

T.C.  
SAKARYA ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ

ENERJİ VERİMLİLİĞİ ANALİZİNDE İYİLEŞTİRİLMİŞ YABANI  
AT ENİYİLEYİCİ – ÇOK KATMANLI ALMAÇ HİBRİT  
(IWHO-MLP) MODELİNİN KULLANIMI

DOKTORA TEZİ

Şahiner GÜLER

Bilgisayar Mühendisliği Anabilim Dalı

Bilgisayar Mühendisliği Bilim Dalı

TEMMUZ 2025



**T.C.  
SAKARYA ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ**

**ENERJİ VERİMLİLİĞİ ANALİZİNDE İYİLEŞTİRİLMİŞ YABANI  
AT ENİYİLEYİCİ – ÇOK KATMANLI ALMAÇ HİBRİT  
(IWHO-MLP) MODELİNİN KULLANIMI**

**DOKTORA TEZİ**

**Şahiner GÜLER**

**Bilgisayar Mühendisliği Anabilim Dalı**

**Bilgisayar Mühendisliği Bilim Dalı**

**Tez Danışmanı: Prof. Dr. Nejat YUMUŞAK**

**TEMMUZ 2025**



Şahiner GÜLER tarafından hazırlanan “Enerji Verimliliği Analizinde İyileştirilmiş Yabani At Eniyileyici – Çok Katmanlı Almaç Hibrit (IWHO-MLP) Modelinin Kullanımı” adlı tez çalışması 11.07.2025 tarihinde aşağıdaki jüri tarafından oy birliği / oy çokluğu ile Sakarya Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı Bilgisayar Mühendisliği Bilim Dalı’nda Doktora tezi olarak kabul edilmiştir.

### Tez Jürisi

|                      |                                                 |
|----------------------|-------------------------------------------------|
| <b>Jüri Başkanı:</b> | <b>Prof. Dr. Nejat YUMUŞAK (Danışman)</b> ..... |
|                      | Sakarya Üniversitesi                            |
| <b>Jüri Üyesi:</b>   | <b>Prof. Dr. Devrim AKGÜN</b> .....             |
|                      | Sakarya Üniversitesi                            |
| <b>Jüri Üyesi:</b>   | <b>Dr. Öğr. Üyesi Güzde YOLCU ÖZTEL</b> .....   |
|                      | Sakarya Üniversitesi                            |
| <b>Jüri Üyesi :</b>  | <b>Doç. Dr. Zeydin PALA</b> .....               |
|                      | Muş Alparslan Üniversitesi                      |
| <b>Jüri Üyesi :</b>  | <b>Dr. Öğr. Üyesi İhsan TUĞAL</b> .....         |
|                      | Muş Alparslan Üniversitesi                      |



## **ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ**

Sakarya Üniversitesi Fen Bilimleri Enstitüsü Lisansüstü Eğitim-Öğretim Yönetmeliğine ve Yükseköğretim Kurumları Bilimsel Araştırma ve Yayın Etiği Yönergesine uygun olarak hazırlamış olduğum “Enerji Verimliliği Analizinde İyileştirilmiş Yabani At Eniyileyici – Çok Katmanlı Almaç Hibrit (IWHO-MLP) Modelinin Kullanımı” başlıklı tezin bana ait, özgün bir çalışma olduğunu; çalışmamın tüm aşamalarında yukarıda belirtilen yönetmelik ve yönergeye uygun davrandığımı, tezin içerdiği yenilik ve sonuçları başka bir yerden almadığımı, tezde kullandığım eserleri usulüne göre kaynak olarak gösterdiğimi, bu tezi başka bir bilim kuruluna akademik amaç ve unvan almak amacıyla vermediğimi ve 20.04.2016 tarihli Resmi Gazete’de yayımlanan Lisansüstü Eğitim ve Öğretim Yönetmeliğinin 9/2 ve 22/2 maddeleri gereğince Sakarya Üniversitesi’nin abonesi olduğu intihal yazılım programı kullanılarak Enstitü tarafından belirlenmiş ölçütlere uygun rapor alındığını, çalışmamla ilgili yaptığım bu beyana aykırı bir durumun ortaya çıkması halinde doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi beyan ederim.

(08/08/2025)

(imza)

Şahiner GÜLER





*Anneme, babama, eşime ve çocuklarıma...*



## TEŞEKKÜR

Doktora eğitimim boyunca tavsiye ve fikirleri için danışman hocam sayın Prof. Dr. Nejat YUMUŞAK'a ve tecrübelerinden her zaman faydalanmamı sağlayan değerli Dr. Öğr. Üyesi Erdal Eker'e sonsuz teşekkürlerimi sunarım.

Bütün hayatım boyunca desteklerini her zaman hissettiren annem ve babama, lisans üstü eğitim hayatım süresince sabırla ve teşvik edici tavırlarıyla her zaman arkamda duran değerli eşim ve çocuklarıma çok teşekkür ederim.

Şahiner GÜLER



## İÇİNDEKİLER

### Sayfa

|                                                                                  |      |
|----------------------------------------------------------------------------------|------|
| ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ .....                                | v    |
| TEŞEKKÜR .....                                                                   | ix   |
| İÇİNDEKİLER .....                                                                | xi   |
| KISALTMALAR .....                                                                | xiii |
| SİMGELER .....                                                                   | xv   |
| TABLO LİSTESİ .....                                                              | xvii |
| ŞEKİL LİSTESİ .....                                                              | xix  |
| ÖZET .....                                                                       | xxi  |
| SUMMARY .....                                                                    | xxv  |
| 1. GİRİŞ .....                                                                   | 1    |
| Literatür Araştırması .....                                                      | 4    |
| 2. YAPAY SİNİR AĞLARI ve MLP .....                                               | 13   |
| 2.1. Yapay Sinir Ağı .....                                                       | 13   |
| 2.2. Çok Katmanlı Almaç Mimarisi (MLP) .....                                     | 14   |
| 2.3. Geri Yayılım .....                                                          | 16   |
| 3. SEZGİSEL ÜSTÜ ALGORİTMALAR .....                                              | 19   |
| 4. IWHO HİBRİT ALGORİTMASI İLE ENİYİLEME PROBLEMLERİNİN ÇÖZÜMÜ .....             | 23   |
| 4.1. Yabani At Eniyileyici .....                                                 | 25   |
| 4.1.1. Başlangıç aşaması .....                                                   | 27   |
| 4.1.2. İkinci aşama: otlama davranışı - yerel arama stratejisi .....             | 27   |
| 4.1.3. Üçüncü aşama: çiftleşme davranışı – çözümlerin birleştirilmesi .....      | 28   |
| 4.1.4. Dördüncü aşama: grup liderliği – en iyi çözümleri takip, sömürü fazı .... | 30   |
| 4.1.5. Beşinci aşama: liderlerin değişimi ve seçimi – yeni nesil oluşturma ..... | 30   |
| 4.2. Random Walk Stratejisi .....                                                | 31   |
| 4.3. Wild Horse – Random Walk (IWHO) Algoritması .....                           | 31   |
| 4.4. Çalışmada Kullanılan Diğer Algoritmalar .....                               | 35   |
| 4.4.1. Capuchin arama algoritması .....                                          | 35   |
| 4.4.2. Harris hawks eniyileme algoritması .....                                  | 36   |
| 4.4.3. Balina – harris hawk – havai fişek algoritması .....                      | 36   |
| 4.4.4. Balina – yabani at eniyileyici .....                                      | 36   |
| 4.4.5. Rastgele yürüyüş – karahindiba algoritması .....                          | 37   |
| 5. IWHO TABANLI MLP EĞİTİMİ İLE ENERJİ VERİMLİLİĞİ PROBLEMİNİN ÇÖZÜMÜ .....      | 39   |
| 5.1. Isıtma, Havalandırma, Klima .....                                           | 39   |
| 5.2. IWHO Algoritması'nın Performans Üstünlüğü .....                             | 39   |
| 5.2.1. Wilcoxon testi .....                                                      | 43   |
| 5.2.2. Duyarlılık analizi .....                                                  | 44   |
| 5.2.3. Kutu grafikleri .....                                                     | 46   |
| 5.2.4. Yakınsama eğrisi .....                                                    | 49   |
| 5.2.5. Big-O notasyonu .....                                                     | 51   |

|                                                     |           |
|-----------------------------------------------------|-----------|
| 5.3. Önerilen IWHO Algoritması ile MLP Eğitimi..... | 51        |
| <b>6. SONUÇ VE ÖNERİLER.....</b>                    | <b>57</b> |
| <b>KAYNAKLAR.....</b>                               | <b>63</b> |
| <b>ÖZGEÇMİŞ.....</b>                                | <b>73</b> |



## **KISALTMALAR**

|              |                                               |
|--------------|-----------------------------------------------|
| <b>ABC</b>   | : Artificial Bee Colony                       |
| <b>ACO</b>   | : Ant Colony Optimization Algorithm           |
| <b>APSO</b>  | : Adaptive Particle Swarm Optimization        |
| <b>CapSA</b> | : Capuchin Search Algorithm                   |
| <b>CEC</b>   | : Congress on Evolutionary Computation        |
| <b>CL</b>    | : Cooling Load                                |
| <b>CNN</b>   | : Convolutional Neural Network                |
| <b>FPA</b>   | : Flower Pollination Algorithm                |
| <b>GA</b>    | : Genetic Algorithm                           |
| <b>GOA</b>   | : Grasshopper Optimization Algorithm          |
| <b>GWO</b>   | : Grey Wolf Optimization                      |
| <b>IWHO</b>  | : Improved Wild Horse Optimizer               |
| <b>HL</b>    | : Heating Load                                |
| <b>HRES</b>  | : Hybrid Renewable Energy Systems             |
| <b>HS</b>    | : Harmony Search                              |
| <b>HVAC</b>  | : Heating, Ventilation, and Air Conditioning  |
| <b>IoT</b>   | : Internet of Things                          |
| <b>KNN</b>   | : K-Nearest Neighbors                         |
| <b>MLP</b>   | : Multilayer Perceptron                       |
| <b>MOPSO</b> | : Multi-Objective Particle Swarm Optimization |
| <b>NDSGA</b> | : Non – Dominated Sorting Genetic Algorithm   |
| <b>PSO</b>   | : Particle Swarm Optimization                 |
| <b>RW</b>    | : Random Walk                                 |
| <b>SVM</b>   | : Support Vector Machine                      |
| <b>TS</b>    | : Tabu Search                                 |
| <b>UCI</b>   | : University of California Irvine             |
| <b>WHO</b>   | : Wild Horse Optimizer                        |
| <b>WOA</b>   | : Whale Optimization Algorithm                |
| <b>WHOW</b>  | : Whale – Wild Horse Optimizer                |
| <b>YSA</b>   | : Yapay Sinir Ağları                          |



## SİMGELER

|                             |                                        |
|-----------------------------|----------------------------------------|
| $b$                         | : Bias değeri                          |
| $f(X_{G,j}^i)$              | : Tayların uygunluk değeri             |
| $f(Stallion_{G,j})$         | : Aygırların uygunluk değeri           |
| $i$                         | : Çıkış değerlerinin sayısı            |
| $lb, ub$                    | : Alt ve üst sınırlar                  |
| $N$                         | : Ağın boyutu                          |
| $O_i$                       | : Gerçek çıkış                         |
| $P$                         | : 0 ile 1'lerden oluşan bir vektör     |
| $P_i$                       | : Tahminî çıkış                        |
| $\overline{P_i}$            | : Veri setinin ortalama değeri         |
| $\overrightarrow{R_1}$      | : 0 – 1 arasındaki rastgele vektörler  |
| $R_2$                       | : 0 – 1 arasındaki rastgele sayılar    |
| $\overrightarrow{R_3}$      | : 0 – 1 arasındaki rastgele vektörler  |
| $\overline{Stallion}_{G,j}$ | : j. gruptaki aday liderin pozisyonu   |
| $Stallion_{G,j}$            | : j. gruptaki mevcut liderin pozisyonu |
| $t$                         | : Mevcut yineleme sayısı               |
| $t_{max}$                   | : Maksimum sayıda yinelemeler          |
| $v$                         | : Giriş vektörü                        |
| $X_{G,j}^i$                 | : j. gruptaki üyenin pozisyonları      |
| $Z$                         | : Hesaplanan uyarlanabilir parametre   |
| $\varphi(v)$                | : Transfer fonksiyonu                  |



## TABLO LİSTESİ

### Sayfa

|                                                                                            |    |
|--------------------------------------------------------------------------------------------|----|
| <b>Tablo 5.1.</b> Kullanılan algoritmadaki parametreler. ....                              | 40 |
| <b>Tablo 5.2.</b> CEC 2019 test fonksiyonları. ....                                        | 40 |
| <b>Tablo 5.3.</b> CEC 2019 fonksiyonlarının istatistikî performans sonuçları. ....         | 41 |
| <b>Tablo 5.4.</b> IWHO-MLP ile diğer hibrit algoritma sonuçlarının karşılaştırılması. .... | 42 |
| <b>Tablo 5.5.</b> Wilcoxon test sonuçları. ....                                            | 43 |
| <b>Tablo 5.6.</b> RW = 300 adım için duyarlılık analizi. ....                              | 45 |
| <b>Tablo 5.7.</b> RW = 500 adım için duyarlılık analizi. ....                              | 46 |
| <b>Tablo 5.8.</b> Regresyonel ölçümlerin sonuçları. ....                                   | 54 |
| <b>Tablo 5.9.</b> Veri sayısına göre yinleme ve işlem sayısının değişimi. ....             | 55 |
| <b>Tablo 5.10.</b> MLP notasyon tablosu özeti. ....                                        | 56 |



## ŞEKİL LİSTESİ

### Sayfa

|                                                                                                                    |    |
|--------------------------------------------------------------------------------------------------------------------|----|
| Şekil 2.1. Bir yapay sinir ağı hücresi yapısı ve temel elemanları. ....                                            | 13 |
| Şekil 2.2. Doğrusal olarak ayrılabilen desenler çifti ve doğrusal olmayan şekilde ayrılabilen desenler çifti. .... | 15 |
| Şekil 2.3. Çok katmanlı yapay sinir ağında öğrenme (Işıkhah, 2020). ....                                           | 16 |
| Şekil 2.4. Fonksiyon ve hata sinyallerinin yönlerinin gösterimi. ....                                              | 17 |
| Şekil 3.1. Sezgisel üstü algoritmaların sınıflandırılması (Zheng vd., 2022). ....                                  | 21 |
| Şekil 4.1. Eniyileme süreci. ....                                                                                  | 25 |
| Şekil 4.2. WHO algoritmasının sürü şeması. ....                                                                    | 26 |
| Şekil 4.3. Orijinal sürüden grupların oluşumu (Naruei & Keynia, 2021). ....                                        | 27 |
| Şekil 4.4. Tayların gruptan ayrılma ve çiftleşme davranışları (Naruei & Keynia, 2021). ....                        | 29 |
| Şekil 4.5. IWHO akış şeması. ....                                                                                  | 32 |
| Şekil 5.1. Kutu grafiği modelinin gösterimi ....                                                                   | 46 |
| Şekil 5.2. İstatistikî sonuçların kutu grafiği karşılaştırmaları. ....                                             | 48 |
| Şekil 5.3. CEC 2019 fonksiyonlarının yakınsama eğrileri. ....                                                      | 50 |
| Şekil 5.4. Big O Notasyonu karmaşıklık grafiği. ....                                                               | 51 |
| Şekil 5.5. Enerji verimliliği problemi veriseti için MLP Mimarisi. ....                                            | 53 |
| Şekil 5.6. CL ve HL için ortalama MSE değerleri. ....                                                              | 54 |
| Şekil 5.7. Ortalama işlem zamanları. ....                                                                          | 55 |
| Şekil 5.8. IWHO-MLP Algoritması'nın hesaplama karmaşıklığı . ....                                                  | 56 |



## **ENERJİ VERİMLİLİĞİ ANALİZİNDE İYİLEŞTİRİLMİŞ YABANI AT ENİYİLEYİCİ – ÇOK KATMANLI ALMAÇ HİBRİT (IWHO-MLP) MODELİNİN KULLANIMI**

### **ÖZET**

Günümüzde enerji verimliliği, sürdürülebilir kalkınma hedeflerine uygun olarak doğal kaynakların korunmasında, çevresel etkilerin en aza indirilmesinde ve ekonomik faydaların en üst düzeye çıkarılmasında çok önemlidir. Artan küresel nüfus, sanayileşme ve teknolojik gelişmelerle birleştiğinde, enerji talebinde sürekli bir artışa neden olmakta ve mevcut enerji kaynaklarının daha verimli ve etkin bir şekilde kullanılmasını gerektirmektedir. Fosil yakıtların sınırlı doğası ve olumsuz çevresel etkileri, yenilenebilir enerji kaynaklarının ve enerji verimliliği girişimlerinin önemini artırmaktadır. Enerji verimliliği, sadece enerji tüketiminin azaltılmasını değil, aynı zamanda enerji kaynaklarının akıllı ve sürdürülebilir yönetimini de kapsar.

Binalardaki enerji tüketiminin önemli bir kısmı ısıtma, havalandırma ve iklimlendirme (HVAC) sistemlerine bağlanmaktadır. Bu sistemlerin verimliliğini artırmak hem enerji tasarrufu hem de maliyet avantajları sağlayabilir. Akıllı binalar ve enerji yönetim sistemleri, enerji tüketiminin izlenmesi, analizi ve en iyilemesi büyük önem taşıyarak enerji verimliliğini artırmak için çeşitli teknolojiler ve yöntemler geliştirmektedir. Enerji verimliliği değerlendirmelerinde, yapay zekâ ve en iyileme tekniklerinin uygulanması, geleneksel yöntemlerin yerini alarak giderek daha önemli hale gelmiştir.

En iyileme, ana bileşenleri amaç fonksiyonu, karar değişkenleri ve kısıtlar olan bir probleme en uygun çözümün belirlenmesini içerir. Amaç fonksiyonu, ele alınacak problemi tanımlar, karar değişkenleri çözüm için parametreleri belirtir ve kısıtlar ekonomik, zamansal, sistemik veya fiziksel sınırlamaları temsil eder. En iyileme süreci, ürün üretim verimliliğini veya kar marjlarını en üst düzeye çıkarmayı hedefleyebilir veya enerji tüketimini, yatırım riskini veya operasyonel maliyetleri en aza indirmeye odaklanabilir. Geleneksel deterministik algoritmalar, özellikle çok boyutlu, doğrusal olmayan ve karmaşık problemlerde yetersiz kalabilir ve bu da çözüm sürelerinin uzamasına veya yerel minimumlarda sıkışıp kalınmasına neden olabilir. Bu gibi durumlarda, klasik algoritmaların problem çözme kapasitesi sınırlıdır ve çözüm alanının büyüklüğü ve karmaşıklığı nedeniyle istenen sonuca ulaşmak zordur. Ancak son yıllarda, doğadan ilham alan metasezgisel algoritmalar, özellikle enerji verimliliği gibi karmaşık problemler için sağlam ve uyarlanabilir çözüm stratejileri olarak ortaya çıkmıştır.

Sezgisel üstü algoritmalar, keşif ve sömürüyü etkin bir şekilde dengeleyerek arama alanı içinde daha verimli ve hızlandırılmış çözümler sağlama yeteneğine sahiptir. Bununla birlikte, bu algoritmalar yerel minimumlara takılma ve erken yakınsama gibi zorluklarla karşılaşabilir.

Bu tez, Wild Horse Optimizer (WHO) algoritmasının en iyileme süreçlerindeki performansını, özellikle sömürü aşamasındaki eksikliklerini ele alarak ve algoritmayı geliştirerek çözüm kalitesini arttırmayı amaçlamaktadır. Bu amacı gerçekleştirmek

için, Rastgele Yürüyüş Stratejisi ile Geliştirilmiş Vahşi At Eniyileyici (IWHO) geliştirilmiştir. Bu yeni algoritma, en iyileme süreçlerinde çözüm çeşitliliğini artırmayı, yerel alanlarda sıkışmayı önlemeyi, daha kararlı, hızlı ve güvenilir sonuçlar elde etmeyi amaçlamaktadır. IWHO algoritması, rastgele bir yürüyüş stratejisi yardımıyla WHO'nun sömürü aşamasındaki zayıflıklarını iyileştirerek, daha geniş bir arama alanını etkili bir şekilde keşfetmesini ve yerel minimumlara takılmadan küresel en iyi noktaya ulaşmasını sağlar.

IWHO algoritmasının performansı, karmaşık ve çok boyutlu CEC 2019 test fonksiyonları kullanılarak kapsamlı bir şekilde değerlendirilmiş ve 51 bağımsız çalışma yapılmıştır. CEC 2019 fonksiyonları, zorlu yapıları ve karmaşık çözüm alanları nedeniyle akademik çevrelerde büyük saygı görmekte ve bu da onları algoritmaların sağlamlığını ve istatistiksel güvenilirliğini değerlendirmek için ideal bir ölçüt haline getirmektedir.

Yakınsama eğrileri ve kutu grafiği analizleriyle desteklenen sonuçlar, IWHO algoritmasının sömürü ve keşfi etkili bir şekilde dengelediğini ve yerel minimumlara takılıp kalmadan küresel en iyi noktaya ulaştığını göstermiştir. HHO, CapSA ve RW-DO gibi algoritmalarla karşılaştırıldığında, IWHO algoritmasının rekabet avantajı gayet açık olmuştur. 30 testin 24'ünde en iyi sonuçları elde etmiş, 5'inde rakip algoritma ile yenilememiş ve sadece 1'inde ortalamanın altında kalmıştır. CEC01, CEC03, CEC04 ve CEC10 gibi fonksiyonlar için kutu grafiklerindeki düşük varyans ve kısa bıyıklar, algoritmanın kararlı yapısını minimum hatayla göstermiştir. Wilcoxon işaretli sıra testi ve Bonferroni düzeltmesi de dahil olmak üzere istatistiksel analizler, algoritmanın hem kararlılık hem de hız açısından rekabet gücünü doğrulamıştır. Wilcoxon test sonuçları, gözlenen farklılıkların istatistiksel olarak anlamlı olduğunu göstermiştir (p değerleri genellikle 0.001'den küçüktür), bu da IWHO'nun rastgele başarıdan ziyade yapısal olarak üstünlüğünün olduğunu göstermektedir. Parametre duyarlılık analizleri, parametrelerin algoritmanın performansı üzerindeki etkisini değerlendirmiş ve  $C = 0.13$  ve  $ps = 0.2$  parametre kombinasyonu ile en iyi sonuçların elde edildiğini ortaya koymuştur. Bu bulgu, IWHO algoritmasının parametrik esnekliğini ve çeşitli problem türlerine uyarlanabilirliğini vurgulamaktadır. Ayrıca, algoritmanın hibritleştirmeye uygun esnek yapısı, ileri mühendislik problemlerinden yapay öğrenme süreçlerine kadar çok çeşitli uygulamalara olanak tanır.

Algoritmanın gerçek dünya senaryolarına uygulanabilirliğini göstermek için, California Irvine Üniversitesi'nden Enerji Verimliliği Problemi veri seti kullanılmıştır. Bu veri seti, HVAC sistemlerinin enerji verimliliğini artırmak için ısıtma ve soğutma yüklerini verimli bir şekilde tahmin etmeyi amaçlayan, akıllı binaların girdi özelliklerini dikkate alarak ısıtma ve soğutma yükü faktörlerini değerlendirir. Bu bağlamda, Çok Katmanlı Perceptron (MLP) mimarisi eğitilmiş ve hem klasik WHO hem de geliştirilen IWHO algoritmaları ile karşılaştırılmıştır. Bulgular, IWHO-MLP algoritmasının klasik WHO-MLP ve literatürde öne çıkan diğer algoritmalara (HHO, CapSA, RW-DO) kıyasla daha düşük hata oranları ve daha yüksek tahmin doğruluğu elde ettiğini göstermektedir.

Özellikle, HVAC sistemleri ile ilgili örnek veri setleri üzerinde yapılan değerlendirmeler, WHO'nun en iyileme sürecini daha hızlı ve doğru bir şekilde tamamladığını göstermiştir. Bu sonuçlar, karmaşık mühendislik tabanlı en iyileme problemleri için bir araç olarak IWHO'nun güvenilirliğini doğrulamaktadır. Yakınsama eğrilerine dayalı analizler, IWHO-MLP algoritmasının erken yakınsamaya takılmadan her yinelemede kademeli olarak ilerlediğini ve etkin bir şekilde küresel

çözümüne ulaştığını göstermektedir. Bu, algoritmanın yerel minimumlara takılıp kalmadan sürekli keşif yeteneğini korurken çözüm alanını verimli bir şekilde taradığını gösterir. Bununla birlikte, IWHO algoritması, WHO'ya kıyasla çalışma süresinde %22,98'lik bir artış yaşasa da elde edilen performans iyileştirmesi ışığında bu artış ihmal edilebilir olarak kabul edilmektedir.

