüksek doğruluk sağlarken, DNN'lerin gürültüye karşı daha dayanıklı olduğu görülmüştür. Kısa ömürlü ürünler için ML yöntemlerinin potansiyeli vurgulanmıştır.
Rohaan vd.	2022	B2B satış tahmini ve yapay zeka entegrasyonu	Gözetimli ML ve NLP (yedek parça talep verileri)	Tekliflerin satış olasılığı değerlendirilerek manuel sürece kıyasla %155 performans artışı sağlanmış; B2B satış tahmininde kapsamlı bir yapay zeka yaklaşımı sunulmuştur.
Haselbeck vd.	2022	Bahçecilik ürünlerinin satış tahmini	Dokuz ML yöntemi ile üç klasik yöntem (ör. XGBoost)	Çoklu mevsimsellik içeren veri setlerinde ML yöntemlerinin üstün olduğu, özellikle XGBoost'un ek değişkenlerle (hava durumu, tatil vb.) en iyi performansı sağladığı tespit edilmiştir.
Abbasimehr vd.	2023	Yenilenebilir enerji tüketimi tahmini	XGBoost ile Derin Öğrenme (iki aşamalı yöntem)	İlk aşamada XGBoost ile özellik önemi belirlenmiş, ikinci aşamada derin öğrenme entegrasyonu ile tahmin doğruluğunun arttığı gözlemlenmiştir.
Dong vd.	2023	Çin'de farklı iklim bölgelerinde günlük yağış tahmini	XGBoost (sayısal hava tahmini verilerinde sapma düzeltme)	Çoklu faktör düzeltmesiyle XGBoost'un istatistiksel yöntemlere kıyasla daha yüksek doğruluk sağladığı ve kısa vadeli tahmin performansını iyileştirdiği saptanmıştır.

Tablo 1.1 Literatürde incelenen çalışmaların özeti (devamı)

L. Zhang vd.	2023	Elektrik sistemlerinde atalet tahmini	XGBoost, SHAP (açıklanabilirlik analizi)	XGBoost'un kısa vadeli sistem ataleti tahminlerinde yüksek doğruluk sağladığı, SHAP ile model kararlarının açıklanabildiği belirtilmiştir.
Z. Wang vd.	2024	Ultrainces niobyum şeritlerin mekanik özelliklerini tahmin	XGBoost	XGBoost'un süreç ve mikro yapı parametrelerini değerlendirerek en düşük hata oranı ve yüksek genel performans sağladığı tespit edilmiştir.
Liu vd.	2024	Müşteri kaybını önleme tahmini	XGBoost ile Bayes optimizasyonu	Sınıf ağırlıkları gibi hiperparametrelerin optimize edilmesiyle tahmin doğruluğunun ve kârlılığın arttığı, modelin e-ticaret ve bankacılık gibi farklı sektörlerde başarılı olduğu gösterilmiştir.
F. Huber vd.	2022	Uzaktan algılama verilerine dayalı tarımsal verim tahmini	XGBoost (SHAP analizi)	Klasik istatistiksel yöntemlere ve bazı DL modellerine kıyasla XGBoost'un daha iyi performans sergilediği, SHAP ile önemli özelliklerin belirlenmesinde başarılı olduğu sonucuna ulaşılmıştır.
Arnold vd.	2024	ML modellerinin performansını artırmada hiperparametre optimizasyonu	Şebeke arama (grid search), rastgele arama, Bayes optimizasyonu	Hiperparametre optimizasyonunun modelin genelleme kabiliyeti için kritik olduğu, yanlış ayarların hatalı sonuçlar doğurabileceği vurgulanmıştır.
Probst vd.	2018	Hiperparametrelerin model performansına etkisi	Altı farklı ML algoritmasında büyük ölçekli kıyaslama	Optimal hiperparametre seçimiyle model doğruluğunun önemli ölçüde arttığı tespit edilmiştir.

Tablo 1.1 Literatürde incelenen çalışmaların özeti (devamı)

Yang ve Shami	2020	Makine öğrenimi modellerinde hiperparametre optimizasyonu	Şebeke arama, rastgele arama, Bayes optimizasyonu, metasezgisel algoritmalar	Farklı veri kümeleri için farklı optimum hiperparametre değerleri olduğu, doğru optimizasyonla performansın ve tekrarlanabilirliğin güçlendiği ifade edilmiştir.
Gülmez	2023	Metasezgisel algoritmaların karmaşık ve gürültülü veri ortamlarında avantajları	Tavşan arama (ARO) ve benzeri doğadan ilham alan yöntemler	Metasezgisel algoritmaların global optimum bulmada etkili olduğu, mühendislik ve finans gibi alanlarda zorlu optimizasyon problemlerine yenilikçi çözümler sunduğu belirtilmiştir.
Alhaddad vd.	2022	FRP malzemelerinin kalite kontrolü için ML modelleri ve metasezgisel optimizasyon	ANN ile ABC algoritması	ANN modelinin ABC ile optimize edilmesi sonucu FRP mekanik özelliklerinin iyileştirildiği, maliyet ve zaman tasarrufu sağlandığı raporlanmıştır.
Cui	2023	CART modelinin ABC algoritması ile hiperparametre optimizasyonu	CART ile ABC	ABC yardımıyla karar düğümleri ve budama süreçleri optimize edilerek hata oranı %5,19 azaltılmış, tahmin doğruluğu %99,26'ya yükselmiştir.
A. Mahmoudian vd.	2023	Bağ mukavemeti ve beton-cam elyaf takviyeli polimer ankraj başarısızlık modları tahmini	GA ile dört farklı ağaç tabanlı ML modeli (ör. XGBoost)	GA ile optimize edilen XGBoost modelinin R^2 değerinde %4'lük artış sağladığı, hiperparametre optimizasyonunun performansı önemli ölçüde iyileştirdiği gösterilmiştir.
Haq vd.	2022	Biyokömür verimini tahmin ve iyileştirme	ML modelleri ile GA ve PSO	PSO destekli model %99 R^2 ve 2.33 RMSE ile en yüksek doğruluğu elde etmiş; hiperparametre optimizasyonu ve özellik seçiminin model performansını büyük ölçüde artırdığı gözlemlenmiştir.

Tablo 1.1 Literatürde incelenen çalışmaların özeti (devamı)

Yi vd.	2023	Doğal havalandırma optimizasyonu (GA ile ANN)	GA ile ANN	GA ile pencere kanadı ve duvar parametreleri optimize edilerek iç mekandaki hava akışının 5.8 kata kadar iyileştiği; doğal havalandırma kapasitesinin artırıldığı gösterilmiştir.
Razavi-Termeh vd.	2023	Sel hassasiyet haritalaması için topluluk ML modellerinin optimizasyonu	Bagging, Rastgele Orman ile GA	GA ile optimize edilen Bagging modelinin %93.5 AUC ve en düşük RMSE'ye ulaştığı, metasezgisel algoritmaların doğruluğu artırmada etkili olduğu ortaya konmuştur.
Chou vd.	2022	XGBoost hiperparametre optimizasyonu için denizanası arama (JS) ve sembiyotik organizma arama (SOS)	JS-XGBoost, SOS-XGBoost	SOS-XGBoost, RMSE'de %63.16 ve MAPE'de %43.72 iyileşme sağlayarak doğruluk ve genelleme performansını kayda değer ölçüde artırmıştır.
Selcuk ve Tang	2023	Betonun farklı karışım tasarımlarında basınç dayanım tahmini	ANN ile GA, FA, PSO	Metasezgisel algoritmalarla optimize edilen ANN'in doğruluğunun önemli ölçüde arttığı, özellikle az veri bulunan karışım tasarımlarında etkili olduğu saptanmıştır.
Gandam vd.	2024	Biyokütle ön işleme optimizasyonu	Hibrit metasezgisel algoritmalar (TLBO, PSO, GA) ile ANN	TLBO-ANN modeli, kimyasal ön işlem verilerini en yüksek doğrulukla modellemiş; hibrit yaklaşımların biyokütle dönüşüm verimliliğini artırmada etkili olduğu görülmüştür.
Nematzadeh vd.	2022	ML ve DL modellerinde hiperparametre optimizasyonu (biyomedikal veri setleri)	GA ile GWO	GWO'nun GA'ya göre daha hızlı yakınsama ve daha iyi sonuçlar verdiği; metasezgisel algoritmaların geniş parametre alanlarında daha etkili olduğu belirtilmiştir.

Tablo 1.1 Literatürde incelenen çalışmaların özeti (devamı)

Ben Seghier vd.	2023	Hücresel çelik kirişlerin yan-torsiyon burkulma direnci tahmini	LSSVM ile PSO, ALO, GWO, HHO	Metasezgisel optimizasyon ile LSSVM parametreleri ayarlanarak daha yüksek doğruluk elde edilmiş; mühendislik problemlerinde yerel aramaya takılmadan çözüm kalitesini artırdığı ifade edilmiştir.
Ngo vd.	2022	Ticari olmayan binalarda enerji tüketimi tahmini	SVR ile Gri Kurt Optimizasyonu (GWO) (WIO-SVR)	WIO-SVR modelinin, SVR ve RF'e kıyasla RMSE ve MAE'de %442-1207.9 arasında iyileşme sağladığı; hibrit yaklaşımın özellikle ofis binalarında yüksek doğruluk sunduğu kaydedilmiştir.
Korkmaz ve Akgüngör	2021	Hava taşımacılığı yolcu talebi tahmini	Çiçek Tozlaşma Algoritması (FPA), Karga Arama (CSA), ABC, KH, BOA	Metasezgisel yöntemlerin %99'a varan doğrulukla talep tahmini yapabildiği, geleneksel yöntemlere kıyasla karmaşık problemlerde daha üstün performans sergilediği gösterilmiştir.
Ouhame vd.	2020	Bulut bilişimde kaynak tahsisi optimizasyonu	Hibrit GWO-ABC	GWO'nun avlanma davranışlarıyla ABC'nin yerel arama stratejilerini birleştirerek %1,25 daha verimli kaynak yönetimi ve yük dengelemesi sağlandığı tespit edilmiştir.
Davoodi vd.	2019	Araç Rotalama Problemi (VRP) için hibrit metasezgisel algoritma	ABC-GA	ABC'de izci arı üretim yöntemiyle GA'nın iyileştirme aşaması birleştirilerek rotaların toplam uzunluğu minimize edilmiş, yakınsama kalitesi artırılmıştır.
Lee ve Hashim	2023	Yapay Arı Tavşan Optimizasyonu (ABRO) ile enerji ve maliyet optimizasyonu (IEEE-26 test sistemi)	Hibrit ABC-ARO (ABRO)	ABRO'nun küresel arama (exploration) ve hızlandırılmış sömürü (exploitation) süreçlerini birleştirerek daha hızlı ve başarılı sonuçlanmıştır.

Tablo 1.1 Literatürde incelenen çalışmaların özeti (devamı)

Z. Makhadmeh vd.	2023	Karmaşık optimizasyon problemlerinde hibrit metasezgisel algoritmaların önemi	Hibrit ABC-PSO	ABC'nin güçlü keşif kabiliyeti ile PSO'nun etkili yerel arama stratejisi birleştirilerek çözüm doğruluğu ve hesaplama verimliliğinin arttığı; tekil algoritmalara göre üstün performans elde edildiği belirtilmiştir.
Fontes vd.	2023	Hibrit GA-PSO, ABC-PSO yaklaşımlarının hiperparametre optimizasyonundaki avantajları	GA-PSO, ABC-PSO	Hibrit yöntemlerin, arama uzayında daha verimli hareket ederek daha yüksek doğruluk oranlarına ulaştığı, özellikle büyük veri setlerinde arama sürecini hızlandırdığı görülmüştür.
S. Makhadmeh vd.	2020	Akıllı evlerde enerji yönetimi için hibrit metasezgisel algoritma	GWO-Minimum Çatışma Algoritması	GWO'nun geniş arama uzayı keşfetmesi, diğer algoritmanın yerel düzeyde iyileştirme yapmasıyla birleştirilerek enerji maliyetinde kayda değer tasarruf sağlandığı gösterilmiştir.
H. Wang vd.	2024	Güneş fotovoltaik (PV) güç çıktısı tahmini (IHO-ELM hibrit modeli)	İyileştirilmiş Su Aygırı Optimizasyonu (IHO)-ELM	LHS, Jaya ve rastgele çaprazlama stratejileriyle zenginleştirilmiş IHO'nun ELM'i optimize ederek MAPE, RMSE, MAE gibi hata ölçütlerinde %17,62 - %38,5 oranında iyileştirme sağladığı belirtilmiştir.

Yapılan kapsamlı literatür taraması, tahmin süreçlerinin karar alma mekanizmalarındaki kritik rolünü ve makine öğrenmesi algoritmalarının doğruluk üzerindeki etkisini açıkça ortaya koymaktadır. Bu algoritmalar arasında XGBoost, üstün tahmin performansı ve farklı veri setleri üzerinde sergilediği güçlü genelleme yeteneği ile öne çıkmaktadır. Çalışmalar, hiperparametre optimizasyonunun makine öğrenmesi modellerinin doğruluğunu önemli ölçüde artırabileceğini, ancak yanlış ayarlamaların model performansını ciddi şekilde olumsuz etkileyebileceğini

göstermektedir. Ayrıca literatürde, hiperparametre optimizasyonu için metasezgisel algoritmaların geniş arama alanlarında etkili çözümler sunan güçlü bir alternatif olduğu vurgulanmaktadır. Ancak, her bir metasezgisel yöntemin kendine özgü avantajları bulunmasına rağmen, hiçbir algoritma tüm problemler için en iyi çözümü garanti edememektedir. Bu durum, farklı metasezgisel algoritmaların performanslarını karşılaştırmayı ve literatürdeki mevcut eksiklikleri giderecek yeni optimizasyon yöntemleri geliştirmeyi önemli bir araştırma alanı haline getirmektedir. Bu doğrultuda, bu çalışma XGBoost'un hiperparametre optimizasyonunu iyileştirmek amacıyla yeni bir hibrit metasezgisel algoritma (ABC-FHO) geliştirerek tahmin modellerinin performansını artırmayı hedeflemektedir. Mevcut yöntemlerin sınırlılıklarını aşmayı amaçlayan bu yaklaşım, makine öğrenimi optimizasyonu alanına önemli bir katkı sağlamayı amaçlamaktadır.

2
METODOLOJİ

2.1 Makine Öğrenmesi Algoritmaları

Makine öğrenmesi, bilgisayar sistemlerinin açıkça programlanmadan, belirli görevleri yerine getirebilmesini sağlayan algoritmalar ve istatistiksel modellerle ilgilenen bir bilim dalıdır. Temel amacı, makinelerin verilerden öğrenerek kendi kendine çözüm üretebilmesidir. Günümüzde; veri madenciliği, görüntü işleme, tahmine dayalı analiz ve web arama motorları gibi geniş bir yelpazede kullanılan makine öğrenmesi, büyük veri kümelerinden anlam çıkarma ve bu verilerle otomatik olarak işlem yapma becerisi sunar (Mahesh, 2018).

Makine öğrenmesi, geçmiş örneklerden faydalanarak problemlerin çözüm kapasitesini geliştiren bir hesaplama paradigmasıdır. Bu süreçte kullanılan geçmiş örneklere "eğitim örnekleri" denir ve bu örneklerden öğrenme süreci ise "genelleştirme" olarak adlandırılır. Makine öğrenmesi, sınıflandırma, regresyon, kümeleme ve pekiştirmeli öğrenme gibi görevlerde uygulanır.

- Sınıflandırma, verileri önceden tanımlanmış kategorilere ayırma işlemidir.
- Regresyon, mevcut girdilere dayanarak sürekli değerlerin tahmin edilmesini içerir.
- Kümeleme, verileri benzerliklerine göre gruplandırmayı amaçlayan bir yöntemdir.
- Pekiştirmeli öğrenme, otonom sistemlerin karar verme süreçlerini optimize etmek için kullanılır.

