



T.C.
MUŞ ALPARSLAN ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**ENERJİ PROBLEMLERİNİN SEZGİSEL
ÜSTÜ ALGORİTMA TEMELLİ YAPAY SİNİR
AĞLARI ARACILIĞI İLE OPTİMİZASYONU**

Şeyma Nur ATAR

YÜKSEK LİSANS TEZİ

**Nükleer Enerji ve Enerji Sistemleri Anabilim
Dalı**

Temmuz-2024
MUŞ
Her Hakkı Saklıdır



T.C.
MUŞ ALPARSLAN ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

ENERJİ PROBLEMLERİNİN SEZGİSEL
ÜSTÜ ALGORİTMA TEMELLİ YAPAY SİNİR
AĞLARI ARACILIĞI İLE OPTİMİZASYONU

Şeyma Nur ATAR

YÜKSEK LİSANS TEZİ

Nükleer Enerji ve Enerji Sistemleri Anabilim
Dalı

Danışman: Dr. Öğr. Üyesi Fatih ŞEVGİN

Jüri Üyesi: Doç. Dr. Abdülhakim ZEYBEK

Jüri Üyesi: Dr. Öğr. Üyesi Zeynep AYKAÇ TAŞ

Temmuz -2024
MUŞ
Her Hakkı Saklıdır

ÖZET

YÜKSEK LİSANS TEZİ

ENERJİ PROBLEMLERİNİN SEZGİSEL ÜSTÜ ALGORİTMA TEMELLİ YAPAY SİNİR AĞLARI ARACILIĞI İLE OPTİMİZASYONU

Şeyma Nur ATAR

Muş Alparslan Üniversitesi
Fen Bilimleri Enstitüsü
Nükleer Enerji ve Enerji Sistemleri Anabilim Dalı

Danışman: Dr. Öğr. Üyesi Fatih ŞEVGİN

Enerji, üretilen bir model ya da sistemin iş yapma kapasitesidir. Günümüz dünyası enerji kaynaklarındaki tükenme olasılığını hesaba katarak teknolojik gelişmeleri enerji verimliliği noktasında kullanmak istemektedir. Tüketilen enerjinin büyük bir kısmı binalarda kullanılmaktadır. Enerji kaynaklarının sınırlı olması, binalarda enerji verimliliği ile ilgili yapılan çalışmaların ne denli önemli olduğunu açıklamaktadır. Bu çalışmanın amacı günümüz dünyasının enerji verimliliği gibi büyük problemlerini optimize edebilen sezgisel üstü algoritmalarından salp sürü algoritması (Salp Swarm Algorithm-SSA)'nın optimizasyoncu olarak değerlendirilmesi ve örnek bir enerji problemi ele alınarak sınıflandırıcı olarak tahmin gücünü gözlemlemektir. Enerjiyi etkili kullanma problemi bina tasarımı için seçilen ekipmanların seçiminde önemli bir yer tutan ısıtma yükü faktörü (Heat Load-HL) ve soğutma yükü faktörü (Cold Load-CL) faktörlerinin doğru tahminlemesi ile çözüme katkı sağlamaktadır. Bu problemin çözümünde makine öğrenme algoritmalarından, bir yapay sinir ağı mimarisi olan çok katmanlı algılayıcı (Multi Layer Perceptron-MLP) seçilerek sezgisel üstü algoritmalarından SSA danışman olarak ele alınmış ve alternatif algoritmalarla karşılaştırması yapılmıştır. Algoritmanın rekabet gücü ve kalitesi CEC 2019 fonksiyon seti vasıtasıyla gözlemlenmiştir. İstatistikî sonuçlar ve grafikler aracılığıyla elde edilen verilere bakıldığında SSA'nın rekabetçi yapıda, etkili ve güncel bir algoritma olduğu gözlemlenmiştir. Enerji verimliliği veri seti binalarda ısıtma, soğutma, havalandırma ve iklimlendirme (Heating, Ventilation, and Air Conditioning- HVAC) sistemlerinin optimal kullanımında değerlendirme kriteri olabilecek bir kaynak tezde kullanılarak SSA temelli MLP mimarisiyle eğitimi sağlanmıştır. Deneysel sonuçlar enerji probleminde de SSA'nın iyi bir sınıflandırma sağlayan danışman olduğu istatistikî deneyler aracılığıyla ispatlanmıştır.

2024, 59 Sayfa

Anahtar Kelimeler: Enerji verimliliği problemi, meta-sezgisel algoritma, makine öğrenme algoritması, çok katmanlı algılayıcı, salp sürüsü algoritması

ABSTRACT

MS THESIS

OPTIMIZATION OF ENERGY PROBLEMS THROUGH HEURISTIC ALGORITHM BASED ARTIFICIAL NEURAL NETWORKS

Şeyma Nur ATAR

**Muş Alparslan University
Natural and Applied Science
Department of Nuclear Energy and Energy Systems**

Advisor: Asst. Prof. Fatih ŞEVGİN

Energy is the capacity of a system to do work. In today's world, the focus is on utilizing technological advancements to achieve energy efficiency, given the potential depletion of energy resources. A significant portion of energy consumption occurs in buildings, highlighting the importance of studies on energy efficiency in this sector. This study aims to evaluate the Salp Swarm Algorithm (SSA), a metaheuristic algorithm, in optimizing major contemporary issues such as energy efficiency. Specifically, it examines SSA's effectiveness as both an optimizer and a classifier in an example energy problem. Efficient energy use is crucial for accurately estimating heating load (HL) and cooling load (CL) factors, which are essential for selecting equipment in building design. To address this issue, the study employs the Multi-Layer Perceptron (MLP), an artificial neural network architecture, in conjunction with SSA as an optimization consultant, and compares it with alternative algorithms. Statistical results and graphs indicate that SSA is a competitive, effective, and modern algorithm. The research utilizes the energy efficiency dataset to evaluate the optimal use of Heating, Ventilation, and Air Conditioning (HVAC) systems in buildings. The SSA-based MLP architecture was trained using this dataset, and the experimental results demonstrated that SSA is an effective classifier for energy-related problems through various statistical analyses.

2024, 59 Pages

Keywords: Energy efficiency problem, metaheuristic algorithm, machine learning algorithm, multi-layer perceptron, salp swarm algorithm

TEŐEKKÜR

Bu alıŐma MuŐ Alparslan Üniversitesi Fen Bilimleri Enstitüsü Nükleer Enerji ve Enerji Sistemleri Anabilim Dalı Yüksek Lisans programında yüksek lisans tezi olarak hazırlanmıŐtır. Tez alıŐmamın yürütülmesinde ve hazırlanmasında her konuda bildiklerini paylaşarak deęerli katkılarını saęlayan tez danıŐmanım Dr. Öğr. Üyesi Fatih ŐEVGİN'e teŐekkürlerimi sunarım.

alıŐmalarım da katkısı olan gerek derslerinde gerekse ders dıŐında deęerli vaktini ayırıp, kıymetli bilgilerini esirgemeyen MuŐ Alparslan Üniversitesi Sosyal Bilimler Meslek Yüksekokulu, Pazarlama ve Reklamcılık Bölüm Başkanı Dr. Öğr. Üyesi Erdal EKER'e teŐekkürü bir bor bilirim.

Őeyma Nur ATAR
MUŐ-2024

İÇİNDEKİLER

ÖZET	iv
ABSTRACT.....	v
TEŞEKKÜR	vi
İÇİNDEKİLER	vii
SİMGELER ve KISALTMALAR.....	ix
ŞEKİLLER DİZİNİ.....	x
TABLolar DİZİNİ.....	xi
1. GİRİŞ	1
2. KAYNAK ARAŞTIRMASI	4
2.1 Yapay Sinir Ağları ile İlgili Kaynak Araştırması	4
2.2 Sezgisel Üstü Algoritmalar ile İlgili Kaynak Araştırması	5
2.3 Energy Verimliliği ile İlgili Kaynak Araştırması.....	7
2.4 Sezgisel Üstü Algoritma Temelli HVAC Çalışmaları	8
2.5 Enerji Verimliliği Veri Seti ile İlgili Yapılan Çalışmalar	10
3. MATERYAL ve YÖNTEM	13
3.1 YSA.....	13
3.1.1 YSA Mimarisi	13
3.2 Sezgisel Üstü Algoritma	16
3.2.1 Salp Sürü Algoritması (SSA).....	16
3.2.2 Çayır Köpeği Optimizasyon (PDO) Algoritması.....	18
3.2.3 Açlık Oyunları Arama (HGS) Algoritması	21
3.2.4 Arşimet Optimizasyon Algoritması (AOA).....	23
3.2.5 Harris Şahinleri Optimizasyon (HHO) Algoritması	26
3.3. Enerji Verimlilik problemi.....	29
3.3.1. İklimlendirme (HVAC) Sistemi.....	30
4. ARAŞTIRMA SONUÇLARI ve TARTIŞMA	32
4.1 SSA Algoritmasının Karşılaştırma Fonksiyonları Aracılığıyla Performans Ölçümü.....	32
4.2 SSA-MLP Eğitimi.....	38
5. SONUÇLAR ve ÖNERİLER.....	41
5.1 Sonuçlar	41
5.2 Öneriler	41
KAYNAKLAR	43

ÖZGEÇMİŞ 51



SİMGELER ve KISALTMALAR

Kısaltma

AOA	:	Archimedes optimization algorithm
CL	:	Cool loading (soğutma yükü)
HGS	:	Hunger games search (açlık oyunları arama)
HHO	:	(Harris Hawks Optimization)
HL	:	Heat loading (ısıtma yükü)
MLP	:	multilayer perceptron (çok katmanlı algılayıcı)
PDO	:	Prairie dog optimization (çayır köpeği optimizasyonu)
SSA	:	Salp swarm algorithm (salp sürüsü algoritması)
YSA	:	Yapay sinir ağları

ŞEKİLLER DİZİNİ

Şekil 3. 1 YSA mimarileri sınıflandırılması.....	14
Şekil 3. 2 (A) Salp , (B) Salp zinciri.....	17
Şekil 3. 3 Çayır köpeği kolonisi	19
Şekil 3. 4 HGS optimizasyon süreci	21
Şekil 3. 5 (A) Yer değiştiren sıvının hacmi, (B) Bir nesne bir sıvıya batırılmıştır.....	23
Şekil 3. 6 Harris şahinleri optimizasyon algoritmasının ilhamı	27
Şekil 3. 7 Bir HVAC modelinde hava akış diyagramı	31
Şekil 4. 1 CEC 2019 aracılığıyla algoritmaların F1 fonksiyonunda yakınsama eğrisi... 34	34
Şekil 4. 2 CEC 2019 aracılığıyla algoritmaların F2 fonksiyonunda yakınsama eğrisi... 35	35
Şekil 4. 3 CEC 2019 aracılığıyla algoritmaların F3 fonksiyonunda yakınsama eğrisi... 35	35
Şekil 4. 4 CEC 2019 aracılığıyla algoritmaların F4 fonksiyonunda yakınsama eğrisi... 35	35
Şekil 4. 5 CEC 2019 aracılığıyla algoritmaların F5 fonksiyonunda yakınsama eğrisi... 36	36
Şekil 4. 6 CEC 2019 aracılığıyla algoritmaların F6 fonksiyonunda yakınsama eğrisi... 36	36
Şekil 4. 7 CEC 2019 aracılığıyla algoritmaların F7 fonksiyonunda yakınsama eğrisi... 36	36
Şekil 4. 8 CEC 2019 aracılığıyla algoritmaların F8 fonksiyonunda yakınsama eğrisi... 37	37
Şekil 4. 9 CEC 2019 aracılığıyla algoritmaların F9 fonksiyonunda yakınsama eğrisi... 37	37
Şekil 4. 10 CEC 2019 aracılığıyla algoritmaların F10 fonksiyonunda yakınsama eğrisi	37
Şekil 4. 11 MLP eğitimi yoluyla algoritmaların heating load kutu grafiği	39
Şekil 4. 12 MLP eğitimi yoluyla algoritmaların cooling load kutu grafikleri	40

TABLÖLAR DİZİNİ

Tablo 3. 1 Enerji verimliliği veri kümesinin özelliği	30
Tablo 4. 1 CEC2019 fonksiyon tanım parametreleri	32
Tablo 4. 2 CEC 2019 aracılığıyla algoritmaların istatistiksel sonuçları	32
Tablo 4. 3 Wilcoxon Signedrank testi ile algoritmaları karşılaştırma (CEC 2019).....	34
Tablo 4. 4 Veri setinin MLP eğitiminin istatistiksel sonuçları	38



1. GİRİŞ

Son yıllarda, dünya büyük ölçüde bilimsel ve endüstriyel gelişmelere şahitlik etmektedir. Bu gelişmelerle birlikte, çözülmesi gereken birçok karmaşık, yüksek boyutlu ve lineer olmayan optimizasyon problemine de ihtiyaç duyulmaktadır. Non-linear problemlerin çözümü, olası çözümlerin arasından en iyi sonucun bulunması anlamına gelir ve bu sürece optimizasyon adı verilir (Yıldız, 2006). Optimizasyon problemleri matematiksel olarak,

$$\min f(x), g(x) \leq 0, h(x) = 0, x \in Q \quad (1.1)$$

tarzın da modellenabilir (Cui ve ark., 2012). Burada $f(x)$ minimize edilmesi gereken bir problemi ve Q rasyonel sayılar kümesini ifade ederken, $g(x) \leq 0, h(x) = 0$ ise problemin kısıtlarını ifade eden fonksiyonlardır. Optimizasyon problemlerinin çözümü belirli algoritmik süreçleri içermekte olup, aynı zamanda her algoritmanın tüm problemleri çözüme yeteneğinin olmadığını bilmek gerekir. Başka bir ifadeyle, bir algoritma belirli problemleri çözebilirken, diğer bir algoritma başka türden problemleri çözebilir. Bu durum, tüm problemler için evrensel bir algoritma olmadığını ortaya koyar (Yang, 2012). Problemlerin çözümü için en temel iki yöntem gradient metot (Lasdon ve ark., 1974) ve sezgisel üstü metottur (Altay ve Altay, 2021). Sezgisel üstü algoritmalar doğadan esinlenerek oluşturulan yapılardır. Bu algoritmalar basit ve doğrusal yapılarda bulunmaktadır. Aynı zamanda popülasyona dayalı rastgeleleştirmelerinden dolayı mühendislik araştırmalarında ve birçok farklı alanda uygulanmaktadırlar. Temel olarak evrimsel ve sürü tabanlı algoritmalar olmak üzere ikiye ayrılmaktadırlar (Salgotra ve ark., 2021). Sezgisel üstü metot son yıllarda oldukça yaygın hale gelmiştir. Bunun nedeni, çözümde türev gerektirmemesi, esnek bir yapıda olması, daha kısa sürede ve daha optimal çözümlere sahip olmasıdır (Çelik ve ark., 2019). Bu konuda ilk çalışmalar genetik algoritma (GA) (Mirjalili, 2019), parçacık sürü optimizasyonu (PSO) (Eberhart ve Kennedy, 1995), yapay arı kolonisi (ABC) (Mirjalili ve ark., 2014) ve karınca kolonisi optimizasyonu (ACO) (Dorigo ve ark., 2006) sayılabilir. Daha sonra gri kurt optimizasyonu (GWO) (Mirjalili ve ark., 2014a), Harris Hawks optimizasyonu (HHO) (Heidari ve ark., 2019), açlık oyunları arama (HGS) (Y. Yang ve ark., 2021), karahindiba optimize edici (DO) (Zhao ve ark., 2022) gibi birçok algoritma üretimi söz konusu olmuştur (Uniyal ve ark., 2022). Sezgisel üstü algoritmalar gerçek dünya problemleri olarak klasik mühendislik problemlerinin çözümü, tasarım problemleri, otomotiv sanayi,

rüzgar çiftlikleri, ısı transfer mekanizmaları gibi birçok endüstriyel alanda geniş yer tutmaktadır (Aslan ve Yıldız, 2020; Gürses ve ark., 2022a; Gürses ve ark., 2022b; Gürses ve ark., 2023; Kunakote ve ark., 2022; Mehta ve ark., 2022; Mehta ve ark., 2022; Panagant ve ark., 2021; Sait ve ark., 2023; Yıldız ve ark., 2021, 2022).

Bu çalışmada ilk olarak sürü temelli Salp Swarm Algoritmasının problem çözme performansı değerlendirilmiştir. Salp Swarm Algoritması (SSA), 2017'de salpların sürü mekanizmasını temel alan ve aynı zamanda biyoloji temelli bir optimizasyon algoritmasıdır (Hegazy ve ark., 2020). SSA, çeşitli optimizasyon problemlerini çözmekte kullanılmakta olduğu gibi endüstri, sanayi, tıp, eğitim ve hayatın birçok alanında matematiksel olarak modellenebilen problemlerin çözümünde de kullanılmıştır. Ayrıca makine öğrenimi, mühendislik tasarımı, kablosuz ağ oluşturma, görüntü işleme ve güç enerjisi gibi farklı alanlardaki çeşitli optimizasyon problemlerinde de kullanılmıştır (Abualigah ve ark., 2020). SSA, salpların okyanuslarda avlanmasını incelemektedir. SSA, salpların okyanusta yollarını bulurken oluşturdukları salp zinciri davranışını temel almaktadır. SSA uygulanması oldukça basit aynı zamanda verimli ve esnek sonuçlar üretebilmektedir (Abbassi ve ark., 2019; Masdari ve ark., 2019). Bununla birlikte, çoğu sezgisel üstü algoritma gibi, SSA'da yerel optimum noktaya takılarak erken yakınsama ya da durgunluk problemi yaşayabilir, bu problemleri çözmek için SSA'nın geliştirilmeye ihtiyacı vardır (Abualigah ve ark., 2022; Abualigah ve ark., 2017; Tawhid ve Ibrahim, 2022). Sezgisel üstü algoritmaların çözüm kalitesini ortaya çıkarmak için kalite fonksiyonu olarak da ifade edilen fonksiyon setleri kullanılır. Bu çalışmada küresel çözüme gidişi zorlaştıran CEC2019 (Naruei ve Keynia, 2022) fonksiyon seti kullanılarak SSA algoritmasının optimizasyon gücü ortaya çıkartılmıştır (Altay ve Altay, 2023).

SSA rekabetçi bir algoritma olarak, performans üstünlüğü değerlendirildikten sonra gerçek dünya problemlerine uygulanarak spesifik sonuçlara ulaşma yeteneği çalışmanın bir diğer amacını oluşturmaktadır. Bu bağlamda non-linear bir problem olan multilayer perceptron (MLP) eğitimi iyi bir örnek oluşturmaktadır (Haykin ve Network, 2004). MLP, yapay sinir ağları eğitiminde danışmanlı öğrenme mimarisi olarak verilerin sınıflandırılmasında kullanılır (Eker ve ark., 2023). MLP eğitiminde giriş ve çıkış tabakaları arasına yerleştirilen gizli tabaka sayesinde veri sınıflandırma oranı daha yüksek ve hata oranı da daha düşük olmaktadır (Mirjalili, 2015). Sezgisel üstü algoritmaların MLP eğitiminde kullanımları ile ilgili oldukça zengin bir literatür vardır (Eker ve ark., 2023; Surucu ve ark., 2023).

SSA tabanlı MLP (SSA-MLP) eğitiminde amaç, geliştirilen algoritmanın enerji problemlerinin çözüm kabiliyetini değerlendirmektir. Binalarda enerji tüketiminin tahmin edilmesi amacıyla yapılan çalışmalar, enerji tasarrufu sağlama ve çevreye zarar veren etkilerden korunma çabalarına önemli bir katkı sunar. Bu bağlamda SSA-MLP eğitimi HVAC sistemi üzerinde sağlanmıştır. Bu çalışmada binaların HL ve CL için enerji verimliliği performansı MLP aracılığıyla tahmin edilmiş ve çalışmada kullanılan veri seti UCI makine öğrenme data deposundan alınmıştır (Tsanas ve Xifara, 2012).

