

KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

YAPAY SİNİR AĞLARI KULLANILARAK ENERJİ TÜKETİM
TAHMİNİ: GÜMÜŞHANE ÖRNEĞİ

YÜKSEK LİSANS TEZİ

Büşra KAYA ÇİÇEK

MART 2024

TRABZON



KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

YAPAY SİNİR AĞLARI KULLANILARAK ENERJİ TÜKETİM
TAHMİNİ: GÜMÜŞHANE ÖRNEĞİ

Büşra KAYA ÇİÇEK

Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsünce
" ELEKTRİK YÜKSEK MÜHENDİSİ"
Unvanı Verilmesi İçin Kabul Edilen Tezdir.

Tezin Enstitüye Verildiği Tarih : 16 / 02 / 2024

Tezin Savunma Tarihi : 19 / 03 / 2024

Tez Danışmanı : Doç. Dr. Fatih Mehmet NUROĞLU

Trabzon 2024

ÖNSÖZ

“Yapay Sinir Ağları Kullanılarak Enerji Tüketim Tahmini:Gümüşhane Örneği” isimli bu tez Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsü Elektrik-Elektronik Mühendisliği Anabilim Dalı, Yüksek Lisans Programı’nda hazırlanmıştır.

Tez çalışmam boyunca hiçbir desteğini esirgemeyen ve kıymetli bilgileriyle destekleyen danışman hocam Sayın Doç. Dr. Fatih Mehmet NUROĞLU’na teşekkürü bir borç bilirim. Tez çalışması sürecinde bana desteklerini esirgemeyen Elektrik-Elektronik Mühendisliği Bölümü’ndeki tüm değerli hocalarıma ve çalışanlarına teşekkürlerimi sunarım.

Doğduğum günden beri elimi hiç bırakmayan, maddi ve manevi desteklerini hiçbir zaman esirgemeyen ve bugünlere gelmemde en büyük paya sahip olan annem Ganime KAYA ve babam Hüseyin KAYA’ya, üç kız kardeşim Merve, Melek ve Aleyna KAYA’ya teşekkür eder, minnettarlığımı sunarım.

Yüksek Lisans eğitimime başladığım günden bu güne yanımda olan Murat Han Çiçek’e ve benim motivasyon kaynağım ve en değerlim oğlum Yiğit Ali ÇİÇEK’e teşekkür ederim. Kendime de azmim için teşekkür ederim.

Bu tez çalışmasının bundan sonraki çalışmalara katkı sağlamasını temenni ederim.

Büşra KAYA ÇİÇEK
Trabzon 2024

TEZ ETİK BEYANNAMESİ

Yüksek Lisans Tezi olarak sunduğum “Yapay Sinir Ağları Kullanılarak Enerji Tüketim Tahmini: Gümüşhane Örneği” başlıklı bu çalışmayı baştan sona kadar danışmanım Doç. Dr. Fatih Mehmet NUROĞLU’nun sorumluluğunda tamamladığımı, verileri/örnekleri kendim topladığımı, deneyleri/analizleri ilgili laboratuvarlarda yaptığımı/yaptırdığımı, başka kaynaklardan aldığım bilgileri metinde ve kaynakçada eksiksiz olarak gösterdiğimi, çalışma sürecinde bilimsel araştırma ve etik kurallara uygun olarak davrandığımı ve aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul ettiğimi beyan ederim. 19/03/2024

Büşra KAYA ÇİÇEK

İÇİNDEKİLER

	<u>Sayfa No</u>
ÖNSÖZ.....	III
TEZ ETİK BEYANNAMESİ.....	IV
İÇİNDEKİLER.....	V
ÖZET	VII
SUMMARY	VIII
ŞEKİLLER DİZİNİ.....	IX
TABLolar DİZİNİ.....	X
SEMBOLLER VE KISALTMALAR DİZİNİ	XI
1. GENEL BİLGİLER	1
1.1. Giriş.....	1
1.1.1. Tezin Özgünlüğü.....	3
1.1.2. Literatür Araştırması	3
1.2. Elektrik Enerjisi Tahmini	5
1.3. Elektrik Enerjisi Tahmin Yöntemleri.....	6
1.3.1. Benzer Gün Yöntemi	8
1.3.2. Regresyon Analizi Yöntemi.....	9
1.3.3. Zaman Serileri Analizi Yöntemi	10
1.3.4. Uzman Sistemler Yöntemi	10
1.3.5. Destek Vektör Yöntemi	10
1.3.6. Bulanık Mantık Yöntemi	11
1.3.7. Genetik Algoritma Yöntemi.....	11
1.3.8. Karar Ağacı Yöntemi	11
1.3.9. Yapay Sinir Ağları Yöntemi	12
1.3.10. Yapay Sinir Ağlarının Eğitilmesi.....	15
1.4. Ali Baba ve Kırk Haramiler Algoritması	15
1.5. Bukalemun Sürü Algoritması.....	18
1.6. Çalışmada Kullanılan Veriler.....	20
1.6.1. Nüfus.....	21
1.6.2. Gayrisafi Millî Yurtiçi Hasıla	21
1.6.3. Toplam Bina.....	22

1.6.4. İş Kayıtlarına Göre Girişim Sayıları	23
1.6.5. Aktif Abone Sayısı	24
1.6.6. Enerji Tüketimi	24
1.6.7. Kişi Başı Elektrik Tüketimi	25
2. YAPILAN ÇALIŞMALAR.....	26
2.1. Gümüşhane 2000-2022 Yılları İçin Uzun Dönem AFT-YSA Kullanılarak Yük Tahmini.....	28
2.2. Gümüşhane 2000-2022 Yılları İçin Uzun Dönem BSA-YSA Kullanılarak Yük Tahmini.....	34
2.3. Gümüşhane 2000-2022 Yılları İçin Uzun Dönem PSO-YSA Kullanılarak Yük Tahmini.....	37
2.4. Performans Analizi Karşılaştırması.....	39
3. SONUÇLAR.....	42
4. ÖNERİLER.....	44
5. KAYNAKLAR	45
6. EKLER.....	48
ÖZGEÇMİŞ	

Yüksek Lisans Tezi

ÖZET

YAPAY SİNİR AĞLARI KULLANILARAK ENERJİ TÜKETİM TAHMINİ: GÜMÜŞHANE ÖRNEĞİ

Büşra KAYA ÇİÇEK

Karadeniz Teknik Üniversitesi
Fen Bilimleri Enstitüsü
Elektrik-Elektronik Mühendisliği Anabilim Dalı
Danışman: Doç. Dr. Fatih Mehmet NUROĞLU
2024, 71 Sayfa

Enerji yük tahmininin önemi, enerji kaynaklarının etkin kullanımı, kesintilerin önlenmesi ve sürdürülebilir enerji politikalarının oluşturulmasında temel bir rol oynayarak vurgulanmaktadır. Ayrıca, enerji altyapısının kapasite planlamasında ve yeni yatırımların gerekliliğinin belirlenmesinde kritik bir faktördür. Bu bağlamda, farklı yöntemler arasında öne çıkan yapay zeka teknikleri, özellikle yapay sinir ağları ve bu ağların parametrelerinin belirlenmesinde kullanılan metasezgisel algoritmalar, son zamanlarda dikkat çekmektedir. Bu çalışma, Ali Baba ve Kırk Haramiler algoritması kullanılarak yapay sinir ağı parametrelerinin belirlendiği ve gerçek verilere dayalı olarak enerji yük taleplerini daha hassas ve güvenilir bir şekilde tahmin etmeyi odak noktasına almaktadır. Bu çalışmada, öncelikle seçilen bölgenin giriş verileri için belirli değişkenler ve çıkış verisi için enerji tüketim verileri analiz edilmiştir. Ardından, AFT kullanılarak yapay sinir ağının parametreleri belirlenmiştir. Belirlenen parametreler ile YSA çalıştırılarak MSE değeri incelenmiştir. Performans analizi yapmak için PSO ve BSA ile aynı işlemler yapılarak karşılaştırma yapılmıştır. Enerji talep tahmininde yapay zeka tabanlı teknolojilerin kullanımının önemini vurgulayarak, sektördeki geleceğe yönelik planlamalara katkıda bulunmayı amaçlamaktadır.

Anahtar Kelimeler: Ali Baba ve Kırk Haramiler Algoritması, Nöroevrim, YSA, Yük Tahmini

Master Thesis

SUMMARY

ENERGY CONSUMPTION ESTIMATION USING ARTIFICIAL NEURAL
NETWORKS: GUMUSHANE
Büşra KAYA ÇİÇEK

Karadeniz Technical University
The Graduate School of Natural and Applied Sciences
Electric Electronical Engineer Graduate Program
Supervisor: Doç. Dr. Fatih Mehmet NUROĞLU
2024, 71 Pages

The significance of energy load forecasting is highlighted by playing a fundamental role in the efficient utilization of energy resources, prevention of interruptions, and the formulation of sustainable energy policies. Additionally, it is a critical factor in capacity planning for energy infrastructure and determining the necessity for new investments. In this context, artificial intelligence techniques, particularly artificial neural networks, and metaheuristic algorithms used in determining the parameters of these networks have gained prominence in recent years. This study focuses on the determination of artificial neural network parameters using the Ali Baba and Forty Thieves algorithm, aiming to predict energy load demands more accurately and reliably based on real data. The analysis in this study involves initially scrutinizing specific variables for input data in the selected region and energy consumption data for the output. Subsequently, the parameters of the artificial neural network are determined using the Ali Baba and Forty Thieves algorithm. The identified parameters are then used to run the artificial neural network, and the Mean Squared Error (MSE) value is examined. To conduct a performance analysis, the same procedures are executed using PSO and BSA for comparison. Emphasizing the importance of utilizing artificial intelligence-based technologies in energy demand forecasting, this study aims to contribute to future planning in the sector.

Keywords: Ali Baba and the Forty Thieves, ANN, Load Forecasting

ŞEKİLLER DİZİNİ

	<u>Sayfa No</u>
Şekil 1. Tahminleme çalışma modeli.....	6
Şekil 2. Enerji tüketiminin talep-arz durumlarının incelenmesi	8
Şekil 3. Biyolojik sinir hücresi ve yapay sinir ağı (Maltarollo, 2013).....	12
Şekil 4. Yapay sinir hücresinin matematiksel modeli (Roffo, 2017; Kızrak, 2022).	14
Şekil 5. Gümüşhane ili 2000-2022 yılları nüfus grafiği	21
Şekil 6. Gümüşhane ili 2004-2022 yılları gayrisafi milli hasıla grafiği	22
Şekil 7. Gümüşhane ili 2002-2022 yılları toplam bina (metrekare) grafiği.....	23
Şekil 8. Gümüşhane ili 2009-2021 yılları girişim sayıları grafiği	23
Şekil 9. Gümüşhane ili 2000-2022 yılları aktif abone sayısı grafiği	24
Şekil 10. Gümüşhane ili 2000-2022 yılları enerji tüketimi (MWh) grafiği.....	25
Şekil 11. Gümüşhane ili 2000-2022 kişi başı elektrik tüketimi (kWh) grafiği.....	25
Şekil 12. YSA'nın optimizasyon algoritmasıyla evrilleştirme blok diyagramı	27
Şekil 13. İki gizli katmana sahip YSA yapı örneği.....	28
Şekil 14. AFT-YSA Gümüşhane 2000-2022 yılları arasında enerji tüketimi verilerine göre akış diyagramı	30
Şekil 15. İki katmanlı 1 nöron sayılı YSA'nın MATLAB blok diyagramı	32
Şekil 16. Üç katmanlı 10 nöron sayılı YSA'nın MATLAB blok diyagramı	33
Şekil 17. Popülasyon büyüklüğü 50 ve iterasyon sayısı 100 iken AFT-YSA modelinin veri grafikleri	34
Şekil 18. Popülasyon büyüklüğü 50 ve iterasyon sayısı 100 iken BSA-YSA modeli veri grafikleri	37
Şekil 19. Popülasyon büyüklüğü 50 ve iterasyon sayısı 100 iken PSO-YSA modeli veri grafikleri	39

TABLÖLER DİZİNİ

	<u>Sayfa No</u>
Tablo 1. Farklı nöron ve katman sayısına göre AFT-YSA'nın MSE sonuçları	31
Tablo 2. Farklı popülasyon büyüklüğü ve iterasyon sayısına göre AFT-YSA MSE sonuçları.....	33
Tablo 3. Farklı katman ve nöron sayılarına göre BSA-YSA modelinin MSE değeri	35
Tablo 4. Farklı iterasyon ve popülasyon sayısına göre BSA-YSA modelinin MSE değeri	36
Tablo 5. Farklı katman ve nöron sayılarına göre PSO-YSA modelinin MSE değeri.....	37
Tablo 6. Farklı iterasyon ve popülasyon sayısına göre PSO-YSA modelinin MSE değeri	38
Tablo 7. Popülasyon ve iterasyon sayısı 100 iken modellerin hata ölçütü analizi	40
Tablo 8. İterasyon 50 iken popülasyon büyüklüğüne göre hata analizi	41
Tablo 9. İterasyon 250 iken popülasyon büyüklüğüne göre hata analizi	41
Tablo 10. Popülasyon ve iterasyon sayısı 100 iken modellerin çalışma süresi	42
Tablo 11. İterasyon sayısı ve popülasyon büyüklüğüne göre çalışma süresi	42

SEMBOLLER VE KISALTMALAR DİZİNİ

$best_t^i$:	Hırsız i Tarafından Ulaşılan En İyi Konumu
$m_t^{a(i)}$:	Marjaneh'in Zekâ Seviyesi
$y_i^{gerçek}$:	Gerçek Sonuç
y_i^{tahmin} :	Tahmin Sonucu
ABC :	Yapay Arı Kolonisi
AFT:	Ali Baba ve Kırk Haramiler Algoritması
BSA:	Bukalemun Sürü Algoritması
CSA :	Guguk Kuşu Arama Algoritması
EPM :	Enerji Planlama Modeli
f :	Fonksiyon
FA :	Ateşböceği Algoritması
GSYH(₺) :	Gayrisafi Yurtiçi Hasıla Türk Lirası
kWh:	Kilo Watt Saat
m^2 :	Metrekare
MAPE:	Ortalama Mutlak Yüzde Hatasını (Mean Absolute Percentage Error)
MSE :	Ortalama Hata Karesi
MWh:	Mega Watt Saat
N :	Veri Sayısı
NR :	Newton Rapson
PSO:	Parçacık Sürü Optimizasyonu
R^2 :	Belirlilik Katsayısı
RMSE:	Ortalama Karesel Hatanın Kökü (Root Mean Square Error)
SSE:	Karesel Hataların Toplamı (Sum Of Squared Errors)
TÜİK :	Türkiye İstatistik Kurumu
w :	Ağırlık Parametresi
WOA :	Balina Optimizasyon Algoritması
X :	Bağımsız Değişken
Y :	Bağımlı Değişken
YSA:	Yapay Sinir Ağları

$\alpha :$	Katsayı
$\beta :$	Katsayı
$Pp_t :$	Hırsızların Ali Baba'ya Karşı Potansiyel Algı Yetenekleri
$Td_t :$	Hırsızların Takip Mesafesi
$gbest_t :$	Herhangi Bir Hırsız Tarafından Elde Edilen Küresel En İyi Konumu



1. GENEL BİLGİLER

1.1. Giriş

Günümüzde artan nüfus, endüstriyel gelişme ve teknolojik ilerlemeler, enerji ihtiyacını sürekli olarak artırmaktadır. Artan enerji ihtiyacının karşılanmasında ve çevresel sürdürülebilirliğin korunmasında enerji verimliliği çözümü benimsenmektedir. Enerji verimliliği için yapılan çalışmalarda elektrik şebekesinde arz-talep dengesi gözetilmektedir. Enerji yük talep tahmini, enerji endüstrisi ve ülkeler için kritik bir öneme sahiptir. Doğru bir şekilde tahmin edilmesi, enerji üreticilerinin kaynaklarını verimli bir şekilde yönetmelerine ve enerji dağıtımını etkili bir biçimde planlamalarına yardımcı olur. Aynı zamanda, enerji talebi tahmini, enerji altyapısının kapasite planlaması ve yeni yatırımların gerekliliği konusunda karar vermede temel bir rol oynar. Hatalı veya eksik tahminler, aşırı üretim veya tüketim durumlarına yol açabilir, bu da hem enerji kaynaklarının israfına hem de aşırı yüklenmiş ağlara bağlı olarak kesintilere neden olabilir. Bu bağlamda, doğru enerji yük talep tahminleri, sürdürülebilir enerji politikalarının oluşturulması ve enerji piyasalarının istikrarının korunması için kritik bir öneme sahiptir.

