



T.C.

**BATMAN ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**

**MAKİNE ÖĞRENMESİ ALGORİTMALARI
KULLANILARAK 2040 YILINA KADAR TÜRKİYE’NİN
ENERJİ TALEP TAHMİNİ**

Hakan ERDEMCI

YÜKSEK LİSANS TEZİ

Elektrik-Elektronik Mühendisliği Anabilim Dalı

**Haziran-2023
BATMAN
Her Hakkı Saklıdır**

TEZ KABUL VE ONAYI

Hakan ERDEMCİ tarafından hazırlanan “Makine öğrenmesi algoritmaları kullanılarak 2040 yılına kadar Türkiye’nin enerji talep tahmini” adlı tez çalışması 09/06/2023 tarihinde aşağıdaki jüri tarafından oy birliği ile Batman Üniversitesi Lisansüstü Eğitim Enstitüsü Elektrik-Elektronik Mühendisliği Anabilim Dalı’nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Jüri Üyeleri

İmza

Başkan

Dr. Öğr. Üyesi Cafer BUDAK

.....

Danışman

Dr. Öğr. Üyesi Ömer Ali KARAMAN

.....

Üye

Dr. Öğr. Üyesi Şehmus FİDAN

.....

Yukarıdaki sonucu onaylarım.

Prof. Dr. Osman PAKMA
Lisansüstü Eğitim Enstitüsü Müdür V.

TEZ BİLDİRİMİ

Bu tezdeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edildiğini ve tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

DECLARATION PAGE

I hereby declare that all information in this document has been obtained and presented in accordance with academic rules and ethical conduct. I also declare that, as required by these rules and conduct, I have fully cited and referenced all material and results that are not original to this work.

Hakan ERDEMCİ

Tarih:

ÖZET

YÜKSEK LİSANS

MAKİNE ÖĞRENMESİ ALGORİTMALARI KULLANILARAK 2040 YILINA KADAR TÜRKİYE’NİN ENERJİ TALEP TAHMİNİ

Hakan ERDEMCİ

Batman Üniversitesi Lisansüstü Eğitim Enstitüsü
Elektrik-Elektronik Mühendisliği Anabilim Dalı

Danışman: Dr. Öğr. Üyesi Ömer Ali KARAMAN

2023, 60 Sayfa

Jüri

Dr. Öğr. Üyesi Cafer BUDAK
Dr. Öğr. Üyesi Ömer Ali KARAMAN
Dr. Öğr. Üyesi Şehmus FİDAN

Nüfusun artışı ile birlikte sanayileşmenin hızla artması enerji ihtiyacını da artırmıştır. Bununla birlikte ortaya çıkan bu enerji ihtiyacını karşılayabilmek için ön görülebilecek enerji tahminlerini yapabilmek için makine öğrenme algoritmaları ön plana çıkmıştır. Parçacık sürü optimizasyonu (PSO), yapay sinir ağları (YSA) ve destek vektörü regresyonu (DVR) bu algoritmalar içerisinde yer almaktadır. Bu çalışmada PSO, YSA ve DVR algoritmaları kullanılarak Türkiye’nin 2020-2040 yılları arasında elektrik enerjisi talep tahminlemesi yapılmıştır. Bu tahminleme işlemlerinin yapılabilmesi için 1980-2019 yılları arasında yıllık elektrik tüketim verileri TEİAŞ’tan (Türkiye Elektrik İletim Anonim Şirketinden), nüfus verileri TÜİK’ten (Türkiye İstatistik Kurumundan), ihracat, ithalat, gayri safi yurtiçi hâsıla (GSYH) verileri Dünya Bankası açık veri kümesinden alınmıştır. PSO, YSA ve DVR enerji talep modelleri nüfus, ihracat, ithalat, GSYH verileri kullanılarak geliştirilmiştir. Türkiye’nin sosyoekonomik durumu göz önünde bulundurularak enerji talebi üç farklı senaryoya göre düzenlenmiştir. PSO, YSA ve DVR yöntemlerinin performans sonuçlarını değerlendirebilmek için Kök Ortalama Kare Hata (KOKH), Ortalama Kare Hata (OKH) ve Ortalama Mutlak Hata (OMH) hata metrikleri ve R^2 değerleri karşılaştırıldı. Hata metrik değerleri incelendiğinde YSA’nın diğer yöntemlere kıyasla daha başarılı sonuçlar verdiği söylenebilir.

1980-2019 yılları arasında gerçekleşen, bağımsız girdi parametreleri olan nüfus, ihracat, ithalat ve GSYH değerleri ile bağımlı çıktı olan enerji tüketimi arasındaki ilişki korelasyon matrisi kullanılarak incelenmiştir. Korelasyon matrisinde 0,991 değeri ile ihracat ve enerji tüketimi arasında güçlü bir doğrusal ilişki olduğu gözlemlenmiştir. Ayrıca Çoklu regresyon denklemleri oluşturulmuştur. Parametreleri (X_1, X_2, X_3, X_4) olan ithalat, ihracat, GSYH, nüfus) bazında F denklemi üzerinden tahminin performans değerlendirmesi yapılmıştır. Dört parametreyi (X_1, X_2, X_3, X_4) içeren regresyon denklemi en yüksek (0,995) R^2 değerine sahip olup kapsamlı bir temsiliyete sahip olduğu anlaşılmıştır.

Anahtar Kelimeler: Destek vektörü regresyonu, Enerji talep tahmini, Parçacık sürü optimizasyonu, Yapay sinir ağları.

ABSTRACT

MS THESIS

TURKEY'S ENERGY DEMAND FORECAST UNTIL 2040 USING MACHINE LEARNING ALGORITHMS Hakan ERDEMCİ

THE GRADUATE EDUCATION INSTITUTE OF BATMAN UNIVERSITY THE DEGREE OF MASTER OF SCIENCE IN ELECTRIC-ELECTRONIC ENGINEERING

Advisor: Asst. Prof. Dr. Ömer Ali KARAMAN

2023, 60 Pages

Jury

**Asst. Prof. Dr. Cafer BUDAK
Asst. Prof. Dr. Ömer Ali KARAMAN
Asst. Prof. Dr. Şehmus FİDAN**

The rapid increase in industrialization, coupled with population growth, has led to an increased energy demand. However, machine learning algorithms have come to the forefront to make anticipatory energy predictions to meet this emerging energy demand. Particle Swarm Optimization (PSO), Artificial Neural Networks (ANN), and Support Vector Regression (SVR) are among these algorithms. In this study, electricity demand forecasting for Turkey between 2020 and 2040 was conducted using the PSO, ANN, and SVR algorithms. To perform these prediction processes, annual electricity consumption data from 1980 to 2019 were obtained from TEİAŞ (Turkey Electricity Transmission Corporation), population data from TÜİK (Turkish Statistical Institute), and export, import, gross domestic product (GDP) data from the World Bank open data set. PSO, ANN, and SVR energy demand models were developed using population, export, import, and GDP data. Considering Turkey's socioeconomic situation, the energy demand was adjusted according to three different scenarios. Root Mean Square Error (RMSE), Mean Square Error (MSE), Mean Absolute Error (MAE), and R^2 values were compared as error metrics to evaluate the performance results of the PSO, ANN, and SVR methods. When examining the error metric values, it can be said that ANN provides more successful results compared to the other methods.

The correlation matrix was used to examine the relationship between energy consumption, which is the dependent output, and independent input parameters such as population, export, import, and GDP values that occurred between 1980 and 2019. A strong linear relationship between export and energy consumption was observed with a correlation value of 0.991 in the correlation matrix. Additionally, multiple regression equations were formed. Performance evaluation of prediction based on the four parameters (X_1 , X_2 , X_3 , X_4) of import, export, GDP, and population was conducted using the F equation. The regression equation containing all four parameters had the highest R^2 value of 0.995, indicating a comprehensive representation.

Keywords: Artificial neural networks, Energy demand forecast, Particle swarm optimization, Support vector regression.

ÖNSÖZ

Bu tez çalışmasının hazırlanmasında bana her yönüyle rehberlik eden, bilgi ve tecrübesini aktarmada kendisini eksik etmeyen, çalışma sürecinin son gününe kadar her türlü fedakârlığı gösteren ve ayrıca kıymetli zamanını esirgmeden tezimin yazımı ve düzenlenmesi konularında her yönüyle katkı sunan danışman hocam Sayın Dr. Öğr. Üyesi **Ömer Ali KARAMAN**' a, desteklerini esirgemeyen Sayın Öğr. Gör. **İLKER ARI**' ya, Sayın Öğr. Gör. **Edip ERTUĞRUL**'a teşekkürlerimi sunarım.

Ayrıca;

Eğitim hayatım boyunca, benim için en iyi şartları sağlayan, daima fedakâr davranan ve bugünlere gelmeme vesile olan saygıdeğer anneme ve babama şükranlarımı sunar, tez çalışmasının her aşamasında desteklerini esirgemeyen eşime, çocuklarım Ebrar ve Muhammed Buğra'ya sevgilerimi sunarım.

Hakan ERDEMCİ
BATMAN-2023

İÇİNDEKİLER

ÖZET	iv
ABSTRACT.....	v
ÖNSÖZ	vi
İÇİNDEKİLER	vii
ŞEKİLLER.....	ix
ÇİZELGELER.....	x
SİMGELER VE KISALTMALAR	xi
1. GİRİŞ	1
1.1. Literatür Araştırması	1
2. MATERYAL VE METOT.....	6
2.1. Parçacık Sürü Optimizasyonu	6
2.1.1 Parçacık sürü optimizasyonu kavramları	9
2.1.2 Parçacık sürü optimizasyonu parametreleri	12
2.1.3 Parçacık etkileşimleri	15
2.1.4 Komşuluk topolojileri	15
2.1.5 Algoritma	15
2.2. Yapay Sinir Ağları	16
2.2.1 YSA'nın tanımı	16
2.2.2 Yapay sinir ağlarının temel görevi	17
2.2.3 Yapay sinir ağlarının genel özellikleri	17
2.2.4 Biyolojik sinir ağları	19
2.2.5 YSA hücresi	21
2.2.6 Yapay sinir ağı modelleri	24
2.2.7 Öğrenme algoritmaları	25
2.3. Destek Vektör Regresyon	29
2.3.1 Doğrusal destek vektör regresyon	30
2.3.2 Doğrusal olmayan destek vektör regresyon	33
2.4. Hata Metrikleri	34
2.5. Veri Kaynakları	35
3. ARAŞTIRMA SONUÇLARI VE TARTIŞMA.....	36
3.1. Parçacık Sürü Optimizasyonu ile Enerji Talep Tahmini	38
3.2. Yapay Sinir Ağları ile Enerji Talep Tahmini	42
3.3. Destek Vektörü Regresyonu ile Enerji Talep Tahmini	45

3.4.	PSO-YSA ve DVR Modellerinin Tahmin Karşılaştırması	48
3.5.	PSO-YSA ve DVR Model Tahminlerinin Performans Sonuçları.....	49
3.6.	Çoklu Regresyon Denklemleri.....	49
4.	SONUÇ ve ÖNERİLER	51
KAYNAKLAR		53
5.	ÖZGEÇMİŞ	60



ŞEKİLLER

Şekil 2.1. Parçacık sürü optimizasyonu akış diyagramı	16
Şekil 2.2. Biyolojik sinir ağının şeması	19
Şekil 2.3. Biyolojik sinir ağının basitleştirilmiş yapısı	20
Şekil 2.4. Basit bir yapay sinir hücresi (nöron) yapısı	21
Şekil 2.5. İleri beslemeli yapı	24
Şekil 2.6. Geri beslemeli yapı	24
Şekil 2.7. Çok katmanlı sinir ağı	26
Şekil 2.8. Kayıp fonksiyonları	30
Şekil 2.9. Doğrusal regresyon fonksiyonu için ε tüpü	30
Şekil 2.10. Doğrusal destek vektör regresyon	31
Şekil 2.11. Doğrusal olmayan regresyon fonksiyonu için ε tüpü	33
Şekil 3.1. 1980-2019 yılları arası gerçekleşen enerji tüketim değeri ve PSO enerji tahmini	39
Şekil 3.2. 2020-2040 yılları arası senaryolara göre PSO model ile enerji talep tahmini	41
Şekil 3.3. 1980-2019 yılları arası gerçekleşen enerji tüketim değeri ve YSA enerji tahmini	42
Şekil 3.4. 2020-2040 yılları arası senaryolara göre YSA enerji talep tahmini	45
Şekil 3.5. 1980-2019 yılları arası gerçekleşen enerji tüketim değeri ve DVR enerji tahmini	45
Şekil 3.6. 2020-2040 yılları arası senaryolara göre DVR enerji talep tahmini	48
Şekil 3.7. 1980-2019 yılları arası gerçekleşen enerji tüketim değeri ile PSO-YSA-DVR modelleri sonucu elde edilen enerji tahmin değerleri	48

ÇİZELGELER

Çizelge 2.1. Biyolojik sınır sistemi ve YSA'nın karakteristiği	20
Çizelge 2.2. Toplama fonksiyonu türleri (Öztemel, 2006)	23
Çizelge 2.3. Eğitim algoritmaları.....	28
Çizelge 3.1. 1980-2019 Yılları arasında gerçekleşen ekonomik ve enerji göstergeleri .	36
Çizelge 3.2. Bağımlı ve bağımsız değişkenler arasındaki korelasyon matrisi.....	37
Çizelge 3.3. Tahmin için oluşturulan senaryolar	38
Çizelge 3.4. 1980-2019 Yılları arasında PSO modelin tahmin hataları.....	39
Çizelge 3.5. 1980-2019 Yılları arasında PSO modelin tahmin hataları.....	40
Çizelge 3.6. PSO modeli ile düşük, orta ve yüksek senaryoya göre enerji talep tahmini	41
Çizelge 3.7. 1980-2019 yılları arasında YSA modelin tahmin hataları.....	43
Çizelge 3.8. YSA model ile düşük, orta ve yüksek senaryoya göre enerji talep tahmini	44
Çizelge 3.9. 1980-2019 Yılları arasında DVR ile oluşturulan modelin tahmin hataları	46
Çizelge 3.10. DVR ile düşük, orta ve yüksek senaryoya göre enerji talep tahmini	47
Çizelge 3.11. Anakara istatistiksel analiz sonuçları	49
Çizelge 3.12. Çoklu alt küme parametreleri, regresyon denklemleri ve R^2 performansı	49

SİMGELER VE KISALTMALAR

Simgeler

w^T	: Ağırlık transpozesi
ξ	: Aylak değişken
y_i	: Bağımlı değişken
β	: Eğim sabiti
c_1	: Genelde 2 olarak alınan bu katsayı, bilişsel öğrenme oranı olarak tanımlanır.
c_2	: Genelde 2 olarak alınan bu katsayı, sosyal öğrenme oranı tanımlanır.
ε	: Hata terimi
E_{linear}	: Lineer model
μ	: Momentum
h_{nd}^t	: n. Parçacığa ait d değişkenin t. çevrimde elde edilen hızı
Σ	: Net girişi belirleyen toplama fonksiyonu
V_{max}	: Sürü içerisindeki her bir parçacığın maksimum hız değeri
e_i	: Tahmin edilen değerler
$E_r^{gözlemlenen}$	: 1980-2019 yılları arasındaki tüketilen enerji
$E_r^{tahmin edilen}$	: 2020-2040 yılları arasında tahmin edilen enerji
$geniyi_{nd}^t$	: Komşu parçacıklar içerisinde t. çevrime kadar geçen en iyi d değişken değeri
$mevcut_{nd}^t$	: n. Parçacığa ait d değişkenin t. çevrimdeki değeri
$peniyi_{nd}^t$	: n. Parçacık için t. çevrime kadar geçen süredeki elde edilen en iyi d değişken değeri
r_1, r_2	: Rastlantı olarak baz alınan 0-1 aralığındaki değerler
b	: Eşik değeri (bias)
C	: Ceza parametresi
$e(k)$	: Hata
$J(x)$	: Jacobian matrisi
NET	: Ağa gelen net girdi
$o(k)$	: Sinir ağı çıkışı
$Out(o)$	: Çıkışlar matrisi
W	: Ağırlıklar
w	: Eylemsizlik (dinginlik) katsayısı
X	: Girdiler
$y(k)$	: Gerçek çıkış
R^2	: Açıklayıcılık katsayısı

Kısaltmalar

ABC	Yapay Arı Kolonisi
ABSO	Yapay Arı Sürüş Optimizasyonu
ACO	Karınca Kolonisi Optimizasyonu
DPT	Devlet Planlama Teşkilatı
DVR	Destek Vektörü Regresyonu
ETKB	Enerji ve Tabii Kaynaklar Bakanlığı
GA	Genetik Algoritma
GBEST	Geniyi
GSYH	Gayri Safi Yurtiçi Hâsıla
HPSO	Hibrit Bir Parçacık Sürü Optimizasyonu
HS	Harmoni Arama
IBEDC	İbadan Elektrik Dağıtım A.Ş.
LM	Levenberg - Marquardt Algoritması
LR	Doğrusal Regresyon
MAE	Ortalama Mutlak Hatayı
MAPE	Ortalama Mutlak Yüzde Hatası
MLR	Çoklu Doğrusal Regresyon
MSE	Ortalama Kare Hatası
NLR	Doğrusal Olmayan Regresyon
PBEST	Peniyi
PSO	Parçacık Sürü Optimizasyon
RBF	Radyal Temel Fonksiyon
RMSE	Kök Ortalama Kare Hatası
TEİAŞ	Türkiye Elektrik İletim A.Ş.
TÜİK	Türkiye İstatistik Kurumu
YSA	Yapay Sinir Ağlar
LM	Levenberg-Marquardt

1. GİRİŞ

Günümüzde teknolojik gelişmelere ve nüfus artışına bağlı olarak enerji ihtiyacı artmaktadır. Artan bu enerji ihtiyacı içerisinde elektrik enerjisi büyük bir paya sahiptir. Gelişmekte olan ekonomiler için teknoloji, sağlık, üretim, hizmet gibi birçok farklı alanda sürdürülebilir büyümeyi sağlamak için enerji kaynaklarının uzun vadeli planlanması zorunludur. Bu planlamaları yaparken ülkenin dinamiklerinin göz önünde bulundurulduğu parametrelerden faydalanılmalıdır. İthalat, nüfus, GSYH ve ihracat gibi sayısal veriler ülkenin büyümesine dair parametreler olarak kullanılabilir. Bu parametreler en uygun çözüm üretebilecek makine öğrenmesi ve optimizasyon yöntemleriyle modellenerek enerji için gerekli alt yapı tesisinin planlanması ve bu alanda yatırımların artırılması sağlanabilir.