SSA temelli MLP çalışmasında bir HVAC sisteminin eğitilmesi sağlanmıştır. HVAC akıllı binalarda enerji girişini sağlayan bir otomasyon sistemidir. Fosil yakıtların sınırlı olması, maliyetlerinin artması ve çevresel kaygılar sebebiyle havalandırma, ısıtma, iklimlendirme (HVAC) sistemlerinde enerji tüketimi azalması gün geçtikçe önemli hale gelmektedir. Bundan ötürü, konfor ile iç mekânın hava kalitesi düşürülmeden, bina enerji tüketiminin azalmasını yeni yöntemlerini üretmek üzerinde çalışılmaktadır. HVAC sistemleri konusunda enerji verimi sağlama yollarından biri, bulunan sistem bileşenlerinin yeni konfigürasyonlarından faydalanan sistemleri üretmektir. Tüm HVAC disiplinlerinin özel tasarım gereksinimi mevcuttur, aynı zamanda hepsi enerji tasarrufu konusunda kolaylık sağlamaktadır. Enerji verimliliği olan HVAC sistemlerde, mekanizmada bulunan parçaların daha stratejik biçimde kullanımında geleneksel sistemlerin yenilenmesi sağlanabilmektedir (Vakiloroya ve ark., 2014). Bu açıdan optimizasyon kalitesini arttıracak modernizasyonu sağlamak her zaman mümkündür. Tez beş kısımdan oluşmaktadır. İlk kısım giriş, ikinci kısım kaynak araştırması, üçüncü kısım materyal ve yöntem, dördüncü kısım araştırma sonuçları ve tartışma, beşinci kısım ise sonuç ve önerilerden oluşturulmuştur.

2. KAYNAK ARAŞTIRMASI

2.1 Yapay Sinir Ağları ile İlgili Kaynak Araştırması

Yapay sinir ağları, hesaplamalı modeller aracılığıyla insan beynini taklit eden, karmaşık ve doğrusal olmayan problemler için yaygın olarak kullanılır. Bu modele ait yapıların eğitimi ve problemlerin üstesinden gelmek için işlem dizgesi adı verilen algoritmalara ihtiyaç vardır. Algoritmalar genelde gradient ve stokastik olmak üzere iki ana başlıkta toplanabilir (Eker ve ark., 2023).

Farklı çalışmalarda yer alan gradyan iniş tabanlı YSA algoritmalarına Batch weight ve bias rule (B) algoritması örnek verilebilir. Algoritmalara ait ağırlıkları güncelleyerek, bias değerleri her döngüden sonra öğrenme fonksiyonuna göre belirlenir ve maksimum iterasyona ulaşıldığında veya doğrulama verilerinin performansı belirtilen değere ulaştığında eğitim tamamlanır (Grippio, 2000). Öte yandan bayes düzenlemesi algoritması ise büyük ağırlıkların olumsuz etkisini yok etmek için düzeltmeler yapar. Düzeltmelerin amacı, tüm ağ ağırlıklarının karelerinden oluşan bir ceza terimi ekleyerek, amaç fonksiyonunda değişiklik yapmak ve ağ tepkisini daha düzgün hale getirmektir. Bu stratejide ağırlık ve sapma değerleri Levenberg- Marquardt (LM) optimizasyonuna göre güncellenmektedir. Çalışma yöntemi, bayes düzenlemesi adı verilen hata ve ağırlık karelerinin kombinasyonunu en aza indirmek ve ardından iyi bir ağ oluşturmak için doğru kombinasyonu belirlemektir (Wang ve ark., 2007). Bayes düzenlemesi algoritmasında girişler sıralıdır ve her iterasyonda her bir veri vektörü ağa sunulur, ağırlıkların ve biasların güncellemeleri yapılır (Shabani ve Mazahery, 2012).

Geleneksel algoritmaların ağ eğitiminde gösterdiği bazı dezavantajları aşmak için son yıllarda sezgisel üstü algoritmalar kullanılmaya başlanmış ve oldukça yaygınlık kazanmıştır (Alba ve Martí, 2006).

Farklı çalışmalarda yer verilmiş sürü tabanlı bazı YSA algoritmaları şunlardır: HGS algoritması, açıklık kavramına dayalı uyarlanabilir ağırlık parametreleri kullanır ve her arama adımında açıklığın etkisini taklit eder. Sürü zekasına sahip tüm toplulukların açıklık oyunlarını genelleştirmektedir (Y. Yang ve ark., 2021). GWO algoritması ise gri kurt sürüsünün davranışından esinlenmiştir. Avlanma, arama, kuşatma ve saldırı olarak adlandırılan farklı stratejiler uygulayarak sürünün liderlik yapısını ve avlanma mekanizmasını taklit eder (Mirjalili ve ark., 2014). AOA algoritması ise suyun kaldırma kuvveti olarak bilinen Arşimet yasasından ilham almıştır (Hashim ve ark., 2021). Bu algoritma, farklı ağırlık ve hacimdeki nesnelere bir sıvıya batırıldığında olanları taklit eder.

Aquila optimizasyon algoritması (AO) ise Aquila adı verilen bir çeşit kuşun doğadaki yiyecek arama davranışından ilham alan bir algoritmadır (Abualigah ve ark., 2021).

Ayrıca literatürde yapay sinir ağları ile ilgili biyocoğrafya temelli optimizasyonu (BBO) (Mirjalili ve ark., 2014b), salp sürüsü algoritması (SSA) (Khishe ve Mohammadi, 2019), yapay arı kolonisi optimizasyonu (ABC) algoritması (Ghanem ve Jantan, 2020), lider salp sürüsü algoritması (MLSSA) (Bairathi ve Gopalani, 2021), karınca aslanı optimizasyonu (ALO) (Heidari ve ark., 2020), manyetik optimizasyon (MOA) (Mirjalili ve Sadiq, 2011), balçık kalıp algoritması (SMA) (Zubaidi ve ark., 2020) algoritmaları kullanılmıştır.

2.2 Sezgisel Üstü Algoritmalar ile İlgili Kaynak Araştırması

Sezgisel üstü algoritmalar yapay sinir ağı eğitiminde iyi bir optimizasyoncu olarak rol almışlardır. Son yıllarda yüzlerce algoritma üretilmiş ve veri sınıflandırma stratejilerinde de başarılı bir şekilde kullanılmıştır. Bu algoritmalara birkaç örnek aşağıda ifade edilmiştir. Parçacık sürü optimizasyonu (PSO) (Eberhart ve Kennedy, 1995), Nelder-mead algorithm (Singer ve Nelder, 2009), bakteriyel koloni optimizasyonu (BCO) (H Niu ve M Zhang, 2012), gri kurt algoritması (GWO) (Mirjalili ve ark., 2014a), Harris Hawks algoritması (HHO) (Heidari ve ark., 2019), Arşimet optimizasyon algoritması (AOA) (Hashim ve ark., 2021), salp sürüsü algoritması (SSA) (Abualigah ve ark., 2020; Eker ve ark., 2024), kaos oyun algoritması (CGO) (Talatahari ve Azizi, 2021), ceylan optimizasyon algoritması (GOA) (Agushaka ve ark., 2023), girdap arama algoritması (VSA) (Gharehchopogh ve ark., 2022), fire hawk optimizer (FHO) (Azizi ve ark., 2023) algoritmalarıdır.

Bu tezde kullanılan SSA algoritması ise MLP eğitimi dışında da aşağıda verilen bir kısım örneklerden de anlaşılacağı gibi gerçek dünya problemlerinin optimizasyonunda kullanılmıştır.

SSA algoritması, otomatik voltaj regülatör (AVR) sistemlerinde (Ekinci ve ark., 2018), kalite test fonksiyonlarında (Bingöl ve Yıldırım, 2021), öznitelik seçiminde (Can ve ark., 2021), yapay sinir ağlarının eğitilmesinde (Atlı, 2022), diyabetin erken dönemde tespit edilmesinde (Özmen ve ark., 2023), ses verilerinden cinsiyet farklılıklarını bulmakta (Özbay ve Özbay, 2023), sensör ağlarında (Çakici, 2022), santral modellerinde (Sezer ve Bayhan, 2021), mühendislik tasarımı problemlerinde (Mirjalili ve ark., 2017) kullanılmıştır.

SSA algoritması, basit mimarisi ve optimizasyon sürecinde gösterdiği üstün performansı sayesinde gerçek dünya problemlerinin çoğuna uygulanabilmiştir. Bu uygulamayla beraber bazı karmaşık optimizasyon problemlerinde yerel optimum noktalara takılma problemi SSA algoritmasının maruz kaldığı bir durumdur. Bunu çözmek için OL, QI ve GOL dahil olmak üzere üç strateji ile SSA algoritması hibritleştirilerek yeni ESSA algoritması önerilmiş ve daha iyi bir performans yakalanmıştır (Zhang ve ark., 2022). Aynı şekilde yerel SSA yerel optimum noktalara takılmanın yanı sıra bazı problemlerin çözümünde girdiği kısır döngüyü aşmak için SSA algoritmasının geliştirilmiş bir versiyonu (DSSA) önerilmektedir (Tubishat ve ark., 2021).

SSA, geniş kapsamlı optimizasyon problemlerini çözmek için araştırmacılar tarafından geliştirilen çeşitli modifikasyonlar için yenilenmiştir (Rizk-Allah ve ark., 2019). SSA algoritmasının keşif ve sömürü yeteneklerini geliştirmek için binary çözümler üretmişlerdir (Atlı, 2022; Ma ve ark., 2021). TCSSA algoritmasında ise, SSA'nın liderlik yapısını iyileştirerek sömürü aşamasını daha başarılı geçmesini sağlamak için de yeni bir binary çözüm önerilmiştir (Özmen ve ark., 2023).

Simpleks yönteme dayalı olarak geliştirilmiş bir salp sürü algoritması (SMSSA) önerilmiştir. Bu tek yönlü yöntem, ele alınan sürüdeki arama ajanı sayısını artırma ve algoritmanın yerel arana bilirliliğini geliştiren rastgele bir varyant stratejisidir. Bu yöntem, SSA'nın keşif ve sömürü aşamaları arasında daha uygun bir denge sağlamaya yardımcı olmanın yanı sıra SSA'yı daha güçlü ve daha hızlı hale getirir (Wang ve ark., 2018). Bir öznitelik seçimi problemini çözmek için SSA ve PSO algoritmasının bir hibriditasyonu olan SSAPSO algoritması oluşturulmuştur (İbrahim ve ark., 2019).

Önerilen CME algoritmasında ise bilinmeyen bir ortamda tanımlanabilir bir haritayı hızlı bir şekilde özetlemek için hem deterministik hem de sezgisel üstü algoritmaları birleştiren yeni bir hibrit uzay araştırma yöntemi geliştirilmektedir. Süreç, sezgisel üstü SSA sömürülerek çok robotlu bir sistemle sonlu bir harita oluşturmak için optimize edilmiştir. Robotun bir sonraki en iyi pozisyonlarını belirleyerek robotun bir sonraki hareketinde yardımcı olan rastgele parametreler üretir. Sonuç olarak SSA, robotun bir sonraki hareket konumunu seçer (Romeh ve Mirjalili, 2023).

Bir çalışmada SSA algoritmasının kalitesi CEC 2019 ve CEC 2020 veri setleri ile değerlendirilmiştir, daha sonrasında enerji tahmin problemine uygulanmış ve başarılı olunmuştur (Eker ve ark., 2024).

2.3 Energy Verimliliği ile İlgili Kaynak Araştırması

Irfan ve ark. (2021), Enerji problemini çözmek için makine öğrenme algoritmalarından yapay sinir ağları ve derin sinir ağları stratejilerini kullanmışlar ve bu stratejinin üstünlüğünü on altı adet algoritma ile karşılaştırarak göstermişlerdir. Goyal ve ark. (2020), sınıflandırıcı topluluk öğrenme metotları ve makine öğrenme algoritmalarını kullanarak tahminlemenin hızı ve doğruluğunu gözlemlemeye çalışmış ve sınıflandırıcı topluluk öğrenmesi makine öğrenme algoritmalarından daha üstün sonuçlar çıkardığını gözlemlemişlerdir. Makine öğrenme algoritmalarının problem çözme kabiliyetleri ile ilgili Tien ve ark. (2022) geniş bir araştırma yaparak literatürü incelemişlerdir. Nilashi ve ark. (2017), Min-max kümeleme (EM) ve uyarlanabilir nöro-bulanık çıkarım sistemi (ANFİS) metotları uygulayarak bu çalışmada belirtilen veri seti aracılığıyla verileri eğitmişlerdir. Akıllı binalarda HL ve CL faktörleri tahminlerinin önemini birçok metodu karşılaştırarak vermişlerdir. Roy ve ark. (2020), çalışmalarında HL ve CL faktör tahminlerini derin sinir ağı, gauss süreci regresyonu, minimax olasılık makinesi regresyonu yöntemlerini karşılaştırarak gerçekleştirmişler ve akıllı binalarda bu tahminlerin önemine dikkat çekmişlerdir. Qian ve ark. (2023), sıcaklık, basınç, nem ve gaz fiyatları gibi faktörlere dayalı olan kentsel gaz tüketiminin daha optimal düzeye çekilmesi için Kategorik destekleme yöntemi (CatBoost) ile sezgisel üstü algoritmaların bir kısmını hibritleştirilmiş ve bir veri seti üzerinden önerilen modelin performansını incelemişlerdir. Khishe ve Mohammadi (2019), pasif sonar veri setini SSA-MLP hibrit sistemi ile eğiterek sınıflandırma doğruluğu yüksek bir model elde etmişlerdir. Wang ve ark. (2022), ekolojik açıdan faydalı ve konforlu bir mekan oluşturmak amacıyla iç mekan bireysel termal konforun ölçümünü hibrit aşırı öğrenme makinesiyle bulanıklaştırılmış açlık oyunları arama modeli (ELM-Fuzz-HGS) önermiş, farklı sezgisel üstü algoritmaların ELM eğitimleriyle karşılaştırmış ve tahmin gücünün yükseldiğini belirtmişlerdir. Sezgisel üstü tabanlı MLP eğitime bir başka örnek Kosarirad ve ark. (2022), büyük veri seti sonar veri tabanını gürültüden arındırmaları için önerdikleri model olup sınıflandırma oranları oldukça yüksek izlenmiştir. Ekolojik akıllı binalarda konforu yükseltmek ve enerji maliyetini minimize etmek için Wang ve ark. (2023), sezgisel üstü tabanlı yeşil bina enerji optimizasyon system modeli geliştirmiş ve ChOA algoritmasının enerji tasarrufunu en iyi optime eden algoritma olduğunu belirtmişlerdir. He ve ark. (2024), sualtı kablosuz sensör ağlarının tasarımı sistemlerinde enerji verimliliğini arttırmak ağ ömrünü uzatmak amacıyla sezgisel üstü tabanlı algoritma

modeli önermiş, HChOA aracılığıyla kümeleme ve çok atlamalı yönlendirme prosedürünü verimli bir şekilde sağladığını belirtmişlerdir.

2.4 Sezgisel Üstü Algoritma Temelli HVAC Çalışmaları

Isıtma, havalandırma ve iklimlendirme (HVAC) sistemlerinin modellenmesi, enerji tüketimini, iç ortam kalitesini değerlendirmeyi ve düzenlemeyi amaçlar. HVAC sistemlerinde genellikle üç tür modelleme yaklaşımı bulunmaktadır. Bunlardan ilki, veri odaklı (kara kutu veya ters) yaklaşımdır. Bu yaklaşımda, genellikle normal işletme koşullarında veya belirli testlerde sistemin performans verileri toplanır ve matematiksel tekniklerle girdi ve çıktı değişkenleri arasındaki ilişki kurulur. İkincisi, fizik temelli (beyaz kutu) yaklaşımdır. Bu yaklaşımda, sistemin modelleri, geçerli fizik yasalarıyla uyumlu olarak, sistemdeki bileşenlerin ayrıntılı bilgileri kullanılarak oluşturulur. Üçüncüsü ise, gri kutu yaklaşımıdır. Bu yaklaşım, fizik temelli yöntemlerle modelin temel yapısını oluşturur ve sistemdeki ölçümlere dayanarak parametre tahmini algoritmalarıyla şekillendirilir (Afram ve Janabi-Sharifi, 2014).

Lu ve ark. (2005), iç mekandaki hava dolaşımıyla soğutma suyunun döngüsünden oluşan merkezi HVAC sistemlerinde binanın iç bölümlerini optimize etmeyi amaçlayan pratik bir yöntem sunan bir çalışma yapmış ve bu çalışmada, bileşen özellikleri ve bileşenler arasındaki etkileşim analiziyle bina içindeki bölmeleri hedeflemiş ve model tabanlı bir optimizasyon problemini modellemişlerdir. Bu problemi çözmek ve kontrol edilebilir değişkenlerde en iyi ayar noktalarını bulmak için değişime uğramış genetik algoritma kullanılmıştır. Elde edilen simülasyon sonuçlarına uygun olarak, bileşenlerdeki değişken CL faktörü ile gerçek zamanlı hesaplamalar yapılarak belirlenen optimal ayar noktalarında sistem enerji tüketimi en aza indirilmiştir.

Zeng ve ark. (2015), enerji tasarruflarını sağlamak amacıyla yaptıkları araştırmada çok bölgeli bir HVAC sistemi üzerinde veri odaklı bir yöntem kullanmışlardır. HVAC enerji tüketimi ve birden fazla bölgedeki çevresel koşulların tahmin modelleri, veri madenciliği algoritmaları tarafından oluşturulmaktadır. Oda sıcaklığı ve bağıl nem gibi ana çevresel koşullar göz önünde bulundurulur. Tahmin modelleri, HVAC sisteminin çalıştırılması için gereken iki değişken olan besleme havası sıcaklık ve statik basınç ayar noktalarını en iyilemek amacıyla oluşturulmuştur. Bu süreç, her bir bölgenin belirlenen ortam koşullarını korurken enerji tüketimini en aza indirmeyi hedeflemiştir. Bu amaçla, ateşböceği algoritması gibi yeni bir buluşsal arama algoritması ile işlem yapılıyor. Ateşböceği algoritması, veri tabanlı tahmin modellerini çözmek ve HVAC operasyonel

kısıtlamaları altında en uygun ayarları belirlemek için sömürülmüştür. Bu algoritma, parçacık sürüsü optimizasyonu ve evrimsel strateji gibi diğer optimizasyon yöntemleriyle karşılaştırılmıştır. Veri tabanlı modellerin avantajı, yeterli miktarda veri sağlandığında, karmaşık endüstriyel sistemlerdeki desenleri daha iyi öğrenebilmeleridir. Bu modeller, veriye bağımlı olmalarına rağmen ve farklı veri kümeleri için yeniden eğitilmeleri gereksinimine rağmen, gerçek zamanlı çevrimiçi uygulamalar için yüksek esneklik sunmaktadır. Üstelik, bu modeller bir kez devreye alındıktan sonra, sistem daha fazla veri ürettiği sürece kolayca güncellenebilir ve sürekli olarak geliştirilebilirler.

Homod (2013), yaptığı HVAC sistemlerindeki modelleme çeşitliliğini ve uygulamadaki eksiklikleri inceleyen bir çalışmada, sistemin avantaj ve dezavantajları da değerlendirmiştir. Araştırmanın sonucunda, iç mekânın termal konforunu en iyi şekilde gösteren modellemenin gri kutu modeli olduğu belirlenmiştir. Ancak, bu modelin uygulamasında, entegrasyon modeli beklenmedik davranışlar sergilediği için başarısız olmuştur.

Wang ve Ma. (2008), HVAC alanında geliştirilebilen veya kullanılacak ana denetim ve optimal kontrol yöntemlerini gruplamayı amaçlayan çalışma yapmışlardır. Tüm kontrol yöntemleri ve optimizasyon tekniklerinin özellikleri açıklanmış ve ardından karşılaştırmıştır. Bunun yanı sıra, HVAC sistemlerindeki son teknolojileri araştıran ve geliştiren denetleyici ve optimal kontrol uygulamalarını kapsayan daha geniş ve genel bir araştırma sunulmuştur.