Gelecekteki enerji taleplerini tahmin etmek için çeşitli istatistiksel ve matematiksel yöntemler kullanılır. Bunlar arasında regresyon analizi, zaman serisi analizi, yapay sinir ağları ve benzeri veri madenciliği teknikleri bulunur. Ayrıca, mevsimsel etkiler, ekonomik aktiviteler ve hava durumu gibi faktörler de yük tahminlerini etkileyen unsurlardır. Geliştiren yöntemlerden elde edilen sonuçlara göre şebekenin yük akışları, hat kayıpları ve kritik çalışma sınırları belirlenmektedir (Çetinkaya, 2016). Doğru tahminler, enerji dağıtım ağının verimli bir şekilde planlanmasına ve operasyonel maliyetlerin optimize edilmesine yardımcı olur.

Yapay sinir ağları (YSA), yapay zekânın bir dalı olarak merkezi sinir sisteminden esinlenerek tasarlanmıştır. Bu sistem, hızlı karar alma ve paralel işlem yetenekleri ile canlı organizmalardaki sinir hücrelerinden ilham alır. Yapay sinir ağları, karmaşık veri setlerini analiz etmek, desenleri tanımak ve tahminlerde bulunmak gibi çeşitli görevlerde başarılı bir şekilde kullanılabilir. Bu nedenle, yapay sinir ağları, bilgisayar bilimleri, yapay zeka, robotik, ekonomi ve diğer birçok alanda ilgi çekici bir araştırma ve uygulama alanı sunmaktadır (Vafer vd., 2014). Yapay sinir ağları insan beyni örnek alınarak giriş-çıkış

birlikteliğini taklit ederek, öğrenme sürecinin matematiksel olarak modellenmesidir. Yapay sinir ağları, matematiksel olarak açık formüllerin bulunmadığı durumlarda bile giriş/ çıkış fonksiyonellikleri bilinen ilişkileri modelleme yeteneğine sahiptir; Ağın girdi / çıktı alanını uygun bir şekilde temsil edene kadar bilinen giriş / çıkış verileri üzerindeki ağları eğiterek elde edilir (Sitton vd., 2017).

Optimizasyon, mühendislik problemlerinde hesaplamının önemli bir parçasıdır. Akıllı şebekeler, lojistik, sensör ağları gibi çeşitli alanlarda bu yöntem uygulanmaktadır. Doğrusal optimizasyon teknikleri belirli problemleri çözerken, doğrusal olmayan optimizasyon problemleri daha zor olabilir ve bu tür problemler için sezgisel yöntemler kullanılabilir. Meta-sezgisel optimizasyon algoritmaları son yıllarda birçok problemde uygulanıp ve başarı göstermiştir. Bu algoritmalar, arama alanını etkili bir şekilde keşfederken çözüm üretir. Optimizasyon problemi için farklı birçok meta-sezgisel algoritma üretilmiştir. Bunlardan en yaygın kullanılanları Parçacık Sürü Optimizasyonu (PSO), Yapay Arı Kolonisi (ABC), Ateşböceği Algoritması (FA), Guguk Kuşu Arama Algoritması (CSA) ve Balina Optimizasyon Algoritması (WOA) gibi doğadan esinlenen meta-sezgisel algoritmalar bu alanda öne çıkmaktadır.

Ali Baba ve Kırk Haramiler algoritması adını taşıdığı hikâyeden yola çıkılarak her yinelemede aramanın önceki yinelemelerden o ana kadar bulunan en iyi çözüm üzerine inşa edilmesi yolundan esinlenerek tasarlanmış ve geliştirilmiştir (Braik, 2022). Ali Baba ve Kırk Haramiler Algoritması (AFT) yapay sinir ağı eğitimi ve diğer optimizasyon problemlerinde kullanılan bir metasezgisel algoritmadır. Bu yöntem, yapay sinir ağlarının hızlı öğrenmesine ve daha iyi genelleme yapmasına olanak tanır. Ayrıca, algoritma eğitim sürecini otomatikleştirir ve uzmanlık gerektiren manuel ayarlamalara olan ihtiyacı azaltır. Yapay sinir ağı eğitiminde metasezgisel algoritmalar, genellikle yapay sinir ağlarının hiperparametrelerini ayarlamak veya optimize etmek için kullanılır.

Bu çalışmada, yapay sinir ağlarında optimum ağırlık setinin bulunmasında algoritmanın performansı etkileyen bir faktör olduğu gösterilmektedir. Literatürde başarılı yöntemlerin bulunmasına rağmen, ağdaki ağırlıkların güncellenmesi süreci hâlâ geliştirilmeye açık bir araştırma alanıdır (Sağ, 2021). Bu tezde, yapay sinir ağlarının hiperparametrelerinin en uygun şekilde belirlenmesi için AFT algoritmasının kullanılması ve bu algoritmanın performansının araştırılmaktadır.

1.1.1. Tezin Özgünlüğü

Bu tez, enerji sektöründe kritik bir rol oynayan yük tahmininde Yapay Sinir Ağları (YSA) eğitimi için Ali Baba ve Kırk Haramiler Algoritması'nın kullanımını ve gerçek veri setleri üzerindeki etkilerini incelemektedir. Geleneksel yöntemlerin özellikle karmaşık ve dinamik enerji sistemleri üzerinde yetersiz kaldığı durumlarda, Ali Baba ve Kırk Haramiler Algoritması'nın, özellikle yük tahmininde, daha etkili sonuçlar sağlama potansiyeli bulunmaktadır. Bu algoritma, optimizasyon yetenekleri ve paralel işleme avantajlarıyla bilinir ve YSA eğitiminde kullanıldığında beklenen çıkışları hızlı ve doğru bir şekilde elde etme potansiyeline sahiptir. Tez, bu algoritmaya dayalı YSA eğitimini, gerçek enerji veri setleri üzerinde test ederek, özgün bir bakış açısı sunmaktadır. Bu, yük tahmininde daha güvenilir ve kesin sonuçlar elde etmek amacıyla yeni bir metodoloji ve yaklaşım sunma potansiyeli taşımaktadır.

1.1.2. Literatür Araştırması

Elektrik yük talebinin hesabı üzerine birçok yöntem mevcuttur. Bu talebin daha doğru sonuçlar vermesi, enerji kaynaklarının verimli kullanımı ve ağların güvenli işleyişi için önemlidir. Bunun için yük talebi üzerine farklı yöntemler üzerinden çalışmalar yapılmıştır. Aşağıda bu çalışmalara örnekler verilmiştir.

Red Electrica de Espana'daki Merkezi Bölge Kontrol Merkezi'nde kısa vadeli yük tahmini yapılmıştır. ARIMA yöntemi kullanılmıştır. Temelde zaman serisi analizi metodolojisine dayanan model, meteorolojinin etkisini bağımlı değişken olarak ele almaktadır. Günlük elektrik yükü tahmini, meteorolojinin saatlik elektrik yüküne olan etkisini açıklamak amacıyla kullanılmıştır (Juberias vd., 1999).

Türkiye'nin 1970-2015 yılları arasındaki elektrik enerjisi tüketim verileri üzerine odaklanılmıştır. Türkiye'nin ekonomik ve sosyal büyümesi ile birlikte artan enerji talebi, ülkenin enerji politikası için kritik bir faktör haline gelmiştir. Bunun için tahmin yöntemleri ve algoritmaları enerji talebi tahmininde yaygın olarak kullanılmaktadır. Elektrik enerjisi talebinin bölgesel, mevsimsel ve anlık dalgalanmalar gösterebilmesi, tahmine etkileyen faktörlerin doğru bir şekilde belirlenmesini ve değerlendirilmesini gerektirmektedir. Çalışmada, Türkiye'nin elektrik enerjisi tüketim tahminlerinin gerçekleşen tüketim değerleriyle karşılaştırılması amacıyla Yapay Sinir Ağları (YSA) ve Adaptif Ağ Tabanlı Bulanık Mantık Çıkarım Sistemi (ANFIS) yöntemleri kullanılmıştır. Bu iki yöntemin

performans analizi yapılarak, hangi yöntemin daha başarılı olduğu belirlenmeye çalışılmıştır (Ekinci, 2019).

Türkiye'nin piyasa ve mevsimsel koşullarını dikkate alarak kısa vadeli elektrik talep tahminlerinde yüksek doğruluk sağlayan bir hibrit sistem geliştirilmesine odaklanan çalışma EPSİM-NN, yapay sinir ağları ve uzman sistemlerin bir arada kullanılmasıyla günlük talep tahminlerini oluşturmaktadır. EPSİM-NN sistemi, günlük ortalama saatlik talep miktarını ve 24 saatlik talep şeklini belirlemek için iki farklı yapay sinir ağı kullanmaktadır. Bu ağların elde ettiği sonuçlar birleştirilerek günlük talep tahmini oluşturulmaktadır. Oluşturulan tahminler, yakın zaman talep trendlerini kullanarak bir uzman sistemden geçirilerek hatalar minimize edilmektedir (Başoğlu & Bulut, 2017).

Elektrik tüketimi, birçok faktörün etkisiyle saatlik olarak değişmektedir. Bu faktörler arasında sıcaklık, çalışma saatleri, tatiller ve günlük maksimum tüketim değerleri yer almaktadır. Çalışmada, 2019 ve 2020'nin Temmuz, Ekim, Ocak ve Nisan ayları incelenerek hafta içi ve hafta sonu tüketimleri analiz edilmiş ve benzerlikler gözlemlenmiştir. Orta dönem yük analizinde yük verisi sınıflandırma yapılarak veri setinin daha doğru analizi yapılmaya çalışılmıştır (Dincer & Nuroğlu, 2021).

Literatürde yapay sinir ağları ile birçok çalışma mevcuttur. Yapay sinir ağları, özellikle makine öğrenmesi alanında metasezgisel algoritmalar kullanılarak eğitilmektedir. Bu yaklaşım, nöroevrim bilim dalının gelişimine önemli katkılar sağlamaktadır. Bu çalışmalardan birçoğuna aşağıda yer verilmiştir.

Çalışmada farklı durumlarda kazıkların yanal sapmasını incelenmiştir. Ayrıca, kazıkların yanal sapmasını tahmin etmek için Elman Sinir Ağı - Geliştirilmiş Aritmetik Optimize Edici algoritmasının bir modeli önerilmiştir. Bu önerilen modelin geçerliliğini değerlendirmek MSE gibi bazı parametreler tahmin edilmiştir. Sonuçlar, küçük ölçekli kazıklar için Elman Sinir Ağı - Geliştirilmiş Aritmetik Optimize Edici yönteminin, diğer yöntemlere kıyasla yanal sapma tahmini için daha güvenilir olduğunu göstermiştir (Zhang vd.,2024).

Bir diğer çalışmada, binalardaki enerji tüketiminin doğru değerlendirilmesi, enerji verimliliğini artırmak ve enerji yönetiminde rehberlik sağlamak amacıyla yapılan araştırmalar ele alınmıştır. İlk olarak, soğutma ve ısıtma yüklerini tahmin etmek için üç yapay sinir ağı çerçevesi ve bir regresyon modeli dahil olmak üzere dört farklı model genişletilmiştir. Ardından, en uygun model seçilerek hiperparametreleri dört optimizasyon tekniği kullanılarak ayarlanmış ve en iyi hibrit model elde edilmiştir. Ayrıca, çoklu amaçlı


optimizasyon sürecinde parçacık sürü optimizasyonu ve biyocoğrafya temelli optimizasyon optimizasyonları kullanılarak optimum koşullar tanımlanmıştır (Afzal, 2024).

Tezin literatüre katkısı bakımından Ali Baba ve Kırk Haramiler ile yapılmış çok az sayıda çalışma bulunmasıdır. Bu çalışmalardan biri aşağıda anlatılmaktadır.

Bir PV sisteminin modellenmesi, Güneş PV sisteminin parametre tahmini için çeşitli optimizasyon teknikleri uygulanmış olmasına rağmen, en iyi optimize edilmiş sonuçlara ulaşmak için hâlâ çalışmalar yapılmaktadır. PV sisteminin parametrelerini tahmin etmek için bir meta-sezgisel optimizasyon algoritması Ali Baba ve Kırk Haramiler (AFT) ve klasik bir teknik olan Newton Rapson (NR) yöntemi kullanılarak hibrit bir yöntem elde edilmiştir (Sharma vd., 2022).

1.2. Elektrik Enerjisi Tahmini

Çevresel sorunlara getirilen çözümlerden enerji verimliliği ve elektrik piyasalarının liberalleşmesi, elektrik yük tahminlerine olan ilgiyi arttırmıştır. Enerji yük tahmininin en doğru oranda yapılması, enerji tedarikçilerinin kayıplarını azaltmaya yardımcı olmaktadır. Elektrik tüketim tahmini, kısa, orta ve uzun vadeli olmak üzere farklı zaman aralıklarında göre ayrılır. Kısa vadeli tahmin genellikle bir saatten bir haftaya kadar olan dönemler için, orta vadeli tahmin bir aydan bir yıla kadar olan dönemler içindir. Uzun vadeli tahmin ise beş yıldan yirmi yıla veya daha uzun süreler için yapılan tahminleri içerir. Bu tahminler, elektrik üretim ve iletimini planlamak ve güç dağıtım sistemlerini gelişimindeki yatırımlar amaçları gibi çeşitli amaçlar için yapılmakta ve kullanılmaktadır. Şekil 1’de tahminleme çalışma modeli gösterilmiştir.



1.3. Elektrik Enerjisi Tahmin Yöntemleri

Elektrik güç tedarik kurumlarının temel amacı, doğru elektrik talep tahminleriyle güvenilir enerji tedariki sağlamak ve işletme maliyetlerini azaltarak sistem verimliliğini artırmaktır. Talep tahmini “belirli bir zaman periyodunda belirli sayıdaki tüketicinin elektrik kurumundan bekleyebileceği elektrik talebidir” şeklinde açıklanabilir (Saleh & Syed, 1996). Talep tahmini bazı planlamalar için önemlidir. Bunlar:

- Elektrik Üretiminin Artışı İçin Planlama
- Elektrik İletim Ağının Genişlemesi İçin Planlama
- Mali Yatırımlar ve Fiyatlandırma İçin Planlama

Elektrik tahmini, anlaşılır bilgilerle talep durumu ve kaynak kapasitesini belirleyerek altyapı planlamasında ve yatırım kararlarında rehberlik eden, ülkenin gelişim eğilimlerini analiz etmeye yardımcı olan bir süreçtir (Kasule, 2018).