Sunulan bulgular, IWHO-MLP algoritmasının hem teorik hem de pratik düzeyde sağlam, uyarlanabilir ve yenilikçi bir en iyileme yaklaşımı olduğunu doğrulamaktadır. Hibrit yapısı, ileri mühendislikten yapay öğrenme süreçlerine kadar geniş bir uygulama yelpazesine olanak tanır ve çeşitli stratejiler aracılığıyla yerel arama zayıflıklarını etkin bir şekilde ele alır.

IWHO-MLP algoritması, geleneksel WHO algoritması ile karşılaştırıldığında üstün performans göstermiş ve literatürdeki zorlu rakiplerini geride bırakmıştır. Parametrik esnekliği ve hibrit yapısı sayesinde çeşitli alanlara uyarlanabilirliği gözlemlenmiştir ve bu özellik de onu yapay sinir ağı eğitimi gibi gelişmiş yapay zekâ problemlerine uygulanabilir hale getirir. Enerji verimliliği, çağdaş sürdürülebilir kalkınma hedefleri doğrultusunda doğal kaynakları korumak, çevresel etkileri azaltmak ve ekonomik faydaları en üst düzeye çıkarmak için çok önemlidir. Bu çalışma, yapay sinir ağı eğitiminde ve başta enerji verimliliği olmak üzere diğer disiplinler arası alanlarda yeni nesil en iyileme tekniklerinin ilerlemesine katkı sağlamaktadır.

IWHO-MLP algoritmasının başarıları, gelecekte çeşitli mühendislik ve yapay zekâ bağlamlarında etkili uygulama potansiyelini vurgulamaktadır. Sonuç olarak, bu tez çalışmasında Rastgele Yürüyüş Stratejisi ile hibritleştirilen Geliştirilmiş Yaban Atı En İyileme Algoritması (IWHO-MLP), enerji verimliliği analizleri ve ileri yapay zekâ uygulamaları için güvenilir, esnek ve yenilikçi bir en iyileme aracı olarak ortaya çıkmaktadır. Algoritmanın hibrit yapısı, parametrik esnekliği ve farklı problem tiplerine adaptasyon kolaylığı ona literatürdeki güçlü rakiplerine karşı avantaj sağlamaktadır. Bulgular, IWHO-MLP algoritmasının hem teorik hem de pratik düzeyde mühendislik tabanlı karmaşık en iyileme problemleri için etkili bir çözüm sağladığını göstermektedir.

**Anahtar Kelimeler:** Sezgisel üstü algoritmalar, Hibrit sezgisel üstü algoritmalar, Random Walk Stratejisi, Yapay sinir ağları, Wild Horse Optimizer, WHO, Çok katmanlı almaç, MLP, Enerji Verimliliği, HVAC Sistemleri.



# **USING AN IMPROVED WILD HORSE OPTIMIZER - MULTILAYER PERCEPTRON HYBRID (IWHO-MLP) MODEL IN ENERGY EFFICIENCY ANALYSIS**

## **SUMMARY**

Currently, energy efficiency is pivotal in conserving natural resources, minimizing environmental impacts, and maximizing economic benefits in accordance with sustainable development goals. The increasing global population, industrialization, and technological advancements have led to a continuous rise in energy demand, necessitating the more efficient and effective use of existing energy sources. The finite nature of fossil fuels and their adverse environmental effects have highlighted the importance of renewable energy sources and energy efficiency initiatives. Energy efficiency encompasses not only the reduction of energy consumption but also the intelligent and sustainable management of energy resources.

A significant portion of energy consumption in buildings is attributed to heating, ventilation, and air conditioning (HVAC) systems. Improving the efficiency of these systems can result in both energy savings and cost benefits. Smart buildings and energy management systems have increasingly adopted various technologies and methods to monitor, analyze, and optimize energy consumption. In energy efficiency assessments, the application of artificial intelligence and optimization techniques has gained prominence, gradually replacing traditional approaches.

Optimization involves determining the most appropriate solution to a problem defined by three main components: the objective function, decision variables, and constraints. The objective function defines the problem to be addressed, decision variables indicate the parameters for the solution, and constraints represent economic, temporal, systemic, or physical limitations. The optimization process may aim to maximize production efficiency or profit margins or focus on minimizing energy consumption, investment risks, or operational costs. However, traditional deterministic algorithms may fall short, especially when dealing with high-dimensional, nonlinear, and complex problems, often resulting in prolonged computation times or entrapment in local optima. Consequently, due to the vastness and complexity of the solution space, these methods often fail to reach the desired global optimum. In recent years, nature-inspired metaheuristic algorithms have emerged as robust and adaptable solution strategies for such complex problems, particularly in the field of energy efficiency.

Metaheuristic algorithms possess the capability to balance exploration and exploitation effectively, enabling more efficient and accelerated solutions across the search space. Nevertheless, they are still prone to challenges such as getting trapped in local minima and premature convergence.

This thesis aims to enhance the performance of the Wild Horse Optimizer (WHO) algorithm, particularly by addressing its shortcomings in the exploitation phase, and to improve solution quality. To achieve this goal, the Improved Wild Horse Optimizer (IWHO) was developed by integrating a Random Walk Strategy. This new algorithm aims to increase solution diversity, prevent stagnation in local regions, and obtain more

stable, faster, and reliable results in optimization processes. By leveraging the random walk mechanism, the IWHO enhances the exploitation phase of the original WHO algorithm, enabling a more effective exploration of the solution space and the attainment of the global optimum without being confined to local minima.

The performance of the IWHO algorithm was extensively evaluated using the complex and high-dimensional CEC 2019 benchmark functions, based on 51 independent runs. Due to their challenging structures and complex solution landscapes, the CEC 2019 functions are highly respected in academic circles and serve as an ideal metric for assessing the robustness and statistical reliability of optimization algorithms.

The results, supported by convergence curves and boxplot analyses, demonstrated that the IWHO algorithm effectively balances exploitation and exploration, achieving global optima without becoming trapped in local minima. Compared to other algorithms such as HHO, CapSA, and RW-DO, the IWHO showed a clear competitive advantage – achieving the best results in 24 out of 30 tests, tying in 5, and falling below average in only 1 case. Low variance and short whiskers observed in boxplots for functions such as CEC01, CEC03, CEC04, and CEC10 indicate the algorithm's stable performance with minimal error. Statistical analyses, including the Wilcoxon signed-rank test and Bonferroni correction, confirmed the algorithm's competitive strength in terms of both stability and speed. The Wilcoxon test results showed that the observed differences were statistically significant (p-values generally below 0.001), indicating that the superiority of the IWHO stems from structural advantages rather than random success. Parameter sensitivity analyses revealed that the parameter combination of  $C = 0.13$  and  $ps = 0.2$  yielded optimal results, highlighting the algorithm's parametric flexibility and adaptability to various problem types. Additionally, its flexible architecture is conducive to hybridization, making it applicable to a wide range of domains, from advanced engineering problems to machine learning processes.

To demonstrate the algorithm's applicability to real-world scenarios, the Energy Efficiency Problem dataset from the University of California, Irvine was used. This dataset evaluates heating and cooling load factors by considering the input features of smart buildings to efficiently predict HVAC energy demands. In this context, a Multilayer Perceptron (MLP) model was trained and compared using both the classical WHO and the developed IWHO algorithms. The results indicate that the IWHO-MLP algorithm achieved lower error rates and higher prediction accuracy compared to the classical WHO-MLP and other prominent algorithms in the literature (HHO, CapSA, RW-DO).

In particular, the evaluations conducted on sample HVAC-related datasets revealed that the IWHO successfully completed the optimization process more rapidly and accurately. These results validate the reliability of the IWHO as a tool for solving complex, engineering-based optimization problems. Convergence-based analyses showed that the IWHO-MLP algorithm advanced incrementally in each iteration without falling into premature convergence, reaching the global solution effectively. This demonstrates the algorithm's ability to continuously explore the search space while avoiding local traps. Although the IWHO algorithm showed a 22.98% increase in computational time compared to WHO, this increase is considered negligible in light of the performance improvements achieved.

The presented findings validate the IWHO-MLP algorithm as a robust, adaptable, and innovative optimization approach on both theoretical and practical levels. Its hybrid nature enables its use across a wide spectrum of applications – from advanced

engineering to artificial learning processes – and effectively addresses weaknesses in local search through various strategies.

Compared to the classical WHO algorithm, the IWHO-MLP demonstrated superior performance and outperformed challenging competitors in literature. Due to its parametric flexibility and hybrid structure, it exhibits high adaptability across various domains, making it suitable for advanced AI problems such as neural network training. Energy efficiency is crucial for protecting natural resources, reducing environmental impacts, and maximizing economic benefits in accordance with contemporary sustainable development goals. This study contributes to the advancement of next-generation optimization techniques in neural network training and interdisciplinary domains, particularly in energy efficiency.

The achievements of the IWHO-MLP algorithm underscore its potential for effective application in future engineering and artificial intelligence contexts. In conclusion, this thesis presents the Improved Wild Horse Optimization Algorithm hybridized with Random Walk Strategy (IWHO-MLP) as a reliable, flexible, and innovative optimization tool for energy efficiency analysis and advanced AI applications. Its hybrid architecture, parametric flexibility, and adaptability to different problem types provide it with a competitive advantage over strong alternatives in the literature. The results demonstrate that the IWHO-MLP algorithm offers an effective solution for engineering-based complex optimization problems at both theoretical and practical levels.

**Keywords:** Metaheuristic Algorithms, Hybrid Metaheuristic Algorithms, Random Walk Strategy, Artificial Neural Network, Wild Horse Optimizer, WHO, Multilayer Perceptron, MLP, Energy Efficiency, HVAC Systems.



## 1. GİRİŞ

Eniyileme, belirli bir sistem veya sürecin parametrelerini en az maliyetle geliřtirmek için matematiksel veya analitik yöntemler kullanan bir dizi görevi içerir. Bu süreç, problemin küresel en iyi noktaya ulaşmasını sağlayan bir yörünge izler (Izci, 2021). Bugüne kadar eniyileme, mühendislik, finans ve bilim alanlarındaki zorlukları ele almak için matematiksel modellerle temsil edilen gerçek dünya problemlerine uygulanmıştır (Eker vd., 2021), (R.M., t.y.). Eniyileme algoritmalarının geliştirilmesi, mühendislik, bilim, ekonomi ve iş dünyası dahil olmak üzere çeşitli alanlarda eniyileme sorunlarını ele almada önemli ilgi görmüştür (Rao & Desai, 1980), (Antoniou & Lu, 2021).

Gerçek dünya eniyileme problemleri, matematiksel olarak ifade edilirse çözülebilir. Gerçek dünya zorlukları ele alınırken, istenen değişkenlerin en iyi olarak türetilmesi çok önemlidir. Zeki algoritmalar bu problemleri çözmek için hayatî araçlar olarak kabul edilmiştir. Bu algoritmalar deterministik ve rastgele türlere ayrılır (Zhao vd., 2020). Ancak, deterministik algoritmalar karmaşık matematiksel hesaplamalar gerekliliğı, türev gerektirmeyen uygulama zorlukları ve yerel en iyi noktalarda sıkışma eğilimi gibi çeşitli sınırlamalara maruz kalmaktadır (Heidari vd., 2019). Bu sınırlamaların azaltılabilmesi için deterministik olmayan, türev içermeyen yöntemler içeren rastgele algoritmalar kullanılmıştır. Bu bağlamda, rastgele algoritmalar olarak sınıflandırılan sezgisel üstü eniyileme teknikleri, bu gereksinimi karşılamak için umut verici çözümler sunar. Bu tür algoritmalar, bilimsel yasalardan ve belirli kısıtlamalarla matematiksel modellemelerden türetilen teoremlerin yanı sıra sürü zekası kullanılarak sürünün davranışlarını taklit eden teoremlere dayanır (Eker vd., 2021).

Sezgisel üstü algoritmaların amacı, belirli bir problem sınıfının örneklerine uygulandığında üstün olan arama veya eniyileme yöntemlerini tanımlamaktır. Tüm sürü tabanlı eniyileme algoritmalarında, problem rastgele çözümler kümesi kullanılarak görölmeye başlanır. Algoritma her çalıştırıldığında, bu rastgele çözümler kümesi değerlendirilir ve bir uygunluk fonksiyonu kullanılarak geliştirilir. Genel en

iyi çözüm elde etme olasılığı, tatmin edici rastgele çözümler ve tekrarlar yoluyla artırılmıştır.

Sezgisel üstü algoritmalar keşif ve sömürü adında iki temel aşama ile karakterize edilir. Bu aşamalar arasındaki dengenin gücü, algoritmanın genel kalitesini gösterir. Keşif, algoritmanın tüm arama uzayını araştırma kapasitesi ile ilgiliyken, sömürü her arama ajanının yerel çevresinde en iyi çözümü tanımlama yeteneğini içerir. Bir algoritmanın belirli bir problem setini ele almadaki etkinliği, farklı doğa veya türdeki eniyileme problemlerine mutlaka çevrilmez (Adam vd., 2019). Hiçbir eniyileme algoritmasının tüm problemlere evrensel olarak uygulanamayacağı kabul edilmektedir. Sezgisel üstü algoritmalar, arama uzayında verimli bir şekilde gezinmek ve makul bir zaman dilimi içinde en iyi çözümler sunmak için tasarlanabilir.

Sezgisel üstü algoritmalar gerçek dünya problemlerini ele almak için yaygın olarak kullanılmaktadır. Mühendislik problemleri (Mehta vd., 2022) klima teknolojisinin verimli kullanımı (Eker vd., t.y.) ve yapay sinir ağlarının eğitimi (Eker vd., 2021) gibi alanlarda da çalışmalar yapılmakla birlikte sezgisel üstü algoritmaların makine öğrenmesi algoritmalarına entegrasyonu üzerine önemli bir literatür mevcuttur (Karimi-Mamaghan vd., 2022), (A vd., 2024).

Genetik Algoritma (GA: Genetic Algorithm) (S. M. Mirjalili, 2018), ilk sürü tabanlı algoritmalar arasındadır. Parçacık Sürü Eniyilemesi (PSO: Particle Swarm Optimization) Algoritması (Kennedy & Eberhart, 1995) kapsamlı bir şekilde incelenmiş ve Gri Kurt Algoritması (GWO: Grey Wolf Algorithm) (S. Mirjalili vd., 2014) ve Harris Hawks Eniyileyici (HHO: Harris Hawks Optimizer) (Heidari vd., 2019) gibi çeşitli algoritmalar, PSO'dan operasyonel prensipleri açısından ilham almıştır. Açlık Oyunu Arama Algoritması (HGS: Hunger Game Search) (Y. Yang vd., 2021), sürü tabanlı algoritmalarda yaygın bir tema olan hayvanların açlık dürtüsünden ilham almıştır. Son yirmi yılda, bu alanda çok sayıda algoritma geliştirilmiş ve uygulanmıştır (*Efficient Initialization Methods for Population-Based Metaheuristic Algorithms: A Comparative Study* | SpringerLink, t.y.; Farag vd., 2024).

No-Free Lunch (NFL) Teoremi, sezgisel üstü algoritmaların zaafalarının giderilmesi için faydalanan bir yöntem olmakla beraber performansı artırmak için probleme özgü bilgiyi kullanmanın önemini vurgular, böylece bir sezgisel üstü algoritmayı istenen şekilde ayarlamak için çeşitli stratejiler geliştirme fırsatı sağlar (Igel, 2014).

Hibritleştirme işleminde, farklı strateji veya algoritmaların entegre edilerek sezgisel üstü algoritmaların tek başına yönetemeyeceği büyük ölçekli problemlerle başa çıkılabilmesi için sezgisel üstü algoritmaların esnekliğinden yararlanılır ve problem çözme performansının artırılarak daha sağlam algoritmalar elde edilmesi sağlanır (Fakhouri vd., 2020). Bu tez çalışmasında Çok Katmanlı Almaçları (MLP) eğitmek için hibrit bir algoritma olan Geliştirilmiş Yabani At Eniyileyici kullanan IWHO-MLP önerilmiştir. Kutu grafikleri ve yakınsama eğrileri kullanılarak yapılan karşılaştırmalı analizler, IWHO-MLP'nin hem geleneksel hem de hibrit yöntemlerden sürekli olarak daha iyi performans gösterdiğini, enerji verimliliği veri seti ve CEC 2019 kıyaslama fonksiyonlarında daha düşük MSE, RMSE ve daha yüksek  $R^2$  değerleri elde ettiğini ortaya koymaktadır. Bu bulgular, mevcut son teknoloji durumunu doğrulamakla birlikte, aynı zamanda ilerletmekte ve sinir ağı eğitiminde sezgisel üstü algoritmaların eniyileme etkinliğini vurgulamaktadır.

IWHO-MLP, MLP eğitimi için eniyileme algoritmaları geliştirir. Algoritmanın eniyileme etkinliği ve MLP eğitimi üzerindeki etkisi, standart eniyileme testlerine ve UCI Enerji Verimliliği veri seti kullanılarak MLP eğitime uygulamalarla değerlendirilir. IWHO-MLP eniyileme ve eğitim kararlılığında üstünlük göstermiştir. Rastgele Yürüyüş Stratejisi ile güçlendirilmiş IWHO-MLP, erken yakınsama sorunlarını ele almış ve Wilcoxon testi ile doğrulandığı gibi klasik WHO ve sezgisel üstü algoritmalarından üstün sonuçlar sunmuştur. MLP eğitim danışmanı olarak IWHO-MLP, WHO'dan daha yüksek açıklama gücü ( $R^2:0.98$ ) ve daha düşük hata oranları elde ederek enerji verimliliği ve HVAC sistemlerinde kesin sonuçlar sağlamıştır.

Kutu grafikleri ve yakınsama eğrileri, IWHO-MLP'nin küresel en iyi noktaya yakın daha kararlı sonuçlar verdiğini göstermiştir. Çözüm zamanı %23 daha az olmasına rağmen, doğruluğu bunu kabul edilebilir kılmıştır. IWHO-MLP'nin uyarlanabilir doğası, enerji verimliliğinden mühendislik tasarımına kadar çeşitli eniyileme problemleri ve makine öğrenmesi uygulamalarına uygundur. Algoritmanın temel avantajları; yeni bir eniyileme yaklaşımı, makine öğrenmesi ile entegrasyonu, enerji verimliliğine başarılı uygulanması sonucu istatistiksel olarak anlamlı sonuçlar vermesi ve kararlı bir performans sunmasıdır.

Önerilen yaklaşım, gelişmiş performans dahil olmak üzere çeşitli temel güçlü yanlar ve avantajlar sunar. IWHO-MLP algoritması, çoğu kıyaslama fonksiyonunda orijinal

WHO algoritması ve diğer alternatiflerle karşılaştırıldığında üstün sonuçlar göstermiştir.

**Kararlılık ve tutarlılık:** Kutu grafiği analizi, IWHO algoritmasının sürekli olarak kararlı performans sergilediğini göstermiştir.

**Geliştirilmiş keşif-sömürü dengesi:** Rastgele Yürüyüş Stratejisi, çözüm çeşitliliği sağlayarak yerel en iyi noktalarda sıkışmayı önler ve erken yakınsamayı azaltır.

**Rekabetçi performans:** IWHO, CEC2019'un zorlu test setleri ele alındığında diğer algoritmalarından üstün sonuçlar vermiştir.

**İstatistiksel anlamlılık:** Wilcoxon işaretli sıra testi, IWHO algoritmasının ayırt ediciliğini ve etkinliğini doğrulamıştır.

**Verimli MLP eğitimi:** IWHO-MLP, enerji verimliliği problemi için MLP eğitiminde üstünlük göstermiş, düşük MSE değerleri, yüksek sınıflandırma becerileriyle daha güvenilir sonuçlar elde etmiştir.

**Geliştirilmiş tahmin doğruluğu:** IWHO-MLP algoritması, Soğutma Yüğü (CL) faktörleri için orijinal WHO algoritmasından daha yüksek tahmin oranları sunar.

**Zaman verimliliği:** Artan karmaşıklığına rağmen, IWHO-MLP eniyileme sürecini makul bir zaman dilimi içinde tamamlar.

**Esneklik ve hibritleştirme potansiyeli:** IWHO-MLP'nin başarısı, WHO algoritmasının diğer stratejilerle entegrasyona uygun esnek bir yapıya sahip olduğunu gösterir.

**Gerçek dünya problemlerine uygulanabilirliği:** IWHO-MLP algoritması, enerji verimliliği için akıllı binalarda HVAC sistemlerini en iyileyici etmek gibi pratik sorunları ele alma potansiyeli gösterir.

## **Literatür Araştırması**

Bu çalışmada hibritleştirmenin bazı örnekleri incelenmiştir.

Hibritleştirme üzerine yapılan temel bir çalışmada (Bouaouda & Sayouti, 2022), hibrit yenilenebilir enerji sistemlerinin (HRES: Hybrid Renewable Energy Systems) boyutlarını en iyilemek için hibrit sezgisel üstü algoritmalar araştırılmıştır. HRES uzak bölgelerde enerji sürdürülebilirliğini artırır; ancak birden fazla faktör nedeniyle eniyileme karmaşıktır. Hibrit sezgisel üstü algoritmalar, HRES eniyilemesi için

geleneksel yöntemlerden daha kesin sonuçlar verir. Bu çalışmada hem tek amaçlı hem de çok amaçlı tasarım eniyilemesi için bu algoritmalar gözden geçirilmiştir. Tek amaçlı eniyilemede, maliyetleri minimize etmek ve güvenilirliği artırmak için GA-TS (Gandomkar vd., 2005), PSO-HS (Dehghan vd., 2009) ve GA-Markov (Hong & Lian, 2012) modeli gibi algoritmalar kullanılmıştır. Çok amaçlı eniyileme için, maliyet, emisyonlar ve güvenilirliği aynı anda en iyilemek için FPA-SA (Tahani vd., 2015), MOPSO-NSGA-II (Lan vd., 2015) ve ABC-ACO (Kefayat vd., 2015) gibi algoritmalar kullanılmıştır. Kullanılan algoritmada keşfi ve sömürüyü dengelemek için en yaygın olarak düşük seviyeli evrimsel hibritleştirme kullanılmıştır.

Hibrit sezgisel üstü yöntemler kullanılarak otonom yeşil enerji sisteminin değerlendirilmesinin yapıldığı bu çalışmada (Fatih Güven & Mahmoud Samy, 2022) Türkiye'de şebeke dışı bir üniversite kampüsü için rüzgâr türbinleri, güneş fotovoltaik panelleri, biyokütle gazlaştırıcısı ve hidrojen depolamalı yakıt hücreleri ile hibrit yenilenebilir enerji sistemi (HRES) sunulmuştur. Araştırmada, güvenilir tedarik sağlanırken yıllık sistem maliyetinin minimize edilebilmesi için elektrik üretimi ve eniyileme algoritmaları inceler. Diğer algoritmalarından daha iyi performans gösteren Hibrit Ateşböceği Genetik Algoritması (HFGA) kullanılarak en iyi boyutlandırma belirlenir.

Kalp yetmezliğinin erken teşhisi için yapılan bir çalışmada, yapay sinir ağı tabanlı Timsah ve Mısır Kızkulağı optimizasyon algoritması önerilmiştir. Önerilen algoritma yerel en iyi noktalarda takılmadan küresel en iyi noktaya yakınsamayı sağlamıştır. Önerilen algoritmanın etkinliğinin gösterilmesi için 5 farklı algoritma ve 5 farklı veri setiyle karşılaştırma yapılmış olup, benzer algoritmalarından daha iyi sonuçlar elde edilmiştir (Akalin, 2024).

Bu çalışmada, IWHO algoritması bir makine öğrenmesi algoritması olan yapay sinir ağı için danışman olarak kullanılmış, böylece bu alana katkıda bulunulmuştur. Bu çalışmada ele alınan Yabani At Eniyileyici, sürü tabanlı bir algoritmadır (Naruei & Keynia, 2021). Yabani at sürüsündeki grup hiyerarşisi, güdülerin tatmini gibi yaygın sürü davranışlarından ilham alır.