Makine öğrenmesi paradigması genellikle iki temel öğrenme türüne ayrılır:

a) Denetimli öğrenme: Tüm eğitim örneklerinin etiketlendiği bir öğrenme türüdür ve genellikle sınıflandırma ve regresyon problemlerinde kullanılır.

b) Denetimsiz öğrenme: Etiketlenmemiş veriler üzerinde çalışır ve kümeleme gibi görevlerde uygulanır. Bu türde, veriler arasındaki benzerlik ölçütleri önemlidir (Jo, 2021).

Çoğu makine öğrenim modelleri parametre ve hiperparametrelere sahiptir. Model parametreleri, eğitim sırasında kendi kendine belirlenirken, hiperparametreler ise model kurulumu sırasında dışarıdan belirlenir. Birçok makine öğrenimi algoritmasında hiperparametreler varsayılan değerlerle gelir. Örneğin; XGBoost algoritmasında "gamma" bir hiperpametredir ve varsayılan değeri 0'dır. Hiperparametrelerin doğru şekilde ayarlanması, modelin performansını artırmak ve görülmemiş veriler üzerinde doğru tahminler yapmasını sağlamak için kritik öneme sahiptir (Arnold vd., 2024).

Deneysel çalışmamızda kullanılan makine öğrenim algoritması için daha detaylı anlatım bir alt başlıkta sunulmuştur.

2.1.1 Esktrem Gradyan Arttırma (XGBoost) Algoritması

XGBoost, gradyan artırma karar ağacı (GBDT) çerçevesine dayanan ve hem sınıflandırma hem de regresyon görevlerinde zayıf öğrenicileri sıralı bir şekilde güçlendirerek, hatayı minimize eden bir makine öğrenimi algoritmasıdır. Algoritmanın öne çıkan özelliklerinden biri, hedef fonksiyonuna düzenlileştirmenin dahil edilmesidir. Bu özellik, doğruluk ile model karmaşıklığını dengeleyerek aşırı öğrenmeyi etkili bir şekilde azaltır. Bu denge, XGBoost'un karmaşık doğrusal olmayan ilişkilerin bulunduğu büyük veri setleri üzerinde genelleme yapmasını sağlar. Ayrıca, hiperparametre ayarlarını optimize etme ve eksik veriyle başa çıkma yetenekleri, algoritmanın tahminleme görevlerinde üstün performans göstermesine katkıda bulunur (Abbasimehr vd., 2023).

XGBoost, karar ağaçlarını sıralı bir şekilde oluşturarak çalışır. Her bir yeni ağaç, önceki ağaçların yaptığı hataları düzeltmeye odaklanır. Bu süreç, hedef fonksiyonunu optimize etmek için hatayı minimize ederken düzenlileştirme terimlerini dahil eden gradyan artırma ile gerçekleştirilir. Spesifik olarak, algoritma negatif gradyanı (hatayı temsil eden) hesaplar ve bu hataları hedefleyen yeni ağaçlar oluşturur. Sonuç olarak, zayıf öğrenicilerden oluşan güçlü bir tahmin modeli elde edilir (Deng vd., 2022).

Diğer gradyan artırma teknikleriyle karşılaştırıldığında, XGBoost modeli şu avantajları sunar: (1) eksik değerleri işleyebilme yeteneği, (2) aşırı öğrenme riskini azaltma ve (3) paralel işlem ve dağıtık hesaplamaları destekleyerek hesaplama performansını artırma. Ayrıca XGBoost, eğitim aşamasında paralel hesaplamaları otomatik olarak gerçekleştirme kapasitesine sahiptir (Dong vd., 2023; Fan vd., 2018).

Bu algoritmaya ait amaç fonksiyonu aşağıdaki gibi ifade edilmektedir:

$$amaç = \sum_{i=1}^{m} L(y_i + \hat{y}_i) + \sum_{k=1}^{n} \Omega(f_k) \quad (2.1)$$

L, tahmin edilen $\hat{y}_i$ ile gerçek y_i değerleri arasındaki tahmin hatasını ifade etmektedir. Ω ise modelin karmaşıklığını yönetebilmek ve aşırı öğrenmeyi önlemek amacıyla hedef fonksiyonuna eklenen düzenleme ceza katsayısı iken; f_k k. ağacın fonksiyonunu temsil etmektedir.

$\hat{y}_i = \sum_{k=1}^{K} f_k(x_i) = \hat{y}_i^{(t-1)} + f_t(x_i)$ ifadesine göre, t. iterasyonda amaç fonksiyonu aşağıdaki gibi tanımlanabilir:

$$amaç = \sum_{i=1}^{n} L\left(y_i, \hat{y}_i^{(t-1)} + f_t(x_i)\right) + \sum_{k=1}^{K} \Omega(f_k) \quad (2.2)$$

Daha sonra bu denklemi optimize etmek için üç faz daha vardır. İlk aşamada, XGBoost, kayıp fonksiyonunu optimize etmek için ikinci dereceden Taylor yaklaşımını kullanır. Böylece, bir sonraki denklem şu şekilde ifade edilebilir:

$$amaç = \sum_{i=1}^{n} \left[L\left(y_i, \hat{y}_i^{(t-1)} + g_i f_t(x_i) + \frac{1}{2} h_i f_t^2(x_i)\right)\right] + \Omega(f_i) \quad (2.3)$$

Burada;

$g_i = \partial_{\hat{y}_i^{(t-1)}} l(y_i, \hat{y}_i^{(t-1)})$ kayıp fonksiyonuna ilişkin birinci dereceden gradyan istatistiğini ifade eder.

$h_i = \partial^2_{\hat{y}_i^{(t-1)}} l(y_i, \hat{y}_i^{(t-1)})$ kayıp fonksiyonuna ilişkin ikinci dereceden gradyan istatistiğini ifade eder.

Sonraki aşamada, düzenleme genişlemesi uygulanır ve sabit terimler elenerek Denklem (2.3)'ün daha basit bir formu elde edilir:

$$amaç = \sum_{i=1}^{n} \left[g_i f_t(x_i) + \frac{1}{2} h_i f_t^2(x_i)\right] + \Omega(f_t) \quad (2.4)$$

Chen ve ark. (2016) tarafından belirtildiği üzere, düzenleme terimi (Ω) için formül aşağıdaki gibidir:

$$\Omega(f) = \gamma T + \frac{1}{2}\,\lambda||\omega||^2 \tag{2.5}$$

Burada;

- γ, her eklenen yaprak için karmaşıklık maliyetini temsil eder,
- λ, düzenleme parametresini ifade eder,
- T, ağaçtaki yaprak sayısını gösterir,
- ω, yapraklarla ilişkili puan vektörünü temsil eder.

Üçüncü aşamada, birincil ve ikincil terimlerin katsayıları birleştirilir. Veri kümesi, bir yaprağın içinde aşağıdaki gibi tanımlanır.

$I_j, I_j = \{i|q(x_i) = j\}$, tanımıyla Denklem (2.4), Denklem (2.5) ve I_j kullanılarak şu şekilde ifade edilebilmektedir:

$$amaç = \sum_{i=1}^{n}\left[g_i f_t(x_i) + \frac{1}{2}h_i f_t^2(x_i)\right] + \gamma T + \frac{1}{2}\,\lambda\sum_{j=1}^{T}\omega_j^2 \tag{2.6}$$

Tüm eğitim örneklerini yaprak düğümlerine göre kategorize ettikten sonra, Denklem (2.6) aşağıdaki gibi yeniden tanımlanabilir:

$$amaç = \sum_{j=1}^{T}\left[\left(\sum_{i\in I_j} g_i\right)\omega_j + \frac{1}{2}\left(\sum_{i\in I_j} h_i + \lambda\right)\omega_j^2\right] + \gamma T \tag{2.7}$$

Burada;

- $G_j = \sum_{i\in I_j} g_i$,
- $H_j = \sum_{i\in I_j} h_i$.

Sonuç olarak amaç fonksiyonuna ait nihai çıktı aşağıdaki gibi yazılabilir;

$$amaç = \sum_{j=1}^{T}\left[G_j\omega_j + \frac{1}{2}\left(H_j + \lambda\right)\omega_j^2\right] + \gamma T \tag{2.8}$$

Bu ifadeyle, optimum hedef değer arayışı, tek bir değişkenin kuadratik bir denklemini minimize etme görevine indirgenebilir.

2.2 Metasezgisel Algoritmalar

Metasezgisel algoritmalar, geleneksel yöntemlerle çözülemeyen karmaşık problemlere, kabul edilebilir çözümler bulmak amacıyla kullanılan optimizasyon araçlarıdır. Genetik, sürü davranışı ve evrim gibi doğal olgulardan ilham alan bu algoritmalar, geniş bir arama alanında küresel optimumu bulmayı hedefler. Mühendislik, finans ve bilgisayar bilimleri gibi çok çeşitli alanlarda bu algoritmalardan faydalanılmaktadır.

Metasezgiseller, yerel arama yöntemlerini ve rastgelelik stratejilerini birleştirerek problem çözümünde esneklik sağlar. Ancak, bu yöntemlerin bir sınırı vardır: küresel optimum çözüme ulaşma garantisi sunmazlar. Bunun yerine, genellikle "yeterince iyi" çözümler bulmak üzerine çalışırlar. Bu algoritmalar, hesaplama maliyetlerini düşük tutarken geniş bir çözüm alanında etkili aramalar yapabilir. Bu nedenle, özellikle karmaşık problemlerde veya büyük veri kümelerinde başarılı sonuçlar elde etmek için faydalanılan güçlü araçlardır.

Metasezgisel algoritmalar, geleneksel matematiksel modellerden ve varsayımlardan bağımsız bir şekilde çalışarak çeşitli problemlere minimum değişiklikle uyum sağlayabilir. Bu algoritmaların öne çıkan özellikleri şunlardır (Almufti vd., 2023):

a. Keşif ve Sömürü Dengesi: Metasezgiseller, arama alanını keşfederek yeni ve daha iyi çözümler bulurken, mevcut çözümleri daha da iyileştirmek için sömürü sürecini dengeler.

b. Stokastik Arama: Rastgeleleştirme kullanarak yeni çözümler üretir ve yerel minimum tuzağından kaçınmayı sağlar.

c. İteratif İyileştirme: Çözümleri aşamalı olarak geliştirir ve mevcut çözümler üzerinde tekrar tekrar iyileştirmeler yapar.

d. Sağlamlık: Gürültülü ve belirsiz problem durumlarını yönetebilir; spesifik problem özelliklerine ve varsayımlarına bağımlılığı en aza indirir.

e. Esneklik: Farklı problem türlerine kolayca uyarlanabilir, ayrıca seçim kriterleri, komşuluk yapıları ve arama stratejileri değiştirilebilir.

f. Paralel İşleme: Arama süreci kolaylıkla paralel hale getirilerek büyük ölçekli problemlerde daha verimli bir çözüm sunar.

2.2.1 Genetik Algoritmalar (GA)

GA, doğal seçilim ve evrim prensiplerinden esinlenerek geliştirilmiş bir optimizasyon y öntemidir. İlk kez 1992'de Holland tarafından tanıtılan GA, "en uygun olanın hayatta kalması" fikrini simüle eder ve olası çözümlerden oluşan bir popülasyon üzerinde çalışır. Bu çözümler, kromozomlar olarak temsil edilir ve birkaç nesil boyunca evrim geçirerek optimal sonucu bulur. GA'nın temel süreçleri arasında kromozomların kodlanması, adayların uygunluklarına göre seçilmesi, iki ebeveyn çözümün genetik özelliklerini birleştirmek için çaprazlama yapılması ve rastgele varyasyonlar eklemek için mutasyonların uygulanması yer alır. Bu mekanizmalar, geniş çözüm alanlarını etkili bir şekilde aramayı ve küresel optimumu bulmayı mümkün kılar, bu da özellikle karmaşık optimizasyon problemleri için faydalıdır (Katoch vd., 2021). GA'ya ait sözde kod Şekil 2.1'de sunulmuştur.

1. Parametrelerin başlatılması (popülasyon boyutu, çaprazlama olasığı vb.).
2. Rastgele bir başlangıç popülasyonunun oluşturulması.
3. Uygunluk değerlerinin değerlendirilmesi.
4. Sonlandırma koşulu sağlanana kadar aşağıdaki adımları tekrarla:
    4.1. Ebeveyn seçiminin yapılması:
        - Uygunluk değerine göre ebeveyn bireyleri seç (örneğin; rulet tekerleği yöntemi)
    4.2. Çaprazlamanın uygulanması:
        - Çaprazlama olasılığına göre yeni bireylerin oluşturulması.
        - Ebeveynlerden genetik bilgileri aktar.
    4.3. Mutasyonun uygulanması:
        - Mutasyon olasılığına göre bireylerin genetik bilgilerini rastgele değiştir.
    4.4. Popülasyonu güncelle:
        -Yeni bireyleri düşük uygunluk değerine sahip bireylerin yerine yerleştir.
    4.5. En iyi çözümü kaydet:
        - Mevcut iterasyona kadar elde edilen en iyi çözümü sakla.
5. Bitiş.
        - Belirlenen durma kriteri sağlandığında işlemi durdur.

Şekil 2.1 GA sözde kodu

2.2.2 Gri Kurt Optimizasyonu (GWO)

GWO, gri kurtların sosyal hiyerarşisi ve avlanma davranışlarından esinlenmiş bir metasezgisel algoritmadır. GWO, popülasyonu alfa, beta, delta ve omega olmak üzere dört sınıfa ayırarak kurtların hiyerarşik yapısını simüle eder. Alfa kurt, sürüye liderlik ederken, beta ve delta kurtlar lideri takip eder ve optimizasyon sürecini destekler. GWO algoritmasında kurtlar, arama alanında avlarını çevreleme, yakalama ve engelleme hareketlerini simüle ederek çözüm sürecini temsil eder. GWO, keşif ve sömürü arasında bir denge kurar ve her iterasyonda kurtların konumlarını ayarlayan parametreler aracılığıyla arama alanında çözümleri etkili bir şekilde keşfetme ve iyileştirme yeteneği sağlar. Basit uygulanabilirliği, az sayıda parametreye sahip olması ve güvenilir performansı, GWO'yu mühendislik, biyoinformatik ve robotik gibi çeşitli alanlarda popüler hale getirmiştir. Gri Kurt Optimizasyonu algoritmasının çözüm adımları sırasıyla aşağıdaki gibidir (Z. Makhadmeh vd., 2023): Bu algoritmaya ait sözde kod Şekil 2.2 de sunulmuştur.

1. Rastgele bir kurt popülasyonunun (çözüm adayları) oluşturulması.
2. Uygunluk değerlerinin değerlendirilmesi ve sıralama.
    - Her bir kurt için uygunluk değerini hesapla.
    - Uygunluk değerlerine göre sırasıyla "alfa", "beta", "delta" ve "omega" olmak üzere sınıflandır.
3. Avın çevrelenmesi
    - Kurtların konumlarını hedefe yaklaşacak şekilde güncelle.
    - Rastgele katsayılar kullanarak kurtların avı çevrelemesini sağla.
4. Avın peşine düşülmesi:
    - Alfa, beta ve delta kurtlarının konumlarını referans alarak diğer kurtların pozisyonlarını güncelle.
5. Ava saldırılması (Sömürü):
6. Avın aranması (Keşif):
    - Kurtlar, belirli bir rastgelelikle avdan uzaklaşarak yeni bölgeleri keşfeder.
7. En iyi çözümün güncellenmesi:
8. Sonlandırma:
    - Durdurma kriteri sağlandığında algoritmayı durdur.
    - Aksi halde, Adım 3-7'yi tekrar et.

Şekil 2.2 GWO sözde kodu

2.2.3 Beyaz Köpek Balığı Optimizasyonu (WSO)

WSO, beyaz köpek balıklarının avlanma davranışlarından esinlenmiş bir metasezgisel algoritmadır. Algoritma, köpekbalıklarının gelişmiş duyularını kullanarak uzun mesafelerde avlarını takip etme yeteneklerini ve avlarını yakalamak için hareketlerini stratejik olarak ayarlama mekanizmalarını simüle eder. Optimizasyon sürecinde, arama ajanları (köpekbalıklarını temsil eder) optimal çözümlere doğru adaptif bir şekilde ilerlerken arama alanındaki yeni bölgeleri keşfeder ve yerel minimumlara takılmaktan kaçınır.