Tahminde amaç gerçeğe en yakın tahmini yapmaktır. Tahmin yöntemlerinde genel olarak gerçek ve tahmin edilen değer arasında hatanın minimum olması amaçlanmaktadır. Bundan dolayı yöntemlerde amaç fonksiyonu için hata fonksiyonu kullanılır. Hata fonksiyonları:

- Karesel Hataların Toplamı (Sum Of Squared Errors (SSE))
- Ortalama Karesel Hatanın Kökü (Root Mean Square Error (RMSE))
- Ortalama Mutlak Yüzde Hatasını (Mean Absolute Percentage Error (MAPE))
- Ortalama Karesel Hata (Mean Square Error (MSE))
- Belirlilik Katsayısı (R^2)


Bu çalışmada ortalama karesel hata eğitim algoritması için kullanılacaktır. Ortalama karesel hata modeldeki değer ile gerçek değer(hedef değer) arasındaki hatanın karesel fark anlamına gelir. Bu hata ölçütü anomali değerlere karşı duyarlıdır. MSE formülü Eşitlik 1. de gösterilmiştir. Burada y_i^{gercek} , gözlemlenen tüketim; y_i^{tahmin} ise tahmin sonucu beklenen tüketimdir.

$$\min f = \frac{1}{N} \sum_{i=1}^N (y_i^{gercek} - y_i^{tahmin})^2 \quad (1)$$

RMSE ise MSE fonksiyonun kareköküdür. MSE’de olduğu gibi aykırı değerlere duyarlıdır.

R-kare veri setinde yer almayan örneklerin model tarafından ne kadar iyi tahmin edileceğinin bir ölçütüdür. R^2 , verilerin yerleştirilmiş regresyon hattına ne kadar yakın olduğunun istatistiksel bir ifadesidir. 0 ile 1 arasında bir değer aralığını sahiptir. 0 durumu modelin hiçbir şey açıklamadığını ve uyumun olmadığını ifade eder. 1 durumunda ise modelin verileri gerçeğe en yakın şekilde açıkladığını gösterir. Ancak, bu durumda da aşırı uyum riski bulunabilmektedir. Bunun için modellemenin MSE, RMSE gibi diğer hata ölçütleri de incelenmelidir.

Elektrik tahminlerinde yapıldığı döneme göre etki eden farklı değişkenler vardır. Bu değişkenler sıcaklık, abone sayısı, nüfus, milli hasıla, meteorolojik veriler, hane halkının büyüklüğü gibi etki faktörleri vardır (Shuvra vd., 2011). Uzun dönemde sıcaklığın bağımsız değişken olmasına rağmen nüfus bağımlı değişkendir. Şekil 2’de enerji tüketiminin talep-arz durumlarının incelenme adımları gösterilmiştir.



Şekil 2. Enerji tüketiminin talep-arz durumlarının incelenmesi

Elektrik talep tahmini, enerji piyasasının dengesi için önemli bir çalışmadır. Bundan dolayıdır ki tahmin için birçok farklı yöntem ve teknik geliştirilmiştir. 483 adet enerji planlama modelinde (EPM) kullanılan tahmin yöntemlerinin sistematik ve eleştirel bir incelemesini sunmaktadır (Debnath & Mourshed, 2018). [16]. Yapılan çalışmada en çok kullanılan yöntemin YSA olduğu belirlendi. Verilerin kullanımı ve boyutu göze alındığında bu çalışmada YSA kullanımı yöntem olarak seçilmiştir.

1.3.1. Benzer Gün Yöntemi

Benzer gün yöntemi kısa dönem yani günlük tahmin için kullanılan bir yöntemdir. Meteorolojik faktörlerin değerlerinin benzer olduğu günler için bu tahmin yöntemi kullanılır. Benzer gün yaklaşımı; ortalama sıcaklık, nem oranı, güneşlenme süresi ve rüzgâr hızı gibi özellikleri birbirine benzeyen günlerin enerji tüketiminin tahmini için kullanılan

yöntemdir. Tahmin çalışmalarında, veri setleri korelasyon sayıları 1'e yakın olan parametreler arasından oluşturulur (Zhou vd., 2020).

1.3.2. Regresyon Analizi Yöntemi

Regresyon analizi, bir bağımlı değişkenin yani sonuç değişkenin bir veya daha fazla bağımsız değişkenle ilişkisini inceleyen istatistiksel analiz yöntemidir. Regresyon analizi, veriler arasındaki ilişkileri modellemeye çalışır. Bu modeller kullanarak bağımlı değişkenin tahminlerini yapılmaktadır. Regresyon analizinin dört farklı modeli vardır (Sezer, 2019). [18]. Bunlar:

Basit Doğrusal Regresyon: Basit doğrusal regresyon, yalnızca bir bağımsız değişkenin bağımlı değişken üzerindeki etkisini incelediği bir regresyon türüdür. Basit doğrusal regresyon analizinde; bir bilinmeyen Y , bilinen X üzerinden, parametreler ve rastgele gürültü cinsinden açıklanmaktadır. Doğrusal regresyon tahmin formülü Eşitlik 2.deki gibi ifade edilir:

$$Y = \alpha + \beta X + \varepsilon \quad (2)$$

Eşitlik 2.de Y bağımlı değişken, X bağımsız değişken, α ve β regresyon analizi ile tahmin edilen kat sayıları ve ε yapılan hata terimine karşılık gelmektedir.

Basit Doğrusal Olmayan Regresyon: Bu türde, bağımlı değişken ile bir veya daha fazla bağımsız değişken arasındaki ilişki, doğrusal bir ilişki yerine başka bir fonksiyonla ifade edilir.

Çoklu Doğrusal Regresyon: Çoklu doğrusal regresyon, birden fazla bağımsız değişkenin aynı bağımlı değişken üzerindeki etkisini inceleyen bir regresyon türüdür. Bu yöntem, bir sonucu etkileyebilecek birden fazla faktörün aynı anda dikkate alınmasını sağlar. Eşitlik 3.de çoklu doğrusal regresyonun formülü verilmiştir. Eşitlik 3.de Y bağımlı değişken, X bağımsız değişken, α_0 ve β_n regresyon analizi ile tahmin edilen kat sayıları ve ε yapılan hata terimine karşılık gelmektedir.

$$y = \alpha_0 + x_1\beta_1 + x_2\beta_2 + x_3\beta_3 + \dots + x_n\beta_n + \varepsilon \quad (3)$$

Çoklu Doğrusal Olmayan Regresyon: Bu tür, çoklu bağımsız değişkenlerin ve bağımlı değişken arasındaki karmaşık olmayan doğrusal olmayan ilişkileri modellemek için kullanılır.

Regresyon analizi, veri analizi ve tahmin yapma süreçlerinde oldukça yaygın bir araçtır. Bu yöntem ilişkileri anlamak, değişkenlerin etkilerini ölçmek ve gelecekteki olayları tahmin etmek için bilgiler sağlamaktadır.

1.3.3. Zaman Serileri Analizi Yöntemi

Zaman serisi, belli bir zaman aralığında gözlemlenen verilerin bir dizisidir. Bu zaman aralığı saniyelerden yıllara kadar değişebilir. Zaman serisi analizi, verinin değişim eğilimini anlamak, mevsimsel desenleri tanımlamak, rastgele olayları incelemek ve gelecekteki değerleri tahmin etmek gibi amaçlar için kullanılmaktadır. Zaman serisi analizi tahmin modelinde geçmiş verilere dayanarak gelecekteki değerleri tahmin etmektedir. Bu tahminler, enerji planlama ve yönetiminde, finansal planlama, stok yönetimi gibi daha birçok uygulama için önemlidir. Zaman serisi analizi için temel modeller arasında Box-Jenkins modeli, AR (OtoRegressif) model, MA (Hareketli Ortalama) model, ARMA (OtoRegressif Hareketli Ortalama) model ve ARIMA (Entegre OtoRegressif Hareketli Ortalama) modeli bulunur. Farklı zaman serisi analizi modelleri ve yöntemleri, farklı veri türleri ve analiz amaçları için kullanılmaktadır.

1.3.4. Uzman Sistemler Yöntemi

Uzman sistemler, uzman bilgisiyle beslenen veri tabanlarına dayalı tahminler yaparak tavsiye ve karar desteği sunar. Bilgisayar tabanlı bu sistemler, insanın karmaşık problemleri çözme yeteneğini taklit eder. Yeni bilgiler eklenerek sürekli güncellenebilirler ve hızlı, doğru sonuçlar sağlarlar.

1.3.5. Destek Vektör Yöntemi

Destek vektör makineleri, tabanını istatistik ve matematikten alan destek vektör yöntemi, özellikle sınıflandırma ve regresyon analizinde kullanılan bir makine öğrenme tekniğidir. Az miktarda veriyle bile karmaşık olmayan sorunları çözebilme yeteneğine sahiptir. Bu yöntem, genellikle yüksek boyutlu destek vektörlerinin alt kümeleri üzerinde

çalışarak genişletilmiş tahmin fonksiyonları oluşturur. Elektrik yük tahmininde sıklıkla tercih edilen bir yöntemdir.

1.3.6. Bulanık Mantık Yöntemi

Bulanık mantık, klasik mantık kurallarının aksine, belirsizlikleri kabul eden bir yaklaşımdır. Kesin sınırlar yerine belirsizlik seviyeleri kullanarak, gerçek dünyadaki karmaşık kavramları daha esnek bir şekilde ele almayı hedefler. Bu yöntem, üyelik fonksiyonları ve bulanık kümeler aracılığıyla belirsizliği ifade eder. Bulanık mantık, özellikle yapay zeka ve kontrol sistemlerinde kullanılarak, belirsizlik içeren problemlere daha etkili çözümler sunar. Elektrik yük tahmininde verilerde eksiklik olduğunda uzman görüşü sonucu elde edilen bilgiler ile veriler tamamlanabilir ve yük tahmini yapılmaktadır.

1.3.7. Genetik Algoritma Yöntemi

Genetik algoritma, canlıların genetik evrim sürecini taklit eder. Her kromozom, çözümü temsil eder. Bu algoritma, üstün çözümleri seçim ve çoğaltma yoluyla korur, zayıf çözümleri eler ve tekrarlamalar sonucunda en uygun çözüme ulaşır. Genetik algoritma, teorik olarak çözüm sunan bir optimizasyon algoritması olarak kabul edilir. Bu yöntem, kararlılık analizi, yük akışı analizleri, ekonomik dağıtım, arıza bulma, güç sistem kontrolü ve yük tahmini gibi birçok alanda başarıyla uygulanmaktadır. Genetik algoritma, karmaşık problemleri çözmek ve optimal çözümler bulmak için kullanılmaktadır.


1.3.8. Karar Ağacı Yöntemi

Kategorik verilerin sınıflandırılması için kullanılan karar ağaçları, denetimli veri madenciliği prensiplerine dayalı tahmin modellerini görsel olarak temsil eder. Ağaç benzeri yapıda, kriter seviyelerine göre nesneleri sınıflandırarak kararlar alır. Her bölünme, ağacın bir dalını oluşturur; bölünme sonunda ise uç düğümler elde edilir. Yeni nesneler, belirlenmiş kurallar kullanılarak kendi karar sınıflarına dahil edilir. Bu yöntem, özellikle yük tahmin çalışmalarında başarıyla kullanılmaktadır (Hu vd., 2020).

1.3.9. Yapay Sinir Ağları Yöntemi

Yapay Sinir Ağları (YSA), geniş veri setlerini modelleme amacıyla kullanılan bir araçtır. Temelinde verilerin girişini, işlenişini ve öğrenme sürecini kavramsal olarak açıklayan bir temsil sunmaktadır. YSA sisteminin geliştirilmesinde insan beyninin öğrenme ve yeni bilgiler üretme yeteneğinden esinlenilmiştir.

Şekil 3'te gösterilen biyolojik sinir hücresinin temel yapısı, dendritler, hücre gövdesi, akson ve sinapslar gibi bileşenleri içermektedir. Yapay nöron, biyolojik nöronlardan ilham alarak tasarlanan bir işlem birimidir. Yapay Sinir Ağları (YSA), bilgi işleme odaklı bir işlevi yerine getirdiği için genellikle veri işleme alanlarında kullanılmaktadır. YSA'lar, gerçek sinir ağlarını modellemek amacıyla çeşitli türlerde tasarlanmıştır. Mühendislikte örüntü tanıma, tahminleme ve veri sıkıştırma gibi alanlarda kullanılmaktadır.



Şekil 3. Biyolojik sinir hücresi ve yapay sinir ağı (Maltarollo, 2013).

Yapay sinir ağlarında nöronlar aralarında bağ kurarak sinir ağları oluşturmaktadır. Nöronlar, bağlantı hatları üzerinden birbirlerine sinyal göndererek iletişim kurarlar. Her bir bağlantı hattının özel bir ağırlık değeri vardır. Bilginin en doğru biçimde iletilmesi, bu ağırlıkların aldıkları değerler sayesinde gerçekleşir. Bu bağlantı ağırlıkları genellikle bir

öğrenme işlemi ile belirlenir (Elmas, 2003). Yapay nöronlar giriş sinyallerini toplarlar, işlerler ve çıktı verirler.


$$net = \sum_1^j w_{ij}x_j + w_{bias} \quad (4)$$

$$y = f(net) \quad (5)$$

Bir yapay sinir hücresi girdiler (x), çıktılar (y), ağırlıklar (w), aktivasyon fonksiyonu ve birleştirme (transfer) fonksiyonundan oluşur. Eşitlik 4 ve Eşitlik 5'te yapay sinir ağlarının fonksiyon matematiksel ifadesi verilmiştir. Girdiler, bir yapay sinir hücresine dışarıdan ve diğer hücrelerden gelen bilgilerdir. Bu veriler, nöron çekirdeğine iletmek üzere toplanır ve işlenir. Ağırlıklar, bilginin hücre üzerindeki etkisini belirten önemli faktörlerdir. Bias yapay sinir ağı sisteminin girdilerinden bağımsızdır. Bias giriş değeri sabit 1(bir) alınan bir nöronun ağırlık değeridir. Eğitim sürecinde ağırlık değerlerini dengelemek amacıyla gizli ve çıkış katmanlarına uygulanır (Sağ & Celil, 2021). Sinir hücresine ulaşan bilgiler, bağlantı ağırlıkları tarafından çarpılarak çekirdeğe aktarılır. Bu ağırlıkların değerleri pozitif, negatif veya sıfır olabilir. Birleştirme fonksiyonu, ağırlıklarla çarpılan girdileri toplayarak hücrenin net girdisini hesaplamaktadır. Aktivasyon fonksiyonu, net girdiyi işleyerek hücre çıktısını belirler. Genellikle nöron çıkışını belirli bir aralıkta $[0,1]$ veya $[-1,1]$ sınırlayan aktivasyon fonksiyonları kullanılır. Bunlar doğrusal, logaritmik sigmoid ve birim basamak fonksiyonları aktivasyon fonksiyonu olarak sıkça kullanılmaktadır. Bu çalışmada sigmoid fonksiyonu nöronların transfer fonksiyonu olarak kullanılmıştır. Sigmoid fonksiyonu Eşitlik 6'da verilmiştir.

$$y = f(net) = \frac{1}{1+e^{-net}} \quad (6)$$

Yapılarına göre yapay sinir ağları, ileri beslemeli ve geri beslemeli sinir ağları olarak sınıflandırılmaktadır. Geri beslemeli sinir ağlarında veri akışı geriye ve ileriye doğru yapılmaktadır. Ağ çıktısı aynı zamanda girdi olarak kullanılabilir. Geri beslemeli ağ dinamiktir ve hafızaları vardır (Benšková, 1994). İleri beslemeli sinir ağlarında ise sinyal iletimi, giriş katmanından çıkış katmanına doğru tek yönlü şekilde bağlantılar kurularak gerçekleştirilmektedir. Şekil 4'te yapay sinir hücresinin matematiksel modeli gösterilmektedir.



Şekil 4. Yapay sinir hücresinin matematiksel modeli (Roffo, 2017; Kızrak, 2022).