Kusiak ve ark. (2010), bir ofis tarzı tesisteki iklimlendirme için enerji tüketimini en aza indirmeyi hedefleyen bir çalışma yapmışlardır. Bu amaçla, kontrol altına alınamayan parametreler arasındaki doğrusal olmayan ilişkiyi modellemek için sekiz farklı veri madenciliği algoritması sömürülmüştür. Çok katmanlı algılayıcı (MLP), diğer modellere göre daha iyi performans gösterdiği için birer soğutucu, pompa, fan ve yeniden ısıtma cihazı modeli oluşturmak için tercih edilmiştir. Bu modeller, enerji optimizasyonu modellemesine iki karar değişkeni eklenerek entegre edilmiştir. PSO algoritmasıyla bu modellemeler çözülmüştür. Sonuçlar, HVAC sistemlerinden kaynaklanan enerji tüketiminde %7'lik bir azalma olduğunu göstermektedir.

Fong ve ark. (2006), enerjii etkin bir şekilde yönetmek amacıyla HVAC sistemlerinde simülasyon-optimizasyon tabanlı bir çalışma yapmışlardır. HVAC sistemlerin su ve hava tarafını içeren karmaşık ilişkilerinden dolayı, değişen hava koşullarına uygun bir şekilde bir yıl boyunca en iyi ayarları sağlamayı hedeflemiştir. Bu amaçla, evrimsel programlama ve sezgisel üstü simülasyon-EP'i birleştirmek için model

oluşturmuşlardır. Bu birleşimle, HVAC kurulumunun soğutulmuş su ve besleme havası sıcaklığını hedefleyen aylık optimum sıfırlama yöntemi geliştirilmiştir. Bu sıfırlama planı, ek maliyetler olmadan mevcut operasyonel ayarlarla karşılaştırıldığında %7'lik bir tasarruf potansiyeli sunmaktadır.

Maheshwari ve ark. (2024), HVAC sistemlerinde enerji tüketimini azaltmaya yönelik optimizasyon algoritmalarının uygulanması ve karşılaştırılması incelenen bir çalışma yapmışlardır. Bu çalışmada, sürü tabanlı ve fizik tabanlı olmak üzere iki ana algoritma kategorisini ele almışlardır. Sürü tabanlı algoritmalar arasında parçacık sürü optimizasyonu, karınca kolonisi optimizasyonu, ateşböceği algoritması ve guguk kuşu arama algoritması bulunurken, fizik tabanlı algoritmalar ise tavlama simülasyonu ve yerçekimi arama algoritmasıdır. Gerçek hayattaki enerji tüketimi verilerine dayanarak, bir HVAC sisteminin damper ayarlarını optimize etmek için bu algoritmalar sömürülmüştür. Çalışmanın sonuçları, farklı algoritmaların uygulanmasıyla enerji tüketiminin neredeyse yarı yarıya azaldığını göstermektedir. Özellikle, Ateş böceği algoritması diğer algoritmalarla karşılaştırıldığında daha iyi enerji optimizasyonu sağlamıştır.

2.5 Enerji Verimliliği Veri Seti ile İlgili Yapılan Çalışmalar

Lu ve ark. (2020), kâr odaklı ve enerji verimli bir Dijital Sinyal İşleme (DSP) yaklaşımı olan PEDSP üzerinde durulan bir çalışmayı yapmıştır. Bu çalışmada, sadece kârı maksimize etmekle kalmamış, aynı zamanda enerji tüketimini de önemli bir karar kriteri olarak ele almıştır. Ürün için bir sökme diyagramını modellemek için bir sökme VE/VEYA grafiği (DAOG) kullanılmıştır; burada 'VE' ve 'VEYA' ilişkileri, alt montajlar arasındaki öncelik ilişkilerini belirtmektedir. DAOG temel alınarak, PEDSP için pareto çözümlerini elde etmek için yapay bir arı kolonisi algoritması, baskın olmayan bir sıralama prosedürü ve değişken bir komşuluk arama yaklaşımını birleştiren hibrit birçok amaçlı meta-sezgisel yöntem önerilmiştir. Önerilen yöntem, gerçek dünya senaryolarına uygulanmış ve diğer çok amaçlı algoritmalarla karşılaştırılmıştır. Sonuçlar, bu yöntemin alternatif yaklaşımlara göre daha hızlı bir şekilde daha iyi bir pareto çözüm seti üretebildiğini göstermiştir.

Iwendi ve ark. (2021), enerji optimizasyonu sorunu üzerinde duran bir çalışma yapmışlardır. Bu konuyu ele almak için, IoT tabanlı kablosuz sensör ağlarındaki (WSN) sensörlerin enerji tüketimini optimize etmek için balina optimizasyon algoritması simülasyonlu tavlama (WOA-SA) adı verilen bir hibrit meta-sezgisel algoritma

sömürülmüştür. Çalışmada, IoT ağını simüle etmek için Xively IoT platformu tercih edilmiş ve ağ 2000 döngü boyunca çalıştırılmıştır. Yük, artık enerji, canlı düğüm sayısı, maliyet fonksiyonu ve sıcaklık gibi çeşitli performans ölçümleri, en uygun koordinatör (CH) noktalarını belirlemek için kullanılmıştır. Önerilen yaklaşım daha sonra çeşitli son teknoloji metotlarla karşılaştırılmıştır. Deney sonuçları, önerilen yaklaşımın mevcut yöntemlerden daha üstün performans gösterdiğini ortaya koymuştur.

Chegari ve ark. (2021), yaptıkları bir çalışmada Fas'ta bulunan zemin kat ve birinci kat (GFFF) konut binalarının iç mekân termal konforunu ve enerji performansını iyileştirmek amacıyla Bina Performans Optimizasyonu (BPO) tekniğine dayanan yeni ve etkin birçok amaçlı optimizasyon yöntemi geliştirmişlerdir. İki hedef arasındaki en uygun dengeyi bulmak için tasarım değişkenleri titizlikle incelenmiştir. Bu metodoloji, Yapay Sınır Ağları (YSA'lar) kullanılarak gerçekleştirilmiştir. TRNSYS yazılımı, YSA'ların öğrenmelerini ayarlayabilmesi için gerekli termal simülasyonları oluşturmak için kullanılmıştır. Elde edilen sonuçlar, bu metodolojinin başarıyla uygulanabildiğini ve farklı önerilen çözümlere yol açtığını göstermiştir. Ancak, en yüksek performansı sergileyen çözümlerin nihayetinde sadece MOPSO sömürülerek korunduğu gözlemlenmiş, bu sayede ısıtma ve soğutma dahil olmak üzere termal ihtiyaçlar toplamının %74,52'sine kadar azaltılırken, iç mekan termal konforu da taban tasarımına göre %4,32 oranında artırılmıştır.

Yuan ve ark. (2023), bina enerji optimizasyonu ile ilgili yaptıkları bir araştırmada, pelikan optimizasyon algoritması (POA) ve tek aday optimize edici (SCO) temelli etkili bir hibrit yöntemi önermişlerdir. Bu hibrit algoritma (POSCO), hem yerel arama gücünden faydalanan tek aday yöntemini hem de etkili global arama yeteneklerine sahip pelikan optimizasyonunu birleştirir. Önerilen POSCO yöntemi, bina optimizasyon görevini gerçekleştirmek üzere geliştirilmiş ve EnergyPlus kodlarıyla entegre edilmiştir. POSCO'nun etkinliği matematiksel test fonksiyonları kullanılarak doğrulanmış ve geleneksel POA ile diğer optimizasyon teknikleriyle karşılaştırılmıştır. POSCO'nun uygulanması, global fonksiyon optimizasyonu için önerilen yöntemin, on üç fonksiyon arasında yedi fonksiyon için en iyi global çözümü sağladığını ve diğer fonksiyonlar için rekabetçi tekniklerle karşılaştırıldığında üstün sonuçlar elde ettiğini göstermiştir. POSCO'nun ofis binalarının yıllık enerji kullanımını azaltmak için kullanılmasıyla, POA prosedürleriyle karşılaştırıldığında enerji kullanımında azalma sağlanmıştır. Ayrıca, POSCO'nun basit POA ve diğer algoritmalarla karşılaştırılması sonucunda, belirli sıcaklık ve aydınlatma koşullarında POSCO'nun daha iyi performans gösterdiği ve enerji

kullanımını azalttığı belirlenmiştir. Tüm veriler, POSCO'nun bina enerji optimizasyon modelleriyle başa çıkmak için umut verici, güvenilir ve uygulanabilir bir strateji olduğunu göstermektedir. Ayrıca, çeşitli iklim koşulları için yapılan bina enerji optimizasyonu bulguları, hava durumu veri setindeki değişikliklerin optimizasyon prosedürünün verimliliği üzerinde sınırlı bir etkiye sahip olduğunu ortaya koymuştur.



3. MATERYAL ve YÖNTEM

3.1 YSA

Yapay sinir ağı, biyolojik sinir ağlarının işleyişinden esinlenerek tasarlanmış bir makine öğrenmesi ve yapay zekâ yöntemidir. Bu yöntem, bilgisayar biliminde ve mühendislik alanlarında karmaşık problemleri çözmek için kullanılan güçlü bir araç olarak kabul edilir. Ayrıca bu yöntem kara kutu yöntemler arasında yer almaktadır.

Yapay sinir ağı, düğümler aracılığıyla sinir hücrelerinin birbiriyle bağlantı kurarak bilgi işlemesi prensibini taklit eder. Her bir düğüm, girdi sinyallerini alır, bunları işler ve bir çıktı sinyali üretir. Bu düğümler, katmanlar halinde düzenlenir ve her bir katmanda birbiriyle bağlantılıdır. Bu bağlantılar, ağı birbirine bağlayan ağırlıklar aracılığıyla temsil edilir (Goodfellow ve ark., 2016).

Yapay sinir ağlarının temel yapı taşı olan bu düğümler, matematiksel işlevlerle tanımlanır. Genellikle, girdi sinyallerini bir ağırlıkla çarparak ve bir aktivasyon fonksiyonuna sokarak işlerler. Bu işlemler, ağı eğitilmesi sırasında ve sonrasında gerçekleşir.

Yapay sinir ağlarının eğitimi, bir öğrenme algoritması sömürülerek gerçekleştirilir. Bu algoritmalar, ağı belirli bir görevi yerine getirecek şekilde ayarlamak için gerçek veri setleri kullanır. En popüler öğrenme algoritmalarından biri, geri yayılım algoritmasıdır. Bu algoritma, ağı çıktılarını ile gerçek değerler arasındaki farkı minimize ederek ağı günceller (Haykin, 1998).

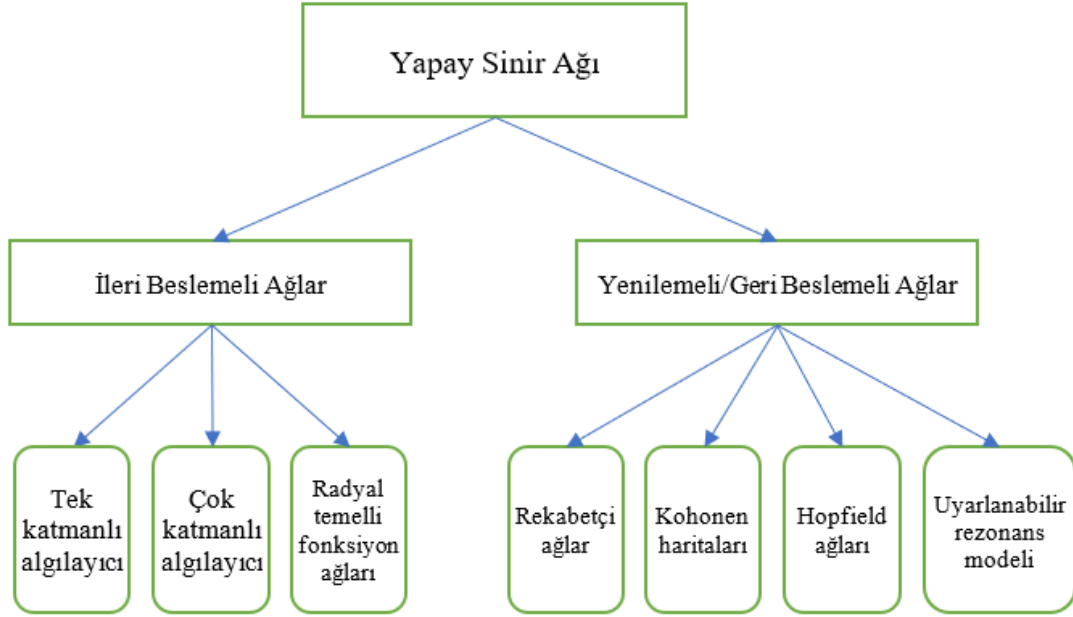
Yapay sinir ağı görüntü ve ses tanıma, doğal dil işleme, doğa olaylarını tahmin etmek, otomatik sürüş, tıbbi tanı ve finansal tahminler gibi birçok alanda başarıyla uygulanmışlardır (LeCun ve ark., 2015).

Bu şekilde, yapay sinir ağı, karmaşık problemleri çözmek için etkili bir yaklaşım sunarlar. Biyolojik sinir sistemlerinden esinlenen bu yapay modelleme teknikleri, teknolojik ilerlemelerin ve yapay zekanın gelişimine önemli katkılarda bulunmaktadır (Haykin, 1998).

3.1.1 YSA Mimarisi

Bir sinir ağındaki düğümlerin yapılandırılma şekilleri, ağı eğitmek amacıyla faydalanılan öğrenme algoritmasıyla ilişkileri oldukça fazladır. Değişik ağ mimarileri için uygun öğrenme algoritmaları gereklidir. Dolayısıyla sinir ağlarının mimarisi öğrenme

algoritmalarından hangisinin kullanılması gerektiğini gösterir. Şekil 3.1’de YSA’nın sınıfları belirtilmiştir (Jain ve ark., 1996).



Şekil 3. 1 YSA mimarileri sınıflandırılması (Eker, 2020)

- **YSA mimarileri sınıflandırılması**

Yapay sinir ağlarının mimarilerinin temeli ileri beslemeli ağlar ile yenilemeli geri beslemeli ağlar olmak üzere gruplandırılır. İleri beslemeli ağları tekil katmanlı (SLP), çok katmanlı (MLP) ağlar ve radyan temelli fonksiyon ağları olmak üzere üç farklı sınıfa bölünebilir (Eker, 2020).

- **Tek Katmanlı Algılayıcılar**

Sinir ağındaki düğümler tabakalar şeklinde sıralanır. En basit ağda düğümleri çıkış tabakasına aksedilen fakat tersi olmayan giriş tabakası mevcuttur. Buradaki ağ çeşidi ileri beslemeli bir ağ olup, döngüsü yoktur. Burada ağa çıkış tabakasını nitelendirmek amacıyla tek katmanlı ağ adı verilmiştir. Giriş tabakasında belirli bir hesap yapılmamış olmasından dolayı önemsenmemiştir (Haykin, 1998).

- **Çok Katmanlı Algılayıcılar**

MLP, örüntüleri tanımada, eğri uydurma ve birçok değişik problem çözümünde sıklıkla yer alan sinir ağıdır. 1960 yılının başlarında ortaya çıkarılan fakat önemli sınırlamaları olduğu gözlenen, algılayıcı (perceptron) sinir ağının gelişmişidir (Noriega, 2005).

MLP, sinir ağının en bilinen, en çok sömürülen türüdür ve ileri beslemelidir. MLP'deki güç, tam anlamıyla doğrusal olmayan aktivasyon fonksiyonları ile elde edilir. Fonksiyonlardan polinom hariç nerdeyse tüm doğrusal olmayan fonksiyonlar bu amaçla kullanılma özelliğine sahiptir. MLP evrensel yaklaşım aracı şeklinde hareket etme özelliğindedir. Eğitime katkı amaçlı geri yayılım algoritması kullanıp, fonksiyonel yaklaşımla, hesaplama sistem yükü öngörüsünde bulunmak ya da polimerizasyonun kimyasal reaksiyon evrimi modeli oluşturmak tarzında farklı farklı bölümlerde bulunan tahminlere ulaşmak gibi büyük ölçüde uygulama yelpazelerinde işlev görebilirler (Popescu ve ark., 2009).

MLP, kaynak düğümleri adı da verilen veri toplama düğümleri bulunduran giriş tabakası, hesaplama düğümleri bulunan gizli tabaka ya da tabakaları ile hesaplama düğümlerinin bulunduğu çıkış tabakasından meydana gelir (Eker, 2020).

MLP'nin yüksek paralellik, doğrusal olmama, hataya dayanıklılık, gürültüye karşı sağlamlık, öğrenme ve yüksek genelleştirme kabiliyetleri tarzında çok çeşitli ve iyi özellikleri mevcuttur. Çok katmanlı algılayıcılar, sınıflandırma, tahmin ve örüntü tanıma, karmaşık ve doğrusal olmayan modelleme tarzında fazlaca çeşidi bulunan problemlere başarılı bir şekilde işlenmiştir (Faris ve ark., 2016).

- **İleri beslemeli sinir ağı**

MLP ağlarında, tabakalardaki sinirler sayısal ağırlıklarla tamamiyle birbiri ile bağlıdır, tüm aktivasyon ve sinir toplama fonksiyonlarını barındırır. Eşitlik 3.1'de tanımlandığı gibi toplama fonksiyonu tüm girdiler ve ağırlıkların çarpımıyla biasın toplamını gösterir. Eşitlikte 3.1'de w_{ij} , I_i 'yi j 'ye bağlayan bağlantı ağırlığı, β_j bias, n giriş sinirlerinin toplam sayısıdır. Toplama fonksiyonunun çıktısı bir aktivasyon fonksiyonuna bir giriş olacaktır. j düğümünün çıkışı Eşitlik 3.3'te ifade edildiği gibidir.

$$S_j = \sum_{i=1}^n w_{ij} I_i + \beta_j \quad (3.1)$$

$$f(x) = \frac{1}{1+e^{-x}} \quad (3.2)$$

$$y_i = f_j(\sum_{i=1}^n w_{ij} I_i + \beta_j) \quad (3.3)$$

Yapay sinir ağının yapısı meydana getirildiğinde, ağın parametrelerini belirlemek maksadıyla modele öğrenme süreci işlenir. Yapay sinir ağı kapsamındaki öğrenme süreci, ağın belirlenmiş olan bir talimatı dikkate alarak yapması amacıyla ağ mimarisi ve bağlantı ağırlıkları güncelleme problemi şeklinde varsayılabilir. Genellikle ağ bağlantısının ağırlıklarını hazır eğitim modelinden öğrenmesi gerekir. Ağdaki ağırlıkları defalarca

güncelleyerek performansı giderek artar. Ağın eğitim süreci, MLP ağının değişik tarzdaki problemlere çözüm üretmek amaçlı gücünü gösteren zorlu bir vazifedir (Eker, 2020).

3.2 Sezgisel Üstü Algoritma

Geleneksel algoritmalar çoğunlukla deterministiktir. Örnek olarak doğrusal programlamadaki simpleks yöntemi deterministiktir. Deterministik optimizasyon algoritmalarının çoğu gradyan bilgisini kullanır ve bunlara gradyan tabanlı algoritmalar denilmektedir. Mesela yaygın olarak kullanılan Newton-Raphson algoritması, fonksiyon türevlerini ve değerlerini kullandığı için gradyan tabanlıdır ve düzgün unimodal problemler için oldukça iyi çalışır. Ancak amaç fonksiyonunda süreksizlik varsa etkin sonuçlara ulaşılmaz. Böyle durumlarda türev gerektirmeyen algoritmalar tercih etmek daha makul olur. Bu tarz algoritmalar sadece fonksiyona ait değerleri kullanır. Nelder-Mead simplex ve Hooke- Jeeves pattern search algoritmaları gradyan içermeyen algoritmaların örnekleridir.

Olasılıksal kurallar ile çerçevelendirilmiş algoritmalar sezgisel ve sezgisel üstü olmak üzere iki kategoriye ayrılır, fakat aralarındaki fark azdır. Basitçe ifade etmek gerekirse, sezgisel deneme yanılma yoluyla sonuca ulaşmak anlamında kullanılabilir. Bu algoritmaların en avantajlı boyutu kısa zamanda sonuca ulaştırması iken dezavantajı en iyi çözüme ulaşma garantisi vermemesidir.