Bu çalışmada için literatür araştırması yapılmış ve benzer yöntemlerin performansları incelenmiştir. 2. Bölüm olan materyal ve metot başlığı altında PSO, YSA ve DVR modellerinin tanımlarına, genel özelliklerine ve algoritmalarına değinilmiştir. 3. Bölüm olan uygulama başlığı altında GSYH, ithalat, nüfus ve ihracat verilerinin 1980-2019 yılları arasında gerçekleşen verileri kullanarak PSO, YSA ve DVR yöntemleriyle 2020-2040 yılları arasındaki Türkiye'nin elektrik enerji talep tahmininin yapılarak modellerin sonuçları karşılaştırılmıştır. Hata metrikleri ve korelasyon katsayısı ile PSO, YSA ve DVR modellerinin performansları ölçülmüştür. Performans testleri sonucu kullanılan üç yöntemin enerji tahmininde verimliliklerini ortaya koymuştur.

1.1. Literatür Araştırması

Türkiye'nin enerji taleplerinin tahminleme süreci 1960 yılında başladı. Devlet Planlama Teşkilatı (DPT) tarafından farklı regresyon yöntemleri ile tahminlemeler yapıldı. Geçen yıllar içerisinde gelişen ve değişen farklı yöntem ve teknikler kullanılarak enerji talep tahminleri yapıldı. Literatür taramaları yapılarak enerji talep tahminlemesine ilişkin önceki yıllarda yapılan çalışmalardan bazılarına aşağıda değinilmiştir.

Bianco ve ark. (2009) tarafından yapılan çalışmada, İtalya'da ekonomik ve demografik değişkenlerin uzun vadeli bir tüketim tahmini üzerindeki etkisi doğrusal regresyon (LR) modeli kullanılarak araştırılmıştır. 1970'den 2007'ye kadar gerçekleşen elektrik tüketimi, GSYH, kişi başına GSYH ve nüfus verileri kullanılmıştır. Geliştirilen

regresyonun en iyi durum için $\pm\%1$ ve en kötü için $\pm\%11$ sapmalarla resmi tahminlerle uyumlu olduğu gözlemlenmiştir (Bianco ve ark., 2009).

Kavaklıoğlu (2011) tarafından yapılan çalışmada, Türkiye'nin elektrik tüketim ve tahminlemesi için DVR metodolojisi kullanılmıştır. İthalat, nüfus, GSYH ve ihracat parametrelerinin 1975-2006 yılları arasında gerçekleşmiş olan veriler kullanılarak çalışma yapılmıştır. 2026 yılına kadar yapılan tahminlemede DVR metodolojisi kullanılarak modelleme yapılabileceği ve bu modelin elektrik enerjisi tüketimini tahmin etmek için kullanılabileceği gözlemlenmiştir (Kavaklıoğlu, 2011).

Kankal ve ark. (2011) tarafından çalışmada, Türkiye'nin İthalat, nüfus, GSYH, istihdam ve ihracat parametrelerinden faydalanılarak YSA modeli oluşturularak enerji tahmini yapılmıştır. Bu amaçla, analizlerde farklı göstergeler içeren dört farklı model kullanılmıştır. YSA tarafından tahmin edilen sonuçlar, resmi tahminlerle karşılaştırılmıştır. YSA enerji tahmin sonuçlarının resmi projeksiyon rakamlarına göre daha düşük enerji tüketimi tahminleri verdiği gözlemlenmiştir (Kankal ve ark., 2011).

Assareh ve ark. (2012) tarafından yapılan çalışmada, İran'ın sanayi ve ekonomik yapısına ilişkin veriler göz önünde bulundurularak PSO ve genetik algoritmaları (GA) ile 2006-2030 yılları arasında ülkenin enerji talebini tahmin etmek amaçlanmıştır. 1981-2005 yılları arasındaki nüfus, GSYH, ithalat ve ihracat verileri kullanılarak optimizasyon yapılmıştır. PSO ve GA algoritmaları ile elde edilen sonuçlar gerçekleşen veriler ile kıyaslanmış ve uyum içinde olduğu görülmüştür. Gerçekleşen değerler için PSO'nun daha optimal sonuçlar verdiği sonucuna ulaşılmıştır (Assareh ve ark., 2012).

Kıran ve ark. (2012) tarafından yapılan çalışmada, PSO ve yapay arı kolonisi (ABC) optimizasyonları kullanılarak Türkiye'deki 2025 yılına kadar elektrik enerjisi talep tahmini yapılmıştır. Türkiye'nin ithalat, ihracat, nüfus ve GSYH verileri girdi olarak modellere dahil edilmiştir. Tüm modeller lineer ve kuadratik olmak üzere iki formda önerilmiştir. Önerilen modellerin bağıl tahmin hataları karınca kolonisi optimizasyonun'dan (ACO) daha düşük olduğu gözlemlenmiştir (Kıran ve ark., 2012).

Bilgili ve ark. (2012) tarafından yapılan çalışmada, Türkiye'de enerji sarfiyatının yoğun olduğu sanayi ve konut kollarının elektrik enerjisine olan taleplerini tahminlemek için LR, YSA algoritma metodolojisi ve doğrusal olmayan regresyon (NLR) çeşitleri çalışılmıştır. Burada bağımsız değişkenler için brüt elektrik üretimi, kurulu güç, toplam abone sayısı ve nüfus seçilmiştir. Çalışma neticesinde ortaya çıkan sonuçlar Enerji ve Tabii Kaynaklar Bakanlığı'na (ETKB) ait tahminler ile kıyas edilmiş, LR ve NLR

modellerinin deęerlerinin YSA algoritmasına ait deęerlerinden daha dūřuk performans gōsterdięi gōzlemlenmiřtir (Bilgili ve ark., 2012).

Moturi ve Kioko (2013) tarafından yapılan alıřmada, kısa vadeli elektrik yk tahmini iin denetimli YSA tabanlı bir model geliřtirilmiř ve bir gnlk yk nceden tahmin etmek iin Kenya Ulusal řebeke g sisteminin gerek yk verilerini uygulayarak modelin performansı deęerlendirilmiřtir. Yapılan testlerin sonucunda, yk tahmini iin saat bařı yaklařımın daha uygun ve verimli olduęu gōzlemlenmiřtir (Moturi ve ark., 2013).

Kialashaki ve Reisel (2014) tarafından yapılan alıřmada, Amerika Birleřik Devletleri'ndeki endstriyel enerji tahminlemesini yapmak iin YSA ve oklu doęrusal regresyon (MLR) teknięi kullanılmıřtır. YSA modeli, 2012'den 2030'a kadar enerji talebinde % 16'lık bir artıř ngrmřtir. YSA modelinin sonuları, ABD Enerji Bakanlığı Enerji Bilgi İdaresi'nden alınan projeksiyonlarla karřılařtırılmıř ve YSA teknięinin girdi/ıktı haritalamasını etkin bir řekilde gerekleřtirebilen gvenilir ve gl bir teknik olduęu gōzlemlenmiřtir (Kialashaki ve ark., 2014).

Yu ve ark. (2015) tarafından yapılan alıřmada, hibrit bir paracık sr optimizasyonu (HPSO) ve GA ile optimize edilmiř radyal temel fonksiyon (RBF) sinir aęı ile yıllık elektrik talebi tahmini yapılmıřtır. PSO–GA-RBF modelinin dięer seilmiř YSA modellerinden daha basit bir aę yapısına veya daha yksek tahmin hassasiyetine sahip olduęu ve senaryo ne olursa olsun, Wuhan'ın elektrik tketiminin, yaklařık %9,7-11,5'lik ortalama yıllık byme oranlarında arttıęı gōzlemlenmiřtir (Yu ve ark., 2015).

Masaebi (2016) tarafından yapılan alıřmada, Sanayi ve teknoloji alanlarında hızla artan enerji ihtiyacına karřın ithalat, nfus, GSYH ve ihracat parametrelerinin 1978-2014 yılları arasındaki verileri kullanılarak İran'ın 2016-2021 yılları arasındaki enerji talebi YSA yntemiyle modellenmiřtir. alıřmada kullanılan verilerin girdi ve ıktıları arasındaki iliřkinin kurulması karmařık olsa da YSA ile elde edilen sonuların gerekleřen enerji verilerine yakın olduęu gōzlemlenmiřtir (Masaebi, 2016).

Kaynar ve ark. (2016) tarafından yapılan alıřmada, Trkiye'nin ithalat, ihracat, GSYH, elektrik tketimi ve nfus verilerinin 1975-2014 yılları arasında gerekleřen deęerleri baz alınarak DVR yntemiyle tahminleme yapılmıřtır. Yapılan tahmin uygulamasında %3.66 hata performansı elde edilmiř ve DVR ynteminin bařarılı olduęu ve sıka kullanılan YSA ve klasik regresyon yntemlerine alternatif olarak kullanılabileceęi nerilmiřtir (Kaynar ve ark., 2016).

Gülcü ve Kodaz (2017) tarafından yapılan çalışmada, Türkiye'nin gelecekteki elektrik enerjisi talebinin tahmini için ithalat, ihracat, GSYH ve nüfus verileri kullanılarak PSO modellemesi yapılmıştır. Deneysel sonuçlar, oluşturulan PSO modelinin çok verimli olduğunu göstermiştir (Gülcü ve ark., 2017).

Özkan (2018) tarafından yılında yapılan çalışmada, 1979-2015 yılları arasındaki GSYH, nüfus, ithalat ve ihracat verileri kullanılarak PSO ve GA algoritma teknikleri ile Türkiye'nin 2018-2050 yılları arasındaki enerji talep tahminlemesi yapılmıştır. Dört farklı senaryo oluşturulmuştur. Bu dört senaryoya ait yüzde doğruluk ölçüt değerlerine bakıldığında tahmin doğruluğu açısından GA'ya ait değerlerin PSO algoritmalarının gerisinde kaldığı gözlemlenmiştir (Özkan, 2018).

Martins ve ark. (2019) tarafından yapılan çalışmada, Ogun eyaletindeki 10 yıllık enerji talep tahminini yapmak için LR tekniği kullanılmıştır. Elde edilen sonuçlarda enerji talebinde 2028 yılına kadar %53'lük bir artış göstereceği gözlemlenmiştir. Bu sonuçların operasyonel ve planlama faaliyetleri için Ibadan Elektrik Dağıtım A.Ş.' ye (IBEDC) çok faydalı olacağı anlaşılmıştır. (Martins ve ark., 2019).

Yakut ve Özkan (2020) tarafından yapılan çalışmalarında, Enerjinin stratejik bir konumda olduğu günümüz dünyasında Türkiye'de 2018-2050 yılları arasında gereksinim duyulan enerji tüketimini tahmin etmek için PSO ve GA modelleri kullanılmıştır. İthalat, nüfus, GSYH ve ihracat parametrelerinin 1979-2017 yılları arasındaki verileri kullanılmıştır. Enerji tahmininde optimal değere ulaşabilmek için hızlı ekonomik gelişmeler, hükümet kararları, teknoloji ve diğer faktörlerden oluşan 4 farklı senaryo oluşturulmuştur. Çalışmalar neticesinde PSO ve GA algoritmalarının MAPE değerlerinin %20'nin altında olması nedeniyle iyi sonuç veren modeller arasında yer alabileceği sonucuna ulaşmışlardır. MSE, MAPE ve RMSE sonuçları göz önünde bulundurulduğunda, PSO'nun GA'ya göre daha optimal sonuçlar verdiği görülmüştür (Yakut ve ark., 2020).

Kayakuş (2020) tarafından yapılan çalışmada, Türkiye'de Ocak 2016-Mart 2020 tarihleri arasındaki dönemlerde gerçekleşen aylık elektrik tüketim verileri kullanılarak enerji tahminlemesi için bir model geliştirilmiştir. Bu modelde DVR ve YSA kullanılmıştır. On beş bağımsız değişken değeri girdi olarak kullanılmış ve Türkiye'nin enerji tüketim değeri bağımlı değişken olarak tahmin edilmiştir. Çalışma verileri neticesinde YSA yönteminde DVR yöntemine göre daha başarılı sonuçlar elde edildiği gözlemlenmiştir (Kayakuş, 2020).

Karaman ve Sağlam (2022) tarafından yapılan çalışmada; PSO ve LR yöntemleri kullanılarak kişi başına tüketilecek enerji talebi tahmin edilmiştir. Hem PSO hem de LR Yöntemleri ile elde edilen sonuçlar MSE, RMSE ve MAE gibi istatistiksel hatalar kullanılarak analiz edilmiştir. Bu yöntemlerin analizi için 1980 ile 2019 yılları arasındaki nüfus, ithalat, ihracat ve GSYH gibi veriler giriş parametreleri olarak kullanılmıştır. Çalışmada; PSO yönteminin diğer modele göre daha iyi performans gösterdiği sonucuna varılmıştır. (Karaman ve ark., 2022).

Karaman ve Sağlam (2022) tarafından yapılan çalışmada; GSYH, ithalat, ihracat ve nüfus gibi çeşitli giriş parametreleri kullanılarak Türkiye için anlık tepe yükünü tahmin etmek için YSA ve LR yöntemleri MATLAB ortamında tasarlanmış ve uygulanmıştır. Çalışmada kullanılan modeller R değerleri dikkate alındığında kullanılabilir sonuçlar göstermiş ancak YSA modelinin performansının LR modeline göre daha yüksek olduğu sonucuna varılmıştır (Karaman ve ark., 2022).

2. MATERYAL VE METOT

Çalışma beş aşamadan meydana gelmektedir. Birinci aşamada bu çalışmanın amacı ve literatür taramasına yer verilmiştir. İkinci aşamada sürü zekası, PSO amaç ve yöntemleri, kavram parametreleri, işlem basamakları ve algoritma hakkında bilgi verilmiştir.

Üçüncü aşamada YSA tanımı, kavramları, genel özellikleri ,fonksiyonları, avantajları ve dezavantajları hakkında bilgi verilmiştir.

Dördüncü aşamada DVR tanımı, amacı ve fonksiyonları hakkında bilgi verilmiştir.

Beşinci aşamada PSO, YSA ve DVR algoritmaları ile enerji tahminlerine ulaşılmış ve karşılaştırmalar yapılmıştır. Bu karşılaştırmalar neticesinde sonuç ve önerilere yer verilmiştir.

2.1. Parçacık Sürü Optimizasyonu

Doğadaki bazı hayvanların bireysel ve sürü halindeki etkileşim ve davranışları sürü zekasının çalışmalarına kaynak teşkil etmektedir. Bu etkileşim ve davranışlar böceklerin yiyecek arayışı, maddeleri ayırıştırabilmeleri, barınma için yuva yapabilmeleri bireysel ve sürü halinde bunları sergilemeleri sürü zekasının temel yapı taşını oluşturmaktadır (Shami ve ark., 2022).

Bireylerin dağınık halde bulunan yapılarda etkileşim içerisinde oldukları kitleye Sürü (swarm) adı verilmiştir. Örnek olarak karınca, kuş, balık, koyun, arı ve kurt gibi hayvanlar gösterilebilir. Zihinsel olarak insanlar tarafından soyut düşünebilme, anlayabilme ve problem çözebilme Zekâ olarak isimlendirilmektedir (Eldem, 2014).

Basit yapılara sahip ajanları içinde barındıran, karmaşık olan toplu davranışları kendi kendilerini yönlendirebilen ve herhangi bir merkezi yapıya sahip olmayan sistemlerin özelliklerini ortaya çıkmasına öncü olan ve aynı zamanda yapay zekanın da bir ürünü olan yapılara sürü zekâsı denilmektedir. Sürü zekasındaki başlıca gelişimsel katkıda doğanın rolü büyüktür. Sistem üzerinde ajan olarak isimlendirilen her bir bireyin merkezi bir kontrol sistemi olmamasına ve hareket alanının kısıtlı olmasına rağmen sürünün oluşturduğu grup bazı zekâ hareketlerini ve özelliklerini sergilemektedir. Sürü zekası, bazı hayvanların bireysel veya toplu halde açıklanamayan iş birliği ve davranışları sonucu bilimsel merak uyandırarak ortaya çıkmıştır (Shami ve ark., 2022).

Sürü zekâsı olarak isimlendirilen sistem birtakım özellikler içermektedir. Özellikler aşağıda söz edildiği gibidir (Kutlu, 2012);

- Hız: Hız davranışlar, topluluk veya sürü içerisinde bulunan bireyler tarafından sergilenir.
- Kurala Dayalı Davranış: Kurala bağlı olarak bireylerin çevresel veya bireysel davranışlarda değişim söz konusu olabilir.
- Uyarılma: Sürü içerisindeki bireyin değişiklikleri üremeye veya ölüme doğrudan bağlıdır.
- Hata Toleransı: Sürü içerisindeki davranışlardaki düğümlerde veya bağlantı noktalarında oluşacak kayıplar, sürü zekasındaki merkeziyetçi kontrol teşkilatlanması sayesinde sorun teşkil etmez.
- Özerklik: Sürü zekasında yabancı olarak algılanan ve kendilerine ait olmayan bir düzen veya davranışa güvenemezler, davranış ve yeteneklerini kendileri organize ederler.
- Birleşim: Birden çok birey bir araya gelerek parçacığı meydana getirirler.
- Ölçeklenebilirlik: Sürü içindeki bireylerin daha nizami olmasına olanak sağlar.

