

T.C.
ERZİNCAN BİNALİ YILDIRIM ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

MAKİNE ÖĞRENMESİ YÖNTEMLERİ İLE HİDROELEKTRİK
SANTRALLERDE ENERJİ ÜRETİM TAHMİNİ: ERZİNCAN İLİNDE BİR
UYGULAMA

Erkam Yusuf IŞIK

Danışman: Prof. Dr. Naim Süleyman TİNÇ

II. Danışman: Doç. Dr. Fulya ASLAY

TEZ JÜRİ ÜYELERİ

Prof. Dr. Naim Süleyman TİNÇ

Doç. Dr. Yakup ŞAHİN

Dr. Öğr. Üyesi Çağrı ALTINTAŞI

YÜKSEK LİSANS TEZİ

ERZİNCAN, 2024

© 2024 [Erkam Yusuf IŞIK]. Tüm hakları saklıdır..

ÖZET

MAKİNE ÖĞRENMESİ YÖNTEMLERİ İLE HİDROELEKTRİK SANTRALLERDE ENERJİ ÜRETİM TAHMİNİ: ERZİNCAN İLİNDE BİR UYGULAMA

Erkam Yusuf IŞIK

**Yüksek Lisans Tezi, Erzincan Binali Yıldırım Üniversitesi, Fen Bilimleri
Enstitüsü,**

Elektrik Elektronik Mühendisliği Anabilim Dalı

Danışman: Prof. Dr. Naim Süleyman TİNÇ

II. Danışman: Doç. Dr. Fulya ASLAY

2024, 108 Sayfa

Yaşam döngüsünün sürekliliği ve ülkelerin hem sosyal hem de ekonomik alanda gelişimi için stratejik bir kavram olarak kabul edilen enerjinin en çok kullanılan çeşidi şüphesiz ikincil enerji kaynağı olan elektriktir. Çeşitli yöntemler kullanılarak yapılan çalışmalar ile gelecekte elektrik üretiminin bilinmesi, enerjinin sürdürülebilirliği için avantaj oluşturmaya yardımcı olacaktır. Bu tez çalışmasında, hidroelektrik santrallerde (HES) makine öğrenmesi yöntemleri kullanılarak kısa ve orta dönem üretim tahminlerine ait en uygun modelin oluşturulması amaçlanmıştır. Son yıllarda, elektrik üretiminde yenilenebilir enerji kaynaklarına talebin artması ile küçük kapasiteli (çoğunlukla kanal tipi) HES'lerin kurulduğu görülmektedir. Kanal tipi mevcut ve kurulumu planlanan HES'lere ait gelecekteki üretim miktarını belirlemek, anlık üretim gücünü görebilmek ve yatırım açısından gelir değerlendirilmesi yapabilmek için güvenilir sonuçlar verebilecek, yüksek doğrulukta çalışabilecek tahmin modelleri oluşturmak önemli hale gelmiştir. Çalışmanın, kanal tipi HES'lerde üretim planlaması yapılması ve yeni yatırım yapılacak bölgelerde enerji üretim miktarını tahmin edebilmek için örnek çalışma olacağı düşünülmektedir.

Anahtar Kelimeler: enerji üretim tahmini, hidroelektrik santrali, makine öğrenmesi yöntemleri, yenilenebilir enerji kaynakları, yapay zeka.

ABSTRACT

ENERGY PRODUCTION ESTIMATION IN HYDROELECTRIC POWER PLANTS USING MACHINE LEARNING METHODS: AN APPLICATION IN ERZINCAN

Erkam Yusuf IŞIK

**Master's Thesis, Erzincan Binali Yıldırım University, Graduate School of Natural
and Applied Sciences**

Department of Electrical Electronics Engineering

Advisor: Prof. Dr. Naim Süleyman TİNÇ

Co-Advisor: Assoc. Prof. Dr. Fulya ASLAY

2024, 108 Pages

Electricity, a secondary energy source that is considered a strategic concept for the continuity and development of countries social and economic life cycles, is undoubtedly the most widely used type of energy. Knowing electricity production through studies using various methods will assist create advantages for the sustainability of energy in the future. In this thesis, it is aimed to create the most appropriate model for short and medium term production estimates in hydroelectric power plants (HPP) by using machine learning methods. It is observed that small capacity, which is mostly channel type, HEPPs have been established with increasing demand for renewable energy sources in electricity production in the recent years. It has become important to create forecast models that can provide reliable results and work with high accuracy in order to determine the future production amount of existing and planned HEPPs of channel type, to see the instantaneous production power and to make income evaluation in terms of investment. It is thought that the study will be a case study for production planning in channel type HEPPs and estimating the amount of energy production in regions where new investments will be made.

Keywords: energy production forecast, hydroelectric power plant, machine learning methods, renewable energy resources, artificial intelligence.

TEŞEKKÜR

Yüksek Lisans tez çalışmamın tamamlanma sürecinde, kıymetli bilgi ve deneyimlerini her zaman paylaşan, iş yoğunluğuna rağmen değerli zamanını benden esirgemeyen, bana her zaman destek olan, güvenen, akademik çalışma motivasyonu kazanmamı sağlayan çok değerli ve kıymetli hocam Sn. Prof. Dr. Naim Süleyman TINÇ'a; tez ilerleme süreçlerinde dile getirdiği değerli görüşlerinden ve etkili yönlendirmelerinden dolayı Sn. Doç. Dr. Fulya ASLAY 'a gönülden teşekkürlerimi sunarım.

Ayrıca, tez çalışmamda kullandığım verilerin temini konusunda Erzincan Meteoroloji İl Müdürlüğü'ne ve İçtaş Yenilenebilir Enerji Üretim ve Ticaret A.Ş.'ye teşekkürlerimi iletirim.

Bugünlere gelmemde en büyük payı olan, hayatıma ışık tutan, sevgisi ve özverisi ile beni yetiştiren, manevi olarak da her zaman hayatımda olan ve birkaç yıl önce kaybettiğim canım annem Necla IŞIK'a sonsuz saygımı; hayat tecrübelerini paylaşarak zor anlarımda hep destek olan babam Niyazi IŞIK'a minnettarlığımı ve biricik oğlum yaşam sevincim Kerim Ali IŞIK'a sonsuz sevgimi belirtmekten onur duyarım.

Erkam Yusuf IŞIK

Eylül, 2024

İÇİNDEKİLER

ÖZET.....	i
ABSTRACT.....	ii
İÇİNDEKİLER	iv
TABLolar DİZİNİ	vi
ŞEKİLLER DİZİNİ.....	vii
SİMGELER VE KISALTMALAR DİZİNİ	x
1. GİRİŞ	1
2. KAVRAMSAL ÇERÇEVE VE İLGİLİ ÇALIŞMALAR	6
3. KURAMSAL TEMELLER	13
3.1. Enerji.....	13
3.2. Enerji Kaynakları ve Türleri	13
3.2.1. Yenilenebilir enerji kaynakları.....	15
3.2.2. Yenilenemez enerji kaynakları.....	15
3.3. Dünyada Enerji Üretimi ve Talebi	16
3.4. Türkiye’de Enerji Üretimi ve Talebi.....	20
3.5. Türkiye’de Enerji Potansiyeli	24
3.6. Makine Öğrenmesi	27
3.7. Makine Öğrenmesi Yöntemleri.....	30
3.7.1. Yapay sinir ağları (artificial neural networks)	30
3.7.1.1. Tek katmanlı yapay sinir ağları.....	33
3.7.1.2. Çok Katmanlı Yapay Sinir Ağları.....	34
3.7.2. Destek vektör makinesi (support vector machine).....	36
3.7.2.1. Destek vektör sınıflandırma (support vector classifier)	37
3.7.2.2. Destek vektör regresyon (support vector regression).....	39
3.7.3. Doğrusal regresyon (linear regression)	40
3.7.3.1. En küçük kareler yöntemi	42
3.7.4. Karar ağacı (decision tree)	43
3.7.4.1. Regresyon ağacı	45
3.7.5. Gauss süreç regresyonu.....	45
3.8. Makine Öğrenmesi Yöntemlerinde Performans Ölçümü.....	47
3.8.1. Ortalama mutlak yüzde hata (mean absolute percentage error - MAPE)	48

3.8.2. Ortalama mutlak hata (mean absolute error - MAE)	48
3.8.3. Ortalama kare hatası (mean square error - MSE).....	49
3.8.4. Ortalama karekök hata (root mean square error - RMSE)	49
3.9. Normalizasyon Kavramı ve Normalizasyon Yöntemleri.....	49
3.9.1. Minimum - maksimum (min - max) yöntemi	50
3.9.2. Ondalık Ölçekleme Yöntemi.....	51
3.9.3. Z-Skor yöntemi	52
3.9.4. Norm yöntemi	53
3.9.5. Sigmoid yöntemi	53
3.10. Programlama Dili Seçimi.....	54
3.10.1. MATLAB ® programlama dili	56
4. MATERYAL VE YÖNTEM	57
4.1. Giriş.....	57
4.2. Verilerin Ön İşlemden Geçirilmesi	59
4.3. Doğrusal Regresyon Yöntemi ile Enerji Üretim Tahmini	59
4.4. Regresyon Karar Ağacı Yöntemi ile Enerji Üretim Tahmini	63
4.5. Destek Vektör Regresyon Yöntemi ile Enerji Üretim Tahmini.....	66
4.6. Gauss Süreç Regresyon Yöntemi ile Enerji Üretim Tahmini	68
4.7. Yapay Sinir Ağları Yöntemi ile Enerji Üretim Tahmini.....	71
5. DEĞERLENDİRME VE SONUÇ	78
5.1. 30 Gün KDÜT Enerji Üretim Tahmin Değerlendirmesi	78
5.2. 90 Gün ODÜT Enerji Üretim Tahmin Değerlendirmesi	79
5.3. 180 Günlük ODÜT Enerji Üretim Tahmin Değerlendirmesi	80
5.4. Sonuç.....	82
KAYNAKÇA.....	84
ÖZGEÇMİŞ	94

TABLÖLAR DİZİNİ

Sayfa

Tablo 3.1. Enerji Kaynaklarının Tükenim ve Dönüştürülebilirlik Durumlarına Göre Sınıflandırılması.....	14
Tablo 3.2. Türkiye’de elektrik üretiminin üretildiği kaynağa göre yüzdesel dağılımı ...	22
Tablo 3.3. Karar Ağacı Hava Tahmin Örneği.....	43
Tablo 4. 1. Performans Fonksiyonlarına Göre DR ile Enerji Üretim Tahmin Sonuçları	62
Tablo 4. 2. Performans Fonksiyonlarına Göre RKA Yöntemi ile Enerji Üretim Tahmin Sonuçları	65
Tablo 4. 3. Performans Fonksiyonlarına Göre DVR Yöntemi ile Enerji Üretim Tahmin Sonuçları	68
Tablo 4. 4. GSR Loss Değerleri	69
Tablo 4. 5. Performans Fonksiyonlarına Göre GSR Yöntemi ile Enerji Üretim Tahmin Sonuçları	71
Tablo 4. 6. Performans Fonksiyonlarına Göre YSA Yöntemi ile Enerji Üretim Tahmin Sonuçları	77
Tablo 5. 1. Performans Fonksiyonlarına Göre 30 Gün KDÜT için Enerji Üretim Tahmin Sonuçlarının Karşılaştırılması.....	78
Tablo 5. 2. Performans Fonksiyonlarına Göre 90 Gün ODÜT için Enerji Üretim Tahmin Sonuçlarının Karşılaştırılması.....	80
Tablo 5. 3. Performans Fonksiyonlarına Göre 180 Gün ODÜT için Enerji Üretim Tahmin Sonuçlarının Karşılaştırılması.....	81

ŞEKİLLER DİZİNİ

Sayfa

Şekil 3. 1. Karbon Esaslı Fosil Kaynaklı Yakıt Rezervleri ve Gelecek Zaman Tükenme Tahminleri.....	17
Şekil 3. 2. Küresel Çapta Çeşitli Enerji Kaynaklarından Elde Edilen Elektrik Üretim Miktarları.....	19
Şekil 3. 3. Çeşitli Enerji Kaynaklarından Üretimi Yapılan Elektrik Enerjisinin Küresel Çapta Sahip Olduğu Yüzdesel Paylar	20
Şekil 3. 4. 2001-2023 Yıllarına Ait Elektrik Yük Talebi Artış Değerleri.....	21
Şekil 3. 5. Türkiye’de Üretilen Elektriğin Üretildiği Kaynağa Göre Yüzdesel Dağılımı	23
Şekil 3. 6. 2022 Yılında Yenilenebilir Enerji Kurulu Güç Dağılım Grafiği (a) Dünyada (b) Türkiye’de.	24
Şekil 3. 7. 2023 Yılında Türkiye’deki Yenilenebilir Enerji Kaynaklarının Yüzdesel Dağılım Grafiği	25
Şekil 3. 8. Biyolojik Sinir Hücresi	31
Şekil 3. 9. Yapay Sinir Ağı Model Yapısı	32
Şekil 3. 10. Tek Katmanlı Yapay Sinir Ağı Modeli.....	34
Şekil 3. 11. Çok Katmanlı Yapay Sinir Ağı Modeli	35
Şekil 3. 12. Destek Vektör Makinesi Genel Yapısı	36
Şekil 3. 13. İki Sınıflı Doğrusal Ayrılabilen Problem Örneği.....	37
Şekil 3. 14. İki Sınıflı Doğrusal Ayrılamayan Problemin Düzlem Üzerinde Gösterimi.....	38
Şekil 3. 15. DVR Örnekleri (a) Doğrusal (b) Doğrusal Olmayan.....	40
Şekil 3. 16. Doğrusal Regresyon Grafiği	41
Şekil 3. 17. Hava Tahmini Örneğine ait Basit Karar Ağacı Şekli.....	44
Şekil 3. 18. GP Prior SE Kernel (a) ve GP Posterior (b) Karşılaştırması	47
Şekil 4. 1. Yukarı Mercan HES’e ait 17 yıllık Brüt Enerji Üretim Grafiği	58
Şekil 4. 2. 30 Günlük Enerji Üretiminin Gerçek Değer ve DR Yöntemi ile Tahmini Değer Grafikleri	60
Şekil 4. 3. 90 Günlük Enerji Üretiminin Gerçek Değer ve DR Yöntemi ile Tahmini Değer Grafikleri	61

Şekil 4. 4. 180 Günlük Enerji Üretiminin Gerçek Değer ve DR Yöntemi ile Tahmini Değer Grafikleri	62
Şekil 4. 5. 30 Günlük Enerji Üretiminin Gerçek Değer ve RKA Yöntemi ile Tahmini Değer Grafikleri	63
Şekil 4. 6. 90 Günlük Enerji Üretiminin Gerçek Değer ve RKA Yöntemi ile Tahmini Değer Grafikleri	64
Şekil 4. 7. 180 Günlük Enerji Üretiminin Gerçek Değer ve RKA Yöntemi ile Tahmini Değer Grafikleri	65
Şekil 4. 8. 30 Günlük Enerji Üretiminin Gerçek Değer ve DVR Yöntemi ile Tahmini Değer Grafikleri	66
Şekil 4. 9. 90 Günlük Enerji Üretiminin Gerçek Değer ve DVR Yöntemi ile Tahmini Değer Grafikleri	67
Şekil 4. 10. 180 Günlük Enerji Üretiminin Gerçek Değer ve DVR Yöntemi ile Tahmini Değer Grafikleri	67
Şekil 4. 11. 30 Günlük Enerji Üretiminin Gerçek Değer ve GSR Yöntemi ile Tahmini Değer Grafikleri	69
Şekil 4. 12. 90 Günlük Enerji Üretiminin Gerçek Değer ve GSR Yöntemi ile Tahmini Değer Grafikleri	70
Şekil 4. 13. 180 Günlük Enerji Üretiminin Gerçek Değer ve GSR Yöntemi ile Tahmini Değer Grafikleri	71
Şekil 4. 14. 30 Günlük Enerji Üretiminin Gerçek Değer ve YSA Yöntemi ile Tahmini Değer Grafikleri	73
Şekil 4. 15. YSA Yöntemi ile 30 Günlük Enerji Üretim Tahminine ait R Değer Grafikleri	74
Şekil 4. 16. 90 Günlük Enerji Üretiminin Gerçek Değer ve YSA Yöntemi ile Tahmini Değer Grafikleri	75
Şekil 4. 17. YSA Yöntemi ile 90 Günlük Enerji Üretim Tahminine ait R Değer Grafikleri	75
Şekil 4. 18. 180 Günlük Enerji Üretiminin Gerçek Değer ve YSA Yöntemi ile Tahmini Değer Grafikleri	76
Şekil 4. 19. YSA Yöntemi ile 180 Günlük Enerji Üretim Tahminine ait R Değer Grafikleri	76

Şekil 5. 1. 30 Gün KDÜT Enerji Üretiminin Gerçek Değer ile Tahmin Edilen Değerlere ait Karşılaştırma Grafikleri	79
Şekil 5. 2. 90 Gün ODÜT Enerji Üretiminin Gerçek Değer ile Tahmin Edilen Değerlere ait Karşılaştırma Grafikleri	80
Şekil 5. 3. 180 Gün ODÜT Enerji Üretiminin Gerçek Değer ile Tahmin Edilen Değerlere ait Karşılaştırma Grafikleri	81



SİMGELER VE KISALTMALAR DİZİNİ

wij	Ağırlık Değeri
A.Ş.	Anonim Şirketi
β	Beta Katsayısı
BP	British Petroleum (İngiliz Pertolü)
BM	Bulanık Mantık
ÇED	Çevresel Etki Değerlendirmesi
ÇKA	Çok Katmanlı Algılayıcı
ÇDR	Çoklu Doğrusal Regresyon
DVM	Destek Vektör Makinası
DVR	Destek Vektör Regresyon
E	Doğal Logaritmik Değer
DR	Doğrusal Regresyon
EPDK	Enerji Piyasası Denetleme Kurulu
EPİAŞ	Enerji Piyasaları İşletme A.Ş.
ETKB	Enerji Tabii Kaynaklar Bakanlığı
E	Epsilon
B_j	Eşik Değeri
ESA	Evrişimsel Sinir Ağı
φ	Fi Sayısı
GSR	Gauss Süreç Regresyonu
GP	Gaussian Process (Gauss Süreci)
GPR	Gaussian Process Regression (Gauss Süreç Regresyonu)
GSYİH	Gayri Safı Yurt İçi Hasıla
Y_i	Gerçek Değer
X_i	Girdi Değeri
n	Gözlem Sayısı
GÖP	Gün Öncesi Piyasa
GES	Güneş Enerji Santrali
α	Güvenirlilik Katsayısı
hPa	Hektopaskal