Sezgisel üstü algoritmalar sezgisel algoritmaların bir üst yapısıdır. Aramayı keşif ve sömürü olarak iki faza ayırırken başlangıçta bir rastgele aday kümesi oluşturur ve tekrarlı hareket ederek her tekrarda daha iyi çözüme ulaşmaya çalışır. Yerel çözümden küresel çözüme geçişte rastgele seçimler yaparak etkili bir plan sunar.

Herhangi bir sezgisel üstü algoritmanın temelinde iki ana bileşen bulunmaktadır. Bu bileşenler, yoğunlaştırma ve çeşitlendirme veya sömürü ve keşfetmedir. Çeşitlendirme, geniş bir arama alanında farklı çözümler üreterek yeni bölgeleri keşfetmeyi amaçlar. Yoğunlaştırma ise, bulunan optimum çözümlerin bilgisini kullanarak yerel bir bölgeye odaklanmayı ve burada daha iyi çözümler bulmayı hedefler. Bu süreç, en iyi çözümlerin belirlenmesiyle birlikte gerçekleşir.

3.2.1 Salp Sürü Algoritması (SSA)

Sürü zekâsı tekniklerine dayalı algoritmalar, doğada toplu halde hareket eden canlıların gösterdikleri ortak davranışları taklit ederler. SSA algoritması da salp topluluklarının davranışlarını taklit eden sürü bazlı bir algoritmadır. Salp sürüsü, yiyecek

arama davranışı göstermek için belli bir zincir kuran, hızlı ve birbiriyle uyumlu hareket eden bir topluluktur. Bu organizmanın hareket kabiliyeti suyu pompalayarak gerçekleşir ve kendine özgü bir zincir kurma marifetiyle plaktonları avlayarak beslenirler. Zincirdeki öncü salplar yiyecek yönünde hareket ederken, takipçi salplar sürü davranışı gibi bir önceki hareketi taklit eder. Salpların bu ritmik ve sürü zekasına dayalı davranışları Salp Swarm Algoritmasının (SSA) ilham kaynağıdır. SSA algoritmasının farklı boyutlarda problemlerin optimizasyonunda verimli bir şekilde çalıştığı bilimsel kaynaklarda mevcuttur (Ali ve ark., 2019; Dhawan ve ark., 2021; Hegazy ve ark., 2019; Mirjalili ve ark., 2017; Zhang ve ark., 2018).



Şekil 3. 2 (A) Salp , (B) Salp zinciri (Abualigah ve ark., 2020)

SSA algoritmasının optimizasyon sürecinde ortaya çıkan güçlü ve zayıf yönleri mevcuttur. Üstün yönleri, basitlik, yakınsama ivmesi güçlü, optimizasyon sürecindeki zamanlamasının oldukça makul düzeyde olması, etkili bir küresel arama ve yakınsama kabiliyeti, farklı hibridasyon stratejilerinde uyarlanabilen sağlam ve esnek bir yapıya sahip olması iken en belirgin dezavantajı erken yakınsamadan muzdarip olmasıdır (Abbassi ve ark., 2019; Abualigah ve ark., 2020; Masdari ve ark., 2019).

SSA algoritmasının matematiksel modellenmesi Eşitlik 5, 6 ve 7’de verilmiştir. Yukarıda bahsedilen zincire salp zinciri adı verilirse bu zincir liderler(θ) ve takipçiler (α) olarak iki bölüme ayrılabilir (Wang ve ark., 2023).

SSA'da, bu salp zincirinin popülasyonu eşit olarak iki bölüme ayrılır. Lider gıda kaynağının konumuna gerçek zamanlı olarak hareket eder ($S : \forall S \in \theta$) bu optimum yani en uygun çözümdür. Liderin konumu Eşitlik 3.4'te ifade edilmiştir (Mirjalili ve ark., 2017).

$$S_j = \begin{cases} F_j + c_1 \left((ub_j - lb_j)c_2 + lb_j \right) & c_3 \geq 0 \\ F_j - c_1 \left((ub_j - lb_j)c_2 + lb_j \right) & c_3 < 0 \end{cases} \quad (3.4)$$

Burada F_j besinin konumunu, ub_j ve lb_j dizideki üst ve alt sınırları gösterir. Sırasıyla c_2 ve c_3 , $[0, 1]$ aralığında rastgele sayılardır. c_1 parametresi bir kontrol parametresi olup optimizasyon sürecinde keşif ve sömürü safhalarını ayarlamakta önemli bir yer tutar, c_1 Eşitlik 3.5'te ifade edilmiştir.

$$c_1 = 2e^{-\left(\frac{4t}{T_{max}}\right)^2} \quad (3.5)$$

Burada t ve T_{max} sırasıyla mevcut ve maksimum yineleme sayısıdır.


Daha sonraki, i 'ninci takipçi $M_j^i (M : \forall M \in \alpha)$, lidere en yakın takipçinin konumunu Newton'un hareket yasası ikinci prensibine göre günceller. i 'ninci takipçinin konumu Eşitlik 3.6'ya göre modellenir.

$$M_j^i = \frac{1}{2}(M_j^i + M_j^{i-1}) \quad i \geq 2 \quad (3.6)$$

3.2.2 Çayır Köpeği Optimizasyon (PDO) Algoritması

PDO algoritması, Amerika'da yaşayan ve çayır köpekleri (PD) adı verilen bir kemirgen türünün hareketlerinden ilham alınarak oluşturulmuştur (Hoogland, 1995). Önerilen algoritma, keşif ve sömürü aşamalarını gerçekleştirmek için çayır köpeğinin dört davranışını taklit etmektedir. PD'lerin yiyecek arama ve yuva kurma faaliyetleri, PDO için keşif davranışı sağlamak amacıyla kullanılır. PD'ler yuvalarını bol miktarda besin kaynağının etrafına kurarlar. PDO'nun keşif aşamasını oluşturan sürü davranışı yeni bir besin kaynağı aramak ve besin kaynağı tükendiğinde onun etrafında yeni yuvalar inşa etmeleridir. PDO'nun sömürü aşamasını oluşturan sürü davranışı ise, iki benzersiz iletişime veya bip sesine verdikleri özel yanıtlardır. PD, yırtıcı tehditlerden gıda bulunabilirliğine kadar farklı senaryolara yönelik sinyallere veya seslere sahiptir. İletişim

becerileri, beslenme ihtiyaçlarının karşılanmasında ve yırtıcı hayvanlara karşı korunma yeteneklerinde önemli bir rol oynamaktadır. Bu iki spesifik davranış, PD'lerin belirli veya gelecek vaat eden bir yere yaklaşmasına yol açar. PDO algoritması başlatma, uygunluk fonksiyonu değerlendirme, keşif ve sömürü aşamalarından oluşur (Eker ve ark., 2023).



Şekil 3.3 Çayır köpeği kolonisi (Ezugwu ve ark., 2022)

Aşağıdaki matris bir kolonideki tüm grupların konumunu ifade eder.

$$CT = \begin{bmatrix} CT_{1,1} & \cdots & CT_{1,d} \\ \vdots & \ddots & \vdots \\ CT_{m,1} & \cdots & CT_{m,d} \end{bmatrix} \quad (3.7)$$

Burada $CT_{i,j}$ ($n \leq m$), bir kolonideki i 'ninci grubun j 'ninci boyutunu temsil eder. Aşağıdaki tanım, bir gruptaki tüm PD'lerin konumunu ifade eder; burada $PD_{i,j}$ ($n \leq m$), i 'ninci gruptaki j 'ninci PD'nin boyutunu temsil eder.

$$PD = \begin{bmatrix} PD_{1,1} & \cdots & PD_{1,d} \\ \vdots & \ddots & \vdots \\ PD_{m,1} & \cdots & PD_{m,d} \end{bmatrix} \quad (3.8)$$

Her grup ve PD Eşitlik 3.9 ve 3.10'de gösterildiği gibi tek bir dağılımla temsil edilir.

$$CT_{i,j} = U(0,1) \times (UB_j - LB_j) + LB_j \quad (3.9)$$

$$PD_{i,j} = U(0,1) \times (Ub_j - Lb_j) + Lb_j \quad (3.10)$$

UB_j ve LB_j boyutsal optimizasyon probleminin alt ve üst sınırlarını ifade ederken, j boyutlu optimizasyon problemi, $ub_j = \frac{UB_j}{m}$, $lb_j = \frac{LB_j}{m}$ ve $U(0,1)$, 0 ile 1 aralığında düzgün dağılıma sahip herhangi bir sayıdır.

Her PD'nin uygunluk fonksiyonunun değeri, belirli bir kaynaktaki yiyeceğin kalitesini, yeni yuvalar inşa etme potansiyelini ve yırtıcı önleme uyarılarına doğru tepkiyi temsil eder. Uygunluk fonksiyonu değerlerini saklayan dizi sıralanır ve elde edilen minimum uygunluk değeri, verilen minimizasyon problemi için en iyi çözüm olarak ilan edilir. Sonraki üç en iyi değer, yırtıcılardan kaçmalarına yardımcı olan yuva inşası için en iyi değerle birlikte dikkate alınır.

$$f(PD) = \begin{bmatrix} f_1[PD_{1,1} & \cdots & PD_{1,d}] \\ \vdots & \ddots & \vdots \\ f_n[PD_{m,1} & \cdots & PD_{m,d}] \end{bmatrix} \quad (3.11)$$

PDO'da keşif ve sömürü arasındaki geçişler dört aşamaya ayrılmıştır. Bu aşamalara maksimum yinelemenin 4'e bölünmesiyle ulaşılır. Açıklamada ilk iki strateji kullanılmıştır. Rasyon aşaması ($iter < \frac{\max_iter}{4}$ ve $\frac{\max_iter}{4} \leq iter < \frac{\max_iter}{2}$) ve son iki strateji ($\frac{\max_iter}{2} \leq iter < 3 \frac{\max_iter}{4}$ ve $3 \frac{\max_iter}{4} \leq iter \leq \max_iter$) kullanımıyla uygulanır.

Keşif aşamasında PD'lerin hareketleri Levy uçuş modeli ile yakalanarak tek bir alanda yoğunlaşmanın önüne geçilmektedir. Bulunan kaynak özel bir sesle gruba bildirilir ve yemeğin kalitesine göre karar verilir. Konum güncellemesi Eşitlik 3.12'de tanımlanmıştır.

$$PD_{i+1,j+1} = GBest_{i,j} - eCBest_{i,j} \times \rho - CPD_{i,j} \times Levy(n), \quad \forall iter < \frac{\max_iter}{4} \quad (3.12)$$

$$PD_{i+1,j+1} = GBest_{i,j} \times rPD \times DS \times Levy(n), \quad \forall \frac{\max_iter}{4} \leq iter < \frac{\max_iter}{2} \quad (3.13)$$

Burada $GBest_{i,j}$, elde edilen en iyi global değerdir, $eCBest_{i,j}$ elde edilen en iyi çözümün etkisidir ve Eşitlik 3.14'te ifade edilir, ρ sabit özel yiyecek kaynağı alarmıdır (*set to 0.1 kHz*), rPD bir alarmın konumudur. Üretilen rastgele çözümde rPD , Eşitlik 16 ile ifade edilen, kolonideki tüm PD'lerin toplam randomize etkisini ifade eder.

$$eCBest_{i,j} = GBest_{i,j} \times \Delta + \frac{PD_{i,j} \times \text{mean}(PD_{n,m})}{GBest_{i,j} \times (UB_j - LB_j) + \Delta} \quad (3.14)$$

$$CPD_{i,j} = \frac{GBest_{i,j} - rPD_{i,j}}{GBest_{i,j} + \Delta} \quad (3.15)$$

Eşitlik 17'de ifade edilen DS terimi, besin kaynağına bağlı olarak kazma gücünü ifade etmektedir. $Levy(n)$ bir Lévy dağılımıdır ve problem uzayının daha iyi ve daha etkili bir şekilde keşfedilmesine katkıda bulunur.

$$DS = 1.5 \times r \times \left(1 - \frac{iter}{max_iter}\right)^{\left(2 \frac{iter}{max_iter}\right)} \quad (3.16)$$

Verilen eşitliklerde r , mevcut yinelemelere bağlı olarak -1 ile 1 arasında değerler almakta ve keşif için olasılıksal özellik sağlamaktadır. Δ , PD 'lerde mevcut olan küçük farklılıkları açıklayan küçük bir sayıyı temsil eder.

PD 'nin iki ayrı sese (iletişim ve uyarı) verdiği yanıt, sömürü aşamasını oluşturur. Beslenme seslerine ve yırtıcı hayvanlardan korunma seslerine verdikleri iki farklı tepki, sömürü aşamasında PD 'nin ümit verici bir şekilde yaklaşmasıyla sonuçlanır. Bu aşamada sırasıyla Δ ve $3 \frac{max_iter}{4} \leq iter \leq max_iter$ stratejileri takip edilir. Bu iki strateji Eşitlik 3.17 ve 3.18'de ifade edilmektedir.

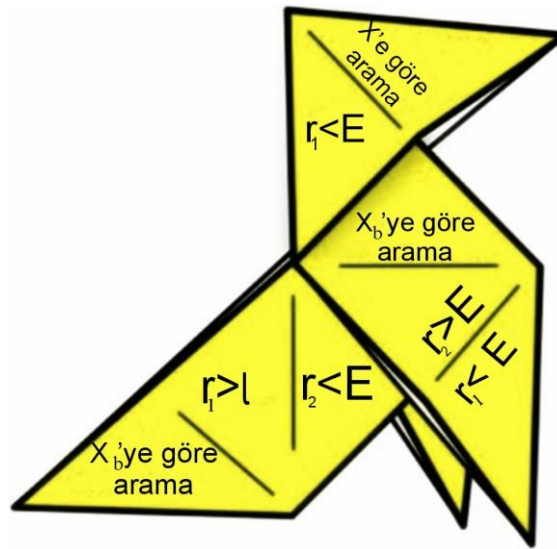
$$PD_{i+1,j+1} = GBest_{i,j} - eCBest_{i,j} \times \varepsilon - CPD_{i,j} \times rand \quad (3.17)$$

$$PD_{i+1,j+1} = GBest_{i,j} \times PE \times rand \quad (3.18)$$

burada ε besin kaynağının kalitesini ifade eder, $PD_{i+1,j+1} = GBest_{i,j} \times PE \times rand$, kolonideki PD 'lerin kümülatif etkisidir ve PE Eşitlik 3.19'da formüle edilen avcılarının etkisidir.

$$PE = 1.5 \times \left(1 - \frac{iter}{max_iter}\right)^{\left(2 \frac{iter}{max_iter}\right)} \quad (3.19)$$

3.2.3 Açlık Oyunları Arama (HGS) Algoritması



Şekil 3. 4 HGS optimizasyon süreci (Yang ve ark., 2021)

Hayvanların hayatta kalma içgüdüğü, HGS algoritmasının geliştirilmesini motive etmiştir. Hayvanlar arasında açlığın tetiklediği faaliyetler ve davranışsal seçimler, HGS algoritması tarafından bir dizi oyun kuralı olarak değerlendirilmektedir. Yiyecek arama sırasında sosyal hayvanlar çoğunlukla iş birliği yapar. Böyle bir işbirlikçi iletişim ve yiyecek arama davranışı Eşitlik 3.20 ile temsil edilir.

$$X(\vec{t} + 1) = \begin{cases} G_1: \overrightarrow{X}(t). (1 + randn(1)), r_1 < l \\ G_2 = \overrightarrow{W}_1 \cdot \overrightarrow{X}_b + \vec{R} \cdot \overrightarrow{W}_2 \cdot |\overrightarrow{X}_b - \overrightarrow{X}(t)|, r_1 > l, r_2 > E \\ G_3 = \overrightarrow{W}_1 \cdot \overrightarrow{X}_b - \vec{R} \cdot \overrightarrow{W}_2 \cdot |\overrightarrow{X}_b - \overrightarrow{X}(t)|, r_1 > l, r_2 < E \end{cases} \quad (3.20)$$

burada $[0,1]$ aralığında iki rastgele sayı r_1 ve r_2 ile gösterilir; mevcut yineleme t ile gösterilir ve normal dağılımı karşılayan rastgele bir sayı $randn(1)$ ile temsil edilir. Açlık ağırlıkları W_1 ve W_2 ile gösterilir. Her bir aracının ve en iyi aracının konumları, mevcut yineleme için sırasıyla $W(t)$ ve X_b ile temsil edilir. l parametresi algoritmanın geliştirilmesine yardımcı olur. G_1, G_2 ve G_3 her bir aralıktaki açlık oyununu simgeler. $R, [-a, a]$ dahilindeki bir sayıyı temsil eder ve bu sayı aşağıdaki şekilde hesaplanır:

$$\vec{R} = 2 \times shrink \times rand - shrink \quad (3.21)$$

$$shrink = 2 \times \left(1 - \frac{t}{T}\right) \text{ olduğunda, } rand [0,1] \text{ dahilinde rastgele bir sayıdır ve } T$$

maksimum yineleme sayısıdır. Eşitlik 3.20'de verilen E parametresi tüm pozisyonlar için bir varyasyon kontrolünü temsil eder ve şu şekilde tanımlanır:

$$E = sech(|F(i) - BF|), i \in 1, 2, \dots, n \quad (3.22)$$

Burada $F(i)$ ve BF sırasıyla her bir ajanın en uygun değeri ve o ana kadar elde edilen en uygun değeridir. $sech$ 'in hiperbolik fonksiyonu $2/(e^x + e^{-x})$ olarak tanımlanır. Bireylerin açlık özellikleri matematiksel olarak simüle edilir. Eşitliklerde tanımlanan açlık ağırlıkları Eşitlik 3.23 ile 3.24'te gösterilmiştir:

$$\overrightarrow{W}_1(i) = \begin{cases} h(i) \cdot \frac{N}{Sum_h} \times r_4, r_3 < l \\ 1, r_3 > l \end{cases} \quad (3.23)$$

$$\overrightarrow{W}_2(i) = (1 - e^{-|h(i) - Sum_h|}) \times r_5 \times 2 \quad (3.24)$$

Burada N sürü büyüklüğünü, h ise bireylere yönelik açlığı ifade etmektedir. Ayrıca r_3, r_4 ve $r_5, [0,1]$ aralığında rastgele sayılardır ve Sum_h , sürünün açlık durum toplamını ifade eder. $h(i)$ parametresi aşağıdaki gibi tanımlanır:

$$h(i) = \begin{cases} 0, All\ fit(i) == BF \\ h(i) + H, All\ fit(i) \neq BF \end{cases} \quad (3.25)$$

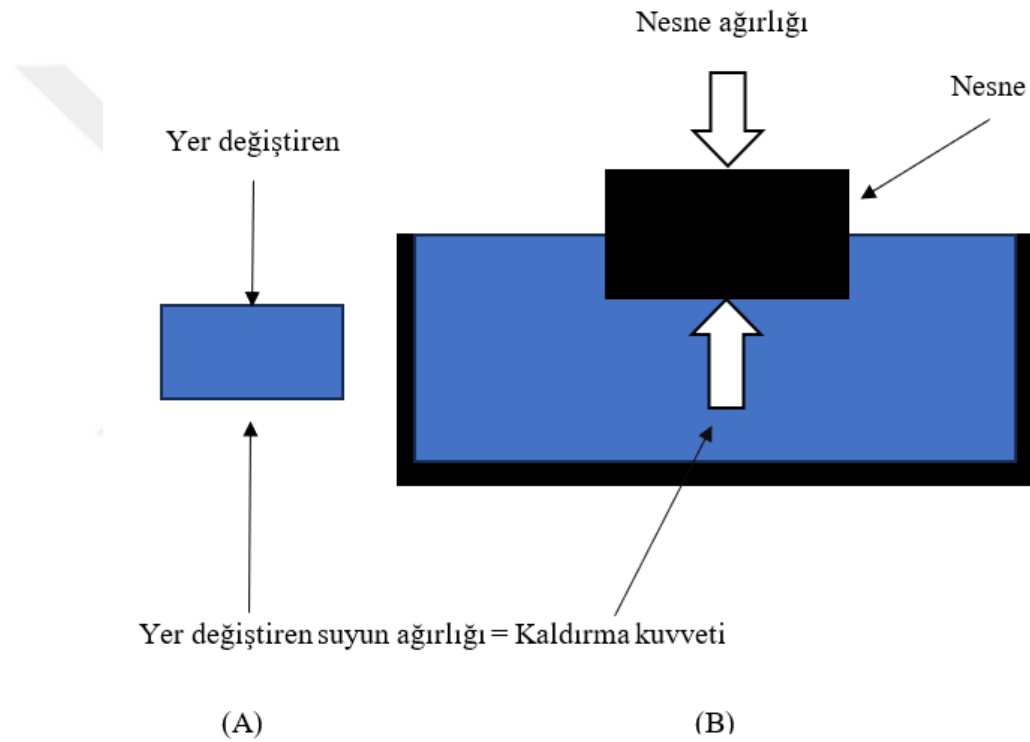
Burada $All\ fit(i)$, mevcut iterasyondaki her bir ajanın uygunluğunu hafızaya alır ve BF , o iterasyona kadar elde edilen en uygun değeri ifade eder.