Sürü zekası içerisinde yer alan optimizasyon algoritmalarından bazıları aşağıda sunulmuştur (Joseph ve ark., 2022) :

- Kurt kolonisi optimizasyonu
- Parçacık sürü optimizasyonu
- Ateş böceği algoritması
- Karınca koloni optimizasyonu
- Bakteriyel besin arama optimizasyon algoritması
- Ateş böceği optimizasyonu

Balık, kuş ve böcek gibi hayvanların koloniler halinde temel ihtiyaçlara ulaşmada etkileşim ve davranış içerisinde olurlar. Bu kolonilerin herhangi bir tehlike anında kaçmaları sonucu sergiledikleri hareketler, yiyecek ararken veya barınma ihtiyacını karşılamak için meydana getirdikleri davranışlar Dr. Eberhart ve Dr. Kennedy için bir ilham kaynağı olmuş. 1995 yılında bu davranışlardan yola çıkarak sezgisel tabana sahip bir optimizasyon olan PSO'yu ortaya atmışlardır (Özdemir ve Öztürk, 2016; Couceiro ve ark., 2016).

Sürü içerisinde yer alan bireyler kültürel olarak birbirleriyle olan iletişimleri ve kendi kendilerine gerçekleştirmiş oldukları öğrenme biçimleri PSO için bir alt yapı oluşturmaktadır. Bireylerin çevreleri ile olan etkileşimlerinden birçok şey öğrenebilirler. Bunun gerçekleşebilmesi için homojen bir yapıya sahip olan ve durağan yapıya sahip yani statik ortamların sağlanması önem arz etmektedir. Bu ortamların sağlanması tek bireyin etkileşimi ile olamaz, farklı deneyimlerden yararlanılması gerekir. Bu da kültürel etkileşimlerin diğer bireylerin öğrenmeye ihtiyaç duymasına yol açar. PSO algoritmasında değişiklikler yapılarak sınırlandırılmamış olan problemler için çözüm oluşturulmaktadır (Gad, 2022).

Multimodal olarak isimlendirilen çok moda sahip olan problemler için metotların sonuç vermediği durumlarda PSO kullanılır. Optimizasyon problemleri içerisinde yer alan portföy optimizasyonu, çizelgeleme problemleri, bulanık (fuzzy) sistem kontrolü, tedarikçi seçimi ve sıralama problemleri, sipariş miktarı tespit etme ve YSA eğitimi gibi problemlerde PSO fonksiyon optimizasyonu kullanılmaktadır (Eldem, 2014).

Sürülerin global olarak sergilemiş oldukları davranışlar ve komşuları ile olan yereldeki etkileri PSO yöntemlerini barındırmaktadır (Chen ve ark., 2022).

$f(x)$ ' in sürekli bir fonksiyon olarak doğrusal ve konveks olmadığı varsayılan Denklem (2.1), global olan minimum değer noktasını tespit eder. Örneğin, $x^* \in IR^n$ noktası Denklem (2.1)'e göre $f(x^*) \leq f(x)$ şartını sağlamalıdır (Chowdhury ve ark., 2013).

$$\min f(x), \quad x \in IR^n \rightarrow f: IR^n \rightarrow IR \quad (2.1)$$

Sürü içerisinde yer alan parçacıkların, optimal en iyi konum hedefi için izlenmesi gereken basamaklar aşağıda sıralanmıştır (Papazoglou ve ark., 2023).

1.basamak: İlk oluşturulacak sürü, içerisinde rastlantısal olarak N tane parçacık bulundurulur.

2.basamak: Güncel ve yeni hız vektörü, her bir parçacık özelliğine göre hesaplanır.

3.basamak: Yeni konum, parçacıklardan her birinin yeni ve eski konumları belirlenerek kıyas edilerek elde edilir.

4.basamak: Hedefe ulaşıldığında izlenen adımlar sonlandırılır. Hedefe ulaşılmamış ise ikinci basamaktan işlemler devam ettirilir.

Sürülerin davranış biçimlerini irdeleyen 2 yaklaşım bulunmaktadır. Bu yaklaşımlar evrimsel programlama ve yapay yaşam olarak söz edilebilir. Bunlar PSO için yapılacak araştırmalarda altyapı oluşturmaktadır (Akbulut, 2016).

Swarm veya diğer adıyla sürü, içerisinde yer alan her bir bireye veya bu bireylerin oluşturduğu koloniye denilmektedir. Arama alanı içerisinde rastgele bir dağılım sergileyen parçacıkların optimal bir çözüm üretmesi hedeflenmektedir. Bu hedefe ulaşırken parçacıkların sonraki hareketlerine karar verebilmeleri gerekmektedir. Bunun için hareketle ilgili üç durumu göz önünde bulundurmaları ve bunları kullanmaları gerekmektedir. Parçacıkların o anki mevcut hız, geçen süre içerisindeki en iyi konum ve bu geçen süredeki sürü içerisinde yer alan tüm bireylerin en iyi konum bilgisine sahip olmaları gerekmektedir. Bu bilgiler ışığında optimal sonuç için adım atılmış olur. Sürü içerisindeki parçacıkların optimal hedef ve konuma ulaşmasına kadarki geçen sürede, her adımda sosyal olarak edindikleri deneyimleri, hızları ve konumu güncellenmektedir (Chauhan ve ark., 2023; Chang ve ark., 2023).

2.1.1 Parçacık sürü optimizasyonu kavramları

PSO algoritmasında global ve yerel komşuluk kavramlarına sahip 2 değişken yer almaktadır. Geniyi (GBEST), sürü içerisinde yer alan parçacıkların bireysel olarak da en iyi konuma ulaşacak şekilde hareket etmesiyle elde edilir. Sürü içindeki parçacıkların bir önceki konumuna göre en iyi konuma ulaşacak şekilde hareket etmesi peniyi (PBEST) elde edilmesini sağlar. PSO algoritmasında yer alan denklemin içerisindeki bazı değişkenler, 1996 yılında Eberhart ve arkadaşları tarafından yapılan incelemeler neticesinde gereksiz olduğu görülmüş ve denklem revize edilmiştir. Revize edilen PSO algoritma denklemi Denklem (2.2) ve Denklem (2.3)'te sunulmuştur (Shami ve ark., 2022) :

$$h_{nd}^{t+1} = h_{nd}^t + c_1 x r_1 x (peniyi_{nd}^t - mevcut_{nd}^t) + c_2 x r_2 x (geniyi_d^t - mevcut_{nd}^t) \quad (2.2)$$

$$mevcut_{nd}^{t+1} = mevcut_{nd}^t + h_{nd}^t \quad (2.3)$$

PSO algoritma denkleminde yer alan parametre tanımlamaları aşağıda verilmiştir:

h_{nd}^t : n. Parçacığa ait d değişkenin t. çevrimde elde edilen hızı

$mevcut_{nd}^t$	: n. Parçacığa ait d değişkenin t. çevrimdeki değeri
w	:Eylemsizlik (dinginlik) katsayısı
r_1, r_2	:Rastlantı olarak baz alınan 0-1 aralığındaki değerler
$peniyi_{nd}^t$	:n. Parçacık için t. çevrime kadar geçen süredeki elde edilen en iyi d değişken değeri
$geniyi_d^t$	:Komşu parçacıklar içerisinde t. çevrime kadar geçen en iyi d değişken değeri
c_1	:Genelde 2 olarak alınan bu katsayı, bilişsel öğrenme oranı olarak tanımlanır.
c_2	: Genelde 2 olarak alınan bu katsayı, sosyal öğrenme oranı olarak tanımlanır.

Sürü içerisinde yer alan parçacıkların güncelleme hızları Denklem (2.2)'de bulunan parametrelere göre üç bölümden meydana gelir (Too ve ark.,2022).

- Arama alanı içerisindeki hareket momentumu, atalet kısmını oluşturur.
- Sürü içerisindeki parçacıkların deneyimleri, bilişsel kısmı oluşturur.
- Sürü içerisindeki bilgi paylaşımı, sosyal kısmı oluşturur.

Eberhart ve Shi tarafından 1998 yılında, alan içerisindeki arama çalışmalarında farklı roller üstlenen bu üç bölüm ile alakalı aşağıdaki gibi tetkik yapılmıştır.

Bilişsel ve sosyal olarak isimlendirilen kısımlar $c_1, c_2 = 0$ olduğunda hız güncellemesinde etkileri yoktur. Sonuca sadece bilişsel olan modele nispeten daha hızlı ulaşılabilir. Bu durumda çözüm alanında olmadığı sürece optimum değer tespit edilemez.

Sadece sosyal kısım parametresi, $c_1=0$ olduğu durumda gerçekleşir. Bu denklemde bilişsel kısım yer almaz. Burada parçacıklar arasında yer alan etkileşim sonucu yeni bir arama alanına geçilebilir. Bazı problemlerin çözümü noktasında parçacık sürüsü etkili bir performans ortaya koyabilir.

Sadece bilişsel kısım parametresi, $c_2= 0$ olduğu durumda gerçekleşir. Burada sosyal kısım yer almaz. Sürü içerisindeki parçacıklar arasında iletişim olmadığından parçacıklar bağımsız hareket edeceklerdir. Bu model rastgele multi modlu başlama özelliğine sahip algoritma haline gelir. Sadece sosyal olan modele göre oldukça yavaş sonuca ulaştırır.

Kişisel ve global en iyi konum ile atalet kısmı bulunur. Orjinal olan PSO oluşturulan algoritmaya göre sonuca daha hızlı bir biçimde ulaşabilir. Bir önceki hızın olmadığı durumda diğer alanlarda arama ihtimali düşük seviyede olabileceğinden dolayı parçacıklar, global ve kişisel en iyi pozisyon etrafında toplanırlar (Özkan, 2018).

2.1.1.1 Atalet ağırlığı (dinginlik katsayısı) olan PSO

Konum ve hız vektör denklemleri PSO algoritma yapı taşını meydana getirir. Denklem 2.4'e göre n.parçacığın yeni hız vektörü hesaplanır. Parçacığın hareketi, o andaki mevcut hızına bağlı olarak değişir. PSO algoritmasının matematiksel denklemi, Eberhart ve Shi (1998) tarafından dinginlik katsayısı (w , inertia weight) kullanılarak yapılan çalışmada oluşturulmuştur. Denklem (2.4)'te verilmiştir (Shi ve ark., 1998).

$$\begin{array}{c}
 \xleftarrow{\text{Bilişsel bileşen}} \quad \xleftarrow{\text{Sosyal bileşen}} \\
 h_{nd}^{t+1} = h_{nd}^t + c_1 x r_1 x (\text{peniyi}_{nd}^t - \text{mevcut}_{nd}^t) + c_2 x r_2 x (\text{geniyi}_d^t - \text{mevcut}_{nd}^t) \\
 N=1,2,\dots,N \quad \quad \quad d=1,2,\dots,D
 \end{array} \quad (2.4)$$

Yaşantıya dayalı olan bilişsel bileşen, parçacıkların geçmiş performansları ile optimal pozisyona gelmelerini sağlar. Denklem (2.4)'te yer alan sosyal bileşen, parçacığın komşuluğunda optimal pozisyona gelmesini sağlar (Too ve ark., 2022). Güncel konum vektörünü hesaplayabilmek adına, eski konum vektörüne parçacığın hızı Denklem (2.5)'de görüldüğü gibi eklenir.

$$\begin{array}{c}
 \text{mevcut}_{nd}^{t+1} = \text{mevcut}_{nd}^t + h_{nd}^t \\
 N=1,2,\dots,N \quad \quad \quad d=1,2,\dots,D
 \end{array} \quad (2.5)$$

Dinginlik katsayısı (w) belirleyebilmek adına yapılan çalışmalar neticesinde Denklem (2.6)'da yer alan yöntemlere ait denklemler kullanılmaktadır (Shami ve ark., 2022).

$$w_1 = (w_1 - w_2) * \left[\frac{\text{toplamlar tur sayısı} - \text{o anki tur}}{\text{tur sayısı}} \right] \quad (2.6)$$

Denklem (2.6) içerisinde yer alan sabit başlangıç ve bitiş değerleri, w_1 ve w_2 katsayılarından oluşmaktadır. O anki tur'da geçerli iterasyon sayısını ve maximum iterasyon sayısını toplam tur sayısı ifade etmektedir. w değerinin 0.9 değerinden başlayarak 0.4 değeri ile son bulması optimizasyon içerisinde en iyi sonuçları elde edebilmek için gerekli olduğu sonucunu ortaya çıkarmıştır. Optimal çözümler için w katsayı değerinin küçük değerde olması alan içerisinde yerel aramanın etkin olduğunu, yüksek değerde olması evrensel aramanın etkin olduğuna işaret etmektedir. Denklem (2.7) ve Denklem (2.8)'de parçacık hızına ait denklemler verilmiştir (Elbes ve ark., 2019).

$$w_i = w_0 * \exp\left(\frac{o \text{ anki tur}}{\text{toplam tur sayısı}}\right)^n \quad (2.7)$$

$$w = \frac{0.5 + rand}{2} \quad (2.8)$$

2.1.2 Parçacık sürü optimizasyonu parametreleri

PSO'da yer alan parametrelerden bazıları (Shami ve ark., 2022) :

- ✓ Sürü boyutu
- ✓ PBEST
- ✓ Sürü sayısı
- ✓ İterasyon sayısı
- ✓ En yüksek hız
- ✓ Dinginlik katsayısı (w)
- ✓ Parçacık aralığı
- ✓ Durma koşulu
- ✓ GBEST
- ✓ Öğrenme faktörleridir. (c_1, c_2)

Sürü sayısı: Sürü içerisinde yer alacak parçacık sayısını ifade eden bu parametre problemin zorluk derecesine göre belirlenir (Eldem, 2014).

Öğrenme faktörleri: Bu parametre PSO algoritmalarının optimal şekilde çalışmasına öncülük eder. Sosyal öğrenme kısmı c_2 ve bilişsel kısım c_1 ile gösterilir.

Bilişsel öğrenme oranı, optimal çözüm üretmek için parçacığın önceki tecrübelerinden faydalanır. Sosyal öğrenme oranı, sürülerin tamamını çözüme kavuşturan parametredir (Sönmez ve ark., 2013).

Sosyal öğrenme kısmı c_2 ve bilişsel kısım c_1 değerleri global ve yerel en iyiyi kapsaması için çoğu zaman 2 olarak kabul edilir. Sosyal öğrenme kısmı c_2 ve bilişsel kısım c_1 değerlerinin, Clerc'in yapmış olduğu çalışma dikkate alındığında 1,49445 alınması sonucuna varılmıştır. Tabi bununla birlikte daralma faktörü de göz ardı edilmemelidir.

Sürü boyutu: Problemin büyüklüğüne göre boyut değişebilir. Makul sürede en iyi çözüme ulaşabilmek için optimal boyutlandırma önemlidir (Couceiro ve ark., 2016).

İterasyon sayısı: İterasyon yani adım sayısı optimal sonuca ulaşmak adına yapılan veya yapılacak olan tekrar sayısını ifade eder. Adım sayısında en iyi sonuca ulaşmak veya yaklaşmak için baz alınan sürü büyüklüğünün en yüksek değerde olması gerekir.

En yüksek hız: Parçacık aralığına bağlı olarak belirlenen bu parametre arama bölgesinin dışına çıkılmasını engeller.

Sürü içerisindeki parçacıkların yerel optimale ulaşabilmeleri için en yüksek hız değerinden daha küçük adımlarla ilerlemek gerekir. Aksi durumda en yüksek hızdan büyük bir değer seçildiğinde parçacık sıkışacaktır. Arama alanı içerisinde farklı hız sınırları belirlenebilir. Genelde en yüksek hız değeri olarak Denklem (2.9) kullanılır (Shami ve ark., 2022) :

$$V_{max} = \frac{\min_i \{b_i - a_i\}}{k} \quad a, b \in R \quad (2.9)$$

Sürü içerisindeki her bir parçacığın maksimum hız değeri Denklem (2.10)'dan yararlanarak hesaplanabilir:

$$V_{max} = \frac{b_i - a_i}{k} \quad i = 1, 2, \dots, n \quad (2.10)$$

Parçacık aralığı (Range): Kullanılan değişkenlerin değer aralığına bağlı olarak oluşturulabilir (Eldem, 2014).

Global en iyi değer: Bu değer sürü içerisinde yer alan bütün bireylerin veya parçacıkların içerisindeki en optimal değerdir. Birinci basamakta komşular belirlenirken ikinci basamakta bu komşu parçacıklar arasındaki optimal değer bulunarak global en iyi değer elde edilir. PSO algoritmasının yakınsama hızını komşu parçacıkların büyüklüğü etkiler. Parçacıkların erken bir araya gelmesini küçük komşuluk parçacıkları

engellerken, parçacıkların hızlı bir şekilde bir araya gelmesine büyük komşuluk parçacıkları destek verir (Jain ve ark.,2022).

Dinginlik katsayısı: Shi ve Eberhart tarafından ilkez kullanılan bu kavramın büyük bir değerde olması, araştırma ve keşif için önem arz etmektedir. Bu katsayı genellikle 0.9 ile 0.4 arasında yer alır. (Jain ve ark.,2022).

Yakınsaklık algoritmanın matematiksel özelliklerinin genetik bir sonucudur. Maksimum hız olan V_{max} değerinin parçacık sürü optimizasyon algoritmasında kısıtlama faktörlerinden biri olarak kullanılması daha kısa bir hesaplama gerektireceğinden maliyetleri azaltır. Algoritmaların matematiksel özellikleri içerisinde yakınsaklık, bir genetik sonuçtur. Denklem (2.11)'de yer alan denklemde, ivme sabiti ve dinginlik katsayısı arasındaki ilişkiyi garanti altına almak için sağlamalıdır (Shami ve ark., 2022):

$$\frac{c_1+c_2}{2} - 1 < w \quad (2.11)$$

Durma koşulu: Algoritma içerisinde optimal sonuca ulaşmak için yeterli iterasyona ulaşılması halinde arama bölgesindeki çalışmaya son verilir.