WHO algoritmasını ele alan çeşitli çalışmalar mevcuttur. 2022'de, Yabani At Eniyileyici (WHO) algoritması sürü özellikleri ve yabani atların hiyerarşisine dayalı olarak geliştirilmiştir. Örneğin, WHO algoritmasının sömürü kapasitesini artırmak ve

yerel en iyi noktalarda sıkışmasını önlemek üzere, keşif ve sömürü arasında denge sağlamak ve su kuyusu mekanizması ile rekabeti güçlendirmek (CWHM) için rastgele koşu stratejisi (RRS) kullanılmıştır. Ayrıca, küresel en iyi sonuç elde etmek için dinamik atalet ağırlığı stratejisi (DIWS) kullanılmıştır (Zheng vd., 2022). WHO algoritmasının yetersiz arama doğruluğu ve yavaş yakınsama hızı gibi sınırlamalarını ele almak için Hibrit Çok Stratejili Geliştirilmiş Yabani At Eniyileyici (HMSWHO) önerilmiştir. Sürünün çeşitliliğini artırmak için Halton dizisi, keşif-sömürü dengesi için uyarlanabilir parametre TDR ve sürünün en kötü pozisyonunu iyileştirmek için simpleks yöntemi uygulanmıştır (*Hybrid Multi-Strategy Improved Wild Horse Optimizer - Li - 2022 - Advanced Intelligent Systems - Wiley Online Library*, t.y.). WHO algoritmasını geliştirmeyi amaçlayan başka bir çalışmada, küresel arama verimliliğini artırmak ve yerel en iyi noktalardan kaçınmak için iki strateji uygulayarak yeni bir algoritma geliştirilmiştir. İlk strateji, her atın bireysel yeteneklerini artıran kuantum hızlandırma stratejisi, ikincisi ise yerel en iyi noktalarda sıkışmayı önleyen kaotik haritalama stratejisidir (M.-W. Li vd., 2024).

WHO algoritmasının çeşitli mühendislik problemlerine uygulandığı çok sayıda çalışma mevcuttur. Bir çalışmada, WHO algoritması rüzgar türbini sisteminde belirli bir kontrolör aracılığıyla rüzgar hızını standartlaştırmak ve potansiyel arızaları önlemek için kontrolör olarak kullanılmıştır (Metwally Mahmoud, 2022). Başka bir çalışmada, küçük şebeke sistemi modelinde elektrik maliyetlerini azaltmak için kontrolör olarak etkinliğini değerlendirmek amacıyla WHO algoritması Cüce Firavun Maymunu Eniyilemesi (DMO) algoritması ile hibritleştirilmiştir (Ganesan & Arockia Edwin Xavier, 2024). Enerji mühendisliği alanında, WHO algoritması eniyileme kontrolörü olarak etkinliğini göstermiştir (Milovanović vd., 2022). Ayrıca öznelik seçimi için de kullanılmıştır (Ewees vd., 2022). Zamanlama problemleri bağlamında, WHO algoritması çeşitli stratejilerle hibritleştirilerek atölyelerdeki iş süreçlerinin planlanmasına başarıyla uygulanmıştır (*An improved multi-objective Wild Horse optimization for the dual-resource-constrained flexible job shop scheduling problem: A comparative analysis with NSGA-II and a real case study*, t.y.). Mevcut literatürde, WHO algoritmasını içeren yapay sinir ağları üzerine çalışmalar bulunmaktadır. Bankacılık sektöründe yüz tanıma sistemlerinin kapsamlı çalışması karar ağaçları, uyarlanabilir sinirsel bulanık çıkarım sistemleri ve yapay sinir ağları gibi yöntemler kullanılmış, WHO algoritması bu yöntemlerin eniyilemesine katkıda bulunmuştur

(Khishe & Mohammadi, 2019). Ayrıca, WHO algoritması sağlık alanında tıbbî görüntülerin uzun süreli depolanmasının sınıflandırılması için yapay sinir ağlarında eniyileyici olarak kullanılmıştır (He vd., 2024).

WHO algoritmasının kararlılığı bu çalışmanın temel motivasyonu olmuştur. Algoritmanın kalitesi CEC 2019 test fonksiyonları kullanılarak değerlendirilmiş ve sonuçları iyileştirmek için Rastgele Yürüyüş (RW) stratejisi ile hibritleştirilmiştir (Bujok & Zamuda, 2019). RW stratejisi, yerel arama süreçlerine rastgelelik katarak ve alternatif çözümler üreterek sezgisel üstü algoritmaların potansiyelini artırır (Gupta & Deep, 2019), (Yin vd., 2020). Bu çalışmanın bulgularına göre, WHO algoritmasının performansında çoğu fonksiyon genelinde önemli iyileşme söz konusudur. Daha önce, Eker ve ark. Yapay Tavşan Eniyilemesi (ARO) algoritması ile RW stratejisinin hibritleştirilmesiyle RW-ARO algoritmasını kullanarak benzer bir araştırma yürütmüş ve Kontrol Mühendisliği'nde başarılı sonuçlar elde etmişlerdir (Eker vd., 2024).

Önerilen IWHO hibrit algoritması ve MLP aracılığıyla binalardaki HVAC (Heating, Ventilating, and Air Conditioning) sistemleri için soğutma yükü (CL: Cooling Load) ve ısıtma yükünü (HL: Heating Load) eğitmek için kullanılmış olan çalışmada IWHO eğitmen olarak atanmıştır. WHO algoritması alternatif olarak seçilmiştir. Bu çalışmada enerji verimliliği problemini ele alan UCI'dan Enerji Verimliliği veri seti kullanılmıştır (Athanasios Tsanas, 2012).

Çeşitli ofis hücresi model versiyonlarında EnergyPlus simülasyon verilerini kullanan bir çalışmada (Stevanović vd., 2024) ısıtma, soğutma, aydınlatma yükleri ve eşdeğer birincil enerji gereksinimleri için Yapay Sinir Ağları (ANN) ve XGBoost vekil modellerinin tahmin yetenekleri değerlendirilmiştir. XGBoost modelleri bu yükleri tahmin etmede üstün doğruluk göstermiştir. Bu çalışmada, XGBoost modelleri, sıfıra yaklaşmayan daha yüksek gradyanlarla daha basit eğimli şekillere sahip ısıtma ve soğutma yüklerinden daha fazla aydınlatma yükleri ve birincil enerji ihtiyaçları için daha büyük doğruluk göstermiştir.

Elektrikli araçların artan yaygınlığı üzerine başka bir çalışmada (Hussain vd., 2025), enerji tüketimini doğru tahmin etmek, etkili güç şebekesi yönetimi için gereklidir. Colorado'dan veriler kullanılarak K-En Yakın Komşular, Lasso Regresyon, Ridge Regresyon, Gradyan Artırma, Destek Vektör Regresyonu, MLP, XGBoost, CatBoost, LightGBM, Gauss Süreç Regresyonu (GPR) ve Ekstra Ağaçlar Regresörü dahil olmak

üzere 11 makine öğrenmesi modeli değerlendirilmiştir. Model MAE (ortalama mutlak hata), MSE (ortalama kare hata),  $R^2$ , RMSE (kök ortalama kare hata) ve NRMSE (normalleştirilmiş RMSE) gibi metrikler kullanılarak değerlendirilmiştir. Hem Gradyan Artırma hem de K-En Yakın Komşular (KNN) güçlü performans gösterirken, doğrusal olmayan ve doğrusal regresyon modelleri aşırı enerji seviyelerini tahmin etmede zorluklarla karşılaşmış olsa da Ekstra Ağaçlar Regresörü enerji tüketimini tahmin etmede en kesin çözüm olarak ortaya çıkmıştır. Bu çalışmanın bir sınırlaması, yalnızca Colorado verilerine dayanmasıdır. Doğru olmasına rağmen, Ekstra Ağaçlar Regresörü'nün hesaplama talepleri gerçek zamanlı uygulamalar için ölçeklenebilirliğini etkileyebilir.

Yapılan bir çalışmada çeşitli sezgisel üstü algoritmalar kategorik artırma (CatBoost) yöntemi ile hibritleştirilmiş, sıcaklık, basınç, nem ve gaz fiyatları gibi faktörlere dayalı olarak kentsel gaz tüketimini en iyilemede önerilen modelin performansı değerlendirilmiştir. (Khishe & Mohammadi, 2019) nolu çalışmada, SSA-MLP hibrit sistemi kullanılarak pasif sonar veri seti eğitilmiş, yüksek sınıflandırma doğruluğu elde edilmiştir. (He vd., 2024) nolu çalışmada enerji verimliliğini artırmak ve ağ yaşam süresini uzatmak için sualtı kablosuz sensör ağları tasarımı için sezgisel üstü tabanlı algoritma modeli önerilmiş, kümeleme ve çok atlamalı yönlendirme prosedürlerini verimli bir şekilde yönetmek için Hibrit Hiyerarşik Şempanze Eniyileme Algoritması önerilmiştir (Qian vd., 2023).

HVAC sisteminin incelendiği çalışmada ise fiziksel sistem modellemesini sembolik regresyon ile birleştiren, sınırlı veri ile etkinliği ve fiziksel ifade gücü ile dikkat çeken hibrit model tanıtılır. Bu model, enerji performansını tahmin etmek için klima sistemlerinde test edilmiştir (Yousaf vd., 2024).

Belge kategorizasyonu için yapılan başka bir çalışmada sezgisel üstü algoritmalar kullanılarak öz nitelik alt küme sayısı önemli miktarda azaltılmıştır (Kyaw vd., t.y.).

Yapay sinir ağı (ANN) yaklaşımıyla, sadece daha yüksek çözünürlüklü görüntülerle tespit edilebilen küçük hastalık lekeli bitki yapraklarında erken hastalığı tespit edilmesi amaçlanan bir çalışmada sezgisel üstü tabanlı bir öz nitelik seçim algoritması kullanılarak bu öz nitelikler yapay sinir ağı için giriş olarak verilmiştir. Yapay sinir ağının sonuçları evrişimsel sinir ağı (CNN) modelleri (AlexNet, VGG16, ResNet-50)

ile karşılaştırılarak sırasıyla % 78.64, % 79.92 ve % 84.88'e karşılık % 89.41 sonuçlar elde edilmiştir (Pham vd., 2020).

Diyabet hastalığının erken başlangıcını tahmin etmek için bir makine öğrenme modeli önerilen bir çalışmada gerekli öz niteliklerin sayısını azaltacak Çok Katmanlı Almacı (MLP) en iyilemek için Gri Kurt Eniyilemesi (GWO) ve Uyarlanabilir Parçacık Swarm Eniyilemesi (APSO) kullanılmıştır. Bu yöntem kullanılarak elde edilen sonuçlar çeşitli geleneksel makine öğrenimi algoritması yaklaşımlarıyla karşılaştırılmıştır (Le vd., 2021).

Gri Kurt Eniyilemesi (GWO) tekniği kullanılarak nesnelerin interneti bulut kenarı ağ geçidi kötü amaçlı yazılım avı için çok kanallı bir destek vektör makinesi (SVM) önerilen bir çalışmada. Bu sezgisel üstü yaklaşımı, nesnelerin interneti bulut kenarı ağ geçidinde kötü amaçlı ve iyi huylu uygulamaları ayırt eden öz niteliklerin en iyi seçimi için kullanılmıştır. Önerilen çok kanallı SVM yaklaşımı, diğer kötü amaçlı yazılım arama tekniklerini doğruluk açısından geride bırakırken, hesaplama maliyetini ve eğitim süresini önemli ölçüde azaltmıştır (Haddadpajouh vd., 2021).

Rahim ağzı kanserini sınıflandırmak ve hastalıkla ilişkili risk faktörleri belirlemek için makine öğrenimi yöntemi olan MLP ve Radyal Tabanlı YSA (RBFNN: Radial Based ANN) kullanılarak doğru bir tanı tahmin modeli önerilen bir çalışmada önerilen bu makine öğrenimi modeli ile başarılı bir şekilde sınıflandırma ve yüksek doğrulukta bir tanı tahmin modeli elde edilmiştir (Çiçek & Küçükakçalı, 2022).

Dağıtım güç sistemi için toplam aktif güç kaybını azaltmak amacıyla rüzgâr tabanlı dağıtık jeneratörlerin ve güneş fotovoltaik tabanlı dağıtık jeneratörlerin konumları ve boyutlarının en iyileştirildiği bu çalışmada toplam aktif güç kaybının en iyi değerini bulmada en etkili yöntemi belirlemek üzere Yabani At Eniyileyici (WHO), Arşimet Eniyileme Algoritması (AOA) ve Geçici Arama Eniyilemesi (TSO) algoritması olmak üzere üç sezgisel üstü algoritma birbirleriyle karşılaştırılmıştır. Analiz sonuçlarına göre, WHO farklı kriterlere göre toplam aktif güç kaybının en iyi değerini elde etmede diğer yöntemlerden daha üstün performans göstermiştir (Minh & Duong, 2024).

Hiperspektral Görüntü Bant Seçimi için Geliştirilmiş Yabani At Eniyileyici (IBSWHO) önerilen çalışmada Hiperspektral görüntüler (HSI) yüksek boyutlu veriler olduğundan ve veri işlemede önemli miktarda gereksiz bilgi içermesinden dolayı IBSWHO'nun yakınsaklığının, yaygın kullanılan doğrusal olmayan test

fonksiyonlarında doğrulanmış olarak son teknoloji eniyileme algoritmalarıyla karşılaştırıldığı çalışmadaki deneysel sonuçlar, IBSWHO tarafından seçilen bant alt kümesinin, geleneksel ve son teknoloji bant seçimi yöntemleriyle karşılaştırıldığında en iyi sınıflandırma doğruluğunu elde ettiğini göstermiş ve önerilen BS yönteminin üstünlüğü doğrulanmıştır (T. Chen vd., 2024).

Akıllı şebeke sistemlerinin enerji yönetimi için hibrit bir teknik önerilen çalışmada Yabani At Eniyileyici (WHO) ve Cüce Firavun Faresi Eniyilemesi (DMO: Dwarf Mongoose Optimization) yöntemleri entegre edilmiştir. Önerilen yaklaşımın temel amacı, akıllı şebeke modelinin kaynaklarını ve gücünü yönetmek ve elektrik maliyetini azaltmaktır. Sistemin hedefi, yük talebini iyileştirmektir. WHO yöntemi, sistemin hedefini minimize eden DMO yöntemi ile geliştirilmiştir. Güç talebine erişim, şarj durumu ve depolama elemanları için yenilenebilir enerji kaynakları sistemin kısıtları olarak kabul edilmektedir. Yenilenebilir güç sistemleri birimi, işletim boyunca kararlı ve tutarlı çıkış gücünü sabitlemek ve sürdürmek için enerji kaynakları olarak bataryalara dayanmaktadır. Oluşturulan simülasyondan, önerilen yöntemin mevcut yöntemlerden daha düşük maliyete ve daha yüksek güce sahip olduğu görülmüştür (*A Hybrid Wild Horses Optimization (WHO) and Dwarf Mongoose Optimization (DMO) method for optimum energy management in SG system - Ganesan - 2024 - Optimal Control Applications and Methods - Wiley Online Library, t.y.*).

Orijinal WHO algoritmasının yineleme sayısı arttıkça yavaş yakınsama göstermesinden dolayı, düşük arama doğruluğuna sahip olması ve yerel en iyi noktaya takılmaya eğilimli olması problemlerini çözmek için, önerilen başka bir çalışmada pekiştirmeli öğrenme ve hibrit çoklu strateji tabanlı Geliştirilmiş Yabani At Eniyileyici (IWHO) önerilmiştir. Önerilen IWHO algoritmasını CEC 2022 test fonksiyonları ve üç pratik mühendislik problemi üzerinde test edilmiş ve IWHO'nun diğer algoritmalarından daha iyi performansa sahip olduğunu ortaya konmuştur (Xi & Liu, 2024).

(X. Chen vd., 2024) nolu çalışmada geliştirilmiş Yabani At Eniyileyici tabanlı bir hibrit bulut iş akışı çizelgeleme algoritması (HCWSA-IWHO) geliştirilmiştir. Son teslim tarihlerinin karşılanması ve iş akışı yürütme maliyetlerinin azaltılmasının hedeflendiği bu çalışmada elde edilen sonuçlarla amacına uygun bir hibrit algoritma elde edilmiştir.

Etkili enerji kullanımı üzerine yapılan bir çalışmada, bina tasarımında kritik olan ısıtma yükü (HL) ve soğutma yükü (CL) faktörlerinin doğru tahminlenmesi probleminin çözümünde, makine öğrenmesi algoritmaları ve MLP kullanılarak elde edilen SSA tabanlı MLP mimarisinin (SSA-MLP) enerji problemlerinde etkili tahmin yetenekleri sergilediği gösterilmiş ve enerji verimliliğinde rekabet avantajına sahip sağlam bir çözüm sunulmuştur (Eker vd., t.y.).

Enerji verimliliği üzerine yapılan başka bir çalışmada kullanıcıların varlığını tespit etmek için ThermoSensor adlı yazılım kullanılmıştır. Sistem, kullanıcı kullanım kalıplarından eğitilmiş koşullandırma şartlarını ve gerçek zamana yakın varlık ve sıcaklık tahminlerini kullanarak havalandırmayı düzenlemektedir. Bu sistemde Pasif kızılötesi sensörü düşük maliyetli, düşük güçlü termal sensör dizisi ile birleştiren çok sensörlü düğüm kullanılmaktadır. Varlığa dayalı bir şekilde alanlar koşullandırılarak oda sıcaklığının verimliliği korunurken yıllık %25 enerji tasarrufu elde edilebileceği gösterilmiştir (Beltran vd., 2013).


Yine enerji verimliliği üzerine yapılan bir çalışmada iç mekân hava kalitesi için içerideki kişileri doğru şekilde tespit etmeye yardımcı olacak CO<sub>2</sub> sensörleri kullanılmıştır. Nüfus ve aktiviteleri hakkındaki gerçek zamanlı verilere göre, tespit sırasında sayıma dayalı varlık profilleri oluşturulmuştur. Bina enerji simülasyonu kullanılarak, bu stratejinin iç mekân hava kalitesi ve enerji tüketimi üzerindeki etkisi belirlenmeye çalışılmıştır. Sonuç olarak, önerilen yöntemin iç mekân hava kalitesini artırmak, statik veya sabit profiller kullanıldığında havalandırma talebinin eksik veya fazla tahmin edilmesi sorununu ele almak üzere talep odaklı havalandırma kontrolleri için dinamik varlık değişiklikleri hakkında veri sağlanabileceği gösterilmiştir (*Machine Learning and Deep Learning Methods for Enhancing Building Energy Efficiency and Indoor Environmental Quality – A Review - ScienceDirect*, t.y.).



## 2. YAPAY SİNİR AĞLARI VE MLP

### 2.1. Yapay Sinir Ağı

Şekil 2.1’de gösterilen bir YSA 5 bileşenden oluşmaktadır.



Şekil 2.1. Bir yapay sinir ağı hücresi yapısı ve temel elemanları.

**Girdi Değerleri:** Yapay sinir ağına girilen verilerdir.

**Ağırlıklar:** Gelen bilgilerin önemlerine göre aldıkları değerlerdir, giriş değerleri ağırlıklarına göre yapay sinir ağı üzerinde etkili olurlar.

**Toplama Fonksiyonu:** Giriş değerlerinin ağırlıklarıyla çarpılıp toplanmasını sağlar.

**Aktivasyon Fonksiyonu:** Toplama fonksiyonundan gelen değeri işleyerek bir çıktı değeri belirler.

**Çıktı:** Aktivasyon fonksiyonunun sonucudur. Bir sinir hücresinin sadece bir çıkışı olabilir. Bir sinir hücresinin çıkışı başka bir sinir hücresinin girişi olabilir.

Şekil 2.1’de gösterildiği gibi yapay sinir ağında öğrenme işleminde örnek girdilerle eğitilen ağın çıktısı doğru çıktılarla karşılaştırılır, hatalara göre ağırlıklar her yinelemede güncellenir ve eğitim işlemi yeniden yapılır.

## 2.2. Çok Katmanlı Almaç Mimarisi (MLP)

MLP’de, doğrusal olmayan aktivasyon fonksiyonlarına sahip çok sayıda sinir hücresinin hiyerarşik olarak bağlandığı bir yapı mevcuttur.

MLP sınıflandırma, tahmin ve regresyon görevleri için uygulanabilen parametrik olmayan bir tahmin edici olarak hizmet veren yapay sinir ağı mimarisidir. Beyin, görme, konuşma tanıma ve öğrenme gibi çeşitli alanlarda mevcut teknolojik ürünleri aşan olağanüstü yeteneklere sahip bir bilgi işleme cihazıdır. Bu uygulamalar, makinelerde gerçekleştirildiğinde net ekonomik avantajlar sağlamaktadır. Beynin bu işlevleri nasıl gerçekleştirdiğini anlayarak, bu görevleri çözmek için biçimsel algoritmalar geliştirilebilir ve bunlar, bilgisayarlarda uygulanabilir. İnsan beyni temelde bir bilgisayardan farklıdır. Bir bilgisayar tipik olarak tek bir işlemciye sahipken, beyin paralel olarak çalışan yaklaşık  $10^{11}$  nörondan oluşan muazzam sayıda işlem biriminden meydana gelmektedir. Kesin ayrıntılar tam olarak anlaşılmamış olsa da bu işlem birimlerinin bir bilgisayar işlemcisinden çok daha basit ve yavaş olduğu düşünülmektedir. Beynin hesaplama gücüne katkıda bulunduğuna inanılan bir diğer ayırt edici özelliği ise kapsamlı bağlantısallığıdır. İşlemler, nöronlar tarafından gerçekleştirilirken, bellek nöronlar arasındaki sinapslarda bulunmaktadır. Beyindeki bilgi işleme sistemi temel bir teori, algoritma ve donanım gerektirmektedir. Bu, istenen işlem için veri girişi, işlevi gerçekleştirmek için bir algoritma ve belirli bir donanım uygulaması kullanarak komutları yürütme yeteneğini içermektedir. Matematiksel bir işlevi içeren sinir ağlarının eğitimi, istatistiksel teknikler aracılığıyla mümkün kılınmaktadır. Bu eğitim için tasarlanan mimarilerden biri MLP yapısıdır (*Machine Learning Textbook: Introduction to Machine Learning (Ethem ALPAYDIN), t.y.*).

Almacın amacı, dışarıdan uygulanan uyarın kümesini iki sınıftan birine doğru şekilde sınıflandırmaktır. **Şekil 2.1**’de  $b$  ile gösterilen yanlılık (bias),  $x_1, x_2, \dots, x_m$  girdi değerleri,  $w_1, w_2, \dots, w_m$  bağlantı veya sinaptik ağırlıklar,  $v$  giriş vektörü ve  $\varphi(v)$  transfer fonksiyonu yer almaktadır. Verilen  $v$  aynı zamanda bir hiperdüzlem olarak da tanımlanabilir.

$$v = \sum_{i=1}^m w_i x_i + b \quad (2.1)$$

Denklem (2.1)’de

$v$ : Giriş vektörü

$\varphi(v)$ : Transfer fonksiyonu

$x = (x_1, x_2, \dots, x_m)^T$ : Giriş değerleri


$w = (w_1, w_2, \dots, w_m)^T$ : Ağırlıklar

$b$ : Yanlılık (bias) değeri olarak gösterilmiştir.

$$v = w^T x \quad (2.2)$$

Test sırasında, çıktı  $y$ , verilen giriş  $x$  için belirlenen ağırlıklar  $w$  ile hesaplanmaktadır. Belirli bir görevi gerçekleştirmek için, girişler verildiğinde doğru çıktıların üretilmesi amacıyla sistemin parametreleri olan  $w$  ağırlıklarının öğrenilmesi gerekmektedir.

Hiperdüzlem, giriş uzayını iki bölgeye ayırmak için kullanılabilir: değerlerin pozitif olduğu bir bölge ve değerlerin negatif olduğu diğer bir bölge. Bu kavram, doğrusal ayırma fonksiyonunun uygulanmasında temeldir. **Şekil 2.2**'te, almaç daha sonra çıktının işaretini inceleyerek girişi iki sınıftan birine sınıflandırabilir: Çıktı pozitifse bir sınıfa ( $C_1$ ) aittir; negatifse diğer sınıfa ( $C_2$ ) aittir (Haykin, 1999).



**Şekil 2.2.** Doğrusal olarak ayrılabilen desenler çifti ve doğrusal olmayan şekilde ayrılabilen desenler çifti.

$$S(v) = \begin{cases} C_1, & S(v) > 0 \\ C_2, & S(v) < 0 \end{cases} \quad (2.3)$$

$x_i$ ,  $C_1$  ya da  $C_2$ 'ye ait,  $S(v)$  bir eşik fonksiyonu olsun. Riskin hesaplanması için aktivasyon fonksiyonuna veya çıktıya ( $y$ ) ihtiyaç vardır. Transfer fonksiyonu, ağın özelliklerini tanımlayan matematiksel fonksiyondur ve ağın çözmesi gereken


probleme göre seçilir. Bu çalışma için transfer fonksiyonu olarak sigmoid'ın seçilmesinin nedeni,  $[0,1]$  aralığında sürekli ve türevlenebilir değerlere sahip olmasıdır. Burada  $a$  parametresi, transfer fonksiyonunun eğimidir.

$$y = \text{sigmoid}(v) = \frac{1}{1 + e^{(-av)}} \quad (2.4)$$

Tek katmanlı ağırlıklara sahip bir almaç yalnızca girişin doğrusal fonksiyonlarını yaklaşık olarak hesaplayabilir ve tahmin edilecek ayırt edicinin doğrusal olmadığı XOR tipi problemleri çözemez. Benzer şekilde, bir almaç doğrusal olmayan regresyon için kullanılamaz. Bu sınırlama, ileri beslemeli ağlar için geçerli değildir. Bu tür MLP'ler, sınıflandırma problemleri için kullanıldıklarında, doğrusal olmayan ayırt edicileri uygulayabilirler. Regresyon için kullanıldıklarında ise girişin doğrusal olmayan fonksiyonlarını yaklaşık olarak hesaplayabilirler.