Keşif ve sömürü arasında bir denge kuran WSO, karmaşık optimizasyon problemlerini çözmede etkili olduğunu kanıtlamış ve hem kısıtlı hem de kısıtsız senaryolar için uygun bir algoritma haline gelmiştir. Bu dengeyi sağlayabilmesi sebebiyle, mühendislikten veri bilimine geniş bir uygulama yelpazesinde popüler olmasını sağlamıştır (Braik vd.,2022).

Beyaz köpek balıkları algoritmasının sözde kodu Şekil 2.3'deki gibidir:

1. Başlangıç:
    - Problem parametrelerini ve WSO algoritmasının parametrelerini başlat.
    - Rastgele olarak başlangıç pozisyonlarını ve hızlarını oluştur.
    - Başlangıç popülasyonun pozisyonlarını değerlendir.
2. Avın keşfi:
    - Köpek balıklarının pozisyonlarını dalgalı bir hareketle güncelle:
3. Ava saldırılması:
    - Beyaz köpek balıkları, avın kokusunu takip ederek pozisyonlarını günceller.
4. En iyi pozisyona yaklaşım:
    - En iyi köpek balığının konumuna göre hareket edilir.
    - Yeni pozisyon, en iyi çözümün yakınında hesaplanır.
5. Balık sürüsü davranışı:
    - En iyi iki çözüm korunur.
    - Diğer köpek balıkları bu çözümlere göre pozisyonlarını günceller.
6. Bitiş
    - Durdurma kriterine ulaşıldığında algoritmayı durdur.
    - En iyi çözümü döndür.

Şekil 2.3 WSO sözde kodu

2.2.4 Yapay Tavşan Optimizasyonu (ARO)

Yapay tavşan optimizasyonu (ARO), doğadan esinlenen ve tavşanların hayatta kalma stratejilerini simüle eden bir metasezgisel algoritmadır. Algoritma, tavşanların yuvalarına dönmeden önce güvenlik amacıyla farklı rotalar izleyerek yiyecek aramalarını model alır. Bu strateji, algoritmanın arama alanında çeşitliliği artırmasına ve yerel minimumlara takılmaktan kaçınmasına olanak sağlar.

ARO, keşif ve sömürü arasında dinamik bir geçiş yapar. Tavşanların enerjisinin azalmasıyla birlikte, algoritma başlangıçta keşif aşamasında daha aktifken, ilerleyen iterasyonlarda sömürü aşamasına daha fazla odaklanır. Bu strateji, algoritmanın karmaşık optimizasyon problemlerinde etkili bir performans sergilemesini sağlar (L. Wang vd., 2022).

Yapay tavşan optimizasyonun adımları aşağıda Şekil 2.4'de sunulmuştur.

1. Popülasyonun başlatılması:.
    - Rastgele olarak başlangıç pozisyonları oluşturulur.
2. Enerji faktörünün başlatılması:
    - Enerji faktörünün ($A(t)$) başlangıçta yüksek değere ayarlanması ve iterasyonlarla birlikte düşmesi.
3. Keşif ve sömürü mekanizmasının belirlenmesi:
    - Eğer A(t) > 1 : Keşif yapılır.
    - Eğer A(t) ≤ 1 : Sömürü yapılır.
4. Keşif:
    - Tavşanlar, diğer tavşanların pozisyonlarına rastgele bir şekilde yaklaşır.
    - Yerel optimadan kaçabilmek için pozisyonlara rastgele bir gürültü eklenmesi.
5. Sömürü:
    - Tavşanlar, kendi bölgelerinde rastgele bir yer seçerek saklanır.
6. Pozisyon güncellenmesi:
    - Tavşanların yeni pozisyonlarını değerlendir ve en iyi pozisyona göre güncelle.
7. Enerji faktörünün güncellenmesi:
8. Sonlandırma:
    - Maksimum iterasyon sayısına ulaşılıncaya dek yukarıdaki adımlar tekrarlanır.
    - En iyi tavşanın pozisyonunu optimum sonuç olarak döndür.

Şekil 2.4 ARO sözde kodu

2.2.5 Yapay Arı Kolonisi (ABC)

Yapay arı kolonisi (ABC) algoritması, bal arılarının besin arama davranışlarını model alan ve 2007 yılında literatüre sunulmuş, doğadan esinlenen bir optimizasyon tekniğidir. Algoritma, çalışan arılar, gözlemci arılar ve izci arılar olmak üzere üç tür arıyı içerir. Çalışan arılar, bilinen besin kaynaklarını seçerken, gözlemci arılar bu bilgilerden faydalanarak karar verir. İzci arılar ise keşfedilmemiş alanlarda yeni besin kaynakları arar (Kaya vd., 2022). Bu süreç, ABC algoritmasının keşif ve sömürü arasında etkili bir denge kurmasını sağlar. Kolayca uygulanabilirliği ve güvenilir performansı sayesinde mühendislik, telekomünikasyon ve veri madenciliği gibi birçok alanda başarıyla uygulanmıştır (Jahangir ve Eidgahee, 2020). Şekil 2.5'de ABC algoritmasının sözde kodu yer almaktadır.

1. Parametrelerin başlatılması (besin kaynaklarının sayısı, çalışan arılar, gözlemci arılar ve işçi arılar).

2. Rastgele bir başlangıç popülasyonunun oluşturulması (besin kaynakları, yani olası çözümler).

3. Her besin kaynağının uygunluk değerinin değerlendirilmesi.

4. Sonlandırma koşulu sağlanana kadar aşağıdaki adımları tekrarlayın:

   4.1 Her bir çalışan arı için:

      - İlgili besin kaynağının komşuluğunu keşfederek yeni çözümler bulun.

      - Eğer yeni çözüm mevcut çözümden daha iyiyse, eski çözümü yenisiyle değiştirin.

   4.2 Her bir besin kaynağının uygunluğuna dayalı olarak seçilme olasılığını hesaplayın.

   4.3 Her bir gözlemci arı için:

      - Uygunluk değerine göre olasılıkla bir besin kaynağı seçin.

      - Seçilen besin kaynağının komşuluğunu keşfedin.

      - Yeni bir çözüm daha iyiyse, besin kaynağını güncelleyin.

   4.4 Önceden belirlenmiş bir döngü sayısı boyunca gelişim göstermeyen besin kaynakları için:

      - Besin kaynağını terk edin.

      - İzci bir arıyı yeni bir rastgele konum keşfetmek üzere gönderin.

5. Şimdiye kadar bulunan en iyi çözümü saklayın.

6. Bitiş.

Şekil 2.5 ABC sözde kodu

2.2.6 Ateş Şahini Optimizasyonu (FHO)

Ateş şahini optimizasyonu (FHO), ateş şahinlerinin avlarını bulmak için yangın yayma davranışlarından esinlenmiş bir metasezgisel algoritmadır. Bu algoritma, avları yeni alanlara yönlendirmek için yangın çıkartarak avlanmayı temsil eder. Keşif aşaması, arama alanındaki yeni bölgelerin keşfedilmesini, sömürü aşaması ise bilinen alanlardaki avların yakalanmasını ifade eder.

FHO, avın hareketine ve bölgelerine dayalı olarak pozisyon güncellemeleri yapar, böylece yerel maksimumlarda sıkışmayı önler ve küresel optimuma verimli bir şekilde ulaşır. Algoritma, hızlı yakınsama ve güçlü arama stratejileri sayesinde mühendislik ve veri bilimi gibi birçok alanda karmaşık optimizasyon problemlerinin çözümünde etkili olduğunu kanıtlamıştır (Azizi vd., 2023). FHO algoritmasına ait sözde kod Şekil 2.6'da sunulmuştur.

1. Popülasyonu başlatın (ateş şahinleri ve avlar, yani olası çözümler).
2. Yeniden değerlendirme: Her bir av (olası çözüm) için uygunluk değerinin hesaplanması.
3. Ateş şahinlerinin ava doğru hareket etmesi:
    - Ateş şahinleri, ava doğru hareket etmesi (uygunluk değerine göre).
    - Ateş şahini daha iyi bir av bulursa, pozisyonunu yeni ava göre günceller.
4. Keşfi artırmak için diğer ateş şahinlerini gönderin:
    - En iyi avdan uzak olan ateş şahinleri, arama alanının keşfedilmemiş bölgelerine gönderilir.
    - Ateş şahinleri, yüksek potansiyele sahip alanları keşfetmek için pozisyonlarını adapte eder.
5. İzci ateş şahinlerini yeni avları keşfetmek için gönderin:
    - Ateş şahini belirli bir hareket içinde daha iyi bir av bulamazsa, yeni bir konuma yeniden konumlandırılır.
    - Yerel minimuma takılmamak için, izci ateş şahinleri, keşfedilmemiş bölgeleri keşfeder.
6. Şimdiye kadar bulunan en iyi çözümü saklayın ve ateş şahinlerinin pozisyonlarını güncelleyin.
7. Sonlandırma koşulu sağlanana kadar adımları tekrarlayın.

Şekil 2.6 FHO sözde kodu

2.2.7 ABC-FHO Hibrit Modeli

ABC ve FHO algoritmalarının hibritleştirilmesi, her iki algoritmanın tamamlayıcı güçlü yönlerini kullanarak bireysel sınırlamaların üstesinden gelmeyi amaçlamaktadır. ABC algoritması, bal arılarının besin arama davranışlarını matematiksel olarak başarılı şekilde simüle edip, küresel arama yetenekleri açısından güçlüdür. Bu özellik, arama alanında çeşitliliği artırır ve erken yakınsamayı önler, bu da FHO algoritmasının Gauss rastgeleleştirme süreci nedeniyle yerel optimumlarda takılma eğilimini etkili bir şekilde tamamlar (Lee ve Hashim, 2023).

Öte yandan, FHO algoritması, arama stratejisini dinamik olarak en iyi çözüme olan yakınlığına göre ayarlayarak daha hızlı yakınsama ve verimli yerel sömürü sağlar (Moosavi vd., 2024). Bu, ABC algoritmasının daha yavaş yakınsama ve erken duraksama eğilimlerini giderir.

Hibrit süreç, ABC algoritmasının çalışan arı fazı ile başlar; burada her bir arı (ajan), arama alanında rastgele bir şekilde yerleştirilir ve yerel komşuluğunu keşfeder. Her ajan için yeni çözüm şu denklemle oluşturulur:

$$x_{new} = x_i + \phi \,.\, (x_i - x_k) \tag{2.9}$$

burada ϕ rastgele bir pertürbasyonu ifade eder, x_i mevcut çözümü ve x_k rastgele seçilen bir komşuyu temsil eder. Bu geniş arama, yerel optimumlardan kaçınmaya yardımcı olur ancak sonraki aşamalarda daha fazla iyileştirme gerektirir. Gözlemci arı fazında, çözümler uygunluklarına dayalı olarak olasılıksal bir şekilde seçilir:

$$p_i = \frac{f(x_i)}{\sum f(x_i)} \tag{2.10}$$

Bu olasılık, her çözümün seçilme ihtimalini, tüm çözümlerin toplam uygunluğuna göre belirler. Bu, daha iyi çözümlere öncelik verirken, daha az optimal çözümlerin keşfedilmesine olanak tanıyarak arama sürecinde çeşitliliği korur.

Bu adım, daha iyi çözümlere daha fazla dikkat vererek sömürüye odaklanmayı artırır. Ancak, bu denge sağlanmazsa aşırı sömürüye yol açabilir ve bu da FHO'yu bu aşamada değerli bir tamamlayıcı haline getirir.

FHO algoritması, adaptif aramalar gerçekleştirir. Eğer bir ajan en iyi çözümden uzaksa, küresel bir arama yapar:

$$x_{new} = x_i + \alpha \,.\, (x_{best} - x_i) \tag{2.11}$$

Ajan en iyi çözüme yakınsa, daha küçük bir adım boyutuyla hassas ayar yapar:

$$x_{new} = x_i + \beta . (x_{best} - x_i) \quad (2.12)$$

Bu adaptif davranış, keşif ve sömürü arasındaki dengeyi sağlar ve ABC algoritmasının belirli bölgeleri aşırı sömürme eğilimini etkili bir şekilde giderir.

Ayrıca, ABC algoritmasının izci arı fazı, belirli bir iterasyon boyunca iyileştirme göstermeyen ajanların yerine rastgele yeni çözümler oluşturur. Bu adım, arama alanında çeşitliliği korur ve algoritmanın erken yakınsamayla alt optimal çözümlerde sıkışmasını önler.

ABC algoritmasının geniş kapsamlı keşif yetenekleri ile FHO'nun adaptif iyileştirme stratejilerinin birleşimi, hibrit yaklaşımın daha hızlı yakınsama ve yerel optimumlara takılma riskini azaltmasını sağlar. Bu, özellikle karmaşık ve dinamik arama alanları için daha güçlü ve verimli bir optimizasyon algoritması sunar. Hibrit ABC-FHO algoritmasının sözde kodu Şekil 2.7'de sunulmuştur.

1. Ajan popülasyonunu arama alanında rastgele başlatın.
2. Tüm ajanların uygunluğunu değerlendirin.
3. Maksimum iterasyonlara ulaşılana kadar aşağıdaki adımları tekrarlayın:
  3.1 ABC: İşçi arı fazı
    - Her bir ajan için:
      - Mevcut ajan pozisyonunu değiştirerek yeni bir çözüm oluşturun.
      - Eğer yeni çözüm daha iyiyse, ajan pozisyonunu güncelleyin ve deneme sayacını sıfırlayın.
      - Aksi halde, o ajan için deneme sayacını artırın.
  3.2 ABC: Gözlemci arı fazı
    - Uygunluklarına dayalı olarak ajanları olasılıksal bir şekilde seçin.
    - Çalışan arı fazında olduğu gibi yeni çözümler oluşturun.
  3.3 FHO aşaması:
    - Her ajan için:
      - En iyi çözüme olan mesafeye bağlı olarak küresel veya yerel bir arama gerçekleştirin.
      - Eğer küresel arama yapılıyorsa, arama alanında daha büyük adımlar atın.
      - Eğer yerel arama yapılıyorsa, ince ayar için daha küçük adımlar atın.
  3.4 ABC: İzci arı fazı
    - Belirli bir sayıda denemeden sonra iyileşmeyen ajanları rastgele yeni çözümlerle değiştirin.
4. En iyi çözümü ve uygunluk değerini döndürün

Şekil 2.7 ABC-FHO sözde kodu

2.3 İstatistiksel Analizler

2.3.1 Shapiro-Wilk Testi

Shapiro-Wilk testi, bir veri kümesinin normal dağılımı takip edip etmediğini değerlendirmek için yaygın olarak tercih edilen bir uygunluk testi yöntemidir. Test, sıralı örnek değerlerini, beklenen değerlerle karşılaştırarak bir istatistik hesaplar. Eğer hesaplanan istatistik, beklenen dağılımdan önemli ölçüde sapıyorsa, null hipotez (H0) reddedilir ve veri kümesinin normal dağılıma uymadığı sonucuna varılır (Shapiro ve Wilk, 1965).

Shapiro-Wilk testi, normalite durumunu test etmek için en sık başvurulan yöntemlerden biridir. Özellikle küçük örneklem boyutlarında (< 50) sağladığı yüksek test gücü sayesinde literatürde sıklıkla tercih edilmektedir (Souza vd., 2023). Çalışmamızda, normalite testi için 10 örneklem kullanılmıştır. Bu bağlamda, Shapiro-Wilk testi, küçük örneklem boyutlarında güvenilir sonuçlar sağlaması nedeniyle bu çalışmada tercih edilmiştir. Normal dağılımın yanı sıra regresyon veya ölçekleme gibi koşullar altında genişletilmiş varyasyonlarını ele almak için, Jurečková ve Picek'in 2007 yılında yaptıkları çalışmada daha detaylı bilgiler yer almaktadır.