Pozisyon değerleri: Belirlenen aralık dışında parçacıkların değer alması veya belirlenen değer aralığında olması halinde Denklem (2.12) ve Denklem (2.13)'teki kısaltmalar kullanılır (Eldem, 2014) :

$$\text{eğer } x_i > x_{max} \text{ ise } x_i = x_{max} \quad (2.12)$$

$$\text{eğer } x_i < x_{min} \text{ ise } x_i = x_{min} \quad (2.13)$$

Hız değerleri: Hız değerlerinin sınırları belirlenen çözüm aralığı içerisinde optimal çözümü aramak için önemlidir. Bu hız değerleri negatif veya pozitif değerler olabilirler. Hız değerlerinin yönü oldukça hareketli ve fazla olabilir. Hız değerlerine ilişkin Denklem (2.14), Denklem (2.15) ve Denklem (2.16)'da verilmektedir:

$$V_{min} = -V_{max} \quad (2.14)$$

$$\text{eğer } V_i > V_{max} \text{ ise } V_i = V_{max} \quad (2.15)$$

$$\text{eğer } V_i < V_{min} \text{ ise } V_i = V_{min} \quad (2.16)$$

Yerel en iyi değer: Her parçacık için bir bellek ayrılırken, bu parametre aynı zamanda parçacıkların ulaşabildiği optimal değerdir.

Optimal değere ulaşabilmek için birden fazla kıstas getirilebilir. Elde edilen en iyi değer her zaman için algoritma içerisinde oluşturulan fonksiyondan elde edilen değere bağlı olmayabilir. Böylelikle daha önce elde edilmiş ancak çözüme katkısı olmayan değerler göz ardı edilmiş olur (Jain ve ark.,2022; Eldem, 2014).

2.1.3 Parçacık etkileşimleri

Sürü içerisinde yer alan bir parçacık yerel optimumuna ulaştığında komşu parçacıklar içerisinde en iyisi olur. Diğer parçacıklar da optimum sonuç elde edilen bölgeye yerleşirler (Jain ve ark.,2022).

2.1.4 Komşuluk topolojileri


Geçmişten günümüze yapılan ve bilhassa da 1940 yılından beridir yapılan araştırmalar oluşan sosyal ağın gruplar içerisindeki iletişime bağlı olarak yeniden şekillenebileceğini göstermiştir. Sosyal ağ veya diğer bir adıyla sosyal etkileşim, bireylerin etkileşimi sonucu ortaya çıkan bir ağ olarak çoğu sosyal bilimci tarafından belirtilmektedir. Popülasyon içerisindeki bireylerin en iyi birey ile etkileşim halinde olması ve onun etrafında toplanması PSO algoritmasının yapı taşı oluşturur (Shami ve ark., 2022).

- GBEST: Sürü içerisinde parçacıklar konumlarını birbirleriyle paylaşırlar. Konumu en iyi olan parçacık sürünün en iyi konumu oluşturur ve mevcut hız bu konuma göre güncellenir.
- PBEST: Her bir parçacık kendi en iyi konumunu günceller. Bu durumda kendisine ait en iyi konumu elde etmiş olur.

2.1.5 Algoritma

PSO algoritmasında parçacıkların hızları her adımda kontrol edilir. Parçacığın hızı evvelki hızından daha iyiye mevcut hızı en iyi hıza güncellenir. Algoritma

işleyişinde en iyi hız ve konum sürekli güncellenmiş olur. PSO' ya ait algoritma Şekil 2.1'de verilmiştir (Eldem, 2014).



Şekil 2.1. Parçacık sürü optimizasyonu akış diyagramı

2.2. Yapay Sinir Ağları

YSA'ya ait yapı taşı olan temel bilgiler, özellikler ve ağ yapısı çeşitleri bu konu başlığı altında verilmiştir.

2.2.1 YSA'nın tanımı

Kısaca belirtmek gerekirse YSA, nöron olarak adlandırılan, insan beynini model olarak basit işlem elemanlarından oluşturulmuş, yüksek karmaşıklığa sahip ve doğrusal

olmayan bir bilgi işleme sistemidir. Yapılan her araştırma, YSA ile ilgili bilinmeyen bir başka özelliğin ortaya çıkışına ön ayak olmuştur. Birçok küçük birimin bilgiyi işlemek adına bir ağ oluşturduğu ve bunun da YSA olarak tanımlanabileceği çoğu bilim insanının ortak görüşüdür (Aktaç, 2016).

2.2.2 Yapay sinir ağlarının temel görevi

Bilgisayarlar verilen komutları insan beyninden daha hızlı bir şekilde çözümleyebilmektedirler. Ancak bu çözüm yolu önceden bilinen ve çözüm yolu kademelendirilmiş sorunlar için geçerli. Analiz ve sentez yapılması gereken sorunlarda bilgisayarlar yetersiz kalmaktadırlar. İnsan beyni kompleks yapısı ile ön plana çıkmaktadır. Bu yapı analiz ve sentez noktasında oldukça faydalı çözümler üretebilmektedir. Ancak gerek hız gerekse karmaşık problem çözümlerinde yetersiz kalabilmektedir. Hem bilgisayarların işlem hızı hem de insan beynin sentez ve analiz bileşenlerini YSA'lar içinde barındırmaktadırlar. Kompleks problemler için YSA'lar tercih edilmektedirler (Albahri ve ark., 2022).

İnsan beynine ilişkin bazı temel konularda YSA ortak özellik sergilemektedirler. Bu konulardan bazıları aşağıda sıralanmıştır.

- Öğrenme
- Sınıflandırma
- İlişkilendirme
- Optimizasyon
- Özellik Belirleme
- Genelleme

Birçok probleme çözüm üretebilen YSA'lar, bilgiyi edindikleri tecrübeler ile sentezlemekteler. Karar noktasında da yine daha önceki tecrübelerinden faydalanmaktadırlar. YSA'lar, hiyerarşik bir düzen içerisinde beraber çalışabilecek hücrelerden meydana gelmektedirler (Zarra ve ark., 2019).

2.2.3 Yapay sinir ağlarının genel özellikleri

YSA'ları her probleme aynı yaklaşımla uygulamak bazen çözüme götürmeyebilir. Bunun için problemin yapısına göre aşağıda belirtilen karakteristik yaklaşımlar sergilenmelidir.

Bellekler dağıtılmış bir yapı sergiler: YSA’larda yalnız bir bağlantının anlamı olmamakla birlikte, ağların birbirleriyle bağlantıları vardır. Bilgiler ağa dağıtılmış durumdadır. Bu yüzden ağlar bir bütün olarak düşünüldüğünde anlamlı bir bilgi ortaya çıkar.

- **Makine öğrenmesini YSA’lar gerçekleştirirler:** Önceki deneyimleri kullanabilmek, buna bağlı olarak analiz ve sentez yapabilmek için bilgisayarların öğrenmesine ihtiyaç duyarlar.

- **Bilgiyi saklarlar:** Bilgiyi sonraki problemlerde kullanmak üzere saklarlar. Bu bilgiler veri tabanına gömülü olmamakla birlikte ağ üzerinde saklıdır.

- **YSA’ların performansları güven oluşturabilmek için önce eğitilir sonra testten geçirilir:** YSA’lar önce eğitim setleri ile eğitilirler. Buradaki eğitimden sonra sorulan sorulara verdikleri cevaplar incelenir. Bu cevapların doğru olması halinde daha önce karşılaşmadığı sorunlar gösterilir. Bunlara doğru bir yaklaşım sergilemesi halinde kullanıma başlanır. Doğru bir yaklaşım sergilememesi halinde tekrardan eğitim seti uygulanır.

- **İlişkilendirme ve örüntüler yapabilirler:** Deneyimlerin sınıflandırmalarını ve örüntü ilişkilendirmelerini yaparlar.

- **Kendilerine has öğrenme ve bilgileri bir araya getirebilirler:** Karşılaştıkları deneyimleri öğrenme şekilleri ve bunları birleştirme özellikleri vardır.

- **Tam ve belli olmayan bilgileri işleyebilirler:** Tam ve belli olmayan bilgileri, YSA’nın çalışma performanslarını kaybetmeden işleyebilirler.

- **Bilgiler eksik olmasına rağmen çalışabilirler:** Eğitim seti ile eğitildikten sonra eksik bilgiler olsa dahi çözüm üretirler. Bu eksik bilgiler çalışma performansını etkilememektedir. Bu hata eksik bilgilere karşın YSA’ların toleranslı olduklarını göstermektedir.

- **Çalışma şekilleri diğer algoritmalarından farklıdır:** Bilgiyi kullanma şekilleri algoritmik olarak diğer geleneksel programlardan ayırdır.

- **Gerçekleşmiş olaylardan faydalanarak öğrenirler:** Problemlere çözüm üretebilmek için deneyimlediği çözümleri analiz eder. YSA’ların karşılaştığı her problem aslında yeni çözümler için birer deneyimdirler.

- **İçerisinde algılama barındıran olaylar için kullanılabilirler:** Bilgi temelli çözümler için algılamaya dönük verileri işleyebilmek için kullanılabilirler.

- **Örüntüyü tamamlayabilirler:** Bazen verilen bir örnek eksik veya yarım verilebilir. Bu örneği tamamlama noktasında çözüm üretirler.


- **Kademeli biçimde ağ yapısında bozulmalar olabilir:** Hatalara karşı toleranslı olduklarından eksik bilgiler karşısında ağ yapısında bozulmalar meydana gelebilir (Öztemel, 2006).

Geleneksel algoritmaların kompleks veya daha önce karşılaşılmamış çözümler noktasında yetersiz kaldığı bilinmektedir. YSA'ların makine öğrenmesi ile birlikte eksik veya belirsiz olan problemler karşısında bile çözüm üretebileceği yukarıda açıklanan bilgiler ışığında görülmektedir (Aktaş, 2016).

2.2.4 Biyolojik sinir ağları

- **Yapısal olarak biyolojik sinir ağları**


Çevreden gelen sinyalleri elektriksel sinyallere dönüştürerek beyine ulaştıran ve ulaşan bu sinyallerin beyinde değerlendirilerek uygun tepki sinyallerinin oluşmasını sağlayan yapı, biyolojik sinir ağıdır. Yapıya ilişkin döngü Şekil 2.2'de gösterilmiştir (Birecikli ve ark., 2020).



Şekil 2.2. Biyolojik sinir ağının şeması

Sinaps, akson, dentrit ve soma olmak üzere biyolojik sinir ağı 4 bölümde sınıflandırılmaktadır.

Sinapslar, hiçbir fiziksel bağlantıları olmayan hücreler arasındaki elektriksel iletimi sağlarlar. Dentritler üzerinden gelen sinyaller somaya aktarılır. Somaya gelen sinyaller işleme tabi tutularak işlenir ve işlenen bu sinyaller sinapslar üzerinden aksonlara iletilir. Aksonlar ise gelen bu sinyalleri çıkışa iletir. Biyolojik sinir ağ yapısı Şekil 2.3'te verilmiştir (Öztemel, 2006).



Şekil 2.3. Biyolojik sinir ağının basitleştirilmiş yapısı

Biyolojik sinir ağ yapısı YSA'ya ilham kaynağı olmuştur. YSA'lar çalışma mantığında nöronların bilgiyi alışı, işleyiş ve çıkışa iletme mantığını uygulayarak paralel bağlı işlem elemanları aracılığıyla sonuca ulaşır (Birecikli ve ark., 2020).


İnsan beyninin biyolojik sinir ağ yapısı içerisinde bulunan nöronlara ait yapı elemanları ile YSA'ların çalışmasında yer alan elemanlar arasında eşitlikler bulunmaktadır. Hücre, nöron ve düğüm YSA'nın çalışmasındaki temel yapı taşlarıdır. Biyolojik sinir ağ yapısı ve YSA'lardaki karşılıkları Çizelge 2.1'de verilmiştir (Kirik, 2010).

Çizelge 2.1. Biyolojik sinir sistemi ve YSA'nın karakteristiği

Biyolojik Sinir Ağı	YSA
Nöron	İşlem Elemanı
Sinaps	Ağırlıklar
Dentrit (mesaj algılayıcı)	Toplama İşlevi
Hücre Gövdesi	Transfer Fonksiyonu
Akson (mesaj nakledici)	Çıkış

2.2.5 YSA hücresi

İlgili girişin etkisini ağırlıklar aracılığıyla nörona bağlanan dış ortamdan alınan veri belirler. Net girişi ise toplam fonksiyonu hesaplar. Bu girişler ile alakalı ağırlıklar; net giriş ve girişlerin çarpımının bir sonucudur. Nöron çıkışını, aktivasyon fonksiyonunun işlem süresince net çıkışı ile alakalı hesaplamalar verir. Bir b sabiti ile şekilde görülen eşik değeri olan bias'ı ifade edilebilir. Bias, aynı zamanda aktivasyon fonksiyonunun sınır değeri olarak isimlendirilir. Basit yapay sinir hücresinin (nöron) yapısı Şekil 2.4'te verilmiştir (Birecikli ve ark., 2020).



Şekil 2.4. Basit bir yapay sinir hücresi (nöron) yapısı

Yapay hücre modeli; girdi, aktivasyon fonksiyonu, birleştirme fonksiyonu, ağırlık fonksiyonu ve çıktılardan oluşur. Yapay sinir hücreleri, en küçük bilgi işleme birimi olarak YSA'lar için temel teşkil etmektedir. YSA'lar, biyolojik sinir hücrelerine göre yapısal olarak daha basittirler. Birçok girdi parametresi nöronlarda bir çıktı olarak ortaya çıkar (Zarra ve ark.,2019).

2.2.5.1 Girişler

Giriş ve çıkışlara ait denklemler, Denklem (2.17)'de verilmiştir.

$$\text{Çıkışlar matrisi, } out(o) = f(W.X + b) \quad (2.17)$$

olarak gösterilen nöron çıkışı hesaplanır. Burada yer alan ağırlıkların matrisi $W = W_1, W_2, W_3 \dots W_n$ 'dir. Girişler matrisleri ise $X = X_1, X_2, X_3 \dots X_n$ 'dir. Giriş sayısı n

olarak gösterilir. Net bir fonksiyon, giriş parametrelerinin eşik değerine ve ağırlıklarına bağlı Denklem (2.18)'deki gibi *Net* olarak tanımlanırsa, *o* çıkış fonksiyonu ile birlikte;

$$Net = \sum_{i=1}^n W_i X_i + b \quad o = f(Net) \quad (2.18)$$

şeklinde yazılabilir. Bu durumda Denklem (2.17)'de verilen eşitlik kullanılarak geniş kapsamlı olarak Denklem (2.19) elde edilir.

$$o = f(\sum_{i=1}^n W_i X_i + b) \quad (2.19)$$

Denklem (2.19)'da *f* aktivasyonu gösterilmiştir. Yapay sinir hücresine (işlem elemanına) çevreden almış olduğu bilgiyi girişlere ($X_1, X_2, X_3 \dots X_n$) getirir (Birecikli ve ark.,2020).

2.2.5.2 Ağırlıklar

Yapay hücreye gelen bilgilerin etkileri için tanımlama yapılmıştır. Ağırlıklar ($W_1, W_2, W_3 \dots W_i$) olarak yapılan bu tanımlama gelen bilginin önemini ve etkisini belirler. Ağırlık değerleri sabit veya değişken değerde olabilirler. Girişlerin kendilerine ait ağırlıkları vardır. X_i giriş hücresi üzerindeki etkisi Şekil 2.3' deki W_i ağırlığı ile gösterilmektedir. Ağırlıkların büyüklüğü ya da küçüklüğü önem derecesini belirlemez. O ağırlığa ilişkin en önemli olay, bir ağırlığın sıfır değerinde olması olabilir. Bu eksi değerlerin önemsiz olduğu anlamına gelmemektedir. Değerin sıfır olması ağırlığın herhangi bir etkisinin olmadığını, değer önünde eksi ve artı işaretlerinin olması etki değerinin negatif veya pozitif olduğunu ifade eder (Aktaç, 2016).

2.2.5.3 Toplama fonksiyonu

Bir hücreye gelen net girişi hesaplamak için birleştirme fonksiyonu kullanılır. Yaygın olarak ağırlıklı toplamı bulan fonksiyon kullanılır. Toplama fonksiyonu çoğunlukla deneme-yanılma yoluyla belirlenir. Ağırlığa giren net girdiyi hesaplayabilmek için girdi parametresi kendi ağırlık değeriyle çarpılıp ardından toplanır. Net girdiye ilişkin oluşturulan formül Denklem (2.20)'de gösterilmiştir (Hamzaçebi, 2011).

$$NET = \sum_i^n X_i W_i \quad (2.20)$$

Denklem (2.20)'de yer alan denklemde, n bir hücreye gelmiş olan toplam girdi sayısını, X girdileri ve W ağırlıkları temsil etmektedir.

Zaman içinde yapılan çalışmalarda farklı toplama fonksiyonları YSA için ortaya çıkmıştır. Bu formülün YSA'da daima kullanılması şart değildir. Toplama fonksiyonunu uygulanmakta olan bazı YSA modelleri belirleyebilmektedir. Toplama fonksiyonunda değişik formüllerin kullanıldığı literatürde yapılan taramalarda görülmektedir. Toplama fonksiyonu bazen kompleks yapıda olabilir. Çizelge 2.2'de genellikle kullanılan toplama fonksiyonların bazıları gösterilmektedir (Öztemel, 2006)

Çizelge 2.2. Toplama fonksiyonu türleri (Öztemel, 2006)


Net Giriş Denklemi	Açıklama
NET Girdi Çarpım $= \prod_i X_i W_i$	NET, ağa gelen net girdidir. Her girdi parametresi kendi ağırlık değeri ile çarpılır. Net değer, bu çarpım sonucu elde edilen değerlerin birbirleriyle çarpılması sonucu bulunur.
Maksimum Net Girdi $= (\max X_i W_i)$, $i = 1, \dots, N$	Tüm girdi parametreleri kendi ağırlık değeri ile çarpılır. Net girdi değeri için çarpılan bu değerler karşılaştırılarak en büyük değerli olanı seçilir.
Minimum Net Girdi $= (\min X_i W_i)$, $i = 1, \dots, N$	Tüm girdi parametreleri kendi ağırlık değeri ile çarpılır. Net girdi değeri için çarpılan bu değerler karşılaştırılarak en küçük değerli olanı seçilir.
Çoğunluk Net Girdi $= \sum_i \text{sgn}(X_i W_i)$	Net girdi değerini hesaplayabilmek için, kendi ağırlıkları ile çarpılan girdi değerlerinin işaret fonksiyonu elde edilir, ardından değerler toplanır.
Kümülatif Toplam NET Girdi $= \text{Net(eski)} + \sum_i^n X_i W_i$	Net girdi değerini hesaplayabilmek için, gelen her bilgi kendi ağırlıkları ile çarpılır, bu çarpımlar toplanır, ardından önceki bilgilere eklenerek bulunur.