HES	Hidroelektrik Santrali
tanh	Hiperbolik Tanjant
IEA	International Energy Agency (Uluslararası Enerji Ajansı)
IMF	International Monetary Fund (Uluslararası Para Fonu)
cal	Kalori
KDÜT	Kısa Dönem Üretim Tahmini
kW	Kilowatt
kWh	Kilowatt Saat
LOG-DR	Logaritmik Doğrusal Regresyon
MATLAB	Matrix Laboratory (Matris Laboratuvarı)
MAE	Mean Absolute Error (Ortalama Mutlak Hata)
MAPE	Mean Absolute Percentage Error (Ortalama Mutlak Yüzde Hatası)
MSE	Mean Square Error (Ortalama Karesel Hata)
MW	Megawatt
MWh	Megawatt Saat
m	Metre
m ²	Metre Kare
m ³	Metre Küp
MLP	Multi Layer Perceptron (Çok Katmanlı Algılayıcı)
NASA	National Aeronautics and Space Administration (Ulusal Havacılık ve Uzay Dairesi)
ODÜT	Orta Dönem Üretim Tahmini
μ	Ortalama Değer
OSOS	Otomatik Sayaç Okuma Sistemi
RBF	Radial Basis Function (Radyal Baz Fonksiyonu)
ROC	Receiver Operating Characteristic (Alıcı Çalışma Karakteristiği)
ReLU	Rectified Linear Unit (Düzeltilmeli Doğrusal Ünite)
R	Regresyon Değeri
RKA	Regresyon Karar Ağacı
RMSE	Root Mean Square Error (Ortalama Kare Kök Hatası)

°C	Santigrat Derece
cm	Santimetre
cm ²	Santimetre Kare
SE	Squared Exponential (Kare Üstel)
SGİ	Stokastik Gradyan İnişi (Stokastik Gradyan İnişi)
SVC	Support Vector Classifier (Destek Vektör Sınıflandırıcısı)
SVM	Support Vector Machine (Destek Vektör Makinesi)
SVR	Support Vector Regression (Destek Vektör Regresyonu)
y_i'	Tahmin Edilen Değer
tansig	Tanjant Sigmoid
TWH	Terawatt Saat
TEP	Ton Eşdeğer Petrol
Σ	Toplam Sembolü
TF	Transfer Fonsiyonu
T.C.	Türkiye Cumhuriyeti
TEDAŞ	Türkiye Elektrik Dağıtım Anonim Şirketi
TEİAŞ	Türkiye Elektrik İletim Anonim Şirketi
UEA	Ulusal Enerji Ajansı
UKSB	Uzun ve Kısa Süreli Bellek
YSA	Yapay Sinir Ağı
%	Yüzde

1. GİRİŞ

Yaşam döngüsünün sürekliliği ve ülkelerin hem sosyal hem de ekonomik alanda gelişimi için stratejik bir kavram olarak kabul edilen enerji, yaşadığımız çağda çoğunlukla fosil kaynaklı olan petrol, doğalgaz ve kömür gibi karbon esaslı yakıtlardan sağlanmaktadır. Küresel olarak bakıldığında elektrik arz talep miktarının %70'inden fazlası bu yakıtlar kullanılarak elde edilmektedir (Al-Falahi vd., 2017). Ülkelerin enerji tüketim arz talebi; teknolojik gelişmeler, hızlı sanayileşme ve dünya genelinde nüfus ile birlikte artış göstermektedir. Ancak belirtilen enerjideki bu artışın; petrol, doğalgaz ve kömür gibi fosil kaynaklı yakıtların tüketimini de beraberinde getirerek küresel anlamda iklim değişikliği ve sera gazı emisyon problemlerine neden olduğu görülmektedir. Karbon esaslı fosil kaynakların gelecek zaman diliminde tükenme tehlikesi olduğundan dolayı yenilenebilir enerji kaynaklarının tercihi çok önemlidir.

Enerjiye olan talebin, her geçen gün daha fazla artmasından dolayı yenilenebilir enerji kaynaklı enerji üretimi önem arz etmektedir. Kolay uygulanabilirlik ve verimlilik açısından en başta gelen yenilenebilir enerji sistemleri rüzgâr, güneş ve hidroelektrik enerji santralleridir. Enerji üretim santrallerinde planlamadan üretime geçiş aşamasına kadar yaşanan başlıca sorunlar; yenilenebilir enerji hacminin büyüklüğü, bu büyüklükte meydana gelen ani değişim ve bu değişimden kaynaklı olarak model tasarlanmasıdır. Enerji üretim tesisi ve bu tesisin kurulumunun yapılacağı bölgelerde; yenilenebilir enerji kaynaklarından olan hidrolik güç, rüzgâr hızı ve güneş ışınımının şiddeti ölçümleri yüksek güvenilirlikte ve doğrulukta olan ölçüm teknikleri ile yapılabilir. Ancak, bu bölgelerde inşa edilecek olan yenilenebilir enerji santralinin üretim miktarının ne olacağını doğrudan hesaplamak bazen güvenilir sonuçlar vermeyebilir. Bilhassa; rüzgâr hızı, yağış miktarı ve bulutluluk oranı gibi parametrelerde gözlemlenen ani değişimler o bölgede kurulabilecek yenilenebilir enerji santralinin üretim miktarındaki güvenilirliği doğrudan etkileyecektir. Kullanılan meteorolojik teknikler ve zaman serileri modelleri ile şimdiye kadar yapılan tahmin çalışmalarında istenilen doğruluk ve değişimlerdeki esneklik tam anlamı ile sağlanamamıştır.

Yenilenebilir enerji üretim santraline ait üretim miktarı meteorolojik verilerden dolayı doğru tahmin edilemez ise, o santrale ait üretim miktarı, kullanılacak elektromekanik teçhizata ait kapasite ve türleri yanlış seçilmekle kalmayıp; yatırım büyüklüğü ve üretim maliyetlerinin de yanlış hesaplanmasına sebep olacaktır. Küresel olarak elektrik enerjisi üretimi incelendiğinde şebekeye sağlanacak olan elektrik enerjisi üretiminde devamlılık arz etmeyen durumlarda üretimden kaynaklı olarak sistemde negatif yönlü dalgalanmalar meydana gelebilmesi söz konusudur. Bu dalgalanmalar, kullanılmakta olan elektrik iletim ağında arızalar meydana getirerek iletim hattının verimliliğinde ve etkinliğinde gözle görünür düşüşler oluşturarak ulusal enerji ağında çökmeler meydana getirecektir. Bu istenilmeyen durumlar; planlanan tahminler, toplumun ihtiyacı olan elektrik enerjisinin devamlılığı ve daha iyi yaşam şartları için kestirimci yaklaşımın katkısı ile kolaylıkla ortadan kaldırılabilir.

Babiller tarafından M.Ö. 650 yılında yapılan kısa dönem hava tahmini, kestirimci yaklaşımın bilinen en eski örneğidir. Çalışmada, bulut hareketi ve ışık halkalarının meydana gelmesi durumları incelenerek hava tahmini yapılmıştır. Günümüzde yapılan tahmin çalışmalarında daha çok nicel ve nitel veri setlerinin kullanıldığı gözlemlenmektedir (NASA, 2002). Elektrik üretim tahmini, geçmiş yıllarda gerçekleşen verilerin ve enerji üretimini etkileyen parametrelerin veri madenciliği esaslarına göre analizinin incelenmesine ve sonuçların değerlendirilmesine göre yapılmaktadır. Geçmiş dönemlerde yapılan yük talep tahmin çalışmalarındaki hesaplamalarda yalnızca geçmiş dönemlere ait yük veri setleri inceleniyorken; günümüzde sıcaklık sayısal değerleri, yüzdelik nispi nem oranları, basınç değerleri, yağış miktarları, milli gelirden artma azalma oranı, ihracattaki değişimler ve üretim için kullanılan işlenmemiş malzemelere ait birim fiyatları gibi veriler de çalışmaya dâhil edilerek tahmin gerçekleşme oranı artırılmaya çalışılmaktadır. Yapılan çalışmaların yenilenebilir enerji üretim kaynakları açısından, yanlış çalışma olması ya da çalışmanın hiç yapılmamış olması durumlarında enerji arz talep dengesinin bozulacağı ve elektrik kesintisi ile bölgede kısmi şebeke çökmesine sebep olacağı ön görülmektedir.

Enerji üretiminde sürekliliğin sağlanması için ileriye dönük tahminlerin yapılması ve yapılacak yatırımın önceliklendirilmesi kaynak temini açısından büyük önem arz

etmektedir. Ayrıca; elektrik üretiminde güvenilir ve doğru bir şekilde tahmin yapılması, değişken elektrik satış birim fiyatlarından yüksek getiri ile yararlanılmasına olanak sağlayacaktır. Üretilen elektrik satış fiyatı, saatlik formda Enerji Piyasaları İşletme A.Ş. (EPIAŞ)'ye ait şeffaflık platformu üzerinden bir gün önceden Gün Öncesi Piyasa (GÖP)'de ilan edilir. EPIAŞ, üreticilerden bu sistem üzerinden saatlik bazda elektrik satış birim fiyatlarını vererek üretilebilecek enerjinin bu fiyatlar kapsamında taahhüt edilmesini talep eder. Şirketler için güvenilir bir enerji üretim tahmini ancak ve ancak doğru bir tahmin yöntemi ile yapılabilir. Ayrıca; söz konusu olan yenilenebilir enerji santralleri GÖP arzını gerçekleştirirken, bu santrallerin taahhüt edecekleri elektrik enerjisinin tahminini “Yenilenebilir Enerji Kaynaklarının Belgelendirilmesi ve Desteklenmesine İlişkin Yönetmelik” dâhilinde gerçekleştirme zorunluluğu vardır.

Bütün elektrik üreticileri, trafo merkezleri ve tüketicilerin enterekte sisteme bağlanarak sabit gerilim, sabit frekans ve anlık tüketim değerleri ile dengeli bir çalışma sağlanması beklenmektedir. Toplam elektrik üretim arz talebinin yetersiz kalması ilk olarak bölgesel enerji kesintilerine neden olurken durumun süreklilik arz etmesi durumunda ise şebekelerde aşırı yüklenmeden dolayı çökmelere sebep olabilmektedir. Enerji üretiminde taahhüt edilen enerjinin üretilmemesi ya da çok fazla üretilmesi durumunda, enterekte sistemde istenilmeyen olumsuz durum oluşacağı için üreticilere cezai müeyyede doğabilir. Cezai müeyyede işlemi, önceden yapılacak güvenilir enerji üretim tahmini ile kontrol altına alınabilir. Hidroelektrik Santrali (HES) yatırımlarında genellikle saatlik, birkaç günlük, aylık ve/veya üç aylık elde edilebilecek elektrik üretiminin tahmin edilmesini beklenir. Hidrolik gücün kullanıldığı HES'ler de;

- Gerçekleştirilecek üretim tahmin çalışması sonucunda, üretimin düşük olacağı ön görülen zamanlarda ileriye dönük altyapı ve santral yatırımlarının planlanmasını yapmak,
- Uzun vadede mevcut yatırımın ne kadar gelir getirebileceğini öngörmek ve bu gelire istinaden yeni yatırımlar ile mevcut HES'e inovasyon planlamak,
- EPIAŞ sistemi üzerinden satış fiyatının yüksek olduğu saatlik dilimlerde enerji satılması istenmesi ile daha yüksek gelir elde etmek amaçlarıyla suyun maksimum verim ile işletilmesi arzulanır.

Bu tez çalışmasında makine öğrenmesi yöntemleri kullanılarak HES’lerde üretilen elektrik için Kısa Dönem Üretim Tahmini (KDÜT) ve Orta Dönem Üretim Tahmini (ODÜT) gerçekleştirilmiştir. Tez çalışması gerçekleştirilirken Erzincan ili Merkez Günbağı Köyü mevkiinde bulunan Yukarı Mercan HES’e ait 2006-2022 yıllarını kapsayan 8 farklı data verisi olan Enerjiye Dönüşen Su Miktarı (m^3), Ortalama Havuz Yüksekliği (m), Net Düşü Ortalama (m), Ortalama Debi (m^3), OSOS (Otomatik Sayaç Okuma Sistemi) Değerleri (Fatura Esas), Santral İç İhtiyaç Sayacı Aktif Tüketim (kWh), Özgül Su Faktörü (m^3/MW) ve Brüt Üretim verileri ile; T.C. Çevre, Şehircilik ve İklim Değişikliği Bakanlığı, Erzurum 12. Bölge Müdürlüğüne bağlı, 17983 istasyon numaralı Ergan Kayak Merkezi istasyonuna ait meteorolojik veriler olan; Global Güneş Radyasyonu Günlük Toplam Değeri ($kwsaat \div m^2$), Ortalama Kar Günlük Yüksekliği (cm), Toplam Günlük Güneşlenme Siddeti ($cal \div cm^2$), Günlük Mevcut Kar Yüksekliği (cm), Toprak Sıcaklığına ait 50 cm de Ortalama Günlük Değeri ($^{\circ}C$), Toprak Sıcaklığına ait 20 cm de Ortalama Günlük Değeri ($^{\circ}C$), Toprak Sıcaklığına ait 10 cm de Ortalama Günlük Değeri ($^{\circ}C$), Toprak Sıcaklığına ait 5 cm de Ortalama Günlük Değeri ($^{\circ}C$), Aktüel Basınç Günlük Ortalama Değeri(hPa), Günlük Ortalama Sıcaklık ($^{\circ}C$), Günlük Ortalama Bulutluluk (8 Okta), Günlük Minimum Bulut Yüksekliği (m) ve Günlük Ortalama Nispi Nem (%) verileri tahmin veri seti oluşturularak kullanılmıştır. 4982 sayılı Bilgi Edinme Hakkı Kanunu doğrultusunda meteorolojik veriler ilgili kurumdan talep edilerek çalışmada kullanılmıştır. 2006-2022 yılları arasındaki günlük veriler kullanılarak makine öğrenmesi yöntemleri ile elektrik üretiminde KDÜT ve ODÜT yapılmış ve tahmin sonuçları gerçek üretim değerleriyle karşılaştırılmıştır. Çalışmada elde edilen sonuçların kısa ve orta vade yatırım ile üretimden gelecek maddi kaynak planlama yapılması açısından işletme finans birimine yol gösterici olması ve akademik olarak da yapılacak çalışmalara katkı sunması beklenmektedir.

Tez çalışması, altı bölümden oluşmaktadır. 1. Bölüm Giriş bölümü olup ardından gelen 2. Bölüm olan Kaynak Özetleri bölümünde, literatürde makine öğrenmesi yöntemleri kullanılarak tahmin yapılan çalışmalar ele alınmıştır. 3. Bölüm olan Kuramsal Temeller bölümünde; enerji ve enerji kaynakları, dünyada ve Türkiye’de güncel enerji arz talep durumları, makine öğrenimi ve algoritma teknik modelleme yöntemleri, veri madenciliği ve değerlendirme kriterleri, normalizasyon hesaplamaları ve veri analizi çalışma

programları detaylıca ele alınmıştır. 4. Bölüm olan Materyal ve Yöntem bölümünde, literatürde yer alan makine öğrenmesi yöntemlerinden beş yöntem ile mevcut hazırlanan veri setleri ve MATLAB programı kullanılarak kanal tipi HES için KDÜT ve ODÜT çalışması yapılmış ve uygulama sonuçları detaylı açıklanmıştır. 5. Bölüm olan Araştırma Bulguları bölümünde, makine öğrenmesidillerine ait uygulamaların hızları, ODÜT ve KDÜT'e ait performans ölçüm sonuçları tablo halinde verilmiş ve tahmin değerlerine ait kıyaslama grafikleri belirtilerek en uygun yöntemin hangisi olduğu belirtilmiştir. 6. Bölüm olan Sonuçlar bölümünde, çalışmanın kısaca özeti yapılmış ve uygulama sonuçları yorumlanmıştır. İleride yapılacak çalışmalar için tavsiye ve önerilerde bulunulmuştur.



2. KAVRAMSAL ÇERÇEVE VE İLGİLİ ÇALIŞMALAR

Elektrik güç şebekelerindeki enerji yönetim sistemlerinin en önemli unsurlarından birisi yük tahminidir. Santrallerin elektrik üretim taahhüdü, karar verme mekanizması, eğirme rezerv üretiminin azaltılması ve bakım programlarının planlanması, güvenilir yük tahmini ile sağlanabilir. Elektrik üretim sistemi operatörlerinin güç sistemini verimli bir şekilde çalıştırabilmeleri için yük üretim algoritmaları hakkında yetkinliğe sahip olmaları gerekir. Yetkinliğini tamamlayan üretim operatörü, güç sistemi üzerinden sürekli olarak yük talep oranını takip eder ve güç sisteminin tüm parçalarının yük tahmin bilgilerine göre üretimin sağlıklı olarak gerçekleştirilmesini sağlar. Enerji yük tahmininde, çoğunlukla regresyon analiz yöntemi kullanılırken; günümüzde yapay zekâ tekniklerinin yaygınlaşması ile kullanılmakta olan makine öğrenmesi yöntemleri yük miktarı tahminlerinde güvenilir sonuçlar oluşturmaktadır.

Elektrik enerjisi üretim tahmini için yapılan çalışmalar kısa, orta ve uzun dönem olmak üzere üç kategoride ele alınabilir. Saatlik, günlük veya haftalık olarak yapılan tahminler kısa dönem; aylık, üç aylık ve altı aylık olarak yapılan tahminler orta dönem; yıllık veya daha uzun süreli tahminler ise uzun dönem tahminler olarak sınıflandırılır. Üretim santrallerinin kendi arasında yük paylaşımı ile ünitelere ait generatörlerin devreye girip çıkması kısa dönem yük tahminleri ile tespit edilir. Kısa dönem tahmin çalışmasında en önemli veriler zaman ve hava parametreleridir. Çoğunlukla, günlük üretimdeki puant enerji verileri gerçek zamanlı olarak üretimden önce tahmin edilmeye çalışılır. Orta dönem yük tahminlerinde ise enerji tarifeleri, bakım-onarım zamanları ve yakıt kaynakları tespit edilerek iletim, dağıtım şebekesi ile kısa sürede enerji üretebilecek santrallerin aktif duruma getirilmesi planlanır. Son olarak uzun dönem yük tahminlerinde ise genellikle enerji santrallerinin inşaa edilmesi ve üretilen enerjinin son kullanıcıya ulaştırılması uzun süreler aldığından gelecek zamanda enerji tüketim verilerinin tahmin edilmesi amaçlanır.