H terimi aşağıdaki şekilde hesaplanan açıklık hissini ifade eder:

$$H = \begin{cases} LH \times (1 + R), TH < LH \\ TH, TH \geq LH \end{cases} \quad (3.26)$$

Burada $TH = (F(i) - \frac{BF}{(WF-BF)}) \times r_6 \times 2 \times (UB - LB)$. Yukarıdaki eşitlikte LH alt sınırı temsil ederken, UB ve LB sırasıyla özellik uzayına ilişkin üst ve alt sınırlardır. $F(i)$ her bir ajanın uygunluk değerini temsil eder ve WF o ana kadar elde edilen en kötü uygunluk değerini belirtir. Şekil 3.4 optimizasyon görevleri için HGS algoritmasının mantığını temsil etmektedir (Izci ve ark., 2022).

3.2.4 Arşimet Optimizasyon Algoritması (AOA)



Şekil 3. 5 (A) Yer değiştiren sıvının hacmi, (B) Bir nesne bir sıvıya batırılmıştır (Hashim ve ark., 2021)

Arşimet'in suyun kaldırma kuvvetini baz alarak oluşturulmuş bir algoritma olan AOA sürü temelli olarak tasarlanmıştır. Sürüdeki bireyler ise suya batırılmış olan nesnelere oluşmaktadır. AOA, nesnelerin yoğunluk ve hacimleri ile hareket ivmelerine göre sıralanarak rastgele bir aday başlangıç kümesi oluşturur. AOA, başlangıç kümesini değerlendirerek sonlandırma ölçütü sağlanana kadar iteratif olarak çözüme yürür. Tüm nesnelerin hacmi ve yoğunluğu AOA aracılığıyla iteratif olarak güncellenir. Komşu nesneler ile çarpışmayı önlemek adına ivme her iterasyonda güncellenir. Nesneye ait ivme, herhangi bir komşu nesneyle çarpışma haline göre güncellenir. Aynı zamanda hacim ve yoğunluğun da güncellenmesiyle nesnenin yeni konumu belirlenmiş olur.

AOA'nın matematiksel modeli ise aşağıda ifade edilmiştir (Hashim ve ark., 2021).

$$O_i = lb_i + rand \times (ub_i - lb_i); i = 1, 2, \dots, N \quad (3.27)$$

burada O_i , N nesneden oluşan bir popülasyondaki i 'nci nesnedir. lb_i ve ub_i sırasıyla arama uzayının alt ve üst sınırlarıdır. Eşitlik 3.28 kullanılarak her i . nesne için hacim ve yoğunluk sıfırlanabilir.

$$den_i = rand$$

$$vol_i = rand \quad (3.28)$$

$rand$, D boyutlu bir vektördür ve $[0,1]$ arasında rastgele sayı üretir. Ve son olarak, Eşitlik 3.29 kullanarak i . nesnenin ivmesini (acc) başlatalım :

$$acc_i = lb_i + rand \times (ub_i - lb_i) \quad (3.29)$$

Bu adımda başlangıç popülasyonu değerlendirilir ve en iyi uygunluk değerine sahip nesne seçilir. x_{best} , den_{best} , vol_{best} , ve acc_{best} atanır.

$t + 1$ yinelemesi için i nesnesinin yoğunluğu ve hacmi Eşitlik 3.30 kullanılarak güncellenir:

$$den_i^{t+1} = den_i^t + rand \times (den_{best} - den_i^t)$$

$$vol_i^{t+1} = vol_i^t + rand \times (vol_{best} - vol_i^t) \quad (3.30)$$

burada vol_{best} ve den_{best} en iyi nesneyle ilişkili hacim ve yoğunluktur ayrıca $rand$ düzgün dağıtılmış rastgele sayıdır.

Cisimler başlangıçta çarpışır ve ardından bir denge durumuna ulaşmaya çalışırlar. Bu süreç, Eşitlik 3.31'de tanımlanan ve keşiften sömürü aşamasına geçişi sağlayan transfer TF operatörü aracılığıyla gerçekleşir.

$$TF = \exp\left(\frac{t-t_{max}}{t_{max}}\right) \quad (3.31)$$

burada transfer fonksiyonu TF 'nin sonucu 1'e ulaşana kadar zamanla kademeli olarak artar. Burada t mevcut iterasyonu gösterirken t_{max} çalışılması istenen iterasyon sayısını gösterir.

$$d^{t+1} = \exp\left(\frac{t_{max}-t}{t_{max}}\right) - \left(\frac{t}{t_{max}}\right) \quad (3.32)$$

d^{t+1} 'in zamanla azalması, halihazırda tanımlanmış gelecek vaat eden bölgede yakınsama yeteneği sağlar. Bu değişkenin doğru şekilde ele alınması sonucunda AOA'da sömürü ve keşif arasındaki denge sağlanmış olur.

$TF \leq 0.5$ ise, nesneneler arasında çarpışma meydana gelir, bu durumda rastgele bir malzeme (mr) seçilmeli ve ivme Eşitlik 3.33 kullanılarak $(t + 1)$ iterasyonu için güncellenmelidir.

$$acc_i^{t+1} = \frac{den_{mr} + vol_{mr} \times acc_{mr}}{den_i^{t+1} \times vol_i^{t+1}} \quad (3.33)$$

burada den_i , vol_i ve acc_i nesnesinin yoğunluğu, hacmi ve ivmesidir. Oysa acc_{mr} , den_{mr} ve vol_{mr} rastgele malzemenin ivmesi, yoğunluğu ve hacmidir. $TF \leq 0.5$ 'in yinelemelerin üçte biri sırasında araştırmayı garanti ettiğini belirtmek önemlidir. 0.5 dışında bir değer uygulanması arama-sömürme davranışını değiştirecektir.

$$acc_i^{t+1} = \frac{den_{mr} + vol_{mr} \times acc_{mr}}{den_i^{t+1} \times vol_i^{t+1}} \quad (3.34)$$

burada acc_{best} en iyi nesnenin ivmesidir.

Değişim yüzdesini hesaplamak için Eşitlik 3.35 kullanılarak ivme normalleştirilmelidir.

$$acc_{i-norm}^{t+1} = u \times \frac{acc_i^{t+1} - \min(acc)}{\max(acc) - \min(acc)} + 1 \quad (3.35)$$

Eşitliklerde verilen u ve l normalleştirme aralığıdır ve sırasıyla 0.9 ve 0.1'e ayarlanır. $acc_{i,norm}^{t+1}$ her ajanın değiştireceği adımın yüzdesini belirler. i nesnesi küresel en iyi değerden uzaksa, ivme değeri artar ve nesne keşif aşamasına geçiş yapar, aksi takdirde sömürü aşamasına geçer. Bu durum, aramanın keşiften sömürü aşamasına nasıl evrildiğini gösterir. Normal şartlarda ivme faktörü yüksek bir başlangıç değeriyle başlar ve zamanla azalır. Bu, arama ajanlarının küresel en iyi çözüme ilerlerken yerel çözümlerden de uzaklaşmalarına yardımcı olur. Ancak, keşif aşamasında kalmak için normalden daha fazla zaman gerektiren bazı arama araçları olduğunu belirtmek gerekir. Bu nedenle, AOA, keşif ve sömürü arasındaki dengeyi korur.

Eğer $TF \leq 0.5$ (keşif aşaması) ise, Eşitlik 3.36 kullanılarak i 'nci nesnenin sonraki iterasyon için konumu $t + 1$ olur.

$$x_i^{t+1} = x_i^t + C_1 \times rand \times acc_{i-norm}^{t+1} \times d \times (x_{rand} - x_i^t) \quad (3.36)$$

burada C_1 sabiti 2'ye eşittir. Aksi takdirde, $TF > 0.5$ ise (sömürü aşaması), nesnelere Eşitlik 3.37'i kullanarak konumlarını günceller.

$$x_i^{t+1} = x_{best}^t + F \times C_2 \times rand \times acc_{i-norm}^{t+1} \times d \times (T \times x_{best} - x_i^t) \quad (3.37)$$

burada C_2 , 6'ya eşit bir sabittir. T zamanla artar ve transfer operatörüyle doğru orantılıdır ve $T = C_3 \times TF$ kullanılarak tanımlanır. T aralıktaki zamanla artar $[C_3 \times 0.3, 1]$ ve başlangıçta en iyi konumdan belirli bir yüzde alır. Düşük yüzdeyle başlar çünkü bu, en iyi konum ile mevcut konum arasında büyük bir fark oluşmasına neden olur, dolayısıyla rastgele yürüyüşün adım boyutu yüksek olur.

F , Eşitlik 3.38 kullanılarak yön değişir.

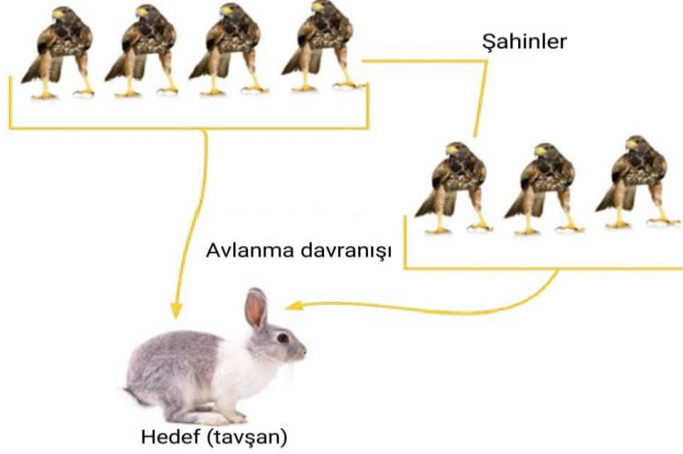
$$F = \{-1 \text{ if } P > 0.5, +1 \text{ if } P \leq 0.5\} \quad (3.38)$$

burada $P = 2 \times rand - C_4$ 'dür.

Her nesneyi f amaç fonksiyonunu kullanarak, değerlendirerek ve şu ana kadar bulunan en iyi çözümü hatırlayarak x_{best} , den_{best} , vol_{best} ve acc_{best} 'i atar.

3.2.5 Harris Şahinleri Optimizasyonu (HHO) Algoritması

HHO algoritması keşif ve sömürü eğilimleri, Harris şahinlerinin avı keşfetme, sürpriz saldırı ve saldırı stratejisi sırasındaki davranışlarından ilham aldı. Yazarlar mümkün olduğunca bu karmaşık doğal desenlerin ana özelliklerini yakalamaya çalıştılar. HHO'nun mantığı ve matematiksel modeli, keşif aşaması, keşiften sömürüye geçiş ve sömürü aşaması olmak üzere üç ana aşamadan oluşmuştur (Alabool ve ark., 2021).



Şekil 3. 6 Harris şahinleri optimizasyon algoritmasının ilhamı (Anonymous, 2020).

Keşif aşamasında şahinlerin avı keşfetmedeki konumlarını açıklar. İki stratejiye bağlıdır. İlk strateji, atmacaların gerçek üyelerin konumlarına göre avı nasıl tespit ettiğini belirler. Ancak ikinci strateji şahinlerin rastgele bir ağaçtaki tüneklere göre avını nasıl tespit ettiğini belirtir (X_{rand}), Eşitlik 3.39 ile modellenmiştir. $X_i, i = 1, 2, 3, 4, \dots, N$ burada N modellenen şahin sayısıdır.

$$X_i(t+1) = \begin{cases} X_{rand}(t) - r_1 |X_{rand}(t) - 2r_2 X(t)|, & q \geq 0.5 \\ (X_{prey}(t) - X_m(t) - Y), & q < 0.5 \end{cases} \quad (3.39)$$

$X_i(t+1)$ şahinlerin bir sonraki yinelemede güncellenmiş konumunu temsil eder. $X_{rand}(t)$ şahinlerin mevcut konumunu temsil eder, r_1, r_2, r_3, r_4 ve q , $(0,1)$ kümesi içindeki rastgele sayıları temsil eder. $X_{prey}(t)$ avın konumunu temsil eder. $X_m(t)$ Eşitlik 3.40'de formüle edilen tüm şahinler için pozisyonların ortalamasını temsil eder.

$$X_m(t) = \frac{\sum_{i=1}^N X_i(t)}{N} \quad (3.40)$$

$Y = r_3(LB + r_4(UB - LB))$ değişkenlerin üst ve alt sınırları arasındaki farkı temsil eder.

HHO'da bu aşama, şahinlerin keşiften sömürüye kadar değişen davranışlarını tanımlamayı ve modellemeyi amaçlamaktadır. Bu davranış kaçan enerjiye bağlıdır.

$$E = 2E_0 \left(1 - \frac{T}{t}\right) \quad (3.41)$$

burada E avın iterasyonlar boyunca azalma eğilimdeki kaçış enerjisini, Detayda, E_0 $(-1,1)$ arasında rastgele değişen avın başlangıç enerjisidir. Av enerjisinin 0'dan 1'e yükselmesi avın güçlendiğini, av enerjisinin 0'dan -1 'e düşmesi ise avın zayıfladığını gösterir. E'nin dinamik davranışı iki çalışma ve 500 yineleme sırasında gösterilmektedir. Diyagram tüm durumlar için geçerlidir ve bu model orijinal yöntemin bir bileşenidir. Eğer

değeri $|E| \geq 1$ ise, o zaman keşif aşaması yarım kalacak, değeri $|E| < 1$ ise, o zaman sömürü aşaması gerçekleşiyor.

Şahinlerin iz sürme stratejileri ve avlardan kaçma davranışları bu sömürü aşamasını oluşturan temel iki unsurdur. Bu nedenle, bu aşama şahinlerin keşfedilen av üzerindeki sürpriz saldırı davranışını modellemeyi amaçlamaktadır. Bunu yapmak için dört takip stratejisi, sert kuşatma, yumuşak kuşatma, aşamalı hızlı dalışlarla yumuşak kuşatma ve aşamalı hızlı dalışlarla sert kuşatma önerilmektedir. HHO'da takip stratejileri arasında geçiş yapmak iki parametreye bağlıdır.

Kaçan enerji (E): $|E| \geq 0.5$ ise, avın hala yeterli enerjisi var.

$|E| < 0.5$ ise, avın yeterli enerjisi yok.

Kaçış şansı (r): $r \geq 0.5$ ise, av başarı ile kaçamıyor (yumuşak kuşatma oluşturulmuş).

$r < 0.5$ ise, av başarıyla kaçıyor (sert kuşatma oluşturulmuş).

Aşağıdaki durumlarda yumuşak kuşatma gerçekleşir. $|E| \geq 0.5$ ve $r \geq 0.5$. Bu, atmacalardan kaçış sırasında avın enerjisinin çekilmesi nedeniyle avın başarılı bir şekilde kaçamayacağı anlamına gelir. Eşitlik 3.42'te ki kural bu tür davranışların modelini sunar.

$$X_i(t+1): \Delta X(t) = E |JX_{prey}(t) - X(t)| \quad (3.42)$$

$$\Delta X(t) = X_{prey}(t) - X(t) \quad (3.43)$$

$\Delta X(t)$ tavşanın konum vektörü ile yinelemedeki mevcut konum arasındaki farkı temsil eder. $J = 2(1 - r_5)$ Her yinelemede rastgele değişen avdan kaçma prosedürüdür. r_5 , (0,1) içindeki rastgele sayıyı temsil eder.

Stratejide iki zorlu kuşatma gerçekleşir: $|E| < 0.5$ ve $r \geq 0.5$, bu avın tükendiği için başarılı bir şekilde kaçamayacağı anlamına gelir. Böyle bir durumda şahinlerin güncellenmiş konumları Eşitlik 3.44 ile verilmektedir.

$$X(t+1) = X_{prey}(t) - E |\Delta X(t)| \quad (3.44)$$

Bu strateji modeli, avın mantıklı bir şekilde uzaklaşmak için sağlam ve yeterli enerjiye sahip olduğu durumlarda şahinlerin konumlarını günceller. $|E| \geq 0.5$ ise, şahinler hâlâ yumuşak bir kuşatma oluşturuyor $r < 0.5$ ise, bir durumda şahinlerin ava doğru mümkün olan en iyi dalışa karar vermesi gerekir. Bu, birkaç hareketin gerçekleştirilmesi, eşitlikler kullanılarak yeni hareketlerin değerlendirilmesi yoluyla yapılabilir. Hareketin sonucu ava doğru yapılan son dalışla karşılaştırılır ve eğer karşılaştırma sonucu ava doğru en iyi dalışın belirlenmesine yol açmıyorsa, o zaman

takım hızlı dalışı toplu uçuşa göre yapılır. (LF) Eşitlik 3.47'te modellendiği gibi sömürü kapasitesini geliştirmek için gerçekleştirilir.

$$Y = X_{prey}(t) - E|JX_{prey}(t) - X(t)| \quad (3.45)$$

$$Z = Y + S \times LF(D) \quad (3.46)$$

D sorunun azalmasını temsil eder. S boyuta göre rastgele vektörü temsil eder. $1 \times D$ ve LF Eşitliği kullanılarak hesaplanan verili uçuş fonksiyonudur.

$$LF(X) = \frac{u \times \sigma}{|v|^{\frac{1}{\beta}}}, \sigma = \left(\frac{r(1+\beta) \times \sin \frac{\pi\beta}{2}}{r(\frac{1+\beta}{2}) \times \beta \times 2^{\frac{\beta-1}{2}}} \right)^{\frac{1}{\beta}} \quad (3.47)$$

u ve $v(0,1)$ içindeki rastgele değerleri temsil ederken, B , 1,5'e ayarlanmış bir sabiti temsil eder.

Bu nedenle, aşamalı hızlı dalış stratejisi ile yumuşak kuşatmada şahinlerin güncellenmiş konumları Eşitlik 3.48 ile hesaplanabilir.

$$X(t+1) = \begin{cases} Y & \text{if } F(Y) < F(X(t)) \\ Z & \text{if } F(Z) < F(X(t)) \end{cases} \quad (3.48)$$

burada F , bir optimizasyon problemi için bir uygunluk fonksiyonudur. Y ve Z Eşitlik 3.45 ve 3.46'da sırasıyla kullanılarak hesaplanır.