2.2.5.4 Hücresinin çıkışı


Birden çok girdisi olan işlem elemanının tek çıktı değeri olduğu gibi girdi değerleri aynı zamanda çıktı değeri de olabilir. Bir işlem elemanına ait çıkış değerlerinin çoğunlukla $[-1 \ 1]$ ya da $[0 \ 1]$ değer aralıklarında olması istenir. Çıktı, ağ dışı kaynak veya bağlantılı olduğu işlem elemanlarına transfer fonksiyonunun sonuçlarını gönderir (Aktaş, 2016).

2.2.6 Yapay sinir ağı modelleri

Tek yönlü sinyal akışını, en genel ve en basit YSA'lar kullanırlar. İki bölümde genel olarak YSA'lar, geri beslemeli ve ileri beslemeli olarak sınıflandırılmaktadır. İleri ve geri beslemeli YSA sırasıyla Şekil 2.5 ve Şekil 2.6'da gösterilmiştir. İleri beslemeye sahip YSA yapıları içerisinde gecikmeler yoktur ancak geri beslemeye sahip YSA yapıları içerisinde gecikmeler vardır. Ağ ağırlıkları, öğreticiden istenen çıkış değerleri ile çıkış değerlerinin karşılaştırılması sonucu güncel hata sinyali elde edilir. İleri beslemeli bir ağ, geri beslemeliye sahip YSA'daki çıkışların girişlere bağlanmasıyla elde edilir (Yurtoğlu, 2005)



Şekil 2.5. İleri beslemeli yapı



Şekil 2.6. Geri beslemeli yapı

2.2.7 Öğrenme algoritmaları

Birçok öğrenme algoritması literatürde yer almaktadır. Öğrenme algoritmaları başlığı altında, geri yayımlı öğrenme algoritmaları olarak öğrenme algoritmaları içerisinde oldukça başarılı olan Levenberg-Marquardt (LM) öğrenme algoritmasına dair bilgiler verilmiştir.

2.2.7.1 Geriye yayılım öğrenme algoritması

Geriye yayılım algoritmaları giriş, çıkış ve gizli katman bölümlerinden meydana gelir. Hiyerarşik bir ağ yapısına sahiptirler. Gizli katmanda yer alan düğüm sayısı ve gizli katman değiştirilebilir. Öğrenme işleminin süresini, artan düğüm sayısının ağırlık hatırlama yeteneğini arttırmasıyla uzatmaktadır. Hatırlama yeteneğini azaltmakta etken olan durum, eğitim süresini kısaltan düğüm sayısının azalmasıdır. Giriş ve çıkış katmanlarında yer alan düğümler kendilerinden sonraki katmandaki düğümlere bağlanırlar. Aynı katmanlarda bu işlem yapılamaz. Katmanların çıkış değerleri kendilerinden sonra gelen katmanların giriş değerleridirler. İleri besleme, ağırlık girişinden çıkışına doğru giriş değerlerinin bu şekilde ilerlemesine denir. Geri yayımdaki hatalar, çift yönlü hafıza tekniği ile ileri besleme yolunu izleyerek geriye yayılım gösterir (Aktaç, 2016).


Gizli katmanın ağırlıklar, geri yayımlı öğrenme kullanıldığı zaman, sonraki katmanlara ait hatalar kullanılarak ayarlanır. Böylelikle son gizli katmanla çıkış katmanı arasında yer alan ağırlıklar ayarlanır. İlk gizli katmana kadar bu işlemler aynı biçimde tekrarlanır. Bu işlemler, ‘toplam hata’ en az seviyeye indirilinceye kadar tamamlanan çalışma süresince tekrarlanır.

Sinir ağının eğitici sınıfına, genel bir algoritma olan geri yayılım algoritması girer. Giriş ve çıkışlar arasında bulunan hata sinyali bulunarak, ağırlık değerleri bu hata sinyaline göre güncellenmektedir. Denklem (2.21)’de hata yani $e(k)$, sinir ağı çıkışı ($o(k)$) ve gerçek çıkış ($y(k)$) arasındaki fark gösterilmiştir.


$$e(k) = y(k) - o(k) \quad (2.21)$$

İleri ve geri yönlü çok katmanlı YSA Şekil 2.7a ve Şekil 2.7b’de görülmektedir. Giriş ve çıkış katmanı arasında yer alan katman veya katmanlara gizli katmanlar da

denilmektedir. Deneme yanılma tekniği ile kullanılması gereken gizli katman ve nöron sayısı hesaplanır (Aktaç, 2016).



a) İleri besleme ağı



b) Geri besleme ağı

Şekil 2.7. Çok katmanlı sinir ağı

2.2.7.2 Levenberg - Marquardt öğrenme algoritması

Geri yayılım algoritmasının sonuca yavaş ulaşması taşıdığı bir dezavantajdır. Geri yayılım bir düşme algoritması iken, LM tarafından oluşturulan algoritma Newton'un algoritmasına yaklaşım sergilemektedir. Adım düşme metodunun sağlamlığıyla newton metodunun hızlarının bileşkesi, LM algoritmasıdır (Yurtoğlu, 2005).

x parametresine göre minimize etmek istediğimiz $E(x)$ fonksiyonuna sahip olduğumuzu düşünelim. Newton metoduna göre Denklem (2.22)'deki gibi olacaktır.

$$\Delta x = (\Delta^2 E(x))^{-1} \Delta E(x) \quad (2.22)$$

Burada Hessian matrisi $\Delta^2 E(x)$ ifadesidir ve $\Delta E(x)$ ise β eğim sabiti, Σ net girişi belirleyen toplama fonksiyonudur. e_i 'in (tahmin edilen değerler) karelerin toplamının fonksiyonu $E(x)$ olduğundan;

$$E(x) = \sum_{i=1}^N e_i^2(x) \quad (2.23)$$

Denklem (2.23)'teki gibi yazılabilir. $\Delta E(x)$ ve $\Delta^2 E(x)$ ait formül Denklem (2.24) ve Denklem (2.25)'te gibi gösterilebilir.

$$\Delta E(x) = J^T(x) \cdot e(x) \quad (2.24)$$

$$\Delta^2 E(x) = J^T(x) \cdot J(x) + S(x) \quad (2.25)$$

burada $J(x)$ Jacobian matrisi olarak adlandırılır ve Denklem (2.26)'deki gibi gösterilir.

$$J(x) = \begin{bmatrix} \frac{\partial e_1(x)}{\partial x_1} & \frac{\partial e_1(x)}{\partial x_2} & \dots & \frac{\partial e_1(x)}{\partial x_n} \\ \frac{\partial e_2(x)}{\partial x_1} & \frac{\partial e_2(x)}{\partial x_2} & \dots & \frac{\partial e_2(x)}{\partial x_n} \\ \frac{\partial e_N(x)}{\partial x_1} & \frac{\partial e_N(x)}{\partial x_2} & \dots & \frac{\partial e_N(x)}{\partial x_n} \end{bmatrix} \quad (2.26)$$

$$S(x) \text{ ise } S(x) = \sum_{i=1}^N e_i(x) \nabla^2 e_i(x) \quad (2.27)$$

olarak ifade edilir. Sonrasında, Gauss-Newton yöntemi için Denklem (2.27) takribi olarak kabul edilir ve Δx Denklem (2.28)'de verilen biçimde gösterilir.

$$\Delta x = (J^T(x).J(x))^{-1} . J^T(x).e(x) \quad (2.28)$$

Gauss-Newton denklemi, LM denkleminin değişime uğramış haliyle Denklem (2.29)'da verilmiştir.

$$\Delta x = (J^T(x).J(x) + \mu I)^{-1} . J^T(x).e(x) \quad (2.29)$$

μ parametresi, bir adım $E(x)$ artırılarak β ile çarpılır. $E(x)$ bir adım azaltışında, μ (momentum) parametresi β 'ya bölünür. Küçük bir μ parametresi nedeniyle algorithmada Gauss-Newton yaklaşımı oluşturulurken, μ büyük değerde olduğunda ise algoritma içerisinde adım düşümü ($1/\mu$ basamak ile) olur. Adım Jacobian matrisinin hesaplanması, bu algorithmadaki anahtardır. Sonuç itibariyle LM algoritması çok fazla bellek getirmesinin dezavantajının yanında çok hızlı olarak çözüme ulaşmayı sağlar. Geri yayılım algoritması daha az bellek gerektirmesi avantaj iken sonuca yavaş ulaşması bir dezavantajdır.

Nöron sayısı azaltılmış olan bir sinir ağının eğitiminde en iyi eğitim algoritmasının bile güçlük çektiği bilinmektedir. Çizelge 2.3'de LM metoduna ait bilgiler paylaşılmıştır (Yu ve ark., 2011).

Çizelge 2.3. Eğitim algoritmaları

Fonksiyon	Açıklama
traincgb	traincgp gibi sonucuna ulaşma noktasında hızlı sonuç verebilmekte ancak işlem ve hafıza yeterliliği noktasında traincgf'in gerisindedir. Gradyan algoritması olarak Powell-Beale tarafından geliştirilmiştir.
traincsg	Eğitim algoritması şeklinde kullanılan CG algoritmasıdır.
traincgp	Problemin sonucuna ulaşma noktasında hızlı sonuç verebildiği gibi işlem ve hafıza yeterliliği noktasında traincgf'in gerisindedir. CG algoritması olarak Polak-Ribiere aracılığıyla geliştirilmiştir.
trainbfg	Sonuca daha kısa adımda ulaşan BFGS Quasi-Newton yöntemidir.
traincgf	Eşlenik Gradyan (CG) algoritması olarak standart algoritmaya göre az işlem ile sonuca gidilir. Fletcher-Reeves metodunu kullanır.
trainoss	Quasi-Newton ve CG algoritmalarını bir araya getiren birleştiren tek adım Sekant metodudur.

2.3. Destek Vektör Regresyon


Schölkopf ve Smola tarafından destek vektör makinelerine ait regresyon problemlerinin çözümünde kullanılması için kapsamlı bir çalışma yapılmıştır. Eğitim örnekleri $\{(x_i, y_i)\}_{i=1}^N$ şeklinde verildiğinde, regresyon problemleri içerisindeki yanıt değişkeni $y_i \in \{+1, -1\}$ yerine $y_i \in \mathbb{R}$ şeklinde tanımlanmaktadır (Yalçın, 2016).

DVR içerisinde destek vektör makineleri için sınıflandırmada kullanılan temel parametreler birbirine benzemesine karşın aralarında küçük farklar da bulunmaktadır. Denklem (2.30)'daki koşulları, veri setinin sağladığını kabul edelim.

$$\begin{aligned} (x_1, y_1), (x_2, y_2), \dots, (x_i, y_i), \quad x \in R^d, y \in R \\ f(x) = w \cdot x_i + b \end{aligned} \quad (2.30)$$

Denklem (2.30) içerisinde x_i d boyutlu olan uzayın girdi vektörünü, çıktı vektörlerini w , hiper düzlemin normali yani ağırlık vektörünü ve sapmayı da b temsil eder (Erdoğan, 2019).


En küçük karelere ait hata ölçütünü gösteren ve karesel kayıp fonksiyonunun bir parçası olan grafik Şekil 2.8a'da verilmiştir Şekil 2.8b'de Laplace kayıp fonksiyonu gösterilmiştir. Şekil 2.8c, robust yani optimal özelliğe sahip olan sağlam kayıp fonksiyonunu tanımlamaktadır. Destek vektör sayısını arttırabilecek seyreklik (sparseness) özelliğine sahip olmaları, bu üç kayıp fonksiyonun benzer noktasıdır. Bundan dolayı Şekil 2.8d'de gösterilen ϵ -duyarsız (ϵ -insensitive) kayıp fonksiyonu, DVR'de marjin önerilmiştir (Anand ve ark., 2020).



Şekil 2.8. Kayıp fonksiyonları

2.3.1 Doğrusal destek vektör regresyon

DVR’de x ve y arasındaki ilişkinin lineer olduğu varsayılır. Başlangıçta eğitim hatasına ait maksimum değerin belirlenmiş olması, hata teriminin ε ’ye eşit veya daha küçük veriler, hatasız olarak temsil edilmesi demektir. Doğrusal regresyon fonksiyon grafiği Şekil 2.9’da verilmiştir (Erdoğan, 2019).



Şekil 2.9. Doğrusal regresyon fonksiyonu için ε tüpü

Kayıp fonksiyonu olan $f(x)$ 'in kullanılmasıyla birlikte; x_i regresyon modeline ait bağımsız değişkeni, y_i bağımlı değişkeni ifade etmesiyle birlikte ε tüpünde bütün verilerin $[-\varepsilon, \varepsilon]$ hata terimi) yer aldığı kabul edilirse Denklem (2.31) oluşturulabilir (Erdoğan, 2019)


$$f(x) = w \cdot x_i + b$$

$$-\varepsilon \leq y_i - w^T \cdot x_i - b \leq \varepsilon \quad (2.31)$$

Soft margin yaklaşımı içerisindeki sapmaları temsil edecek değişkenlere, ε tüpü içerisinde sapma durumlarına müsaade edilmeye çalışıldığında ihtiyaç duyulur. Bu değişkenlere ait grafik Şekil 2.10'da verilmiştir. ξ aylak değişken olmak üzere, Denklem (2.32) ve Denklem (2.33)'teki her kısıt için $\xi_i^+, \xi_i^- \geq 0$ şeklinde değişkenler tanımlanır.

$$y_i - w^T \cdot x_i - b \leq \varepsilon + \xi_i^+ \quad (2.32)$$

$$y_i - w^T \cdot x_i - b \geq -\varepsilon - \xi_i^- \quad (2.33)$$



Şekil 2.10. Doğrusal destek vektör regresyon

Marjinin $[-\varepsilon, \varepsilon]$ duyarlılığı içerisinde en büyük değere ulaşması, genelleştirme yeteneği adına yüksek bir fonksiyon değeri belirleyebilmek için gereklidir. Böylelikle en iyi model Denklem (2.34), Denklem (2.35), Denklem (2.36) ve Denklem (2.37)'de gösterilir. w^T ağırlık transpozesidir.

$$enk \frac{1}{2} \|w\|^2 + C \sum_{i=1}^n (\xi_i^+ + \xi_i^-) \quad (2.34)$$

$$y_i - w^T \cdot x_i - b \leq \varepsilon + \xi_i^+ \quad (2.35)$$

$$w^T \cdot x_i + b - y_i \leq \varepsilon + \xi_i^- \quad (2.36)$$

$$\xi_i^+, \xi_i^- \geq 0 \quad (2.37)$$

Regresyon fonksiyonuna ait genelleştirme yeteneği ile ε 'dan büyük değerlerde kabul edilecek sapmalar, amaç fonksiyonu içerisinde kullanılan C 'yi (ceza parametresini) içermektedir (Ekinçi ve ark., 2017).

C hataların uyarlanmasıyla regresyon fonksiyon düzlüğü arasında yer alan dengeyi sağlamakla görevli bir parametredir (İnce ve ark., 2016). Lagrange çarpanları kullanılarak, kısıtlamalara ilişkin hata fonksiyonunu en aza indirebilmek için Denklem (2.38) kullanılır. $a_i^- \geq 0, a_i^+ \geq 0, \mu_i^- \geq 0, \mu_i^+ \geq 0$ koşullarını Denklem (2.38) yerine getirmektedir.

$$L_p = C \sum_{i=1}^L (\xi_i^+ + \xi_i^-) + \frac{1}{2} \|w\|^2 + \sum_{i=1}^L (\mu_i^+ \xi_i^+ + \mu_i^- \xi_i^-) - \sum_{i=1}^L a_i^+ (\varepsilon + \xi_i^+ + y_i - f(x_i)) - \sum_{i=1}^L a_i^- (\varepsilon + \xi_i^- - y_i + f(x_i)) \quad (2.38)$$

Optimal çözüm içerisinde b , w , ξ_i^- ve ξ_i^+ değişkenlerine göre L_p 'ye ait kısmi türevler 0'a eşitlenir. Denklem (2.39), Denklem (2.40), Denklem (2.41) ve Denklem (2.42)'de gösterilmiştir.

$$\frac{\partial L_p}{\partial w} = 0 \rightarrow w = \sum_{i=1}^L (a_i^+ - a_i^-) \cdot x_i \quad (2.39)$$

$$\frac{\partial L_p}{\partial b} = 0 \rightarrow w = \sum_{i=1}^L (a_i^+ - a_i^-) = 0 \quad (2.40)$$

$$\frac{\partial L_p}{\partial \xi_i^+} = 0 \rightarrow C = a_i^+ - \mu_i^+ \quad (2.41)$$

$$\frac{\partial L_p}{\partial \xi_i^-} = 0 \rightarrow C = a_i^- + \mu_i^- \quad (2.42)$$

Veri setine ait değerlerin Denklem (2.43)'teki koşulları sağladığı varsayılarak Denklem (2.38) ve Denklem (2.39), Denklem (2.40)'ta yerine yerleştirilir ve L_p , a_i^+ ve a_i^- 'ye göre maksimum elde edilir.

$$0 \leq a_i^+, a_i^- \leq C \quad \sum_{i=1}^L (a_i^+ - a_i^-) = 0 \quad \forall_i$$

$$L_p = \sum_{i=1}^L (a_i^+ - a_i^-) f(x_i) - \epsilon \sum_{i=1}^L (a_i^+ - a_i^-) - \frac{1}{2} \sum_{i,j} (a_i^+ - a_i^-) ((a_j^+ - a_j^-) \cdot x_i \cdot x_j \quad (2.43)$$

Denklem (2.39); Denklem (2.34), Denklem (2.35), Denklem (2.36) ve Denklem (2.37)'de yerine yerleştirildiğinde tahmin fonksiyonu Denklem (2.44)'teki gibi olur.


$$f(x) = \sum_{i=1}^L (a_i^+ - a_i^-) \cdot x_i \cdot x + b \quad (2.44)$$

S destek vektörleri $0 \leq a \leq C$ ve $\xi_i^+ = 0$ (veya $\xi_i^- = 0$) şartlarını sağlayan i indisleri bulunarak oluşturulabilir. Denklem (2.45)'te verilmiştir (Erdoğan, 2019).

$$b = f(x_S) - \epsilon - \sum_{m \in S} (a_m^+ - a_m^-) \cdot x_m \cdot x_S \quad (2.45)$$

2.3.2 Doğrusal olmayan destek vektör regresyon

Dual amaç fonksiyonunda çekirdek hilesi, DVR'ye ait girdi uzayındaki veriler iç çarpım olarak ifade edildiği durumlar içerisinde kullanılmaktadır. Öznitelik uzayın genişletilerek Şekil 2.11'de verilen girdi uzayı içerisinde nonlineer fonksiyonlar, lineer öğrenim makineleriyle oluşturulabilirler (Erdoğan, 2019).