Yapay sinir ağları, girdilere dayalı çıktı üretebilmek için öğrenme sürecinden geçer. Bu öğrenme süreci, çeşitli yöntemlerle gerçekleştirilir. Yapay sinir ağları öğrenme yöntemleri, danışmanlı, danışmansız ve destekleyici olmak üzere üç kategoriye ayrılır. Denetimli öğrenme (danışmanlı öğrenme), ağın eğitim verileri üzerinden öğrenmesini sağlar. Her eğitim örneğinin girişi ile birlikte beklenen çıkış etiketi verilir. Ağ, bu etiketleri tahmin etmeye çalışarak hata oranını azaltmaya çalışmaktadır. Ağa doğru çıkışı öğretmek için bir "danışman" kullanılır. Denetimsiz öğrenme (danışmansız öğrenme), ağın etiketlenmemiş veriler üzerinden öğrenmesine odaklanır. Ağ, veri setindeki desenleri algılamaya ve kendi içerisinde yapısını oluşturmaya çalışır. Bu yöntemde bir dış danışman olmaksızın, ağ veri setindeki doğal yapıları kendi başına öğrenir. Destekleyici öğrenme, ağ bir ortamda belirli bir görevi gerçekleştirme çabasıdır. Ağ, doğru davranışları öğrenmeye çalışır ve çevresel geribildirimle güçlendirilir. Bu öğrenme türleri, yapay sinir ağlarının çeşitli uygulama alanlarına ve problemlere uyarlanmasını sağlamaktadır.

1.3.10. Yapay Sinir Ağlarının Eğitilmesi

Yapay sinir ağlarının öğrenme yeteneği, tahmin problemi için en avantajlı özelliği olabilmektedir. Tahminde kullanılan YSA yönteminde, YSA'dan beklenen girilen verilere karşılık çıkışta üretilen verinin gerçeğe en yakın olması istenmektedir. YSA tarafından üretilen çıktı değerlerinin gerçek çıktı değerlerine yaklaşması, YSA yapısında bulunan nöronlar arası ağırlık değerlerinin optimum seviyeye ulaşması ile gerçekleşecektir. Problemin en iyi çözümü, ağ bağlantılarının doğru ağırlık değerlerine sahip olmaları ile bulunacaktır (Yılmaz, 2023). Öğrenme süreci, hata minimumda tutularak doğru değerlere ulaşmak üzere ağırlıklar sürekli güncellenmektedir. YSA'nın bu kısmında, optimal ağırlık değerlerine ulaşmak için belirli bir eğitim algoritması kullanılır. Ağırlık değerleri bu algoritmanın yönergelerine göre düzenlenir. Hedefe ulaşıldığında mevcut ağırlık değerleri kaydedilir ve öğrenme tamamlanmış olur. Eğitim aşamasından sonra test kısmı gelmektedir. Bu kısımda sinir ağı ilk kez karşılaştığı giriş değerleriyle test edilmektedir. YSA, bu yeni verilere beklenen doğru çıktıları verirse, başarılı bir öğrenme gerçekleşmiştir.

Bu eğitimde geri yayılım, kademeli korelasyon, parçacık sürü optimizasyonu, genetik algoritmalar ve yapay arı kolonisi yaygın olarak kullanılan algoritmalar. Bu çalışmada özgünlük amaçlı yapay sinir ağının eğitiminde Ali Baba ve Kırk Haramiler Algoritması kullanılmıştır.

1.4. Ali Baba ve Kırk Haramiler Algoritması

Bu algoritma Ali Baba ve kırk haramiler masalından esinlenerek, insanların eylemlerinin koordineli bir modeli olarak taklit eden bir optimizasyon yöntemi sunmaktır. Bu hikayeden çıkarılacak ilkeler, bu algoritmanın temel varsayımlarını yerine getirmektedir (Braik vd., 2022). Bu ilkeler:

- Kırk haramiler bir grup halinde iş birliği yapar ve Ali Baba'nın evini bulmak için birinden veya hırsızlardan birinden rehberlik alırlar. Bu bilgi doğru olabilir veya olmayabilir.
- Kırk haramiler, Ali Baba'nın evini bulana kadar başlangıç mesafesinden başlayarak bir mesafe kat edecekler.
- Marjaneh (Ali Baba'nın hizmetçisi), Ali Baba'yı onların gelmesinden bir şekilde korumak için haramileri defalarca kandırabilir.

Haramiler (hırsızlar) ve Marjaneh'in davranışları, optimize edilecek bir amaç fonksiyonuna bağlanabilecek şekilde düzenlenir. Bu düzenleme sonucu aşağıda denklemleri verilene meta-sezgisel algoritmanın geliştirilmiştir.

AFT algoritması, d boyutlu bir arama uzayındaki n sayıda bireyin konumunun rastgele başlatılmasıyla başlatılır. Denklemden x tüm hırsızların konumudur, d belirli bir problemin değişken sayısıdır ve x_j^i j 'inci boyutta i 'inci hırsızın konumunu göstermektedir. Eşitlik 7'de bu matris gösterilmiştir.

$$x = \begin{pmatrix} x_1^1 & \cdots & x_d^1 \\ \vdots & \ddots & \vdots \\ x_1^n & \cdots & x_d^n \end{pmatrix} \quad (7)$$

Hırsızların konumu için; x_i . soruna aday çözümü gösteren hırsızın konumu gösterir ve l_j ve u_j denklemin alt ve üst sınırını belirtir. J boyutlu ve r rastgele $[0-1]$ arası dağıtılan bir sayıdır. Marjaneh ise tüm hırsızlara göre farklı bir plan gerçekleştireceğinden hepsinde farklı zeka seviyesi başlatılır. Marjaneh'in başlangıç zeka seviyeleri Eşitlik 8 ve Eşitlik 9'da m_j^i j 'inci boyutta i 'inci hırsıza karşı gösterdiği zeka seviyesi gösterilmiştir.

$$x_i = l_j + r. (u_j - l_j) \quad (8)$$

$$m = \begin{pmatrix} m_1^1 & \cdots & m_d^1 \\ \vdots & \ddots & \vdots \\ m_1^n & \cdots & m_d^n \end{pmatrix} \quad (9)$$

Karar değişkenlerinin değerleri, her hırsızın konumu için değerlendirilen kullanıcı tanımlı bir uygunluk fonksiyonuna eklenmektedir ve karşılık gelen uygunluk değerleri Eşitlik 10'da verildiği gibi bir dizide saklanır. AFT algoritması simülasyonunda, her hırsızın yeni konumu, belirlenmiş bir uygunluk fonksiyonu ile değerlendirilir. Eğer yeni konumun çözüm kalitesi, mevcut konumun kalitesinden daha iyiye, hırsızın konumu güncellenir. Her hırsız, kendi çözüm kalitesinin daha verimli olduğunu düşünüyorsa, mevcut konumunda kalmaya devam eder.

$$f = \begin{pmatrix} f_1 [& x_1^1 & \cdots & x_d^1] \\ \vdots & \vdots & \ddots & \vdots \\ f_n [& x_1^n & \cdots & x_d^n] \end{pmatrix} \quad (10)$$

Hırsızlar Ali Baba'yı takip ederken üç durum meydana gelmektedir. Bu durumların hepsinde hırsızlar en verimli şekilde Ali Babayı aramaları varsayılırken hizmetçi, hırsızları rastgele konumlarda arama yapmaya zorlar.

İlk durum olarak hırsızların Ali Baba'yı takipteyken, aldıkları bilgilere dayanarak konumları aşağıdaki gibi formüle edilmektedir.

$$x_{t+1}^i = gbest_t + \left[Td_t(best_t^i - y_t^i)r_1 + Td_t(y_t^i - m_t^{a(i)})r_2 \right] sgn(rand - 0.5) \\ r_3 \geq 0.5, r_4 > Pp_t \quad (11)$$

Eşitlik 11'de x_{t+1}^i , i. hırsızın konumunu temsil eder, y_t^i hırsız i için Ali Baba'nın konumunu, $best_t^i$ hırsız i tarafından ulaşılan en iyi konumu, $gbest_t$ şu ana kadar herhangi bir hırsız tarafından elde edilen küresel en iyi konumu, $m_t^{a(i)}$ hırsız i'yi gizlemek için kullanılan Marjaneh'in zekâ seviyesini, Td_t hırsızların takip mesafesini, Pp_t hırsızların Ali Baba'ya karşı potansiyel algı yeteneklerini ifade etmektedir (Braik, 2023). Burada r_1 , r_2 , $rand$, r_3 ve r_4 rastgele [0-1] aralığında seçilmiş değerlerdir.

Marjaneh, hırsızların elde ettiği yeni çözümün kalitesi, önceki çözümlerinden daha iyi ise, eşitlik 12'de kullanarak planlarını günceller. Burada f uygunluk fonksiyonunu gösterir.

$$m_t^{a(i)} = \begin{cases} x_t^i, & \text{eğer } f(m_t^{a(i)}) \leq f(x_t^i) \\ m_t^{a(i)}, & \text{eğer } f(m_t^{a(i)}) > f(x_t^i) \end{cases} \quad (12)$$

Eşitlik 13 ve Eşitlik 14'te t ve T sırasıyla mevcut ve maksimum iterasyon değerlerini ifade eder, α_0 takip mesafesinin başlangıç tahminini, α_1 ise sömürü ve keşif kontrolünü sağlamak için kullanılan sabit bir değerdir. β_0 hırsızların arama sürecinin kenarında hedeflerine ulaşma olasılığının son yaklaşımını, β_1 ise keşif ve sömürüyü kontrol etmek için kullanılan sabit bir değeri göstermektedir.

$$Td_t = \alpha_0 e^{-\alpha_1 \left(\frac{t}{T}\right)_1^\alpha} \quad (13)$$

$$Pp_t = P\beta_0 \log(\beta_1 \left(\frac{t}{T}\right)^{\beta_0}) \quad (14)$$

Burada a , $[n, 1].[0, 1]$ aralığında oluşturulan rastgele sayıların bir vektörünü temsil eder. Eşitlik 15’de gösterilmiştir.

$$a = [(rand)_1, (rand)_2, \dots, (rand)_j] = [(n - 1).rand(n, 1)] \quad (15)$$

İkinci durumda hırsızlar aldatıldıklarını fark edebilir, bu nedenle Ali Baba’yı bulmak için arama alanında rastgele keşiflerde bulunabilirler. Bu durumda, hırsızların yeni konumları Eşitlik 16’da gösterilir. Bu denkleme Td_t dahildir. Çünkü hırsızlar, Ali Baba’nın evinin olabilecek en elverişli alanları ayırt etme konusunda iyi bir düzeyde bilgiye sahiptir.

$$x_{t+1}^i = Td_t[(u_j - l_j)rand + l_j] \quad (16)$$

Üçüncü durumda ise AFT algoritmasının keşif ve araştırma özelliklerini iyileştirmek amacıyla, bu çalışma eşitlik A’dan yararlanılarak elde edilebilecek konumlar dışında diğer konumları da incelenmektedir. Bu durumda, hırsızların yeni konumları aşağıda Eşitlik 17’de ifade edilebilir.

$$x_{t+1}^i = gbest_t + \left[Td_t(best_t^i - y_t^i)r_1 + Td_t(y_t^i - m_t^{a(i)})r_2 \right] sgn(rand - 0.5) \quad (17)$$

$$r_3 < 0.5$$

1.5. Bukalemun Sürü Algoritması

Bukalemun Sürü Algoritması (BSA), mevcut meta-sezgisel yöntemlerden farklı olarak, keşif ve kullanım dengesini sağlamak için bukalemun avlanma stratejilerinden ilham alarak geliştirilmiş bir algoritmadır. Bukalemunların yiyecek arayışı, avlarını izleme, arama ve avlanma süreçlerini içeren matematiksel modellerle algoritma oluşturulmuştur. Bukalemunların arama performansını artırmak için keşif ve kullanım dengesini sağlamak

amacıyla, BSA yinelemeleri sırasında uyarlanabilir bir parametre önerilmiştir ve daha güvenilir bir performans elde edilebilmektedir. BSA'nın adaptif parametreleri, geniş bir uygulama alanına sahip olmasını ve çeşitli problemlere uyum sağlamasını sağlamaktadır.

BSA bir popülasyon tabanlı algoritmadır. Başlangıçta n adet bukalemundan oluşan bir popülasyon, her bir bukalemunun bir problem için aday bir çözümü temsil ettiği d boyutlu bir arama uzayında i . bukalemunun konumunu bulmaktadır. Her bukalemunun iterasyon t 'de arama alanındaki konumu bir vektörle gösterilir. Bukalemunların başlangıç konumlarını ve arama alanında hareketlerini matematiksel olarak tanımlaması Eşitlik 18'de gösterilmiştir.

$$y_t^i = [y_{t,1}^i, y_{t,2}^i, \dots, y_{t,d}^i] \quad (18)$$

Başlangıç popülasyonu, problem boyutu ve bukalemunların sayısı temel alınarak, arama uzayında rastgele başlangıç değerleri ile oluşturulan y matrisi Eşitlik 19'da gösterilmiştir.

$$y^i = l_j + r \cdot (u_j - l_j) \quad (19)$$

Burada y^i , i . bukalemunun başlangıç vektörünü temsil etmektedir. Eşitlik 19'da j .boyutta arama alanının alt ve üst sınırlarını sırasıyla l_j ve u_j gösterilmiştir. Bu eşitlikte r , $[0,1][0,1]$ aralığında uniform dağılımlı rastgele bir sayıdır. Her bir bukalemunun yeni konumu için bir uygunluk fonksiyonu kullanılarak çözüm kalitesi belirlenir. Eğer yeni konumun çözüm kalitesi, mevcut konumun çözüm kalitesinden daha iyi ise, mevcut konum güncellenir. Ancak, BSA modelinde bukalemunlar, mevcut konumlarındaki çözüm kalitesi yeni bir konumdan daha iyiyse, mevcut konumlarını korurlar. Bukalemunların yiyecek arayışı sırasında hareketlerinin davranışı, pozisyon güncelleme stratejisi Eşitlik 20'de matematiksel olarak ifade edilmektedir.

$$y_{t+1}^{i,j} = \begin{cases} y_t^{i,j} + p_1(P_t^{i,j} - G_t^j)r_2 + p_2(G_t^j - y_t^{i,j})r_1 & r_i \geq P_p \\ y_t^{i,j} + \mu((u^j - l^j)r_3 + l_b^j) \operatorname{sgn}(\operatorname{rand} - 0.5) & r_i < P_p \end{cases} \quad (20)$$

Bukalemunların av aramasındaki hareketlerini matematiksel olarak modellemek için konum güncelleme stratejisi önerilebilir ve Eşitlik 20'deki gibi ifade edilmektedir. Bu

eşitlikte $y_{t+1}^{i,j}$, i numaralı bukalemunun j boyutta t iterasyon adımındaki yeni konumunu; $y_t^{i,j}$, i numaralı bukalemunun j boyutta t numaralı iterasyon adımındaki mevcut konumunu; $P_t^{i,j}$, i numaralı bukalemunun j boyutta t numaralı iterasyon döngüsünde şimdiye kadar elde ettiği en iyi konumu; G_t^j , t numaralı iterasyonda herhangi bir bukalemun tarafından şimdiye kadar elde edilen en iyi konumu temsil eder temsil etmektedir. p_1 ve p_2 , keşif kabiliyetini kontrol eden iki pozitif sayı; r_1 ve r_2 , aralıkları $[0,1]$ olan rastgele sayı; r_i , i numaralı $[-1,1]$ aralığında rastgele bir sayı, P_p , bukalemunun avı algılama olasılığını temsil etmektedir. P_p , bu değer 0,1 olarak belirlenmiştir. Eşitlikte $sgn(rand - 0.5)$, keşif ve sömürü yönlendirme üzerinde etki için kullanılır ve değeri 1 veya -1 olabilir. Burada sgn işareti fonksiyonu, $rand - 0.5$ ifadesinin işaretini döndürür. Bu sayede keşif ve sömürü arasındaki yönlendirmeyi belirlemektedir. μ , iterasyonların bir fonksiyonu olarak tanımlanan bir parametredir ve iterasyon sayısı ile azalmaktadır (Braik, 2021). BSA'da sömürme özelliğini gerçekleştirebilmek için temel parametreler vardır. Bu parametreler aşağıda listelenmiştir.