Sonraki stratejide avın kaçmak için yeterli enerjisi yoktur. $|E| < 0.5$ ve $r < 0.5$ ise, şahinler sıkı bir kuşatma kurmuştur. Bu strateji, atmacaların konumları ile hedeflenen av arasındaki ortalama mesafeyi azaltmaya çalıştıkları önceki stratejiden (aşamalı hızlı dalışlarla yumuşak kuşatma) farklıdır. Eşitlik 3.49'da bu strateji sert kuşatmaya göre modellenmiştir.

$$X(t+1) = \begin{cases} Y' & \text{if } F(Y') < F(X(t)) \\ Z' & \text{if } F(Z') < F(X(t)) \end{cases} \quad (3.49)$$

Y' Eşitlik 51 kullanılarak elde edilir.

$$Y' = X_{prey}(t) - E|JX_{prey}(t) - X_m(t)| \quad (3.50)$$

Z' Eşitlik 52 kullanılarak elde edilir.

$$Z' = Y' + S \times LF(D) \quad (3.51)$$

3.3. Enerji Verimlilik problemi

Önerilen metotun ve üzerinde çalışılan veri setinin temel amacı, optimal enerji tasarruflu binaların yapımında mühendislere yardımcı olacak HL ve CL'yi verimli bir şekilde tahmin etmektir. Yıllar geçtikçe enerji tüketimi daha büyük bir probleme dönüşmekte ve farklı yollarla tasarruf sağlanmaya çalışılmaktadır. Özellikle büyük şirketlerin enerji tüketimi karşısındaki önlemleri her geçen gün artmaktadır. Binalardaki

enerji tüketimi tasarruf sağlanması gereken tüketimin ilk sıralarında gelmektedir. Bu tüketim kolu genellikle HVAC yoluyla enerjiyi kullanır (Irfan, ve ark., 2021). Bina tasarımlarında HL ve CL'nin hesaplanması iç mekân iklimlendirme ekipmanlarının doğru seçimi konusunda önemli bir yer tutmaktadır. Zira bu yüklerin azaltılması enerji tasarrufunda kritik bir öneme sahiptir (A. Zeng ve ark., 2019). Enerji tüketimini optimize etmek için iyi bir tahminleme stratejisine ihtiyaç vardır. HL ve CL tahminlemede UCI veri seti (Tsanas ve Xifara, 2012) kullanılarak farklı çalışmalar yapılmıştır. Enerji verimliliği veri kümesinin 8 adet özelliği bulunmakta ve bu özelliklerin yüklendiği ağırlıklar kullanılarak HL ve CL faktörleri gözlemlenmiştir. Tablo 4.4'te özellikler verilmiştir.

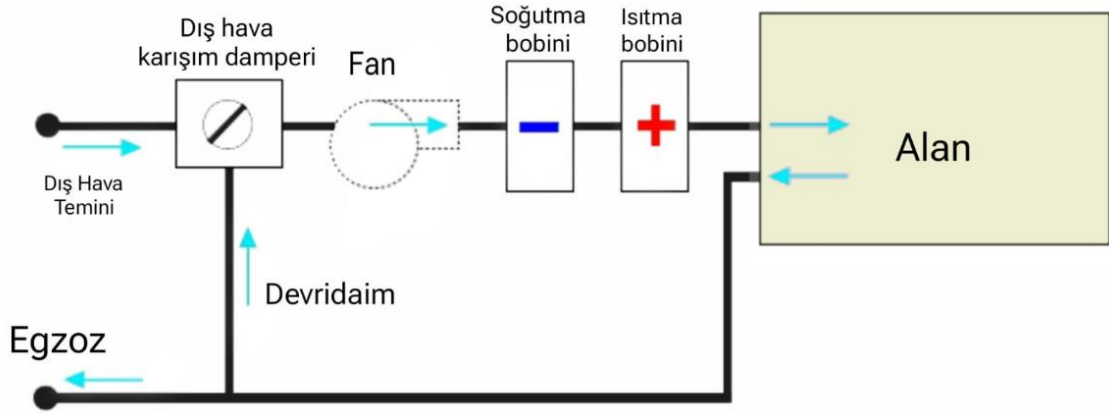
Tablo 3. 1 Enerji verimliliği veri kümesinin özelliği

GİRİŞ/ÇIKIŞ DEĞİŞKENİ	DEĞİŞKEN İSMİ	DEĞİŞKEN TANIMI
GİRİŞ	I1	Göreceli Kompaktlık
	I2	Yüzey Alanı
	I3	Duvar Alanı
	I4	Çatı Alanı
	I5	Toplam Yükseklik
	I6	Oryantasyon
	I7	Camlama Alanı
	I8	Camlama Alanı Dağılımı
ÇIKTI	O1	Isıtma Yüğü
	O2	Soğutma Yüğü

3.3.1. İklimlendirme (HVAC) Sistemi

Uluslararası enerji ajansı (IEA)'na göre enerji tüketiminin %34'ü binalarda harcanan enerji olmak üzere günümüzde enerji tüketimindeki artış önemli bir probleme işaret etmektedir (Cichowicz ve Jerominko, 2023). Enerji tüketiminde tasarruf sağlama ihtiyacı için yeni yöntemler araştırılmaktadır. Binalarda kullanılan enerji, ısıtma, soğutma, havalandırma ve iklimlendirme yoluyla (HVAC) kullanılır. HVAC sistemi, bina içindeki havanın ısıtılması, soğutulması ve havalandırılması işlemlerini gerçekleştirerek binanın HL ve CL faktörlerini hesaplama sayesinde içeride uygun hava koşullarını oluşturmak için tasarlanmıştır. Binalarda HL ve CL faktörlerinin tahmin edilmesi, doluluk düzeyine göre tüketimin azaltılması, binanın performansındaki değişimin enerji taleplerini yönetmesi, zararlı gazların emisyonlarını azaltması ve doğru tahminleme sayesinde maliyetlerin azalması açısından önemlidir (Roy ve ark., 2020). Gerekli soğutma ve ısıtma kapasiteleri, bina özellikleri, kullanımı ve iklim koşulları gibi temel faktörlere göre tahmin edilmektedir. HVAC sisteminin optimum düzeyde

tasarlanması enerji tasarrufunu sağlamada önemli role sahiptir (Irfan ve ark., 2021; McQuiston ve ark., 2023; Tien Bui ve ark., 2019). Bu bağlamda yapıların iç mekân dizaynları, enerji tüketiminde tasarruf sağlamanın yanı sıra insan sağlığı açısından da önem arz etmekte ve bu tasarrufu sağlamada HVAC sistemleri genellikle tercih edilen aktif sistemler olmaktadır (Çam, 2023). Şekil 3.7.'de bir HVAC modelinin elemanları çalışma sistematigi yer almaktadır. Bu modele Fan-coil model denmektedir. Fan-coil sistemleri, mekânın ısıtma ve soğutma gereksinimlerini karşılayarak istenilen sıcaklık seviyesini sağlamak için kullanılan bir tür ısıtma ve soğutma sistemidir. Bu sistemler, içinden ısıtıcı veya soğutucu akışkanın geçtiği serpantinlerle mekân arasındaki ısı transferini sağlayarak çalışır. Bir fan-coil cihazı, tipik olarak üst kısımda serpantin borularını, alt kısımda ise hava dolaşımını sağlayan bir radyal fanı ve filtreyi içerir (Seven, 2021).



Şekil 3. 7 Bir HVAC modelinde hava akış diyagramı (Seven, 2021)

4. ARAŞTIRMA SONUÇLARI ve TARTIŞMA

4.1 SSA Algoritmasının Karşılaştırma Fonksiyonları Aracılığıyla Performans Ölçümü

CEC 2019 ile performans üstünlüğünün ölçülmesi aşağıda belirtilmiştir. CEC 2019 fonksiyon seti güncel ve birçok çalışmada kullanılmaktadır. Fonksiyon kümesinde F1-F3 fonksiyonları multimodal, F4-F10 fonksiyonları ise multimodal shifted and rotated özelliklere sahiptir. Özellikle keşif aşamasında evrensel optimum noktanın ortaya çıkarılmasında bu fonksiyon seti kullanılmaktadır.

Tablo 4. 1 CEC2019 fonksiyon tanım parametreleri

Fonksiyonlar	Boyut	Arama Aralığı	Uygun Değer
F1: Storn'un Chebyshev Polinomu Uydurma Problemi	9	[-8192, 8192]	1
F2: Ters Hilbert Matris Problemi	16	[-16384, 16384]	1
F3: Lennard-Jones Minimum Enerji Kümesi	18	[-4.4]	1
F4: Rastrigin'in Fonksiyonu	10	[-100, 100]	1
F5: Griewangk'ın Fonksiyonu	10	[-100, 100]	1
F6: Weierstrass Fonksiyonu	10	[-100, 100]	1
F7: Modifiye Schwefel Fonksiyonu	10	[-100, 100]	1
F8: Genişletilmiş Schafer'in F6 Fonksiyonu	10	[-100, 100]	1
F9: Mutlu Kedi Fonksiyonu	10	[-100, 100]	1
F10: Ackley Fonksiyonu	10	[-100, 100]	1


Tablo 4. 2 CEC 2019 aracılığıyla algoritmaların istatistiksel sonuçları

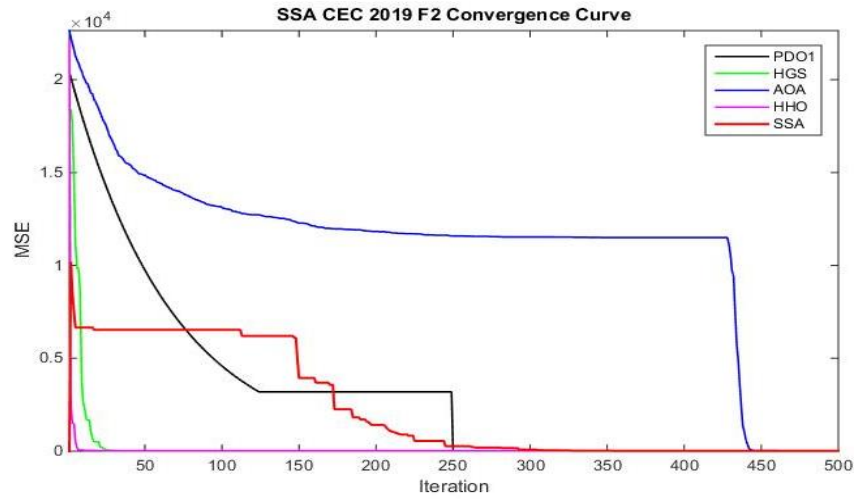
FONKSİYON	METRİK	SSA	PDO	HGS	AOA	HHO
F1	Ortalama	8.806e+09	6.800e+04	4.562e+04	2.435e+09	5.261e+04
	Standart Sapma	1.206e+10	2.606e+04	1.130e+04	6.110e+09	5.375e+03

	En İyi Değer	2.979e+08	4.485e+04	3.904e+04	7.519e+05	4.491e+04
	En Kötü Değer	4.721e+10	1.431e+05	9.858e+04	2.140e+10	6.354e+04
F2	Ortalama	1.735e+01	1.781e+01	1.734e+01	1.931e+01	1.736e+01
	Standart Sapma	1.605e-02	4.793e-01	1.181e-12	4.151e-01	1.090e-02
	En İyi Değer	1.734e+01	1.735e+01	1.734e+01	1.839e+01	1.735e+01
	En Kötü Değer	1.741e+01	1.900e+01	1.734e+01	1.985e+01	1.740e+01
F3	Ortalama	1.270e+01	1.270e+01	1.270e+01	1.270e+01	1.270e+01
	Standart Sapma	9.034e-15	1.069e-06	1.016e-07	1.095e-03	8.665e-06
	En İyi Değer	1.270e+01	1.270e+01	1.270e+01	1.270e+01	1.270e+01
	En Kötü Değer	1.270e+01	1.270e+01	1.270e+01	1.271e+01	1.270e+01
F4	Ortalama	3.526e+01	1.441e+04	3.909e+01	1.159e+04	1.690e+02
	Standart Sapma	1.613e+01	5.781e+03	2.140e+01	6.242e+03	6.662e+01
	En İyi Değer	1.293e+01	6.749e+03	9.953e+00	4.712e+03	7.336e+01
	En Kötü Değer	6.766e+01	2.841e+04	8.856e+01	3.067e+04	3.380e+02
F5	Ortalama	1.188e+00	4.212e+00	1.203e+00	4.026e+00	2.372e+00
	Standart Sapma	1.211e-01	7.067e-01	1.506e-01	8.097e-01	5.937e-01
	En İyi Değer	1.074e+00	2.887e+00	1.037e+00	2.311e+00	1.362e+00
	En Kötü Değer	1.676e+00	5.899e+00	1.826e+00	5.379e+00	3.988e+00
F6	Ortalama	4.856e+00	9.412e+00	3.910e+00	8.971e+00	9.436e+00
	Standart Sapma	1.594e+00	1.239e+00	9.907e-01	7.952e-01	1.114e+00
	En İyi Değer	2.120e+00	7.175e+00	1.662e+00	6.862e+00	6.970e+00
	En Kötü Değer	8.060e+00	1.168e+01	5.711e+00	1.058e+01	1.134e+01
F7	Ortalama	3.701e+02	8.310e+02	2.273e+02	2.350e+02	3.085e+02
	Standart Sapma	2.362e+02	1.926e+02	1.892e+02	1.245e+02	1.653e+02
	En İyi Değer	-2.148e+02	4.431e+02	-7.815e+01	2.502e+01	3.707e+01
	En Kötü Değer	8.158e+02	1.249e+03	6.238e+02	4.276e+02	6.781e+02
F8	Ortalama	5.143e+00	6.246e+00	5.557e+00	5.491e+00	5.820e+00
	Standart Sapma	8.516e-01	4.264e-01	6.133e-01	5.410e-01	5.400e-01
	En İyi Değer	3.248e+00	5.043e+00	3.744e+00	4.148e+00	4.660e+00
	En Kötü Değer	6.372e+00	6.934e+00	6.349e+00	6.525e+00	6.678e+00
F9	Ortalama	2.635e+00	1.553e+03	2.915e+00	8.915e+02	3.270e+00
	Standart Sapma	1.593e-01	3.746e+02	3.184e-01	5.017e+02	4.617e-01
	En İyi Değer	2.418e+00	6.617e+02	2.402e+00	6.234e+00	2.644e+00
	En Kötü Değer	3.098e+00	2.481e+03	3.811e+00	1.761e+03	4.359e+00
F10	Ortalama	2.005e+01	2.030e+01	2.002e+01	2.015e+01	2.025e+01
	Standart Sapma	1.025e-01	1.446e-01	2.642e-02	5.981e-02	1.482e-01
	En İyi Değer	1.998e+01	2.009e+01	2.000e+01	2.006e+01	1.997e+01
	En Kötü Değer	2.038e+01	2.060e+01	2.010e+01	2.027e+01	2.060e+01

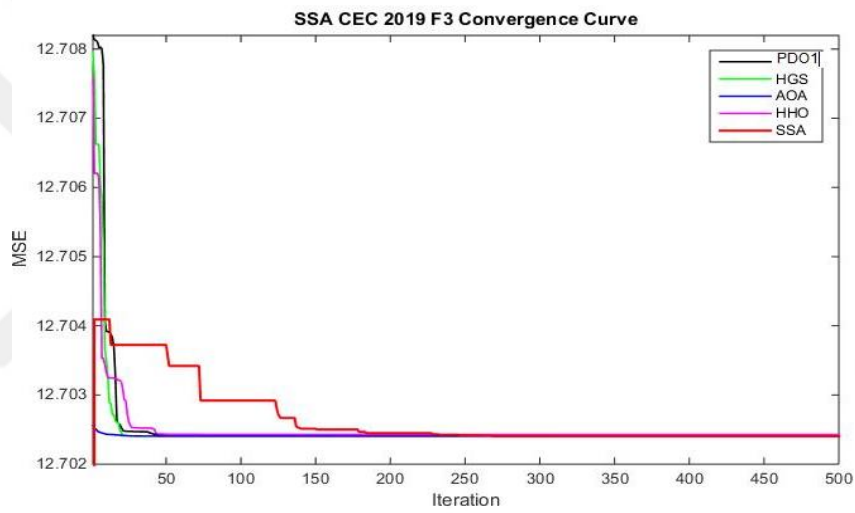
Tablo 4. 3 Wilcoxon Signedrank testi ile algoritmaları karşılaştırma (CEC 2019)

Fonksiyon	Metrikler	SSA-PDO	SSA-HGS	SSA-AOA	SSA-HHO
F1	p-değer	1.734e-06	1.734e-06	3.600e-03	1.734e-06
	W/T/L	W	W	W	W
F2	p-değer	1.734e-06	1.734e-06	1.734e-06	3.065e-04
	W/T/L	W	W	W	W
F3	p-değer	5.606e-06	1.560e-02	1.734e-06	1.734e-06
	W/T/L	W	W	W	W
F4	p-değer	1.734e-06	5.038e-01	1.734e-06	1.734e-06
	W/T/L	W	L	W	W
F5	p-değer	1.734e-06	6.435e-01	1.734e-06	1.734e-06
	W/T/L	W	L	W	W
F6	p-değer	1.734e-06	1.960e-02	1.734e-06	1.921e-06
	W/T/L	W	W	W	W
F7	p-değer	1.734e-06	5.300e-03	2.560e-02	1.650e-01
	W/T/L	W	W	W	L
F8	p-değer	3.882e-06	5.980e-02	1.650e-01	1.360e-04
	W/T/L	W	L	L	W
F9	p-değer	1.734e-06	3.317e-04	1.734e-06	2.353e-06
	W/T/L	W	W	W	W
F10	p-değer	8.466e-06	4.284e-01	9.627e-04	1.360e-05
	W/T/L	W	L	W	W


**Şekil 4. 1** CEC 2019 aracılığıyla algoritmaların F1 fonksiyonunda yakınsama eğrisi



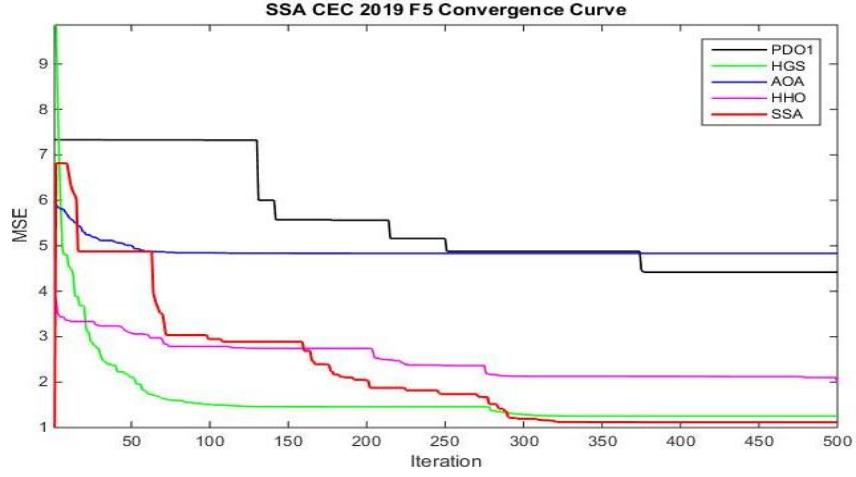
Şekil 4. 2 CEC 2019 aracılığıyla algoritmaların F2 fonksiyonunda yakınsama eğrisi




Şekil 4. 3 CEC 2019 aracılığıyla algoritmaların F3 fonksiyonunda yakınsama eğrisi




Şekil 4. 4 CEC 2019 aracılığıyla algoritmaların F4 fonksiyonunda yakınsama eğrisi




Şekil 4. 5 CEC 2019 aracılığıyla algoritmaların F5 fonksiyonunda yakınsama eğrisi




Şekil 4. 6 CEC 2019 aracılığıyla algoritmaların F6 fonksiyonunda yakınsama eğrisi




Şekil 4. 7 CEC 2019 aracılığıyla algoritmaların F7 fonksiyonunda yakınsama eğrisi



Şekil 4. 8 CEC 2019 aracılığıyla algoritmaların F8 fonksiyonunda yakınsama eğrisi



Şekil 4. 9 CEC 2019 aracılığıyla algoritmaların F9 fonksiyonunda yakınsama eğrisi



Şekil 4. 10 CEC 2019 aracılığıyla algoritmaların F10 fonksiyonunda yakınsama eğrisi

CEC 2019 fonksiyon setinde tüm fonksiyonlar multimodal yapıda olduğu için, bir algoritmanın erken yakınsama ve yerel alanı aşma yeteneğini ölçer; diğer bir deyişle,

algoritmanın keşif yeteneğini değerlendirir. SSA algoritması CEC 2019 fonksiyon setinde ortalama değer açısından F3, F4, F5 fonksiyonları ile F8, F9 fonksiyonlarında en iyi değeri yakalamayı başarmıştır. Bu fonksiyonların temel özelliği multimodal shifted and rotated olması yani çok modlu ve kaydırılıp döndürülme ile algoritmanın keşif yeteneğinin üstün olduğunu göstermektedir.