### 2.3. Geri Yayılm

İleri beslemeli sinir ağlarının eğitilmesi için yaygın olarak kullanılan bir algoritmadır. Şekil 2.3'de çok katmanlı yapay sinir ağında öğrenme modeli gösterilmiştir.



Şekil 2.3. Çok katmanlı yapay sinir ağında öğrenme (Işıksan, 2020).

MLP'ler, geri yayılım olarak adlandırılan yaygın bir algoritma ile denetimli bir şekilde eğitilerek bazı zor ve farklı türden problemleri başarıyla çözmek için uygulanır. **Şekil 2.4**'te görüldüğü üzere, bir MLP'de fonksiyon sinyalleri ileri yayılım yönünde akarken, hata sinyali geri yayılım akışı ile yanıt verir ve hatayı en aza indirmek için ağ eğitilir. Hata sinyali ağın bir çıkış nöronunda başlar ve ağ boyunca geriye doğru hareket eder. Ağdaki her nöron, bir şekilde hataya bağlı olan hata adlı bir fonksiyon kullanarak hesaplama katılır (*Adaptive, Learning, and Pattern Recognition Systems; Theory and Applications*, 1970; Haykin, 1999).



**Şekil 2.4.** Fonksiyon ve hata sinyallerinin yönlerinin gösterimi.

Öğrenme, bir sinir ağındaki giriş parametrelerinin, ağıdaki gizli katmanlardaki işlemlerden geçirilerek çıkış parametrelerinin elde edilmesi sürecidir. Öğrenme türü, parametre değişikliklerine göre belirlenir (*Adaptive, Learning, and Pattern Recognition Systems; Theory and Applications*, 1970).

Hata metrikleri, tahmin edilen sonuçlar ile gerçek değerler arasındaki sapmanın nicel bir ölçüsü olarak kullanılır. Tek bir sonuç kapsamlı açıklama sağlamayabilse de diğer model sonuçları ile karşılaştırma için sayısal bir temel sağlanarak en uygun regresyon modelinin seçimi kolaylaştırılır.

Denetleyici, sinir ağına belirli bir eğitim vektörü için istenen yanıtı sağlayabilir ve bu yanıt ağı üstlenmesi gereken en iyi eylemi temsil eder. Ağ parametreleri, eğitim vektörü ve ağı istenen ile gerçek yanıtları arasındaki fark olarak tanımlanan hata sinyalinin birleşik etkisi altında ayarlanır. Bu ayarlama süreci, sinir ağıının sonunda

istatistiksel anlamda en iyi olduğu varsayılan denetleyiciyi taklit etmesini sağlama amacıyla yinelemeli ve artımlı olarak gerçekleştirilir. Bu süreç aracılığıyla, denetleyici tarafından kullanılabilen çevresel bilgi, eğitim sırasında sinir ağına mümkün olduğunca kapsamlı bir şekilde aktarılır. Bu koşul sağlandığında, eğitici ortadan kaldırılabilir ve sinir ağının çevre ile bağımsız olarak etkileşime girmesine izin verilir. Hata değerleri aşağıdaki metrikler kullanılarak hesaplanabilir:

*MSE*: Ortalama kare hatası

*RMSE*: Kök ortalama kare hatası

*MAE*: Ortalama mutlak hata

*MAPE*: Ortalama mutlak yüzde hatası

$R^2$ : Belirlilik katsayısı

$$MSE = \frac{1}{N} \sum_{i=1}^N (P_i - O_i)^2 \quad (2.5)$$

$$RMSE = \sqrt{MSE} \quad (2.6)$$

$$MAE = \frac{1}{N} \sum_{i=1}^N |P_i - O_i| \quad (2.7)$$

$$MAPE = \frac{MAE}{\text{Ortalama Doğru Değerler}} * 100 \quad (2.8)$$

$$R^2 = 1 - \frac{\sum_{i=1}^N (P_i - O_i)^2}{\sum_{i=1}^N (P_i - \bar{P})^2} \quad (2.9)$$

Denklem (2.5) ve (2.9)'da verilen;

$i$ : Çıkış değerlerinin sayısı

$P_i$ : Tahminî çıkış

$\bar{P}$ : Veri setinin ortalama değeri

$O_i$ : Gerçek çıkış

$N$ : Ağın boyutu

### 3. SEZGİSEL ÜSTÜ ALGORİTMALAR

Eniyileme, bir problemin muhtemel çözümleri arasından en iyi sonucu veren çözümün elde edilmesidir. Eniyileme problemlerinin çözümünde kullanılan algoritmaları genel olarak klasik eniyileme algoritmaları ve sezgisel eniyileme algoritmaları olarak ikiye ayrılmaktadır. Klasik eniyileme algoritmalarında tüm çözüm kümesi taranarak kesin çözüme ulaşılması hedeflenirken, sezgisel üstü eniyileme algoritmalarında ise çözüm uzayına sezgisel olarak yaklaşılmakta ve en iyi ya da en iyi noktaya yakın bir çözüme ulaşılması hedeflenmektedir.


Geniş bir çözüm uzayına sahip olan kısıtlı veya kısıtsız problemlerde matematiksel eniyileme algoritmalarının kullanımı, zaman ve işlem çokluğu açısından maliyetli olmaktadır.

Bir eniyileme algoritmasının her tür problemde başarılı olması veya beklenen sonuçlara ulaşması mümkün olmayabilmektedir. Bu nedenle problemin türüne göre uygun algoritmanın belirlenmesi çok önemlidir. Sezgisel üstü algoritmalar kullanılarak, çok geniş çözüm uzaylarında verimli arama işlemleri sonucunda en iyi çözüme daha hızlı ulaşılmaktadır (Çelik vd., 2019). Eniyileme problemlerinin çok geniş çalışma alanlarında mevcut olması eniyileme tekniklerinin geliştirilmesine olan ihtiyacı artırmıştır.

Geleneksel eniyileme problemlerinin, tek bir adayla çözüme başlama, yerel en iyi noktalarda takılı kalma ve erken yakınsama gibi risklerinden dolayı, son 20 yılda sezgisel üstü eniyileme çözümlerine ihtiyacı ve ilgiyi artırmıştır (Boussaïd vd., 2013; Ekinci & Hekimoglu, 2019; S. Mirjalili, 2016).

Sezgisel üstü eniyileme algoritmalarının zeki hesaplamalar gerektiren problemlerin çözümünde gün geçtikçe daha çok kullanılır hale gelmiştir. Böylece çok sayıda gerçek dünya mühendislik problemine de uygulanabilmektedir (EKİNCİ & DEMİRÖREN, 2016). Sezgisel üstü algoritmalarının yaygın hale gelmelerinin başlıca nedenleri vardır (Eker vd., 2019).

- Sezgisel üstü algoritmaları, ilhamlarını gerçek hayattan alırlar. Farklı fiziksel olay veya biyolojik davranışlardan esinlenirler. Kanıtlanmış bazı temel teoriler ve matematiksel modellere sahiptirler (Jaddi vd., 2017).
- Sezgisel üstü algoritmalar, herhangi bir eniyileme problemi için verilen bir giriş kümesine karşılık bir çıkış kümesi oluşturabilirler. Çok yönlü ve çok esnek olan sezgisel üstü algoritmaların yapıları ve parametreleri değiştirebildiği için elde edilen sonuçlardan sonra daha iyi çözümler elde edilebilir.
- Problemlerin çözümünde yerel minimumlardan kaçınmak veya kurtulmak çok önemlidir. Ayrıca, uygun bir süre içinde çözümlerin doğruluğu artırılabilir ve farklı algoritmaların güçlü yönleri kullanılarak hibrit algoritmalar geliştirilebilir.
- Sezgisel üstü eniyileme algoritmaları, tek ve çok modlu, düşük ve yüksek boyutlu, tek ve çok amaçlı, ayrık ve sürekli problemler için çözüm olabilmektedir (Zhao vd., 2019).
- Sezgisel üstü algoritmaların hibritleşme kapasiteleri sayesinde algoritmaların zayıf yönlerini giderebilmek için bu konuda güçlü olan başka bir algoritma kullanılarak performansı daha yüksek bir algoritma elde edilebilir (Zhao vd., 2019).



**Şekil 3.1.** Sezgisel üstü algoritmaların sınıflandırılması (Zheng vd., 2022).



#### 4. IWHO HİBRİT ALGORİTMASI İLE ENİYİLEME PROBLEMLERİNİN ÇÖZÜMÜ

Eniyileme, matematiksel veya analitik süreçler kullanılarak belirli bir sistem ya da sürecin parametrelerinin daha düşük maliyetle en iyi hale getirilmesini sağlayan bir işlemler dizisidir. Eniyileme süreci, bir problemin küresel bir en iyi noktaya ulaşmasını sağlayan bir yol izler [69]. Bu süreç, bugüne kadar mühendislik, finans ve bilimsel problemleri çözmek için matematiksel modellerle ifade edilen gerçek dünyada kullanılmıştır [70]. Eniyileme algoritmalarının geliştirilmesi, mühendislik, bilim, ekonomi ve işletme gibi birçok alanda karşılaşılan eniyileme problemlerine yönelik büyük ilgi görmüştür [71]. Gerçek dünyadaki bir eniyileme problemi, matematiksel bir formülasyonla ifade edilebilirse çözülebilir. Gerçek hayattaki problemlerle başa çıkarken önemli olan nokta, istenen değişkenleri en iyi şekilde elde etmektir. Bu nedenle eniyileme algoritmaları, bu tür problemlerle başa çıkmak için önemli araçlar olarak kabul edilmektedir (Zhao vd., 2020). Bu tür problemlerin çözümü için çeşitli deterministik algoritmalar bulunmaktadır (Heidari vd., 2019). Ancak, bu yöntemlerin karmaşık matematiksel hesaplamalar ve türev gerektirmesi, uygulanma zorlukları ve yerel en iyi noktada takılma gibi çeşitli dezavantajları bulunmaktadır. Bu dezavantajları aşmanın bir yolu, türevsiz yaklaşımları kullanmaktır. Bu bağlamda, sezgisel üstü eniyileme algoritması, bu ihtiyacı karşılamak için potansiyel çözümler sunmaktadır (Izci vd., 2022).

Sezgisel üstü algoritmalar, türevsiz yaklaşımlar arasında yer alan ve son zamanlarda eniyileme problemleri için en etkili yöntemler olarak kullanılan algoritmalarlardır. Bu tür algoritmalar, bilimsel yasalara dayanan teoremlerle birlikte belirli matematiksel modellemelerle çalışırken, sürü zekasına sahip toplulukların ortak davranışlarını taklit etmeye dayanır (Eker vd., 2021).

Tüm sürü tabanlı eniyileme algoritmalarında, başlangıç aday çözüm kümesi kullanılarak eniyileme süreci başlatılır. Algoritma her çalıştırıldığında, bu rastgele çözümler kümesi değerlendirilir ve bir uygunluk fonksiyonu ile geliştirilir. Probleme en uygun genel çözüm elde etme olasılığı, yeterli sayıda rasgele çözüm ve yeterli sayıda yineleme kullanılarak artırılır. Sezgisel üstü algoritmalarda süreç, keşif ve

sömürü adı verilen iki ana aşamadan oluşur ki sömürü-keşif dengesinin gücü aynı zamanda algoritmanın kalitesini ifade eder. Keşif, algoritmanın arama alanını bir bütün olarak tarayabilme yeteneğini ifade ederken, sömürü, her bir arama ajanının bulunduğu yerel alanda tarama yaparak en uygun çözüme ulaşmasını ifade eder (Izci vd., 2020).

Bir algoritma, belirli bir problem kümesini çözmede gösterdiği başarıyı, farklı nitelik ve türdeki bir eniyileme probleminde gösteremeyebilir (Adam vd., 2019). Bu durum, daha geniş yelpazedeki problemlerin çözümü için yeni eniyileme teknikleri önerilerine veya mevcut algoritmaların geliştirilmesine ihtiyaç duyulduğunu gösterir. Daha iyi bir çözüm elde etmek için hibritleştirme teknikleri kullanılabilir (Nenavath & Jatoth, 2018, 2015). Hibritleştirme, sezgisel üstü algoritmaların başaramadığı büyük problemleri çözmek, problem çözmede daha hızlı performans sağlama ve güçlü algoritmalar sunma gibi üç önemli avantaja sahiptir (Fakhouri vd., 2020).


Sürü temelli algoritmaların tarihinde görülen ilk ve en etkili algoritmalarından biri Genetik Algoritma'dır (GA) (S. M. Mirjalili, 2018). Üzerine çok çalışma yapılan Harris Hawks Optimizer (HHO) (Heidari vd., 2019), Grey Wolf Algorithm (GWO) (S. Mirjalili vd., 2014) ve bunun gibi birçok algoritmaya da çalışma prensipleri açısından ilham kaynağı olan algoritma Particle Swarm Optimization (PSO) algoritmasıdır (Kennedy & Eberhart, 1995). Tüm sürü tabanlı algoritmaların ilham kaynağı olan hayvanların açlık dürtüsünden ilham alınarak oluşturulmuş algoritma ise Hunger Games Search Algorithm (HGS) (Y. Yang vd., 2021)'dir. Yirmi yılı aşan süreçte bu konuda birçok algoritma yazılmış ve uygulamaları yapılmıştır (*Efficient Initialization Methods for Population-Based Metaheuristic Algorithms: A Comparative Study* | SpringerLink, t.y.; Lagaros vd., 2022).

Bu çalışmada ele alınan WHO Algoritması sürü tabanlı algoritmalarındandır (Naruei & Keynia, 2021). Yabani bir at sürüsünde grup hiyerarşisi, sürülerin su ve otlama ihtiyaçlarının giderilmesi gibi ortak sürü davranışlarından ilham alınarak düzenlenmiştir.

WHO algoritmasının oldukça kararlı bir yapısı olması çalışmanın motivasyon kaynaklarındandır. Algoritma kalitesi CEC2019 (Bujok & Zamuda, 2019) test fonksiyonları ile test edilmiş ve daha iyi sonuçların elde edilmesi için Random Walk stratejisi ile hibritleştirme sağlanmıştır.

Random Walk (RW) stratejisi sayesinde sezgisel üstü algoritmaların yerel arama süreçlerinde rastgele dağılımı ve buradan alternatif çözümler üretme potansiyeli arttırılmıştır (Gupta & Deep, 2019; Yin vd., 2020). Çalışmanın sonucunda fonksiyonların çoğunda WHO algoritmasının sonuçlarının büyük ölçüde iyileştirildiği gözlemlenmiştir.


IWHO algoritmasının eniyileme süreci **Şekil 4.1**'de verilmiştir.



**Şekil 4.1.** Eniyileme süreci.

#### 4.1. Yabani At Eniyileyici

WHO algoritması, vahşi hayvan sürülerinin ortak sürü davranışlarından ilham alan bir algoritmadır. **Şekil 4.2** WHO algoritmasının sürü şemasını ele alır. Şekilde ifade edilen sürü hiyerarşisi ( $N$ ), ebeveyn ( $S$ ) ve yavrulardan ( $F$ ) oluşmuştur ve her bir lider bir grup oluşturur ( $G$ ). Sürülerin otlama, çiftleşme, su arama, lider seçimi gibi davranışlarından ilham alınan algoritma beş aşamadan oluşmuştur (Naruei & Keynia, 2021).




**Şekil 4.2.** WHO algoritmasının sürü şeması.

Algoritma, eniyileme sürecini bir dizi aday çözümle başlatır. İlk kümede, aday at simülasyonu belirli bir hiyerarşi sunar. Bu hiyerarşide, farklı liderler altında at grupları bulunur. Bu aşamada, **Şekil 4.2**'de gösterildiği gibi bir sürü diyagramı oluşturulur.

Atlar, genel olarak bölgesel ve bölgesel olmayan iki sınıfa ayrılabilirler ve taylar, aygırlar, kısraklar gibi farklı yaşlardaki gruplar halinde yaşarlar. Taylar büyüdükten sonra gruplarından ayrılır ve kendi ailelerini kurmak için başka gruplara katılırlar. Bu durum da kardeşler arasında çiftleşmeyi engeller. Yabani At Eniyileyici Algoritması atların otlama, tahakküm, liderlik hiyerarşisi ve çiftleşme gibi sosyal davranışlarından esinlenen, sürü tabanlı bir sezgisel üstü algoritmadır ve 5 ana adımdan oluşur (Zheng vd., 2022):

1. Başlangıç sürüsü ile at gruplarının oluşturulması ve liderlerin seçimi
2. Atların otlatılması ve çiftleştirilmesi
3. Lider aygır tarafından gruba liderlik yapılması
4. Lider değişimi ve seçimi
5. En iyi çözümün kaydedilmesi



**Şekil 4.3.** Orijinal sürüden grupların oluşumu (Naruei & Keynia, 2021).

#### 4.1.1. Başlangıç aşaması

Bu aşamada başlangıç kümesi, at grupları ve liderin belirlenmesi süreçleri vardır ve **Şekil 4.3**'te görüldüğü gibi sürü şeması ortaya çıkarılır.

Bir gruptaki lider sayısının oranı,

$$PS = \frac{G_i}{N_i}, i = 1, 2, 3, \dots \quad (4.1)$$

eşitliğiyle belirlenir.

$N$  tane birey,  $G$  tane grup için;  $G$  tane lider ve  $N - G$  tane lider olmayan (kısırak ve taylar) at vardır.

#### 4.1.2. İkinci aşama: otlama davranışı - yerel arama stratejisi

Sürünün otlaktaki davranışları modellenir. Bu davranışta aygır merkezî rol oynar.

$$X_{G,j}^i = 2Z\cos(2\pi RZ) \cdot (Stallion_{G,j} - X_{G,j}^i) + Stallion_{G,j} \quad (4.2)$$

Burada  $j$ . grup içerisindeki  $i$ . grubun üye ve aygırlarının pozisyonu  $Stallion_{G,j}$  ve  $X_{G,j}^i$  ile ifade edilir.  $R$  parametresi  $(-2, 2)$  açık aralığında random bir değer,  $Z$  ise denklem (4.3)'te hesaplanan süreçteki değişimlere göre kendini uyarlayan parametredir.

$X_{G,j}^i$ :  $j$ . gruptaki üyenin pozisyonları

$Stallion_{G,j}$ :  $j$ . gruptaki aygırların pozisyonları

$R$ :  $(-2, 2)$  arasındaki rastgele bir sayı

$$P = \overrightarrow{R_1} < TDR \quad (4.3)$$

$$TDR = 1 - \frac{t}{t_{max}} \quad (4.4)$$

$$Z = R_2\theta IDX + \overrightarrow{R_3}\theta(\sim IDX), IDX = (P == 0) \quad (4.5)$$

$TDR$ : Doğrusal olarak azalan parametre

$t$ : Mevcut yineleme sayısı

$t_{max}$ : Maksimum sayıda yinelemeler

$Z$ : Hesaplanan uyarlanabilir parametre

$P$ : boyutu problemin boyutlarına eşit olan ve 0 ile 1'lerden oluşan bir vektör

$\overrightarrow{R_1}$  ve  $\overrightarrow{R_3}$ : 0 – 1 arasındaki rastgele vektörler

$R_2$ : (0 – 1) arasındaki rastgele sayılar

Otlama aşamasında aygırın otlama alanının merkezinde olduğu varsayılmıştır. Taylar ise grubun yakınında otlarlar. Diğer bireylerin hareketleri için ise aşağıdaki formüller kullanılır.

#### 4.1.3. Üçüncü aşama: çiftleşme davranışı – çözümlerin birleştirilmesi

Atların çiftleşme davranışında sürü henüz çiftleşme yaşına gelmeden tayları ayırarak ebeveyn ile tay arasında çiftleşmeyi önlemektedir. Denklem (4.6)'te bu davranış modellenmiştir.


$$X_{G,k}^p = \text{Crossover}(X_{G,j}^q, X_{G,j}^z), \quad i \neq j \neq k, \quad q = z = \text{end} \quad (4.6)$$

$$\text{Crossover} = \text{mean}$$

Bu eşitlikte  $X_{G,k}^p$ ,  $i$  grubundaki  $q$  atının ve  $j$  grubundaki  $z$  atının konumlarını içeren  $k$  konumundaki  $p$  atının konumudur. Burada geçiş parametresi olan *Crossover yüzdesi* (*PC*) WHO'nun ayarlanabilen parametrelerindendir.

Atların diğer hayvanlardan ayrılan benzersiz bir davranışları, tayların ergenliğe erişmeden ve çiftleşmeden orijinal gruplarından ayrılmasıdır. Böylece kardeş taylar arasında çiftleşme engellenmektedir. Çiftleşme davranışı için ise aşağıdaki formül kullanılır.

$X_{G,k}^p$ :  $j$  grubundaki  $z$  atının ve  $i$  grubundaki  $q$  atının pozisyonlarına göre şekillendirilmiş (çaprazlanmış) olan  $k$  grubundaki  $p$  atının pozisyonu. Temel WHO'da çaprazlama olasılığı, PC adlı bir sabit sayıya ayarlanmıştır.



**Şekil 4.4.** Tayların gruptan ayrılma ve çiftleşme davranışları (Naruei & Keynia, 2021).

#### 4.1.4. Dördüncü aşama: grup liderliği – en iyi çözümleri takip, sömürü fazı

Grup liderleri, diğer grup üyelerini uygun bir su birikintisi olan alana yönlendirirken denklem (4.7) ile modellenen rekabet söz konusu olacak ve liderler arasındaki yarışta kazanan grup önceliğe sahip olacaktır. Bu davranış aşağıdaki eşitlikte modellenmiştir.

Burada  $WH$ , su birikintisinin konumunu,  $\overline{Stallion}_{G,j}$  ve  $Stallion_{G,j}$  ise sırasıyla liderin aday konumu ile mevcut konumunu ifade etmektedir.

Grup liderleri, grubu suyun bulunduğu uygun bir alana yönlendirirler. Ayrıca grup liderleri diğer gruplarla yarışıp kendi gruplarının suyu öncelikle kullanmasını sağlarlar. Bu davranışın formülü ise aşağıdaki gibidir.

$$\overline{Stallion}_{G,j} = \begin{cases} 2Z\cos(2\pi RZ) \times WH - (Stallion_{G,j}) + WH, r_3 > 0.5 \\ 2Z\cos(2\pi RZ) \times WH - (Stallion_{G,j}) - WH, r_3 \leq 0.5 \end{cases} \quad (4.7)$$

$\overline{Stallion}_{G,j}$ : j. gruptaki aday liderin pozisyonu

$Stallion_{G,j}$ : j. gruptaki mevcut liderin pozisyonu

$WH$ : Su birikintisinin pozisyonu

#### 4.1.5. Beşinci aşama: liderlerin değişimi ve seçimi – yeni nesil oluşturma

Son aşama olan bu aşamada liderin değişimi ve seçimi ele alınır. Başlangıçta lider seçimi tüm bireyler arasında rastgele olurken daha sonra uygunluk değeri en iyi olan at lider olur. Bu davranış, denklem (4.8) ile modellenmiştir.

$$Stallion_{G,j} = \begin{cases} X_{G,j}^i & , f(X_{G,j}^i) < f(Stallion_{G,j}) \\ Stallion_{G,i} & , f(X_{G,j}^i) \geq f(Stallion_{G,j}) \end{cases} \quad (4.8)$$

$f(X_{G,j}^i)$ : Tayların uygunluk değeri

$f(Stallion_{G,j})$ : Aygırların uygunluk değeri

**Otlarken:** Mevcut pozisyonlarını iyileştirmeye çalışır.

**Sürü halinde hareket ederken:** Birbirlerini takip eder.

**Lider takip ederken:** En iyi çözümü (en küçük uygunluk değeri) olan ata doğru hareket eder.

Her bir atın amaç fonksiyonundan hesaplanan performans ölçüsü olan bir en uygunluk değeri vardır. En uygun değeri en düşük olan at lider konumuna geçer

#### 4.2. Random Walk Stratejisi

Sezgisel üstü aramalar en iyi çözümü yakalamak için rastgelelik prensibinden faydalanırlar. En iyi çözüme ulaşmak için mevcut yolların tümünü denemeye çalışan belli bir aday çözüm kümesiyle hareket edilir. Küresel aramanın yapılabilmesi ancak yerel en iyi noktayı aşmakla mümkündür; bu süreci yönetme becerisi ancak deterministik olmayan rastgelelik ile mümkündür. Bu aynı zamanda yerel arama için de kullanılır. Yerel arama ve küresel aramanın rastgeleliğine ve dengesine ince ayar yapmak, herhangi bir sezgisel üstü algoritmanın performansını kontrol etmede çok önemlidir (X.-S. Yang, 2012).