- ✓ p_1 ve p_2 : Bu, küresel ve yerel arama süreçlerini dengeleme davranışları için oluşturulmuştur.
- ✓ μ : İterasyonun geçmesiyle birlikte keşif zamanla azalırken sömürme isteği artmaktadır. Bir bukalemunun avına yakın olduğu son iterasyonlarda, bu parametre ile pozisyon güncelleme süreci avın etrafında yerel arama yapmaya yardımcı olarak sömürüyü arttırmaktadır. Bu parametre, keşif ve sömürü arasında daha iyi bir denge kurmayı sağlayabilmektedir.
- ✓ γ : En iyi çözümü araştırarak sömürü miktarını kontrol etmektedir.
- ✓ ρ : Bu parametre, algoritmanın sömürme potansiyelini kontrol etmek için kullanılmaktadır.
- ✓ $sgn(rand-0.5)$: Keşfin yönünü değiştirerek sömürünün kalitesini artırır.

1.6. Çalışmada Kullanılan Veriler

Bu çalışmada kullanılan ve girişler olan veriler nüfus, gayrisafi yurtiçi hasıla, kişi başına toplam elektrik tüketimi, yapı kullanma izin belgesi alan toplam bina yüzölçümü ve girişim sayıları ve çıkış olan enerji tüketimi verilmiştir (URL-1 & URL-2).

1.6.1. Nüfus


Türkiye İstatistik Kurumu'nun (TÜİK) resmi sitesindeki bölgesel istatistikler arayüzünden Gümüşhane ilinin adrese dayalı nüfus kayıt sistemleri 2000 yılında başlanmıştır. Gümüşhane iline ait 2000-2022 yılları arası nüfus verileri Ek Tablo 1'de verilmiştir. Gümüşhane iline ait 2000-2022 nüfus verileri Şekil 5'te grafikte gösterilmiştir. Grafik incelendiğinde Gümüşhane ilinin nüfus verilerine göre 2016'da üniversitenin kontenjan ve bölüm sayısını arttırmasına bağlı olarak hızla artan nüfus sonraki yıllarda tekrar azalma eğilimine gitmiştir.



Şekil 5. Gümüşhane ili 2000-2022 yılları nüfus grafiği

1.6.2. Gayrisafi Millî Yurtiçi Hasıla


TÜİK'in resmi sitesinden bölgesel istatistikler bölümünden Kişi Başına Gayrisafi Yurtiçi Hasıla 2004-2022 yılları arasındaki Kişi başına GSYH (₺) verileri alınmıştır. Gümüşhane ili için GSYH(₺) verileri Şekil 6'da gösterilmiştir. Gümüşhane iline ait 2000-2022 yılları arası gayrisafi millî yurtiçi hâsıla verileri Ek Tablo 1'de verilmiştir. Grafik incelendiğinde 2008 krizi hariç kişi başı gelirin yükselişte olduğu saptanmıştır.



Şekil 6. Gümüşhane ili 2004-2022 yılları gayrisafi milli hasıla grafiği

1.6.3. Toplam Bina


TÜİK'in resmi sitesinden Yapı Kullanma İzin Belgesi-Yüzölçüm: Toplam Bina (m²) kısmından 2002-2022 yılları arasındaki veriler alınmıştır. Gümüşhane iline ait 2000-2022 yılları arası yapı kullanma izin belgesi-yüzölçüm: toplam bina (m²) verileri Ek Tablo 1'de verilmiştir. Yapı kullanma izin belgesi alan toplam bina (m²)' si, Şekil 7'de gösterilmiştir.



Şekil 7. Gümüşhane ili 2002-2022 yılları toplam bina (metrekare) grafiği

1.6.4. İş Kayıtlarına Göre Girişim Sayıları


TÜİK'in resmi sitesinden iş kayıtlarına göre girişim sayıları 2009-2021 yılları arasındaki veriler alınmıştır. İş kayıtlarına göre girişim sayıları Şekil 8'de gösterilmiştir.



Şekil 8. Gümüşhane ili 2009-2021 yılları girişim sayıları grafiği

1.6.5. Aktif Abone Sayısı


EPDK'nın resmi sitesinden illere göre abone sayısı başlığı altında Gümüşhane iline ait 2000-2022 yılları arasındaki veriler alınmıştır. Gümüşhane iline ait 2000-2022 yılları arası aktif abone sayısı verileri Ek Tablo 1'de verilmiştir. Bu veriler Şekil 9'da Gümüşhane ili için aktif abone sayısının yıllara göre değişiminin grafiğinde gösterilmiştir.



Şekil 9. Gümüşhane ili 2000-2022 yılları aktif abone sayısı grafiği

1.6.6. Enerji Tüketimi


TÜİK'in resmi sitesinden illere göre Toplam Elektrik Tüketimi (MWh) başlığı altında 2000-2022 yılları arasındaki veriler alınmıştır. Gümüşhane iline ait 2000-2022 yılları arası enerji tüketim verileri Ek Tablo 1'de verilmiştir. Bu veriler Şekil 10'da Gümüşhane ili için toplam elektrik tüketim değeri 2012 yılından sonra büyük bir artış göstermiştir. Bu yıllarda açılan maden üretimi ve çimento fabrikası enerji tüketimi arttırmıştır. Toplam tüketilen enerji yapılan çalışmada çıkış olarak belirtilerek yapılan tahmin ve gerçek değer arasındaki hata bulunmuştur.



Şekil 10. Gümüşhane ili 2000-2022 yılları enerji tüketimi (MWh) grafiği

1.6.7. Kişi Başı Elektrik Tüketimi


TÜİK'in resmi sitesinden bölgesel istatistikler bölümünden Kullanım Yerlerine Göre Elektrik Tüketimi: Kişi Başına Toplam Elektrik Tüketimi (kWh) başlığı altında 2000-2022 yılları arasındaki Gümüşhane ili için kişi başına toplam elektrik tüketimi (kWh) verileri alınmıştır. Bu veriler Şekil 11'de gösterilmiştir.



Şekil 11. Gümüşhane ili 2000-2022 kişi başı elektrik tüketimi (kWh) grafiği

2. YAPILAN ÇALIŞMALAR

Yapay Sinir Ağları (YSA), makine öğrenimi alanında temel bir algoritmadır ve yeni girdi verileri üzerinde yüksek performans elde etmek için sinir ağlarını eğitmekten sorumludur. Gözetimli öğrenme yöntemi kullanılarak, eğitmen önce sinir ağlarına örnek veriler sağlar ve ardından YSA'nın yapısal parametrelerini her eğitim aşamasında değiştirerek performansı iyileştirmeye çalışır. YSA, enerji talep tahmininde kullanılmakta ve performans olarak başarılı sonuçlar vermektedir (Koçbey, 2019). YSA'nın birçok türü bulunmaktadır. Çok Katmanlı YSA da bir türlerden biridir. Çok katmanlı YSA'nın eğitimi, arama alanının bilinmemesi sebebiyle zordur (Nur, 2021). Aynı zamanda eğitim süresi uzunluğu problem olmakta ve veri kümesi ve girdiler de değişebilmektedir. Normalde ağ mimarisi, deneme-yanılma yöntemiyle manuel olarak oluşturulan, zaman alan ve tecrübe gerektiren bir süreçtir. Ancak nöroevrim, bu süreci otomatikleştirerek daha hızlı ve etkili bir çözüm sunmaktadır. Evrimleşen YSA, doğal seçim ilkesini taklit ederek yapay sinir ağlarının evrimini gerçekleştiren bir optimizasyon yaklaşımıdır. Bu yöntem, genetik algoritmaları veya evrimsel stratejileri içerir ve bu algoritmaların yardımıyla sinir ağlarının mimarisini, ağırlıklarını veya hiperparametrelerini optimize etmeye çalışır. Manuel olarak tasarlanmış sinir ağlarına göre daha etkili ve özelleştirilebilir sonuçlar sağlamaktadır. Bu yapıyı incelemek için çalışmada YSA farklı algoritmalar ile optimize edilerek performansları analiz edilmiştir. Veri setini eğitim ve test olarak bölerek modelin performansını daha iyi değerlendirilmesini sağlamaktadır. Bu işleme çapraz doğrulama ismi verilmektedir. YSA çalışmasında verilerin eğitim-test olarak ayrılmaktadır. Genellikle eğitim verisi yüzde seksen, test verisi yüzde yirmi alınmaktadır (Yurdusever, 2021). Ağın parametrelerinin değer aralığı $[-1,1]$ alındı. Şekil 12'de YSA'nın optimizasyon algoritmasıyla evrilleştirilmesine ait blok diyagramı gösterilmektedir. Çalışmada kullanılan yazılımlar Ek. 1 ve Ek. 2 verilmiştir.




Şekil 12. YSA'nın optimizasyon algoritmasıyla evrilleştirme blok diyagramı

Normalizasyon, veri setindeki değerleri belirli bir aralığa veya ölçeğe taşıyan bir işlemdir. Bu işlem, farklı özelliklere sahip olan veri noktalarının karşılaştırılabilir hale getirilmesini sağlar. Genellikle $[0, 1]$ aralığına taşıma yöntemiyle gerçekleştirilir. Veri setindeki her değer, minimum ve maksimum değerler arasında lineer bir şekilde ölçeklenir. Eşitlik 21'de normalizasyon işlemi formüle edilmiştir. Normalizasyon işlemi yazılımı Ek 3'de verilmiştir. Bu normalizasyon işlemleri, makine öğrenimi ve istatistiksel analiz gibi alanlarda yaygın olarak kullanılmaktadır. Veri setindeki farklı özellikler veya değişkenler arasındaki büyüklük farklılıklarını ortadan kaldırarak, algoritmaların daha dengeli ve etkili bir şekilde çalışmasına sağlamaktadır. Ayrıca, normalizasyon, aşırı büyük veya küçük değerlere sahip veri noktalarının model performansını olumsuz etkilemesini önler, böylece daha güvenilir ve tutarlı sonuçlar elde edilmektedir.

$$x_{norm} = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (21)$$

Çalışmada 2000-2018 yılları arasındaki veriler eğitim ve 2018-2022 yılları arasındaki veriler test için ayrılmıştır. Sisteme nüfus, gayrimillî yurtiçi hasıla, toplam bina yüzölçümü (m^2) ve abone sayısı giriş olarak verilmiş ve çıkış olarak enerji tüketimi belirlenmiştir.

Sistemimiz çok girişli-tek çıkışlı ağı sahiptir. Yapay sinir ağının bu verilerle oluşturulan bir örneği Şekil 13'te gösterilmiştir. Şekilde 1. gizli katmanında 7 nöron; 2. Gizli katmanında 3 nöron sayılı 4 girişli 1 çıkışlı bir ağ yapısı gösterilmiştir.



Şekil 13. İki gizli katmana sahip YSA yapı örneği

Bu çalışmada, enerji talep tahmininde Ali Baba ve Kırk Haramiler algoritmasıyla beraber çalışan YSA'nın performansı incelenmiştir. Ali Baba ve Kırk Haramiler algoritması ile yapay sinir ağlarının eğitimi yapılmıştır. Çalışmada AFT'nin performansını incelemek ve karşılaştırmak için Parçacık Sürü Optimizasyonu ve Bukalemun Sürü Algoritması ile AFT-YSA'daki aynı çalışmalar yapılmıştır. Çalışmaların sonucunda hata performans analizi yapılmıştır.


2.1. Gümüşhane 2000-2022 Yılları İçin Uzun Dönem AFT-YSA Kullanılarak Yük Tahmini

Çalışmanın ilk kısmında Ali Baba ve Kırk Haramiler algoritmasıyla 2000-2018 yılları arasındaki veriler eğitim ve 2018-2022 yılları arasındaki veriler test için ayrılmıştır. Sisteme nüfus, gayrimillî yurtiçi hasıla, toplam bina yüzölçümü (m^2) ve abone sayısı giriş olarak verilmiş ve çıkış olarak enerji tüketimi belirlenmiştir. Sistemimiz çok girişli-tek çıkışlı ağı sahiptir. Tüm veri setleri [0-1] aralığına çekilerek normalizasyon yapıldı. Bu veriler yapay sinir ağları ve AFT çalışmaları için MATLAB R2019 programında kodlama kullanılmıştır.

Çalışmada AFT-YSA modelinde eğitim fonksiyonu TrainLMLevenberg-Marquardt, öğrenme algoritmasında geri yayımlı ve gizli katmanda transfer fonksiyonu olarak tansig

ve performans kriteri için MSE olarak seçilmiştir. AFT-YSA'nın çalışmasının daha iyi analizini yapmak için gizli katman sayısı 1 ve 2 olarak giriş katmanı ile beraber 2 katmanlı ve 3 katmanlı YSA kullanılmıştır. Katmanların nöron sayısına göre performansını incelemek için 1'den 20'ye kadar deneme yapılmıştır. AFT'nin popülasyon büyüklüğü 10-30-50-75-100 olarak girilerek denemeler yapılmıştır. En fazla iterasyon sayısı 50-100-250 olarak seçilmiştir. Her nöron sayısı da kendi içerisinde program 30 defa çalıştırılmış en düşük MSE değerine sahip sonuç tabloda gösterilmiştir. Çalışmanın AFT ile hibrit yapısı ve YSA parametrelerle çalışması incelenmiştir. Şekil 14'te Ali Baba ve Kırk Haramiler algoritmasıyla evrimselleştirilen yapay sinir ağı yapısının çalışmada kullanılan enerji tüketim verisiyle modelin akış diyagramı gösterilmektedir.





Şekil 14. AFT-YSA Gümüşhane 2000-2022 yılları arasında enerji tüketimi verilerine göre akış diyagramı

Öncelikle katman ve nöron sayısının etkisini incelemek için popülasyon büyüklüğü 40 ve maksimum iterasyon sayısı 100 alınarak Gümüşhane enerji tüketim verileriyle AFT-YSA çalıştırılarak aşağıdaki Tablo 1’de sonuçlar elde edilmiştir.


Tablo 1. Farklı nöron ve katman sayısına göre AFT-YSA’nın MSE sonuçları

<i>Nöron Sayısı</i>	<i>2 Katmanlı</i>	<i>3 Katmanlı</i>
1	0.003981	0.237647
2	0.003912	0.047908
3	0.004751	0.048520
4	0.012262	0.041430
5	0.066808	0.104672
6	0.064566	0.066843
7	0.106181	0.061783
8	0.111273	0.066674
9	0.093875	0.030854
10	0.054033	0.054717
11	0.161144	0.037067
12	0.151811	0.227975
13	0.124240	0.083539
14	0.090315	0.046783
15	0.091841	0.047099
16	0.044697	0.111526
17	0.150013	0.078836
18	0.066023	0.055942
19	0.028883	0.038749
20	0.057401	0.101653

MSE (Mean Squared Error) düşük olduğunda model daha iyidir, yani gerçek değerlerle tahmin edilen değerler arasındaki fark düşüktür. Bu duruma göre 2000-2022 yılları arası Gümüşhane ili enerji tüketimi verileriyle Tablo 1. 2 katmanlı durum incelendiğinde aşağıdaki sonuçlar elde edilmiştir.