Bu tabloya paralel olarak Şekil 4.1, 4.2, 4.3, 4.4, 4.5, 4.6, 4.7, 4.8, 4.9 ve 4.10'da görselleştirilen yakınsama eğrileri incelendiğinde ise F3, F4, F5 fonksiyonları ile F8, F9 fonksiyonlarının düzenli ve kararlı bir şekilde yakınsadığı ve diğer fonksiyonlarda da erken yakınsamaya maruz kalmadığı, her iterasyonda en uygun noktaya doğru yaklaştığı görülebilir.

4.2 SSA-MLP Eğitimi

Bu çalışmada UCI'den alınan HL ve CL' nü kapsayan problem optimize edilerek (Tsanas ve Xifara, 2012) ve MLP metodu ile sınıflandırılacaktır. Sınıflandırma kapsamında iki temel sonuca varılmaya çalışılacaktır. Bunlardan birincisi sınıflandırma oranı Eşitlik 4.1'de verilen $Predict_Rate$ değeri ise Eşitlik 4.2'te verilen mean square error (MSE) oranıdır. Rekabetçi algoritmalar içerisinde $Predict_Rate$ en yüksek ve MSE oranı en düşük olan algoritma başarılı sayılacaktır.

$$M_j^i = \frac{1}{2}(M_j^i + M_j^{i-1}) \quad i \geq 2 \quad (4.1)$$

$$Predict_Rate = 100 \left(\frac{PR}{NoS} \right) \quad (4.2)$$

PR bir çalıştırma sonucunda ortaya çıkan mevcut oran, NoS veri setinde bulunan örnek sayısını ifade eder.

$$MSE = \frac{1}{N} \sum_{i=1}^N (P_i - O_i)^2 \quad (4.3)$$

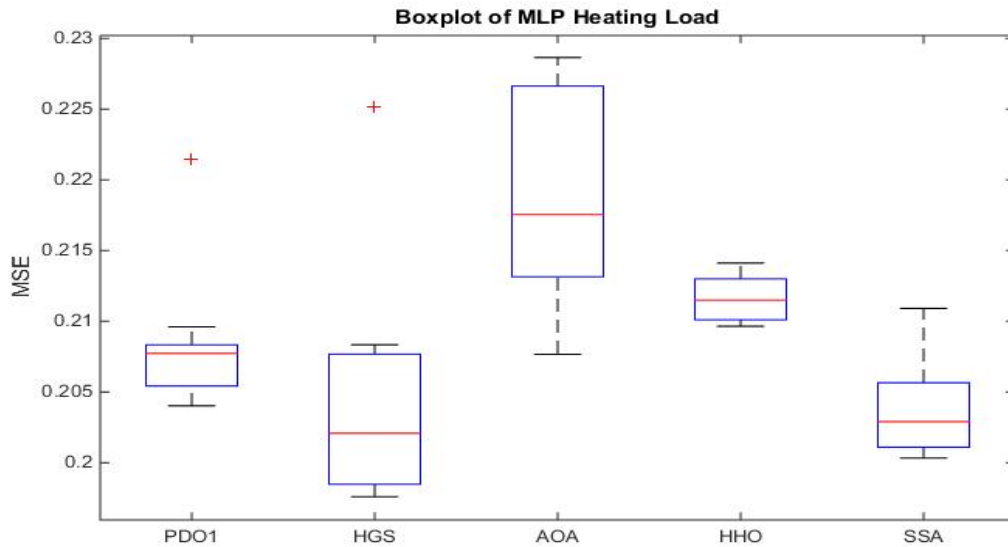
burada, i giriş birimidir, P_i arzu edilen ve O_i gözlemlenen değerdir. N ise, çıkışların sayısıdır.

Sınıflandırılacak data setin temel özellikleri aşağıda Tablo 1' de verilmiştir.

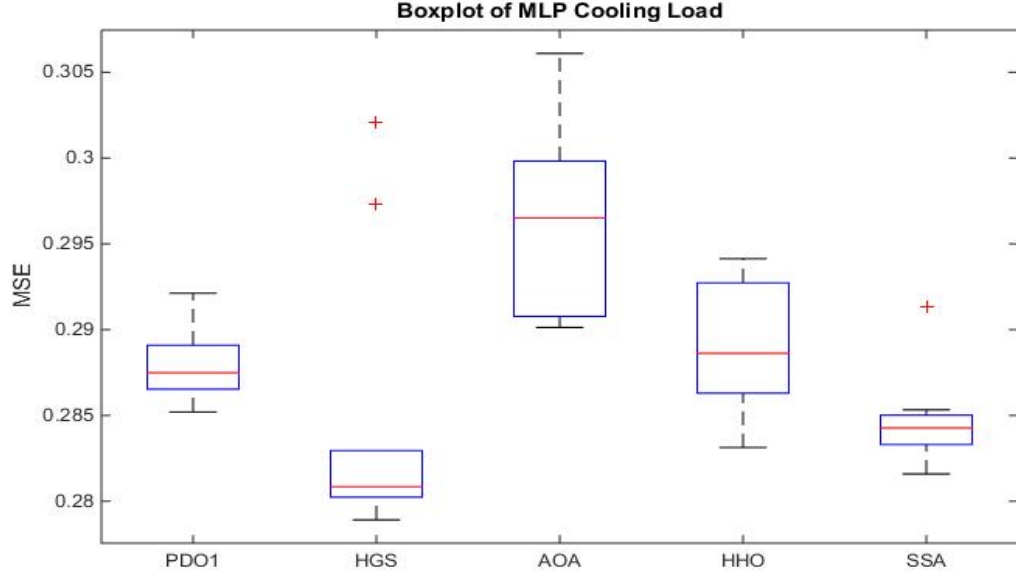
Tablo 4. 4 Veri setinin MLP eğitiminin istatistiksel sonuçları

FONKSİYON	METRİK	PDO1	HGS	AOA	HHO	SSA
ÇIKIŞ SINIFI ISITMA YÜKÜ	Ortalama	2.084e-01	2.045e-01	2.184e-01	2.117e-01	2.038e-01
	Standart Sapma	4.900e-03	8.200e-03	7.700e-03	1.700e-03	3.300e-03

	En İyi Değer	2.040e-01	1.976e-01	2.077e-01	2.096e-01	2.003e-01
	En Kötü Değer	2.214e-01	2.252e-01	2.286e-01	2.141e-01	2.109e-01
	Sınıf oranı	%99,8667	%99,8560	%99,8660	%99,8702	%100
	Rütbe	3	2	5	4	1
ÇIKIŞ SINIFI SOĞUTMA YÜKÜ	Ortalama	2.879e-01	2.846e-01	2.963e-01	2.890e-01	2.846e-01
	Standart Sapma	2.000e-03	8.200e-03	5.200e-03	3.700e-03	2.700e-03
	En İyi Değer	2.852e-01	2.789e-01	2.901e-01	2.831e-01	2.816e-01
	En Kötü Değer	2.921e-01	3.021e-01	3.061e-01	2.941e-01	2.913e-01
	Sınıf oranı	%99,8667	%99,8560	%99,8660	%99,8698	%100
	Rütbe	3	2	5	4	1



Şekil 4. 11 MLP eğitimi yoluyla algoritmaların heating load kutu grafiği



Şekil 4. 12 MLP eğitimi yoluyla algoritmaların cooling load kutu grafikleri

Tablo 4.4 incelendiğinde belli hata oranları ile etkili iklimlendirme algoritmalarının sonuçları verilmiştir. MLP eğitiminde sezgisel üstü algoritmaların kullanımı enerji sektöründe de başarılı bir şekilde sağlandığı bu çalışmada gözlemlenmiştir. Bu tabloda en düşük MSE oranı SSA algoritmasında var olduğu gibi en yüksek sınıflandırma oranına da yine SSA algoritmasının sahip olduğu görülmektedir. Binalar farklı özellikleri ile ele alınıp tüm bu özelliklerin birlikte değerlendirilerek çıkış yükleri açısından SSA algoritmasının öne çıkması bu algoritmanın bina tasarımlarında HL ve CL hesaplanması konusunda kullanılmasının uygun olduğunu gösterir. Şekil 4.11 ve 4.12’de box-plot grafik sonuçları bulunmaktadır. box-plot grafikler istatistikte medyan, birinci ve üçüncü quartil, alt ve üst uç değerler ise aşırı değerleri gösteren kullanışlı ölçüm araçlarıdır. İki ayrı çıkış değeri olarak hem CL hem de HL değerlerinde SSA algoritmasının değerlerinin birbirine çok yakın olduğu gözlemlenmektedir. Bununla beraber HL değerinde hiç aşırı değer gözlemlenmemekte, CL değerinde ise sadece bir aşırı değer gözlemlenmektedir. Yani tablo 4.4’ü sağlayan paralel değerler söz konusudur (Eker ve ark., 2024).

5. SONUÇLAR ve ÖNERİLER

5.1 Sonuçlar

Bu tezde, sezgisel üstü algoritma temelli yapay sinir ağlarını kullanarak enerji algoritmaları olarak da PDO, HGS, AOA ve HHO algoritmaları karşılaştırılmıştır. Bu algoritmalar arasında en optimum sonucu veren SSA algoritması olmuştur.

SSA ve alternatif algoritmalar CEC 2019 fonksiyon seti kullanılarak değerlendirilmiş ve bu değerlendirmeler sonucunda SSA'nın her iki test setinde de daha avantajlı olduğu gözlemlenmiştir. Wilcoxon signedrank testi ile SSA algoritmasının alternatif algoritmalarla karşılaştırılarak benzersiz veri setleri üretmede güçlü bir yapıya sahip olduğu gösterilmiştir. Bu durum SSA algoritmasının her boyuttaki problemin çözümünde kullanılabilmesini göstermekle birlikte, algoritmanın esnek yapısı nedeniyle farklı stratejilerle geliştirilmeye ve melezlemeyle uygun olduğu ve farklı çalışmalar yapıldığında farklı problemler için çeşitli çözümler sunabileceği de gözlemlenmiştir.

Günümüzde gezegenimizin karşı karşıya olduğu enerji sorununu çözenin bir yolu da enerjinin verimli kullanılmasını sağlamaktır. Bu bağlamda enerji verimli akıllı binalarda HL ve CL talebinin en aza indirilmesi enerji tasarrufuna katkı sağlayacaktır. Bu çalışmada üretilen model ile bina tasarımcılarının ısıtma, soğutma, havalandırma ve iklimlendirme (HVAC) sistemlerinde gerekli verimliliği elde edebilecekleri öngörülebilir. %100'lük tahminleme yeteneği ve yaklaşık 0,20'lik MSE değerleri ile başarılı bir problem optimizasyonu elde edilmiştir. Bu model ile küresel enerji krizinin ele alınması bağlamında, özellikle iklim kontrolünün kalitesini artırmayı hedefleyen binaların tasarımında doğru çevresel kontrol ekipmanlarının seçilmesinin önemi de vurgulanmaktadır. Bu bağlamda, başta SSA algoritması olmak üzere sezgisel üstü algoritmaların HL ve CL faktörlerinin hesaplanmasında etkin bir rol oynayabileceği deneysel olarak gözlemlenmiştir. Ayrıca sezgisel üstü algoritmaların rekabetçi doğası vurgulanarak, kendi çerçeveleri içerisinde en iyi algoritmayı bulma ve kullanma imkânı sağlanmaktadır. SSA-MLP algoritması, bu alandaki potansiyelini doğrulayan başarılı sonuçlar göstermiştir.

5.2 Öneriler

Gelecekteki çalışmalar, farklı güvenilir veri setlerinden ve SSA algoritmasının esnekliğinden yararlanarak hem YSA hem de çeşitli makine öğrenimi algoritmalarıyla

hibridizasyon yoluyla enerji problemlerini çözmek için yeni uygulamalara yol açabilir. Bu makalenin bu alanda yol gösterici bir referans olacağına inanılmaktadır.



KAYNAKLAR

- Abbassi, R., Abbassi, A., Heidari, A. A., and Mirjalili, S. 2019. An efficient salp swarm-inspired algorithm for parameters identification of photovoltaic cell models, *Energy Conversion and Management*, 179, 362-372.
- Abualigah, L. M., Khader, A. T., Hanandeh, E. S., and Gandomi, A. H. 2017. A novel hybridization strategy for krill herd algorithm applied to clustering techniques, *Applied Soft Computing*, 60, 423-435.
- Abualigah, L., Diabat, A., and Zitar, R. A. 2022. Orthogonal learning Rosenbrock's direct rotation with the gazelle optimization algorithm for global optimization, *Mathematics*, 10(23), 4509.
- Abualigah, L., Shehab, M., Alshinwan, M., and Alabool, H. 2020. Salp swarm algorithm: A comprehensive survey, *Neural Computing and Applications*, 32, 11195-11215.
- Abualigah, L., Yousri, D., Abd Elaziz, M., Ewees, A. A., Al-Qaness, M. A., and Gandomi, A. H. 2021. Aquila optimizer: A novel meta-heuristic optimization algorithm, *Computers & Industrial Engineering*, 157, 107250.
- Afram, A., and Janabi-Sharifi, F. 2014. Review of modeling methods for HVAC systems, *Applied Thermal Engineering*, 67(1-2), 507-519.
- Agushaka, J. O., Ezugwu, A. E., and Abualigah, L. 2023. Gazelle optimization algorithm: A novel nature-inspired metaheuristic optimizer, *Neural Computing and Applications*, 35(5), 4099-4131.
- Alabool, H. M., Alarabiat, D., Abualigah, L., and Heidari, A. A. 2021. Harris hawks optimization: A comprehensive review of recent variants and applications, *Neural Computing and Applications*, 33, 8939-8980.
- Alba, E., and Martí, R. 2006, Metaheuristic procedures for training neural networks, C. 35, *Springer Science & Business Media*.
- Ali, T. A. A., Xiao, Z., Sun, J., Mirjalili, S., Havyarimana, V., and Jiang, H. 2019. Optimal design of IIR wideband digital differentiators and integrators using salp swarm algorithm, *Knowledge-Based Systems*, 182, 104834.
- Altay, E. V., ve Altay, O. 2021. Güncel metasezgisel optimizasyon algoritmalarının CEC2020 test fonksiyonları ile karşılaştırılması, *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi*, 12(5), 729-741.
- Altay, O., ve Altay, E. V. 2023. Investigation of slime Mould algorithm and hybrid slime Mould Algorithms' performance in global optimization problems, *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi*, 13(4), 661-671.
- Anonymous, 2020. An Efficient Harris Hawks Optimization (HHO) Algorithm for Solving Numerical Expressions, *Transpire Online*.
- Aslan, B., ve Yıldız, A. R. 2020. Optimum design of automobile components using lattice structures for additive manufacturing, *Materials testing*, 62(6), 633-639.
- Atlı, F. D. (2022). "Yapay sinir ağlarının eğitimi için salp sürü optimizasyonu algoritmasının iyileştirilmesi", Yüksek lisans tezi, *Fen Bilimleri Enstitüsü*, Necmettin Erbakan Üniversitesi, Konya, 58.

- Azizi, M., Talatahari, S., and Gandomi, A. H. 2023. Fire Hawk Optimizer: A novel metaheuristic algorithm, *Artificial Intelligence Review*, 56(1), 287-363.
- Bairathi, D., & Gopalani, D. 2021. Numerical optimization and feed-forward neural networks training using an improved optimization algorithm: Multiple leader salp swarm algorithm, *Evolutionary Intelligence*, 14(3), 1233-1249.
- Bingöl, H., ve Yıldırım, M. 2021. Global optimizasyon için sürü tabanlı bir yaklaşım salp sürü algoritması, *Fırat Üniversitesi Fen Bilimleri Dergisi*, 33(1), 51-59.
- Can, C., Kaya, Y., and Kılıç, F. 2021. Salp sürü algoritması ile öznelik seçimi ve sınıflandırıcı performans değerlendirilmesi, *Avrupa Bilim ve Teknoloji Dergisi*, 30, 12-16.
- Chegari, B., Tabaa, M., Simeu, E., Moutaouakkil, F., and Medromi, H. 2021. Multi-objective optimization of building energy performance and indoor thermal comfort by combining artificial neural networks and metaheuristic algorithms, *Energy and Buildings*, 239, 110839.
- Cichowicz, R., and Jerominko, T. 2023. Comparison of calculation and consumption methods for determining Energy Performance Certificates (EPC) in the case of multi-family residential buildings in Poland (Central-Eastern Europe), *Energy*, 282, 128393.
- Cui, Z., Xu, Y., and Zeng, J. 2012. Social emotional optimization algorithm with random emotional selection strategy, *Theory and New Applications of Swarm Intelligence*, 33-50.
- Çakici, F. N. (2022). “Kablosuz sensör ağlarında graf bağlılığın konumlandırma üzerindeki etkisinin ve hatalı konumlandırılan sensör düğümlerinin incelenmesi”, Yüksek Lisans Tezi, *Fen Bilimleri Enstitüsü*, Kırıkkale Üniversitesi, Kırıkkale, 140.
- Çam, A. (2023). “Bina Enerji Modellemesi yöntemiyle konut yapısı enerji analizi: Ankara Yeşiltepe Yapı Kooperatifi örneği”, Yüksek Lisans Tezi, *Fen Bilimleri Enstitüsü*, Necmettin Erbakan Üniversitesi, Konya, 107.
- Çelik, Y., Yıldız, İ., ve Karadeniz, A. T. 2019. Son Üç Yılda Geliştirilen Metasezgisel Algoritmalar Hakkında Kısa Bir İnceleme, *Avrupa Bilim ve Teknoloji Dergisi*, 463-477.
- Dhawan, S., Gupta, R., Rana, A., and Sharma, S. (2021). Various Swarm Optimization Algorithms: Review, Challenges, and Opportunities, *Research Gate*, 291-301.
- Dorigo, M., Birattari, M., and Stutzle, T. 2006, Ant colony optimization, *IEEE Computational Intelligence Magazine*, 1(4), 28-39.
- Eberhart, R., and Kennedy, J. 1995. Particle swarm optimization, *Proceedings of the IEEE international conference on neural networks*, 4, 1942-1948.
- Eker, E. (2020). “Yapay Sinir Ağlarının Modern Sezgisel-Üstü Algoritmaları Yoluyla Eğitimi”, Doktora Tezi, *Fen Bilimleri Enstitüsü*, Van Yüzüncü Yıl Üniversitesi, Van, 155.
- Eker, E., Atar, Ş., Şevgin, F., ve Tuğal, İ. 2024. Optimization of Non-Linear Problems Using Salp Swarm Algorithm and Solving the Energy Efficiency Problem of Buildings with Salp Swarm Algorithm-based Multi-Layer Perceptron Algorithm, *Electrica*, 24(2): 436-449.
- Eker, E., Kayri, M., Ekinci, S., ve İzci, D. (2023). Comparison of Swarm-based Metaheuristic and Gradient Descent-based Algorithms in Artificial Neural Network Training, *ADCAIJ: Advances in Distributed Computing and Artificial Intelligence Journal*, 12(1), e29969-e29969.