Şekil 2.11. Doğrusal olmayan regresyon fonksiyonu için ϵ tüpü

DVR'nin doğrusal olmayan duruma genelleştirilmesine yönelik x_i örnekleri $\phi = \mathbb{R}^D \rightarrow H$ fonksiyonunun yardımıyla özellik uzayına haritalanmaktadır. DVR yalnızca x_i örneklerinin iç çarpımlarıyla ilişkili olduğundan ϕ fonksiyonunu bilmemize gerek kalmaksızın $k(x_i, x_j) = \phi(x_i) \cdot \phi(x_j)$ fonksiyonunu hesaplanması yeterli

olacaktır. NLR’de doğrusal olarak ayrılamayan sınıflandırıcılarla aynı adımlar izlenir ve LR’ye benzer bir şekilde çözüme ulaştırılır. Ancak özellik uzayına veriyi taşıma veya kernel fonksiyonu kullanılarak çözüm sağlanır. Denklem (2.46), Denklem (2.47) ve Denklem (2.48)’de ilgili denklemler verilmiştir (Yalçın, 2016).

$$\max \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N (a_i^+ - a_i^-)(a_j^+ - a_j^-)k(x_i, x_j) - \varepsilon \sum_{i=1}^N (a_i^+ - a_i^-) - \sum_{i=1}^N y_i (a_i^+ - a_i^-) \quad (2.46)$$

$$\sum_{i=1}^N (a_i^+ - a_i^-) = 0 \quad (2.47)$$

$$0 \leq a_i^+, a_i^- \leq C \quad (2.48)$$

Ağırlıklar ve tahmin fonksiyonu Denklem (2.49) ve Denklem (2.50)’deki gibi yazılır.

$$w = \sum_{i=1}^N (a_i^+ - a_i^-) \phi(x_i) \quad (2.49)$$

$$f(x) = \sum_{i=1}^N (a_i^+ - a_i^-) k(x_i, x_j) + b \quad (2.50)$$

2.4. Hata Metrikleri

Bu çalışmada, PSO-YSA-DVR modellerinin tahmin başarısını yorumlamak için yaygın olarak kullanılan bazı istatistiksel kriterler kullanılmıştır. Hata ölçümleri; *MSE*, R^2 , *RMSE* ve *MAE* içerir. *MAE* ve *RMSE*, sırasıyla tahmin edilen değer tutarsızlığını ve gerçek değere yakınlığı değerlendirir. *MSE*, tahmini değerlerin gerçek değerden sapmasını temsil eder. *RMSE* ve *MAE* değerlerinin düşük olması arzu edilir. Ayrıca R^2 , gerçek ve tahmin edilen değerler arasındaki ilişkiyi belirtir (Zhang ve ark. 2020).

R^2 , bağımlı değişkendeki değişikliklerin ne kadarının bağımsız değişkendeki değişikliklerden kaynaklandığını gösterir ve $1 > R^2 > 0$ arasında değer almalıdır. R^2 değeri 1'e ne kadar yakınsa, regresyon doğrusunun o kadar iyi uyduğu söylenebilir. Başka bir deyişle, bağımlı değişkendeki değişikliklerin bu kadar bağımsız değişkendeki değişikliklerden kaynaklandığı söylenebilir. R^2 , *RMSE*, *MSE* ve *MAE* formülleri Denklem (2.51), Denklem (2.52), Denklem (2.53) ve Denklem (2.54)'te verilmektedir (Sağlam ve ark., 2022).

$$R^2 = \frac{(\sum_{i=1}^N (x_i^* - \bar{x}_i^*)(x_i - \bar{x}_i))^2}{\sum_{i=1}^N (x_i^* - \bar{x}_i^*)^2 \sum_{i=1}^N (x_i - \bar{x}_i)^2} \quad (2.51)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i^* - x_i)^2} \quad (2.52)$$

$$MSE = \frac{1}{N} \sum_{i=1}^N (x_i - x_i^*)^2 \quad (2.53)$$

$$MAE = \frac{1}{N} \sum_{i=1}^N |x_i - x_i^*| \quad (2.54)$$

Not: $x_i, x_i^*, N, \bar{x}_i, \overline{x_i^*}$ sırasıyla tahmin edilen değeri, gerçek değeri, örneklem büyüklüğünü, ortalama tahmin edilen değeri ve ortalama gerçek değeri temsil eder.

2.5. Veri Kaynakları

1980-2019 yılları arasındaki elektrik tüketimi TEİAŞ kurumundan temin edilmiştir. Nüfus, TÜİK'ten alınmıştır. GSYH, ithalat ve ihracat değerleri Dünya Bankası Açık Veri Kümesinden alınmıştır.

3. ARAŞTIRMA SONUÇLARI VE TARTIŞMA

Ekonomik göstergelere dayalı olarak 2020-2040 yılları arasında enerji tüketimi için yapılacak tahmin için lineer model Denklem (3.1) önerilmiştir.

$$E_{linear} = w_1 \cdot X_1 + w_2 \cdot X_2 + w_3 \cdot X_3 + w_4 \cdot X_4 + w_5 \quad (3.1)$$

Tasarım modellenirken Denklem (3.1)'de yer alan X_1 ithalat, X_2 ihracat, X_3 GSYH ve X_4 nüfus parametrelerini, w ise modelin ağırlık veya katsayısını temsil etmektedir.

$$mif(v) = \sum_{r=1}^R [E_r^{gözlemlenen} - E_r^{tahmin edilen}]^2 \quad (3.2)$$

$E_r^{gözlemlenen}$: 1980-2019 yılları arasındaki tüketilen enerji

$E_r^{tahmin edilen}$: 2040 yılına kadar tahmin edilen enerji

Geçmiş dönemdeki parametrelerden faydalanarak oluşturulacak modelin amaç fonksiyonu Denklem (3.2)'de verilmiştir. Türkiye'nin 1980-2019 yılları arasında gerçekleşen ithalat, ihracat, GSYH, nüfus ve enerji tüketim verileri Çizelge 3.1'de verilmiştir.

Çizelge 3.1. 1980-2019 Yılları arasında gerçekleşen ekonomik ve enerji göstergeleri

Yıllar	İthalat (\$ 10^9)	İhracat (\$ 10^9)	GSYH (\$ 10^9)	Nüfus (10^6)	Enerji Talebi TWh
1980	8.20	3.55	173.33	43.97	20.40
1981	9.16	5.85	181.75	44.98	22.03
1982	9.69	7.65	188.22	46.02	23.59
1983	10.21	7.69	197.58	47.07	24.47
1984	11.80	9.36	210.84	48.11	27.64
1985	12.75	10.66	219.79	49.13	29.71
1986	12.19	10.08	235.20	50.12	32.21
1987	15.47	13.58	257.51	51.10	36.70
1988	15.94	16.94	263.48	52.05	39.72
1989	19.05	17.36	264.25	52.99	43.12
1990	26.48	20.13	288.74	53.92	46.82
1991	24.95	20.76	290.82	54.84	49.28
1992	27.48	22.80	305.46	55.74	53.98
1993	34.85	24.63	328.83	56.65	59.24
1994	26.63	27.91	313.48	57.56	61.40
1995	41.27	33.71	338.18	58.48	67.39
1996	50.49	39.09	363.14	59.42	74.16
1997	57.68	46.66	390.65	60.37	81.88
1998	54.34	56.72	400.04	61.32	87.70

1999	48.16	47.53	386.99	62.28	91.20
2000	61.56	53.09	413.82	63.24	98.30
2001	45.69	53.22	390.03	64.19	97.07
2002	54.83	58.32	415.17	65.14	102.95
2003	72.83	69.35	439.10	66.08	111.77
2004	102.69	92.09	482.12	67.01	121.14
2005	122.44	105.38	525.47	67.90	127.07
2006	146.41	119.61	561.98	68.75	176.00
2007	176.16	143.39	590.33	69.58	189.00
2008	206.98	174.46	595.14	70.41	198.00
2009	150.58	145.51	566.43	71.32	194.00
2010	196.45	157.84	614.17	72.32	210.43
2011	253.09	185.33	682.95	73.44	230.31
2012	249.76	206.84	715.66	74.65	242.37
2013	266.90	211.71	776.39	75.92	248.32
2014	258.30	222.00	814.74	77.23	257.32
2015	223.15	200.72	864.31	78.52	265.72
2016	214.63	189.71	893.03	79.82	277.52
2017	249.70	211.24	960.03	81.10	292.00
2018	236.24	227.78	988.64	82.31	302.37
2019	224.66	238.50	997.43	83.42	303.67

TWh: Teravatsaat

Korelasyon matrisi, bir veri setindeki birden fazla değişkenin etkisini incelemek için kullanılır. Korelasyon matrisinde işaretlerin yanı sıra sayıların büyüklükleri de önemlidir ancak ilişkiler -1 ile 1 arasında tanımlanır. Değerler 1'e yakınsa ikisi arasında güçlü bir doğrusal ilişki vardır denilebilir. Değerler -1'e yakınlarsa, güçlü bir ters ilişki vardır. Değer 0'a yakınsa, veriler arasında doğrusal bir ilişki yoktur (Sağlam ve ark., 2022).

1980-2019 yılları arası gerçekleşen ithalat, ihracat, GSYH ve nüfus olarak belirlenen girdi değerleri ile elektrik tüketimi olarak belirlenen çıktı değeri arasındaki korelasyon matrisi Çizelge 3.2'de gösterilmektedir. İhracat ile elektrik tüketimi arasında güçlü bir doğrusal ilişki (0,991) olduğu görülmektedir. Ayrıca, ithalat ve ihracat arasında güçlü doğrusal bir ilişki (0.9895) vardır.

Çizelge 3.2. Bağımlı ve bağımsız değişkenler arasındaki korelasyon matrisi

Girişler	İthalat	İhracat	GSYH	Nüfus	Elektrik Tüketimi
İthalat	1	0.9895	0.946	0.9232	0.9742
İhracat	0.9895	1	0.9727	0.9478	0.991
GSYH	0.946	0.9727	1	0.9684	0.9892
Nüfus	0.9232	0.9478	0.9684	1	0.9669
Elektrik Tüketimi	0.9742	0.991	0.9892	0.9669	1

Türkiye’de 2020-2040 yılları arasındaki enerji tahmini için Çizelge 3.1’deki gerçekleşen parametrelerin artış miktarları, ekonomik ve sosyal durum göz önüne alınarak düşük, orta ve yüksek olmak üzere 3 senaryo öngörülmektedir. Orta senaryo oluşturulurken ithalat, ihracat ve GSYH büyüme oranları Kıran ve ark.’nın yaptığı çalışmadan (Kıran ve ark., 2012), nüfus artış oranı TÜİK açık veri bankasından elde edilmiştir (TÜİK, 2023). Düşük senaryo oluşturulurken herhangi bir duraksama ihtimali göz önünde bulundurularak orta senaryoya göre daha düşük artış oranları alınmıştır. Aynı şekilde yüksek senaryo oluşturulurken herhangi bir ilerleme ihtimali göz önünde bulundurularak orta senaryoya göre daha büyük artış oranları alınmıştır.

Senaryolar ile ilgili Çizelge 3.3’de belirtilen büyüme tahminleri göz önünde bulundurulmuştur.

Çizelge 3.3. Tahmin için oluşturulan senaryolar

Girdi Parametreleri	Düşük Senaryo	Orta Senaryo	Yüksek Senaryo
İthalat	4.0%	4.5%	5%
İhracat	3.0%	3.5%	4.0%
Gayri Safi Yurtiçi Hasıla	3.0%	4%	5.0%
Nüfus	0.2%	0.4%	0.5%

Bu senaryolar kullanılarak 2020-2040 yılları arasındaki ithalat, ihracat, GSYH ve nüfus tahminleri ortaya çıkarılmıştır. Matlab R2021 b paket programı kullanılarak PSO, YSA ve DVR yöntemleri ile 2020-2040 yılları arasındaki Türkiye’nin enerji talep tahmini yapılmıştır.

3.1. Parçacık Sürü Optimizasyonu ile Enerji Talep Tahmini

PSO modellenirken Çizelge 3.4’te yer alan parametre değerleri kullanılmıştır.


Çizelge 3.4. 1980-2019 Yılları arasında PSO modelin tahmin hataları

Parametre	Değer
Parçacık sayısı	100
Çevrim sayısı	1000
Maksimum eylemsizlik (w_{max})	0.9
Minimum eylemsizlik (w_{min})	0.2
Bilişsel öğrenme (c_1)	2
Sosyal öğrenme (c_2)	2

1980 ve 2019 yılları arasında gerçekleşen ithalat, ihracat, GSYH, nüfus ve enerji tüketim verileri Denklem (3.1) ve Denklem (3.2) kullanılarak modellenmiş ve Denklem (3.3)'te belirtilen denklem elde edilmiştir.

$$E_{linear} = 0.0502 * X_1 + 0.5522 * X_2 + 0.1520 * X_3 + 0.7147 * X_4 - 44.4261 \quad (3.3)$$

Şekil 3.1'de 1980-2019 yılları arasında, PSO modeli kullanılarak elde edilen tahmin değerleri ile gerçekleşen enerji tüketimi değerleri karşılaştırılmaktadır. 1980-2019 yılları arasında PSO modelle tahmin edilen değerlerin, gerçek değerleri başarılı bir şekilde takip ettiği görülmektedir.

**Şekil 3.1.** 1980-2019 yılları arası gerçekleşen enerji tüketim değeri ve PSO enerji tahmini

Çizelge 3.5'te gözlemlenen enerji talebi, PSO model ile tahmin edilen enerji talebi ve hata yüzde oranları gösterilmektedir. Hata yüzdesinin %-29,79 ile %14,32 aralığında değiştiği görülmektedir.

Çizelge 3.5. 1980-2019 Yılları arasında PSO modelin tahmin hataları


Yıllar	Gözlemlenen enerji talebi (TWh)	PSO model ile tahmin edilen enerji talebi (TWh)	Hata Yüzdesi (%)
1980	20.40	15.72	-29.79
1981	22.03	19.04	-15.72
1982	23.59	21.78	-8.29
1983	24.47	24.01	-1.93
1984	27.64	27.77	0.46
1985	29.71	30.62	2.98
1986	32.21	33.32	3.34
1987	36.70	39.51	7.12
1988	39.72	42.98	7.58
1989	43.12	44.15	2.34
1990	46.82	50.44	7.18
1991	49.28	51.69	4.66
1992	53.98	55.81	3.28
1993	59.24	61.39	3.51
1994	61.40	61.11	-0.48
1995	67.39	69.46	2.98
1996	74.16	77.36	4.13
1997	81.88	86.76	5.63
1998	87.70	94.25	6.95
1999	91.20	87.57	-4.14
2000	98.30	96.08	-2.31
2001	97.07	92.42	-5.04
2002	102.95	100.19	-2.75
2003	111.77	111.50	-0.25
2004	121.14	132.76	8.75
2005	127.07	148.31	14.32
2006	176.00	163.53	-7.63
2007	189.00	183.06	-3.25
2008	198.00	203.08	2.50
2009	194.00	180.55	-7.45
2010	210.43	197.64	-6.48
2011	230.31	226.91	-1.49
2012	242.37	244.46	0.86
2013	248.32	258.15	3.81
2014	257.32	270.17	4.76
2015	265.72	265.11	-0.23
2016	277.52	263.89	-5.16
2017	292.00	288.64	-1.16
2018	302.37	302.31	-0.02
2019	303.67	309.78	1.97

Çizelge 3.6’da 2020-2040 yılları arasında düşük, orta ve yüksek senaryolar temelinde PSO modeli kullanılarak elde edilen enerji talep tahmin sonuçları gösterilmektedir.

Çizelge 3.6. PSO modeli ile düşük, orta ve yüksek senaryoya göre enerji talep tahmini

Yıllar	Enerji Talebi TWh		
	Düşük Senaryo	Orta Senaryo	Yüksek Senaryo
2020	318.85	321.20	323.49
2021	328.19	333.05	337.82
2022	337.82	345.34	352.80
2023	347.73	358.09	368.46
2024	357.95	371.32	384.82
2025	368.47	385.05	401.93
2026	379.31	399.30	419.82
2027	390.48	414.08	438.52
2028	401.98	429.42	458.07
2029	413.84	445.33	478.52
2030	426.05	461.85	499.89
2031	438.63	478.98	522.25
2032	451.59	496.77	545.63
2033	464.95	515.23	570.07
2034	478.71	534.38	595.64
2035	492.88	554.26	622.38
2036	507.49	574.89	650.35
2037	522.54	596.31	679.60
2038	538.05	618.53	710.20
2039	554.02	641.60	742.21
2040	570.49	665.54	775.69

Şekil 3.2’de her üç senaryo temelli PSO modeli kullanılarak elde edilen enerji talep tahminleri gösterilmektedir. Her üç senaryo temelli PSO model sonuçlarının lineere yakın olarak arttığı görülmektedir.