Enerji üretim şirketleri, yük arz talep miktarını önceden kestirebilmek ve kaynakları iyi bir şekilde yönetebilmek amacıyla yük tahmin yöntemlerini kullanır. Dağıtım şirketleri ise iletim hatlarının enerji akışını optimize ederek sıkışıklığı ve aşırı yükü azaltmak için

yük tahmin yöntemlerini kullanır. Yük tahmini uygun değerde ve güvenilir bir çalışma ağına sahip olmak için etkin bir rol oynar. Geçmişteki mühendislik stratejileri ile gelecekteki enerji üretimini tahmin etmek için çizelgelere ve tablolara dayandırılır. Bu stratejik standartlar, meteorolojik ve takvim parametrelerini kullanarak veri setleri ile günümüzdeki mühendislik yaklaşımlarında yeni yöntemler ile kullanmayı esas alır. HES'ler de enerji üretim tahmini ile ilgili literatürde yapılan çalışmalardan bir kısmı aşağıda özetlenmiştir.

Tokar ve Markus (2000) yaptıkları çalışmada, yağış ve akış parametre değerleri ile Yapay Sinir Ağı (YSA)'nda yapılan kavramsal modellemede; yağış miktarı, kar suyu eşdeğeri ve sıcaklık değerleri ile model oluşturularak havza akışının tahmin edilmesini amaçlamışlardır. Amerika Birleşik Devletleri'nde yer alan Little Patuxent Nehri havzasına ait günlük yağış-akış süreci verilerinin YSA yöntemi ile oluşturulduğu modellemede kavram niteliğinde olan yağış-akış tekniği ile eğitime ve teste ait sonuçlar karşılaştırılmıştır. YSA tekniği ile yapılan modellemenin daha yüksek doğruluk oranına sahip olduğu ve tekniğin eğitim çalışmasındaki süreyi kısalttığı görülmüştür.

Solak vd. (2002) tarafından yapılan çalışmada, İrlanda'nın yıllık yük verisi modellemesinin sonuçlarının tahmininde diğer yapay zekâ yöntemlerine göre Gaussian Process Regresion (GPR) modeline ait sonuçların daha avantajlı olduğu belirtilmiştir. GPR modelinin dezavantajı ise; veri seti hiper parametrelerine ait problem ve çalışmasının her bir adımında gerçekleşen matrislerin tersinin alınması olarak belirtilmiştir.

Hamzaçebi ve Kutay (2004) yaptıkları çalışmada, 1970–1990 yılları arasındaki elektrik enerjisi veri setleri ve nüfus bilgilerini kullanarak, 2004 yılından 2010 yılına kadar olan süre için regresyon ve YSA modelleri ile Türkiye'ye ait uzun dönem elektrik enerjisi arz talep tahminini yapmışlardır. İki tahmin modellemesi arasından YSA modelinin, regresyon modeline göre tahmin aracı olarak kullanılabilirliğinin daha kolay olduğunu ve daha güvenilir sonuç verdiğini belirtmişlerdir.

Ceylan (2004) yaptığı çalışmada, Gölbaşı bölgesine ait elektrik tüketim verileri ile YSA ve regresyon analizi yöntemlerini kullanarak bir sonraki gün için gerekli olan elektrik enerjisini tahmin etmeye çalışmıştır. Çalışmada, en iyi tahmin yönteminin YSA yöntemi olduğunu belirtmiştir. Tahmin çalışmasında elektrik tüketimine etki eden faktörler olarak gün içerisinde meydana gelen sıcaklığa ait minimum ve maksimum değerleri kullanmıştır.

Mamun ve Nagasaka (2004) yaptıkları çalışmada, Destek Vektör Makinesi (DVM) ve YSA yöntemleri ile çalışma günleri için yapılan yük talep tahminini etkileyen sıcaklık değerleri, rüzgâr hızı, nispi nem miktarı, aydınlanma süresi verilerinden oluşan meteorolojik ve çevresel etmenlerden kaynaklı veri setlerini oluşturmuşlardır. MAPE değerini DVM için %7, YSA için ise %13,6 olarak bulmuşlardır. YSA çalışmasında hatanın yüksek olduğu, DVM algoritmasının YSA algoritmasına göre daha güvenilir sonuçlar verdiği gözlemlenmiştir.

Çobaner vd. (2008) yaptıkları çalışmada, mevcut sulama amaçlı kullanılan baraja ek yeni HES kurma aşamasında fizibilite değerlendirme raporu için ileri beslemeli ve bir gizli katmanlı Levenberg-Marquardt algoritması ile oluşturdukları YSA yöntemini modellemişlerdir. Elde edilen sonuca göre, sulama barajından gelen yıllık ortalama suyun, hidroelektrik enerji üretimi için güvenilir tahmin verisi olduğunu belirtmişlerdir. Ghanbari vd. (2009) İran'ın yıllık elektrik tüketimini tahmin etmek için Doğrusal Regresyon (DR), Logaritmik Doğrusal Regresyon (Log-DR) ve YSA algoritması ile modelledikleri çalışmalarında MAPE değerini sırası ile; YSA için %2,08, DR için %27,06 ve Log-DR için %12,60 olarak bulmuşlardır. Böylelikle YSA tekniğinin diğer iki tekniğe göre daha güvenilir sonuçlar verdiğini tespit etmişlerdir.

Demren (2011) yaptığı çalışmada, 2006-2009 yılları arasındaki enerji tüketim verilerini DVM ve YSA yöntemlerine uygulayarak İstanbul Avrupa Yakası için orta dönem günlük yük tahmini çalışması yapmıştır. Eğitim verisi olarak, ortalama hava sıcaklığı, takvim günleri ve elektrik fiyatı değerlerinden oluşan veri setlerini oluşturarak 2010 yılı Nisan ayına ait puant yük değerlerini tahmin etmeyi hedeflemiştir. Çalışma sonuçlarına göre,

DVM'ye ait tahmin değerlerinin, YSA'ya göre gerçek değerlere daha çok yakınsadığı tespit edilmiştir.

Božić ve Stojanović (2011) yaptıkları çalışmada, takvimsel veri, sıcaklık ve rüzgâr veri parametrelerini kullanarak DVM modeli ile bir yıllık orta dönem yük talep tahmini ile MAPE değerini %4,25 olarak bulmuşlardır. Yapılan çalışma mevsimlere ayrılarak ayrıntılı incelendiğinde, Christmas günlerinde ve yılbaşı gününde MAPE hatalarının fazla olduğu tespit edilmiştir. Bu günlerin yıl içerisindeki gün sayısına oranı düşük olduğu için hatalar gürültü olarak değerlendirilmiştir.

Yasin (2013) tarafından sunulan çalışmada, YSA ve DVM metodları ile üç büyük şehre ait saatlik veriler, sıcaklık verileri ve bir yıllık elektrik yük değerleri ile veri setleri oluşturularak ağ eğitim testi modellenmiştir. Böylece her döneme ait eğitimde kullanılan veri setlerine ait test çalışmaları doğrulamıştır. Doğrulama sonuçlarına göre, kısa dönem çalışmalarında YSA'nın DVM'den daha iyi sonuçlar verdiği, uzun dönem çalışmalarında ise DVM metodunun YSA'ya göre daha iyi sonuç verdiği gözlemlenmiştir. Ayrıca sıcaklık veri setinin, oluşturulan algoritmalara direkt etkisinin olduğu da tespit edilmiştir.

Blum ve Riedmiller (2013) tarafından yapılan çalışmada, GPR yöntemi ile günlük ve haftalık olarak güneş ve rüzgâr enerjisinden elde edilen elektrik üretim ve tüketim verileri kullanılarak esnek tahmin modeli oluşturmak için 5 kovaryans fonksiyonu kullanılmıştır. Modellemede çeşitli üreticilere ait talepler için güvenilir tahminler yapılmıştır.

Hachino vd. (2014) yaptıkları çalışmada, GPR yöntemi ile saatlik yük verileri kullanılarak oluşturulan kısa dönemli yük tahminine ait sonuçların gerçek yük değerlerine (MAPE değeri %4,5) % 95,5 oranında benzerlik oranı sağladığını göstermişlerdir.

George vd. (2016) doğrusal regresyon tekniği, YSA ve bölgesel polinom regresyon yönteminden oluşan 3 değişik model ile Hindistan'ın Idukki havzası için yağış tahmin çalışması yapmışlardır. Çalışılan modellerde; ortalama deniz seviyesi basıncı, jeopotansiyel yükseklik, ortalama hava sıcaklık değeri, bağıl nem oranı ve rüzgâr hızı veri setlerini kullanmışlardır. Çalışmada oluşturulan modellere ait sonuçlar

karşılaştırıldığında, doğrusal regresyon yöntemiyle bölgede yağış tahmininin daha başarılı olduğunu görmüşlerdir.

Kaynar vd. (2016) tarafından yapılan çalışmada, Destek Vektör Regresyon (DVR) ve kaotik yöntemlerden oluşan çoklu algoritma modelinde kullanılmak üzere gayri safi yurtiçi hâsıla (GSYİH), ithalat-ihracat değerleri ve nüfus değişkenlerine ait veri setleri oluşturularak Türkiye'nin 1974-2014 yılları arasında gerçekleşen yıllık elektrik tüketim değerleri için tahmin yapılmıştır. Yapılan çoklu modellemede test verilerine ait MAPE değeri %3,66 iken; modellemeye ait tahmin MAPE değeri %1,46 olarak elde edilmiştir. MAPE değerinin %5'in altında olmasından dolayı oluşturulan modellemenin, klasik regresyon tekniklerine ve YSA'ya göre yeni bir yöntem olacağı vurgulanmıştır.

Kyrkou vd. (2018) yaptıkları çalışmada, YSA, regresyon ağacı ve DVM modelleri ile oluşturdukları fotovoltaiik enerji tahmini için 1 yıllık gerçek üretime ait veri setlerini kullanmışlardır. Yapılan modelleme çalışmasında kullanılan yapay zekâ yöntemleri arasında karşılaştırma yapıldığında, %0,6 MAPE değeri ve %0,76 RMSE değeri ile YSA modelinin, diğer modellerden başarılı olduğu gözlemlenmiştir.

Yıldıran vd. (2018), YSA ve doğrusal regresyon yöntemleri ile geçmiş yıllara ait yağış verilerini kullanarak oluşturduğu yağış tahmini çalışmasında, YSA modelinin daha başarılı sonuçlar verdiğini gözlemlemişlerdir.

Amber vd. (2018) yaptıkları çalışmada, HES'in enerji üretimini artırmak için kısa dönem hava tahmini veri setleri, geçmiş dönem hidrolojik veri setleri ve rezervuar akış miktar veri setlerini kullanarak yapay arı kolonisi ve YSA yöntemleri ile bir sinir ağı modeli oluşturmuşlardır. Modellemedeki amaç gelen suyun üretim optimizasyonunun daha az veri algoritması ile oluşturulmak istenilmesidir.

Wang vd. (2020) yaptıkları çalışmada HES'e ait enerji üretim değerlerini tahmin etmek ve verimliliği artırmak için oluşturdukları sinir ağı modelinde, su miktarı, aylık rezervuar su seviye yüksekliği, özgül su faktörü verilerini girdi olarak kullanmışlardır. Çalışmada,

çıktı verilerine bakarak HES'in üretim verimliliğinin artırılarak güvenli enerji üretim tahmini yapıldığı kanısına varmışlardır.

Dampage vd. (2020) yaptıkları çalışmada, Çok Katmanlı Algılayıcı (ÇKA), Evrişimsel Sinir Ağı (ESA) ile Uzun ve Kısa Süreli Bellek (UKSB) algortimalarıyla YSA oluşturarak, HES için günlük enerji üretiminde kullanılmak üzere su tahmin çalışması yapmışlardır. Modeller ile yapılan çalışma sonuçları değerlendirildiğinde, UKSB algoritmasının doğru ve güvenilir değerler verdiği görülmüştür.

Arslan (2020) tarafından sunulan çalışmada, Keban Barajı göl seviyesinin ve su kaynaklarının verimli bir şekilde işletilmesi amacıyla Bulanık Mantık (BM), DVR ve Çoklu Doğrusal Regresyon (ÇDR) modelleriyle günlük rezervuar seviye yüksekliği tahmini yapılmıştır. Yapılan modelleme sonuçlarına göre BM ve DVM modellerinin Keban Barajına ait rezervuar su seviyesini tahmin etmede daha başarılı olduğu tespit edilmiştir.

Kaur vd. (2021) yaptıkları çalışmada, çeşitli makine öğrenmesi yöntemleri ile kısa dönem elektrik talep tahminlerini yaparak elde edilen sonuçları kıyaslamış ve bu çalışma için güvenilir değerleri DVR ve Lasso Regresyon algoritmalarının verdiğini görmüşlerdir.

Özdemir (2021) yaptığı çalışmada, 2011-2022 yılları arasında İskenderun yerleşkesine ait aylık ortalama elektrik tüketim verileri ve aylık ortalama sıcaklık verilerini kullanarak orta dönemli elektrik tüketim tahminini saptayabilmek için YSA modeli oluşturmuştur. Tahmin modellemesinde, talebi etkileyen mevsimsel, sosyal ve iklimsel faktörlerden dolayı aylık bazda en düşük MAPE değerleri Haziran ayı için %1,62 iken en yüksek MAPE değeri Ağustos ayı için %8,69 olduğu tespit edilmiştir. Yapılan 12 aylık tahminde ortalama MAPE değeri %5'ten düşük çıktığı için YSA'nın tahmin modeline ait performansının oldukça başarılı olduğu vurgulanmıştır.

Işık ve Şeker (2021) yaptıkları çalışmada, Türkiye'ye ait 1985-2019 yılları arasındaki kurulu güç verileri, brüt elektrik üretim, elektrik tüketim, dış ticaret değerlerindeki değişim ve insan popülasyonu verileri kullanılarak petrol, doğal gaz, kömür ve yenilenebilir enerji kaynaklarından YSA modeli ile elektrik üretim tahmini yapılması

amaçlanmıştır. Çalışmada, enerji veri girdilerine bağlı olarak YSA modeli ile enerji üretim tahminin yüksek doğruluğa sahip olduğu vurgulanmıştır.



3. KURAMSAL TEMELLER

3.1. Enerji

Enerji; kelime anlamı olarak iş ve iş yapabilme yeteneği olarak açıklanabilir. Enerji elektriksel sistemlerin çalışabilmesi için en temel olgudur (Yavaş, 2018). Başlıca enerji çeşitleri; nükleer enerji, potansiyel enerji, kinetik enerji, kimyasal enerji, ısı ve elektrik enerjileridir. Günümüzde en çok kullanılan enerji çeşidi, kinetik enerji ve potansiyel enerjidir. Kinetik enerji cismin hareketinden, hızından kaynaklı sahip olduğu enerji; potansiyel enerji ise cismin bulunduğu konumdan, yükseltiden kaynaklı sahip olduğu enerjidir. Termodinamik yasasına göre ise enerji, sadece bir formdan başka forma dönüştürülebilir (Kanlı vd., 2014). Enerji, çeşitli süreçler yardımı ile bir noktadan başka noktaya transfer edilebilir ve bir formdan başka forma geçebilir. Örneğin; HES’lerde suyun potansiyel enerjisi kinetik enerjiye, suyun hızından dolayı oluşan kinetik enerji ise mekanik enerji formu ile elektrik enerjisine dönüştürülmektedir. Enerji, joule (J) cinsinden ölçülürken; elektrik enerjisi kilowatt saat (kWh) ve ısı enerjisi kalori (kal) olarak ifade edilir. Günümüzde az karşılaşılan bazı enerji formları, mekanik ve radyant enerjisi olarak verilebilir (Töman vd., 2016). Enerji; sanayi, ulaşım ve teknoloji başta olmak üzere hayatımızda geniş ve etkili bir alanda kullanılır. Enerji kullanımının evrendeki temel etkileri, çevresel olaylar ve ekonomik etkenler olarak değerlendirilirken; fen bilimlerine ait birçok alanda da önemli rol oynar.

3.2. Enerji Kaynakları ve Türleri

Enerjinin elde edilmesi için tüketilen kaynağa, enerji kaynağı denir. Yaşamın devamlılığı ve ihtiyaçların karşılanması için çeşitli yapılarda enerji kaynakları kullanılır. Tükenim durumlarına göre enerji kaynakları yenilenebilir (tükenmez) ve yenilenemez (tükenir) olarak; dönüştürülebilirlik durumlarına göre ise birincil enerji ve ikincil enerji kaynakları olarak nitelendirilir (Koç ve Kaya, 2015). Tablo 3.1’de tükenim durumuna göre yenilenemez enerji kaynakları kömür, petrol, uranyum ve toryum; yenilenebilir enerji kaynakları ise hidrolik, güneş, biokütle, rüzgâr, jeotermal, dalga, gel-git ve hidrojen olarak sınıflandırılmıştır. Dönüştürülebilirlik durumlarına göre kömür, petrol, doğal gaz, nükleer, biokütle, hidrolik, güneş, rüzgar, dalga ve gel-git enerji kaynakları birincil

(primer) enerji; elektrik, benzin, motorin, ikincil kömür, kok, petrokok, hava gazı ve sıvılaştırılmış petrol gazı (LPG) gibi enerji kaynakları ikincil (sekonder) enerji olarak adlandırılmıştır (Koç ve Kaya, 2015).

Tablo 3.1. Enerji Kaynaklarının Tükenim ve Dönüştürülebilirlik Durumlarına Göre Sınıflandırılması

Enerji Kaynakları	
Tükenime Göre	Dönüştürülebilirliklerine Göre
A) Yenilenemez (Tükenir) 1) Fosil Kaynaklı ➤ Kömür ➤ Petrol ➤ Doğal Gaz 2) Çekirdek Kaynaklı ➤ Uranyum ➤ Toryum	A) Birincil (Primer) ➤ Kömür ➤ Petrol ➤ Doğal Gaz ➤ Nükleer ➤ Biyokütle ➤ Hidrolik ➤ Güneş ➤ Rüzgâr ➤ Dalga, Gel-Git
B) Yenilenebilir (Tükenmez) ➤ Hidrolik ➤ Güneş ➤ Biyokütle ➤ Rüzgâr ➤ Jeotermal ➤ Dalga, Gel-Git ➤ Hidrojen	B) İkincil (Sekonder) ➤ Elektrik, Benzin, Motorin ➤ İkincil Kömür, ➤ Kok, Petrokok ➤ Hava Gazı ➤ Sıkıştırılmış Petrol Gazı

3.2.1. Yenilenebilir enerji kaynakları

Yenilenebilir enerji kaynakları yapıları itibariyle sürekli kendilerini yenileyebilen doğal bir çevrim döngüsünde kullanılan, çevreye zararlı etkileri de yenilenemez enerji kaynaklarına göre çok daha az olan ve sürdürülebilirlikleri mümkün olan kaynaklardır. Ülkelerin bağımsızlığı açısından enerji üretilebilirlik son derece önemlidir (Baysal ve Daşdemir, 2021). HES'ler tarafından üretilen enerji, yağış rejimlerine bağlı olarak kendini sınırsız tekrarlayan, hidrolik çevrim (su döngüsü) sürdüğü sürece bitmeyecek olan enerji kaynağıdır. Su, hem yeryüzünde bulunan doğal kaynakların en önemlisi hem de vazgeçilemez değerli yenilenebilir enerji kaynağı olarak mucizevi bir maddedir. (Bozkurt ve Tür, 2015). HES'lerde enerji üretimi yapılırken girdi olarak suyun kullanılması, HES'lerin inşaat maliyetinin diğer enerji üretim santrallerinden düşük olması ve çevreye verdiği zararın, karbon ve sera gazı salınım oranına göre çok az değerde olması HES'lerin en önemli tercih sebepleridir. Temiz enerji olmasından dolayı günümüzde HES'ler, dünyadaki toplam enerji kaynakları içerisinde en büyük paya sahip olan yenilenebilir enerji kaynağıdır (Bülbül ve Çokluk, 2017).