Random Walk stratejisi, rastgeleliği sağlama noktasında belli sınırlar içerisinde belli sayıda rastgele adım ile bunu sağlamaktadır. Bu strateji sayesinde bir sonraki yinelemeye yapılan müdahale bir ince ayar vazifesi görerek algoritmanın yerel en iyi noktaya düşmesini engeller (Eker vd., 2024; Gupta & Deep, 2019; Yin vd., 2020).


Bu çalışmada rastgele adım sayısını RW aracılığıyla çoğaltarak yerel aramada da en iyi noktayı bulmayı geciktirerek yerel en iyi noktadan kurtulma olasılığı arttırılmış oldu. Bu stratejide değişen bir parametreye göre grup liderinin konumu saptırılabilir. Böylece uygunluk değerleri farklılaşmış olur.

$$x = x_0 + Walk \times (0.5 - rand(1)) \quad (4.9)$$

Burada  $x$  saptırılmış değeri,  $x_0$ , liderin mevcut en iyi konumunu,  $Walk$ , belirlenmiş rastgele adım sayısını belirtir.

#### 4.3. Wild Horse – Random Walk (IWHO) Algoritması

Wild Horse Random Walk (IWHO) Algoritması'nın akış şeması **Şekil 4.5**'te oluşturulmuştur.



Şekil 4.5. IWHO akış şeması.

Sezgisel üstü algoritmalar en iyi çözümleri tanımlamak için rastgeleleştirme kullanır, en iyi sonuç için tüm olası yolları keşfetmek amacıyla bir dizi aday çözümle çalışır. Küresel arama elde etmek yerel bir en iyi noktaya ulaşmayı gerektirir; bu süreç yerel aramalarda da uygulanan deterministik olmayan rastgeleleştirme ile kolaylaştırılır.

Yerel ve küresel aramalar arasında denge sağlamak, sezgisel üstü algoritmaların performansını değerlendirmek için çok önemlidir (Nosrati vd., 2024). Random Walk stratejisi, tanımlanmış sınırlar içinde önceden belirlenmiş sayıda rastgele adım tanıtılarak bu dengeyi artırır. Bu strateji sonraki yinelemelerde ince ayar mekanizması görevi görür ve algoritmanın yerel en iyi noktalarda sıkışmasını önler (Eker vd., 2024; Gupta & Deep, 2019; Yin vd., 2020). Rastgele yürüyüş yöntemi düzenli ilerlemeyi bozarak çeşitlilik tanıtır, yerel en iyi noktalarda erken sıkışmayı önlemek için gelecekteki yinelemelerle sapma sağlar. Bu yaklaşım, yerel en iyi noktalara çok hızlı ulaşmadan onlardan kaçınmaya yardımcı olur. Keşif aşamasında, sonraki yinelemelerde sapma azaldıkça ilerleme kaydedilir, bu da daha az belirgin sapmalara ve kararlı sonuçlar elde etmeye yol açar. Adım boyutunu belirleyen Walk parametresi, rastgele yürüyüşlerin çeşitli arama algoritmalarına entegre edilmesine olanak tanır. Erken çözümü geciktirerek yerel en iyi noktalarda sıkışmayı önleme işlevi görür. Adım boyutu dağılımını seçmek arama sürecinde hayati öneme sahiptir. Küçük adım boyutu, mevcut çözümleri iyileştirmeye odaklanarak mevcut duruma yakın arama uzayına yoğunlaşmayı teşvik eder. Tersine, yeterince büyük adım boyutu, daha fazla araştırma için yeni ve umut verici bölgeleri potansiyel olarak ortaya çıkararak arama uzayı içindeki keşfedilmemiş alanların keşfini teşvik eder (Eker, 2024).

Bu çalışmada, RW aracılığıyla rastgele adım sayısını artırarak, yerel arama aşamasında en iyi noktanın keşfini geciktirerek erken yakınsamayı önleme ve yerel en iyi noktada sıkışma olasılığını azaltır. Bu stratejide, uygunluk değerleri grup liderinin pozisyonunu değişken bir parametreye göre ayarlayarak farklılaştırılır.

$$\left. \begin{aligned} gBest &= WH.pos \\ x_0 &= gBest \end{aligned} \right\} \quad (4.10)$$

$$x = x_0 + Walk \times (0.5 - rand(1)) \quad (4.11)$$

Burada gBest, denklem (4.10)'daki su birikintisinin en iyi konumudur; sapma değerini, liderin mevcut en iyi pozisyonunu ve denklem (4.11)'daki rastgeleleştirilmiş adım sayısını temsil eder. IWHO algoritmasının akış şeması **Şekil 4.5**'te gösterilmiştir.

**Algoritma 41.** IWHO algoritmasının sözde kodu.

- 1: **Aşama 1: Başlangıç**
- 2: **Parametrelerin ayarlanması:**
- 3:  $N$  = arama ajanlarının (atların) sayısı

```

4:  $t_{max}$  = maksimum yineleme sayısı
5:  $dim$  = problemin boyutu (değişken sayısı)
6:  $lb, ub$  = alt ve üst sınırlar
7:  $r$  = rastgele yürüyüş adım sayısı
8: Başlangıç popülasyonunun oluşturulması
9: for  $i = 1$  to  $N$  do
10:    $X_i$ : alt ve üst sınırlar arasından rastgele konum  $[lb, ub]$ 
11:    $X_i$ 'nin uygunluğunun değerlendirilmesi
12: end for
13: Hiyerarşinin ve grup yapısının oluşturulması
14: Denklem (4.1) kullanılarak lider oranı yani  $PS$ 'nin hesaplanması
15: Bütün sürünün gruplara ve liderlere ayrılması
16: Ana Döngü
17: for  $t = 1$  to  $t_{max}$  do
18:    $Z$  parametresinin güncellenmesi
19:    $Z = 2 * (1 - (t/t_{max})^2)$ 
20:   Aşama 2: Otlama davranışı
21:   for each group  $i$  do
22:     for each member  $j$  in group  $i$  do
23:       Denklem (4.2) ile konum güncellenmesi
24:        $R = (-2, 2)$  arasında rastgele değer
25:        $X_{ij} = X_{ij} + R * z * (X_{stallion} - X_{ij})$ 
26:       Evaluate fitness ( $X_{ij}$ )
27:     end for
28:   end for
29:   Aşama 3: Çiftleşme Davranışı
30:   for each group  $i$  do
31:     for each member  $j$  in group  $i$  do
32:       if random() < PC then # PC (çaprazlama yüzdesi)
33:         Denklem (4.6) ile çaprazlama
34:         Farklı  $k$  grubundan rastgele bir  $Z$  atı seçme
35:          $X_{ij} = crossover(X_{ij}, X_{zk})$ 
36:         Evaluate fitness ( $X_{ij}$ )
37:       end if
38:     end for
39:   end for
40:   Aşama 4: Liderler Arasında Rekabet
41:   for each leader  $i$  do
42:     Denklem (4.10) ile liderin konumunun güncellenmesi
43:      $X_{candidate} = X_i + random() * (X_{puddle} - X_i)$ 
44:     if fitness ( $X_{candidate}$ ) better than fitness ( $X_i$ ) then
45:        $X_i = X_{candidate}$ 
46:     end if
47:   end for
48:   Aşama 5: Lider Seçimi
49:   for each group  $i$  do
50:     Denklem (4.8) ile yeni lider seçimi
51:     if (liderden daha iyi bir uygunluk değerine sahip tay varsa)
52:       Liderin güncellenmesi
53:     end if
54:   end for
55: GELİŞTİRME: Random Walk Stratejisi

```

```

56:         for each leader  $i$  do
57:              $best\_position = X_i$ 
58:             Random Walk adımlarının çalıştırılması
59:             for  $step = 1$  to  $r$  do
60:                 Denklem (4.11) ile Random Walk'un uygulanması
61:                  $X_{deviated} = best\_position + random\_deviation()$ 
62:                 Sınırların sağlanması
63:                  $X_{deviated} = \max(lb, \min(ub, X_{deviated}))$ 
64:                 Yeni konumun değerlendirilmesi
65:                 if  $fitness(X_{deviated})$  better than  $fitness(best\_position)$  then
66:                      $best\_position = X_{deviated}$ 
67:                 end if
68:             end for
69:             Liderin pozisyonunu, Random Walk sonucu elde edilen en iyi sonuçla güncelleme
70:              $X_i = best\_position$ 
71:         end for
72:         Küresel En İyi Sonucu Güncelleme
73:         Daha iyi bir  $X_{best}$  sonucu elde edilirse, güncelle
74:     end for
75: return  $X_{best}$ 

```

Standart WHO aşamalarına uygun olarak, liderler çevredeki ortamı araştırmak için çoklu adımlar atarak rastgele keşiflerde bulunmaktadır. Bu metodoloji, yerel en iyi noktalardan kaçınmaya yardımcı olmakta ve erken yakınsamayı önlemektedir. Bu rastgele keşifler sırasında belirlenen en iyi pozisyon daha sonra benimsenmiştir. Random Walk stratejisi, orijinal WHO algoritmasına kıyasla IWHO'da önemli bir geliştirme sağlamakta, arama uzayının keşfini iyileştirmekte ve yerel en iyi noktalardan kaçınmayı kolaylaştırmaktadır.

#### 4.4. Çalışmada Kullanılan Diğer Algoritmalar

##### 4.4.1. Capuchin arama algoritması

Capuchin maymunlarının besin arama esnasında ağaçlar ve nehir kıyılarında dolaşma davranışlarından ilham alınarak önerilen popülasyon tabanlı Capuchin Arama Algoritması'nda (CapSA) maymunların zıplama, sallanma ve tırmanma eylemleri modellenmiştir. Zıplama eylemini ağaçtan ağaca geçmek için kullanan capuchin maymunları, sallanma ve tırmanma eylemleriyle ağaçlar, dallar ve dalların uçlarında kısa mesafeli olarak hareket ederler. Keşif ve sömürü dengesini sağlamak için yaşam şeması yakınsama stratejisini temsil eden uyarlanabilir bir mekanizma kullanır. Yüksek yakınsama hızı sağlamasına rağmen yineleme sayısı arttıkça yerel en iyi noktaya takılmaya eğilimli olması bu algoritma için bir dezavantajdır (Braik, 2021; S. Li vd., 2023).

#### 4.4.2. Harris hawks eniyileme algoritması

Şahinlerin avlanma davranışını modelleyen bu algoritma popülasyon tabanlı sezgisel üstü bir algoritmadır. Şahinlerin sürpriz saldırı adı verilen toplu avlanma tekniğinin modellendiği bu algoritmanın esnek yapısı ve yüksek performanslı sonuçlar sağlaması avantaj olmakla beraber (Heidari vd., 2019), kararsız eniyileme etkisi (Golilarz vd., 2019), keşif ve sömürü yeteneklerindeki dengesizlik nedeniyle erken yakınsama ve yerel en iyi noktalara düşme gibi (Salawudeen vd., 2020) dezavantajlara sahiptir.

#### 4.4.3. Balina – harris hawk – havai fişek algoritması

Kambur balina sürülerinin avlanma davranışlarından ilham alan doğa tabanlı Balina Eniyileme Algoritması (WOA: Whale Optimization Algorithm) (S. Mirjalili & Lewis, 2016), şahinlerin sürü halinde avlanma davranışından ilham alan sürü tabanlı Harris Şahinleri Eniyileme Algoritması (HHO: Harris Hawks Optimization) (Heidari vd., 2019) ve havai fişeklerin patlama davranışlarını taklit eden Havai Fişek Algoritması (FWA: Fireworks Algorithm) (*Fireworks Algorithm for Optimization* | SpringerLink, t.y.) algoritmalarının hibritleştirilmesi sonucu önerilen Balina – Harris Hawk – Havai Fişek Algoritması (WHOFWA: Whale Hawk Optimization Fireworks Algortihm), popülasyon çeşitliliğini önemli ölçüde artırarak küresel ve yerel arama arasında denge kurmakla ve çözüm doğruluğunu artırmakla (Rouhi & Pira, 2024) beraber hesaplama karmaşıklığını artırma dezavantajını da kendisiyle beraber getirmektedir.

#### 4.4.4. Balina – yabani at eniyileyici

Kambur balinaların avlanma davranışlarının modellenmesiyle önerilen Balina Eniyileme Algoritması (WOA: Whale Optimization Algorithm) ve yabani atların otlama, çiftleşme, lider seçimi ve değişimi gibi sosyal davranışlarından ilham alan Yabani At Eniyileyici (WHO: Wild Horse Optimizer) algoritmalarının hibritleştirilmesiyle önerilen Balina – Yabani At Eniyileyici (WHOW: Whale – Wild Horse Optimizer) Algoritması ile WOA'nın spiral hareket mekanizması sayesinde arama uzayında daha etkili keşif, daha esnek çözümler gibi avantajlarının yanı sıra daha yüksek doğruluk oranları, farklı eniyileme problemlerinde uygulanabilirlik, daha az parametre sunulmuştur. WHOW, sunduğu avantajlarına karşılık düşük sömürü yeteneği, yerel en iyi noktalara takılmaya eğilimli olma, yavaş yakınsama hızı ve muhtemel hesaplama karmaşıklığı gibi dezavantajlara da sahiptir (Ewees vd., 2022).

#### **4.4.5. Rastgele yürüyüş – karahindiba algoritması**

Rastgele adımlarla modellenmiş olan Random Walk Algoritması ile karahindiba tohumlarının rüzgarda uçuşlarının modellenmesiyle önerilen Karahindiba Algoritması'nın (DO) hibritleştirilmesiyle önerilen Rastgele Yürüyüş – Karahindiba Algoritması (RW-DO) (Eker, 2024)





## 5. IWHO TABANLI MLP EĞİTİMİ İLE ENERJİ VERİMLİLİĞİ PROBLEMİNİN ÇÖZÜMÜ

### 5.1. Isıtma, Havalandırma, Klima

Binalardaki ısıtma, havalandırma ve klima (HVAC) sistemleri, yüksek enerji ihtiyaçları nedeniyle küresel operasyonel CO<sub>2</sub> emisyonlarının önemli bir kaynağıdır.

Geleneksel kontrol sistemleri, bina enerji kullanımını yönetmede etkili olsa da karmaşık ortamlarla başa çıkmakta zorlanmakta veya deneyimlerden öğrenme yeteneğini karar alma süreçlerine entegre edememektedir. Bu durum, hesaplama gereksinimlerini artırmaktadır (Al Sayed vd., 2024).

HVAC sistemleri ev, ofis, hastane, alışveriş merkezleri ve endüstriyel tesislerde yaygın olarak kullanılır. Modern sistemler enerji verimliliği, akıllı kontrol ve hava filtreleme özellikleri de sunar.

Mevcut yapılar, küresel enerji kullanımında yaklaşık %40 ve karbon emisyonlarında %30'luk bir paya sahip olup, ısıtma ve soğutma yükleri bu tüketimin önemli bir bölümünü temsil etmektedir (Tahir & Al-Ghamdi, 2023).

Kentleşme hızlandıkça ve iklim değişikliği şiddetlendikçe, bina soğutma ve ısıtma talep tahminlerinin en iyilenmesi, enerji verimliliğini artırmak ve çevresel etkiyi azaltmak için vazgeçilmez hale gelmiştir (Behmane & Pakere, 2024). Yaygın olarak kullanılan geleneksel mühendislik tabanlı tahmin yöntemleri, enerji sistemleri içindeki karmaşık doğrusal olmayan ilişkileri yakalamada genellikle başarısız olmaktadır.

Son çalışmalar, makine öğrenmesi (ML) tekniklerinin tahmin doğruluğunu artırabileceğini ve daha uyarlanabilir tahmin modelleri sunabileceğini önermektedir (Patil vd., 2024).

### 5.2. IWHO Algoritması'nın Performans Üstünlüğü

**Tablo 5.1**'de IWHO algoritmasının parametreleri gösterilmektedir.

**Tablo 5.1.** Kullanılan algoritmadaki parametreler.

| Parametre      | Açıklama                                   | Değer                                      |
|----------------|--------------------------------------------|--------------------------------------------|
| $N$            | Arama ajanlarının sayısı                   | 40                                         |
| $t_{max}$      | Maksimum yineleme sayısı                   | 500                                        |
| $d$            | Problemin boyutu                           | 9, 10, 16, 18 (CEC2019 fonksiyonları)      |
| $lb, ub$       | Alt ve üst sınırlar                        | $[-100, 100]$                              |
| $r$            | Random Walk adım sayısı                    | 300                                        |
| $x_i$          | $i$ . atın / ajanın konumu                 | -                                          |
| $x_{i,j}$      | $i$ grubundaki $j$ . atın                  | -                                          |
| $x_{stallion}$ | Grup liderinin (aygırın) konumu            | -                                          |
| $Z$            | Kendinden uyumlu parametre                 | $Z = 2 \times (1 - (\frac{t}{t_{max}})^2)$ |
| $R$            | Güncelleme denklemlerindeki rastgele değer | $R \in (-2, 2)$                            |
| $P$            | Rastgele vektör                            | $P \in (0, 1)$                             |
| $PC$           | Çaprazlama yüzdesi                         | Uyarlanabilir                              |

Çalışmada kullanılan CEC 2019 fonksiyonları **Tablo 5.2**'de gösterilmiştir.

**Tablo 5.2.** CEC 2019 test fonksiyonları.

| Fonksiyonlar                                             | Boyut | Sınırlar            | Uygunluk değeri |
|----------------------------------------------------------|-------|---------------------|-----------------|
| CEC01: Storn'un Chebyshev Polinom Uygunluk Problemi (F1) | 9     | $[-8.192, 8.192]$   | 1               |
| CEC02: Ters Hilbert Matris Problemi (F2)                 | 16    | $[-16.384, 16.384]$ | 1               |
| CEC03: Lennard-Jones Minimum Enerji Küme Problemi (F3)   | 18    | $[-4, 4]$           | 1               |
| CEC04: Rastrigin Fonksiyonu (F4)                         | 10    | $[-100, 100]$       | 1               |
| CEC05: Griewangk Fonksiyonu (F5)                         | 10    | $[-100, 100]$       | 1               |
| CEC06: Weierstrass Fonksiyonu (F6)                       | 10    | $[-100, 100]$       | 1               |
| CEC07: Değiştirilmiş Schwefel Fonksiyonu (F7)            | 10    | $[-100, 100]$       | 1               |
| CEC08: Genişletilmiş Schafer F6 Fonksiyonu (F8)          | 10    | $[-100, 100]$       | 1               |
| CEC09: Mutlu Kedi Fonksiyonu (F9)                        | 10    | $[-100, 100]$       | 1               |
| CEC10: Ackley Fonksiyonu (F10)                           | 10    | $[-100, 100]$       | 1               |

Algoritmaların aldığı değerlerin uygunluğunu ölçmek için **Tablo 5.3**'te gösterilen istatistikî ölçütler olarak ortalama, en iyi değer, en kötü değer ve standart sapma kullanıldı. **Tablo 5.3** incelendiğinde önerilen IWHO algoritmasının CEC03 ve CEC04 dışında tüm fonksiyonlarda en uygun değeri yakaladığını CEC03 için tüm algoritmaların farklı standart sapmalarla aynı sonuçlara vardığını CEC03'te ise WHO'nun çok iyi, önerilen IWHO algoritmasının ise ikinci sırada olduğu görülecektir.

**Tablo 5.3.** CEC 2019 fonksiyonlarının istatistikî performans sonuçları.

| Fonk. | Ölçüt   | WHO       | IWHO-MLP  | CapSA     | HHO      |
|-------|---------|-----------|-----------|-----------|----------|
| CEC01 | Ort     | 5.34E+04  | 4.21E+04  | 5.01E+04  | 5.11E+04 |
|       | Std Spm | 4.62E+04  | 4.17E+04  | 5.39E+04  | 6.15E+03 |
|       | En iyi  | 3.54E+04  | 3.15E+04  | 3.59E+04  | 4.28E+04 |
|       | En kötü | 3.60E+05  | 3.34E+05  | 3.18E+05  | 7.30E+04 |
| CEC02 | Ort     | 1.73E+01  | 1.73E+01  | 1.73E+01  | 1.74E+01 |
|       | Std Spm | 2.15E-14  | 2.15E-14  | 8.80E-05  | 9.99E-03 |
|       | En iyi  | 1.73E+01  | 1.73E+01  | 1.73E+01  | 1.73E+01 |
|       | En kötü | 1.73E+01  | 1.73E+01  | 1.73E+01  | 1.74E+01 |
| CEC03 | Ort     | 1.27E+01  | 1.27E+01  | 1.27E+01  | 1.27E+01 |
|       | Std Spm | 3.15E-06  | 2.36E-07  | 2.21E-14  | 6.49E-06 |
|       | En iyi  | 1.27E+01  | 1.27E+01  | 1.27E+01  | 1.27E+01 |
|       | En kötü | 1.27E+01  | 1.27E+01  | 1.27E+01  | 1.27E+01 |
| CEC04 | Ort     | 2.62E+01  | 2.87E+01  | 4.12E+01  | 1.80E+02 |
|       | Std Spm | 1.57E+01  | 2.36E+01  | 2.10E+01  | 6.29E+01 |
|       | En iyi  | 5.97E+00  | 8.95E+00  | 8.96E+00  | 8.60E+01 |
|       | En kötü | 8.66E+01  | 1.24E+02  | 1.05E+02  | 3.80E+02 |
| CEC05 | Ort     | 1.07E+00  | 1.05E+00  | 1.19E+00  | 2.45E+00 |
|       | Std Spm | 7.07E-02  | 2.86E-02  | 1.08E-01  | 5.15E-01 |
|       | En iyi  | 1.01E+00  | 1.00E+00  | 1.02E+00  | 1.27E+00 |
|       | En kötü | 1.49E+00  | 1.14E+00  | 1.59E+00  | 3.86E+00 |
| CEC06 | Ort     | 5.60E+00  | 3.60E+00  | 7.64E+00  | 9.03E+00 |
|       | Std Spm | 9.28E-01  | 9.87E-01  | 1.23E+00  | 1.11E+00 |
|       | En iyi  | 3.53E+00  | 1.53E+00  | 4.66E+00  | 5.75E+00 |
|       | En kötü | 7.37E+00  | 6.02E+00  | 1.03E+01  | 1.11E+01 |
| CEC07 | Ort     | 1.22E+02  | 6.01E+01  | 4.63E+02  | 3.61E+02 |
|       | Std Spm | 1.25E+02  | 1.26E+02  | 3.07E+02  | 1.78E+02 |
|       | En iyi  | -2.05E+02 | -2.53E+02 | -1.66E+02 | 1.82E+01 |
|       | En kötü | 3.69E+02  | 2.73E+02  | 1.00E+03  | 9.39E+02 |
| CEC08 | Ort     | 4.74E+00  | 4.33E+00  | 5.39E+00  | 5.77E+00 |
|       | Std Spm | 6.43E-01  | 7.06E-01  | 8.49E-01  | 4.84E-01 |
|       | En iyi  | 3.33E+00  | 2.90E+00  | 3.06E+00  | 4.59E+00 |
|       | En kötü | 5.88E+00  | 5.70E+00  | 6.84E+00  | 6.76E+00 |
| CEC09 | Ort     | 2.45E+00  | 2.38E+00  | 2.53E+00  | 3.15E+00 |
|       | Std Spm | 1.29E-01  | 3.19E-02  | 1.60E-01  | 4.49E-01 |
|       | En iyi  | 2.35E+00  | 2.34E+00  | 2.35E+00  | 2.48E+00 |
|       | En kötü | 3.10E+00  | 2.48E+00  | 2.98E+00  | 4.64E+00 |
| CEC10 | Ort     | 2.00E+01  | 1.96E+01  | 2.01E+01  | 2.02E+01 |
|       | Std Spm | 9.12E-03  | 2.64E+00  | 9.95E-02  | 9.52E-02 |
|       | En iyi  | 2.00E+01  | 1.16E+00  | 2.00E+01  | 2.00E+01 |
|       | En kötü | 2.00E+01  | 2.00E+01  | 2.04E+01  | 2.04E+01 |

Önerilen IWHO-MLP algoritmasının, WHO'nun varyantları olarak önerilen WHOFWA (Rouhi & Pira, 2024) ve WHOW (Ewees vd., 2022) algoritmaları ve Random Walk stratejisi ile çalışılan RW-DO (He vd., 2024) algoritmasıyla karşılaştırılmasıyla elde edilen sonuçlar **Tablo 5.4**'te gösterilmiş olup 7 fonksiyonda çok iyi sonuçlar elde edilmiştir.