- ✓ 1 ile 6 arasındaki nöron sayıları için MSE değerleri genellikle düşüktür ve modelin iyi performansta olduğunu göstermektedir.
- ✓ 7 ile 12 arasındaki nöron sayıları için MSE değerleri biraz artmıştır ancak hâlâ kabul edilebilir seviyelerdedir.
- ✓ 13 ve sonrasındaki nöron sayıları için MSE değerleri belirgin bir şekilde artar, bu durumda modelin aşırı uydurduğu veya ezberlediği düşünülmektedir.

Genelde, modelin karmaşıklığı arttıkça eğitim verilerine aşırı uyma (overfitting) riski de artmaktadır. Bu, modelin eğitim verilerine çok iyi uyması ancak genelleme yapma yeteneğinin düşük olmasını göstermektedir. Özellikle, nöron sayısı arttıkça modelin eğitim verilerine daha iyi uyması beklenmektedir fakat bir süre sonra model aşırı uyma gösterdiğinde bu durum tersi yönde etki etmektedir. Dolayısıyla, genel bir değerlendirme yapacak olursak, 1 ile 6 arasındaki nöron sayıları tercih edilebilir görünmektedir, çünkü düşük MSE değerleri genellikle daha iyi genelleme yeteneği ile ilişkilidir. Ancak, bu değerlendirme, kullanılan veri setine, problem türüne ve diğer faktörlere bağlı olarak değişebilmektedir. Şekil 15'te iki katmanlı 1 nöron sayılı YSA'nın MATLAB blok diyagramı gösterilmektedir.




Şekil 15. İki katmanlı 1 nöron sayılı YSA'nın MATLAB blok diyagramı

2000-2022 yılları arası Gümüşhane ili enerji tüketimi verileriyle Tablo 1. 3 katmanlı durum incelendiğinde aşağıdaki sonuçlar elde edilmiştir.

- ✓ Nöron sayısı 1'den 10'a kadar olan durumda, genel olarak düşük MSE değerleri gözlemlenir. Ancak, bu durumda 3 katmanlı yapı, 2 katmanlı yapıya kıyasla daha yüksek MSE değerlerine sahip görünüyor.
- ✓ Nöron sayısı 11'den 20'ye kadar olan durumda, MSE değerleri daha karmaşık bir model oluşturduğumuz için genellikle artmıştır.
- ✓ Nöron sayısı arttıkça MSE değerlerinin dalgalandığını görülmektedir. Bu durum nöron sayısının model performansı üzerinde net bir etkiye sahip olmadığını göstermektedir.

Bu durumda, 3 katmanlı yapı için 1 ile 10 arasındaki nöron sayıları tercih edilebilir görünmektedir, çünkü bu aralıkta MSE değerleri genellikle daha düşüktür. Şekil 16'da üç katmanlı 10 nöron sayılı YSA'nın MATLAB blok diyagramı gösterilmektedir.



Şekil 16. Üç katmanlı 10 nöron sayılı YSA'nın MATLAB blok diyagramı

Katman ve nöron sayısına göre Tablo 1. incelendiğinde 2 katmanlı yapının, genel olarak daha düşük MSE değerlerine sahiptir. AFT-YSA'nın 2 katmanlı 1 ile 10 arasındaki nöron sayılı modeli, 3 katmanlı modele kıyasla daha iyi performans göstermektedir. Bu durum, daha basit bir yapı olan 2 katmanlı modelin, veri setindeki örüntüleri daha iyi öğrendiği ve genelleme yeteneğinin daha güçlü olduğunu göstermektedir. Bunun yanı sıra 2 katmanlı modelin bu veri setine göre incelendiğinde aşırı uyuma karşı daha dirençli yapıdadır.

AFT-YSA çalışmasının popülasyon büyüklüğü ve iterasyon sayısına oranla performansını incelemek için 2 katmanlı ve 10 nöronlu YSA alınarak Gümüşhane enerji tüketim verileriyle AFT-YSA çalıştırılarak aşağıdaki Tablo 2'de sonuçlar elde edilmiştir.


Tablo 2. Farklı popülasyon büyüklüğü ve iterasyon sayısına göre AFT-YSA MSE sonuçları

		<i>Popülasyon Büyüklüğü</i>				
		<i>10</i>	<i>30</i>	<i>50</i>	<i>75</i>	<i>100</i>
<i>İterasyon Sayısı</i>	<i>50</i>	0.0990738	0.0341895	0.0931778	0.0860728	0.3240362
	<i>100</i>	0.0600506	0.0523192	0.0988537	0.1543904	0.2022119
	<i>250</i>	0.0619204	0.0371634	0.0660640	0.0865116	0.0281111
	<i>1000</i>	0.0468568	0.1030173	0.1434452	0.0689112	0.0766949

Tablo 2.de AFT-YSA modelinin performansı popülasyon büyüklüğü ve iterasyon sayılarına bağlı olarak değişmektedir. En düşük MSE değeri, popülasyon büyüklüğü 100 ve iterasyon sayısı 250 iken (0.0281111) elde edilmiştir.

Popülasyon büyüklüğü arttıkça, genellikle modelin performansı artar. Bu durum, daha fazla veri kullanılarak modelin daha iyi genelleme yapmasına katkıda bulunmaktadır. Fakat

Tablo 2 incelendiğinde bazı durumlarda popülasyon büyüklüğünün artmasının MSE değerlerini arttırdığı gözlemlenmektedir. Burada popülasyon büyüklüğünün aşırı artışının modeli karmaşıktırarak aşırı uymaya sebep olabilmektedir. İterasyon sayısı arttıkça modelin daha fazla öğrenme olasılığı vardır. İterasyon sayısı ile model performansı doğru orantılıdır. Ancak, iterasyon sayısının çok yüksek olması, modelin eğitim verilerine aşırı uyum sağlamasına (overfitting) ve test verileri üzerinde kötü bir genelleme yapmasına neden olabilmektedir. Şekil 17’de popülasyon büyüklüğü ve AFT’de bu değişken harami sayısını gösterir. Harami sayısı 50 ve iterasyon sayısı 100 iken AFT-YSA modelinin verisinin gerçek-tahmin grafiği incelendiğinde eğitim verisinde birbirine yakın iken test verisinde hatanın arttığı görülmektedir. Bunun nedeni test verisinin yetersizliği olabilmektedir.



Şekil 17. Popülasyon büyüklüğü 50 ve iterasyon sayısı 100 iken AFT-YSA modelinin veri grafikleri

2.2 Gümüşhane 2000-2022 Yılları İçin Uzun Dönem BSA-YSA Kullanılarak Yük Tahmini

Çalışmanın bu kısmında, Bukalemun Sürü Algoritması(BSA) parametreler ile YSA üzerindeki etkilerini karşılaştırmayı amaçlamaktadır. BSA ile değiştirilmiş hibrit yapının incelendiği çalışmada, AFT'nin yerine BSA kullanılmıştır. Çalışmada performans kriteri için MSE olarak seçilmiştir. P_p , bu değer 0.1 olarak belirlenmiştir ve kapsamlı deneysel testlerden sonra bulunmuştur. BSA'nın parametreleri $\rho=1.0$, $p_1=2.0$, $p_2=2.0$, $c_1=2.0$, $c_2=1.80$, $\gamma=2.0$, $\alpha = 4.0$, $\beta=3.0$ seçilmiştir (Braik, 2021). BSA-YSA'nın çalışmasının analizi için gizli katman sayısı 1 ve 2 olarak giriş katmanıya beraber 2 katmanlı ve 3 katmanlı YSA kullanılmıştır. Katmanların nöron sayısına göre performansını incelemek için 1'den 20'ye kadar deneme yapılmıştır. BSA'nın popülasyon büyüklüğü 10-30-50-75-

100 olarak girilerek denemeler yapılmıştır. İterasyon sayısı 50-100-250 olarak seçilmiştir. Her nöron sayısı da kendi içerisinde program 30 defa çalıştırılmış en düşük MSE değerine sahip sonuç tabloda gösterilmiştir. Çalışmanın AFT ile hibrit yapısı ve YSA parametrelerle çalışması incelenmiştir.

Öncelikle katman ve nöron sayısının etkisini incelemek için popülasyon büyüklüğü 40 ve maksimum iterasyon sayısı 100 alınarak Gümüşhane enerji tüketim verileriyle BSA-YSA çalıştırılarak aşağıdaki Tablo 3'teki sonuçlar elde edilmiştir.

Tablo 3. Farklı katman ve nöron sayılarına göre BSA-YSA modelinin MSE değeri

<i>Nöron Sayısı</i>	<i>2 Katmanlı</i>	<i>3 Katmanlı</i>
1	0.025497	0.016685
2	0.010423	0.049504
3	0.025413	0.014089
4	0.024381	0.031920
5	0.149226	0.089517
6	0.068149	0.143919
7	0.310274	0.172010
8	0.106100	0.312093
9	0.022604	0.036164
10	0.100914	0.193389
11	0.212816	0.155595
12	0.029227	0.008858
13	0.041612	0.066296
14	0.208757	0.093631
15	0.086812	0.094156
16	0.003464	0.163541
17	0.151090	0.006097
18	0.019815	0.008994
19	0.050935	0.015675
20	0.020955	0.115866

Tablo 3'e bakıldığında, Bukalemun sürüsü algoritması (BSA) ile hibrit hale getirilmiş YSA'nın farklı katman ve nöron sayıları için MSE değerlerini göstermektedir. MSE değeri, bir modelin tahminlerinin gerçek değerlerden ne kadar sapma gösterdiğini ölçmektedir. Daha düşük MSE değeri, daha iyi bir model uyumunu göstermektedir. Tablo 3'ün değerlendirmesi için:

- ✓ MSE değerlerinin genel olarak kabul edilebilir bir seviyede olduğunu görülmektedir. En düşük MSE değeri 0.003464'tür ve 2 katmanlı ve 16 nöronlu bir YSA modeli için elde edilmiştir.

- ✓ Katman sayısı arttıkça MSE değerlerinin genel olarak azaldığını görülmektedir. Bu, daha fazla katmanın modelin karmaşıklığını ve veriye uyum yeteneğini artırdığını göstermektedir.
- ✓ Nöron sayısı arttıkça MSE değerlerinin dalgalandığını görülmektedir. Bu durum nöron sayısının model performansı üzerinde net bir etkiye sahip olmadığını göstermektedir.


BSA-YSA çalışmasının popülasyon büyüklüğü ve iterasyon sayısına oranla performansını incelemek için 2 katmanlı ve 10 nöronlu YSA alınarak Gümüşhane enerji tüketim verileriyle BSA-YSA çalıştırılarak aşağıdaki Tablo 4'teki sonuçlar elde edilmiştir.

Tablo 4. Farklı iterasyon ve popülasyon sayısına göre BSA-YSA modelinin MSE değeri

		Popülasyon Büyüklüğü				
		10	30	50	75	100
İterasyon Sayısı	50	0.024898	0.184722	0.106809	0.069410	0.043334
	100	0.015148	0.020949	0.106150	0.013196	0.027115
	250	0.328005	0.067051	0.145592	0.193461	0.020479
	1000	0.061152	0.079405	0.139800	0.213231	0.170497

Tablo 4 incelendiğinde BSA-YSA modelinin MSE değerlerinin iterasyon sayısı arttıkça genel olarak azaldığı görülmektedir. Bu durum modelin daha fazla iterasyonda daha iyi bir uyum sağladığını göstermektedir. Popülasyon büyüklüğünün MSE değeri üzerinde etkisi görülmemektedir. En düşük MSE değeri (0.013196), 100 iterasyon ve 100 popülasyon büyüklüğünde elde edilmiştir.

Şekil 18'de popülasyon büyüklüğü 50 ve iterasyon sayısı 100 iken BSA-YSA modelinin verisinin gerçek-tahmin grafiği incelendiğinde eğitim verisinde eğriler birbirine yakınken test verisinde birbirinden uzaklaşmıştır.



Şekil 18. Popülasyon büyüklüğü 50 ve iterasyon sayısı 100 iken BSA-YSA modeli veri grafikleri

2.3. Gümüşhane 2000-2022 Yılları İçin Uzun Dönem PSO-YSA Kullanılarak Yük Tahmini

Çalışmanın bu kısmında, PSO parametreler ile YSA üzerindeki etkilerini karşılaştırmayı amaçlamaktadır. PSO ile değiştirilmiş hibrit yapının incelendiği çalışmada, AFT'nin yerine PSO kullanılmıştır. PSO ile yapılan denemelerde nöron sayısı, katman sayısı, popülasyon büyüklüğü ve iterasyon sayısı da değiştirilerek en düşük MSE değerine ulaşılmaya çalışılmıştır. İlk olarak katman ve nöron sayısının etkisini incelemek için popülasyon büyüklüğü 40 ve maksimum iterasyon sayısı 100 alınarak Gümüşhane enerji tüketim verileriyle PSO-YSA çalıştırılarak aşağıdaki Tablo 5'teki sonuçlar elde edilmiştir.

Tablo 5. Farklı katman ve nöron sayılarına göre PSO-YSA modelinin MSE değeri

Nöron Sayısı	2 Katmanlı	3 Katmanlı
1	0.019559	0.014963
2	0.022887	0.027464
3	0.012920	0.013617
4	0.222195	0.009861
5	0.023984	0.027076
6	0.054903	0.031230
7	0.048620	0.227385
8	0.014285	0.009707
9	0.038315	0.246673
10	0.047362	0.008386
11	0.035065	0.110006
12	0.070468	0.047039
13	0.198299	0.105229
14	0.013204	0.446086

Tablo 5'in devamı

15	0.029366	0.610924
16	0.027718	1.050520
17	0.123370	0.219718
18	0.078993	0.290297
19	0.012503	1.124482
20	0.347217	0.477408


Tablo 5 incelendiğinde genel olarak, 2 katmanlı modeller 3 katmanlı modellere göre daha iyi performans göstermiştir. Bu sonuçlardan PSO-YSA modelinin enerji yük tahmini için uygun olabileceğini, ancak modelin hiperparametrelerinin dikkatli bir şekilde seçilmesi gerektiğini göstermektedir. Çünkü bazı değerler 1'in üstünde çıkmıştır.

PSO-YSA çalışmasının popülasyon büyüklüğü ve iterasyon sayısına oranla performansını incelemek için 2 katmanlı ve 10 nöronlu YSA alınarak Gümüşhane enerji tüketim verileriyle PSO-YSA çalıştırılarak aşağıdaki Tablo 6'daki sonuçlar elde edilmiştir.

Tablo 6. Farklı iterasyon ve popülasyon sayısına göre PSO-YSA modelinin MSE değeri

		Popülasyon Büyüklüğü				
		10	30	50	75	100
İterasyon Sayısı	50	0.139700	0.772458	0.282041	0.049607	0.018838
	100	0.697662	0.024433	0.012901	0.216705	0.003618
	250	0.044055	0.025929	0.014207	0.669170	0.137254
	1000	0.040071	0.034362	0.085889	0.610441	0.356861

Tablo 6 incelendiğinde iterasyon sayısı arttıkça, MSE değerleri genel olarak azalmaktadır. Bu, modelin daha fazla iterasyonda daha iyi bir uyum sağladığını göstermektedir. En düşük MSE değeri (0.003618), 100 iterasyon ve 100 popülasyon büyüklüğünde elde edilmiştir.



Şekil 19. Popülasyon büyüklüğü 50 ve iterasyon sayısı 100 iken PSO-YSA modeli veri grafikleri

Şekil 19’da popülasyon büyüklüğü 50 ve iterasyon sayısı 100 iken PSO-YSA modelinin verisinin gerçek-tahmin grafiği incelendiğinde eğitim verisinde eğriler birbirine yakınken test verisinde zamanla birbirine yaklaşmıştır.