Hidroelektrik güç sistemleri, tüm dünyada gelişmeye devam ederek son teknolojiye sahip elektromekanik teçhizatlara sahiptir. HES'ler, işletme maliyeti düşük, çalışma ömrü uzun ve verimleri oldukça yüksek olan yenilenebilir enerji santrallerindendir. Ulusal şebekede meydana gelen güç ve enerji ihtiyacı değişimlerine çok hızlı adapte olarak kısa sürede üretime girip üretimden çıkabilen, üretim arzında meydana gelen değişime göre yük alıp yük azaltabilen ve anlık meydana gelen yük değişimlerine hızlı cevap verebilme özelliğine sahip olan HES'lere dünya genelinde anlık enerji değişiminden kaynaklanan ihtiyacının giderilmesi özelliğinden dolayı birinci öncelik verilmektedir (İnal ve Oy, 2020).

3.2.2. Yenilenemez enerji kaynakları

Dünya genelinde enerji ihtiyacının büyük bir bölümü, yapısında yüksek oranda karbon, kükürt ve azot bulunan fosil kaynaklı yenilenemez enerji kaynaklarından sağlanmaktadır. Ancak bu kaynak kendisini yenileyememesi ve böylece mevcut kaynakların

azalmasından dolayı yakın zamanda tükenme ihtimali göz önünde bulundurulmaktadır (Koç ve Şenel , 2013). Yenilenemez enerji kaynaklarının tükenebilir olmaları ve çevre sorunlarına neden olmalarından dolayı sürdürülebilirlikleri yoktur. Yenilenemez enerji kaynakları dünya üzerinde sadece belirli noktalarda bulunmaktadır. Ancak, yenilenebilir enerji kaynaklarına nispeten miktar ve enerji potansiyeli bakımından daha dengeli bir oluşuma sahiptir.


Dönüştürülebilirliklerine göre iki başlığa ayrılan enerji kaynaklarından birincil enerji kaynakları doğada temel halde bulundukları için herhangi bir formdan başka forma dönüşüme uğramazlar. Bu kaynaklar yenilenebilir veya yenilenemez enerji kaynağı olabilir. Enerji üretiminin başlangıcını oluştururlar ve ikincil enerji kaynaklarına dönüştürülerek farklı amaçlarla kullanılabilirler. Bir diğer tür olan ve birincil enerji kaynaklarının dönüşümleri sonucunda oluşan ikincil enerji kaynakları ise ihtiyaç duyulan enerji formuna dönüştürülerek ortaya çıkarılır. Dönüşümler sonucu oluşan ikincil enerji kaynakları, günlük yaşamda ihtiyaçların karşılanmasında kullanılan elektrik enerjisinin üretilmesinde en büyük girdi miktarına sahiptir (Koç ve Şenel, 2013).

3.3. Dünyada Enerji Üretimi ve Talebi

Ülkelerin gelişmişliğini gösteren en önemli etkenlerden biri de enerji üretimi ve tüketimidir. Sanayi alanındaki ilerlemeler ve dünya nüfusunun hızla artması enerjiye olan ihtiyacı daha da artırmaktadır. Geçtiğimiz dönemlerde fosil kaynaklardan üretimi yapılan enerjinin, bugünlerde yenilenebilir enerji kaynaklarından üretilmesine öncelik verilmeye başlanmıştır (Koç vd., 2018). Şekil 3.1'deki grafiğe göre dünya genelinde en çok tercih edilen karbon esaslı fosil kaynakların, gelecek zamanda tükeneceği tarihler öngörülerek 2050 yılında petrolün, 2060 yılında doğal gazın ve 2080 yılında da kömürün tükeneceği öngörülmektedir (Görgülü, 2022).

Dünya Enerji Konseyi'nin yayınlamış olduğu "2021 Yılı Küresel Enerji Raporu Özeti" çalışmasında, 2019 yılında tahmin edilen küresel elektrik arz talebi, yıl sonunda tahmin edilen seviyenin %3,4 oranında artış iyileşme gösteren piyasalarda ve gelişmekte olan ekonomilerde görülmüştür. Elektrik arz talebinde 2020 yılında ise son 70 yıl içerisindeki

en büyük mutlak düşüş olan %4 seviyesi görülmüştür. 2021 yılında ise enerji talebi %4,6 seviyesine çıkarak, 2019 yılındaki daralmayı ve 2020 yılındaki beklenilmeyen düşüşü telafi eden bir büyüme göstermiştir (Word Energy Council Turkey, 2021).



Şekil 3. 1. Karbon Esaslı Fosil Kaynaklı Yakıt Rezervleri ve Gelecek Zaman Tükenme Tahminleri


Yenilenebilir enerji kaynaklarından elektrik üretiminin hızla arttığı güncel durumda nükleer enerjiden elektrik üretiminin de 2025 yılında rekor seviyeye ulaşacağı öngörülmektedir. Küresel elektrik talebindeki büyüme, 2022'deki %2,4'lük artışın ardından 2023'te, gelişmiş ekonomiye sahip ülkelerdeki tüketim düşüşü nedeniyle, nispeten azalmış ve %2,2 olarak elde edilmiştir. Enerji krizinin geniş kapsamlı yansımaları 2023 yılı boyunca devam etmiş ve yüksek enflasyon seviyelerinin elektrik talep miktarında olumsuz yönde etki oluşturduğu görülmüştür. Bununla birlikte, ekonomik olarak gelişmekte olan piyasaların, teknoloji ve hızlanan elektrifikasyonun devam etmesiyle, büyümenin 2024-2026 tahmin döneminde %3,4'ten daha yüksek bir seviyede çıkması öngörülmektedir (Kaya 1, 2024).

Küresel enerji arzında; 2021 yılında birincil enerji kaynağına olan talep %5,8 oranında artış göstererek 2019 yılı seviyesini %1,3 ile geçmiştir. 2019 yılında karbon esaslı yakıtlar, enerji arzının %83'ünü karşılarken; 2021 yılında ise %1 oranında düşüş göstererek %82'sini karşılamıştır. Yenilenebilir enerji kaynaklarından elektrik üretimi

artmasına rağmen, enerji yoğunluğu ve karbon emisyon oranında 2021 yılında düşme olmadığı görülmüştür. 2021 yılında doğal gaz tüketiminin, 2020 yılına göre artış miktarı %5,3 olmuştur. 2020 yılına göre kömür tüketiminde ise; 2021 yılında %6 oranında artış olmuştur. 2021 yılında gözlemlendiğinde, rüzgâr ve güneş enerjisinden elektrik üretim payı %10,2'ye ulaşmıştır. Rüzgâr ve güneş enerjisinin, dünyadaki kurulu güce olan katkısının ilk defa nükleer enerjiden daha fazla olduğu 2021 yılında görülmüştür. 2021 yılında yenilenebilir enerji kaynaklarının payı, enerji üretiminde %13 seviyelerine ulaşmıştır (BP, 2022).


Gelişmekte olan ekonomilerdeki beklenen güçlü büyüme, sanayide beklenen toparlanma ve dünyanın birçok yerinde konut ve ulaşım sektörlerinin devam eden elektrifikasyon ile birleştiğinde, küresel elektrik talebinin artmasının kaçınılmaz olacağı tahmin edilmektedir. Daha yüksek elektrik tüketim talebinin bir diğer önemli sebebi ise, enerji veri merkezlerinin artması (şirketler tarafından oluşturulan ve depolanan verilerin saklanması için serverların oluşturulması, yazılımda sanallaştırma teknolojisi, bulut bilgi işlemi ve ağı bağlı depolama sistemlerinin artması vb.), aşırı sıcak havalar, elektrikli araçlar, yapay zeka sistemlerinin kurulması, kripto para birimlerinin yaygınlaşmasıdır. Küresel elektrik talebinde 2023 yılında yüzde 2,5 artış gerçekleştiği görülmüştür. 2024 yılı ve 2025 yılında ise talebin yaklaşık yüzde 4 artması beklenilmektedir. Bu artış oranı, küresel mali kriz ve Covid-19 salgını sonrasında istisnai dönemler hariç, 2007 yılından sonra görülen en yüksek yıllık büyüme olarak göze çarpmaktadır. 2025 yılında Hindistan ve Çin gibi Dünya'nın büyük ekonomilerine sahip ülkelerinde elektrik tüketim miktarlarında güçlü artışlar görülmesi beklenilmektedir. Güçlü ekonomik yatırımlar ve sıcak havanın etkisi ile elektrik tüketim talebi Hindistan'da yüzde 8, Çin'de ise yüzde 6 seviyelerini aşması öngörülmektedir. Buna karşın, Avrupa Birliği'nde elektrik tüketim talebinde daha yavaş toparlanma gerçekleşmesi ve enerji krizinin de etkisiyle 2 yıl üst üste yaşanan daralmanın ardından yüzde 1,7'lik bir artış beklenilmektedir. Bu gelişmelerin yanı sıra, veri merkezlerinin elektrik tüketim miktarları az olmasına rağmen küresel elektrik talebinde büyümeye devam etmektedir. Veri merkezlerinin elektrik talebi 2022'de küresel elektrik tüketiminin yaklaşık yüzde 1'ini oluşturmuştu. Bu oranın 2026 yılından sonra yüzde 1,5 ile 3 arasında seyredeceği tahmin ediliyor (Kaya 2, 2024).

Şekil 3.2’de küresel çapta çeşitli enerji kaynaklarından üretilen elektrik miktarları ve Şekil 3.3’te ise üretilen elektrik enerjisinin küresel çapta sahip olduğu payların yüzdesel grafiği sunulmuştur (Jones, 2022). Grafiklere bakıldığında elektrik üretiminde en çok paya sahip olan kömürden üretilen elektrik enerjisi miktarının bazı yıllarda düşüş gösterdiği görülmektedir. Ancak 2021 yılında sert bir yükselme hamlesi ile tekrar artış göstererek en yüksek üretim değerine ulaşılmıştır. Elektrik üretiminde büyüklük olarak ikinci sırada gaz kaynağı bulunmakta ve gazdan elektrik üretimi yıl bazında da artış göstererek devam etmektedir. Yenilenebilir enerji kaynaklarından elektrik üretimi incelendiğinde ise rüzgar ve güneş enerjisinden üretilen elektrik enerjisi miktarı, 2010 yılından önce diğer yenilenebilir enerji kaynaklarından geride kalsa da, bu enerji kaynaklarının 2010-2021 yılları arasında hidroelektrikten sonra en çok elektrik üretiminin gerçekleştiği yenilenebilir enerji kaynakları olduğu görülmektedir. Rüzgâr enerjisinden üretilen elektrik enerjisi, 2000 yılından itibaren düzenli olarak artış gösterirken; güneş enerjisinden elektrik üretiminde 2009 yılına kadar kayda değer bir artış gözlemlenmemiştir. 2010 yılından itibaren, güneş paneli teknolojisinin de gelişmesi ile birlikte güneş enerjisinden elektrik üretim miktarında artış görülmektedir. 2000-2022 yılları arasında hidroelektrik en fazla elektrik üretiminin yapıldığı yenilenebilir enerji kaynağı olmuştur.



Şekil 3. 2. Küresel Çapta Çeşitli Enerji Kaynaklarından Elde Edilen Elektrik Üretim Miktarları

Şekil 3.3'te, yıllara göre çeşitli kaynaklardan üretilen elektrik enerjisinin toplam üretime göre yüzdelik oranları gösterilmiştir. Burada hidrolik enerjiden elde edilen elektrik enerjisi üretim oranının yıllara göre korunmakta olduğu görülmektedir. Rüzgar, güneş ve biyo enerji gibi yenilenebilir enerji kaynaklarından üretilen elektrik enerjisi oranı yıllara göre yükselerek devam etmektedir. Toplam temiz enerji oranının, fosil kaynaklı kömürden elde edilen elektrik enerjisi oranı ile ters orantılı olduğu görülmektedir. Temiz enerji oranı 2012 yılından 2022 yılına kadar artış gösterirken, aynı yıllar arasında kömürden elde edilen elektrik enerji oranında düşüş görülmektedir. Bu grafiklerden yola çıkarak başta hidrolik enerji olmak üzere diğer yenilenebilir enerji kaynaklarından elde edilen elektrik enerjisi oranı artırılabilirse, kömürden elde edilen elektrik enerjisi oranının gitgide düşeceği ve daha temiz enerji elde edilebileceği vurgulanabilir.




Şekil 3. 3. Çeşitli Enerji Kaynaklarından Üretimi Yapılan Elektrik Enerjisinin Küresel Çapta Sahip Olduğu Yüzdesel Paylar

3.4. Türkiye’de Enerji Üretimi ve Talebi

Ülkemizde yapılan ithalat harcamalarının dörtte biri enerji kaynakları için yapılırken, ithalat yolu ile alınan enerji kaynaklarının ise dörtte üçü elektrik enerjisi ihtiyacını karşılamak için kullanılmaktadır. Ülkemizde yeterli miktarda petrol ve doğalgaz çıkarılamaması ve yenilenebilir enerji kaynaklarından ihtiyacımızı karşılayacak kadar enerji sağlanamaması nedeniyle ihtiyaç duyulan enerjinin büyük bir kısmı ithal edilen

enerji kaynaklarından karşılanmaktadır (Yılankırkan ve Doğan, 2020). 18.05.2005 tarihli Resmi Gazete ve 5346 sayılı Yenilenebilir Enerji Kaynaklarının Elektrik Enerjisi Üretim Amaçlı Kullanımına İlişkin Kanun ile ülkemizde başlıca yenilenebilir enerji kaynakları; hidrolik güç, rüzgâr, güneş, jeotermal, biokütle, biyogaz, dalga, akıntı enerjisi ve gel-git olarak tanımlanmaktadır.

Şekil 3.4'te verilen Türkiye'ye ait 2001-2023 yıllarına ait elektrik yük talebi artış değerleri Haziran 2023 itibariyle son on iki ay verisine göre uyarlanmış ve 23 yılda Türkiye'deki elektrik talep büyümesinin değişim oranları gösterilmiştir (EPİAŞ, 2024). Türkiye'de elektrik talebindeki büyüme oranı, 2008 yılı sonuna kadar sürekli artmış fakat 2009 yılında elektrik talep büyümesi %2 azalmış ve 2010-2018 yılları arasında tekrar artış göstermeye devam etmiştir. 2019 yılında talep % 0,1 azalmış ve akabinde 2020 yılında da %0,9 artmıştır. 2021'de Covid-19 sonrası toparlanma etkisi nedeniyle yüksek bir artış olan %8,9'un ardından 2022 yılında %1,2 ve 2023 yılında da %2,1 oranında azalma meydana geldiği görülmektedir.




Şekil 3. 4. 2001-2023 Yıllarına Ait Elektrik Yük Talebi Artış Değerleri

Enerji Tabii ve Kaynaklar Bakanlığı (ETKB) ve Türkiye Elektrik İletim Anonim Şirketi (TEİAŞ) verilerine göre Türkiye'de çeşitli enerji kaynaklarından üretilen elektrik üretiminin yüzdelik değerleri Tablo 3.2.'de gösterilmiş ve bu değerler Şekil 3.5'te grafik olarak sunulmuştur. Grafiğe göre, elektrik üretiminde en büyük pay doğal gaz

kaynağına ait iken; 2010 - 2013 yılları arasında, 2014-2016 yılları arasında, 2017-2019 yılları arasında ve 2021-2023 yılları arasında gazdan elektrik üretimi giderek azalmıştır. Diğer yandan, 2013-2014 yılları arasında, 2016-2017 yılları arasında ve 2019-2021 yılları arasında küresel ısınma ve elektrikte oluşan talep miktarındaki artışa bağlı olarak doğal gazdan elektrik üretimi artış göstermiştir. Kömürden elde edilen elektrik enerjisinin 2010 yılından 2019 yılına kadar genel olarak artış eğiliminde olduğu; 2019-2022 yılları arasında azaldığı ve 2023 yılında yaşanan doğal gaz krizinden sonra tekrar %80 oranında çok sert bir artış olduğu görülmektedir. Hidrolik güçten elde edilen elektrik enerji kuraklık ve küresel ısınmaya bağlı ve yağış rejiminden kaynaklı sürekli değişkenlik göstermektedir. Hidrolik enerjiden kaynaklı değişimden dolayı oluşan elektrik üretimi farkının doğal gaz kaynağından karşılandığı grafikte görülmektedir. Son olarak, güneş, rüzgâr ve jeotermal kaynaklardan elde edilen elektrik enerjisinin 2010-2023 yılları arasında düzenli olarak arttığı görülmektedir.