2.3.2 Mann-Whitney U Testi

Mann-Whitney U testi, iki bağımsız grubun dağılımları arasında fark olup olmadığını belirlemek için kullanılan parametrik olmayan bir istatistiksel testtir. Genellikle, veriler normal dağılım varsayımlarını karşılamadığında t-testi yerine tercih edilir (Karuniawati vd., 2021).

Test, gruplar arasında sıraların toplamını karşılaştırır ve dağılımlar arasında önemli bir fark olup olmadığını belirler. Null hipotez (H0), gruplar arasında dağılım açısından bir fark olmadığını varsayar. Alternatif hipotez (Ha) ise dağılımların farklı olduğunu öne sürer. Bu test; biyoloji, sosyal bilimler ve tıbbi araştırmalar gibi parametrik testlerin varsayımlarının sağlanmadığı çeşitli alanlarda kullanışlıdır (MacFarland ve Yates, 2016).

2.3.3 Performans Ölçüm Metrikleri

Bu çalışmada, tahmin modellerinin doğruluğunu değerlendirmek için iki temel istatistiksel metrik kullanılmıştır: Ortalama Mutlak Yüzde Hatası (MAPE) ve Kök Ortalama Kare Hatası (RMSE). Literatürde sıkça tercih edilen bu iki metriğin birlikte kullanılması, modelin performansı hakkında kapsamlı bir fikir sağlamaktadır (X. Guo vd., 2021).

Aşağıdaki eşitliklerde; y_i gözlemlenen değerleri, $\hat{y}_i$ tahmin edilen değerleri, $\bar{y}_i$ ise gerçek değerlerin ortalamasını ifade etmektedir.

- MAPE, tahmin edilen ve gerçek değerler arasındaki ortalama yüzde hatasını hesaplayarak doğruluk için normalleştirilmiş bir ölçüm sağlar.

$$MAPE = \frac{1}{N}\sum_{i=1}^{N}\left|\frac{y(i)-\hat{y}(i)}{y(i)}\right| \times 100\% \quad (2.13)$$

- RMSE, tahmin edilen ve gözlemlenen değerler arasındaki ortalama kare farkının karekökünü ölçer. Bu metrik, daha büyük hatalara daha fazla ağırlık vererek tahmin doğruluğuna yönelik daha duyarlı bir değerlendirme sunar.

$$RMSE = \sqrt{\frac{1}{N}\sum_{i=1}^{N}(y(i) - \hat{y}(\mathrm{i}))^2} \tag{2.14}$$

Daha düşük MAPE ve RMSE değerleri, daha iyi bir model performansını ifade etmektedir. Bu metrikler, özellikle satış tahmini gibi dinamik veri yapılarına sahip uygulamalarda modelin güvenilirliğini değerlendirmek için kritik öneme sahiptir. (Tao vd., 2023; Vivas vd., 2020)

3
DENEYSEL ÇALIŞMA

Bu bölümde; GA, ARO, GWO, WSO, ABC, FHO ve hibrit ABC-FHO algoritmalarının, satış tahmini üzerindeki performansını değerlendirmek için gerçekleştirilen deneyler detaylı bir şekilde sunulmaktadır. Kapsamlı bir değerlendirme sağlamak amacıyla, algoritmalar üç farklı satış veri kümesi üzerinde test edilmiştir. Her bir veri kümesi, benzersiz satış desenlerini ve zorluklarını yansıtacak şekilde seçilmiştir. Veri kümelerinin detayları aşağıda sunulmaktadır:

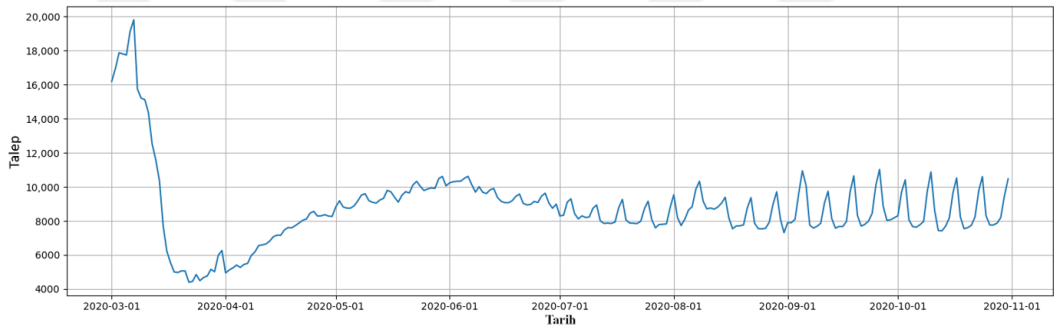

Şekil 3.1 Veri kümesi 1'e ait satış çizelgesi

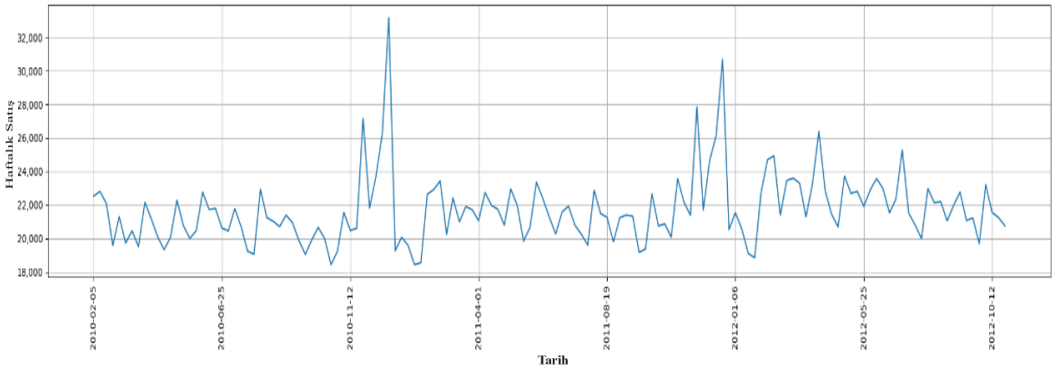

Şekil 3.2 Veri kümesi 2'ye ait satış çizelgesi

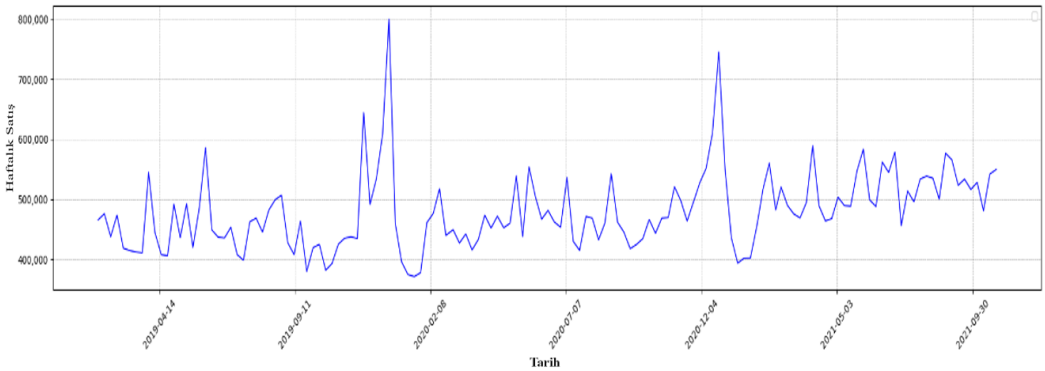

Şekil 3.3 Veri kümesi 3'e ait satış çizelgesi

Şekil 3.1, Şekil 3.2 ve Şekil 3.3, her bir veri kümesi için satış grafiklerini sunmakta olup, verilerin belirli zaman periyotlarındaki dağılımını görselleştirmektedir.

Tablo 3.1 Çalışmada kullanılan veri setlerine ait özet bilgiler

Veri kümesi	Kaynak	Örneklem sayısı	Öznitelik sayısı
Veri kümesi 1	https://github.com/ashfarhangi/COVID-19/ (erişim tarihi: 8 Ekim 2024)	30264	13
Veri kümesi 2	https://www.kaggle.com/datasets/aslanahmedov/walmart-sales-forecast (erişim tarihi: 8 Ekim 2024)	8190	12
Veri kümesi 3	https://data.world/revanthkrishnaa/amazon-uk-sales-forecasting-2018-2021/workspace/project-summary (erişim tarihi: 8 Ekim 2024)	8661	21

- Veri Kümesi 1: Bu veri kümesi, COVID-19 ile ilişkili satış verilerinden elde edilmiştir. Pandemi kaynaklı tüketici davranış değişikliklerinin neden olduğu dalgalı satış dinamiklerini yansıtmaktadır. Tarih, satışlar ve bölge gibi 13 özelliği içerir. Ek olarak, karantina önlemlerinin ve toparlanma süreçlerinin satışlar üzerindeki etkisini de yansıtmaktadır.

- Veri Kümesi 2: Bu veri kümesi, Walmart'ın birden fazla mağazası üzerinden haftalık satış verilerini içermektedir. Mağazalar, haftalık satışlar ve tatil günleri gibi özellikler içerir. Bu yapı, önerilen algoritmaların çok bölgeli perakende bağlamındaki uyarlanabilirliğini test etmek için idealdir.
- Veri Kümesi 3: Amazon firmasının Birleşik Krallık satışlarına odaklanan bu veri kümesi, 2019'dan 2021'e kadar olan dönemi kapsamaktadır. Veri kümesi; haftalık satışlar, ürün kategorisi ve promosyonel indirimler gibi 21 özelliği içerir. Zaman kapsamı, pandemi döneminde e-ticaret büyümesindeki kritik desenleri yakalamaktadır.

Bu çalışmada kullanılan veri kümeleri, Şekil 3.1, Şekil 3.2, Şekil 3.3'de gösterilmiş ve Tablo 3.1'de özetlenmiştir. Bu veri kümeleri, farklı zaman desenleri, talep dalgalanmaları ve özellik karmaşıklıklarıyla geniş bir satış dinamiği yelpazesi yakalamıştır. Bu durum, ABC-FHO modelinin farklı satış ortamlarındaki performansının titiz bir şekilde ölçülebilmesini sağlamaktadır.

3.1 Deneyin Kurulması

Çalışmamızda, tüm deneyler 16 GB RAM'e sahip ve Windows 10 çalıştıran, 3.13 GHz işlemcili bir bilgisayarda Python 3.13.1 kullanılarak gerçekleştirilmiştir. Önerilen algoritmaların performansı, Tablo 3.1'de belirtilen, açık veri setleri kullanılarak yapılan deneylerle doğrulanmıştır. Veri kümelerinin standartlaştırılması amacıyla, model eğitimi öncesinde eksik veya aykırı değerler temizlenmiş, kategorik verilere gerekli dönüşümler uygulanmış ve tüm deneylerde modellerin aynı koşullar altında çalışması sağlanmıştır. Veri kümesi, %80 eğitim ve %20 test oranında ikiye ayrılmıştır. Modelin performansını değerlendirmek için, eğitim verisi üzerinde 5 katlı çapraz doğrulama yöntemi kullanılmış, nihai performans ölçümleri ise %20'lik test verisinde gerçekleştirilmiştir. Rastgelelik etkisini azaltmak adına bu testler bağımsız olarak 10 kez tekrarlanmıştır. Deneylerin tekrarlanabilirliğini sağlamak için sabit bir 42 rastgele durum (random state) ayarı uygulanmıştır. Çalışmamızda; veri kalitesini sağlamak ve aşırı öğrenme ile veri sızıntısı gibi tahmin modelinin güvenilirliğini etkileyebilecek durumları önlemek amacıyla, veri ön işleme ve tahmin modelleri, Maharana vd. (2022)'nin çalışması gibi literatürdeki çalışmalar dikkate alınarak oluşturulmuştur. Deneye ait akış şeması Şekil 3.4'te sunulmuştur.

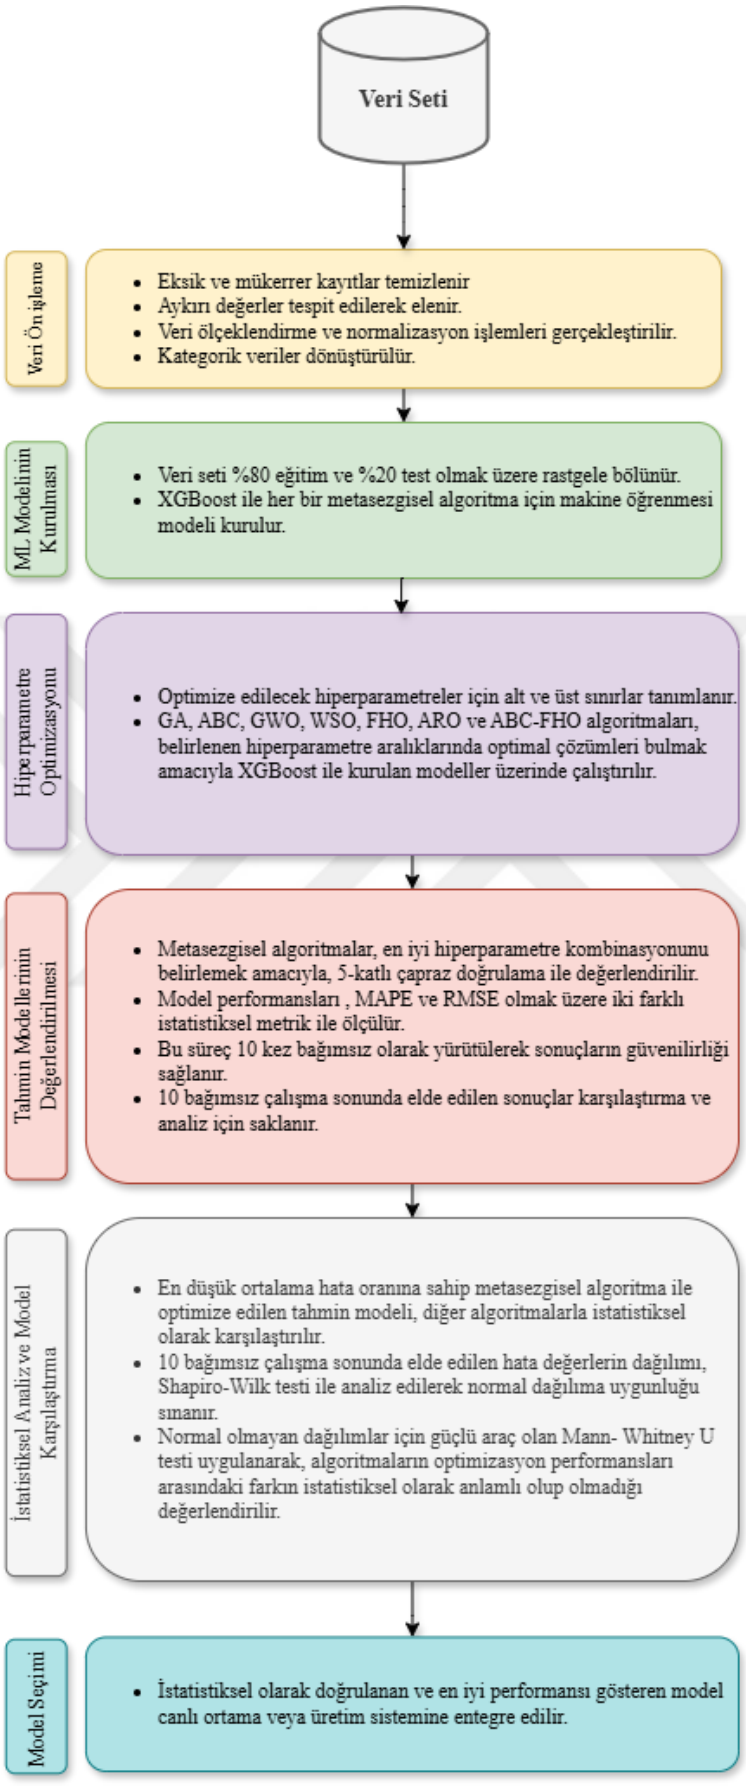

Şekil 3.4 Önerilen tahmin modeline ait akış şeması

3.2 Parametrelerin Ayarlanması

Hibrit ABC-FHO algoritması, literatürde yaygın olarak kullanılan (GA, ABC, GWO) ve son yıllarda literatüre kazandırılan (ARO, WSO, FHO) algoritmalarla karşılaştırılarak, uygulanan metasezgisel yaklaşımların hiperparametre optimizasyonundaki etkinlikleri kapsamlı bir şekilde değerlendirilmiştir. Uygulanan metasezgisel algoritmaların sahip olduğu parametreler için literatürde önerilen parametre değerleri kullanılmıştır (Azizi vd., 2023; Karaboga ve Basturk, 2007; Wang ve Ni, 2019; Braik vd., 2022). Metasezgisel algoritmalar için varsayılan veya önerilen parametre değerlerini kullanmak, kapsamlı ayarlamalara ihtiyaç duymadan güvenilir sonuçlar elde edilmesini sağladığı için, yaygın olarak başvurulan bir uygulamadır (Arcuri ve Fraser, 2023). Hibrit ABC-FHO yöntemi, hem bağımsız ABC algoritmasından hem de FHO'dan parametre ayarlarını doğal olarak devralarak, birleşik bir çerçeve içinde uyumluluk sağlamaktadır. Bağımsız ve hibrit yöntemler arasında aynı parametre değerlerinin korunması, hibritleşmenin etkisini izole ederek parametre farklılıklarından kaynaklanabilecek değişimleri önlemiştir. Tüm algoritmalara, hesaplama verimliliğini etkili performans ile dengelemek amacıyla, 10 birimlik sabit bir popülasyon boyutu ve maksimum 30 iterasyon uygulanmıştır.