- Eker, E., Kayri, M., Ekinçi, S., ve Kaçmaz, M. A. 2023. Performance Evaluation of PDO Algorithm through Benchmark Functions and MLP Training, *Electrica*, 23(3).
- Ekinçi, S., Hekimoğlu, B., ve Kaya, S. 2018. Tuning of PID controller for AVR system using salp swarm algorithm, *2018 international conference on artificial intelligence and data processing (IDAP)*, 1-6.
- Ezugwu, A. E., Agushaka, J. O., Abualigah, L., Mirjalili, S., and Gandomi, A. H. 2022. Prairie dog optimization algorithm, *Neural Computing and Applications*, 34(22), 20017-20065.
- Faris, H., Aljarah, I., Al-Madi, N., and Mirjalili, S. 2016. Optimizing the Learning Process of Feedforward Neural Networks Using Lightning Search Algorithm, *International Journal on Artificial Intelligence Tools*, 25(06), 1650033.
- Fong, K. F., Hanby, V. I., & Chow, T. T. 2006. HVAC system optimization for energy management by evolutionary programming, *Energy and Buildings*, 38(3), 220-231.
- Ghanem, W. A., and Jantan, A. 2020. Training a neural network for cyberattack classification applications using hybridization of an artificial bee colony and monarch butterfly optimization, *Neural Processing Letters*, 51(1), 905-946.
- Gharehchopogh, F. S., Maleki, I., and Dizaji, Z. A. 2022. Chaotic vortex search algorithm: Metaheuristic algorithm for feature selection, *Evolutionary Intelligence*, 15(3), 1777-1808.
- Goodfellow, I., Bengio, Y., and Courville, A., 2016, Deep learning, *MIT press*.
- Goyal, M., Pandey, M., and Thakur, R., 2020. Exploratory Analysis of Machine Learning Techniques to predict Energy Efficiency in Buildings, *2020 8th International Conference on Reliability, Infocom Technologies and Optimization*, Noida, India, 1033-1037.
- Grippo, L. 2000. Convergent on-line algorithms for supervised learning in neural networks, *IEEE Transactions on Neural Networks*, 11(6), 1284-1299.
- Gürses, D., Mehta, P., Patel, V., Sait, S. M., ve Yildiz, A. R. 2022a. Artificial gorilla troops algorithm for the optimization of a fine plate heat exchanger, *Materials Testing*, 64(9), 1325-1331.
- Gürses, D., Mehta, P., Sait, S. M., Kumar, S., ve Yildiz, A. R. 2023. A multi-strategy boosted prairie dog optimization algorithm for global optimization of heat exchangers, *Materials Testing*, 65(9), 1396-1404.
- Gürses, D., Mehta, P., Sait, S. M., ve Yildiz, A. R. 2022b. African vultures optimization algorithm for optimization of shell and tube heat exchangers, *Materials Testing*, 64(8), 1234-1241.
- Hashim, F. A., Hussain, K., Houssein, E. H., Mabrouk, M. S., and Al-Atabany, W. 2021. Archimedes optimization algorithm: A new metaheuristic algorithm for solving optimization problems, *Applied intelligence*, 51, 1531-1551.
- Haykin, S., 1998. *Neural networks: A comprehensive foundation*, Prentice Hall PTR, United States.
- Haykin, S., and Network, N. 2004. A comprehensive foundation, *Neural networks*, 2(2004), 41.
- He, S., Li, Q., Khishe, M., Salih Mohammed, A., Mohammadi, H., and Mohammadi, M. (2024). The optimization of nodes clustering and multi-hop routing protocol using hierarchical chimp optimization for sustainable energy efficient underwater wireless sensor networks, *Wireless Networks*, 30(1), 233-252.

- Hegazy, A. E., Makhlof, M. A., and El-Tawel, G. S. 2019. Feature selection using chaotic salp swarm algorithm for data classification, *Arabian Journal for Science and Engineering*, 44, 3801-3816.
- Hegazy, A. E., Makhlof, M. A., and El-Tawel, G. S. 2020. Improved salp swarm algorithm for feature selection, *Journal of King Saud University-Computer and Information Sciences*, 32(3), 335-344.
- Heidari, A. A., Mirjalili, S., Faris, H., Aljarah, I., Mafarja, M., and Chen, H. 2019. Harris hawks optimization: Algorithm and applications, *Future generation computer systems*, 97, 849-872.
- Heidari, A. A., Faris, H., Mirjalili, S., Aljarah, I., and Mafarja, M. 2020. Ant lion optimizer: theory, literature review, and application in multi-layer perceptron neural networks, *Nature-inspired optimizers: theories, literature reviews and applications*, 23-46.
- Homod, R. Z. 2013. Review on the HVAC system modeling types and the shortcomings of their application, *Journal of Energy*, 2013.
- Hoogland, J. L., 1995. The black-tailed prairie dog: Social life of a burrowing mammal. *University of Chicago Press*.
- Ibrahim, R., Ewees, A., Oliva, D., Elsayed Abd Elaziz, M., and Lu, S. 2019. Improved salp swarm algorithm based on particle swarm optimization for feature selection, *Journal of Ambient Intelligence and Humanized Computing*, 10.
- Irfan, M., Faizir, R., Widiyanto, W., and Faruq, A. 2021. Prediction of Residential Building Energy Efficiency Performance using Deep Neural Network, *IAENG International Journal of Computer Science*, 48(3), 731-737.
- Iwendi, C., Maddikunta, P. K. R., Gadekallu, T. R., Lakshmana, K., Bashir, A. K., and Piran, Md. J. 2021. A metaheuristic optimization approach for energy efficiency in the IoT networks. *Software: Practice and Experience*, 51(12), 2558-2571.
- Izci, D., Ekinci, S., Eker, E., ve Kayri, M. 2022. Augmented hunger games search algorithm using logarithmic spiral opposition-based learning for function optimization and controller design, *Journal of King Saud University - Engineering Sciences*.
- Jain, A. K., Mao, J., and Mohiuddin, K. M. 1996. Artificial neural networks: A tutorial, *Computer*, 29(3), 31-44.
- Khishe, M., and Mohammadi, H. 2019. Passive sonar target classification using multi-layer perceptron trained by salp swarm algorithm, *Ocean Engineering*, 181, 98-108.
- Kosarirad, H., Ghasempour Nejati, M., Saffari, A., Khishe, M., and Mohammadi, M. 2022. Feature Selection and Training Multilayer Perceptron Neural Networks Using Grasshopper Optimization Algorithm for Design Optimal Classifier of Big Data Sonar, *Journal of Sensors*, 2022, e9620555.
- Kunakote, T., Sabangban, N., Kumar, S., Tejani, G. G., Panagant, N., Pholdee, N., Bureerat, S., and Yildiz, A. R. 2022. Comparative performance of twelve metaheuristics for wind farm layout optimisation, *Archives of Computational Methods in Engineering*, 1-14.
- Kusiak, A., Li, M., and Tang, F. 2010. Modeling and optimization of HVAC energy consumption, *Applied Energy*, 87(10), 3092-3102.

- Lasdon, L. S., Fox, R. L., and Ratner, M. W. 1974. Nonlinear optimization using the generalized reduced gradient method, *Revue française d'automatique, informatique, recherche opérationnelle. Recherche opérationnelle*, 8(V3), 73-103.
- LeCun, Y., Bengio, Y., and Hinton, G. 2015. Deep learning, *Nature*, 521(7553), 436-444.
- Lu, L., Cai, W., Xie, L., Li, S., and Soh, Y. C. 2005. HVAC system optimization—In-building section, *Energy and Buildings*, 37(1), 11-22.
- Lu, Q., Ren, Y., Jin, H., Meng, L., Li, L., Zhang, C., and Sutherland, J. W. 2020. A hybrid metaheuristic algorithm for a profit-oriented and energy-efficient disassembly sequencing problem, *Robotics and Computer-Integrated Manufacturing*, 61, 101828.
- Ma, L., Wang, C., Xie, N. G., Shi, M., Ye, Y., and Wang, L. 2021. Moth-flame optimization algorithm based on diversity and mutation strategy. *Applied Intelligence*, 51, 5836-5872.
- Maheshwari, S., Dubey, D. S., Gulia, V., and Solke, N. 2024. Comparative Analysis of Optimization Algorithms for Energy Consumption Minimization in HVAC Systems, *Proceedings of the 5th International Conference on Information Management & Machine Intelligence*, 1-10.
- Masdari, M., Tahani, M., Naderi, M. H., and Babayan, N. 2019. Optimization of airfoil Based Savonius wind turbine using coupled discrete vortex method and salp swarm algorithm, *Journal of Cleaner Production*, 222, 47-56.
- McQuiston, F. C., Parker, J. D., Spitler, J. D., and Taherian, H. 2023. Heating, ventilating, and air conditioning: Analysis and design, *John Wiley & Sons*.
- Mehta, P., Yıldız, B. S., Sait, S. M., and Yıldız, A. R. 2022. Gradient-based optimizer for economic optimization of engineering problems, *Materials Testing*, 64(5), 690-696.
- Mehta, P., Yildiz, B. S., Sait, S. M., and Yildiz, A. R. 2022. Hunger games search algorithm for global optimization of engineering design problems, *Materials Testing*, 64(4), 524-532.
- Mirjalili, S. 2015. How effective is the Grey Wolf optimizer in training multi-layer perceptrons, *Applied Intelligence*, 43, 150-161.
- Mirjalili, S. 2019. Genetic Algorithm. İçinde S. Mirjalili, *Evolutionary Algorithms and Neural Networks*, 780, Springer International Publishing, 43-55.
- Mirjalili, S., and Sadiq, A. S. 2011. Magnetic optimization algorithm for training multi layer perceptron, *2011 IEEE 3rd international conference on communication software and networks*, 42-46.
- Mirjalili, S., Gandomi, A. H., Mirjalili, S. Z., Saremi, S., Faris, H., and Mirjalili, S. M. 2017. Salp Swarm Algorithm: A bio-inspired optimizer for engineering design problems, *Advances in engineering software*, 114, 163-191.
- Mirjalili, S., Mirjalili, S. M., and Lewis, A. 2014. Grey wolf optimizer, *Advances in engineering software*, 69, 46-61.
- Mirjalili, S., Mirjalili, S. M., and Lewis, A. 2014. Let a biogeography-based optimizer train your multi-layer perceptron, *Information Sciences*, 269, 188-209.
- Naruei, I., and Keynia, F. 2022. Wild horse optimizer: A new meta-heuristic algorithm for solving engineering optimization problems, *Engineering With Computers*, 38(Suppl 4), 3025-3056.

- Nilashi, M., Dalvi-Esfahani, M., Ibrahim, O., Bagherifard, K., Mardani, A., and Zakuan, N. 2017. A soft computing method for the prediction of energy performance of residential buildings, *Measurement*, 109, 268-280.
- Niu, N., and Zhang, M. 2012. An Optimization to Schedule Train Operations with Phase-Regular Framework for Intercity Rail Lines, *Discrete Dynamics in Nature and Society*.
- Noriega, L. (2005). Multilayer perceptron tutorial, *School of Computing*, Staffordshire University, 4(5), 444.
- Özbay, F. A., and Özbay, E. 2023. A new approach for gender detection from voice data: Feature selection with optimization methods, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 38:2 (2023), 1179-1192.
- Özmen, T., Üzeyir, K., Koçyiğit, Y., ve Sarnel, H. 2023. Metasezgisel yöntemlerle öznitelik sayısını azaltarak diyabetin erken dönemde tespiti, *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, 29(6), 596-606.
- Panagant, N., Pholdee, N., Bureerat, S., Yildiz, A. R., and Mirjalili, S. 2021. A comparative study of recent multi-objective metaheuristics for solving constrained truss optimisation problems, *Archives of Computational Methods in Engineering*, 1-17.
- Popescu, M.-C., Balas, V. E., Perescu-Popescu, L., and Mastorakis, N. 2009. Multilayer perceptron and neural networks, *WSEAS Transactions on Circuits and Systems*, 8(7), 579-588.
- Qian, L., Chen, Z., Huang, Y., and Stanford, R. J. 2023. Employing categorical boosting (CatBoost) and meta-heuristic algorithms for predicting the urban gas consumption, *Urban Climate*, 51, 101647.
- Rizk-Allah, R. M., Hassanien, A. E., Elhoseny, M., and Gunasekaran, M. 2019. A new binary salp swarm algorithm: Development and application for optimization tasks, *Neural Computing and Applications*, 31, 1641-1663.
- Romeh, A. E., and Mirjalili, S. 2023. Multi-Robot Exploration of Unknown Space Using Combined Meta-Heuristic Salp Swarm Algorithm and Deterministic Coordinated Multi-Robot Exploration, *Sensors*, 23(4), Article 4.
- Roy, S. S., Samui, P., Nagtode, I., Jain, H., Shivaramakrishnan, V., and Mohammadi-Ivatloo, B. 2020. Forecasting heating and cooling loads of buildings: A comparative performance analysis, *Journal of Ambient Intelligence and Humanized Computing*, 11, 1253-1264.
- Sait, S. M., Mehta, P., Gürses, D., and Yildiz, A. R. 2023. Cheetah optimization algorithm for optimum design of heat exchangers, *Materials Testing*, 65(8), 1230-1236.
- Salgotra, R., Singh, U., Singh, S., Singh, G., and Mittal, N. 2021. Self-adaptive salp swarm algorithm for engineering optimization problems, *Applied Mathematical Modelling*, 89, 188-207.
- Seven İ. 2021, Fan Coil Sistemleri, Fan Coil Nedir, <https://www.muhandisiz.net/fan-coil-sistemleri.html> [Erişim Tarihi: 05.07.2024].
- Sezer, K. S., ve Bayhan, N. 2021. Doğadan Esinlenen Optimizasyon Algoritmaları Tabanlı Kesir Dereceli PID Denetleyicilerle Kontrol Edilen Bir Santral Modelinin Performansının İncelemesi, *Bilecik Şeyh Edebalı Üniversitesi Fen Bilimleri Dergisi*, 8(1), 383-397.
- Shabani, M. O., and Mazahery, A. 2012. Prediction performance of various numerical model training algorithms in solidification process of A356 matrix composites, *Indian Journal of Engineering & Materiale Sciences*, 19, 129-134.

- Singer, S., and Nelder, J. 2009. Nelder-mead algorithm, *Scholarpedia*, 4(7), 2928.
- Surucu, O., Gadsden, S. A., and Yawney, J. 2023. Condition monitoring using machine learning: A review of theory, applications, and recent advances, *Expert Systems with Applications*, 221, 119738.
- Talatahari, S., and Azizi, M. 2021. Chaos game optimization: A novel metaheuristic algorithm, *Artificial Intelligence Review*, 54(2), 917-1004.
- Tawhid, M. A., and Ibrahim, A. M. 2022. Improved salp swarm algorithm combined with chaos, *Mathematics and Computers in Simulation*, 202, 113-148.
- Tien Bui, D., Moayedi, H., Anastasios, D., and Kok Foong, L. 2019. Predicting heating and cooling loads in energy-efficient buildings using two hybrid intelligent models, *Applied Sciences*, 9(17), 3543.
- Tien, P. W., Wei, S., Darkwa, J., Wood, C., and Calautit, J. K. 2022. Machine Learning and Deep Learning Methods for Enhancing Building Energy Efficiency and Indoor Environmental Quality – A Review, *Energy and AI*, 10, 100198.
- Tsanas, A., and Xifara, A. 2012. Energy efficiency, *UCI Machine Learning Repository*.
- Tubishat, M., Ja'afar, S., Alswaiti, M., Mirjalili, S., Idris, N., Ismail, M. A., and Omar, M. S. 2021. Dynamic salp swarm algorithm for feature selection, *Expert Systems with Applications*, 164(113873).
- Uniyal, N., Pant, S., Kumar, A., and Pant, P. 2022. Nature-inspired metaheuristic algorithms for optimization, *Meta-heuristic Optimization Techniques*, 1, 1-10.
- Vakiloroya, V., Samali, B., Fakhar, A., and Pishghadam, K. 2014. A review of different strategies for HVAC energy saving, *Energy Conversion and Management*, 77, 738-754.
- Wang, C., Xu, R., Ma, L., Zhao, J., Wang, L., Xie, N., and Cheong, K. H. 2023. An efficient salp swarm algorithm based on scale-free informed followers with self-adaption weight, *Applied Intelligence*, 53(2), 1759-1791.
- Wang, D., Shengqi, J., and Liu, X., 2018. A Simplex Method-Based Salp Swarm Algorithm for Numerical and Engineering Optimization, *In Intelligent Information Processing IX: 10th IFIP TC 12 International Conference, IIP 2018, Proceedings*, 10, Springer International Publishing, Nanning, China, 150-159.
- Wang, L., Khishe, M., Mohammadi, M., and Mahmoodzadeh, A. 2022. Extreme learning machine evolved by fuzzified hunger games search for energy and individual thermal comfort optimization, *Journal of Building Engineering*, 60, 105187.
- Wang, Q., Chen, G., Khishe, M., Ibrahim, B. F., and Rashidi, S. 2023. Multi-objective optimization of IoT-based green building energy system using binary metaheuristic algorithms, *Journal of Building Engineering*, 68, 106031.
- Wang, S., and Ma, Z. 2008. Supervisory and optimal control of building HVAC systems: A review, *Hvac&R Research*, 14(1), 3-32.
- Wang, W., Gelder, P. H. V., and Vrijling, J. K. 2007. Comparing Bayesian regularization and cross-validated early-stopping for streamflow forecasting with ANN models, *IAHS Publications-Series of Proceedings and Reports*, 311, 216-221.
- Yang, X., 2012. Swarm-based metaheuristic algorithms and no-free-lunch theorems, *Theory and New Applications of Swarm Intelligence*, National Physical Laboratory United Kingdom, 1-16.

- Yang, Y., Chen, H., Heidari, A. A., and Gandomi, A. H. 2021. Hunger games search: Visions, conception, implementation, deep analysis, perspectives, and towards performance shifts, *Expert Systems with Applications*, 177, 114864.
- Yıldız, A. R. (2006). “Tasarım Optimizasyon Problemlerinin Çözümü İçin Çok Amaçlı Arama Tabanlı Bir Sistemin Geliştirilmesi”, Doktora Tezi, *Fen Bilimleri Enstitüsü*, Uludağ Üniversitesi, Bursa, 128.
- Yıldız, B. S., Kumar, S., Pholdee, N., Bureerat, S., Sait, S. M., and Yildiz, A. R. 2022. A new chaotic Lévy flight distribution optimization algorithm for solving constrained engineering problems, *Expert Systems*, 39(8), e12992.
- Yıldız, B. S., Pholdee, N., Panagant, N., Bureerat, S., Yildiz, A. R., and Sait, S. M. 2021. A novel chaotic Henry gas solubility optimization algorithm for solving real-world engineering problems, *Engineering with Computers*, 1-13.
- Yuan, X., Karbasforousha, M. A., Syah, R. B. Y., Khajehzadeh, M., Keawsawasvong, S., and Nehdi, M. L. 2023. An Effective Metaheuristic Approach for Building Energy Optimization Problems, *Buildings*, 13(1), Article 1.
- Zeng, A., Ho, H., and Yu, Y. 2019. Prediction of building electricity usage using Gaussian Process Regression, *Journal of Building Engineering*, 28, 101054.
- Zeng, Y., Zhang, Z., and Kusiak, A. 2015. Predictive modeling and optimization of a multi-zone HVAC system with data mining and firefly algorithms, *Energy*, 86, 393-402.
- Zhang, H., Cai, Z., Ye, X., Wang, M., Kuang, F., Chen, H., and Li, Y. 2022. A multi-strategy enhanced salp swarm algorithm for global optimization, *Engineering with Computers*, 1-27.
- Zhang, J., Wang, Z., and Luo, X. 2018. Parameter estimation for soil water retention curve using the salp swarm algorithm, *Water*, 10(6), 815.
- Zhao, S., Zhang, T., Ma, S., and Chen, M. 2022. Dandelion Optimizer: A nature-inspired metaheuristic algorithm for engineering applications, *Engineering Applications of Artificial Intelligence*, 114, 105075.
- Zubaidi, S. L., Abdulkareem, I. H., Hashim, K. S., Al-Bugharbee, H., Ridha, H. M., Gharghan, S. K., Al-Qaim, F. F., Muradov, M., Kot, P., and Al-Khaddar, R. 2020. Hybridised artificial neural network model with slime mould algorithm: A novel methodology for prediction of urban stochastic water demand, *Water*, 12(10), 2692.

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı : Şeyma Nur ATAR

EĞİTİM

Derece	Adı, İlçe, İl	Bitirme Yılı
Lise	: Emel Çatal Anadolu Lisesi, Erzurum/Merkez	2015
Üniversite	: Atatürk Üniversitesi Erzurum	2021
Yüksek Lisans	: Muş Alparslan Üniversitesi. Muş	Devam ediyor

YABANCI DİLLER

İngilizce, Almanca

YAYINLAR