Tablo 3.2. Türkiye’de elektrik üretiminin üretildiği kaynağa göre yüzdesel dağılımı


Yıl	Kömür (%)	Doğal Gaz (%)	Hidrolik (%)	Rüzgâr (%)	Güneş (%)	Jeotermal (%)	Diğer (%)
2010	26,06	46,47	24,53	1,18	0,2	0,32	1,24
2011	28,87	45,36	22,82	1,7	0,36	0,3	0,59
2012	28,4	43,63	24,16	2,13	0,32	0,38	0,98
2013	26,56	43,77	24,74	2,9	0,33	0,56	1,14
2014	29,94	48,08	16,21	3,1	0,41	0,94	1,32
2015	28,05	37,81	25,76	4,45	0,34	1,3	2,29
2016	33,63	32,52	24,5	5,65	0,38	1,76	1,56
2017	32,8	37,17	19,59	6,02	0,97	2,06	1,39
2018	37,16	30,34	19,66	6,54	2,56	2,44	1,3
2019	37,14	18,85	29,22	7,15	3,04	2,95	1,65
2020	34,5	23,13	25,47	8,1	3,57	3,27	1,96
2021	30,9	33,2	16,7	9,4	4,2	3,2	2,4
2022	20,6	24,7	30,9	10,9	8,8	1,6	2,5
2023	36,3	21,4	19,6	10,4	5,7	3,4	3,2



Şekil 3. 5. Türkiye’de Üretilen Elektrğin Üretildiği Kaynağa Göre Yüzdesel Dağılımı

Karbon ve azot esaslı enerji kaynaklarının yenilenememesi ve bu kaynakların verdiği zararlar nedeniyle küresel dünyada yenilenebilir enerji kaynaklarına yönelim gitgide artırmaktadır. Türkiye sahip olduğu coğrafi konumu itibari ile yüksek değerlerde güneş enerjisi, rüzgâr enerjisi ve hidrolik güç potansiyeline sahiptir. Türkiye, tek başına dünya jeotermal potansiyel enerjisinin %8’ine sahiptir (Yılmaz, 2012).

2022 yılında dünyada ve Türkiye’deki yenilenebilir enerji kaynaklı kurulu güç dağılımının grafikleri Şekil 3.6’da gösterilmiştir. Bu grafikten, yenilenebilir enerji kaynaklarından hidrolik enerjinin Türkiye’de %42,5 ve dünyada ise %58,6 oranıyla en yüksek paya sahip güç olduğu görülmektedir. Hidrolik enerjiden sonra sıralama Türkiye’de rüzgâr (%19,7), güneş (%14,5), biyoenerji (%4,1) ve jeotermal (%3,1) enerji kaynakları ile devam ederken; dünyada ise güneş (%26,7), rüzgâr (25,8), biyoenerji (%4,5) ve jeotermal (%0,5) olarak devam etmiştir (TEİAŞ, 2022; Ritchie, vd., 2022).




Şekil 3. 6. 2022 Yılında Yenilenebilir Enerji Kurulu Güç Dağılım Grafiği (a) Dünyada
(b) Türkiye’de.

3.5. Türkiye’de Enerji Potansiyeli

Şekil 3.7’de sunulan grafikte görüldüğü gibi 2023 yılında ülkemizde üretilen elektriğin %36,3’ü kömür ile, %21,4’ü doğal gaz ile, %19,6’sı hidrolik güç ile, %10,4’ü rüzgâr ile, %5,7’si güneş ile, %3,4’ü jeotermal enerji ile ve %3,2’si diğer kaynaklar ile elde edilirken; toplam enerji üretiminde, yenilenebilir enerji kaynaklarının oranı %39,1 ve karbon, azot esaslı yenilenemez enerji kaynaklarının oranı %60,9’dur. Ayrıca, 2024 yılı Şubat ayı sonu itibarıyla ülkemizde 760 adedi hidroelektrik, 69 adedi kömür, 364 adedi rüzgâr, 63 adedi jeotermal, 357 adedi doğal gaz, 15.780 adedi güneş, 473 adedi ise diğer elektrik enerjisi üretim santrali olmak üzere toplam 17.866 (lisanssız santraller dâhil) elektrik üretim santrali mevcuttur (ETKB, 2024). Tüm bu değerler göz önünde bulundurulduğunda yenilenebilir enerji kaynakları potansiyelinin gittikçe arttığı gözlemlenmektedir. Başlıca enerji kaynaklarının ülkemizdeki potansiyeli aşağıda detaylıca ele alınmıştır.

Güneş Enerjisi Potansiyeli: Türkiye, coğrafi konumu itibarı ile yüksek güneş enerjisi potansiyeline sahiptir. Özellikle Güneydoğu Anadolu Bölgesi ve Akdeniz Bölgesi’nde toplam ışıınım ve toplam güneş radyasyonu değerleri 1.750-2.000 kWh/m² olarak belirtilmiştir (ETKB, 2022). Son yıllarda, ülkemizde güneş paneli üretim fabrikalarının

açılması ve bu panellerin kullanımı ile Güneş Enerji Santrali (GES)'nin inşa edilmesi bu potansiyelin kullanılmasına yönelik adımlardır.



Şekil 3. 7. 2023 Yılında Türkiye'deki Yenilenebilir Enerji Kaynaklarının Yüzdesel Dağılım Grafiği

Rüzgâr Enerjisi Potansiyeli: 2006 yılında sayısal hava tahmin modeli ve mikro-ölçekli rüzgâr akış modeli kullanılarak Türkiye Rüzgâr Enerji Potansiyeli Atlası oluşturulmuştur. Yapılan çalışma, 200 m yatay, yerden 50 m yükseklikte ve 7,5 m/s üzeri yıllık ortalama rüzgâr hızlarına sahip kullanılabilir alanlarda icra edilmiştir. Yapılan çalışma sonucunda, Türkiye'de kurulabilecek rüzgâr elektrik enerji santrallerinin toplam kapasitesinin 47.849,44 MW olduğu hesap edilmiştir. Ege Bölgesi 8 m/sn, Marmara kıyıları 7 m/sn ve Trakya bölgesi 6,5 m/sn rüzgâr hızı ile Türkiye'nin rüzgâr enerjisi potansiyelinin en yüksek olduğu bölgeleridir (ETKB, 2024).

Hidroelektrik Enerji Potansiyeli: Türkiye'de yer alan akarsu ve nehirlerin birçoğu yüksek hidroelektrik güce sahiptir. Bu gücü kullanan tesisler suyun sahip olduğu potansiyel enerjiyi, kinetik enerjiye; kinetik enerjiyi mekanik enerjiye ve mekanik enerjiyi de elektrik enerjisine dönüştürür. Özellikle, Doğu Karadeniz ve Güneydoğu Anadolu Bölgeleri hidrolik enerji potansiyeli yüksek bölgelerimizdir.

Jeotermal Enerji Potansiyeli: Türkiye, jeotermal enerji potansiyeli çok yüksek olan bir ülke olup ülkemizdeki jeotermal kaynakların %78'i Batı Anadolu'da, %9'u İç

Anadolu’da, %7’si Marmara Bölgesi’nde, %5’i Doğu Anadolu Bölgesinde ve %1’i ise diğer bölgelerde yer almaktadır. Bu jeotermal kaynakların %90’ı ısıtma ve termal turizm için kullanılıyorken; %10’luk kısmı ise elektrik enerjisi üretiminde kullanılmaktadır. Türkiye’de ilk jeotermal kaynaktan elektrik üretimi, 1975 yılında 0,5 MW güce sahip Kızıldere Santralinde gerçekleştirilmiştir. Ayrıca, 2008 yılında özel sektörde jeotermal enerjiden elektrik üretimine başlamış olup 2023 yılı sonunda 208 MW’lık kurulu güç artışı ile toplam kurulu güç 16.335 MW seviyesine ulaşmıştır (ETKB, 2024).

Kömür ve Doğalgaz Kaynakları Potansiyeli: Ülkemizde düşük ısıl değere, yüksek kül ve nem oranına sahip linyit kömür yer altı kaynağı bulunmaktadır. Ülkemizde 2023 yılında 35,1 milyon ton taş kömürü, 79,1 milyon ton linyit ve asfaltit, 5,6 milyon ton taş kömürü koku olmak üzere toplam 119,8 milyon ton kömür tüketilmiştir. Taş kömürü ile linyitin %60,2’si ve asfaltitin ise %83,5’u termik santrallerde elektrik enerjisi üretmek için kullanılmıştır. Dünyadaki sera gazlarının %1’i ve Türkiye’deki sera gazlarının %33’ü kömür kullanılması sonucunda ortaya çıkmaktadır (ETKB, 2024).

Nükleer Enerji Potansiyeli: Türkiye’ye ait şuanda aktif çalışan nükleer enerji santrali bulunmamakta olup inşaatı başlayan nükleer santraller bitirildiğinde nükleer enerji potansiyeline sahip olunmuş olacaktır. 12 Mayıs 2010 tarihinde Türkiye Cumhuriyeti Hükümeti ile Rusya Federasyonu arasında nükleer enerji santralinin kurulması ve işletilmesine dair sözleşme imzalanılarak, ülkemizin uzun yıllardır planladığı nükleer güç santrali kurma hedefinde ilk adım atılmıştır. 13 Aralık 2010 tarihinde kurulan proje şirketi, 1 Aralık 2014 tarihinde Çevresel Etki Değerlendirmesi (ÇED) olumlu kararını, 15 Haziran 2017 tarihinde Enerji Piyasası Denetleme Kurulu (EPDK)’ndan elektrik üretim lisansını alarak ilk reaktör üretim ünitesi için lisans başvurusunda bulunmuş ve 19 Ekim 2017 tarihinde sınırlı çalışma yetkisini alarak fiili olarak 2 Nisan 2018’de inşaat çalışmalarına başlamıştır. Benzer şekilde, ikinci nükleer güç ünitesi için 30 Kasım 2018’de çalışma sözleşmesi yapılmıştır. 26 Ağustos 2019’da üniteye ait inşaat lisansı alınarak 8 Nisan 2020 tarihinde inşaat başlanılmıştır. Proje şirketi, 28 Mart 2019’da üçüncü güç ünitesi için ve 12 Mayıs 2020 tarihinde de dördüncü güç ünitesi için inşaat lisansı başvurularında bulunmuştur. 3 Mayıs 2013 tarihinde ülkemizin inşasını planladığı ikinci nükleer güç santrali Sinop Nükleer Güç Santrali için Japonya ile inşaat ve

işletilmesine ilişkin hükümlere ait anlaşma imzalanarak resmi çalışmalar devam etmektedir (ETKB, 2023).

3.6. Makine Öğrenmesi

Makine öğrenmesi, ilk defa bilgisayar bilimcileri tarafından 1956 yılında Dartmouth konferansında ele alınmış ve birçok araştırmaya konu olmuştur. Makine öğrenmesi, bilgisayar ve elektronik cihazlar ile kontrol yapılmadan öğrenme özelliği kazandırılan tekniklerden biridir (Çoban, 2018). Makine öğrenmesi, hem veri tabanı problemlerinin hem de yapay zekâ çalışmalarının bir parçasıdır. Makine öğrenme algoritması, değişken bir çalışma alanında bulunan değişiklikleri öğrenip bu değişikliklere uyum sağlayabiliyorsa, sistem tasarımcısının olası tüm durumları tahmin etmesi ve bu durumlar için çözüm oluşturması gerekmez. Çünkü bu akıllı sistem, tüm değişiklikleri ve olası durumları öğrenme yeteneği sayesinde ortaya çıkarmaktadır.

Makine öğrenmesi, kendine has algoritmaları ve metotları geliştirirken girdi veri setlerinden öğrenme veri setlerine göre sonuç değerlerine ait tahminler yapar. Bu tahminlerde istatistik, optimizasyon, veri madenciliği, yapay zeka, evrimsel hesaplama ve yapay sinir ağları gibi verilerden sonuç çıkarmayı amaçlayan doğru örüntüleri oluşturarak kullanır. Makine öğrenmesi yöntemleri, çok sayıdaki veri setini inceleyerek tahmin yapmak için model oluşturmayı amaçlar. Bu analiz çalışmalarını kolaylaştıran veri madenciliği, veri setleri içerisindeki verileri inceleyerek anlamlı verilerin çıkarılmasını sağlayan yöntem olarak adlandırılır (Diri, 2014).

Bir sisteme insan öğrenmesine benzer öğrenme yeteneği, makine öğrenmesi yöntemi ile kazandırılır. Öğrenme yeteneği için sisteme yüklenen veri setleri arasından bir örüntü oluşturulur. Oluşturulan örüntü ile veri setleri arasındaki bağlantılar incelenerek sonuç elde edilir. Örneğin; borsadaki bir hisse senedinin borsadaki geçmiş dönem fiyat hareketleri incelenip gelecekteki fiyat tahmini makine öğrenmesi sayesinde yapılabilir (Keleş vd., 2020). Makine öğrenme modelinde algoritma oluşumunun başarılı olması, modelin eğitildiğinde öğreniminin temsili ve çıkarımında güvenilir sonuçlar verir.

Yapılan çalışmalarda, öğrenme ve çıkarım algoritmasının etkinliği, tahmin doğruluğu kadar önemli hale gelmektedir (Şapcı, 2022).

Gün geçtikçe dünya genelinde enerjiye olan talep miktarında artış görülmektedir. Enerjideki talep artışından dolayı, enerji krizinin olmaması için enerji üretim kaynaklarının önceden arz planlamasının yapılması, talep tahmini için önemli avantaj sağlar. Makine öğrenmesi yöntemleri ile geleceğe yönelik, enerji kaynaklarından olan elektrik ve doğalgaz üretim ve tüketim miktarları tahmin edilebilir (Karaman ve Bektaş, 2023). Makine öğrenmesini etkileyen etmenlerden birincisi makineye tecrübe kazandırmak için girilen veri setleridir. Deneyim olarak girilen veri setleri, fazla veri ve farklı durumlardan oluşuyorsa, öğrenmeye katkısı veri seti miktarı ile doğru orantılı olacaktır. İkinci faktör, çalışmanın sonucunu etkilemeyen veya veri setinde aynı etkiye sahip başka verinin kullanılmasıdır. Diğer bir ifade ile kullanılan veri setleri arasında birbirleri ile ilişkilendirmenin düşük olduğu veya problem çözümüne katkısının çok az olduğu gözlemlenen veri setleridir. Bu veri setleri ile makine öğrenme yöntemi kullanılarak yapılan çalışmalarda hata oluşabileceği ve sonucun olumsuz yönde etkilenebileceğinden dolayı pek tercih edilememektedir. Üçüncü faktör, belirlenen öğrenme tekniğinin makinenin öğrenmesi için görev ve gerekli veri kümesiyle alakalıdır. Makine öğrenmesi, problemlerin bir kısmını çözmek için verilerin içerisinden bir çıktı değerine ihtiyaç duyulabilir. Çıktı değeri kullanılan problemler, tahmin ve sınıflandırma çalışmalarıdır. Çıktı değeri kullanılması ile ilgili olarak, makine öğrenmesinde çözülecek probleme göre yöntem belirlenmesi güvenilir sonuç elde etmek için önem arz etmektedir. Makine öğrenmesi araştırma alanları temel olarak görev merkezli yapılan çalışmalar, bilişsel benzetim uygulamaları ve teorik incelemeler olarak üçe ayrılır. Performansı zamanla azalan eski yapılmış çalışmalarda, performansı artırmak için yapılan öğrenme sistemlerinin geliştirilmesi görev merkezli çalışma olarak adlandırılır. Çalışmalarda bilişsel modelleme yaklaşımı olarak da adlandırılan bilişsel benzetim çalışmaları, insan öğrenme etaplarının analiz edilmesi ve bilgisayar ile uygulaması yapılan simülasyon çalışmalarını kapsar. Son olarak teorik incelemeler ise kolaylıkla kullanılabilir alanlardan bağımsız olarak var olan öğrenme tekniklerinin ve algoritmalarının teorik uygulanmasını kapsar (Kayademir, 2020). Makine öğrenmesi, veri setinin çok iyi analiz edilmesi ve

sonuç alma aşamalarının düzenlenmesi için son derece önemli bir teknoloji olup sürekli olarak gelişerek akademik ve endüstriyel çalışmalarda önemli bir yer edinmektedir.

Makine öğrenmesinde öğrenme işlemi gözetimli (denetimli), gözetimsiz (denetimsiz), yarı gözetimli ve pekiştirmeli öğrenme olmak üzere dört farklı biçimde gerçekleşir (Hoogendoorn ve Funk, 2018). Bu öğrenme işlemleri aşağıda detaylıca açıklanmıştır.

Denetimli öğrenmeye, etiketli veri seti modelinin öğrenebilmesi için gereksinim duyulur. Modellemeden önce, hangi veri setinin hangi bilgiyi karşıladığı belirlenir. Girdiler ile çıktılar arasındaki bağ tespit edilerek en uygun teknik geliştirilirken, sisteme yüklenen girdi verisinin oluşturacağı sonuç tahmin edilir (Aydın ve Özkul, 2015). Örneğin; demontaj olarak satılan ürünün yanında montajının nasıl yapılacağını belirten, parçalarının kurulumunu gösteren bir kitapçık verilir. Denetimli öğrenmede, parçaları ve kurulum kılavuzu verilen demontaj ürününün montajı yapılarak bütün hale getirilmesi beklenir.

Denetimsiz öğrenmede, sisteme veri setleri yüklenerek girdi değerleri arasındaki örüntünün makine öğrenmesi yöntemleri tarafından belirlenmesi istenir. Teknikte var olan veri setleri ile makinenin kendi kendine öğrenmesi beklenir (Keskin ve Yıldız, 2018). Çevrimiçi sitelerden yapılan alışverişlerde, sepete eklenen ürünlerden sonra sitenin bazı ürün tavsiyelerinde bulunması denetimsiz öğrenmeye örnek olarak verilebilir. Yarı gözetimli öğrenme, gözetimli ve gözetimsiz öğrenme yöntemlerinin tam orta noktasında yer alır. Veri setinin, etiketli ve etiketsiz verileri birlikte içerdiği durumlarda öğrenme işleminin nasıl gerçekleşeceğini belirleyen öğrenme yöntemidir (Zhu ve Goldberg, 2009). Metin ve görüntü sınıflandırma çalışmalarında sıklıkla kullanılan öğrenme yöntemlerinden birisidir.

Pekiştirmeli öğrenmede, oluşturulan modellemenin öğrenebilmesi için veri seti yok iken alınan sonuçlara göre makine öğrenmesi gerçekleştirilir. Pekiştirmeli öğrenmede, ödül sistemi oluşturularak alınan çıktılarına göre sonuç karşılaştırılır ve öğrenme karşılaştırma değerlerine göre yapılır (Efe, 2021). Pekiştirmeli öğrenmeye örnek olarak; üniversite sınavına ilk defa hazırlanmaya başlayan öğrencinin, çözdüğü soruların sonuçlarının

yanlış olması ve yanlış sonuçlardan deneyim kazanarak soru çözümlerini öğrenip üniversite sınavını kazanması verilebilir.