**Tablo 5.4.** IWHO-MLP ile diğer hibrit algoritma sonuçlarının karşılaştırılması.

| Fonksiyon | Ölçüt   | IWHO-MLP | WHOFWA   | WHOW     | RW-DO    |
|-----------|---------|----------|----------|----------|----------|
| CEC01     | Ort     | 4.21E+04 | 4.76E+04 | 7.59E+04 | 1.01E+12 |
|           | Std Spm | 4.17E+04 | 4.71E+01 | 4.57E+04 | 5.48E+12 |
| CEC02     | Ort     | 1.73E+01 | 1.73E+01 | 1.73E+01 | 7.54E+02 |
|           | Std Spm | 2.15E-14 | 2.09E-05 | 8.31E-14 | 4.03E+03 |
| CEC03     | Ort     | 1.27E+01 | 1.27E+01 | 1.27E+01 | 1.27E+01 |
|           | Std Spm | 2.36E-07 | 8.75E-10 | 3.95E-15 | 3.24E-04 |
| CEC04     | Ort     | 2.87E+01 | 4.62E+01 | 2.29E+01 | 2.00E+03 |
|           | Std Spm | 2.36E+01 | 1.68E+01 | 5.03E+00 | 5.18E+03 |
| CEC05     | Ort     | 1.05E+00 | 1.31E+00 | 1.08E+00 | 2.22E+00 |
|           | Std Spm | 2.86E-02 | 1.41E-01 | 3.93E-02 | 1.12E+00 |
| CEC06     | Ort     | 3.60E+00 | 4.73E+00 | 5.78E+00 | 1.55E+00 |
|           | Std Spm | 9.87E-01 | 9.60E-01 | 6.06E-01 | 6.87E+00 |
| CEC07     | Ort     | 6.01E+01 | -        | 1.54E+02 | 5.85E+02 |
|           | Std Spm | 1.26E+02 | -        | 5.60E+01 | 3.81E+02 |
| CEC08     | Ort     | 4.33E+00 | 5.10E+00 | 4.88E+00 | 6.03E+00 |
|           | Std Spm | 7.06E-01 | 6.57E-00 | 5.11E-01 | 8.88E-01 |
| CEC09     | Ort     | 2.38E+00 | 2.57E+00 | 2.67E+00 | 2.58E+02 |
|           | Std Spm | 3.19E-02 | 1.26E-01 | 1.29E-01 | 1.22E+03 |
| CEC10     | Ort     | 1.96E+01 | 1.94E+01 | 2.00E+01 | 2.05E+01 |
|           | Std Spm | 2.64E+00 | 3.23E+00 | 9.41E-03 | 2.17E-01 |

**Tablo 5.5**'teki G/B/Y harfleri sırasıyla 'Galibiyet', 'Beraberlik' ve 'Yenilgi' anlamlarına gelmekte olup, IWHO algoritmasının diğer algoritmalarla karşılaştırıldığı durumları yansıtmaktadır. Güven sınırı p-değeri, istatistiksel anlamlılığı gösterdiği kabul edilen 0.05'in altındaki bir değerdir. Galibiyet, Beraberlik, Yenilgi (G/B/Y) için elde edilen sonuçlar değerlendirildiğinde önerilen IWHO algoritmasının farklı ve orijinal bir algoritma olduğu güçlü bir şekilde ortaya konmuştur.

### 5.2.1. Wilcoxon testi

Wilcoxon İşaretli Sıralar Testi parametrik olmayan bir istatistiksel testtir. İki bağımlı (eşleştirilmiş) örneklem arasındaki farkın medyan düzeyinde anlamlı olup olmadığının test edilmesi için kullanılır. Özellikle verilerin normal dağılım göstermediği, örneklem büyüklüğünün küçük olduğu ya da t-testinin uygulanamadığı durumlarda kullanılır. Çoğu zaman üzerinde çalışılacak verilerde normal dağılım ya da varyans homojenliği sağlanamayabilir. Bu durumda parametrik testlere alternatif olarak parametrik olmayan testlere başvurulur. Wilcoxon testi, klasik eşleştirilmiş t-testinin parametrik olmayan karşılığıdır.

Wilcoxon testinde iki eşleştirilmiş ölçüm arasındaki farklar alınır. Farkların mutlak değeri alınır ve büyüklüğe göre sıralanır. Sıralar, işaretlerine (pozitif/negatif) göre toplanır. Daha küçük toplam test istatistiği olarak alınır. Bu istatistik, tablo değeriyle veya p-değeriyle karşılaştırılır. p-değerinin 0.05'ten küçük olması hedeflenir, çünkü böylece sonucun tesadüfi değil, anlamlı olduğu görülür.

**Tablo 5.5.** Wilcoxon test sonuçları.

| Fonksiyon | Ölçüt    | WHO        | CapSA    | HHO      |
|-----------|----------|------------|----------|----------|
| CEC01     | p-değeri | 3.03E-04   | 2.80E-03 | 9.66E-05 |
|           | G/B/Y    | G          | G        | G        |
| CEC02     | p-değeri | 1.00E+00   | 5.15E-10 | 5.15E-10 |
|           | G/B/Y    | Y          | G        | G        |
| CEC03     | p-değeri | 1.00E+00   | 5.00E-01 | 5.15E-10 |
|           | G/B/Y    | Y          | G        | G        |
| CEC04     | p-değeri | 7.7860E-01 | 2.27E-05 | 5.47E-10 |
|           | G/B/Y    | Y          | G        | G        |
| CEC05     | p-değeri | 1.07E-01   | 1.40E-09 | 5.15E-10 |
|           | G/B/Y    | B          | G        | G        |
| CEC06     | p-değeri | 8.27E-10   | 5.15E-10 | 5.15E-10 |
|           | G/B/Y    | G          | G        | G        |
| CEC07     | p-değeri | 3.25E-01   | 8.65E-09 | 7.80E-10 |
|           | G/B/Y    | Y          | G        | G        |
| CEC08     | p-değeri | 5.93E-01   | 8.61E-07 | 3.94E-09 |
|           | G/B/Y    | Y          | G        | G        |
| CEC09     | p-değeri | 2.27E-05   | 7.32E-09 | 5.15E-10 |
|           | G/B/Y    | G          | G        | G        |
| CEC10     | p-değeri | 6.70E-08   | 5.15E-10 | 5.15E-10 |
|           | G/B/Y    | G          | G        | G        |

IWHO algoritmasının WHO, CapSA ve HHO algoritmalarıyla ikili olarak performans karşılaştırma işlemleri sonucunda hemen hemen tüm fonksiyonlar için WHO, CapSA ve HHO algoritmalarına karşı anlamlı bir üstünlük (G) ortaya konmuştur. **Tablo 5.5**'teki sonuçlar dikkate alındığında elde edilen sonuçlar, IWHO'nun genel olarak rakiplerine kıyasla daha etkili ve güvenilir bir eniyileme algoritması olduğu anlaşılmaktadır.

### 5.2.2. Duyarlılık analizi

Duyarlılık analizi, bir modelin sonuçlarının, giriş parametrelerindeki değişimlere karşı ne kadar duyarlı olduğunu ölçmek için kullanılan bir yöntemdir. Hangi giriş parametresinin, çıktı üzerinde ne kadar etkili olduğunu belirmesinden dolayı önem arz etmektedir. Model sonuçlarını en çok etkileyen değişkenlerin belirlenmesini, girdi değişkenlerinin belirsizlik içeren koşullarda nasıl sonuçlara sebebiyet vereceğinin anlaşılmasını sağlar.

**Tablo 5.6** ve **Tablo 5.7**'de ayrıntılı olarak gösterilen sonuçlara göre; gerçekleştirilen bir duyarlılık analizinde parametre ayarlamalarının IWHO algoritması üzerindeki etkileri değerlendirildiğinde neredeyse tüm fonksiyonlar için sonuçlar olumlu olmuştur. Rastgele yürüyüş adım sayısı 300 ve 500 olarak iki farklı analiz gözlemlenmiştir.

**Tablo 5.6.** RW = 300 adım için duyarlılık analizi.


| Fonk. | RW = 300 ve sürü boyutu = 40 |          |          |          | RW = 300 ve sürü boyutu = 50 |          |          |          |
|-------|------------------------------|----------|----------|----------|------------------------------|----------|----------|----------|
|       | ps=0.2                       | PC=0.12  | PC=0.13  | PC=0.14  | ps=0.2                       | PC=0.12  | PC=0.13  | PC=0.14  |
| CEC01 | Ort                          | 6.89E+08 | 6.41E+08 | 7.67E+08 | Ort                          | 5.74E+08 | 4.52E+08 | 4.66E+08 |
|       | Std                          | 1.04E+09 | 6.82E+08 | 1.16E+09 | Std                          | 8.51E+08 | 3.86E+08 | 1.77E+08 |
| CEC02 | Ort                          | 1.73E+05 | 1.73E+05 | 1.73E+05 | Ort                          | 1.73E+05 | 1.73E+05 | 1.73E+05 |
|       | Std                          | 0        | 0        | 1.40E-10 | Std                          | 0        | 0        | 0        |
| CEC03 | Ort                          | 1.27E+05 | 1.27E+05 | 1.27E+05 | Ort                          | 1.27E+05 | 1.27E+05 | 1.27E+05 |
|       | Std                          | 1.40E-02 | 2.18E-10 | 0        | Std                          | 1.57E-01 | 9.62E-03 | 8.93E-03 |
| CEC04 | Ort                          | 3.25E+05 | 2.46E+05 | 3.62E+05 | Ort                          | 1.98E+05 | 1.71E+05 | 1.76E+05 |
|       | Std                          | 5.34E+05 | 1.21E+05 | 6.28E+05 | Std                          | 1.00E+05 | 1.50E+05 | 7.38E+04 |
| CEC05 | Ort                          | 1.06E+04 | 1.05E+04 | 1.06E+04 | Ort                          | 1.04E+04 | 1.03E+04 | 1.05E+04 |
|       | Std                          | 4.31E+02 | 2.92E+02 | 4.75E+02 | Std                          | 2.79E+02 | 2.44E+02 | 2.69E+02 |
| CEC06 | Ort                          | 5.40E+04 | 5.54E+04 | 5.40E+04 | Ort                          | 5.22E+04 | 5.15E+04 | 5.24E+04 |
|       | Std                          | 1.07E+04 | 8.05E+03 | 8.27E+03 | Std                          | 9.78E+03 | 8.47E+03 | 7.89E+03 |
| CEC07 | Ort                          | 1.28E+06 | 1.27E+06 | 1.29E+06 | Ort                          | 7.41E+05 | 7.32E+05 | 1.20E+06 |
|       | Std                          | 1.37E+06 | 1.30E+06 | 1.35E+06 | Std                          | 1.31E+06 | 1.21E+06 | 1.11E+06 |
| CEC08 | Ort                          | 4.78E+04 | 4.50E+04 | 4.69E+04 | Ort                          | 4.64E+04 | 4.35E+04 | 4.49E+04 |
|       | Std                          | 7.51E+03 | 6.54E+03 | 6.96E+03 | Std                          | 5.05E+03 | 7.43E+03 | 7.15E+03 |
| CEC09 | Ort                          | 2.44E+04 | 2.43E+04 | 2.44E+04 | Ort                          | 2.39E+04 | 2.30E+04 | 2.39E+04 |
|       | Std                          | 6.61E+02 | 9.13E+02 | 6.75E+02 | Std                          | 3.06E+02 | 7.62E+02 | 5.02E+02 |
| CEC10 | Ort                          | 1.97E+05 | 1.96E+05 | 2.00E+05 | Ort                          | 2.00E+05 | 1.90E+05 | 2.00E+05 |
|       | Std                          | 2.52E+04 | 8.22E+01 | 2.64E+04 | Std                          | 4.85E+01 | 3.82E+01 | 1.32E+02 |

**Tablo 5.7.** RW = 500 adım için duyarlılık analizi.

| Fonk  |      | RW = 500 ve sürü boyutu = 40 |          |          |         | RW = 500 ve sürü boyutu = 50 |          |          |          |
|-------|------|------------------------------|----------|----------|---------|------------------------------|----------|----------|----------|
|       |      | ps=0.2                       | PC=0.12  | PC=0.13  | PC=0.14 | ps=0.2                       | PC=0.12  | PC=0.13  | PC=0.14  |
| CEC01 | Ort  | 3.30E+09                     | 5.17E+08 | 6.16E+08 |         | Ort                          | 4.27E+08 | 7.56E+08 | 7.06E+08 |
|       | Std  | 1.26E+10                     | 2.20E+08 | 6.61E+08 |         | Std                          | 4.01E+07 | 1.44E+09 | 1.23E+09 |
| CEC02 | Ort  | 1.73E+05                     | 1.73E+05 | 1.73E+05 |         | Ort                          | 1.73E+05 | 1.73E+05 | 1.73E+05 |
|       | Std  | 0                            | 0        | 0        |         | Std                          | 3.61E-11 | 3.61E-11 | 0        |
| CEC03 | Ort  | 1.27E+05                     | 1.27E+05 | 1.27E+05 |         | Mean                         | 1.27E+05 | 1.27E+05 | 1.27E+05 |
|       | Std  | 5.48E-11                     | 5.48E-11 | 3.86E-03 |         | Std                          | 5.48E-11 | 3.86E-03 | 5.48E-11 |
| CEC04 | Mean | 5.18E+05                     | 2.25E+05 | 2.32E+05 |         | Mean                         | 2.45E+05 | 2.31E+05 | 2.38E+05 |
|       | Std  | 8.78E+05                     | 1.61E+05 | 1.19E+05 |         | Std                          | 1.08E+05 | 1.18E+05 | 1.43E+05 |
| CEC05 | Mean | 1.05E+04                     | 1.06E+04 | 1.06E+04 |         | Mean                         | 1.05E+04 | 1.04E+04 | 1.04E+04 |
|       | Std  | 3.86E+02                     | 3.80E+02 | 3.39E+02 |         | Std                          | 2.74E+02 | 3.30E+02 | 2.35E+02 |
| CEC06 | Mean | 5.58E+04                     | 5.14E+04 | 5.32E+04 |         | Mean                         | 5.57E+04 | 5.09E+04 | 5.20E+04 |
|       | Std  | 1.13E+04                     | 1.34E+04 | 9.04E+03 |         | Std                          | 6.66E+03 | 1.07E+04 | 9.77E+03 |
| CEC07 | Mean | 1.29E+06                     | 9.15E+05 | 9.26E+05 |         | Mean                         | 9.52E+05 | 7.05E+05 | 7.18E+05 |
|       | Std  | 9.83E+05                     | 1.29E+06 | 1.16E+06 |         | Std                          | 9.11E+05 | 1.03E+06 | 1.39E+06 |
| CEC08 | Mean | 4.60E+04                     | 4.48E+04 | 4.81E+04 |         | Mean                         | 4.76E+04 | 4.36E+04 | 4.43E+04 |
|       | Std  | 5.21E+03                     | 8.35E+03 | 5.35E+03 |         | Std                          | 4.68E+03 | 9.39E+03 | 7.79E+03 |
| CEC09 | Mean | 2.47E+04                     | 2.43E+04 | 2.46E+04 |         | Mean                         | 2.40E+04 | 2.37E+04 | 2.39E+04 |
|       | Std  | 1.91E+03                     | 7.42E+02 | 1.09E+03 |         | Std                          | 5.48E+02 | 4.26E+02 | 3.86E+02 |
| CEC10 | Mean | 1.91E+05                     | 2.00E+05 | 1.81E+05 |         | Mean                         | 2.00E+05 | 1.80E+05 | 1.89E+05 |
|       | Std  | 4.06E+04                     | 1.06E+02 | 5.67E+04 |         | Std                          | 6.21E+01 | 2.28E+02 | 4.59E+04 |

### 5.2.3. Kutu grafikleri

Kutu grafikler medyan, 1. ve 3. kartil, en az ve en çok değerler ile outlier (aykırı) değerlerin birlikte sunulduğu bir grafik türüdür. **Şekil 5.1**'de bu sınırlar gösterilmiştir. **Şekil 5.1**'te analizi yapılan kutu grafiğinin genel bir gösterimi görülmektedir.


**Şekil 5.1.** Kutu grafiği modelinin gösterimi

**Şekil 5.2**'deki grafikler incelendiğinde tüm fonksiyonlarda önerilen IWHO en iyi noktaya en yakın algoritma olduğu gözlemlenir. Bazı fonksiyonlarda çok az aykırı değerler gözlemlenmiş olsa da 51 bağımsız çalıştırma sonucu alınan sonuçlara

bakıldığında sonuçların birbirine oldukça yakın olduğu görülmektedir, bu durum da algoritmanın kararlı bir yapıya sahip olduğunu göstermektedir.

**Şekil 5.2'**deki kutu grafiği modelinde görüldüğü üzere, kutu grafikleri aykırı olmayan minimum ve maksimum değerlere uzanan bıyıklar ile birlikte çizgiler halinde gösterilmekte ve verilerin dağılımını ortaya koymaktadır. Bir kutu grafiğinde, bıyıklar aykırı olmayan minimum ve maksimum değerlere uzanarak verilerin çoğunun dağılımını gösterir. Kutunun kendisi, verilerin orta %50'sini kapsayan ve birinci çeyrekte (Q1) üçüncü çeyreğe (Q3) uzanan çeyrekler arası aralığı (IQR) temsil eder. Kutu içindeki kalın çizgi, verilerin medyanını veya %50'lik dilimini ifade eder. Bıyıkların dışında kalan herhangi bir veri noktası aykırı değer olarak kabul edilir ve kırmızı bir nokta ile gösterilir.






Şekil 5.2. İstatistikî sonuçların kutu grafiği karşılaştırmaları.

#### 5.2.4. Yakınsama eğrisi

Yakınsama eğrileri; bir algoritmanın çözüm doğruluğunun değerlendirilebilmesi, ne kadar hızlı yakınsandığının gözlemlenebilmesi, kararlı olup olmadığının tespit edilebilmesi, hiperparametrelerin performansa etkisinin analiz edilebilmesi gibi sonuçlar için kullanılan temel grafiklerden biridir. Her yinelemede hesaplanan çözümün, küresel ya da yerel çözüme olan uzaklığının değerlendirilmesi sayesinde çözümün doğruluğunun zaman içinde nasıl geliştiği gözlemlenebilir. Algoritmanın ne kadar hızlı yakınsadığını yani çözüme doğru ne kadar hızlı ilerlediğini görmemizi sağlar. Bu, özellikle farklı algoritmaların karşılaştırılmasında kritik bir öneme sahiptir. Yakınsama eğrileri, algoritmanın kararlı mı yoksa salınımlı mı davrandığını göstererek, parametre ayarlamalarında ve yapı iyileştirmelerinde öngörü sağlar. Hiperparametrelerin (örneğin öğrenme oranı, adım büyüklüğü, tolerans değeri vb.) performansa etkisini analiz etmek için de kullanılır.

**Şekil 5.3**'te elde edilen yakınsama eğrileri ile algoritmaların 500 yineleme sonunda en iyi değere nasıl yaklaşıldığını göstermekle beraber algoritmanın yerel minimum noktalarında takılıp takılmadığının ve erken yakınsamaya maruz kalıp kalmadığının gözlemlenebilmesini de sağlamaktadır.




Şekil 5.3. CEC 2019 fonksiyonlarının yakınsama eğrileri.

**Şekil 5.3'**te görüldüğü üzere, önerilen IWHO algoritmasının tüm fonksiyonlarda hızlı bir yakınsamaya sebep olmadan kademeli olarak ilerlediği görülmektedir. IWHO algoritmasının sadece belirli bir yineleme aralığında bir ilerleme göstermeyip, sürekli olarak daha iyi çözümlere doğru hareket ettiğinin gözlemlenmesi, önerilen algoritmanın yerel en iyi noktalarda takılmadan küresel çözüme ulaştığını da göstermektedir. Bununla beraber IWHO algoritmasının tüm fonksiyon seti boyunca ne iyi noktaya doğru yakınsandığı gözlemlenebilmektedir.

### 5.2.5. Big-O notasyonu

Big-O notasyonu bir algoritmanın zaman karmaşıklığını ifade etmek için kullanılan matematiksel bir gösterimdir. Burada amaç zamanın hesabı değil, veri seti büyüdükçe işlem sayısının hesabıdır. **Şekil 5.4'**teki grafikte veri seti boyutuna göre karşılaşılabilecek işlem sayılarının değişimleri gösterilmiştir.




Şekil 5.4. Big O Notasyonu karmaşıklık grafiği.

### 5.3. Önerilen IWHO Algoritması ile MLP Eğitimi

Bu bölümün temel amacı, akıllı binalarda kullanılan ısıtma, havalandırma ve klima (HVAC) sistemlerinde enerji yük faktörlerinin verimliliğini eniyilemektir. Binalarda kullanılan enerji, HVAC sistemleri aracılığıyla tüketilmektedir. HVAC sistemi, bina içindeki havayı ısıtarak, soğutarak ve havalandırarak uygun iç hava koşullarını oluşturmak üzere tasarlanmıştır ve bu süreçte binanın soğutma yükü (CL) ve ısıtma yükü (HL) ve faktörlerini hesaplamaktadır. Binalarda CL ve HL faktörlerinin doğru tahmin edilmesi, doluluk durumuna dayalı enerji tüketiminin azaltılması, enerji

taleplerine göre bina performansındaki deęişikliklerin yönetilmesi, zararlı gaz emisyonlarının azaltılması ve maliyetlerin düşürülmesi açısından önemlidir. Gerekli soğutma ve ısıtma kapasiteleri, bina özellikleri, kullanım şekli ve iklim koşulları gibi temel faktörlere dayalı olarak tahmin edilmektedir. HVAC sisteminin en iyi tasarımı, enerji tasarrufunun sağlanmasında kritik bir rol oynamaktadır. Bu bağlamda, binaların iç tasarımı yalnızca enerji tüketiminden tasarruf açısından deęil, aynı zamanda insan sağlığı açısından da önemlidir. Enerji tasarrufu sağlamak amacıyla, genellikle aktif sistemler olarak tercih edilen HVAC sistemleri kullanılmaktadır. Verimlilik ve enerji tasarrufunu maksimize etmek için HVAC sistemleri, binanın iklim koşullarına göre tasarlanmalıdır (McQuiston vd., 2004; *Prediction of Residential Building Energy Efficiency Performance using Deep Neural Network* | Request PDF, t.y.; Tien Bui vd., 2019; Yussuf & Asfour, 2024).

MLP mimarisi, seçilen problemin boyutlarına göre tasarlanmıştır. Bu çalışmada kullanılan enerji verimlilięi problem veri seti 8 özellięe sahiptir. Bu nedenle, aęın giriş sinyali 8 özellięe baęlı olarak 8 parametreden oluşmaktadır. Bu giriş parametreleri; kütle yoğunluęu, duvar alanı, yüzey alanı, çatı alanı, konumlanma, pencere alanı, pencere alanının dağılımı, toplam yükseklik iken çıkış sinyalleri ısıtma yükü ve soğutma yükü olarak tanımlanmıştır. Giriş ve çıkış katmanları arasında yer alan gizli katmandaki düęüm sayısı, giriş katmanındaki 8 düęümün iki katından bir fazla olmak üzere 17'dir. Şekil 5.5'da enerji verimlilięi problemi veri seti için oluşturulan MLP mimarisi gösterilmiştir.



**Şekil 5.5.** Enerji verimliliği problemi veriseti için MLP Mimarisi.


Şekil 5.5'te gösterilen mimaride, hata oranı olarak MSE, transfer fonksiyonu olarak sigmoid fonksiyonu kullanılmıştır. Soğutma yükü ve ısıtma yükü farklı birer çalışma alanını belirttiği için tek bir çıkış kullanılmıştır. Hem WHO hem de önerilen IWHO hibrit algoritmaları danışman olarak seçilmiş ve MLP eğitimi gerçekleştirilmiştir. MLP eğitiminin sonuçları istatistiksel olarak değerlendirilmiştir. WHO'nun çalışma süresi 10 bağımsız çalıştırma için ortalama 0,0087 iken, IWHO-MLP'nin çalışma süresi 0,0107'dir. Hibrit algoritma için eklenen parametreler zamanda ortalama %22,98'lik bir gecikmeye neden olsa da her yinelemede harcanan kısa süre göz önüne alındığında algoritmaların eniyileme süreçlerinin hızlı olduğu görülmüştür.


**Tablo 5.8.** Regresyonel ölçümlerin sonuçları.

| Metrik         | WHO          |             | IWHO-MLP     |             |
|----------------|--------------|-------------|--------------|-------------|
|                | Soğutma Yüğü | Isıtma Yüğü | Soğutma Yüğü | Isıtma Yüğü |
| MSE            | 2.65E-01     | 3.33E-01    | 2.57E-01     | 3.14E-01    |
| RMSE           | 5.15E-01     | 5.68E-01    | 5.08E-01     | 5.61E-01    |
| MAE            | 4.20E-01     | 4.70E-01    | 4.30E-01     | 4.8E-01     |
| MAPE           | %1,7         | %1,9        | %1,7         | %1,9        |
| R <sup>2</sup> | 9.81E-01     | 9.80E-01    | 9.85E-01     | 9.83E-01    |

IWHO Algoritması hem soğutma hem de ısıtma yüğü için düşük hata metrikleri (MSE, RMSE, MAE) ve önemli açıklama gücü (R<sup>2</sup>) ile kanıtlanan güçlü regresyon performansı sergilemektedir. %2'nin altındaki MAPE değerleri, modelin tahminlerinin gerçek değerlerle yakından uyumlu olduğunu göstermektedir. 0,98'in üzerindeki R<sup>2</sup> değeri, modelin verilerdeki varyansın neredeyse tamamını açıkladığını işaret etmektedir.