Tablo 3.2, XGBoost algoritması için başlangıç hiperparametre aralığını göstermekte ve potansiyel yapılandırmaları keşfetmek için geniş bir alanı kapsamaktadır. Bu sınırlar; "colsample_bytree", "n_estimators" ve "learning_rate" gibi parametreler dahil olmak üzere, parametre ayarlarında esneklik sağlamak ve çözüm alanının kapsamlı bir şekilde aranmasını temin etmek amacıyla tasarlanmıştır. Tablo 3.3'te gösterilen XGBoost hiperparametrelerinin seçimi ve aralığı, önceki çalışmaların kapsamlı incelemesiyle belirlenmiştir (Wang ve Ni, 2019; Kapoor ve Perrone, 2021; Kavzoglu ve Teke, 2022). Bu parametreler, model performansını optimize etmek ve hesaplama verimliliğini korumak için en etkili parametreler olarak vurgulanmıştır. Ayrıca; "learning_rate", "max_depth" ve "colsample_bytree" gibi parametreler, model doğruluğunu ve genelleme yeteneğini artırmada önemli katkılar sağladığı için tercih edilmiştir. Doğal olarak büyük veya sınırsız sınırları olan hiperparametreler, aşırı uyumu önlemek ve ağaç karmaşıklığını kontrol etmek için sınırlandırılmıştır. Ek olarak, "subsample" ve "min_child_weight" gibi parametrelerin dahil edlilmesi, modele rastgelelik

eklemek ve ağaç bölme kriterlerini düzenlemek için dahil edilerek modelin dayanıklılığını artırmıştır.

Tablo 3.2 Hiperparametrelerinin alt, üst sınırları ve varsayılan değerleri

Hiperparametreler	**Alt Sınır**	**Üst Sınır**	**Varsayılan Değer**
colsample_bytree	0.1	1	1
n_estimators	30	400	100
max_depth	0	∞	6
learning_rate	0.1	1	0.3
min_child_weight	0.1	∞	1
reg_alpha	0	∞	0
reg_lambda	0	∞	1
subsample	0	1	1
num_leaves	1	∞	1

Tablo 3.3, vaka çalışmasında kullanılan hiperparametreler için arama alanını daraltarak yeniden düzenlenmiş arama aralığını göstermektedir. Bu aralık, başlangıçtaki ampirik testler ve literatürdeki çalışmalar temel alınarak seçilmiş ve yüksek olasılıkla optimal sonuçlar verecek değerlere daraltılmıştır. Bu düzenleme, hesaplama yükünü azaltırken optimizasyon sürecinin verimli ve hedef odaklı olmasını sağlayarak, kabul edilebilir zaman sınırları içinde model ayarlarının yapılmasını kolaylaştırmıştır.

Tablo 3.3 Deneysel çalışma için hiperparametrelerinin alt ve üst sınırları

Hiperparametreler	Alt Sınır	Üst Sınır
colsample_bytree	0.5	1
n_estimators	50	1000
max_depth	2	15
learning_rate	0.01	5
min_child_weight	0.001	10
reg_alpha	0	1
reg_lambda	0	1
subsample	0.5	1
num_leaves	10	900

Bu çalışmada, hibrit ABC-FHO algoritması ve diğer karşılaştırma algoritmaları kullanılarak, Tablo 3.3'te tanımlanan hiperparametreler, arama alanı uzayı taranarak optimize edilmiştir. Bu kapsamlı arama stratejisi, XGBoost modelinin tahmin doğruluğunu en üst düzeye çıkaran optimal parametre ayarlarını belirlemeyi amaçlamaktadır. Bu yapılandırma, satış tahmini doğruluğunu artırmak için hibrit ve karşılaştırma algoritmalarının, model ayarlarında gösterdiği performansının etkili bir şekilde değerlendirilmesini sağlamaktadır.

3.3 Bulgular ve Analizler

Bu alt bölümde; GA, ARO, WSO, GWO, bağımsız ABC algoritması, bağımsız FHO algoritması ve hibrit ABC-FHO algoritmasının performanslarına ait sonuçlar sunulmaktadır. Değerlendirme, daha önce belirtilen istatiksel performans ölçümleri (MAPE, RMSE) temel alınarak yapılmış ve ek olarak yakınsama davranışı, kutu grafikleri ve istatistiksel bir analiz ile desteklenmiştir.

Üç farklı veri kümesi boyunca, algoritmaların performansı Tablo 3.4, Tablo 3.5 ve Tablo 3.6'da gösterilmiştir. Her algoritma, güvenilir sonuçlar elde etmek için 10 bağımsız çalıştırma ile test edilmiştir. RMSE ve MAPE, doğruluğu değerlendirmek için temel ölçütler olarak kullanılmıştır.

Tablo 3.4'de, 10 bağımsız çalıştırma sonucunda elde edilen, her bir algoritmaya ait ortalama MAPE ve RMSE değerleri yer almaktadır.

Tablo 3.4 Ortalama MAPE ve RMSE değerleri

Veri kümesi	Metrik	GA	ARO	WSO	GWO	ABC	FHO	ABC-FHO
Veri kümesi 1	MAPE	0.057	0.053	0.052	0.055	0.051	0.053	0.049
	RMSE	624.90	602.96	580.21	601.93	559.80	607.50	532.96
Veri kümesi 2	MAPE	0.073	0.073	0.073	0.072	0.071	0.072	0.071
	RMSE	2308.38	2295.41	2302.68	2328.83	2296.83	2312.16	2279.23
Veri kümesi 3	MAPE	0.0887	0.0874	0.0871	0.0878	0.0856	0.0887	0.0855
	RMSE	58878.51	57974.10	58054.78	58578.09	56733.30	58564.27	56614.05

MAPE ve RMSE değerlerinin daha düşük olması daha iyi bir model doğruluğunu ifade eder. Hibrit ABC-FHO algoritması, tüm veri kümelerinde tutarlı bir şekilde en düşük hata ölçümlerini elde ederek üstün performans sergilemiştir. Tablo 3.4'de özetlenen, algoritmaların ortalama başarılarını gösteren sonuçlar ile alakalı daha detaylı yorumlar aşağıda yer almaktadır;

- Veri Kümesi 1: Hibrit ABC-FHO algoritması, en düşük MAPE (0.049) ve RMSE (532.96) değerlerini elde ederek diğer algoritmalardan belirgin şekilde daha iyi bir performans göstermiştir. Özellikle, GA ve GWO ile karşılaştırıldığında önemli bir fark olduğu görülmüştür.

- Veri Kümesi 2: Hibrit ABC-FHO algoritması, hata değerlerinin diğer algoritma hata değerlerine nispeten daha yakın olmasına rağmen, küçük bir avantaj sağlamış ve 0.071 MAPE ve 2279.23 RMSE değerleriyle başarılı bir performans sergilemiştir.

- Veri Kümesi 3: Hibrit ABC-FHO algoritması, en düşük MAPE (0.0855) ve RMSE (56614.05) değerlerini elde ederek üstün performans sergilediğini bu veri kümesinde de göstermiştir.

Tablo 3.5, her bir algoritma için, MAPE ölçütü kullanılarak, elde edilen en iyi ve en kötü değerleri göstermektedir. Bu analiz, algoritmaların performans tutarlılıkları hakkında önemli bilgiler sunmaktadır.

Tablo 3.5 En iyi ve en kötü MAPE değerleri

Veri kümesi		Metrik	GA	ARO	WSO	GWO	ABC	FHO	ABC-FHO
Veri kümesi 1	En iyi	MAPE	0.052	0.047	0.045	0.046	0.047	0.049	0.046
	En kötü	MAPE	0.060	0.060	0.059	0.065	0.056	0.063	0.053
Veri kümesi 2	En iyi	MAPE	0.072	0.071	0.070	0.070	0.070	0.070	0.068
	En kötü	MAPE	0.075	0.077	0.075	0.077	0.073	0.074	0.074
Veri kümesi 3	En iyi	MAPE	0.0968	0.0975	0.0908	0.0943	0.0958	0.0929	0.0920
	En kötü	MAPE	0.1048	0.1045	0.1061	0.1043	0.1000	0.1028	0.0985

Elde edilen MAPE değerleri, her algoritmanın performansını ve değişkenliğini daha ayrıntılı bir şekilde değerlendirmeye olanak tanır. En iyi MAPE değerleri, algoritmaların doğruluk ve dayanıklılık açısından yüksek performans tutarlılığını vurgular. Örneğin; veri kümesi 1 incelendiğinde; WSO algoritması en iyi MAPE (0.045) skorunu yakalamasına karşın, fazlaca dalgalanma göstererek en kötü MAPE (0.059) skorunu da vermiştir. ABC-FHO algoritması ise tüm veri kümelerinde en az dalgalanmayı gösteren algoritmadır.

Tablo 3.6 ise, RMSE ölçütü ile elde edilen, en iyi ve en kötü değerleri karşılaştırmalı olarak göstermektedir. Bu analiz, algoritmaların performanslarının farklı bir istatistiksel metrik ile de değerlendirilmesini ve daha güvenilir yorum yapabilme fırsatını sunmuştur.

Tablo 3.6 En iyi ve en kötü RMSE değerleri

Veri kümesi		Metrik	GA	ARO	WSO	GWO	ABC	FHO	ABC-FHO
Veri kümesi 1	En iyi	RMSE	527.4	484.9	540.5	470.0	482.1	485.1	475.1
	En kötü	RMSE	714.91	716.40	692.78	724.93	689.39	663.79	638.41
Veri kümesi 2	En iyi	RMSE	2246.1	2249.8	2222.7	2283.3	2280.8	2263.6	2267.2
	En kötü	RMSE	2414.2	2338.4	2356.4	2368.9	2323.9	2384.9	2295.4
Veri kümesi 3	En iyi	RMSE	56740.1	55407.8	56378.2	56323.6	54457.2	57468.1	54375.3
	En kötü	RMSE	61537.1	58974.6	60597.3	61244.5	57925.9	61815.3	58751.6

Elde edilen RMSE değerleri, algoritmaların en yüksek tahmin doğruluğunu ve değişkenliğini yansıtır. RMSE değerlerinin düşük olması, algoritmanın tutarlılığını ve istikrarını göstermektedir. MAPE skorlarına benzer olarak, WSO algoritması kimi veri kümelerinde en başarılı skorlara ulaşabilmiş ancak aynı zamanda en kötü skorları da vererek, yüksek dalgalanmaları bu metrikte de göstermiştir. ABC-FHO algoritması ise tüm veri kümelerinde istikrarlı değerler sunmuştur.

Şekil 3.5 MAPE ve Şekil 3.6 RMSE değerlerinin dağılımını göstermekte olup, bunlar veri kümesi 1, veri kümesi 2 ve veri kümesi 3 için detaylı olarak analiz edilmiştir. Bu dağılımlar, algoritmaların hata ölçütlerine göre performans varyasyonlarının görselleştirilmesidir.

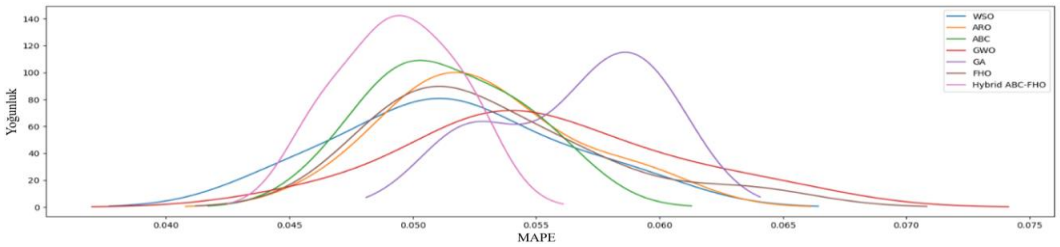

(a) Veri kümesi 1

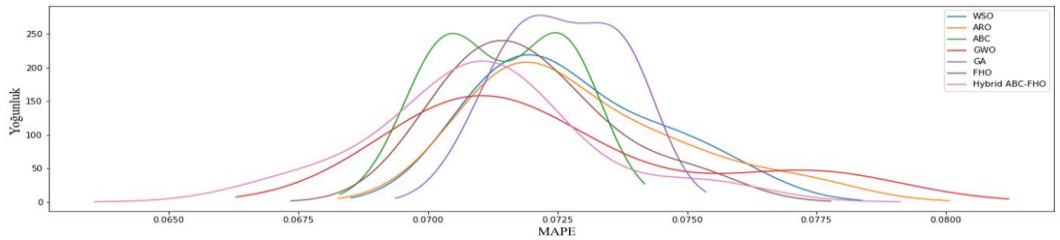

(b) Veri kümesi 2

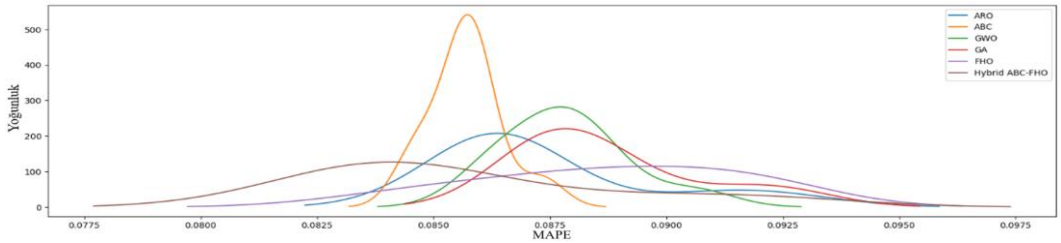

(c) Veri kümesi 3

Şekil 3.5 MAPE değerinin iterasyonlar boyunca dağılım grafikleri

Şekil 3.5'te gösterildiği gibi, hibrit ABC-FHO algoritması, diğer algoritmalara kıyasla daha dar ve daha yoğun dağılımlar sergileyerek, tüm veri kümelerinde tutarlı bir doğruluk ve minimum varyasyon sağlamıştır . Bu durum özellikle veri kümesi 1'de belirgindir; burada ABC-FHO algoritmasının yoğunluk eğrisi, daha düşük MAPE değerleri etrafında sıkıca toplanmıştır ve bu da yüksek bir stabilite ve güvenilirlik göstergesidir. Veri kümesi 2 ve veri kümesi 3 benzer bir eğilim göstermiştir. Ancak veri kümesi karmaşıklığı nedeniyle genel dağılımın daha geniş olduğu görülmüştür.