3.7. Makine Öğrenmesi Yöntemleri

Makine öğrenmesinde kullanılan yöntemler, denetimli ve denetimsiz öğrenme yöntemi olmak üzere iki grupta incelenir. Denetimli öğrenme yöntemleri, lojistik regresyon modellemesi, karar ağacı, sinir ağı yöntemleri, rastgele orman regresyonu, lineer regresyon, destek vektör makineleri, k-en yakın komşular yöntemleridir. Denetimsiz öğrenme yöntemleri ise apriori ve fp-growth yöntemleri ile kümeleme modellemesi çalışmalarında kullanılan k ortalamalar yöntemleridir (Gezer ve Saylan, 2017). Makine öğrenimi modelleme çalışmalarına çok fazla örnek uygulama gösterilebilir. Çok fazla veri setinin makine öğrenmesi yöntemleri ile kullanılması sonucunda yeni veriler oluşturulur. Özellikle mühendislik alanında kullanılan makine öğrenmesi yöntemleri ile mimarlık alanında yapılan uygulamalarda, tasarım ve üretim kısımlarında etkili sonuçlar alınmaktadır. Makine öğrenmesi yöntemi, mimarlık alanında yer alan tasarım aşamasında yeni fikirler oluşturulmasına fırsat sağlayarak üretim aşamasında oluşacak risklerin azaltılması için de oldukça faydalı bir yöntemdir (Şapcı, 2022).

Çok sayıda veri setine, metin madenciliği ve duygu analizinde kullanmak için ihtiyaç duyulur. Karmaşık modellemelerin oluşturulup sonuçlandırılmasında çok fazla hesaplama işlemine ihtiyaç vardır. Yüksek hesaplama gerektiren uygulamalarda da makine öğrenmesi yöntemleri ile güvenilir sonuçlar elde edilebilmektedir (Atalay ve Çelik, 2017).


3.7.1. Yapay sinir ağları (artificial neural networks)

Yapay sinir ağlarına ait ilk çalışma 1938 yılında Rashevsky tarafından başlatılmış ancak o zamanki bilgisayarların güçlü işlemciye sahip olmamasından dolayı 1960 yılında çalışmalar durma noktasına gelmiştir. 1980 yılından sonra bilgisayar teknolojisinin ilerlemesi ve gelişmesinden sonra yapay sinir ağları ile ilgili çalışmalara yeniden başlanılarak yeni teknikler ortaya konulmuştur. Yapay sinir ağları, yapay zekâ biliminin

bir çalışma alanı olarak bilgisayarların öğrenmesi için belirli tekniklerden oluşur. Bilgisayarlar geçmiş dönemlerde sadece hesaplama yapmak ve veri aktarmak için kullanılıyorken, günümüzde çok fazla miktarlardaki veri setlerini özetleyen ve bu veri setleri ile oluşan durumlarla sonuç oluşturabilen yetenekli elektronik makineler haline gelmiştir (Ağyar, 2015).

YSA, insan beynine ait öğrenme tekniği ile yeni bilgiler üretme ve ortaya çıkarma gibi özellikleri yardım almadan kendiliğinden gerçekleştirmek amacı ile biyolojik sinir ağı yapısından geliştirilen bilgisayar tekniğidir. YSA insan beyninin özellikleri olan öğrenme, genelleme, hatırlama işlemlerini yapmaya çalışır. YSA, öğrenme işlevini gerçekleştirirken kullandığı algoritmaların temelini matematiksel formüller ile oluşturur (Kabalcı, 2014).

YSA, sadece sayısal veri setleri ile çalışmaktadır. Eğer kullanılacak veri setleri içerisinde nominal değerlere sahip veri setleri var ise, bu değerlerin sayısal değerlere dönüştürülmesi gerekmektedir (Ağyar, 2015). YSA bazı örnek örüntüler ile eğitildikten sonra öğrenmeyi gerçekleştirir. Öğrenme işleminden sonra girdi veri setleri ile sonuç oluşturur.




Şekil 3. 8. Biyolojik Sinir Hücresi

Şekil 3.8’de belirtilen insan beyninde yer alan biyolojik sinir hücreleri aksonlar ile birbirine bağlıdır (Erbaş, 2005). Bu aksonlar sayesinde, hücreler arası veri akışı sağlanır. YSA da insan beynine benzer şekilde çok sayıda sinir hücresi birbirine paralel bağlanarak

nöronları oluşturur. YSA eğitimi yapılırken elde edilen öğrenme veri setleri, nöronların arasında oluşan bu ağı üzerinde saklanır (Erbaş, 2005). YSA non-lineer yapılarda kullanılması, çeşitli problemleri modelleyebilmesi, öğrenme ve genelleme yapabilmesi, hata toleransının düşük olması gibi genel karakteristik özelliklerinden dolayı çalışmalarda en çok tercih edilen makine öğrenmesi yöntemidir. Ayrıca, YSA sahip olduğu paralel dağılmış yapısından dolayı hızlı ve verimli bir şekilde çalışabilmektedir.

YSA görüntü işleme, veri madenciliği, bölümlere ayırma, değerlendirme ve süreç modelleme gibi birçok çalışmada etkin kullanılmaktadır. Şekil 3.9'da basit bir YSA yapısına ait sinir hücresi belirtilmiştir. X , dışarıdan veri setleri ile oluşturulan girdileri gösterirken; W , farklı değerlerdeki ağırlıkları göstermektedir. Bütün ağırlıkların bir araya getirildiği toplama (birleştirme) fonksiyonu, sonuç oluşturmak için kullanılan aktivasyon (transfer) fonksiyonu ve çıkış fonksiyonu olmak üzere beş ana bileşenden oluşmaktadır (Keskenler ve Keskenler, 2017).



Şekil 3. 9. Yapay Sinir Ağı Model Yapısı

YSA yapısında hücrelere dışarıdan verilen bilgiler girdileri oluşturur. Bu girdiler veya bir önceki katmandan gelen veri setleri, giriş verisi olarak YSA'ya ait hücrelere iletilir. Bu girdiler X_i sembolüyle gösterilir ve Eşitlik 3.1'de belirtilen ağırlık (w_{ij}) ile çarpılarak eşik değeri (b_j) ile toplanır (Özveren, 2006). Ağırlıklar, bir yapay sinir ağına ait gelen verinin önemini ve nöron da oluşturduğu etkiyi gösterir. Ağırlıklar ($w_1, w_2, w_3, \dots$

w_i), yapay sinir ağı tarafından alınan girişlerin sinir hücresinde etkisini belirleyen uygun katsayılardır (Öztemel, 2013).

$$Z_i = f\left(\sum_{i=1}^n (w_{ij}x_i + b_j)\right) \quad (3.1)$$


Eşitlik 3.2’de belirtilen toplam fonksiyonu ile oluşturulan değer, doğrusal ya da doğrusal olmayan türevlenebilir bir aktif fonksiyondan geçirilerek çıktı hesaplanır.

$$y = f(Z_i) = f\left(\sum_{i=1}^n (w_{ij}x_i + b_j)\right) \quad (3.2)$$

YSA modellerinde öğrenme denetimli ve denetimsiz olmak üzere iki şekilde yapılır. Denetimli öğrenme tekniğinde, modellemeye giriş ve çıkış değerleri birlikte verilir. Teknik sisteme verilen giriş ve çıkış veri setleri arasındaki bağlantıyı kurarak öğrenme işlemini yerine getirir. Veri setleri arasındaki ağırlıklar ağ tarafından geliş güzel uyarlanır. Denetimsiz öğrenmede, modellemeye sadece giriş veri setleri verilerek modellemenin bir çıkış verisi oluşturması beklenir (Öztemel, 2003).

3.7.1.1. Tek katmanlı yapay sinir ağları

Şekil 3.10’da gösterilen tek katmanlı yapay sinir ağı modeli sadece giriş ve çıkış katmanından meydana gelmiştir (Ersoy ve Karal, 2012). Modelin birden çok girdi değeri olabilir fakat sadece bir tane çıktı değeri vardır. Tek katmanlı yapay sinir ağı, doğrusal olmayan modellemelerde tercih edilmez.




Şekil 3. 10. Tek Katmanlı Yapay Sinir Ağı Modeli

Modelde, giriş kısmındaki nörondan çıktı kısmındaki nörona bağlantı yapılırken; giriş kısmı, veri setindeki her özelliği ayrı nöron ile temsil eden düğümlerden meydana gelir. Çıktı kısmı, giriş kısmındaki veri setleri üzerinde modelleme çalışması yaparak sonuç üreten nöronlardan meydana gelir. Çıktı nöronuna ait girdi verileri belirli ağırlıklar ile çarpılarak toplanır. Toplanan girdi değerleri, modelde belirtilen aktivasyon fonksiyonunda işlem görür. Aktivasyon fonksiyonu, çoğunlukla basit doğrusal fonksiyon ya da merdiven fonksiyon olabilir. Aktivasyon fonksiyonunun çıktısı, ağırlı çıktı değeri olarak kabul edilir (Ersoy ve Karal, 2012).

3.7.1.2. Çok Katmanlı Yapay Sinir Ağları

Şekil 3.11’de belirtilen çok katmanlı sinir ağı modeli, giriş (girdi) katmanı, gizli katmanlar ve çıkış (çıkı) katmanından meydana gelmektedir. Daha çok karmaşık problemlerin analizinde tercih edilirler. Girdi katmanında çok sayıda giriş veri setleri olabilir. Problemin analizine göre, modellemede çok sayıda gizli katman yer alabilir. Gizli katmanda da çok sayıda düğüm yer alırken, her katmandaki veriler çeşitli fonksiyonlarla ağ bağlantısı kurup veri setlerindeki bilgileri çıktı katmanına aktarırlar (Ataseven, 2013).



Şekil 3. 11. Çok Katmanlı Yapay Sinir Ağı Modeli


Veri, girdi katmanından itibaren modele ait her katmandan teker teker işlem görerek ilerler. Katmanlara ait nöronlar, bir önceki katmandan gelen girdi verilerine göre aktif fonksiyon ile işleme alır. Rectified Linear Unit (ReLU), sigmoid, hiperbolik tanjant (tanh) gibi fonksiyonlar kullanılarak nöronlara ait çıktıların hesaplama işlemi yapılır. Bu fonksiyonlar, modellenen ağın non-lineer problemleri analiz etmesini sağlar. Bağlantı ağının gücünü gösteren ağırlıklar ve nöronlar için eklemeye yapılan biaslar, modelin eğitiminde belirlenir (Ataseven, 2013). Eğitim çalışması sonrasındaki modelin sonucu ile gerçek değer arasında oluşan hata (fark), geri besleme algoritması ile elde edilir ve ağırlıklar bu sonuçların oranına göre belirlenir.

Stokastik Gradyan İnişi (SGİ) Uygulanabilir Moment Tahmini ve Karesel Gradyanın Hareketli Ortalaması gibi algoritmalar, ağırlıkların güncellenmesini sağlar (Yılmaz vd., 2018). Çok katmanlı yapay sinir ağlarına ait karar verme süreçleri karmaşık yapıdadır. Bu modellemeler, güçlü hesaplama ve çok fazla veri setine ihtiyaç duyar. Yapay zeka ve makine teknik modellemelerinde, çok katmanlı yapay sinir ağları temel görev üstlenerek karmaşık problemleri çözmede önemli katkılar sağlar.

3.7.2. Destek vektör makinesi (support vector machine)

Destek Vektör Makineleri (DVM) ilk defa 1992 yılında Vapnik tarafından ele alınmış olup günümüzde kullanılan şeklini de yine Vapnik tarafından 1995 yılında almıştır (Meral ve Saraçlı, 2020). 1997 yılında DVM tekniği, Vapnik tarafından yapılan çalışmada regresyon uygulamalarını da dâhil ederek uygulama alanını genişletmiştir. Bu çalışmalardan sonra DVM tekniği, matematikçilerin ve yapay zekâ çalışan bilim insanlarının ilgi odağı haline gelmiştir. DVM özellikle makine öğrenmesi alanında, istatistiksel regresyon yöntemi belirlemede ve sinyal işlemede uygun bir teknik olarak kullanılmıştır (Karagülle, 2008). DVM'nin en önemli avantajı, sınıflandırma problemlerini kareli optimizasyon problemine çevirerek, çözümü esnasında gerçekleşen öğrenme adım sayısını azaltmakta ve diğer teknik yöntemlere göre daha hızlı çözümleyebilmektedir. DVM kullanılarak yapılan çalışmalarda istatistiksel öğrenme teknikleri esas alınır. DVM çok sınıflı problemlerin analizi için geliştirilerek, çok sınıflı vektörler arasındaki mesafeyi maksimum yapmayı amaçlamıştır (Ayhan ve Erdoğan, 2014).


DVM yöntemi, genellikle non-lineer regresyon analizlerinde başarılı sonuç veren yöntem olarak kullanılmaktadır. Şekil 3.12'de DVM'nin çalışma teknik yapısı gösterilmiştir. Şekilde $K(x, x_m)$ değerleri çekirdeğe ait fonksiyonları, $y_n a_n$ değerleri Lagrange çarpanlarını, Bias b değeri, dışarıdan gelen etkiyi, x ise giriş veri setini göstermektedir. DVM'de çıktı değeri, girdi değerinin çekirdeğe ait fonksiyon ve Lagrange Çarpanlarının bağımsız değerleri ile dışarıdan gelen hata toplamına eşittir. (Uçak, 2012).



Şekil 3. 12. Destek Vektör Makinesi Genel Yapısı


3.7.2.1. Destek vektör sınıflandırma (support vector classifier)

DVM’de sınıflandırma problemleri, doğrusal ve doğrusal olmayan ayrılabilir problem olarak iki başlık altında incelenir. Doğrusal ayrılabilirlik, verilerin doğrusal bir düzlemle ayrılabilmesi olarak tanımlanırken, doğrusal olmayan ayrılabilirlik ise verilerin doğrusal bir düzlemle ayrılamaması olarak tanımlanır (Acı vd., 2017).



Şekil 3. 13. İki Sınıflı Doğrusal Ayrılabilen Problem Örneği

Şekil 3.13’de doğrusal düzlemde siyah çizgi ile ayrılabilen ve kırmızı - yeşil noktalardan oluşan iki bölge belirtilmektedir. Buradaki hedef, siyah çizgi ile bölünen iki bölge içerisine sonradan eklenecek bir noktanın hangi alanda yer alacağını belirlemektir. Mavi çizgi ile belirtilen sınır düzlemlerin arasında kalan bölgeye margin alanı denir. Margin alanının büyüklüğü, belirtilen sınırın başarısını gösterir. Bazı problem veri setlerinin, lineer bir şekilde ayrılması mümkün olmayabilir. Bu tarz problemlere doğrusal ayrılamayan (non-linear) problemler denir. Problem analizi, yine 2 bölgeye ayrılarak yapılır. Şekil 3.14’de doğrusal olmayan bir durumun düzlem üzerinde gösterimi yapılmıştır.



Şekil 3. 14. İki Sınıflı Doğrusal Ayrılamayan Problemin Düzlem Üzerinde Gösterimi

Non-lineer problemlerin analizi için çeşitli çekirdek (kernel) modelleri kullanılabilir. Bu çekirdeklerin en çok kullanılanları, Radial Basis Function (RBF), polinomial, sigmoid ve doğrusal çekirdek modelleridir. Çekirdek model seçimi, veri setinin oluşturulma şekline ve problemin yapısına bağlıdır (Ayhan vd., 2014). Non-lineer bir problemin çözümü için Eşitlik 3.3’de gösterilen formül kullanılır.

$$f(x) = \text{sign}(\sum a_i y_i \phi(x) \phi(x_j) + b) \quad (3.3)$$

Non-lineer problem analizinde kullanılan çekirdeklere ait eşitlikler, Eş. 3.4, Eş. 3.5, Eş. 3.6 ve Eş. 3.7 de belirtilmiştir.

Doğrusal Çekirdek	$K(x_i, x_j) = x_i \cdot x_j$	(3.4)
-------------------	-------------------------------	-------

Polinomial Çekirdek	$K(x_i, x_j) = (\gamma(x_i \cdot x_j) + c)^d$	(3.5)
---------------------	---	-------

Sigmoid Çekirdek	$K(x_i, x_j) = \tanh(\gamma(x_i \cdot x_j) + c)$	(3.6)
------------------	--	-------

Radyal Tabanlı Çekirdek	$K(x_i, x_j) = \exp(-\gamma x_i - x_j ^2)$	(3.7)
-------------------------	---	-------


Destek Vektör Sınıflandırma (DVS) modelinde başarı, çekirdek modeline ait parametreler ve aşırı öğrenme problemini çözmek için kullanılan düzenleme parametresi c 'nin uygun şekilde ayarlanmasına bağlıdır.

c değeri, modelin eğitim verilerine sağladığı uyumu belirler. c 'ye ait yüksek değerlerin uyumu (overfitting) çekirdeğe uyumu çok fazla artırırken, verilen düşük değerler de modelin çekirdeğe uyum sağlayamamasına sebep olur. Oluşturulan modeller, karar sınırını belirleme ve analiz etme açısından karmaşık yapıdadır. Veri setleri büyük olduğunda, eğitim için geçen zaman beklenenden uzun olabilir. Fakat veri setleri modele uygun tasarlandığında güvenilir tahminler oluşturabilirler (Kavzoğlu ve Çölkesen, 2010).

3.7.2.2. Destek vektör regresyon (support vector regression)

Destek Vektör Regresyonu (DVR), destek vektör makinelerinin regresyon problem analizlerinde kullanılan çeşididir. DVR tekniği, girdi olarak hazırlanan veri seti için çıktı değeri tahmin ederken veri analizi ile hiper düzlem (doğru) oluşturmaya çalışır. Oluşturulan hiper doğru, veri setlerine ait noktalara mümkün olduğunca yakın değerde olmalıdır (Açıkkar ve Sivrikaya, 2020).

DVR'de aynı DVS'de olduğu gibi, doğrusal olan ve doğrusal olmayan problemlerin analizinde kullanılabilir. Şekil 3.15'te doğrusal ve doğrusal olmayan DVR yapılarına ait grafikler görülmektedir. DVR'de, tayin edilen ε (epsilon) değeri ile, hiper düzlem çevresinde bir marj alan meydana getirilir. Bu marj alandaki veri noktalarını, model hata olarak görmez. Model, bu marj alanındaki tahmin verilerini kabul edilebilir hata sınırları içerisinde olarak değerlendirme yapar. Böylece tasarlanan model sadece marjın dışındaki veri setlerini hedefine alır. Çekirdek yöntemleri (kerneltricks) kullanılarak doğrusal olmayan problemlere ait veri setleri, yüksek boyutlu bir uzaya taşınır (Demirezen ve Çetin, 2021).



Şekil 3. 15. DVR Örnekleri (a) Doğrusal (b) Doğrusal Olmayan


DVR tekniği, finansal veri tahminleri, hava durumu tahminleri, enerji üretimi ve tüketimi tahminleri başta olmak üzere çeşitli alandaki uygulamalarda kullanılır. DVR uygulamalarında uygun çekirdek ve hiper parametre ayarları seçilmez ise, güçlü ve esnek bir model olması tek başına güvenilir sonuç vermez. Dikkate alınması gereken diğer faktörler ise; modellemede hesaplama maliyetinin yüksek olması ve model yorumlanabilirliğidir.