İkinci bir analiz olarak, **Şekil 5.6**'de gösterildiği üzere ortalama MSE için WHO ve IWHO değerlerinin yakınsama eğrileri incelendiğinde, IWHO algoritmasının CL için MSE değerleri 6 çalıştırmada WHO'dan daha düşük olmuş ve aynı zamanda daha tutarlı olmuştur. Benzer şekilde, HL için IWHO algoritmasının MSE değerleri WHO algoritmasına kıyasla birbirine daha yakın ve daha kararlı olmuştur.

**Şekil 5.6.** CL ve HL için ortalama MSE değerleri.



Şekil 5.7. Ortalama işlem zamanları.


Üçüncü bir analiz olarak, WHO ve IWHO algoritmaları tahmin oranları açısından karşılaştırıldığında, WHO algoritmasının CL faktörü için ortalama tahmin değeri  $99,6980 \pm 1,4980E - 14$  iken IWHO için bu değer  $99,7010 \pm 1,1751E - 14$ 'tür. HL faktörü için hem WHO hem de IWHO algoritmalarının ortalama tahmin değerleri 100'dür.

Dördüncü bir analiz olarak, Big-O notasyonu değerlendirilmiştir. Bu çalışmada tanıtılan IWHO-MLP algoritmasının hesaplama karmaşıklığı birkaç parametreden etkilenmektedir: Sürü büyüklüğü ( $N$ ), maksimum yineleme sayısı ( $t$ ), rastgele yürüyüş adım sayısı ( $s$ ) ve problem boyutu ( $d$ ). Her yinelemede, popülasyonun her üyesi için konum güncellemeleri, rastgele yürüyüşler ve uygunluk değerlendirmeleri gerçekleştirilmiştir. Bu işlemler Big-O notasyonu ile  $O(t \times N \times (s + d))$  olarak ifade edilebilir. Karmaşıklık hesaplaması,  $S = 300$  ve  $d = 162$ 'yi sabit tutarak  $t$  ve  $n$  değişkenlerindeki varyasyonlara dayalı olarak belirlenebilmektedir.

**Tablo 5.9** analiz sonuçlarını, **Şekil 5.8** ise IWHO algoritmasının hesaplama karmaşıklığını göstermektedir.

**Tablo 5.9.** Veri sayısına göre yineleme ve işlem sayısının değişimi.

| Sürü Boyutu (N) | Toplam İşlem Sayısı (milyon) | Yineleme Sayısı (t) | Toplam İşlem Sayısı (milyon) |
|-----------------|------------------------------|---------------------|------------------------------|
| 50              | 5.78                         | 50                  | 4.62                         |
| 100             | 11.55                        | 100                 | 9.24                         |
| 150             | 17.32                        | 150                 | 13.86                        |
| 200             | 23.10                        | 200                 | 18.48                        |
| 250             | 28.88                        | 250                 | 23.10                        |
| 300             | 34.65                        | 300                 | 27.72                        |



**Şekil 5.8.** IWHO-MLP Algoritması'nın hesaplama karmaşıklığı .

Bu analiz, IWHO-MLP algoritmasının hesaplama karmaşıklığının kabul edilebilir sınırlar içinde kaldığını ve benzer sezgisel üstü eniyileme algoritmalarına kıyasla karşılaştırılabilir olduğunu göstermektedir. MLP mimarisinin tüm parametrelerini özetleyen bir notasyon tablosu **Tablo 5.10**'da verilmiştir.

**Tablo 5.10.** MLP notasyon tablosu özeti.

| Parametre                        | Açıklama                                   | Değer                                                                                                                                  |
|----------------------------------|--------------------------------------------|----------------------------------------------------------------------------------------------------------------------------------------|
| HL                               | Isıtma yükü (MLP'nin çıktısı)              | -                                                                                                                                      |
| CL                               | Soğutma yükü (MLP'nin çıktısı)             | -                                                                                                                                      |
| Giriş öznitelikleri              | MLP girişleri için öznitelikler            | Kütle Yoğunluğu<br>Duvar Alanı, Yüzey Alanı<br>Çatı Alanı Konumlanma<br>Pencere Alanı<br>Pencere Alanının Dağılımı<br>Toplam Yükseklik |
| Gizli katman düğümleri           | MLP'nin gizli katmanındaki düğüm sayısı    | 17                                                                                                                                     |
| Çıkış düğümleri                  | MLP'deki çıkış düğümlerinin sayısı         | 1 (HL or CL)                                                                                                                           |
| Popülasyon boyutu                | Eniyilemedeki ajan sayısı                  | 200                                                                                                                                    |
| Çalıştırma sayısı                | Deneyler için bağımsız çalışma sayısı      | 10                                                                                                                                     |
| İşlem zamanı (WHO için)          | 10 çalıştırma için ortalama çalışma süresi | 0.0087                                                                                                                                 |
| İşlem zamanı (IWHO-MLP için)     | 10 çalıştırma için ortalama çalışma süresi | 0.0107                                                                                                                                 |
| Tahmin oranı (CL, WHO için)      | CL (WHO-MLP) için ortalama tahminî değer   | $99.6980 \pm 1.4980E-14$                                                                                                               |
| Tahmin oranı (CL, IWHO-MLP için) | CL (IWHO-MLP) için ortalama tahminî değer  | $99.7010 \pm 1.1751E-14$                                                                                                               |
| Tahmin oranı (HL, WHO için)      | HL (WHO-MLP) için ortalama tahminî değer   | 100                                                                                                                                    |
| Tahmin oranı (HL, IWHO-MLP için) | HL (IWHO-MLP) için ortalama tahminî değer  | 100                                                                                                                                    |
| Karmaşıklık                      | IWHO-MLP için hesaplama karmaşıklığı       | $O(t \times N \times (s + d))$                                                                                                         |

## 6. SONUÇ VE ÖNERİLER

Günümüzde en iyileme teknikleri, yalnızca mühendislik ve bilimsel araştırmaların değil, aynı zamanda enerji verimliliğinden ekonomik planlamaya kadar pek çok disiplinin merkezinde yer almaktadır. Gerçek dünya problemlerinin karmaşık ve çok boyutlu yapıda olmasından kaynaklı olarak çözüm zorlukları, geleneksel yöntemlerin dışında esnek, uyarlanabilir ve güçlü algoritmaların geliştirilmesini beraberinde getiriyor. Bu zorunlulukla beraber geliştirilen yeni algoritmalar doğadan ilham alan ve sürü zekâsı prensiplerine dayanan stratejilerle üretilmiştir. Sezgisel üstü olarak tanımlanan bu algoritmalar hem arama alanını etkin biçimde tarama hem de küresel en iyi çözüme ulaşma konusunda önemli üstünlüklere sahiptir. Bu tezde, önerilen IWHO-MLP algoritmasının hem performans üstünlüğü hem de gerçek dünya problemlerinde sağladığı başarı ayrıntılı bir şekilde ortaya konmaktadır.

Bu tezde, WHO algoritmasının temel zaaflarından olan sömürü aşamasında yeterince iyi bir çıkış yakalayamaması nedeniyle Random Walk stratejisinin algoritmaya entegre edilerek belli bir sapma oluşması neticesinde sömürü aşamasını takılmadan geçmesinin sağladığı avantajlar deneysel olarak gözlemlenmiştir. Ayrıca sonuçlar alternatif rekabetçi sezgisel üstü algoritmaların sonuçlarıyla karşılaştırılmıştır. Kullanılan analiz araçları istatistiksel tablolar, kutu grafikleri, yakınsama eğrileri, duyarlılık analizi ve big-O notasyonu gibi metotları içermektedir. Önerilen IWHO-MLP algoritmasının deneysel sonuçları incelendiğinde sonuçların büyük oranda iyileştiği görülmüştür. Hem kutu grafiği hem de yakınsama eğri analizleri sonucunda sömürü-keşif dengesinden dolayı sonuçların kararlı bir şekilde yakınsandığı görülmektedir.

Wilcoxon işaretli-sıra parametrik olmayan testi aracılığıyla elde edilen sonuçlar da IWHO-MLP algoritmasının farklı ve güçlü bir algoritma olduğu kanaatini desteklemektedir. Önerilen IWHO-MLP algoritmasının başarısı aynı zamanda WHO algoritmasının hibritleşmeye uygun esnek bir yapısının olduğunu göstermiştir. Bu esneklik yeteneği WHO algoritması üzerinde farklı stratejilerin uygulanabileceğini, yerel arama alanında bulunan zafiyetin farklı hibritleştirmelerle giderilebileceğini göstermektedir. Ayrıca, IWHO-MLP algoritması gelecekteki çalışmalarda

mühendislik tasarım problemleri ve yapay sinir ağı eğitimi gibi en iyileme zorluklarına uygulanabilir olarak değerlendirilmektedir. IWHO tabanlı MLP mimarisi, verimli enerji kullanımının kritik olduğu günümüzde özellikle önemlidir. MLP eğitimi bağlamında değerlendirildiğinde, IWHO algoritması Random Walk stratejisi aracılığıyla WHO algoritmasının belirli eksikliklerini etkili bir şekilde ele almış, en iyileme sürecini düşük hata oranı ve yüksek tahmin oranıyla en iyi bir zaman diliminde tamamlamıştır. Tüm bunlarla birlikte, MLP eğitimi yoluyla bu tür doğrusal olmayan problemlerin başarılı çözümünün, gerçek dünya problemlerini eniyileme çalışmalarına katkı sağlaması beklenmektedir.

CEC 2019 fonksiyonları, küresel çözüme ulaşmayı geciktiren yapıları nedeniyle en zorlu doğrusal olmayan fonksiyon setleri arasında yer almakta ve algoritma kalitesini değerlendirmek için yaygın olarak kabul görmektedir. Çalışmada temel hedef, küresel parametrik olmayan standartlaşmış bir fonksiyon setini Random Walk stratejisiyle hibritleştirilmiş WHO algoritması (IWHO) ile çözmek ve sonuçları diğer rekabetçi sezgisel üstü algoritmalarla karşılaştırmaktır. IWHO'daki Random Walk stratejisi, CEC 2019 test fonksiyonlarına aşırı uyum potansiyel riski taşımakla birlikte CEC 2019 test setinin keşif özellikleri bu riski azaltmaya yardımcı olmaktadır. Bu çalışmada 10 farklı fonksiyona sahip CEC 2019 setinin seçilmesinin temel gerekçesi, bu fonksiyonların küresel çözümü zorlaştıran yapısından dolayı kıyaslama ölçütü olarak tanınmasıdır. CEC 2019 fonksiyonları, eniyileme algoritmalarının etkinliğini değerlendirmek için tasarlanmış olup, geniş bir problem türü ve karmaşıklık yelpazesini kapsamaktadır. Bu çeşitlilik, algoritmaların hem yakınsama hızının hem de küresel en iyiyi tanımlama yeteneklerinin objektif bir şekilde değerlendirilmesi için yeterlidir. Bu fonksiyonlar, CEC 2019 kıyaslama ölçütünün çekirdek ve en sık atıf yapılan alt kümesini oluşturmakla birlikte boyut, aralık ve problem türü bakımından farklılık göstermekte, algoritmaların performansını kapsamlı bir şekilde değerlendirmek için yeterli zorluk ve çeşitlilik sağlamaktadır. IWHO için 40 arama ajanı, 500 yineleme ve 300 Rastgele Yürüyüş adımı seçilmiştir. Her fonksiyon 51 bağımsız çalıştırmada test edilmiş olup, bu sayı sonuçların daha objektif ve güvenilir olmasını sağlamaktadır. Algoritmanın tüm parametrelerini özetleyen bir gösterim tablosu Tablo 4.1 olarak eklenmiştir.

Önerilen IWHO-MLP algoritmasının CEC03 ve CEC04 dışında tüm fonksiyonlarda en uygun değeri yakaladığını, CEC03 için tüm algoritmaların farklı standart

sapmalarla aynı sonuçlara vardığını, CEC03'te ise WHO'nun çok iyi, önerilen IWHO-MLP algoritmasının ise ikinci sırada olduğu görülmektedir.

Önerilen IWHO algoritması, daha önce WHO'nun varyantları olarak önerilen WHOFWA ve WHOW algoritmaları ve Random Walk stratejisi ile çalışılan RW-DO algoritmasıyla karşılaştırılmıştır. Sonuç olarak, 7 fonksiyonda çok iyi sonuçlar elde edilmiştir. Çıkan 30 sonuçtan G/B/Y için sırasıyla 24/1/5 sonuçları elde edilmiş ve bu sonuçlar da önerilen IWHO algoritmasının güçlü bir şekilde farklı ve orijinal bir algoritma olduğunu ortaya koymuştur.

IWHO algoritması, neredeyse tüm fonksiyonlar için CapSA ve HHO algoritmalarına karşı kayda değer üstünlük göstermiştir. WHO algoritmasıyla karşılaştırıldığında, bazı fonksiyonlarda üstün olmuş, diğerlerinde ise eşitlenmiş veya geride kalmıştır. Dikkat çekici şekilde, CapSA ve HHO'ya karşı IWHO, üstünlük göstermiştir. p-değerleri çoğunlukla çok küçük olmuş (örneğin,  $5.15E-10$ ), bu da gözlemlenen farkın tesadüfi olmaktan ziyade, IWHO'nun üstünlüğünün istatistiksel olarak sağlam olduğunu göstermiştir. Wilcoxon işaretli sıra testinin sonuçları, IWHO algoritmasının özellikle CapSA ve HHO algoritmalarıyla karşılaştırıldığında neredeyse tüm CEC 2019 fonksiyonlarında istatistiksel olarak anlamlı şekilde üstün olduğunu ortaya koymaktadır. Bu bulgular, IWHO'nun genel olarak rakiplerine kıyasla daha etkili ve güvenilir bir eniyileme algoritması olduğunu göstermektedir.

Kullanılan Bonferroni düzeltmesinde değerlendirme ( $p_{values} < 0.05/30$ ) dikkate alındığında,  $h$  vektörünün tüm elemanları 1 olmuştur. Bu sonuç, fonksiyonların Bonferroni testine göre anlamlı olduğunu göstermektedir.

IWHO algoritmasının içindeki en iyi beta parametre değerlerinin belirlenmesi amacıyla bir duyarlılık analizi gerçekleştirilmiştir. Bu amaçla, on farklı fonksiyondan oluşan CEC 2019 test seti seçilmiştir.  $C$  parametresi 0.12, 0.13 ve 0.14 değerlerinde test edilirken,  $ps$  parametresi 0,2 sabit değerinde tutulmuştur. Bu ayarlamaların IWHO algoritması üzerindeki etkileri değerlendirilmiştir. CEC06 için elde edilen sonuçlar en iyi standart sapmayı üretmese de diğer tüm fonksiyonlar için sonuçlar olumlu olmuştur.

**Şekil 5.2** incelendiğinde tüm fonksiyonlarda önerilen IWHO algoritmasında değerlerin birbirine daha yakın ve diğer algoritmalarla karşılaştırıldığında en iyi noktaya da en yakın algoritma olduğu gözlemlenir. CEC01, CEC03, CEC04 ve CEC10

fonksiyonlarında çok az aykırı değerleri gözlemlenmekle beraber 51 bağımsız çalıştırmadan elde edilen sonuçların birbirine oldukça yakın olması algoritmanın kararlı bir yapıya sahip olduğunu göstermektedir. Sonuç olarak bu algoritmanın küresel çözümlerinin en iyi sınırlar içerisinde ve en uygun küresel çözüme de nispeten daha yakın olduğu ifade edilebilir.

Önerilen IWHO algoritmasının ürettiği değerlerin tüm fonksiyonlarda daha yakın bir şekilde kümелendiği ve diğer algoritmalara kıyasla en iyi noktaya en yakın algoritma olduğu açıkça görülmektedir. Hem WHO hem de IWHO algoritmalarında CEC01 fonksiyonu için kutu grafiğinde yer alan bıyıklar, HHO ve CapSA'ya göre belirgin şekilde daha alçak ve kısadır. Bu durum, WHO ve IWHO'nun üstün (daha düşük MSE) ve daha tutarlı sonuçlar elde ettiğini göstermektedir. En düşük bıyık noktası, bu algoritmaların küresel en iyi noktaya daha yakın olduğunu veya küresel en iyi noktaya ulaştığını göstermektedir. CEC02 fonksiyonu için WHO, IWHO ve CapSA çok kısa bıyıklar ve alçak kutular sergilerken, HHO önemli ölçüde daha yüksek ve değişkendir. WHO ve IWHO'nun büyük olasılıkla küresel en iyi noktaya ulaştığı düşünülmektedir. Benzer şekilde, CEC03 fonksiyonu için WHO ve IWHO'nun bıyıkları en düşükken, HHO önemli ölçüde daha yüksektir. Bu durum WHO ve IWHO'nun küresel en iyi noktaya daha yakın olduğunu daha da belirginleştirmektedir. CEC04-CEC10 aralığındaki fonksiyonlarda WHO ve IWHO en düşük bıyık değerlerini göstermektedir. bu sonuçlardan hareketle bu algoritmaların diğer algoritmalara kıyasla daha iyi sonuçlar küresel en iyi değere daha yakın verdiği görülmektedir. CEC01, CEC03, CEC04 ve CEC10 fonksiyonlarında birkaç aykırı değer gözlemlense de 51 bağımsız çalıştırmadan elde edilen sonuçların tutarlılığı algoritmanın kararlı yapısını vurgulamaktadır. Sonuç olarak, bu algoritmanın küresel çözümlerinin en iyi sınırlar içinde olduğu ve en iyi küresel çözüme daha yakın olduğu sonucuna varılabilir.

Yakınsama eğrileri, algoritmaların 500 yineleme sonunda en iyi değere nasıl yaklaştığını, yerel minimum noktalarında takılıp takılmadığını ve erken yakınsamaya maruz kalıp kalmadığını belirlemektedir. Bu bağlamda, önerilen IWHO algoritmasının tüm fonksiyonlarda erken yakınsama olmadan kademeli olarak ilerlediğini göstermektedir. IWHO algoritmasının belirli bir yineleme aralığında sabit bir ilerleme göstermeyip, bunun yerine sürekli olarak daha iyi çözümlere doğru hareket ettiğinin gözlemlenmesi, IWHO algoritmasının yerel en iyi noktalarda takılmadan küresel çözüme ulaştığının kanıtı olarak değerlendirilebilir. Sonuç olarak, IWHO

algoritmasının tüm fonksiyon seti boyunca en iyi noktaya doğru yakınsadığı gözlemlenebilmektedir.

Makul en iyileme sürelerine rağmen, IWHO, WHO'ya kıyasla çalışma zamanında %22,98'lik bir artış yaşamaktadır ve bu durum katı zaman kısıtlamaları olan uygulamalar için bir endişe kaynağı olabilir ancak en iyileme hızı nedeniyle bu ihmal edilebilir bir zaafıdır. Random Walk stratejisinin etkinliği büyük ölçüde parametre seçimine bağlıdır ve bu parametre, duyarlılık testi yoluyla aşılabilecek bir zorluktur. Ayrıca, farklı alanları ve hibritleştirilmeleri keşfetmek, parametre duyarlılığını azaltmaya yardımcı olabilir. Şu anda algoritmanın uygulaması, çalışma öncelikli olarak HVAC sistemlerini hedeflemektedir. Veri setinin nispeten küçük olması bir zaaf gibi görünse de literatürde bu veri setiyle ilgili yoğun bir çalışma grafiği gözlemlenebilir. Bunun anlamı farklı reel dünya problemleri için bu veri setiyle yapılan çalışmaların iyi bir model üretmesidir. Böylece bu modelin başarısı farklı çalışmalarda da gerçek sonuçlara ulaşmayı sağlamaktadır. Random Walk stratejisi yerel en noktalardan kaçınmak için tasarlanmıştır ancak karmaşık en iyileme ortamlarındaki performansının üstünlüğü farklı alanlar ve daha fazla araştırma ile gelecek çalışmalarda deneysel olarak gözlemlenebilecektir. Bu potansiyel sınırlılıklar çalışmanın sonuçlarını tehlikeye atmasa da daha fazla araştırma ve analizin önerilen IWHO algoritmasını ve uygulamalarını geliştirebileceği alanları vurgulamaktadır.

Önerilen IWHO algoritmasının, çeşitli mühendislik problemlerini çözmeyi amaçlayan gelecekteki araştırma girişimlerine rehberlik etmesi öngörülmektedir.



## KAYNAKLAR

- A Hybrid Wild Horses Optimization (WHO) and Dwarf Mongoose Optimization (DMO) method for optimum energy management in SG system—Ganesan—2024—Optimal Control Applications and Methods—Wiley Online Library. (t.y.). Geliş tarihi 10 Temmuz 2025, gönderen <https://onlinelibrary.wiley.com/doi/10.1002/oca.3131?af=R>
- A, P., K, V., C, L., M, K., B, G. S., J, B. P. P., & R, S. S. (2024). Meta-Heuristics and Machine Learning Applications in Complex Systems. İçinde Metaheuristic and Machine Learning Optimization Strategies for Complex Systems (ss. 257-275). IGI Global Scientific Publishing. <https://doi.org/10.4018/979-8-3693-7842-7.ch014>
- Adam, S., Alexandropoulos, S.-A., Pardalos, P., & Vrahatis, M. (2019). No Free Lunch Theorem: A Review. İçinde Springer Optimization and Its Applications (ss. 57-82). [https://doi.org/10.1007/978-3-030-12767-1\\_5](https://doi.org/10.1007/978-3-030-12767-1_5)
- Adaptive, Learning, and Pattern Recognition Systems; theory and applications. (1970). <https://shop.elsevier.com/books/adaptive-learning-and-pattern-recognition-systems-theory-and-applications/mendel/978-0-12-490750-8>
- Akalın, F. (2024). Survival Classification in Heart Failure Patients by Neural Network-Based Crocodile and Egyptian Plover (CEP) Optimization Algorithm. Arabian Journal for Science and Engineering, 49(3), 3897-3914. <https://doi.org/10.1007/s13369-023-08183-z>
- Al Sayed, K., Boodi, A., Sadeghian Broujeny, R., & Beddiar, K. (2024). Reinforcement learning for HVAC control in intelligent buildings: A technical and conceptual review. Journal of Building Engineering, 95, 110085. <https://doi.org/10.1016/j.jobe.2024.110085>
- An improved multi-objective Wild Horse optimization for the dual-resource-constrained flexible job shop scheduling problem: A comparative analysis with NSGA-II and a real case study. (t.y.). Geliş tarihi 12 Ağustos 2024, gönderen [https://www.researchgate.net/publication/376330051\\_An\\_improved\\_multi-objective\\_Wild\\_Horse\\_optimization\\_for\\_the\\_dual-resource-constrained\\_flexible\\_job\\_shop\\_scheduling\\_problem\\_A\\_comparative\\_analysis\\_with\\_NSGA-II\\_and\\_a\\_real\\_case\\_study](https://www.researchgate.net/publication/376330051_An_improved_multi-objective_Wild_Horse_optimization_for_the_dual-resource-constrained_flexible_job_shop_scheduling_problem_A_comparative_analysis_with_NSGA-II_and_a_real_case_study)
- Antoniou, A., & Lu, W.-S. (2021). Practical Optimization: Algorithms and Engineering Applications. Springer US. <https://doi.org/10.1007/978-1-0716-0843-2>
- Athanasios Tsanas, A. X. (2012). Energy Efficiency [Dataset]. UCI Machine Learning Repository. <https://doi.org/10.24432/C51307>