2.4. Performans Analizi Karşılaştırması

Makine öğrenmesinde modellerin performansını karşılaştırmak ve minimum hata olacak şekilde modeli seçmek önemlidir. Bu performansı karşılaştırmak için hata ölçütleri mevcuttur. Tahminleme amaçlı kullanılacak olan modellerde MSE, RMSE ve R^2 sık kullanılan ölçütlerdir (URL-3). Çalışmanın önceki kısmında ele alınan AFT-YSA, BSA-YSA ve PSO-YSA hibrit yapıları Gümüşhane 2000-2022 yılları arasındaki enerji tüketim veri setiyle modellenmiştir. Modellemelerde 2 katmanlı ve gizli katman nöron sayısı 10 olarak alınmıştır. Bu modellemelerde MSE, RMSE ve R^2 ölçütleri incelenmiştir. Bu analizin sonuçları aşağıdaki Tablo 7’de gösterilmiştir. Tablo 7’de tüm modelleme de iterasyon sayısı ve popülasyon büyüklüğü 100 alınmıştır.

Tablo 7. Popülasyon ve iterasyon sayısı 100 iken modellerin hata ölçütü analizi

		<i>AFT-YSA</i>	<i>BSA-YSA</i>	<i>PSO-YSA</i>
2 Katmanlı <i>Nöron Sayısı=5</i>	MSE	0.000552	0.000504	0.000858
	RMSE	0.023496	0.022444	0.016072
	R²	0.995829	0.995970	0.995048
2 Katmanlı <i>Nöron Sayısı=10</i>	MSE	0.000429	0.000681	0.000178
	RMSE	0.020722	0.026096	0.013323
	R²	0.996756	0.994552	0.996659
3 Katmanlı Nöron <i>Sayısı=5</i>	MSE	0.000601	0.000867	0.000642
	RMSE	0.024523	0.029447	0.025334
	R²	0.995456	0.993063	0.995151
3 Katmanlı <i>Nöron Sayısı=10</i>	MSE	0.001044	0.000821	0.000419
	RMSE	0.032314	0.028656	0.020474
	R²	0.992111	0.993431	0.996833

Tablo 7 incelendiğinde R^2 modellerinin bire yakınlığı modellerimizin performansının iyi olduğunu göstermektedir. Bundan dolayı AFT-YSA modelinin enerji tüketim tahminlemesinde kullanılabileceği gözlemlenmiştir. Detaylı incelendiğinde AFT-YSA modelimizin PSO-YSA modeliyle yakın sonuçlar içerirken BSA-YSA diğerlerine göre düşük kalmıştır. Ayrıca nöron ve katman sayısının bu modellemelerde pek bir etkisinin olmadığı gözlemlenmiştir.

R^2 analizini popülasyon büyüklüğü ve iterasyon sayısı üzerinden incelendiği Tablo 8 ve Tablo 9 oluşturulmuştur. Bu tablodaki tüm modellemeler 2 katmanlı, 10 nöronlu alınarak hesaplanmıştır. Tablo 8’de tüm modellemeler 2 katmanlı, 10 nörona sahip ve iterasyon sayısı 50 alınarak hesaplanmıştır.

Tablo 8. İterasyon 50 iken popülasyon büyüklüğüne göre hata analizi

			AFT-YSA	BSA-YSA	PSO-YSA
Popülasyon Büyüklüğü	50	<i>MSE</i>	0.000820	0.002768	0.000944
		<i>RMSE</i>	0.028639	0.052612	0.030727
		<i>R²</i>	0.993803	0.977856	0.992866
	100	<i>MSE</i>	0.000819	0.001061	0.000729
		<i>RMSE</i>	0.028617	0.032579	0.026998
		<i>R²</i>	0.993813	0.991509	0.994493

Tablo 8 ve 9 incelendiğinde PSO ve AFT yapılı YSA hibrit modellemelerin birbirine yakın hata değerinde iken BSA modelinin performans olarak iyi ama diğer modellemelerden geride kaldığı görülmektedir. İterasyon arttıkça hata MSE ve MSE bağlı RMSE değerleri Tablo 9’da azaldığı gözlemlenmiştir. Tablo 9’da *R²* değerleri incelendiğinde Tablo 8’e göre artmış ve 1’e yaklaşmıştır. Modelin performansında iterasyon sayısının önemi gösterilmiştir.

Tablo 9. İterasyon 250 iken popülasyon büyüklüğüne göre hata analizi

			AFT-YSA	BSA-YSA	PSO-YSA
Popülasyon Büyüklüğü	50	<i>MSE</i>	0.000348	0.000410	0.000326
		<i>RMSE</i>	0.018647	0.020250	0.018060
		<i>R²</i>	0.997218	0.996902	0.997536
	100	<i>MSE</i>	0.000400	0.000484	0.000118
		<i>RMSE</i>	0.019996	0.022010	0.010848
		<i>R²</i>	0.996979	0.996124	0.999111

Algoritmaların eğitimi ile beraber çalışma sürelerini incelemek için Intel® i5, 4 çekirdekli ve 8 mantıksal işlemcili bir işlemcili, temel hızı 1.60 GHz olan bilgisayarda MATLAB 2019a programında algoritmalar ayrı ayrı çalıştırıldı. Çalışma süresini incelemek için programda kodların her bir sınıfı için üst sınırına “tic” ve alt sınırına “elapsed_time = toc” kodları eklenerek ayrı ayrı hesaplandı ve en son tabloya toplam süre saniye biriminden Tablo 10’da gösterildi.

Tablo 10. Popülasyon ve iterasyon sayısı 100 iken modellerin çalışma süresi

		<i>AFT-YSA</i>	<i>BSA-YSA</i>	<i>PSO-YSA</i>
<i>Süre</i>	<i>2 Katmanlı</i>	95 saniye	107 Saniye	72 Saniye
	<i>5 Nöronlu</i>			
	<i>2 Katmanlı</i>	96 Saniye	111 Saniye	87 Saniye
	<i>10 Nöronlu</i>			
	<i>3 Katmanlı</i>	104 Saniye	125 saniye	92 Saniye
	<i>5 Nöronlu</i>			
	<i>3 Katmanlı</i>	108 Saniye	157 Saniye	103 Saniye
	<i>10 Nöronlu</i>			

Tablo 10 incelendiğinde katman ve nöron sayısı arttıkça algoritmaların eğitimi ve çıkış verme süreçleri artmıştır. En hızlıdan yavaşına sırasıyla PSO-YSA, AFT-YSA, BSA-YSA olmuştur. Tablo 11'deki tüm modellemeler 2 katmanlı, 10 nörona sahip 50 alınarak hesaplanmıştır.

Tablo 11. İterasyon sayısı ve popülasyon büyüklüğüne göre çalışma süresi

		<i>AFT-YSA</i>	<i>BSA-YSA</i>	<i>PSO-YSA</i>
<i>Popülasyon</i>				
<i>Büyüküğü</i>				
<i>i = 50</i>	<i>50</i>	25 Saniye	31 Saniye	20 Saniye
	<i>100</i>	48 Saniye	61 Saniye	39 Saniye
<i>i = 250</i>	<i>50</i>	121 Saniye	179 Saniye	120 Saniye
	<i>100</i>	228 Saniye	282 Saniye	198 Saniye

Tablo 11 incelendiğinde popülasyon büyüklüğü ve iterasyon sayısı arttıkça programların çalışma süreleri uzamıştır. Programın çalışma süreleri en kısıdan uzuna sırasıyla PSO-YSA, AFT-YSA, BSA-YSA olmuştur.

3. SONUÇLAR

Elektrik enerjisi, modern yaşamın vazgeçilmez bir kaynağıdır ve birçok alanda kritik bir rol oynamaktadır. Dünya genelinde nüfus artışı, ekonomik gelişme ve teknolojik ilerlemelerle elektrik enerjisi tüketimi sürekli artmaktadır. Elektrik enerjisi tüketiminin doğru tahmin edilmesi, enerji sistemlerinin etkin, güvenilir ve sürdürülebilir bir şekilde işlemesi için kritik öneme sahiptir. Bu doğru tahminleme sayesinde, enerji kaynakları daha verimli kullanılabilir, enerji maliyetleri kontrol altında tutulabilir, enerji güvenliği sağlanabilir ve sürdürülebilir bir enerji geleceği inşa edilebilir. Bu tahminleme için çeşitli yöntemler ve modeller kullanılmaktadır. Yöntemlerde genellikle geçmiş tüketim verileri, hava durumu, nüfus artışı, ekonomik göstergeler gibi faktörleri dikkate alır. Yapay zeka ve makine öğrenmesi gibi yeni teknolojilerin kullanımıyla, elektrik enerjisi tüketiminin daha hassas bir şekilde tahmin edilmesi mümkün hale gelmektedir. Yapay sinir ağları, geçmiş verilerden karmaşık örüntüleri öğrenerek enerji tüketimini yüksek tahmin etmek için kullanılmaktadır. Yapay sinir ağlarının eğitiminde algoritmalar kullanılarak oluşturulan hibrit yapıdan eğitimsiz YSA oranla daha verimli sonuçlar alınmaktadır. Öğrenme yeteneğine sahip olan yapay sinir ağlarının tahminlemedeki değerlendirilmesi ağına doğru bir şekilde eğitime ve eğitiminde kullanılan öğrenme algoritmasının performansına bağlıdır.

Bu çalışmada metasezgisel yöntemler ile Yapay Sinir Ağlarının çalışmasını incelemek için Gümüşhane ili enerji tüketiminin tahmin analiz edilmiştir. Çalışmada gerçek veriler kullanılmıştır. Çalışmada YSA üç farklı algoritma ile eğitilmiştir. Bu tez çalışmasında daha önce literatürde öğrenme algoritması olarak kullanılmamış Ali Baba ve Kırk Haramiler algoritması ve Bukalemun Sürü algoritmasıyla model oluşturulmuş ve AFT ve BSA'nın öğrenme algoritması olarak uygulanabilirliği incelenmiştir. Performans analizi için MSE, RMSE ve R^2 ölçütleri ile AFTYSA, BSAYSA ve PSOYSA modelleri analiz edilmiştir.

Çalışma dört kısımdan oluşturuldu. Öncelikle her bir öğrenme algoritması YSA ile hibrit yapı oluşturularak iterasyon sayısı, nöron sayısı, popülasyon büyüklüğü ve katman sayısı değiştirilerek modelin performansları incelenmiştir. MATLAB programında yazılım programlanmıştır. Program her bir çalışma için otuz defa tekrarlanarak ölçütlerin ortalaması alınmıştır. Ağına eğitim kısmında maksimum iterasyon sayısına ulaşıldığında ve parametreler yeterli olduğunda durdurulmuştur. Bütün modellerin çalışmasının sonuçları ayrı ayrı tablolandırılmıştır. Bu çalışmada nöron sayısının kendi içerisinde çok bir etki etmediği

gözlemlenmiştir. MSE hata ölçütünü en etkileyen faktör iterasyon sayısı olduğu gözlemlenmiştir. Katman sayısının incelenmesinde genel olarak iki katmanlı yapının basit yapısı sebebiyle üç katmanlı yapıya göre daha düşük hata oranına sahip olduğu görülmüştür. Modeller birbiriyle karşılaştırıldığında performansın en yüksekten düşüğe sırasıyla PSO-YSA, AFT-YSA, BSA-YSA olduğu gözlemlenmiştir. Bu çalışmalar sonucunda MSE, RMSE ve R^2 değerleri de dikkate alınarak AFT-YSA modelinin enerji tüketiminin tahminlemede kullanılabilirliği sonucuna varılmıştır.



4. ÖNERİLER

Yüksek lisans tezi olan bu çalışmada AFT-YSA'nın enerji tüketim verisiyle performansı incelenmiş ve modelin kullanılabilirliği sonucuna varılmıştır.

Yapılan çalışmada AFT-YSA modeli evrimleştirilmiş bir YSA'dır. Evrimselleştirilmiş YSA(EYSA), yapay sinir ağlarının parametrelerinin optimize edilmesinde güçlü bir yöntem olarak öne çıkmaktadır. EYSA karmaşık problemlerin etkili bir şekilde çözümüne katkı sağlamaktadır ve genelleme yeteneği ile yüksek performans sunmaktadır. Bu nedenle, EYSA alanının gelişimi için yeni optimizasyon tekniklerinin geliştirilmesi ve çeşitli veri setlerinde kullanımının performansı analiz edilerek uygulamalarda kullanımının artması önemlidir. Bu konu ile ilgilenmek isteyen araştırmacılara öneriler aşağıdaki gibi belirtilmiştir:

- Daha büyük ve farklı bir eğitim veri seti kullanılarak, modelin performans analizi yapılabilir.
- Diğer makine öğrenmesi algoritmalarıyla farklı EYSA'lar oluşturularak performans analizi yapılabilir.
- Veri setinden yerine amaç fonksiyonundan gidilerek EYSA modeli oluşturulur ve performans analizi yapılabilir.
- EYSA'da kullanılacak veri setinin soyut çıkışa sahip olduğunda doğruluk, duyarlılık, F-skoru gibi analizleri yapılabilir.

5. KAYNAKLAR

- Afzal, S., Shokri, A., Ziapour, B. M., Shakibi, H., & Sobhani, B. (2024). Building energy consumption prediction and optimization using different neural network-assisted models; comparison of different networks and optimization algorithms. *Engineering Applications of Artificial Intelligence*, 127, 107356.
- Başıoğlu, B., & Bulut, M. (2017). Kısa dönem elektrik talep tahminleri için yapay sinir ağları ve uzman sistemler tabanlı hibrit sistem geliştirilmesi. *Journal of the Faculty of Engineering & Architecture of Gazi University/Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 32(2).Formun Üstü
- Benšková, L., 1994, Eksik temelin etkisinin çekici bir sinir ağı ile modellenmesi. *Ağ: Sinir Sistemlerinde Hesaplama*, 5 (3), 333-349.
- Braik, M. (2023). Enhanced Ali Baba and the forty thieves algorithm for feature selection. *Neural Computing and Applications*, 35(8), 6153-6184.
- Braik, M. S. (2021). Chameleon Swarm Algorithm: A bio-inspired optimizer for solving engineering design problems. *Expert Systems with Applications*, 174, 114685
- Braik, M., Ryalat, M. H., & Al-Zoubi, H. (2022). A novel meta-heuristic algorithm for solving numerical optimization problems: Ali Baba and the forty thieves. *Neural Computing and Applications*, 34(1), 409-455.
- Çetinkaya, Ü., 2016, Enerji Sistemlerinde Dinamik Güç Akışı İzleme ve Gerilim Kararlılık Analizi, Gazi Üniversitesi, Yüksek Lisans Tezi, Ankara.
- Debnath, K. B., & Mourshed, M. (2018). Forecasting methods in energy planning models. *Renewable and Sustainable Energy Reviews*, 88, 297-325
- Dincer, K., & Nuroğlu, F. M., (2021). Comparative Analysis of Hourly Electricity Consumption on Weekdays and Weekends . *International Congress on Multidisciplinary Natural Sciences and Engineering* (pp.112).
- Ekinci, F. (2019). YSA VE ANFIS Tekniklerine Dayalı Enerji Tüketim Tahmin Yöntemlerinin Karşılaştırılması . *Düzce Üniversitesi Bilim ve Teknoloji Dergisi*, 7 (3), 1029-1044 . DOI: 10.29130/dubited.485822
- Elmas, Ç., 2003, Yapay Sinir Ağları (Theory, Architecturue, Education, Application). Seckin Yayıncılık, Ankara.
- Hu, G., Mohammadiun, S., Gharabagh, A. A., Li, J., Hewage, K., & Sadiq, R. (2020). Selection of oil spill response method in Arctic offshore waters: A fuzzy decision tree based framework. *Marine Pollution Bulletin*, 161, 111705.