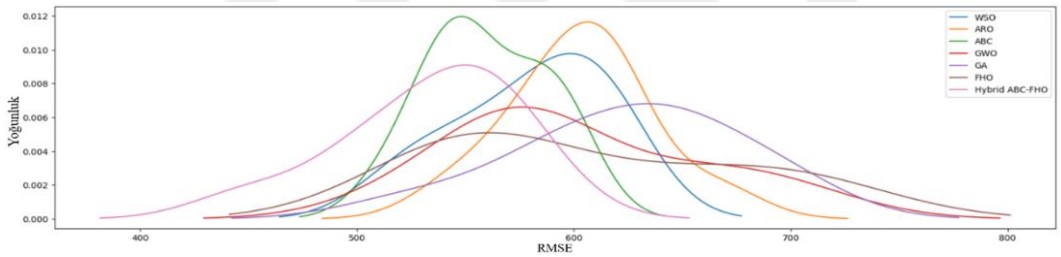

(a) Veri kümesi 1

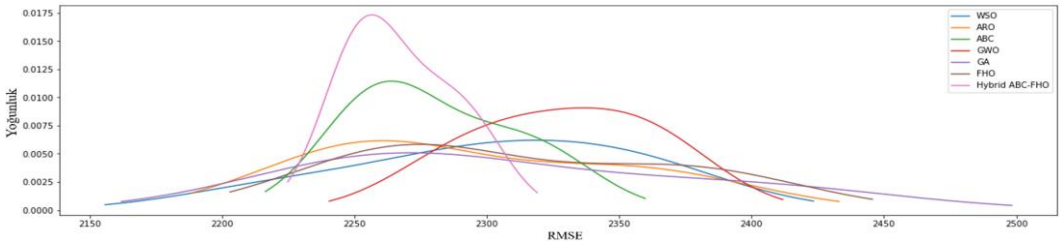

(b) Veri kümesi 2

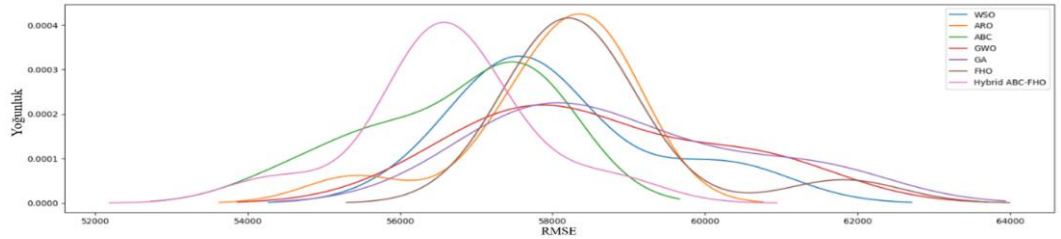

(c) Veri kümesi 3

Şekil 3.6 RMSE değerinin iterasyonlar boyunca dağılım grafikleri

Şekil 3.6 bu gözlemleri daha da destekler niteliktedir. ABC-FHO algoritması, tüm veri kümeleri arasında en dar dağılımı sergilemiştir. Özellikle veri kümesi 1'de görüldüğü gibi sürekli düşük RMSE değerleri elde edilmiştir. ABC-FHO algoritması veri kümesi 2 ve veri kümesi 3'te, karşılaştırmalı olarak istikrarlı bir performans göstermeye devam etmiştir. Ayrıca veri karakteristiklerindeki değişimlere rağmen, doğru tahminler elde etme konusunda esnekliğini ve güvenilirliğini kanıtlamıştır.

Diğer algoritmaların performansı incelendiğinde, her yöntemin veri kümeleri arasında kendine özgü güçlü ve zayıf yönler sergilediği görülmektedir. GA, güvenilir bir performans sunmasına rağmen, daha karmaşık senaryolarda yavaş yakınsama hızı ve yüksek varyans gibi sınırlamalar göstermiştir. ARO, küçük veri kümelerinde rekabetçi bir performans sergilemiş ancak farklı veri karmaşıklıkları karşısında dayanıklılık açısından yetersiz kalmıştır. Benzer şekilde, WSO tutarlı bir doğruluk sağlamış olsa da, hibrit ABC-FHO ile kıyaslandığında yakınsama hızı ve hata minimizasyonu konularında geride kalmıştır. GWO ise orta boyutlu veri kümelerinde etkili bir performans sergilemiş, ancak genel stabilite ve hassasiyet açısından hibrit yaklaşımın gerisinde kalmıştır. Bağımsız ABC algoritması, optimizasyon problemlerini verimli bir şekilde çözme kabiliyetini göstermiş ancak hibrit ABC-FHO'nun sunduğu hassasiyet ve stabilite düzeyine ulaşamamıştır. FHO ise umut vadeden sonuçlar elde etmiş olmasına rağmen, başlangıç koşullarına duyarlılığı nedeniyle zaman zaman performans değişkenliği göstermiştir.

Bu bulgular, bireysel algoritmaların değerli sonuçlar sunduğunu, ancak hibrit ABC-FHO'nun doğruluk, stabilite ve dayanıklılık açısından tüm veri kümelerinde üstün performans sergileyerek öne çıktığını göstermektedir. Tahmin modellerindeki küçük bir iyileştirmenin dahi süreçlere önemli katkılar sağladığı unutulmamalıdır. Bu durum, özellikle büyük ölçekli organizasyonel yapıya sahip kurumlar için kritik bir avantaj sağlamaktadır.

Şekil 3.7 ve Şekil 3.8, her algoritma için, 3 farklı veri kümesinde 10 iterasyon sonucunda elde edilen MAPE ve RMSE değerlerinin, kutu grafikleri ile temsili gösterilmektedir. Bu grafikler, her bir algoritmanın doğruluğu ve kararlılığı hakkında önemli bilgiler sağlamaktadır. Daha dar çeyrekler arası aralıklara ve daha az uç değere sahip algoritmalar, daha tutarlı bir performans sergilemiştir. Buna

karşılık, daha geniş dağılımlar ve daha fazla uç değer, daha yüksek bir değişkenlik göstermektedir.

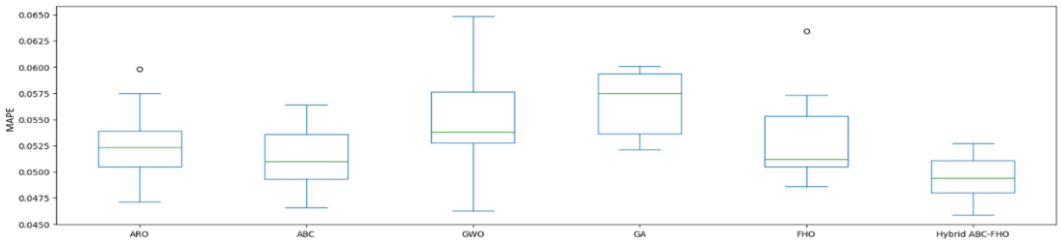

(a) Veri kümesi 1

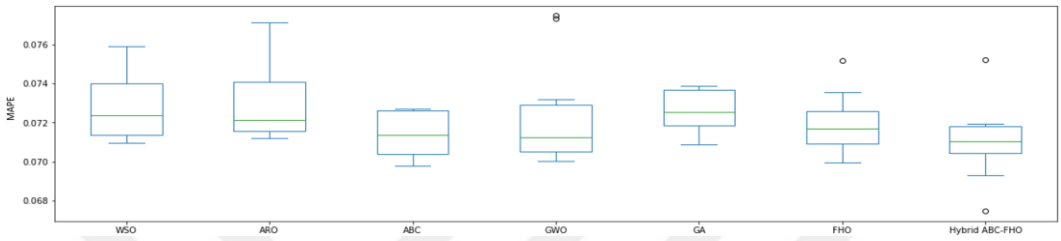

(b) Veri kümesi 2

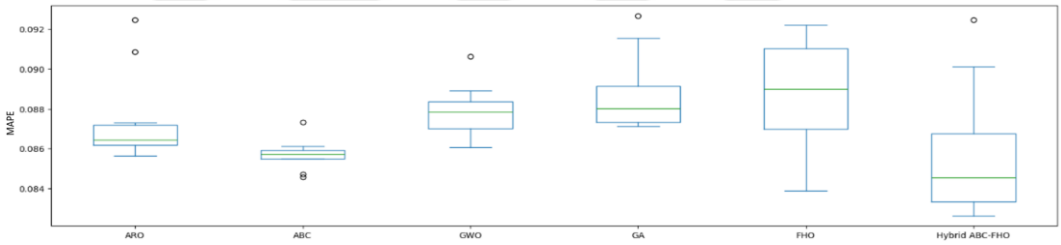

(c) Veri kümesi 3

Şekil 3.7 MAPE değerinin iterasyonlar boyunca kutu grafikleri

Kutu grafikleri, her algoritmanın performansındaki dalgalanmaları vurgulayarak, veri karakteristiklerine ve başlangıç koşullarına duyarlılığın farklılıklarını ortaya koymaktadır. MAPE ve RMSE değerlerindeki bu değişim, her algoritmanın farklı satış tahmini senaryolarında sağlamlık ve güvenilirlik seviyesini yansıtmaktadır.

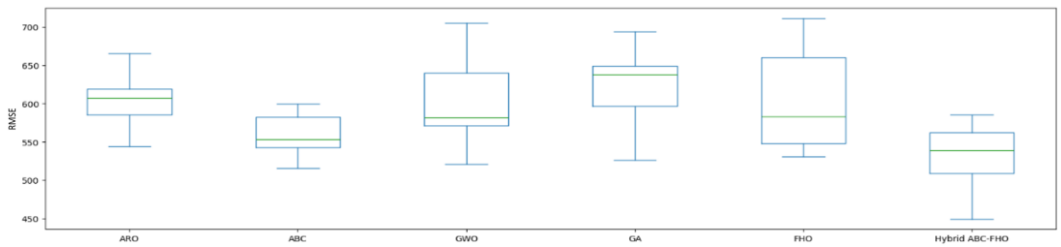

(a) Veri kümesi 1

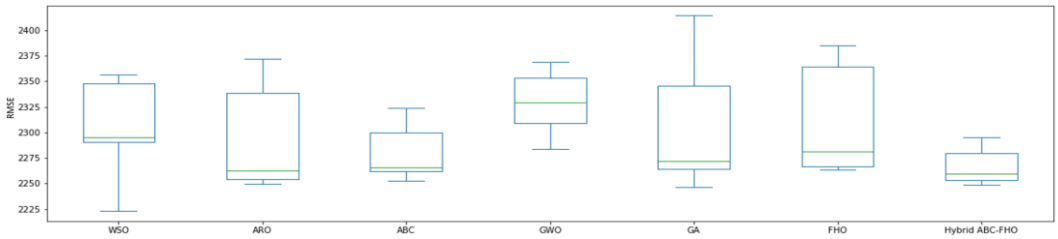

(b) Veri kümesi 2

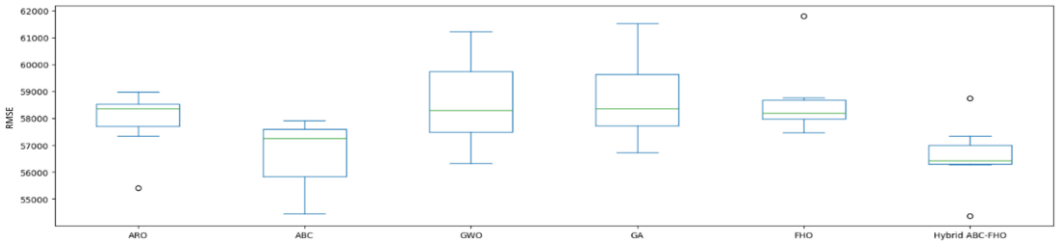

(c) Veri kümesi 3

Şekil 3.8 RMSE değerinin iterasyonlar boyunca kutu grafikleri

Daha dar çeyrekler arası aralıklara ve daha az uç değere sahip algoritmalar, daha büyük bir tutarlılık sergilemiştir. Özellikle, hibrit ABC-FHO algoritması, MAPE ve RMSE değerlerinde daha dar yayılma ve daha az uç değerlerle tüm veri kümelerinde güvenilir ve kararlı bir performans göstermiştir. Bu tutarlılık, ABC-FHO algoritmasının veri değişkenliğine ve başlangıç koşullarına daha az duyarlı olduğunu göstermiş ve onu çeşitli tahmin senaryoları için güvenilir bir seçim haline getirmiştir.

Tablo 3.7 Algoritmalara ait ortalama çalışma süreleri

Veri Kümesi	GA	ARO	WSO	GWO	ABC	FHO	ABC-FHO
Veri Kümesi 1	15.882	16.677	15.275	11.694	21.536	17.110	23.442
Veri Kümesi 2	45.413	48.612	45.193	48.987	60.380	41.552	68.350
Veri Kümesi 3	18.190	18.068	17.379	16.512	20.440	16.256	22.130

Tablo 3.7, her algoritmanın 3 veri kümesindeki tahmin görevlerini tamamlamak için ihtiyaç duyduğu ortalama süreyi (saniye cinsinden) göstermektedir. Hibrit ABC-FHO algoritması, özellikle veri kümesi 2 için, bağımsız yaklaşımlara kıyasla daha uzun hesaplama süreleri sergilemiştir. GWO algoritması, tüm veri kümeleri

arasında en hızlı algoritmalardan biri olmuş ve hesaplama verimliliğinin kritik olduğu senaryolar için uygun bir seçenek olduğu görülmüştür.

Hibrit ABC-FHO algoritmasının stabilitesini ve üstünlüğünü doğrulamak için titiz bir istatistiksel analiz gerçekleştirilmiştir. ABC-FHO algoritması dahil olmak üzere tüm algoritmalar, 10 ajan ve 30 iterasyon içeren tutarlı bir yapılandırma altında, 10 kez bağımsız olarak tekrar edilerek çalıştırılmıştır. Bu yapılandırma, birden fazla veri kümesi boyunca MAPE ve RMSE gibi güvenilir performans metriklerinin toplanmasını sağlamıştır. Bu tekrarlar, performans farklarının değişkenliğini ve istatistiksel anlamlılığını değerlendirmek için temel oluşturmuştur.

Öncelikle, Shapiro-Wilk testi, her algoritma için MAPE ve RMSE değerlerinin dağılımlarının normal dağılıma uyup uymadığını incelemek için uygulanmıştır. Bu test için sıfır hipotezi, verilerin normal dağıldığını belirtmiştir. Ancak sonuçlar, tüm veri kümelerinde normal olmayan dağılımlar olduğunu göstermiştir. Bu durum, daha ileri analizler için parametrik olmayan bir testin kullanılmasını gerektirmiştir. Bu adım, sonraki istatistiksel yöntemlerin uygunluğunu sağlamak için kritik öneme sahiptir.

ABC-FHO algoritmasının performansını diğer algoritmalarla karşılaştırmak için parametrik olmayan istatistiksel yöntemlerden Mann–Whitney U testi kullanılmıştır. Bu testin sıfır hipotezi, ABC-FHO algoritmasının performansı ile diğer algoritmaların performansları arasında anlamlı bir fark olmadığını varsaymıştır. Sıfır hipotezinin reddedilmesi, gözlemlenen farkların istatistiksel olarak anlamlı olduğunu ve rastgele varyasyondan kaynaklanmadığını gösterir. Mann–Whitney U testi, hem MAPE hem de RMSE ile ölçülen çıktılara uygulanarak, algoritma performansının kapsamlı bir şekilde değerlendirilmiştir.