3.7.3. Doğrusal regresyon (linear regression)

Doğrusal regresyon, bilinmeyen veriyi bilinen veri kullanılarak tahmin edebilen makine öğrenmesi yöntemlerinden biridir. Doğrusal regresyon, bilinmeyen veya bağımlı bir değişkeni ve bilinen veya bağımsız bir değişkeni doğrusal bir denklem ile matematiksel ilişki kurar (Aalen, 1989). Örneğin, geçen yıl gerçekleşen gelirleriniz ve giderleriniz incelendiğinde, gelire ait verileri bağımsız değişken ve gider değerlerini de bağımlı değişken olarak ele alalım. Harcamalar gelirin dörtte biri ise bir sonraki senenin gelir değerlerini bilirsek doğrusal regresyon tekniği ile bir sonraki senenin gelirinin dörtte birinin, gider olacağını belirtebiliriz.

Doğrusal regresyon, geniş uygulama alanına sahip olan veri biliminde en temel tekniklerden biridir. Ancak, tekniğe ait veri setlerinin doğrulanması ve teknik için ideal veri setleriyle tasarlanması önem arz etmektedir. Doğrusal tekniğin uygulaması yapılırken, bağımlı ve bağımsız değişkenler arasında doğrusal bağlantı olmasına,

hataların varyansının değişken olmamasına, hataların anormal dağılım göstermemesine azami özen gösterilmelidir (Kılıç, 2013). Şekil 3.16’de yer alan grafikte, x eksenini bağımsız değişken ve y eksenini bağımlı değişken olacak şekilde gösterilmiştir. Doğrusal regresyonun amacı, bağımlı ve bağımsız değişkene ait nokta veri setlerine en uygun doğrusal çizgi grafiği (doğrusal fonksiyonu) oluşturmaktır (Keramati ve Hamdullahpur, 2022).



Şekil 3. 16. Doğrusal Regresyon Grafiği

Eşitlik 3.8’de doğrusal regresyona ait bağımlı ve bağımsız değişkenler arasındaki ilişki matematiksel formül ile belirtilmiştir. Formülde, bağımlı değişkeni y, bağımsız değişkeni x, x ile y arasında doğrusal olarak belirtilemeyen durumu ε belirtir. Eğer ε değeri sıfır olursa, x değerinin bilinmesiyle bağımsız değişken y değeri bulunabilir. Formüldeki β_0 değeri, doğrunun y eksenini kestiği noktayı; β_1 regresyon katsayısını diğer bir ifade ile eğimini gösterir. Eşitlik 3.9’da, birden fazla bağımsız değişkenin olması durumunda kullanılacak formülü belirtir (Şahinler, 2000).

$$y = \sum_{i=1}^n (\beta_0 + \beta_i x_i) + \varepsilon \quad (3.8)$$

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3 + \beta_i x_i + \varepsilon \quad (3.9)$$

Bir doğrusal regresyon formülündeki β değerleri, en küçük kareler yöntemi ile elde edilmektedir. Doğrusal regresyon yöntemi kullanılarak bağımlı değişkenin bulunması için veri setlerinin ard arda veya sürekli sayısal değer olması ve kategorik verinin yer almaması gerekmektedir. Modellemede yer alan bağımsız değişken değerlerinin sayısal veri olması gerekir. Ancak, bazı özel durumlarda kategorik veri seti olabilir. Doğrusal regresyon; analiz yöntemlerine ve modelin kompleks yapısına göre çeşitlilik gösterebilir. Basit regresyon modeli, tek bağımsız değişken ile tek bağımlı değişkeni tahmin etmek için kullanılan tekniktir. Çoklu doğrusal regresyon ise iki ya da iki den fazla değişken kullanılarak bağımlı değişken tahmini yapmak için kullanılan tekniktir (Kılıç, 2013).

3.7.3.1. En küçük kareler yöntemi

En küçük kareler yöntemi, doğrusal regresyon tekniğinde iki ya da daha fazla değişken arasındaki bağlantıyı açıklamak için kurulan bir modeldir. Bu teknik kullanılarak oluşturulan modelin mevcuttaki modele yakınsama miktarı, oluşturulan regresyon modelinin veri setine uygunluk seviyesini gösterir (Vupa ve Alma, 2008)

Eşitlik 3.10'da gösterilen doğrusal fonksiyon formülünde, y bağımlı değişkeni, x bağımsız değişkeni, a eğimi ve b ise doğrunun y eksenine ile kesiştiği noktayı gösterir. Bütün veri setine ait noktalar için, modelin tahmin değeri ile gerçek değeri arasındaki hata farkı hesap edilir. En küçük kareler yöntemi, hataların karelerinin toplamını minimum seviyeye indirgemeyi hedeflerken genellikle diferansiyel teknikler kullanılır.

a ve b parametreleri için alınan türevlerin sıfıra eşit olduğu noktaların tespit edilmesi ile en iyi a ve b değerleri bulunur. Bu değerler, veri setine ait noktaların genel eğilimini gösterir.


$$y = ax + b \quad (3.10)$$

3.7.4. Karar ağacı (decision tree)

Karar ağacı yöntemi, veri madenciliği sınıflandırma yöntemidir. Yöntemde kategorik ve sürekli (nümerik) veriler kullanılır. Sınıflandırmada çalışılan teknik, ağaç diyagramı şekline sahiptir. Yapıda, veri seti sınıflandırma nizamı görsel olarak belirtilmektedir (Koyunbaba vd., 2013). Karar ağacının yönteminin en büyük avantajı, nominal ve nümerik veri ile çalışabilmesidir. Örnek olarak Tablo 3.3'te belirtilen veri setleri ile hedef tahmin çalışması oluşturulmuştur. Tablonun oluşturulmasındaki amaç, veri seti içerisinde yer alan değişkenleri küçük parçalara ayırarak daha kolay kontrol edilmek istenilmesidir. Tablo 3.3'te belirtilen değişkenler kategorik verilerden oluşmaktadır. Örneğin; hava güneşli ve rüzgar mevcut iken hedef değer negatif ; hava yağmurlu nem normal iken hedef pozitif olarak elde edilmektedir.

Tablo 3.3. Karar Ağacı Hava Tahmin Örneği

<i>Değişkenler</i>					
<i>No</i>	Hava	Sıcaklık	Nem	Rüzgar	Hedef
1	Yağmurlu	Sıcak	Yüksek	Hayır	Negatif
2	Yağmurlu	Sıcak	Yüksek	Evet	Negatif
3	Bulutlu	Sıcak	Yüksek	Hayır	Pozitif
4	Güneşli	Ilık	Yüksek	Hayır	Pozitif
5	Güneşli	Serin	Normal	Hayır	Pozitif
6	Güneşli	Serin	Normal	Evet	Negatif
7	Bulutlu	Serin	Normal	Evet	Pozitif
8	Yağmurlu	Ilık	Yüksek	Hayır	Negatif
9	Yağmurlu	Serin	Normal	Hayır	Pozitif
10	Güneşli	Ilık	Normal	Hayır	Pozitif
11	Yağmurlu	Ilık	Normal	Hayır	Pozitif
12	Bulutlu	Ilık	Yüksek	Evet	Pozitif
13	Bulutlu	Sıcak	Normal	Hayır	Pozitif
14	Güneşli	Ilık	Yüksek	Evet	Negatif



Şekil 3. 17. Hava Tahmini Örneğine ait Basit Karar Ağacı Şekli

Şekil 3.17’de oluşturulan karar ağacı şeklinde, karar ağacı eğitim veri setinde belirtilen verilerin her biri doğru sınıf ile oluşturulurken anlamlı sınıflandırma ilişkisine dikkat edilmelidir.

Karar ağacı tekniğinde kullanılan algoritmalar;

- Hunt algoritması
- CART
- ID3, C4.5, C5.0
- SLIQ, SPRINT

Kullanılan bu teknikler ile seçici sınıflandırmayı sağlayan analizler yapmak mümkün olmaktadır.

Karar ağacı algoritmalarının anlaşılır olması, veri setlerinin görsel şekiller ile aktarılması, oluşturulma ve kullanılma maliyetinin düşük olması, sayısal ve nümerik verilerin birlikte

kolayca işlenebilirliği, istatistiksel alanda rahatça uygulanabilirliği tercih edilmesinde öncelik sağlamaktadır.

Aşırı öğrenme nedeniyle kompleks karar ağaçlarının oluşması ile sonuçların bazen anlamsız olması, veri setlerinde oluşturulan küçük bir değişimde bütün algoritma dizaynının değişikliğe uğraması ve baskın veri seti nedeni ile yanlış karar ağacı oluşması karar ağacı algoritmaları için dezavantaj oluşturmaktadır.

3.7.4.1. Regresyon ağacı

Regresyon Ağacı Yöntemi Breiman Friedman Olsen ve Stone tarafından geliştirilerek sınıflandırma ve regresyon ağaçlarının oluşturulmasında kullanılan yapay zeka yöntemlerinden biridir (Tran vd., 2008). Regresyon ağacı yöntemlerinden olan Bagging ve Boosting, çok fazla öğrenme ve modelin çalışmasını artırmaya yönelik geliştirilmiş iki teknik çalışmalarda kullanılmaktadır. Bagging yaklaşımı, veri seti içerisinde yeni ağaçlar oluşturulurken alınan veriler yerine, yeni veriler koyulacak şekilde algoritmalar oluşturulması ile dizayn edilir. Boosting modelinde, artık optimizasyonunu esas olarak çalışma başarı artışı hedeflemektedir (Keskin ve Yıldız, 2018).

Regresyon ağacı yöntemi, bütün veri setini kapsayacak tekil düğüm noktalarının oluşturulması ile meydana gelir. Veri setine ait bilgiler, benzer değişken değerleri için aynı değerlerde olmamalı. Çünkü aynı değerlere sahip veriler, algoritmadaki hataları azaltmaktadır.

3.7.5. Gauss süreç regresyonu

Gauss Süreç Regresyonu (GSR), non-lineer olan çok değişkenli regresyon ve sınıflandırma analizi için kullanılan başarılı ve esnek makine öğrenmesi yöntemidir. GSR yönteminin, tahmin edilen sonuçlar üzerindeki belirsiz ölçüm yapması ve parametrik olmayan verilerle başarılı tahminler yapabilmesi özellikleri en önemli tercih sebepleridir (Snelson ve Ghahramani, 2007).

Sonuçları oluşturan formülün, ortalama hesaplama $m(x)$ ve kovaryans hesaplaması $k(x,x')$ tarafından belirtilen stokastik bir teknik olan Gauss süreci olduğu hipotezini esas alır. Gauss sürecinin çalışması, girdi değişkenleri ile çıktı değişkenlerini bağlayan bir işlevdir. Kovaryans işlevi, çalışmanın düzgünlüğünü ve benzer olmayı kodlar (Mohd Aris vd. 2019)

Eşitlik 3.11’de belirtilen fonksiyon GSR olasılık dağılımını tanımlar.

$$f(x) \sim GP(m(x), K(x, x')) \quad (3.11)$$

Eşitlik 3.12’de ortalama fonksiyonu olan $m(x)$, Eşitlik 3.13’te kovaryans fonksiyonu olan $K(x, x')$ ifade edilmektedir.

$$m(x) = E[f(x)] \quad (3.12)$$

$$K(x, x') = E[(f(x) - m(x))(f(x') - m(x'))^T] \quad (3.13)$$

Eşitlik 3.14’te verilen Kovaryans fonksiyonu, çok fazla tercih edilen SE (Squared Exponential) denklemdir.


$$K_{SE}(x, x') = \Phi_f^2 \exp\left(-\frac{1}{\Phi^2} \|x - x'\|^2\right) \quad (3.14)$$

SE denkleminde kullanılan Kovaryans fonksiyonunda belirtilen θ_f , x-ölçekleme (genlik) ve θ_l , y-ölçekleme (uzunluk ölçeği) olarak belirtilmektedir (Snelson ve Ghahramani, 2007).

Eşitlik 3.15’te belirtilen Kovaryans matrisi, değerlendirilecek X girdi veri setlerinin sınırlı kombinasyonlarını sağlamaktadır (Skagestad, 2018).

$$K := K((x_1, \dots, x_n)(x_1, \dots, x_n)) = \begin{bmatrix} K(x_1, x_1) & \dots & K(x_1, x_n) \\ \vdots & \ddots & \vdots \\ K(x_n, x_1) & \dots & K(x_n, x_n) \end{bmatrix} \quad (3.15)$$

Şekil 3.18’de belirtilen GSR prior SE kernel ile kullanımı (a) ve 5 gürültüsüz gözlem sonrası GP (Gaus Proses - Gaussian Process) posterior (b) sonuçları verilmiştir. Şekil 3.18 (a)’da Eşitlik 3.14 kullanılarak oluşturulan grafikte çıktı değerleri daha kararsız iken, (b)’de Eşitlik 3.16 kullanılarak elde edilen grafikte çıktı değerleri kararlı ve sağlıklı sonuçlar vermektedir (Murphy, 2012).



Şekil 3. 18. GP Prior SE Kernel (a) ve GP Posterior (b) Karşılaştırması

3.8. Makine Öğrenmesi Yöntemlerinde Performans Ölçümü

Makine öğrenmesi yöntemleri kullanılarak sınıflandırma ve regresyon çalışmaları yapılırken, beklenen tahmin sonucunun başarı seviyesinin ne olduğunu tespit etmek için çeşitli performans ve parametre teknikleri kullanılır (Yıldırım, 2021). Bir problemin çözümü için beklenen tahmin sonucunu oluşturacak makine öğrenmesi yöntemi kullanılmak istenilirken, her bir tekniğin çalışması ölçülür ve ölçüm sonucunda başarılı teknik modelleme kullanılır. Diğer önemli nokta ise, eğitim ve test veri setlerinin başarı sonuçlarının mukayese edilmek istenmesidir. Performans kriterleri veri kümesine ve test

kümesine ayrı ayrı uygulanarak mukayese yapılır, istenilmeyen sonuçlara müdahale edilir (Devreyakan, 2021).

Makine öğrenmesi yöntemleri ile yapılan tahmin çalışmalarının performans ölçümlerinde temel 4 kriter değerlendirilmektedir. Bu ölçüm kriterleri aşağıda başlıklar halinde açıklanmış ve ölçüm için uygulanan formüller her bir kriter için verilmiştir. Bu formüllerde y_i ; gerçek değer, y_i' ; tahmin edilen değer ve n ; gözlem sayısıdır.

3.8.1. Ortalama mutlak yüzde hata (mean absolute percentage error - MAPE)

Makine öğrenmesi yöntemleri ile yapılan tahmin çalışmalarında elde edilen tahmin sonuçlarının gerçek sonuçlarla farkının, gerçek değere bölümünün mutlak değeri alınarak, işlem sonucunun veri sayısına bölünmesinin yüzde olarak ifade edilmesiyle oluşturulan bir tekniktir. Ancak, veri setleri arasında 0 (sıfır) değeri olan veri varsa bölme işlemini tanımsız yapacağı için yüzde olarak belirtilen değerde hatalı sonuç elde edilir. Düşük tahmin değerlerinde hata %100'ü geçemez fakat, tahmin değerleri gerçek değerden çok uzak ise hata oranı için üst limit değeri yoktur (Özen vd., 2021).

MAPE değeri %10'un altındaki modeller “çok iyi” olarak, %10 ile %20 arasındaki modeller “iyi” olarak, %20 ile %50 arasındaki modeller “kabul edilebilir” olarak değerlendirilmiştir (Aslay, 2013). Eşitlik 3.17’de belirtilen MAPE formülü, çalışmalarda hesaplama yapmak için kullanılmaktadır.

$$MAPE = \frac{100}{n} \sum_{i=1}^n \left| \frac{y_i - y_i'}{y_i} \right| \quad (3.17)$$

3.8.2. Ortalama mutlak hata (mean absolute error - MAE)

Gerçek veri seti değerleri ile tahmin edilen değerlerin mutlak değer farkı alınarak, sonuç değerleri toplanır ve veri seti sayısına bölünür. Elde edilen sonuç sıfır ile sonsuz arasındaki değerlerde değişiklik gösterebilir. Elde edilen sonuç değerinin sıfıra yakınlığı, modelin başarısını göstermektedir (Aydın, 2018).

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - y_i'| \quad (3.18)$$

3.8.3. Ortalama kare hatası (mean square error - MSE)

Veri setindeki gerçek değerler ile tahmin edilen değerlerin farkının karesi alınır. Alınan kare farkı her veri seti için kümülatif olarak toplanır ve veri seti sayısına bölünerek MSE değeri elde edilir. Veri setinde çok farklı değerlerin olması, oluşturulan MSE modelin uygun bir tasarım olmadığını gösterir (Yurttabir ve Kıymetli Şen, 2021).

$$MAE = \frac{1}{n} \sum_{i=1}^n (y_i - y_i')^2 \quad (3.19)$$

3.8.4. Ortalama karekök hata (root mean square error - RMSE)

RMSE değeri, MSE değerinin karekök işlemi sonucunda elde edilir. RMSE değeri, tahmin işlemine ait hataların standart sapması olarak da belirtilir. RMSE değeri sıfır ile sonsuz değer arasında sayısal bir değer alır. RMSE değeri, sıfıra ne kadar yakınsa model de o kadar kararlı olduğunu gösterir (Gezmez, 2022).

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - y_i')^2} \quad (3.20)$$

3.9. Normalizasyon Kavramı ve Normalizasyon Yöntemleri

Normalizasyon, veri seti içerisinde yer alan değişken değerlere sahip verilerin belli bir kurala göre sınıflandırılma işlemidir. Bu işlem, değişken ölçeklerdeki verileri kıyaslanabilir hale getirerek, makine öğrenmesi yöntemlerinde güvenilir sonuçlar alınmasında yardımcı olur (Saranya ve Manikandan, 2013). Özellikle makine öğrenme yöntemlerinde normalizasyon işlemi veri setinin homojen ve çalışması kolay olması için yapılması gerekmektedir. Normalizasyon işleminin yapılması aşağıdaki faydaları sağlar.