- Juberias, G., Yunta, R., Moreno, J. G., & Mendivil, C. (1999, April). A new ARIMA model for hourly load forecasting. In 1999 IEEE Transmission and Distribution Conference (Cat. No. 99CH36333) (Vol. 1, pp. 314-319). IEEE.
- Karpathy, A. (2018). Stanford university cs231n: Convolutional neural networks for visual recognition. URL: <http://cs231n.stanford.edu/syllabus.html>, 13-35.
- Kasule, A. (2018). Hibrit algoritma kullanarak elektrik enerji tüketim modelinin oluşturulması ve kestirimi: Uganda örneği (Doctoral dissertation, Sakarya Üniversitesi (Turkey)).
- Koçbey, M. E., (2019). Bursa ili elektrik gücü talep tahmin analizi, Balıkesir Üniversitesi, Yüksek Lisans Tezi, Balıkesir.
- Maltarollo, V. G., Honório, K. M., & da Silva, A. B. F. (2013). Applications of artificial neural networks in chemical problems. Artificial neural networks-architectures and applications, 203-223.
- Nur, I. M. (2021). Gri kurt optimizasyon (GKO) algoritması ve yapay sinir ağı (YSA) kullanılarak hibrit bulut tabanlı saldırı tespit ve yanıt sistemi. , Konya Teknik Üniversitesi, Master's thesis, Konya.
- Sağ, T., Abdullah Jalil Jalil, Z., 2021, İleri beslemeli sinir ağının eğitimi için Vortex arama optimizasyon algoritması. Uluslararası J. Mach. Öğrenmek. & Siber. 12 , 1517–1544.
- Saleh, M. I., & Syed, M. A. (1996). Principles of electricity demand forecasting. Power Eng, 139-143.
- Sezer, M. S. (2019). Yapay sinir ağları ve farklı tahmin yöntemleri ile uzun dönem yük tahmini: Zonguldak örneği (Master's thesis, Kütahya Dumlupınar Üniversitesi/Fen Bilimleri Enstitüsü).
- Sharma, P., Thangavel, S., Raju, S., & Prusty, B. R. (2022). Parameter Estimation of Solar PV Using Ali Baba and Forty Thieves Optimization Technique. Mathematical Problems in Engineering, 2022.
- Shuvra, M. A., Rahman, M. M., Ali, A., & Khan, I. S. (2011). Modeling and forecasting demand for electricity in Bangladesh: Econometrics model. In International Conference on Economics, Trade and Development (Vol. 7, p. 74).
- Sitton, J. D., Zeinali, Y. & Story, B. A., 2017, Rapid soil classification using artificial neural networks for use in constructing compressed earth blocks, Construction and Building Materials, 138, 214-221.
- URL-1. (2023, Ekim 10). İstatistikler: <https://biruni.tuik.gov.tr/bolgeselistatistik/tablo> Olustur.do adresinden alınmıştır.
- URL-2. (2023, Ekim 10). Faaliyet Raporları: <https://www.tedas.gov.tr/tr/1/faaliyet-raporlari/RoutePage/63c659ecd27de36b22f9cf1b> adresinden alınmıştır.

- URL-3. (2023, Aralık 1). Hata Ölçütleri: <https://medium.com/academy-team/makine-%C3%B6%C4%9Frenmesi-regresyon-modellerindeki-hata-metriklerine-g%C3%BCncel-bak%C4%B1%C5%9F-mae-mse-rmse-r-kare-d1ab758c5759>. adresinden alınmıştır.
- Vaferi, B., Samimi, F., Pakgohar, E. & Mowla, D., (2014). Artificial neural network approach for prediction of thermal behavior of nanofluids flowing through circular tubes, Powder Technology, 267, 1-10.
- Yılmaz, Ö. (2023). Yapay sinir ağı eğitimi için çoklu evren optimizasyonu ve tavlama benzetimi algoritması ile yeni bir melez meta-sezgisel model önerisi. Selçuk Üniversitesi, Doktora Tezi, Konya.
- Yurdusever, T. (2021). Çeşitli aktiviteler sırasında kaydedilmiş EEG ve EMG işaretlerinin sınıflandırılması . Karadeniz Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Trabzon.
- Zhang, M., Yang, J., Ma, R., Du, Q., & Rodriguez, D. (2024). Retraction notice to Prediction of small-scale piles by considering lateral deflection based on Elman Neural Network-Improved Arithmetic Optimizer algorithm[ISA Trans. 127 (2022) 473-486]. ISA transactions, S0019-0578.
- Zhou, Y., Zhou, N., Gong, L., & Jiang, M. (2020). Prediction of photovoltaic power output based on similar day analysis, genetic algorithm and extreme learning machine. Energy, 204, 117894.

6. EKLER

<i>Yıl</i>	<i>Nüfus</i>	<i>Abone sayısı</i>	<i>GSYH (₺)</i>	<i>Yapı kullanma izin belgesi- Yüzölçüm : Toplam bina (m²)</i>	<i>Gümüşhane İli Enerji Tüketimi (MWh)</i>
2000	116008	26664	2365	20877	55533
2001	118147	27987	2897	22509	55902
2002	120166	29584	3499	25705	59215
2003	122175	31356	4343	30231	59991
2004	124267	32758	5877	32866	63851
2005	126423	33809	6646	104426	64654
2006	128628	34868	7567	109502	77479
2007	130825	36221	8295	69331	85267
2008	131367	37838	9294	93125	90993
2009	130976	39616	9516	187466	124028
2010	129618	41817	11455	138131	153344
2011	132374	43695	14329	143273	178640
2012	135216	45886	16016	146237	216981
2013	141412	47873	17448	251964	278693
2014	146353	50464	18114	204523	352615
2015	151449	52842	18932	233415	351318
2016	172034	55066	19929	155595	381120
2017	170173	57930	20934	227724	407315
2018	162748	66245	25678	276387	384188
2019	164521	73039	28997	246732	344599
2020	141702	78183	37932	122042	353746
2021	150119	84474	47555	194753	381823
2022	144544	92149	55632	152220	343190

Ek 1. AFT göre YSA kodu (BSA ve PSO algoritmaları parametrelerine göre uyarlandı.)

% 1. Excel Verilerini Okuma

```
filename = 'normalized_veriler.xlsx';
```

```
data = xlsread(filename);
```

% 2. Eğitim ve Test Verilerini Ayırma

```
% splitPercentage = input('Verilerin yüzde kaçını eğitim için ayırmak istiyorsunuz?  
(Örneğin, 0.8): ');
```

```
splitPercentage = 0.8
```

```
ndata=size(data,1);
```

```
splitIndex = round(splitPercentage * ndata);
```

```
%% % AFT parameters Veya PSO ve BSA kullanılacaksa npop yani popülasyon sayısı  
noThieves= 50;
```

```
%% % Algoritmadan istenilen parametre göre networka atama
```

```
%noP = 60;
```

```
%maxIter = 250 ;
```

```
%fobj = @costANNPso;
```

```
%IW=Network.IW{1,1}; IWnum=numel(IW);
```

```
%LW=Network.LW{2,1}; LWnum=numel(LW);
```

```
%b1=Network.b{1,1}; b1num=numel(b1);
```

```
%b2=Network.b{2,1}; b2num=numel(b2);
```

```
%toplamparams=IWnum+LWnum+b1num+b2num;
```

```
%dim=toplamparams;
```

```
%ub = 1*ones(1,toplamparams);
```

```
%lb = 0*ones(1,toplamparams);
```

```
%% Convergence curve
```

```
itemax=100;
```

```
ccurve=zeros(1,itemax);
```

```
input=data(:,1:4);
```

```
target=data(:,5);
```

```
traindata = data(1:splitIndex,:);
```

```
traininputs=(traindata(:,1:end-1));
traintarget=(traindata(:,end));
```

```
testdata= data(splitIndex+1:end,:);
testinputs=(testdata(:,1:end-1));
testtarget = (testdata(:,end));
```

```
%% creat network katmanlar
layers=[10 10];
transferfun={'tansig','purelin'};
```

```
Network=newfit(traininputs,traintarget,layers,transferfun);
%% % call AFT diğer BSA ve PSO için o network tanımına göre değiştirilebilir.
enetwork=AFT(Network,traininputs,traintarget);
%disp(['==> The optimal fitness value found by the AFT algorithm', num2str(1) ' is
', num2str(bFitnessAFT, 12)]);
sinavtr=sim(enetwork,traininputs);
hatatr=(sinavtr-traintarget);
sinavts=sim(enetwork,testinputs);
hatats=(sinavts-testtarget);
```

```
%% Grafikler
figure;
subplot(2,2,[1 2])
plot(traintarget,'b')
hold on
plot(sinavtr,'r')
legend('gercek','ysadan gelen sonuc')
title('Train Data')
subplot(2,2,3)
plot(hatatr)
legend('hatalar')
```

```
subplot(2,2,4)
histfit(hatatr)
legend('histogram')
```

```
figure;
subplot(2,2,[1 2])
plot(testtarget,'b')
hold on
plot(sinavts,'r')
legend('gercek','ysadan gelen sonuc')
title('Test Data')
subplot(2,2,3)
plot(hatats)
legend('hatalar')
```

```
subplot(2,2,4)
histfit(hatats)
legend('histogram')
ortalama1=mean(hatatr)
disp(ortalama1)
ortalama2=mean(hatats)
disp(ortalama2)
```

```
% Doğruluk Analizi
mse_train = mean(hatatr.^2);
rmse_train = sqrt(mse_train);
r2_train = 1 - mse_train / var(traintarget);
```

```
mse_test = mean(hatats.^2);
rmse_test = sqrt(mse_test);
r2_test = 1 - mse_test / var(testtarget);
```

```
fprintf('Eğitim Verileri:\n');
fprintf('MSE: %f\n', mse_train);
fprintf('RMSE: %f\n', rmse_train);
fprintf('R Kare (R2): %f\n', r2_train);
```

```
fprintf('\nTest Verileri:\n');
fprintf('MSE: %f\n', mse_test);
fprintf('RMSE: %f\n', rmse_test);
fprintf('R Kare (R2): %f\n', r2_test);
```

```
%YSA gösterimi
view(enetwork)
%%creatnet.m fonksiyonu
function newtwork2=creatnet(x,network)
IW=network.IW{1,1}; IWnum=numel(IW);
LW=network.LW{2,1}; LWnum=numel(LW);
b1=network.b{1,1}; b1num=numel(b1);
b2=network.b{2,1}; b2num=numel(b2);
toplamparams=IWnum+LWnum+b1num+b2num;
IWsx=x(1:IWnum);
IWnew=reshape(IWsx,size(IW,1),size(IW,2)); x=x(IWnum+1:end);
LWsx=x(1:LWnum);
LWnew=reshape(LWsx,size(LW,1),size(LW,2)); x=x(LWnum+1:end);
b1sx=x(1:b1num); b1new=reshape(b1sx,size(b1,1),size(b1,2)); x=x(b1num+1:end);
b2sx=x(1:b2num); b2new=reshape(b2sx,size(b2,1),size(b2,2));
newtwork2=network;
newtwork2.IW{1,1}=IWnew;
newtwork2.LW{2,1}=LWnew;
newtwork2.b{1,1}=b1new;
newtwork2.b{2,1}=b2new;
end
```

Ek 2. Eğitim Kodu (TrainingPSO kodu diğer AFT ve BSA göre uyarlandı.)

```

function Newnetwork=TrainingPso(network,Xtr,Ytr)
    %% difinition problem
    costfunction=@costANNPso;
    IW=network.IW{1,1}; IWnum=numel(IW);
    LW=network.LW{2,1}; LWnum=numel(LW);
    b1=network.b{1,1}; b1num=numel(b1);
    b2=network.b{2,1}; b2num=numel(b2);
    toplamparams=IWnum+LWnum+b1num+b2num;
    nvar=toplamparams;
    varsize=[1 nvar];
    varmin=-1*ones(1,toplamparams);
    varmax=1*ones(1,toplamparams);
    function cost=costANNPso(xx,network,Xtr,Ytr)
    cost=zeros(size(xx,1),1);
    for i=1:size(xx,1)
        x=xx(i,:);
        newnetwork2=creatnet(x,network);
        Netytr=sim(newnetwork2,Xtr);
        c=mse(Netytr-Ytr);
        cost(i,1)=c;
    end
end

    %% pso parameters
    maxit=250;
    npop=50;
    w=1;
    wdamp=0.99;
    c1=1;
    c2=1;
    %% initialization

```

```

bos_parca.pozisyon=[];
bos_parca.velocity=[];
bos_parca.cost=[];
bos_parca.best.pozisyon=[];
bos_parca.best.cost=[];
Globalbest.pozisyon=[];
Globalbest.cost=inf;
parca=repmat(bos_parca,npop,1);
for i=1:npop
    parca(i).pozisyon=unifrnd(varmin,varmax,varsiz);
    parca(i).cost=costfunction(parca(i).pozisyon,network,Xtr,Ytr);
    parca(i).valocity=zeros(varsiz);
    parca(i).best.pozisyon=parca(i).pozisyon;
    parca(i).best.cost=parca(i).cost;
    if parca(i).cost<Globalbest.cost
        Globalbest.pozisyon=parca(i).pozisyon;
        Globalbest.cost=parca(i).cost;
    end
end
bestcost=zeros(maxit,1);
%% main loop
for it=1:maxit
    for i=1:npop
        parca(i).valocity=w*parca(i).valocity...
            +c1*rand(varsiz).*(parca(i).best.pozisyon-parca(i).pozisyon)...
            +c2*rand(varsiz).*(Globalbest.pozisyon- parca(i).pozisyon);
    % update pozisyon
    parca(i).pozisyon=parca(i).pozisyon+parca(i).valocity;
    % evalute
    parca(i).cost=costfunction(parca(i).pozisyon,network,Xtr,Ytr);
    % update personal best
    if parca(i).cost<parca(i).best.cost
        parca(i).best.pozisyon=parca(i).pozisyon;

```

```

        parca(i).best.cost=parca(i).cost;
        if parca(i).best.cost<Globalbest.cost
            Globalbest=parca(i).best;
        end
    end
    %update Global
end
bestcost(it)=Globalbest.cost;
%%disp(['itration' num2str(it) ': bestcost ' num2str(bestcost(it))]);
w=w*wdamp;
end
%% results
%%figure;
%plot(bestcost);
    Globalbest.pozisyon;
Newnetwork=creatnet(Globalbest.pozisyon,network);
end

```

Ek 3. Normalizasyon Kodu

```
% Excel dosyasından veriyi oku
veri = xlsread('tuketim_gumushane.xls');
% Her sütunu ayrı ayrı normalize et
[a, y] = size(veri);
for i = 1:n
    min_val = min(veri(:, i));
    max_val = max(veri(:, i));
    veri(:, i) = (veri(:, i) - min_val) / (max_val - min_val);
end
% Normalized veriyi ekrana yazdır (isteğe bağlı)
disp('Normalized Veri:');
disp(veri);
% Normalized veriyi yeni bir Excel dosyasına yazdır
writematrix(veri, 'normalized_veri.xlsx');
disp('Normalized veri "normalized_veri.xlsx" dosyasına yazıldı.');
```

ÖZGEÇMİŞ

İlköğretim, ortaöğretim ve lise eğitimini Gümüşhane’de tamamladı. Karadeniz Teknik Üniversitesi Mühendislik Fakültesi Elektrik Elektronik Mühendisliği bölümünden 2018 yılında mezun oldu. 2019 yılında Karadeniz Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Elektrik Elektronik Mühendisliği Anabilim dalında Elektrik bölümünde tezli yüksek lisans programına başladı. DENEYAP atölyesinde yazılım teknolojileri ve ileri robotik alanında eğitmenlik yapmaktadır. Evli ve bir çocuk annesidir.

Yayınlar:

Performans Analysis of Energy Consumption Prediction with Chameleon Swarm Algorithm, Arceng International Sciences Conference, Ankara, Türkiye, February 03-04, 2024.