Tablo 3.8'de sunulan Mann–Whitney U testi sonuçları, ABC-FHO algoritmasını değerlendirmek üzere kurulan sıfır hipotezinin, veri kümelerinde değerlendirilen algoritmaların ekseriyeti için reddedildiğini göstermektedir. Bu, ABC-FHO algoritmasının MAPE ve RMSE değerlerindeki performans iyileştirmelerinin diğer algoritmalara kıyasla istatistiksel olarak anlamlı olduğunu göstermektedir. Bulgular, hibrit ABC-FHO algoritmasının diğer karşılaştırma algoritmalarını sürekli olarak geride bıraktığını, ayrıca sağlamlık ve etkinlik açısından güçlü istatistiksel kanıtlar sağladığını ortaya koymaktadır.

Shapiro–Wilk ve Mann–Whitney U testlerinin sonuçlarını birleştirerek yapılan analiz, ABC-FHO algoritmasının başarısının tesadüfi olmadığını kesin bir şekilde doğrulamaktadır.

Üç farklı satış veri kümesi üzerinde gerçekleştirdiğimiz deneylerde, hibrit ABC-FHO algoritması; GA, ARO, WSO, ABC algoritmaları ve FHO gibi metasezgisel algoritmaları sürekli olarak geride bırakmıştır. Ayrıca bu çalışmada, FHO'nun hiperparametre optimizasyonunda bağımsız bir yöntem olarak ilk kez uygulanmış olması dikkat çekici bir noktadır ve bu algoritma başarılı bir performans sergilemiştir. Bulgularımızın güvenilirliğini sağlamak için çapraz doğrulama kullanılmış ve her model 10 kez çalıştırılmıştır. Akabinde sonuçların ortalaması alınarak analiz edilmiş ve istatistiksel testler uygulanmıştır.

Tablo 3.8 H0 hipotezinin p-value değerlerine göre sonuçları

Veri kümesi	Algoritma	Hipotez (MAPE)	Hipotez (RMSE)
Veri kümesi 1	GA	Reddedildi	Reddedildi
	ARO	Reddedildi	Reddedildi
	WSO	Reddedildi	Reddedildi
	GWO	Reddedildi	Reddedildi
	ABC	Reddedildi	Reddedilmedi
	FHO	Reddedildi	Reddedildi
Veri kümesi 2	GA	Reddedildi	Reddedildi
	ARO	Reddedildi	Reddedildi
	WSO	Reddedildi	Reddedildi
	GWO	Reddedilmedi	Reddedildi
	ABC	Reddedilmedi	Reddedildi
	FHO	Reddedildi	Reddedildi
Veri kümesi 3	GA	Reddedildi	Reddedildi
	ARO	Reddedildi	Reddedildi
	WSO	Reddedildi	Reddedildi
	GWO	Reddedildi	Reddedildi
	ABC	Reddedildi	Reddedildi
	FHO	Reddedildi	Reddedildi

Yapılan testler, hibrit yaklaşımın sağladığı performans iyileştirmelerinin istatistiksel olarak anlamlı olduğunu doğrulamıştır. Hibrit model tahmin doğruluğunda üstün performans sergilemiştir. Ancak, önerilen model diğer algoritmalarla karşılaştırıldığında, en uzun hesaplama süresine sahip olduğu tespit edilmiştir. Buna karşılık, bağımsız GWO algoritması, hesaplama verimliliği açısından en hızlı algoritma olmuştur.

4
SONUÇ

Bu çalışma, literatüre ABC-FHO adlı yeni bir metasezgisel algoritma kazandırarak, çeşitli metasezgisel algoritmalar ile birlikte yeni algoritmanın, makine öğrenimi modellerinin hiperparametre optimizasyonunda uygulanarak etkinliğini incelemiştir. Çalışmada vurgulanan satış tahmini; operasyonel verimliliği artırma, stok yönetimi ve gelir optimizasyonu gibi stratejik karar alma süreçlerinde önemli bir rol oynamaktadır. ABC-FHO algoritması; GA, ARO, WSO, GWO, ABC ve FHO gibi algoritmalar ile karşılaştırıldığında, MAPE ve RMSE gibi temel ölçütlerde tutarlı bir şekilde üstün performans göstermiştir. Ayrıca elde edilen sonuçların tesadüfi olmadığı istatistiksel testler ile de kanıtlanmıştır. Bu başarı, ABC-FHO algoritmasının karmaşık, doğrusal olmayan, farklı özelliklere ve veri hacimlerine sahip veri kümelerini, etkili bir şekilde optimize edebilme yeteneğini ortaya koymaktadır.

ABC-FHO algoritması, keşif ve sömürü arasında etkili bir denge kurarak, ABC ve FHO algoritmalarının güçlü yönlerini bir araya getirmiştir. Bu sinerji, yüksek boyutlu hiperparametre arama alanlarında daha düşük hata oranlarıyla daha verimli sonuçlar elde etmeyi mümkün kılmıştır. Daha düşük MAPE ve RMSE değerleri elde ederek, ABC-FHO algoritması, veri desenleri ve tahmin gereksinimlerinin çeşitlilik gösterdiği gerçek dünyadaki uygulamalar için uygun olduğunu kanıtlamıştır.

Bununla birlikte, bu çalışma, doğruluk ve hesaplama verimliliği arasında bir ödüne işaret etmektedir. ABC-FHO algoritması, en iyi tahmini doğruluğu sunarken, GWO gibi diğer algoritmalara nazaran daha fazla hesaplama süresine ihtiyaç duymuştur. Bu durum, ABC-FHO algoritmasının uzun vadeli tahminler veya doğruluğun öncelikli olduğu görevler için ideal olduğunu, ancak gerçek zamanlı veya yüksek öncelikli karar alma süreçlerinde, algoritmanın hesaplama süresinin göz önünde bulundurulmasının gerektiği sonucunu doğurmuştur. Özellikle büyük veri kümeleri veya hızlı yanıt gerektiren uygulamalarda, işlem süresinin optimize edilmesi

algoritmanın daha geniş bir kullanım alanına sahip olmasını sağlayabilir. Hesaplama süresi konusundaki bu sınırlama, algoritmanın etkinliğini artırmak için yapılacak gelecekteki çalışmalara önemli bir yönlendirme sunmaktadır.

Gelecekteki çalışmalar, paralel hesaplama teknikleri veya adaptif stratejiler keşfederek, hesaplama süresini kısaltıp algoritmanın daha geniş bir uygulama yelpazesi için daha pratik hale getirilmesine odaklanabilir. Özellikle paralel işleme yeteneklerinden yararlanarak algoritmanın hızlandırılması, büyük veri kümeleriyle çalışan sistemler için önemli bir avantaj sağlayacaktır. Bunun yanı sıra, daha dinamik keşif ve sömürü stratejilerinin geliştirilmesi, ABC-FHO algoritmasının farklı veri yapıları üzerinde daha verimli çalışmasına olanak tanıyabilir. Bu tür optimizasyonlar, algoritmanın yalnızca doğruluk açısından değil, hesaplama verimliliği açısından da daha rekabetçi hale gelmesini sağlayacaktır.

ABC-FHO algoritmasının potansiyelini daha da geliştirmek için, gelecekteki araştırmalar bu yöntemin farklı sektörlerdeki veri setleri üzerindeki performansını inceleyerek genelleştirilebilirliğini doğrulayabilir. Bu kapsamda, finans, sağlık, üretim ve enerji gibi çeşitli alanlarda gerçekleştirilecek çalışmalar, algoritmanın farklı veri desenleri ve problem türleri karşısındaki uyumunu değerlendirme fırsatı sunacaktır. Böylece, ABC-FHO'nun geniş bir optimizasyon aracı olarak uygulanabilirliği daha kapsamlı bir şekilde ortaya konabilir.

Sonuç olarak, hibrit ABC-FHO algoritması, satış tahmini için hiperparametre optimizasyonunda başarılı bir çözüm sunmakta, tahmin doğruluğu ile hesaplama talepleri arasında etkili bir denge kurmaktadır. Bu çalışma, karmaşık tahmin görevlerinde hibrit ve yeni algoritmaların önemini vurgulamaktadır. Ayrıca, ABC-FHO algoritmasının performansı, farklı veri setleri ve sektörler üzerinde uygulanabilir olduğunu desteklemektedir. Bu yöntem, endüstrilerin karmaşık veri desenleri ve operasyonel gereksinimlerine uyum sağlayarak tahmin yeteneklerini arttırmaları için umut verici bir yaklaşım sunmaktadır.

KAYNAKÇA

Abbasimehr, H., Paki, R., & Bahrini, A. (2023). A novel XGBoost-based featurization approach to forecast renewable energy consumption with deep learning models. Sustainable Computing: Informatics and Systems, 38, 100863. https://doi.org/10.1016/j.suscom.2023.100863

Abd Elaziz, M., Hosseinzadeh, M., & Elsheikh, A. H. (2023). A novel hybrid of Fire Hawk Optimizer and Artificial Rabbits Optimization for complex optimization problems. Journal of Intelligent & Fuzzy Systems, 36(2), 125-139. https://doi.org/10.3233/JIFS-219090

Alhaddad, W., He, M., Halabi, Y., & Almajhali, K. Y. M. (2022). Optimizing the material and printing parameters of the additively manufactured fiber-reinforced polymer composites using an artificial neural network model and artificial bee colony algorithm. Structures, 46, 1781-1795. https://doi.org/10.1016/j.istruc.2022.10.134

Almufti, S. M., Shaban, A. A., Ali, Z. A., Ali, R. I., & Dela Fuente, J. A. (2023). Overview of Metaheuristic Algorithms. Polaris Global Journal of Scholarly Research and Trends, 2(2), 10–32. https://doi.org/10.58429/pgjsrt.v2n2a144

Al-Shourbaji, I., Hassan, M. M., & Mohamed, M. A. (2022). Hybrid ant colony optimization and reptile search algorithm for solving complex optimization problems. Expert Systems with Applications, 192, 116331. https://doi.org/10.1016/j.eswa.2022.116331

Arcuri, A.; Fraser, G. Parameter tuning or default values? An empirical investigation in search-based software engineering. Empir. Softw. Eng. 2023, 18, 594–623. https://doi.org/10.1007/s10664-013-9249-9.

Arnold, C.; Biedebach, L.; Küpfer, A.; Neunhoeffer, M. The role of hyperparameters in machine learning models and how to tune them. Political Sci. Res. Methods 2024, 12, 841–848. https://doi.org/10.1017/psrm.2023.61.

Azizi, M.; Talatahari, S.; Gandomi, A.H. Fire Hawk Optimizer: A novel metaheuristic algorithm. Artif. Intell. Rev. 2023, 56, 287–363. https://doi.org/10.1007/s10462-022-10173-w.

Ben Jabeur, H., Bouzidi, M., & Malek, J. (2024). XGBoost outperforms traditional machine learning models in retail demand forecasting. Journal of Retailing and Consumer Services, 67, 102859. https://doi.org/10.1016/j.jretconser.2024.102859

Ben Seghier, M. E. A., Carvalho, H., de Faria, C. C., Correia, J. A. F. O., & Fakury, R. H. (2023). Numerical analysis and prediction of lateral-torsional buckling resistance of cellular steel beams using FEM and least square support vector machine optimized by metaheuristic algorithms. Alexandria Engineering Journal, 67(1), 489–502. https://doi.org/10.1016/j.aej.2022.12.062

Braik, M., Awadallah, M. A., & Mousa, A. (2022). White Shark Optimizer: A novel meta-heuristic algorithm for global optimization problems. Applied Soft Computing, 110, 107625. https://doi.org/10.1016/j.asoc.2021.107625

Choi, Y.; Seo, S.; Lee, J.; Kim, T.W.; Koo, C. A machine learning-based forecasting model for personal maximum allowable exposure time under extremely hot environments. Sustain. Cities Soc. 2024, 101, 105140. https://doi.org/10.1016/j.scs.2023.105140.

Chou, J.-S., Liu, C.-Y., Prayogo, H., Khasani, R. R., Gho, D., & Lalitan, G. G. (2022). Predicting nominal shear capacity of reinforced concrete wall in building by metaheuristics-optimized machine learning. Journal of Building Engineering, 61, 105046. https://doi.org/10.1016/j.jobe.2022.105046

Cui, Y. (2023). Optimizing decision trees for English Teaching Quality Evaluation (ETQE) using Artificial Bee Colony (ABC) optimization. Heliyon, 9(e19274). https://doi.org/10.1016/j.heliyon.2023.e19274

Çetinbaş, M., Özcan, E., & Bayramoğlu, S. (2023). Hybrid White Shark Optimizer and Artificial Rabbits Optimization for photovoltaic parameter extraction. Renewable Energy, 180, 1236-1249. https://doi.org/10.1016/j.renene.2022.10.034

Davoodi, M., Malekpour Golsefidi, M., & Mesgari, M. S. (2019). A hybrid optimization method for vehicle routing problem using artificial bee colony and genetic algorithm. International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, XLII-4/W18, 293–297. https://doi.org/10.5194/isprs-archives-XLII-4-W18-293-2019

Deng, Y., Zhang, J., & Liu, F. (2022). A hybrid model of XGBoost and LSTM for electricity load forecasting. Journal of Energy Storage, 46, 103568. https://doi.org/10.1016/j.est.2021.103568

Dhake, P. S., Patil, A. D., & Desai, R. R. (2023). Genetic algorithm for optimizing hyperparameters in LSTM-based solar energy forecasting. Renewable Energy, 198, 75-84. https://doi.org/10.1016/j.renene.2022.08.003

Dong, J., Zeng, W., Wu, L., Huang, J., Gaiser, T., & Srivastava, A. K. (2023). Enhancing short-term forecasting of daily precipitation using numerical weather prediction bias correcting with XGBoost in different regions of China. Engineering Applications of Artificial Intelligence, 117, 105579. https://doi.org/10.1016/j.engappai.2022.105579

Elalem, Y. K., Maier, S., & Seifert, R. W. (2023). A machine learning-based framework for forecasting sales of new products with short life cycles using deep neural networks. International Journal of Forecasting, 39(6), 1874-1894. https://doi.org/10.1016/j.ijforecast.2022.09.005

Fan, J., Wang, X., Wu, L., Zhou, H., Zhang, F., Yu, X., ... & Xiang, Y. (2018). Comparison of Support Vector Machine and Extreme Gradient Boosting for predicting daily global solar radiation using temperature and precipitation in humid subtropical climates: A case study in China. Energy conversion and management, 164, 102-111.

Fontes, D. B. M. M., Homayouni, S. M., & Gonçalves, J. F. (2023). A hybrid particle swarm optimization and simulated annealing algorithm for the job shop

scheduling problem with transport resources. European Journal of Operational Research, 306, 1140–1157. https://doi.org/10.1016/j.ejor.2022.09.006

Gandam, P. K., Chinta, M. L., Gandham, A. P., Pabbathi, N. P., Velidandi, A., Prabhu, A. A., & Baadhe, R. R. (2024). Integrated multi-objective optimization of sodium bicarbonate pretreatment for the outer anatomical portion of corncob using central composite design, artificial neural networks, and metaheuristic algorithms. Industrial Crops and Products, 207, 117717. https://doi.org/10.1016/j.indcrop.2023.117717

Guo, L., Huang, X., Li, Y., & Li, H. (2023). Forecasting crude oil futures price using machine learning methods: Evidence from China. Energy Economics, 127, 107089. https://doi.org/10.1016/j.eneco.2023.107089

Guo, X., Gao, Y., Li, Y., Zheng, D., & Shan, D. (2021). Short-term household load forecasting based on Long-and Short-term Time-series network. Energy Reports, 7, 58-64.

Gülmez, B. (2023). Stock price prediction with optimized deep LSTM network with artificial rabbits optimization algorithm. Expert Systems with Applications, 227, 120346. https://doi.org/10.1016/j.eswa.2023.120346

Haq, Z. U., Ullah, H., Khan, M. N. A., Naqvi, S. R., & Amin, N. A. S. (2022). Comparative study of machine learning methods integrated with genetic algorithm and particle swarm optimization for biochar yield prediction. Bioresource Technology, 363, 128008. https://doi.org/10.1016/j.biortech.2022.128008

Haselbeck, F., Killinger, J., Menrad, K., Hannus, T., & Grimm, D. G. (2022). Machine learning outperforms classical forecasting on horticultural sales predictions. Machine Learning with Applications, 7, 100239. https://doi.org/10.1016/j.mlwa.2021.100239

Holland, J.H. Adaptation in Natural and Artificial Systems: An Introductory Analysis with Applications to Biology, Control, and Artificial Intelligence, 2nd ed.; MIT Press: Cambridge, MA, USA, 1992.