Şekil 3.2. 2020-2040 yılları arası senaryolara göre PSO model ile enerji talep tahmini

3.2. Yapay Sinir Ağları ile Enerji Talep Tahmini

YSA yapısı dört nöronlu bir giriş katmanı, 10 nöronlu bir gizli katman ve 1 nöronlu çıkış katmanı olarak modellenmiştir. Levenberg-Marquardt (LM) algoritması YSA'nın eğitiminde sağlamış olduğu hız ve kararlılık nedeni ile tercih edilmiştir. Verilerin %70'i eğitim için, %15'i doğrulama ve %15'i test için kullanılmıştır.

Şekil 3.3'te 1980-2019 yılları arasında YSA modeli kullanılarak elde edilen enerji tahmin değerleri ile gerçekleşen enerji tüketimi karşılaştırılmıştır. 1980-2019 yılları arasında YSA modelle tahmin edilen verilerin, gerçek değerlerle örtüştüğü görülmektedir. Böylece YSA modelinin tahmin performansının çok iyi olduğu söylenebilir.



Şekil 3.3. 1980-2019 yılları arası gerçekleşen enerji tüketim değeri ve YSA enerji tahmini

Çizelge 3.7'de 1980-2019 yılları arasında gözlemlenen enerji talebi, YSA model ile tahmin edilen enerji talebi ve hata yüzde oranları gösterilmektedir. Hata yüzdesinin % -1.24 ile %15.08 aralığında değiştiği gözlemlenmiştir.

Çizelge 3.7. 1980-2019 yılları arasında YSA modelin tahmin hataları


Yıllar	Gözlemlenen enerji talebi (TWh)	YSA ile tahmin edilen enerji talebi (TWh)	Hata Yüzdesi (%)
1980	20.40	20.92	2.47
1981	22.03	22.07	0.17
1982	23.59	23.59	0.00
1983	24.47	25.29	3.24
1984	27.64	27.58	-0.22
1985	29.71	30.09	1.27
1986	32.21	33.23	3.06
1987	36.70	37.15	1.20
1988	39.72	40.56	2.06
1989	43.12	42.68	-1.04
1990	46.82	46.25	-1.24
1991	49.28	50.29	2.01
1992	53.98	54.97	1.80
1993	59.24	60.24	1.66
1994	61.40	63.00	2.54
1995	67.39	67.05	-0.51
1996	74.16	73.81	-0.47
1997	81.88	82.03	0.18
1998	87.70	86.74	-1.10
1999	91.20	90.85	-0.39
2000	98.30	99.02	0.73
2001	97.07	96.36	-0.73
2002	102.95	104.81	1.78
2003	111.77	111.04	-0.66
2004	121.14	122.17	0.85
2005	127.07	149.64	15.08
2006	176.00	175.20	-0.46
2007	189.00	189.95	0.50
2008	198.00	197.73	-0.14
2009	194.00	194.01	0.01
2010	210.43	210.43	0.00
2011	230.31	230.24	-0.03
2012	242.37	242.09	-0.11
2013	248.32	247.95	-0.15
2014	257.32	257.02	-0.11
2015	265.72	276.23	3.80
2016	277.52	277.29	-0.08
2017	292.00	291.71	-0.10
2018	302.37	300.04	-0.78
2019	303.67	303.45	-0.07

Çizelge 3.8’de 2020-2040 yılları arasında ortaya konulan düşük, orta ve yüksek senaryolar temelinde YSA modeli kullanılarak elde edilen enerji talep tahmin sonuçları gösterilmektedir.

Çizelge 3.8. YSA model ile düşük, orta ve yüksek senaryoya göre enerji talep tahmini

Yıllar	Enerji Talebi TWh		
	Düşük Senaryo	Orta Senaryo	Yüksek Senaryo
2020	317.29	319.68	321.99
2021	326.68	331.60	336.43
2022	336.35	343.98	351.53
2023	346.32	356.82	367.32
2024	356.59	370.16	383.83
2025	367.17	384.00	401.09
2026	378.08	398.36	419.15
2027	389.32	413.27	438.04
2028	400.91	428.75	457.80
2029	412.85	444.81	478.47
2030	425.15	461.49	500.09
2031	437.84	478.81	522.70
2032	450.91	496.79	546.37
2033	464.39	515.45	571.12
2034	478.27	534.82	597.02
2035	492.59	554.94	624.13
2036	507.34	575.83	652.48
2037	522.55	597.51	682.16
2038	538.23	620.03	713.21
2039	554.39	643.41	745.71
2040	571.05	667.69	779.72


Şekil 3.4’te üç senaryo temelinde YSA modeli kullanılarak elde edilen enerji talep tahminleri gösterilmektedir. Her üç senaryo temelli YSA modeli kullanılarak elde edilen sonuçlar lineere yakın bir biçimde arttığı görülmektedir.



Şekil 3.4. 2020-2040 yılları arası senaryolara göre YSA enerji talep tahmini

3.3. Destek Vektörü Regresyonu ile Enerji Talep Tahmini

Şekil 3.5'te 1980-2019 yılları arasında DVR modeli kullanılarak elde edilen enerji talep tahmini ile gerçekleşen enerji tüketimi karşılaştırılmıştır. Şekil 3.5 incelendiğinde DVR modelin gerçek değeri takip etmeye çalıştığı görülmektedir.



Şekil 3.5. 1980-2019 yılları arası gerçekleşen enerji tüketim değeri ve DVR enerji tahmini

Çizelge 3.9’da 1980-2019 yılları arasında gözlemlenen enerji talebi, DVR modelle tahmin edilen enerji talebi ve hata yüzde oranları gösterilmektedir. Hata yüzdesinin % -200 ile %15.51 aralığında değiştiği görülmektedir.

Çizelge 3.9. 1980-2019 Yılları arasında DVR ile oluşturulan modelin tahmin hataları


Yıllar	Gözlemlenen enerji talebi (TWh)	Tahmin edilen enerji talebi (TWh) DVR-LR	Hata Yüzdesi (%)
1980	20.40	6.80	-200.00
1981	22.03	12.40	-77.66
1982	23.59	14.22	-65.89
1983	24.47	17.12	-42.93
1984	27.64	21.00	-31.62
1985	29.71	24.10	-23.28
1986	32.21	27.14	-18.68
1987	36.70	35.59	-3.12
1988	39.72	39.22	-1.27
1989	43.12	35.56	-21.26
1990	46.82	45.59	-2.70
1991	49.28	43.20	-14.07
1992	53.98	49.45	-9.16
1993	59.24	59.48	0.40
1994	61.40	61.32	-0.13
1995	67.39	67.80	0.60
1996	74.16	72.38	-2.46
1997	81.88	82.08	0.24
1998	87.70	85.30	-2.81
1999	91.20	82.38	-10.71
2000	98.30	94.52	-4.00
2001	97.07	92.66	-4.76
2002	102.95	91.95	-11.96
2003	111.77	110.90	-0.78
2004	121.14	132.10	8.30
2005	127.07	150.40	15.51
2006	176.00	159.30	-10.48
2007	189.00	182.60	-3.50
2008	198.00	199.70	0.85
2009	194.00	176.30	-10.04
2010	210.43	196.00	-7.36
2011	230.31	226.40	-1.73
2012	242.37	241.50	-0.36
2013	248.32	266.70	6.89
2014	257.32	277.60	7.31
2015	265.72	265.90	0.07
2016	277.52	253.70	-9.39
2017	292.00	292.80	0.27
2018	302.37	304.90	0.83
2019	303.67	310.20	2.10

Çizelge 3.10’da 2020-2040 yılları arasında ortaya konulan düşük, orta ve yüksek senaryolar temelinde DVR modeli kullanılarak elde edilen enerji talep tahmin sonuçları gösterilmektedir.

Çizelge 3.10. DVR ile düşük, orta ve yüksek senaryoya göre enerji talep tahmini

Yıllar	Enerji Talebi TWh		
	Düşük Senaryo	Orta Senaryo	Yüksek Senaryo
2020	315.05	319.60	319.70
2021	304.54	333.30	339.60
2022	336.34	339.10	354.40
2023	343.26	349.20	369.80
2024	339.47	341.30	368.00
2025	351.28	377.70	381.80
2026	355.27	386.80	400.40
2027	372.42	392.60	443.60
2028	374.65	411.10	435.70
2029	350.87	427.00	454.60
2030	390.98	429.60	505.90
2031	399.72	450.50	490.10
2032	406.56	455.60	511.00
2033	415.72	445.90	566.10
2034	381.98	480.70	562.30
2035	434.52	473.30	636.80
2036	443.73	487.70	643.50
2037	452.47	502.50	671.70
2038	408.15	543.10	717.00
2039	476.76	574.40	684.70
2040	485.43	594.20	714.00


Şekil 3.6’da üç senaryo temelinde DVR modeli kullanılarak elde edilen enerji talep tahminleri gösterilmektedir. Düşük, orta ve yüksek senaryolar kullanılarak elde edilen enerji talep tahminleri zikzaklı bir şekilde arttığı görülmektedir.



Şekil 3.6. 2020-2040 yılları arası senaryolara göre DVR enerji talep tahmini

3.4. PSO-YSA ve DVR Modellerinin Tahmin Karşılaştırması

Şekil 3.7’de 1980-2019 yılları arasında gerçekleşen enerji tüketimi ile PSO, YSA ve DVR modelleri kullanılarak elde edilen enerji tahminleri karşılaştırılmıştır. 1980-2004 yılları arasında her üç model ile tahmin edilen verilerin gerçek değerlerle örtüştüğü, 2004 yılından sonra YSA model tahmini ile gerçek değerlerin tam olarak örtüşmeye devam ettiği ancak diğer modellerin gerçek değeri takip etmeye çalıştığı gözlemlenmiştir.



Şekil 3.7. 1980-2019 yılları arası gerçekleşen enerji tüketim değeri ile PSO-YSA-DVR modelleri sonucu elde edilen enerji tahmin değerleri

3.5. PSO-YSA ve DVR Model Tahminlerinin Performans Sonuçları

Çizelge 3.11’de YSA, PSO ve DVR modelleri ile ortalama R^2 , $RMSE$, MSE ve MAE değerleri elde edildi. Her üç yöntem tahmin performanslarının iyi olduğu ancak YSA modeli tarafından elde edilen R^2 , MAE , MSE ve $RMSE$ değerlerinin PSO ve DVR modellerine göre daha iyi sonuçlar verdiği görülmektedir.

Çizelge 3.11. Anakara istatistiksel analiz sonuçları

Hata Metrikleri	Yöntemler		
	YSA	PSO	DVR
MSE	16.097	46.775	94.294
RMSE	4.012	6.839	9.710
MAE	1.4035	4.856	7.019
R^2	0.9982	0.9945	0.9908

3.6. Çoklu Regresyon Denklemleri

Bu bölümde girdi parametreleri (X_1 , X_2 , X_3 , X_4) olan ithalat, ihracat, GSYH, nüfus) bazında F denklemi üzerinden tahminin performans değerlendirmesi yapılmakta ve sonuçlar sunulmaktadır. Parametreler (X_1 , X_2 , X_3 , X_4) farklı alt kümeler (vb. X_1 , X_2 , X_3 veya X_2 , X_3) ayrılır ve performansları incelenir. Performansları incelemek için R^2 değerleri hesaplanmıştır (Sağlam ve ark., 2022).

Çizelge 3.12. Çoklu alt küme parametreleri, regresyon denklemleri ve R^2 performansı

Sıra No	Parametreler	Çoklu Regresyon Denklemleri	R^2
1	X_1, X_2, X_3, X_4	$F = -49.914 + 0.089284 * X_1 + 0.48065 * X_2 + 0.15825 * X_3 + 0.78607 * X_4$	$R^2 = 0.995$
2	X_2, X_3, X_4	$F = -47.462 + 0.61379 * X_2 + 0.14806 * X_3 + 0.78086 * X_4$	$R^2 = 0.994$
3	X_1, X_3, X_4	$F = -64.02 + 0.3626 * X_1 + 0.21054 * X_3 + 0.8503 * X_4$	$R^2 = 0.993$
4	X_3, X_4	$F = -102.91 + 0.32548 * X_3 + 1.1863 * X_4$	$R^2 = 0.98$
5	X_1, X_2, X_4	$F = -82.719 - 0.12819 * X_1 + 1.0247 * X_2 + 2.0838 * X_4$	$R^2 = 0.99$
6	X_2, X_4	$F = -90.488 + 0.8576 * X_2 + 2.2348 * X_4$	$R^2 = 0.99$
7	X_1, X_4	$F = -167.68 + 0.5579 * X_1 + 3.763 * X_4$	$R^2 = 0.98$
8	X_1, X_2, X_3	$F = -16.317 + 0.086601 * X_1 + 0.49675 * X_2 + 0.1895 * X_3$	$R^2 = 0.994$
9	X_2, X_3	$F = -14.155 + 0.62581 * X_2 + 0.17942 * X_3$	$R^2 = 0.994$
10	X_1, X_3	$F = -28.091 + 0.36962 * X_1 + 0.24634 * X_3$	$R^2 = 0.993$
11	X_1, X_2	$F = 23.942 - 0.30766 * X_1 + 1.5105 * X_2$	$R^2 = 0.984$

Çizelge 3.12'de alt kümelerine ayrılan parametreler, bu parametrelere ilişkin denklemler ve R^2 performansları sunulmaktadır. İlk satırda gösterilen ve dört parametreyi (X_1, X_2, X_3, X_4) içeren regresyon denklemi en yüksek (0,995) R^2 değerine sahiptir. Bu nedenle, dört parametreyi içeren denklem, F denklemlerini güçlü bir şekilde temsil eder. Çizelge 3.11'de gösterilen Denklem (4)'teki X_1, X_2 ve Denklem (7)'deki X_2, X_3 değişkenlerini içermeyen ifadelerin düşük R^2 performansından dolayı bu denklemlerin genelleme yeteneklerinin düşük olduğu söylenebilir. Tüm parametreleri içeren denklem 1'in en yüksek korelasyon değerine sahip olduğu görülmektedir.



4. SONUÇ ve ÖNERİLER

Elektrik üretimi, kapasite planlamasına ve elektrik şebekelerinin minimum maliyetle kurulmasına dayandığından, elektrik talep tahmini kilit bir faktördür. Başarılı tahminler elde etmek için alternatif yöntemler, hangi yöntemin en faydalı olacağını belirlemek için her zaman politika yapıcılar tarafından değerlendirilmelidir. Bu çalışmada üç farklı senaryo uygulanarak PSO, YSA ve DVR modelleri ile elektrik talep tahmini yapılmıştır.

PSO, YSA ve DVR tahmin modelleri Matlab ortamında oluşturulurken 1980-2019 yılları arasındaki yıllık GSYH, nüfus, ithalat ve ihracat verileri girdi parametreleri olarak kullanıldı. Her üç model, üç farklı senaryolara göre Türkiye'nin gelecekteki elektrik talebini tahmin etmek için kullanılmıştır.

Önerilen modellerin performanslarını ölçmek için R^2 , RMSE, MSE ve MAE hata metrikleri kullanılmıştır. Hata metrikleri, tahmin tekniklerinin doğruluğu ve kesinliği hakkında net bir gösterge vermektedir. YSA'nın Çizelge 3.11'de gösterildiği gibi RMSE, MSE ve MAE hata metrik değerlerinin PSO ve DVR'ye göre daha düşük değerde olduğu, R^2 metrik değerinin ise daha yüksek değerde olduğu görülmektedir. Hata metrikleri ve R^2 değeri dikkate alındığında YSA'nın PSO ve DVR modellerine göre daha başarılı tahmin performansı sergilediği söylenebilir.

İthalat, ihracat, GSYH ve nüfus olarak belirlenen girdi değerleri ile elektrik tüketimi olarak belirlenen çıktı değeri arasındaki korelasyon matrisi Çizelge 3.2'de gösterilmektedir. Çizelge incelendiğinde ihracat ile elektrik tüketimi arasında (0,991) ve ithalat ile ihracat arasında (0.9895) güçlü bir doğrusal ilişki olduğu söylenebilir.

2020-2040 yılları arasındaki enerji talep tahmininde (TWh) PSO, YSA ve DVR modelleri için uygulanan senaryolarda belirtilen zaman dilimi içerisinde bazı zamanlarda azalışların yaşandığı görülmektedir. Bunların nedeni senaryolar oluşturulurken ileride yaşanabilecek sosyo-ekonomik sorunlar ve enerji tasarrufu gibi durumların oluşabileceği öngörülmüştür.

Sonuç olarak YSA, PSO ve DVR'nin önümüzdeki yıllar için enerji planı tahminlerinde kullanılabileceği anlaşılmaktadır. Bu da yeni stratejilerin belirlenmesi için bilim insanlarına ve yatırımcılara ışık tutacaktır.

Artan enerji ihtiyacını karşılayabilmek için yenilenebilir enerji kaynakları alternatif bir enerji kaynağı olarak önerilmektedir. Bu kaynakların kullanılmasında ve

santrallerin kurulum planlanmasında YSA, PSO ve DVR modellerinin kullanılabileceği önerilmektedir.