- Behmane, E., & Pakere, I. (2024). Assessment of the Potential for Increasing the Energy Efficiency in the Cooling Sector. CONECT. International Scientific Conference of Environmental and Climate Technologies, 26-26. <https://doi.org/10.7250/CONECT.2024.011>
- Beltran, A., Erickson, V., & Cerpa, A. (2013). ThermoSense: Occupancy Thermal Based Sensing for HVAC Control (s. 8). <https://doi.org/10.1145/2528282.2528301>
- Bouaouda, A., & Sayouti, Y. (2022). Hybrid Meta-Heuristic Algorithms for Optimal Sizing of Hybrid Renewable Energy System: A Review of the State-of-the-Art. Archives of Computational Methods in Engineering, 29(6), 4049-4083. <https://doi.org/10.1007/s11831-022-09730-x>
- Boussaïd, I., Lepagnot, J., & Siarry, P. (2013). A survey on optimization metaheuristics. undefined, 237, 82-117. <https://doi.org/10.1016/J.INS.2013.02.041>
- Braik, M. (2021). A Hybrid Multi-gene Genetic Programming with Capuchin Search Algorithm for Modeling a Nonlinear Challenge Problem: Modeling Industrial Winding Process, Case Study. Neural Processing Letters, 53(4), 2873-2916. <https://doi.org/10.1007/s11063-021-10530-w>
- Bujok, P., & Zamuda, A. (2019). Cooperative Model of Evolutionary Algorithms Applied to CEC 2019 Single Objective Numerical Optimization. 2019 IEEE Congress on Evolutionary Computation (CEC), 366-371. <https://doi.org/10.1109/CEC.2019.8790317>
- Chen, T., Sun, Y., Chen, H., & Deng, W. (2024). Enhanced Wild Horse Optimizer with Cauchy Mutation and Dynamic Random Search for Hyperspectral Image Band Selection. Electronics, 13(10), Article 10. <https://doi.org/10.3390/electronics13101930>
- Chen, X., Qiu, L., Li, T., Fan, Y., & Zhou, N. (2024). Hybrid Cloud Workflow Scheduling Algorithm Based on the Improved Wild Horse Optimization Algorithm. 2024 5th International Conference on Computer Engineering and Application (ICCEA), 660-666. <https://doi.org/10.1109/ICCEA62105.2024.10604107>
- Çelik, Y., Yıldız, İ., & Karadeniz, A. T. (2019). Son Üç Yılda Geliştirilen Metasezgisel Algoritmalar Hakkında Kısa Bir İnceleme. European Journal of Science and Technology, 463-477. <https://doi.org/10.31590/EJOSAT.638431>
- Çiçek, İ. B., & Küçükakçalı, Z. (2022). Application with Multilayer Perceptron and Radial Basis Function from Neural Network-Based Methods to Predict Cervical Cancer. ODÜ Tıp Dergisi, 9(3), Article 3. <https://dergipark.org.tr/en/pub/odutip/issue/74758/1178619>
- Dehghan, S., Saboori, H., Parizad, A., & Kiani, B. (2009). Optimal sizing of a hydrogen-based wind/PV plant considering reliability indices. 2009 International Conference on Electric Power and Energy Conversion Systems, (EPECS), 1-9. <https://ieeexplore.ieee.org/document/5415739>
- Dündar, A., İzci, D., Ekinci, S., & Eker, E. (2021). A Novel Modified Lévy Flight Distribution Algorithm based on Nelder-Mead Method for Function

- Optimization. Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi, 12(3), Article 3. <https://doi.org/10.24012/dumf.955645>
- Efficient Initialization Methods for Population-Based Metaheuristic Algorithms: A Comparative Study | SpringerLink. (t.y.). Geliş tarihi 21 Haziran 2023, gönderen <https://link.springer.com/article/10.1007/s11831-022-09850-4>
- Eker, E. (2024). Hybridized Dandelion Optimizer with Random Walks (RW-DO) and its Applications (SSRN Scholarly Paper No. 4922067). Social Science Research Network. <https://papers.ssrn.com/abstract=4922067>
- Eker, E., Atar, Ş., Şevgin, F., & Tuğal, İ. (t.y.). 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.
- Eker, E., Izci, D., Ekinci, S., Migdady, H., Zitar, R. A., & Abualigah, L. (2024). Efficient voltage regulation: An RW-ARO optimized cascaded controller approach. e-Prime - Advances in Electrical Engineering, Electronics and Energy, 9, 100687. <https://doi.org/10.1016/j.prime.2024.100687>
- Eker, E., Kayri, M., Ekinci, S., & Izci, D. (2021). A New Fusion of ASO with SA Algorithm and Its Applications to MLP Training and DC Motor Speed Control. Arabian Journal for Science and Engineering, 46(4), 3889-3911. <https://doi.org/10.1007/s13369-020-05228-5>
- Eker, E., Üniversitesi, M. A., Bölümü, P. ve R., Üniversitesi, B., & Bölümü, B. M. (2019). Kısıtlı optimizasyon problemlerinin çözümü için atom arama optimizasyon algoritması. Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi, 10(3), 841-851. <https://doi.org/10.24012/DUMF.540402>
- EKİNCİ, S., & DEMİRÖREN, A. (2016). Modeling, simulation, and optimal design of power system stabilizers using ABC algorithm. Turkish Journal of Electrical Engineering and Computer Science, 24(3), 1532-1546. <https://doi.org/10.3906/elk-1311-208>
- Ekinci, S., & Hekimoglu, B. (2019). Improved Kidney-Inspired Algorithm Approach for Tuning of PID Controller in AVR System. undefined, 7, 39935-39947. <https://doi.org/10.1109/ACCESS.2019.2906980>
- Ewees, A. A., Ismail, F. H., & Ghoniem, R. M. (2022). Wild Horse Optimizer-Based Spiral Updating for Feature Selection. IEEE Access, 10, 106258-106274. IEEE Access. <https://doi.org/10.1109/ACCESS.2022.3211263>
- Fakhouri, H. N., Hudaib, A., & Sleit, A. (2020). Hybrid Particle Swarm Optimization with Sine Cosine Algorithm and Nelder-Mead Simplex for Solving Engineering Design Problems. Arabian Journal for Science and Engineering, 45(4), 3091-3109. <https://doi.org/10.1007/s13369-019-04285-9>
- Farag, A. A., Ali, Z. M., Zaki, A. M., H.Rizk, F., Eid, M. M., & EL-Kenawy, E.-S. M. (2024). Exploring Optimization Algorithms: A Review of Methods and Applications. Journal of Artificial Intelligence and Metaheuristics, Issue 2, 08-17. <https://doi.org/10.54216/JAIM.070201>

- Fatih Güven, A., & Mahmoud Samy, M. (2022). Performance analysis of autonomous green energy system based on multi and hybrid metaheuristic optimization approaches. *Energy Conversion and Management*, 269, 116058. <https://doi.org/10.1016/j.enconman.2022.116058>
- Fireworks Algorithm for Optimization | SpringerLink. (t.y.). Geliş tarihi 15 Temmuz 2025, gönderen [https://link.springer.com/chapter/10.1007/978-3-642-13495-1\\_44](https://link.springer.com/chapter/10.1007/978-3-642-13495-1_44)
- Gandomkar, M., Vakilian, M., & Ehsan, M. (2005). A Genetic-Based Tabu Search Algorithm for Optimal DG Allocation in Distribution Networks. *Electric Power Components and Systems*, 33(12), 1351-1362. <https://doi.org/10.1080/15325000590964254>
- Ganesan, P., & Arockia Edwin Xavier, S. (2024). A Hybrid Wild Horses Optimization (WHO) and Dwarf Mongoose Optimization (DMO) method for optimum energy management in SG system. *Optimal Control Applications and Methods*, 45(5), 1925-1949. <https://doi.org/10.1002/oca.3131>
- Golilarz, N. A., Addeh, A., Gao, H., Ali, L., Roshandeh, A. M., Mudassir Munir, H., & Khan, R. U. (2019). A New Automatic Method for Control Chart Patterns Recognition Based on ConvNet and Harris Hawks Meta Heuristic Optimization Algorithm. *IEEE Access*, 7, 149398-149405. <https://doi.org/10.1109/ACCESS.2019.2945596>
- Gupta, S., & Deep, K. (2019). A novel Random Walk Grey Wolf Optimizer. *Swarm and Evolutionary Computation*, 44, 101-112. <https://doi.org/10.1016/j.swevo.2018.01.001>
- Haddadjajouh, H., Mohtadi, A., Dehghantanaha, A., Karimipour, H., Lin, X., & Choo, K. K. R. (2021). A Multikernel and Metaheuristic Feature Selection Approach for IoT Malware Threat Hunting in the Edge Layer. *IEEE Internet of Things Journal*, 8(6), 4540-4547. <https://doi.org/10.1109/JIOT.2020.3026660>
- Haykin, S. S. (1999). *Neural Networks: A Comprehensive Foundation*. Prentice Hall.
- He, S., Li, Q., Khishe, M., Salih Mohammed, A., Mohammadi, H., & 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. <https://doi.org/10.1007/s11276-023-03464-9>
- Heidari, A. A., Mirjalili, S., Faris, H., Aljarah, I., Mafarja, M., & Chen, H. (2019). Harris Hawks Optimization: Algorithm and Applications. *Future Generation Computer Systems*, 97, 849-872. <https://doi.org/10.1016/j.future.2019.02.028>
- Hong, Y.-Y., & Lian, R.-C. (2012). Optimal Sizing of Hybrid Wind/PV/Diesel Generation in a Stand-Alone Power System Using Markov-Based Genetic Algorithm. *IEEE Transactions on Power Delivery*, 27(2), 640-647. <https://doi.org/10.1109/TPWRD.2011.2177102>
- Hussain, I., Ching, K. B., Uttraphan, C., Tay, K. G., & Noor, A. (2025). Evaluating machine learning algorithms for energy consumption prediction in electric vehicles: A comparative study. *Scientific Reports*, 15(1), 16124. <https://doi.org/10.1038/s41598-025-94946-7>

- Hybrid Multi-Strategy Improved Wild Horse Optimizer—Li—2022—Advanced Intelligent Systems—Wiley Online Library. (t.y.). Geliş tarihi 19 Mayıs 2024, gönderen <https://onlinelibrary.wiley.com/doi/full/10.1002/aisy.202200097>
- Igel, C. (2014). No Free Lunch Theorems: Limitations and Perspectives of Metaheuristics (ss. 1-23). [https://doi.org/10.1007/978-3-642-33206-7\\_1](https://doi.org/10.1007/978-3-642-33206-7_1)
- Işıksan, E. (2020, Ocak 1). Multi Layer Perceptron (MLP) Nedir? Medium. <https://isikhanelif.medium.com/multi-layer-perceptron-mlp-nedir-4758285a7f15>
- Izci, D. (2021). An Enhanced Slime Mould Algorithm for Function optimization. 2021 3rd International Congress on Human-Computer Interaction, Optimization and Robotic Applications (HORA), 1-5. <https://doi.org/10.1109/HORA52670.2021.9461325>
- Izci, D., Ekinici, S., Eker, E., & Kayri, M. (2020). Improved Manta Ray Foraging Optimization Using Opposition-based Learning for Optimization Problems. 2020 International Congress on Human-Computer Interaction, Optimization and Robotic Applications (HORA), 1-6. <https://doi.org/10.1109/HORA49412.2020.9152925>
- Izci, D., Ekinici, S., Kayri, M., & Eker, E. (2022). A novel improved arithmetic optimization algorithm for optimal design of PID controlled and Bode's ideal transfer function based automobile cruise control system. *Evolving Systems*, 13(3), 453-468. <https://doi.org/10.1007/s12530-021-09402-4>
- Jaddi, N. S., Alvankarian, J., & Abdullah, S. (2017). Kidney-inspired algorithm for optimization problems. *Communications in Nonlinear Science and Numerical Simulation*, 42, 358-369. <https://doi.org/10.1016/J.CNSNS.2016.06.006>
- Karimi-Mamaghan, M., Mohammadi, M., Meyer, P., Karimi-Mamaghan, A. M., & Talbi, E.-G. (2022). Machine learning at the service of meta-heuristics for solving combinatorial optimization problems: A state-of-the-art. *European Journal of Operational Research*, 296(2), 393-422. <https://doi.org/10.1016/j.ejor.2021.04.032>
- Kefayat, M., Lashkar Ara, A., & Nabavi Niaki, S. A. (2015). A hybrid of ant colony optimization and artificial bee colony algorithm for probabilistic optimal placement and sizing of distributed energy resources. *Energy Conversion and Management*, 92, 149-161. <https://doi.org/10.1016/j.enconman.2014.12.037>
- Kennedy, J., & Eberhart, R. (1995). Particle Swarm Optimization. *Proceedings of ICNN'95 - International Conference on Neural Networks*, 4, 1942-1948 c.4. <https://doi.org/10.1109/ICNN.1995.488968>
- Khishe, M., & Mohammadi, H. (2019). Passive sonar target classification using multi-layer perceptron trained by salp swarm algorithm. *Ocean Engineering*, 181, 98-108. <https://doi.org/10.1016/j.oceaneng.2019.04.013>
- Kyaw, K. S., Limsiroratana, S., & Sattayaraksa, T. (t.y.). A Comparative Study of Meta-Heuristic and Conventional Search in Optimization of Multi-Dimensional Feature Selection. <https://services.igi-global.com/resolvedoi/resolve.aspx?doi=10.4018/IJAMC.292517>, 13(1), 1-34. <https://doi.org/10.4018/IJAMC.292517>

- Lagaros, N. D., Plevris, V., & Kallioras, N. Ath. (2022). The Mosaic of Metaheuristic Algorithms in Structural Optimization. *Archives of Computational Methods in Engineering*, 29(7), 5457-5492. <https://doi.org/10.1007/s11831-022-09773-0>
- Lan, H., Wen, S., Hong, Y.-Y., Yu, D. C., & Zhang, L. (2015). Optimal sizing of hybrid PV/diesel/battery in ship power system. *Applied Energy*, 158, 26-34. <https://doi.org/10.1016/j.apenergy.2015.08.031>
- Le, T. M., Vo, T. M., Pham, T. N., & Dao, S. V. T. (2021). A Novel Wrapper-Based Feature Selection for Early Diabetes Prediction Enhanced with a Metaheuristic. *IEEE Access*, 9, 7869-7884. <https://doi.org/10.1109/ACCESS.2020.3047942>
- Li, M.-W., Wang, Y.-T., Yang, Z.-Y., Huang, H.-P., Hong, W.-C., & Li, X.-Y. (2024). CQND-WHO: Chaotic quantum nonlinear differential wild horse optimizer. *Nonlinear Dynamics*, 112(6), 4899-4927. <https://doi.org/10.1007/s11071-023-09246-4>
- Li, S., Li, Z., Li, Q., Zhang, M., & Li, L. (2023). Hybrid improved capuchin search algorithm for plant image thresholding. *Frontiers in Plant Science*, 14, 1122788. <https://doi.org/10.3389/fpls.2023.1122788>
- Machine Learning and Deep Learning Methods for Enhancing Building Energy Efficiency and Indoor Environmental Quality – A Review—ScienceDirect. (t.y.). Geliş tarihi 09 Temmuz 2025, gönderen <https://www.sciencedirect.com/science/article/pii/S2666546822000441>
- Machine Learning Textbook: Introduction to Machine Learning (Ethem ALPAYDIN). (t.y.). Geliş tarihi 27 Haziran 2024, gönderen <https://www.cmpe.boun.edu.tr/~ethem/i2ml/>
- McQuiston, F. C., Parker, J. D., & Spitler, J. D. (2004). *Heating, Ventilating and Air Conditioning Analysis and Design* (6th edition). John Wiley & Sons Inc.
- Mehta, P., Yıldız, B., Sait, S., & Yıldız, A. (2022). Hunger games search algorithm for global optimization of engineering design problems. *Materials Testing*, 64, 524-532. <https://doi.org/10.1515/mt-2022-0013>
- Metwally Mahmoud, M. (2022). Improved current control loops in wind side converter with the support of wild horse optimizer for enhancing the dynamic performance of PMSG-based wind generation system. *International Journal of Modelling and Simulation*, 0(0), 1-15. <https://doi.org/10.1080/02286203.2022.2139128>
- Milovanović, M., Klimenta, D., Panić, M., Klimenta, J., & Perović, B. (2022). An application of Wild Horse Optimizer to multi-objective energy management in a micro-grid. *Electrical Engineering*. <https://doi.org/10.1007/s00202-022-01636-y>
- Minh, C. L. T., & Duong, M. Q. (2024). Reducing Overall Active Power Loss by Placing Solar and Wind Generators in a Distribution Power System using Wild Horse Optimizer Algorithm. *Journal of Engineering and Technological Sciences*, 56(5), Article 5. <https://doi.org/10.5614/j.eng.technol.sci.2024.56.5.2>

- Mirjalili, S. (2016). SCA: A Sine Cosine Algorithm for solving optimization problems. *Knowledge-Based Systems*, 96, 120-133. <https://doi.org/10.1016/J.KNOSYS.2015.12.022>
- Mirjalili, S., & Lewis, A. (2016). The Whale Optimization Algorithm. *Advances in Engineering Software*, 95, 51-67. <https://doi.org/10.1016/J.ADVENGSOFT.2016.01.008>
- Mirjalili, S. M. (2018). *Evolutionary Algorithms and Neural Networks—Theory and Applications*. Studies in Computational Intelligence.
- Mirjalili, S., Mirjalili, S. M., & Lewis, A. (2014). Grey Wolf Optimizer. *Advances in Engineering Software*, 69, 46-61. <https://doi.org/10.1016/j.advengsoft.2013.12.007>
- Naruei, I., & Keynia, F. (2021). Wild horse optimizer: A new meta-heuristic algorithm for solving engineering optimization problems. *Engineering with Computers*, 1-32. <https://doi.org/10.1007/s00366-021-01438-z>
- Nenavath, H., & Jatoth, R. K. (2018). Hybridizing sine cosine algorithm with differential evolution for global optimization and object tracking. *Applied Soft Computing*, 62, 1019-1043. <https://doi.org/10.1016/j.asoc.2017.09.039>
- Nosrati, L., Bidgoli, A. M., & Javadi, H. H. S. (2024). Identifying People's Faces in Smart Banking Systems Using Artificial Neural Networks. *International Journal of Computational Intelligence Systems*, 17(1), 9. <https://doi.org/10.1007/s44196-023-00383-7>
- Patil, M. S., Kulkarni, D. M., & Patil, M. S. A. (2024). Energy Load Forecasting Based on the Load Consumption Factors and Techniques Employed: A Review. *International Research Journal on Advanced Engineering Hub (IRJAEH)*, 2(04), Article 04. <https://doi.org/10.47392/IRJAEH.2024.0143>
- Pham, T. N., Tran, L. V., & Dao, S. V. T. (2020). Early Disease Classification of Mango Leaves Using Feed-Forward Neural Network and Hybrid Metaheuristic Feature Selection. *IEEE Access*, 8, 189960-189973. <https://doi.org/10.1109/ACCESS.2020.3031914>
- Prediction of Residential Building Energy Efficiency Performance using Deep Neural Network | Request PDF. (t.y.). Geliş tarihi 23 Temmuz 2024, gönderen [https://www.researchgate.net/publication/358929639\\_Prediction\\_of\\_Residential\\_Building\\_Energy\\_Efficiency\\_Performance\\_using\\_Deep\\_Neural\\_Network](https://www.researchgate.net/publication/358929639_Prediction_of_Residential_Building_Energy_Efficiency_Performance_using_Deep_Neural_Network)
- Qian, L., Chen, Z., Huang, Y., & Stanford, R. J. (2023). Employing categorical boosting (CatBoost) and meta-heuristic algorithms for predicting the urban gas consumption. *Urban Climate*, 51, 101647. <https://doi.org/10.1016/j.uclim.2023.101647>
- Rao, S. S., & Desai, R. C. (1980). Optimization Theory and Applications. *IEEE Transactions on Systems, Man, and Cybernetics*, 10(5), 280-280. *IEEE Transactions on Systems, Man, and Cybernetics*. <https://doi.org/10.1109/TSMC.1980.4308490>
- R.M., R.-A. (t.y.). Hybridizing sine cosine algorithm with multi-orthogonal search strategy for engineering design problems | *Journal of Computational Design and Engineering* | Oxford Academic. Geliş tarihi 10 Mayıs 2023, gönderen <https://academic.oup.com/jcde/article/5/2/249/5728993>

- Rouhi, A., & Pira, E. (2024). WHOFWA: An effective hybrid metaheuristic algorithm based on wild horse optimizer and fireworks algorithm. *Journal of Electrical and Computer Engineering Innovations (JECEI)*, 12(2), 319-342. <https://doi.org/10.22061/jecei.2024.10422.699>
- Salawudeen, A. Tijani., Nyabvo, P. J., Nuhu, A. S., Akut, E. K., Cinfwat, K. Z., Momoh, Izuagbe. Solomon., & Imam, M. L. (2020). Recent Metaheuristics Analysis of Path Planning Optimaztion Problems. 2020 International Conference in Mathematics, Computer Engineering and Computer Science (ICMCECS), 1-7. <https://doi.org/10.1109/ICMCECS47690.2020.240845>
- Stevanović, S., Dashti, H., Milošević, M., Al-Yakoob, S., & Stevanović, D. (2024). Comparison of ANN and XGBoost surrogate models trained on small numbers of building energy simulations. *PLOS ONE*, 19(10), e0312573. <https://doi.org/10.1371/journal.pone.0312573>
- Tahani, M., Babayan, N., & Pouyaei, A. (2015). Optimization of PV/Wind/Battery stand-alone system, using hybrid FPA/SA algorithm and CFD simulation, case study: Tehran. *Energy Conversion and Management*, 106, 644-659. <https://doi.org/10.1016/j.enconman.2015.10.011>
- Tahir, F., & Al-Ghamdi, S. G. (2023). Climatic change impacts on the energy requirements for the built environment sector. *Energy Reports*, 9, 670-676. <https://doi.org/10.1016/j.egyr.2022.11.033>
- Tien Bui, D., Moayedi, H., Anastasios, D., & Kok Foong, L. (2019). Predicting Heating and Cooling Loads in Energy-Efficient Buildings Using Two Hybrid Intelligent Models. *Applied Sciences*, 9(17), Article 17. <https://doi.org/10.3390/app9173543>
- Ting, T.O., Yang, X., Cheng, S., & Huang, K. (2015). Hybrid Metaheuristic Algorithms: Past, Present, and Future. *Recent Advances in Swarm Intelligence and Evolutionary Computation*.
- Uryasev, S., & Pardalos, P. M. (2013). *Stochastic Optimization: Algorithms and Applications*. Springer Science & Business Media.
- Xi, M., & Liu, H. (2024). An improved wild horse optimization algorithm based on reinforcement learning for numerical and engineering optimizations. *The Journal of Supercomputing*, 81(1), 188. <https://doi.org/10.1007/s11227-024-06651-3>
- Yang, X.-S. (2012). *Metaheuristic Optimization: Algorithm Analysis and Open Problems* (No. arXiv:1212.0220). arXiv. <https://doi.org/10.48550/arXiv.1212.0220>
- Yang, Y., Chen, H., Heidari, A. A., & Gandomi, A. H. (2021). Hunger games search: Visions, conception, implementation, deep analysis, perspectives, and towards performance shifts. *Expert Systems with Applications*, 177, 114864. <https://doi.org/10.1016/J.ESWA.2021.114864>
- Yin, Y., Tu, Q., & Chen, X. (2020). Enhanced Salp Swarm Algorithm based on random walk and its application to training feedforward neural networks. *Soft Computing*, 24(19), 14791-14807. <https://doi.org/10.1007/s00500-020-04832-9>

- Yousaf, S., Bradshaw, C. R., Kamalapurkar, R., & San, O. (2024). A gray-box model for unitary air conditioners developed with symbolic regression. *International Journal of Refrigeration*, 168, 696-707. <https://doi.org/10.1016/j.ijrefrig.2024.10.008>
- Yussuf, R. O., & Asfour, O. S. (2024). Applications of artificial intelligence for energy efficiency throughout the building lifecycle: An overview. *Energy and Buildings*, 305, 113903. <https://doi.org/10.1016/j.enbuild.2024.113903>
- Zhao, W., Wang, L., & Zhang, Z. (2019). Atom search optimization and its application to solve a hydrogeologic parameter estimation problem. *Knowledge-Based Systems*, 163, 283-304. <https://doi.org/10.1016/J.KNOSYS.2018.08.030>
- Zhao, W., Wang, L., & Zhang, Z. (2020). Artificial ecosystem-based optimization: A novel nature-inspired meta-heuristic algorithm. *Neural Computing and Applications*, 32(13), 9383-9425. <https://doi.org/10.1007/s00521-019-04452-x>
- Zheng, R., Hussien, A. G., Jia, H.-M., Abualigah, L., Wang, S., & Wu, D. (2022). An Improved Wild Horse Optimizer for Solving Optimization Problems. *Mathematics*, 10(8), 1311. <https://doi.org/10.3390/MATH10081311>



## ÖZGEÇMİŞ

Ad-Soyad : Şahiner GÜLER

### ÖĞRENİM DURUMU:

- **Lisans** : 2003, Sakarya Üniversitesi Mühendislik Fakültesi Bilgisayar Mühendisliği
- **Yüksek lisans** : 2019, Sakarya Üniversitesi Bilgisayar ve Bilişim Mühendisliği Anabilim Dalı Bilgisayar ve Bilişim Mühendisliği

**MESLEKİ DENEYİM:** 2013 yılından beri Muş Alparslan Üniversitesi'nde öğretim görevlisi olarak görev yapmaktadır.

### TEZDEN TÜRETİLEN ESERLER:

- Güler, Ş., Eker, E., & Yumuşak, N. (2025). Improvement of Wild Horse Optimizer Algorithm with Random Walk Strategy (IWHO), and Appointment as MLP Supervisor for Solving Energy Efficiency Problem. *Energies*, 18(11), 2916. <https://doi.org/10.3390/en18112916>