Huber, F., Yushchenko, A., Stratmann, B., & Steinhage, V. (2022). Extreme Gradient Boosting for yield estimation compared with Deep Learning approaches. Computers and Electronics in Agriculture, 202, 107346. https://doi.org/10.1016/j.compag.2022.107346

Huber, J., & Stuckenschmidt, H. (2020). Advances in seasonal and promotional sales forecasting using machine learning models. Journal of Business Research, 117, 452-461. https://doi.org/10.1016/j.jbusres.2020.05.004

Jabeur, S. B., Mefteh-Wali, S., & Viviani, J. L. (2024). Forecasting gold price with the XGBoost algorithm and SHAP interaction values. Annals of Operations Research, 334(1), 679-699. https://doi.org/10.1007/s10479-021-04187-w

Jahangir, H.; Eidgahe, D.R. A new and robust hybrid artificial bee colony algorithm—ANN model for FRP-concrete bond strength evaluation. Constr. Build. Mater. 2020, 264, 113160. https://doi.org/10.1016/j.conbuildmat.2020.113160.

Jain, E., & Singh, A. (2024). Optimizing gradient boosting algorithms for obesity risk prediction: A comparative analysis of XGBoost, LightGBM, and CatBoost

models. International Conference on Cybernation and Computation (CYBERCOM), Dehradun, India, 2024, pp. 320-324, doi: 10.1109/CYBERCOM63683.2024.10803186.

Jo, T. (2021). Machine learning foundations. Machine Learning Foundations. Springer Nature Switzerland AG. https://doi. org/10.1007/978-3-030-65900-4.

Jurečková; J; Picek, J. Robust Statistical Methods with R; Springer: Berlin/Heidelberg, Germany, 2007. https://doi.org/10.1007/978-0-387-68887-2.

Kapoor, S.; Perrone, V. A simple and fast baseline for tuning large XGBoost models. arXiv 2021, arXiv:2111.06924. https://doi.org/10.48550/arXiv.2111.06924.

Karaboga, D.; Basturk, B. A powerful and efficient algorithm for numerical function optimization: Artificial bee colony (ABC) algorithm. J. Glob. Optim. 2007, 39, 459–471. https://doi.org/10.1007/s10898-007-9149-x.

Karuniawati, H., Hassali, M. A. A., Suryawati, S., Ismail, W. I., Taufik, T., & Hossain, M. S. (2021). Assessment of Knowledge, Attitude, and Practice of Antibiotic Use among the Population of Boyolali, Indonesia: A Cross-Sectional Study. International Journal of Environmental Research and Public Health, 18(16), 8258. https://doi.org/10.3390/ijerph18168258

Katoch, S., Chauhan, S. S., & Kumar, V. (2021). A review on genetic algorithm: Past, present, and future. Multimedia Tools and Applications, 80(5), 8091-8126. https://doi.org/10.1007/s11042-020-10139-6

Kavzoglu, T.; Teke, A. Advanced hyperparameter optimization for improved spatial prediction of shallow landslides using extreme gradient boosting (XGBoost). Bull. Eng. Geol. Environ. 2022, 81. https://doi.org/10.1007/s10064-022-02708-w.

Kaya, M., Karaboga, D., & Basturk, B. (2022). A comprehensive review of artificial bee colony algorithm variants and their applications. Swarm and Evolutionary Computation, 72, 101069. https://doi.org/10.1016/j.swevo.2022.101069

Korkmaz, E., & Akgüngör, A. P. (2021). The forecasting of air transport passenger demands in Turkey by using novel meta-heuristic algorithms. Concurrency and Computation: Practice and Experience, 33(16), e6263. https://doi.org/10.1002/cpe.6263

Lee, W. W., & Hashim, M. R. (2023). A hybrid algorithm based on artificial bee colony and artificial rabbits optimization for solving economic dispatch problem. Proceedings of the IEEE International Conference on Automatic Control and Intelligent Systems (I2CACIS), 298-303. https://doi.org/10.1109/I2CACIS57635.2023.10193351

Liu, Z., Jiang, P., De Bock, K. W., Wang, J., Zhang, L., & Niu, X. (2024). Extreme gradient boosting trees with efficient Bayesian optimization for profit-driven customer churn prediction. Technological Forecasting & Social Change, 198, 122945. https://doi.org/10.1016/j.techfore.2023.122945

MacFarland, T. W., & Yates, J. M. (2016). Introduction to nonparametric statistics for the biological sciences using R. Springer. https://doi.org/10.1007/978-3-319-30634-6

Maharana, K., Mondal, S., & Nemade, B. (2022). A review: Data pre-processing and data augmentation techniques. Global Transitions Proceedings, 3(2022), 91–99. https://doi.org/10.1016/j.gltp.2022.04.020

Mahesh, B. (2018). Machine Learning Algorithms - A Review. International Journal of Science and Research (IJSR), 9(1), 381–386. https://doi.org/10.21275/ART20203995

Mahmoudian, A., Tajik, N., Mohammadzadeh Taleshi, M., Shakiba, M., & Yekrangnia, M. (2023). Ensemble machine learning-based approach with genetic algorithm optimization for predicting bond strength and failure mode in concrete-GFRP mat anchorage interface. Structures, 57, 105173. https://doi.org/10.1016/j.istruc.2023.105173

Mahmoudian, Y., Nemati, A., & Safaei, A. S. (2023). A forecasting approach for hospital bed capacity planning using machine learning and deep learning with application to public hospitals. Healthcare Analytics, 4, 100245. https://doi.org/10.1016/j.health.2023.100245

Makhadmeh, S. N., Khader, A. T., Al-Betar, M. A., Naim, S., Abasi, A. K., & Alyasseri, Z. A. A. (2020). A novel hybrid grey wolf optimizer with min-conflict algorithm for power scheduling problem in a smart home. Swarm and Evolutionary Computation, 57, 100793. https://doi.org/10.1016/j.swevo.2020.100793

Makhadmeh, Z., Al Momani, M., & Mohammed, A. (2023). An enhanced Grey Wolf Optimizer for solving real-world optimization problems. Expert Systems with Applications, 213, 118834. https://doi.org/10.1016/j.eswa.2023.118834

Malik, A., Onyema, E. M., Dalal, S., Lilhore, U. K., Anand, D., Sharma, A., & Simaiya, S. (2023). Forecasting students' adaptability in online entrepreneurship education using modified ensemble machine learning model. Array, 19, 100303. https://doi.org/10.1016/j.array.2023.100303

Mann, H. B., & Whitney, D. R. (1947). On a test of whether one of two random variables is stochastically larger than the other. The Annals of Mathematical Statistics, 18(1), 50-60. https://doi.org/10.1214/aoms/1177730491

Massaro, M., Dumay, J., & Garlatti, A. (2021). A hybrid XGBoost-ARIMA model for improving sales forecasting accuracy in retail. Journal of Business Economics and Management, 22(4), 512-526. https://doi.org/10.3846/jbem.2021.14039

Mishra, P.K.; Singh, S.; Kumar, A.; Gupta, V. Evaluating the performance of machine learning models in rainfall forecasting: A comparison of XGBoost, ARIMA, and state space models. Environ. Earth Sci. 2024, 83, 11481. https://doi.org/10.1007/s12665-024-11481-w.

Mohakud, B. & Dash, R. (2021). Grey wolf optimization-based convolutional neural network for skin cancer detection. Journal of King Saud University - Computer and Information Sciences, 34(6), 3717-3729. https://doi.org/10.1016/j.jksuci.2021.05.011

Moosavi, S.K.R.; Saadat, A.; Abaid, Z.; Ni, W.; Li, K.; Guizani, M. Feature selection based on dataset variance optimization using Hybrid Sine Cosine—Firehawk

Algorithm (HSCFHA). Future Gener. Comput. Syst. 2024, 141, 1–15. https://doi.org/10.1016/j.future.2024.02.017.

Nematzadeh, S., Kiani, F., Torkamanian-Afshar, M., & Aydin, N. (2022). Tuning hyperparameters of machine learning algorithms and deep neural networks using metaheuristics: A bioinformatics study on biomedical and biological cases. Computational Biology and Chemistry, 97, 107619. https://doi.org/10.1016/j.compbiolchem.2021.107619

Ngo, N.-T., Truong, T. T. H., Truong, N.-S., Pham, A.-D., Huynh, N.-T., Pham, T. M., & Pham, V. H. S. (2022). Proposing a hybrid metaheuristic optimization algorithm and machine learning model for energy use forecast in non-residential buildings. Scientific Reports, 12(1065). https://doi.org/10.1038/s41598-022-04923-7

Ouhame, S., Hadi, Y., & Arifullah. (2020). A hybrid grey wolf optimizer and artificial bee colony algorithm used for improvement in resource allocation system for cloud technology. International Journal of Online and Biomedical Engineering (iJOE), 16(14), 4-17. https://doi.org/10.3991/ijoe.v16i14.16623

Panarese, P., Vasile, G., & Zambon, E. (2021). Sales forecasting using XGBoost: A case study in the e-commerce sector. Expert Systems with Applications, 177, 114934. https://doi.org/10.1016/j.eswa.2021.114934

Peláez-Rodríguez, C., Pérez-Aracil, J., Fister, D., Torres-López, R., & Salcedo-Sanz, S. (2024). Bike sharing and cable car demand forecasting using machine learning and deep learning multivariate time series approaches. Expert Systems With Applications, 238, 122264. https://doi.org/10.1016/j.eswa.2023.122264

Probst, P., Boulesteix, A. L., & Bischl, B. (2018). Tunability: Importance of hyperparameters of machine learning algorithms. arXiv preprint arXiv:1802.09596. https://doi.org/10.48550/arXiv.1802.09596

Razavi-Termeh, S. V., Sadeghi-Niaraki, A., Seo, M. B., & Choi, S. M. (2023). Application of genetic algorithm in optimization parallel ensemble-based machine learning algorithms to flood susceptibility mapping using radar satellite imagery. Science of the Total Environment, 873, 162285. https://doi.org/10.1016/j.scitotenv.2023.162285

Rohaan, D., Topan, E., & Groothuis-Oudshoorn, C. G. M. (2022). Using supervised machine learning for B2B sales forecasting: A case study of spare parts sales forecasting at an after-sales service provider. Expert Systems With Applications, 188, 115925. https://doi.org/10.1016/j.eswa.2021.115925

Sarwar, S., Aziz, G., & Tiwari, A. K. (2023). Implication of machine learning techniques to forecast the electricity price and carbon emission: Evidence from a hot region. Geoscience Frontiers, 14(1), 101647. https://doi.org/10.1016/j.gsf.2023.101647

Selcuk, S., & Tang, P. (2023). A metaheuristic-guided machine learning approach for concrete strength prediction with high mix design variability using ultrasonic pulse velocity data. Developments in the Built Environment, 15, 100220. https://doi.org/10.1016/j.dibe.2023.100220

Shapiro, S.S.; Wilk, M.B. An analysis of variance test for normality (complete samples). Biometrika 1965, 52, 591–611. https://doi.org/10.2307/2333709.

Souza, R. R., Toebe, M., Mello, A. C., & Bittencourt, K. C. (2023). Sample size and Shapiro-Wilk test: An analysis for soybean grain yield. European Journal of Agronomy, 142, 126666. https://doi.org/10.1016/j.eja.2022.126666

Tao, M.; Hong, Z.; Liu, L.; Zhao, M.; Wu, C. An intelligent approach for predicting overbreak in underground blasting operation based on an optimized XGBoost model. Eng. Appl. Artif. Intelligence. 2023, 6, 100279.

Valipour, M., Khoshkam, H., Bateni, S. M., & Jun, C. (2024). Machine-learning-based short-term forecasting of daily precipitation in different climate regions across the contiguous United States. Expert Systems With Applications, 238, 121907. https://doi.org/10.1016/j.eswa.2023.121907

Vivas, E.; Allende-Cid, H.; Salas, R. A systematic review of statistical and machine learning methods for electrical power forecasting with reported MAPE score. Entropy 2020, 22, 1412. https://doi.org/10.3390/e22121412.

Von Bloh, M., Noia Júnior, R. S., Wangerpohl, X., Saltık, A. O., Haller, V., Kaiser, L., & Asseng, S. (2023). Machine learning for soybean yield forecasting in Brazil. Agricultural and Forest Meteorology, 341, 109670. https://doi.org/10.1016/j.agrformet.2023.109670

Wang, H., Binti Mansor, N. N., & Mokhlis, H. B. (2024). Novel Hybrid Optimization Technique for Solar Photovoltaic Output Prediction Using Improved Hippopotamus Algorithm. Applied Sciences, 14(7803). https://doi.org/10.3390/app14177803

Wang, L., Cao, Q., Zhang, Z., Mirjalili, S., & Zhao, W. (2022). Artificial rabbits optimization: A new bio-inspired meta-heuristic algorithm for solving engineering optimization problems. *Engineering Applications of Artificial Intelligence, 115*, 105082. https://doi.org/10.1016/j.engappai.2022.105082

Wang, Y.; Ni, X.S. A XGBoost risk model via feature selection and Bayesian hyper-parameter optimization. arXiv 2019, arXiv:1901.08433. https://doi.org/10.48550/arXiv.1901.08433.

Wang, Z. H., Liu, Y. F., Wang, T., Wang, J. G., Liu, Y. M., & Huang, Q. X. (2024). Intelligent prediction model of mechanical properties of ultrathin niobium strips based on XGBoost ensemble learning algorithm. Computational Materials Science, 231, 112579. https://doi.org/10.1016/j.commatsci.2023.112579

Wolpert, D. H., & Macready, W. G. (1997). No free lunch theorems for optimization. IEEE Transactions on Evolutionary Computation, 1(1), 67–82. https://doi.org/10.1109/4235.585893

Yang, L., & Shami, A. (2020). On hyperparameter optimization of machine learning algorithms: Theory and practice. Neurocomputing, 415, 295–316. https://doi.org/10.1016/j.neucom.2020.07.061

Yi, Y. K., Anis, M., Jang, K., & Kim, Y. J. (2023). Application of machine learning (ML) and genetic algorithm (GA) to optimize window wing wall design for natural ventilation. Journal of Building Engineering, 68, 106218. https://doi.org/10.1016/j.jobe.2023.106218

Zhang, L., Guo, Z., Tao, Q., Xiong, Z., & Ye, J. (2023). XGBoost-based short-term prediction method for power system inertia and its interpretability. Energy Reports, 9, 1458-1469. https://doi.org/10.1016/j.egyr.2023.04.065

Zhang, X., Wu, Y., & Li, Z. (2021). A comparison of XGBoost and ARIMA in demand forecasting of e-commerce platforms. Electronic Commerce Research and Applications, 45, 101030. https://doi.org/10.1016/j.elerap.2021.101030

Zulfiqar, U., Rehman, M. U., & Khan, A. (2022). Adaptive differential evolution and support vector machines for load forecasting. Electric Power Systems Research, 208, 107976. https://doi.org/10.1016/j.epsr.2022.107976

TEZDEN ÜRETİLMİŞ YAYINLAR

Konferans Bildirileri

Aydın, M. R., & Gülsün, B. (2024). A novel metaheuristic approach for hyperparameter tuning in machine learning models. In 19th International Istanbul Scientific Research Congress on Life, Engineering, Architecture and Mathematical Sciences | Congress Proceedings Book.

Makaleler

Gülsün, B., & Aydin, M. R. (2024). Optimizing a Machine Learning Algorithm by a Novel Metaheuristic Approach: A Case Study in Forecasting. Mathematics, 12(24), 3921. https://doi.org/10.3390/math12243921