KAYNAKLAR

- Akbulut, İ., 2009, *Parçacık sürü optimizasyonu ile anten tasarımı* (Doctoral dissertation, Bilişim Enstitüsü).
- Aktaş, M. Y., 2016, Rüzgâr Güç Yoğunluğunun Yapay Sinir Ağı İle Tahmini, Yüksek Lisans Tezi, *Siirt Üniversitesi, Fen Bilimleri Enstitüsü*, Siirt.
- Akyol, Sinem & Alataş, Bilal. (2012). Güncel sürü zekası optimizasyon algoritmaları, *Nevşehir Üniversitesi Fen Bilimleri Enstitü Dergisi*. 1. 36-50.
- Albahri, A. S., Alnoor, A., Zaidan, A. A., Albahri, O. S., Hameed, H., Zaidan, B. B., & Yass, A. A., 2022, Hybrid artificial neural network and structural equation modelling techniques: a survey, *Complex & Intelligent Systems*, 8(2), 1781-1801.
- Alireza, A. L. F. I., 2011, PSO with adaptive mutation and inertia weight and its application iFVn parameter estimation of dynamic systems, *Acta Automatica Sinica*, 37(5), 541-549.
- Anand, P., Rastogi, R. ve Chandra, S., 2020, Yeni destek vektörü regresyon modelleri sınıfı, *Uygulamalı Yumuşak Hesaplama*, 94, 106446.
- Anonim, 2021, Yapay Sinir Ağları [online], Türkiye, <https://www.psikolojik.gen.tr/yapay-sinir-aglari.html> [Erişim Tarihi: 6 Mart 2021].
- Askarzadeh A. Comparison of particle swarm optimization and other metaheuristics on electricity estimation: a case study of Iran, *Energy* 2014;72:484–91.
- Assareh, E., Behrang, M. A., & Ghanbarzdeh, A., 2012, Forecasting energy demand in Iran using genetic algorithm (GA) and particle swarm optimization (PSO) methods, *Energy Sources, Part B: Economics, Planning, and Policy*, *Iran*, 7(4), 411-422.
- Aygören, H., Sarıtaş, H., Moralı, T., 2012, “İMKB 100 Endeksinin Yapay Sinir Ağları ve Newton Nümerik Arama Modelleri ile Tahmini”, *Uluslararası Alanya İşletme Fakültesi Dergisi*, 4 (1), ss. 73-78.
- Bilgili, M., Şahin, B., Yaşar, A. ve Şişmek, E., 2012, Electric Energy Demands of Turkey in Residential and Industrial Sectors, *Renewable and Sustainable Energy Reviews*, 16, 404-414.
- Birecikli, B., Karaman, O. A., Çelebi, S. B., Turgut, A., 2020, Failure load prediction of adhesively bonded GFRP composite joints using artificial neural networks, *Journal of Mechanical Science and Technology*, 34 (11) (2020) 4631~4640. <http://doi.org/10.1007/s12206-020-1021-7>.

- Cebekhulu E, Onumanyi AJ, Isaac SJ., 2022, *Performance Analysis of Machine Learning Algorithms for Energy Demand–Supply Prediction in Smart Grids* [online], Sustainability, Basel, Switzerland, 14 (5), 2546–.
- Chang, C. C. W., Ding, T. J., Bhuiyan, M. A. S., Chao, K. C., Ariannejad, M., & Yian, H. C., 2023, Nature-inspired optimization algorithms in solving partial shading problems: *A systematic review. Archives of Computational Methods in Engineering*, 30(1), 223-249.
- Chauhan, P., & Barak, S., 2023, Particle Swarm Optimization and Its Applications in the Manufacturing Industry, In *Design and Applications of Nature Inspired Optimization: Contribution of Women Leaders in the Field* (pp. 19-38), Cham: Springer International Publishing.
- Chen, P. Y., Chen, R. B., & Wong, W. K., 2022, Particle swarm optimization for searching efficient experimental designs: *A review. Wiley Interdisciplinary Reviews: Computational Statistics*, 14(5), e1578.
- Chowdhury, S., Tong, W., Messac, A., & Zhang, J., 2013, A mixed-discrete particle swarm optimization algorithm with explicit diversity-preservation, *Structural and Multidisciplinary Optimization*, 47(3), 367-388.
- Couceiro, M., & Ghamisi, P., 2016, Fractional-order Darwinian PSO. In *Fractional order darwinian particle swarm optimization*, Springer International Publishing, (pp. 11-20).
- Cura T., 2008, “Modern sezgisel teknikler ve uygulamaları”, *Papatya Yayıncılık Eğitim*, İSTANBUL.
- Çolak, İ., Bayındır, R., Sefa, İ., Demirbaş, Ş. ve Ergen, H., 2005. Alternatif Enerji Kaynaklarının Kullanımı, *III.Yenilenebilir Enerji Kaynakları Sempozyumu*, Mersin, 19-25.
- Drucker, H., Burges, C.J.C, Kaufman, L., Smola, A.J., Vapnik, V.N., 1997, Support vector regression machines, *Advances in Neural Information Processing Systems* 9, M.C. Mozer, M.I. Jordan, T. Petsche (Eds.), MIT Press, 155-161.
- Ducatelle, F. , Di Caro, G. A., & Gambardella, L. M., 2010, Principles and applications of swarm intelligence for adaptive routing in telecommunications networks, *Swarm Intelligence*, 4(3), 173-198.
- Ekinci, M. E., 2017, Destek vektör regresyon ile hava kirliliği tahmini, Yüksek Lisans Tezi, *Eskişehir Osmangazi Üniversitesi, Fen Bilimleri Enstitüsü*
- Elbes, M., Alzubi, S., Kanan, T., Al-Fuqaha, A., & Hawashin, B., 2019, A survey on particle swarm optimization with emphasis on engineering and network applications, *Evolutionary Intelligence*, 12, 113-129.
- Eldem, H., 2014, Karınca Koloni Optimizasyonu (KKO) ve Parçacık Sürü Optimizasyonu (PSO) Algoritmaları Temelli Bir Hiyerarşik Yaklaşım

- Geliştirilmesi, Yüksek Lisans Tezi, *Selçuk Üniversitesi, Fen Bilimleri Enstitüsü, Konya*.
- Erdoğan Çatalbaş, E. B., 2019, Rüzgar Hız Ve Enerji Verilerinin Tahmini İçin Kaotik Yaklaşımla Birlikte Destek Vektör Regresyonunun Kullanımı, *İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul*
- Gad, A. G., 2022, Particle swarm optimization algorithm and its applications: a systematic review, *Archives of computational methods in engineering*, 29(5), 2531-2561.
- Gülcü , Ş., & Kodaz, H., 2017, The estimation of the electricity energy demand using particle swarm optimization algorithm: A case study of Turkey, *Procedia Computer Science*
- Ham, M., F., Kostanic, I., 2001, Principles of Neurocomputing for Scienceand Engineering, Mcgraw – Hill Companies, New York, USA.
- Hamzaçebi, C., 2011, Yapay Sinir Ağları: tahmin amaçlı kullanımı Matlab ve Neurosolutions uygulamalı, *Ekin Basım Yayın Dağıtım*, Bursa, Sayfa:133.
- Haykin, S., 1999, Neural networks: A comprehensive foundation, Prentice-Hall Inc. (2nded.), *Englewood Cliffs*, NJ.
- Hebb, D.O., 1949, The Organization of Behaviour, *John Wiley Sons*, New York-USA.
- Rim, Houimli., Mourad, Zmami., Mourad, Zmami., Ousama, Ben-Salha., Ousama, Ben-Salha., 2020, *Short-term electric load forecasting in Tunisia using artificial neural networks* [online], *Energy systems*, Berlin, Periodical, 11 (2), 357–375.
- Söyler I., İzgi E., 2022, *Electricity Demand Forecasting of Hospital Buildings in Istanbul* [online], *Sustainability* (Basel, Switzerland). [Online] 14 (13), 8187–.
- İnce, H. ve İmamoğlu, S.Z., 2016, Destek Vektör Regresyon ve İkiz Destek Vektör Regresyon Yöntemi ile Tedarik Seçimi, *Doğuş Üniversitesi Dergisi*, pp.241-253
- Jain, M., Saihjpal, V., Singh, N., & Singh, S. B., 2022, An Overview of Variants and Advancements of PSO Algorithm, *Applied Sciences*, 12(17), 8392.
- Joseph, S. B., Dada, E. G., Abidemi, A., Oyewola, D. O., & Khammas, B. M., 2022, Metaheuristic algorithms for PID controller parameters tuning: Review, approaches and open problems, *Heliyon*, e09399.
- Karaman , A. Ö., & Sağlam, M., 2022, Performance Analysis Of Modern Methods For Estimating Instantaneous Peak Load, *International Informatics Congress (IIC2022)*, 17-19 February 2022, Batman, Turkey.
- Karaman , A. Ö., & Sağlam, M., 2022, Performance Analysis Of Modern Methods For Estimating Electricity Energy Consumption Per Capita, *International Informatics Congress (IIC2022)*, 17-19 February 2022, Batman, Turkey.

- Katiyar, K., Kumar, A., Pandey, C. K., Das, B., 2010, A comparative study of monthly mean daily clear sky radiation over India, *International Journal of Energy and Environment*, 1: 177–182.
- Kavaklıoğlu, K., 2011, “Modeling and prediction of Turkey’s electricity consumption using Support Vector Regression”, *Applied Energy*, 88 (1), 368-375.
- Kayakuş, M., 2020, The Estimation of Turkey's Energy Demand Through Artificial Neural Networks and Support Vector Regression Methods, *Alphanumeric Journal*, 8 (2) , 227-236 . DOI: 10.17093/alphanumeric.756651
- Kaynar , O., Yüksek, G., & Demirkoparan, F., 2016, Genetik Algoritma İle Eğitilmiş Destek Vektör Regresyon Kullanılarak Türkiye’nin Elektrik Tüketim Tahmini, *İktisat Fakültesi Mecmuası*, Cilt: 66, 2016/2 s, 45-60
- Kendall, M. G., Stuart, A., 1963, The Advanced Theory of Statistics, *Griffin Pres.*, London.
- Kıran, M. S., Özceylan, E., Gündüz, M., & Paksoy, T., 2012, Swarm intelligence approaches to estimate electricity energy demand in Turkey, *Knowledge-Based Systems*, 36, 93-103.
- Kialashaki, A. ve Reisel, J., R., 2014, Development and Validation of Artificial Neural Network Models of The Energy Demand in The Industrial Sector of The United States, *Energy*, 76, 749-760.
- Kirik, A., 2010, Tornalamada kesme parametrelerindeki değişime göre yüzey pürüzlülüğünün tahmini için model geliştirme, Yüksek Lisans Tezi, *Gazi Üniversitesi, Fen Bilimleri Enstitüsü*, Ankara.
- Kutlu, M., 2012, Parçacık sürü optimizasyonu yaklaşımı ile portföy optimizasyonu ve İMKB’de bir uygulama, Doktora Tezi, *Selçuk Üniversitesi, Sosyal Bilimler Enstitüsü*, Konya.
- Laurent, H., Jobard, I., Toma, A., 1998, Validation of satellite and ground based estimates of precipitation over the Sahel, *Atmospheric Research*, 47-48, 651-670.
- M., Akpınar, A., Kömürcü, M. ve Özaşhin T. Ş., 2011, Modeling and Forecasting of Turkey’s Energy Consumption Using Socio-Economic and Demographic Variables, *Applied Energy*, 88, 1927-1939.
- Mandic, D.P., Chambers, J. A., 2001, Recurrent Neural Networks for Prediction - Learning Algorithms Architectures and Stability, *John Wiley & Sons Ltd*.
- Martin T. H., Mohammad, B. M., 1994, Training Feedforward Networks with the Marquardt

- Martins , O., Ade-Ikuesan, O. O., & Oyedeji, A., 2019, Ogun Eyaletinde doğrusal regresyon uzun vadeli enerji talep tahmini modellemesi, Nijerya, *Uygulamalı Bilimler ve Çevre Yönetimi Dergisi*, 23(4):753.
- Masaebi, P., 2016, Yapay Sinir Ağları İle İran Elektrik Tüketim Tahmini, *Karadeniz Teknik Üniversitesi, Fen Bilimleri Enstitüsü*, Trabzon.
- Moturi, C., A. ve Kioko, F., K., 2013. Use of Artificial Neural Networks for Short-Term Electricity Load Forecasting of Kenya National Grid Power System, *International Journal of Computer Application*, 63, 2, 25-30.
- Özdemir, M. T., & Öztürk, D., 2016, İki Bölge Güç Sisteminin Optikten Esinlenen Optimizasyon Algoritması ile Optimal Yük Frekans Kontrolü. Fırat Üniversitesi, *Mühendislik Bilimleri Dergisi (MBD)*, 28-2.
- Özkan, E., 2018, Parçacık Sürü Optimizasyonu Ve Genetik Algoritma Kullanarak Türkiye'nin 2050 Yılına Kadar Enerji Tüketim Tahmininin Yapılması, *Korkut Ata Üniversitesi, Sosyal Bilimler Enstitüsü*, Osmaniye.
- Öztemel, E., 2003, Yapay Sinir Ağları, *Papatya Yayıncılık*, İstanbul.
- Pankaj, M., Benjamin, W.W., 1992. Artificial Neural Networks Concepts and Theory, *IEEE Computer Society Press*, Washington.
- Papazoglou, G., & Biskas, P., 2023, Review and Comparison of Genetic Algorithm and Particle Swarm Optimization in the Optimal Power Flow Problem, *Energies*, 16(3), 1152.
- Saglam, M., Spataru C., & Karaman A. O., 2022, "Electricity Demand Forecasting with Use of Artificial Intelligence: The Case of Gokceada Island" *Energies* 15, no. 16: 5950. <https://doi.org/10.3390/en15165950>
- Sağiroğlu, Ş., Beşdok, E. ve Erler, M., 2003, Mühendislikte Yapay Zeka Uygulamaları- I Yapay Sinir Ağları, *Ufuk Kitap Kırtasiye-Yayıncılık Tic. Ltd. Şti.*, Kayseri.
- Shah, I., Jan, F., & Ali, S., 2022, *Functional Data Approach for Short-Term Electricity Demand Forecasting* [online], *Mathematical problems in engineering*, 20221–14.
- Shi, Y., & Eberhart, R., 1998, A modified particle swarm optimizer. In *Evolutionary Computation Proceedings, IEEE World Congress on Computational Intelligence., The 1998 IEEE International Conference on* (pp. 69-73), IEEE.
- Smola, A.J., 1996, Regression estimation with support vector learning machines, M.Sc. thesis, *Technische Universität, München*, 78 p.
- Sönmez, M., & Öztürk, G., 2013, Alternatif Rotalı Hücre Oluşturma Problemlerinin Çözümü İçin Yeni Bir Melez Yaklaşım, *Anadolu University Journal of Science and Technology A - Applied Sciences and Engineering*, 14 (2) , 105-118 .

- Steiger, J. H., 1980, Tests for comparing elements of a correlation matrix, *Psychological bulletin*, 87(2), 245.
- Swingler, K., 1994, Financial Prediction, Some Pointers, Pitfalls, and Common Errors, Center for Cognitive and Computational Neuroscience, *Stirling University*.
- Şen, Z., 2004, Yapay sinir ağları ilkeleri, *Su Vakfı yayınları*.
- Shami T. M., El-Saleh A. A., Alswaitti M., Al-Tashi Q., Summakieh M. A. and Mirjalili S., 2022, "Particle Swarm Optimization: A Comprehensive Survey", in *IEEE Access*, vol. 10, pp.10031-10061, doi: 10.1109/ACCESS.2022.3142859.
- Too, J., Sadiq, A. S., & Mirjalili, S. M., 2022, A conditional opposition-based particle swarm optimisation for feature selection, *Connection Science*, 34(1), 339-361.
- Türkiye İstatistik Kurumu (TÜİK), 2023, Nüfus ve demografi [online], Erişim adresi: <https://data.tuik.gov.tr/Kategori/GetKategori?p=nufus-ve-demografi-109&dil=1> (Erişim: 10 Mart 2023).
- Türkiye Elektrik İletim A.Ş. (TÜİK), 2023, Elektrik tüketim verileri [online], Erişim adresi: <https://www.teias.gov.tr/en-US/interconnections> (Erişim Tarihi: 23 Mayıs 2022).
- Dünya Bankası, 2023, İhracat, ithalat, gayri safi yurtiçi hâsıla (GSYH) verileri [online], Erişim adresi: https://data.worldbank.org/?intcid=ecr_hp_BeltD_en_ext (Erişim Tarihi: 2 Mayıs 2023).
- Uçak, K., 2002, Destek Vektör Regresyonu ile PID Kontrolör Tasarımı, Yüksek Lisans Tezi, *İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü*, İstanbul.
- V., Manca, O. and Nardini, S., 2009, "Electricity consumption forecasting in Italy using linear regression models", *Energy*, 34 (9), 1413-1421.
- Yakut, E. & Özkan, E., 2020, Parçacık Sürü Optimizasyonu ve Genetik Algoritma Kullanılarak Ekonomik Göstergelerle Enerji Tüketim Tahmininin Modellenmesi: 1979-2050 Yılları Arasında Türkiye'de Bir Uygulama. *Alfanümerik Günlük*, 8 (1) , 59-78 . DOI: 10.17093/alfanumerik.747427.
- Yalçın, C., 2016. Destek Vektör Regresyon İle Uçaklarda Anlık Yakıt Tüketiminin Analizi, *Mimar Sinan Güzel Sanatlar Üniversitesi, Fen Bilimleri Enstitüsü*, İstanbul.
- Yıldız B., 2001, Finansal başarısızlığın öngörülmesinde YSA kullanımı ve halka açık şirketlerde ampirik bir uygulama, *İMKB Dergisi*, Cilt 5, Sayı:17.
- Yıldız, T., 2011, Enerji ve Tabii Kaynaklar Bakanlığı, Türkiye enerji politikalarımız *Ankara, Türkiye*, Kasım 1.

- Yu , S., Wang, K., & Wei, Y., 2015, A hybrid self-adaptive Particle Swarm Optimization–Genetic Algorithm–Radial Basis Function model for annual electricity demand prediction. Elde edilme tarihi: 18 Aralık 2022,
- Yu, H., Wilamowski, B., 2011, Levenberg-marquardt training, *The Industrial Electronics Handbook*, 1–16.
- Yurtoğlu, H., 2005, Yapay Sinir Ağları metodolojisi ile öngörü modellemesi: bazı makroekonomik değişkenler için Türkiye örneği, *DPT Uzmanlık Tezleri*, DPT 2683.
- Zarra, T., Galang, M. G., Ballesteros Jr, F., Belgiorno, V., & Naddeo, V., 2019, Environmental odour management by artificial neural network–A review, *Environment international*, 133, 105189.