- Veri setinde yer alan bilgilerin, farklı özelliklerde yer alması verilerin farklı sınıflandırmaya sahip olduğunu gösterir (örneğin; üretilen enerji miktarı ve hava sıcaklığı gibi). Bu sınıf farklılıkları, algoritmaların veri setinden kaynaklı yanlış işlem yapmasına yol açar. Normalizasyon ile farklı özelliklere sahip veri seti değerleri 0 ile 1 arasında ortak ölçeğe göre hazırlanır. Böylece farklı özellik sorunu çözülür.
- Normalizasyon, veri setindeki değerlerin tüm özelliklerini eşit derecede olmasını sağlayarak büyük ölçekli verilerin algoritmada baskın olmasını engeller.
- Normalizasyon, veri setine ait özelliklerin belirli bir kurala göre sınıflandırarak algoritmaların hızlı ve etkili öğrenmesini sağlar.
- Normalizasyon, tasarlanan modelin en basit halde olmasına olanak sağlar ve aşırı uyum (ezberleme) riskini ortadan kaldırmayı hedefler.
- Yüksek miktarda bilgiye sahip veri setlerinde normalizasyon işlemi, modelin kompleks halini ve veri ezber olayını azaltabilir.
- Veri analistleri ve modelleme çalışanları için normalizasyon işlemi yapılmış veriler ile çalışmak tahmin sonuçlarının yorumlanması işlemini kolaylaştırır.

Normalizasyon işlemini gerçekleştirmek için literatürde çeşitli yöntemler bulunmaktadır. Bu yöntemlerin nihai sonucu normalizasyon işlemini gerçekleştirmek olsa da kendi aralarında bir takım farklı unsurlar göstermektedirler. Normalizasyon yöntemleri aşağıda başlıklar halinde ele alınmıştır.

3.9.1. Minimum - maksimum (min - max) yöntemi

Veri seti değerlerini, doğrusal olarak bir kategoride sınıflamak için kullanılan bu teknik, daha çok mühendislik problem analizlerinde kullanılır. Sınıflandırma aralığı genellikle 0-1 arasında aldığı sayısal değerlerde olur. Problemin analizine göre 0-1 aralığı istenilen büyüklüğe göre oluşturulabilir (Yüce ve Özkan, 2021). Eşitlik 3.21’de belirtilen Minimum- Maksimum Yöntemine ait eşitlikte normalize edilmiş değer gerçek değer ile veri seti içerisinde yer alan en küçük değer farkının, veri seti içerisinde yer alan en büyük değer ile en küçük değer arasındaki farka bölümü ile elde edilir.

$$x' = \frac{(x_i - x_{\min})}{(x_{\max} - x_{\min})} \quad (3.21)$$

x' : Normalize edilmiş değer

x_i : Normalize edilecek değer

$x_{\max}$: Veri seti içerisindeki en büyük değer

$x_{\min}$: Veri seti içerisindeki en küçük değer

Tekniğin amacı, veri setinde yer alan farklı özelliklere sahip değerlerin aynı büyüklüğe sahip olmasını sağlayarak, oluşturulan algoritmaya ait her bir veri seti değerini eşit ağırlıkta işlemesini sağlamaktır. Kullanılan veri setinde, veriye ait bir özellik milyonlar biriminde iken diğer veriye ait özellik onlar biriminde ise, büyük ölçek farklılığına sahip bu tarz veri setlerinde etkin değerler alabilmek için bu yöntem kullanılır. Bahsi geçen veri seti örneğinde min-max normalizasyonu yapılarak algoritma uygulamalarında oluşacak dengesizliği en aza indirmeye hedeflenir.

3.9.2. Ondalık Ölçekleme Yöntemi

Bu yöntemde veri setindeki değerlerin 1'den küçük olacak şekilde sınıflandırılması hedeflenir ve bu işlemi yapmak için, veri setindeki gerçek sayı değerleri 10 veya 10'un katlarına bölünür. Bölme işleminde payda, veri seti içerisindeki en büyük verinin mutlak değerine göre belirlenebilir (Cihan vd., 2017). Eşitlik 3.22'de belirtilen Ondalık Ölçekleme Yöntemine ait eşitlikte normalize edilmiş değer, Normalize edilecek değer (gerçek sayı değerinin), onluk tabanda yer alan değere bölümü ile elde edilir.

$$A' = \frac{A_i}{10^j} \quad (3.22)$$

A' : Normalize edilmiş değer

A_i : Normalize edilecek değer

10^j : Veriyi 1'den küçük yapan değer

Bu teknik ile veri setindeki değerler yönetilebilir bir seviyeye getirilerek verilerin farklılıkları etkili bir şekilde uygulanmaktadır. Ondalık ölçeklendirme, veri setinde yer alan büyük sayısal değer bulunduran verilerde kullanışlıdır. Büyük sayıların küçük ve çalışılması kolay sayı aralıklarına dönüştürülmesi algoritmaların hızlı ve etkili uygulanabilmesini sağlar.

3.9.3. Z-Skor yöntemi

Veri setinde bulunan çok büyük değerler, sonuca çok fazla ve dengesiz etkide bulunabilirler. Bu değerlerin, makine öğrenmesi yöntemi kullanılarak yapılan çalışma sonucunda diğer veriler gibi eşit etki edebilmesi için Z-skor normalizasyon yöntemi kullanılır (Han vd., 2022).

Eşitlik 3.23'de belirtilen Z-Skor Yöntemine ait eşitlikte normalize edilmiş değer, gerçek değer ile veri seti içerisinde yer alan ortalama değer farkının, veri seti içerisindeki standart sapma değerine bölümü ile elde edilir.

$$x' = \frac{x_i - \mu_i}{\sigma_i} \quad (3.23)$$

x' : Normalize edilmiş değer

x_i : Normalize edilecek değer

μ_i : Veri setinin ortalama değeri

σ_i : Verideki standart sapma

Bu yöntem, veri seti değerini ortalama değer yakınlarında sabitler ve işlem verilerin ortalama değerlerine göre varyasyon seviyesini görmemizi sağlar. Veri setlerine ait değerleri, kuralları belli bir sınıflandırmaya dahil ederek farklı değerlere sahip veriler

arasında kıyaslama yapar. Anormal değerlere sahip veri setleri Z-skor ile kolayca belirlenebilir.

3.9.4. Norm yöntemi

Bu yöntemde, veri setlerinin içerisinde yer alan değerlerin her birinin karesi alınarak kümülatif toplama işlemi yapılır. Toplanan değerlerin karekökü alınarak norm değer Eşitlik 3.24’de belirtilen formüle göre hesaplanır. Normalize edilecek değer, Eşitlik 3.25’te belirtilen norm değere bölünerek normalizasyon işlemi tamamlanır (Yüce ve Özkan, 2021).

Eşitlik 3.24’de belirtilen normalize edilecek verilerin norm değerine ait eşitlikte değer, gerçek değerlerin karekök içerisinde karelerinin toplamının mutlak değeri ile elde edilir. Norm Yöntemi ile normalizasyon değeri, Eşitlik 3.24’de elde edilen değer, Eşitlik 3.25’de belirtilen Norm Yöntem ‘e ait eşitlikte payda değerinde kullanılarak normalize olacak gerçek değer bölümü ile elde edilir.

$$|x| = \sqrt{x_1^2 + x_2^2 + x_3^2 + \dots + x_i^2} \quad (3.24)$$

$|x|$: Normalize edilecek veriler için norm değeri

$$x' = \frac{x_i}{|x|} \quad (3.25)$$

x' : Normalize edilmiş değer

x_i : Normalize edilecek değer

3.9.5. Sigmoid yöntemi

Bu yöntem, sigmoid fonksiyonu kullanılarak veriler 0 ile 1 veya -1 ile 1 aralığında sınıflandırılarak makine öğrenimi ve derin öğrenme çalışmalarında başarılı sonuçlar elde edilmesini sağlar. Makine öğrenmesi yöntemi güvenilir tahmin verilerinin elde edilmesi

için veri setlerinin 0 ve 1 arasında sınıflandırılmasını uygun görür. Sigmoid normalizasyon yöntemi Eşitlik 3.26'ya göre yapılır (Jayalakshmi ve Santhakumaran, 2011).

Sigmoid yöntemi, veri setlerine ait değer noktalarının arasındaki bağı koruyarak girdi verilerinin sürekli ve düzgün bir şekilde normalizasyon işlemini sağlar. Girdi verilerindeki aşırı değerler sigmoid normalizasyonunu olumsuz etkileyebilir. Veri setinde çok büyük veya çok küçük değerler mevcut ise, sigmoid fonksiyonu bu değerleri 0-1 arasına sıkıştıracaktır. Bu durum, farklı olan değerlerin normalleştirilmiş değerler üzerindeki etkisini azaltacaktır. Bu nedenle, sigmoid normalizasyonu uygulanmadan önce veri setine ait girdi değerlerinin incelenmesi gerekmektedir.

$$x' = \frac{1}{1 + e^{-x_i}} \quad (3.26)$$

x_i : Normalize edilecek değer

e : Doğal logaritma değeri

3.10. Programlama Dili Seçimi

Makine öğrenmesi yöntemlerinde veri analizi için Python, R, Scala, Structured Query Language (SQL) (Yapılandırılmış Sorgu Dili), Statistical Analysis System (SAS), Java, Matlab ve Julia gibi programlama dilleri çok fazla tercih edilmektedir. Bu programlama dillerinin kullanımı kişisel deneyimlere, kullanılacak veri seti türüne, proje ölçeğine göre belirlenir. Veri analiz yöntemi ve veri madenciliği alanlarında kullanılan bu proje dilleri, veri setlerini görselleştirme, çizim yapabilme ve kolay kodlanabilme özelliklerine sahiptir (Kılınç vd., 2016).

Scala, 2003 yılından itibaren kullanılan ve sınıf yapısının olduğu programlama dilidir. Scala dilinin diğer programlama dillerine göre kendine has özelliği azdır. Fakat, modelleme yapılırken ihtiyaçlar doğrultusunda geliştirilebilir özelliğe sahiptir. Çeşitli

programlama dillerinden ilham alınarak oluşturulan Scala dili, Java Sanal Makinası üzerinden çalıştırılır (Sayar ve Ergün, 2014).

SQL programlama dili, veri biliminde çok fazla kullanılan dillerden biridir. Genellikle veri tabanı oluşturulması, verilerin analiz edilmesi ve verilerin yorumlandırılması için kullanılmaktadır (Sezgin ve Çelik, 2013).

SAS, paket program ve programlama dilidir. Bu program genellikle büyük firmaların tercih ettiği kodlama programı olup ücretli ve lisanslıdır. Daha çok bilim insanları tarafından kullanılan SAS yazılımı, büyük çaptaki veriler ile istatistiksel tahminler yapmak için kullanılmaktadır (Eskici ve Koçak, 2018).

Eğitim, bankacılık, sağlık, enerji gibi alanlarda bulunan büyük veri setlerinin yönetimi için çok sayıda teknik oluşturulmuştur. Bu tekniklerin uygulanabilmesi için kullanılan programlama dillerinden biriside java programlama dilidir. (Karabay ve Ulaş, 2017). Java, çok sayıda çeşitli sınıflar içeren nesne tabanlı bir programlama dilidir. 1995 yılından itibaren web uygulamalarının geliştirilmesinde kullanılmaktadır. Son yıllarda yapay zekâ tekniklerinde kullanılan popüler bir programlama dili haline gelmiştir (Tungut, 2021).

Mathlab, genellikle matematiksel işlemlerden olan istatistiksel hesaplamalar ve veri analizi çalışmalarında kullanılmaktadır. Ayrıca, robotik çalışmalarda da yaygın olarak kullanılan ve uygulamaların görselleşmesini sağlayan yüksek performansa sahip bir programdır. Bireysel kullanımlarda maliyeti yüksek olan mathlab, zor ve kompleks yapıdaki uygulamalarda tercih edilen, kullanımı kolay basit bir programlama dilidir. Program ticari amaç doğrultusunda geliştirildiği için, kurumsal kullanımlarda daha ekonomiktir (Yayla, 2019).

Julia, 2012 yılından itibaren kullanılmaya başlanılan yüksek başarı oranına sahip üst düzey programdır. Veri biliminde karşılaşılan problemleri analiz etmek için nitelikli derleyici ve geniş matematik kütüphanesine sahip programdır. Julia; makine öğrenmesi, bilimsel uygulamalar, sayısal hesaplamalar ve yapay zekâ çalışmalarında kullanılan açık kaynak kodlu bir programdır. Bu program ile yapılan uygulamalarda kullanılan bilgisayar

kaynağı yorulmaz ve program C tabanlı olduğu için hız konusunda yüksek performans gösterir. Programın uygulaması kolaydır ve farklı programlama dillerine ait kütüphaneler rahatlıkla kullanılabilir (Özden ve Turanlı, 2023).

3.10.1. MATLAB ® programlama dili

MATrix LABoratory (MATLAB), tek başına sayılar yerine matrisler ve dizilerle çalışma yapan üst düzey bir programlama dili ve platformudur. Bilimsel çalışmalar için tasarlanan MATLAB programı, üniversite düzeyinde matematik, fen bilimleri derslerinde ve mühendislik bilimleri için bir öğretim aracı olarak kullanılmaktadır. MATLAB programı LINPACK (doğrusal sistem paketi) ve EISPACK (Eigen sistem paketi) tarafından oluşturulan matris yazılımına kolay erişim sağlamak için yazılmış, teknik bilgi işlem için yüksek performanslı programlama dilidir. Program veri analizi çalışmaları, sinyal işleme projeleri, optimizasyon ve birden çok bilimsel çalışma gerektiren analizler için bir takım fonksiyonlara sahiptir. Ayrıca, 2 ve 3 boyutlu grafik oluşturma ve animasyon tasarlamada kullanılan fonksiyonları da içermektedir.

MATLAB, kullanıcı tarafından komut penceresi olan Prompt'a girilecek olan programa ait komut veya geçerli kodu çalıştırır. Kullanıcı tarafından girilen geçerli verilere, matlab hemen sonuç için yanıt oluşturarak çıkış değeri verir. Buna ek olarak, betik dosyalarında (script files) veya Matlab kod dosyalarında bulunan kodlar da bu programda derlenebilir (Houcque, 2005). Programının bir avantajı da "toolbox" adı verilen sembolik modelleri içermesidir. Toolbox karmaşık matematik problemlerini çözmek, çalışma planlamak ve değiştirmek için hazır fonksiyonları içerir (Kubat, 2013).

4. MATERİYAL VE YÖNTEM


4.1. Giriş

Bu tez çalışmasında makine öğrenmesi yöntemleri kullanılarak Erzincan ili Merkez Günbağı Köyü mevkiinde bulunan Yukarı Mercan HES’de üretilen enerji için KDÜT ve ODÜT gerçekleştirilmiştir. 29.05.2005 yılında enerji üretime başlayan Yukarı Mercan HES, Erzincan Merkez’e 33 km uzaklıkta yer almaktadır. Yukarı Mercan HES, Karasu Nehrinin bir kolu olan Mercan Deresine ait su ile enerji üretimi yapmaktadır. Çalışmada kullanılan meteorolojik veriler; T.C. Çevre, Şehircilik ve İklim Değişikliği Bakanlığı, Erzurum 12.Bölge Müdürlüğü kontrolündeki 17983 istasyon numaralı Ergen Kayak Merkezi İstasyonu’na ait verilerdir. Ayrıca çalışmada Yukarı Mercan HES’e ait enerji üretimini doğrudan etkileyen 2006-2022 yıllarını kapsayan 17 yıllık veri setleri kullanılmıştır.

Çalışmada enerji üretim talebine etki eden meteorolojik faktörler Günlük Toplam Global Güneş Radyasyonu ($\text{kwsaat} \div \text{m}^2$), Günlük Ortalama Kar Yüksekliği (cm), Günlük Toplam Güneşlenme Şiddeti ($\text{cal} \div \text{cm}^2$), Günlük Mevcut Kar Yüksekliği (cm), Günlük Ortalama 50 cm Toprak Sıcaklığı ($^{\circ}\text{C}$), Günlük Ortalama 20 cm Toprak Sıcaklığı ($^{\circ}\text{C}$), Günlük Ortalama 10 cm Toprak Sıcaklığı ($^{\circ}\text{C}$), Günlük Ortalama 5 cm Toprak Sıcaklığı ($^{\circ}\text{C}$), Günlük Ortalama Aktüel Basınç (hPa), Günlük Ortalama Sıcaklık ($^{\circ}\text{C}$), Günlük Ortalama Bulutluluk (8 Okta), Günlük Minimum Bulut Yüksekliği (m) ve Günlük Ortalama Nispi Nem (%) olarak belirlenmiştir. Kullanılan meteorolojik veriler 4982 sayılı Bilgi Edinme Hakkı Kanunu doğrultusunda ilgili kurumdan talep edilmiştir. Enerji üretim talebine etki eden üretim faktörleri Enerjiye Dönüştürülen Su Miktarı (m^3), Ortalama Havuz Yüksekliği (m), Net Düşü Ortalaması (m), Ortalama Debi (m^3), OSOS Değerleri (Faturaya Esas Değerler MWh), İç İhtiyaç Aktif Tüketim Miktarı (kWh), Özgül Su Faktörü (m^3/Mw) ve Brüt Üretim (MWh) verileri olarak belirlenmiştir.

Yukarı Mercan HES’e ait 2006-2022 yıllarını kapsayan 17 yıla ait 8 farklı enerji üretimi etkileyen veri seti ve Meteoroloji 12.Bölge Müdürlüğüne bağlı 17983 istasyon numaralı Ergen Kayak Merkezi istasyonuna ait 14 farklı veri seti eğitim, doğrulama ve test verisi

olarak üçe ayrılmıştır. Eğitim veri seti olarak mevcut veri setine ait ilk 13 yıllık veri (%76) kullanılmıştır. Eğitim veri setine ait veri sayısı 104.390 olarak kullanılmıştır. Doğrulama için veri setine ait 3 yıllık veri (%17) kullanılmıştır. Doğrulama veri sayısı 15.344'tür. Test verisi olarak ise 1 yıllık veri (%7) kullanılmıştır. Test verisi sayısı 5.110 adettir. Test verisi 30 günlük, 90 günlük ve 180 günlük olacak şekilde ayrı ayrı tahmin edilmiştir.



Şekil 4. 1.Yukarı Mercan HES'e ait 17 yıllık Brüt Enerji Üretim Grafiği

Çalışmada Yukarı Mercan HES için makine öğrenmesi yöntemleri kullanılarak üretilen brüt enerji üretim değerinin tahmini amaçlanmıştır. Yukarı Mercan HES'e ait 17 yıllık brüt enerji üretim grafiği Şekil 4.1'de gösterilmiştir. Şekilden görüldüğü gibi üretim miktarı değişkenlik gösterirken, yıl içerisindeki maksimum üretim zamanlarının aynı olduğu görülmektedir.

KDÜT ve ODÜT için çalışmada aşağıdaki algoritmalar ile yük talep tahmini gerçekleştirilmiştir;

- Doğrusal Regresyon (DR)
- Regresyon Karar Ağacı (RKA)
- Destek Vektör Regresyon (DVR)
- Gauss Süreç Regresyonu (GSR)
- Yapay Sinir Ağları (YSA)

Kullanılan algoritmaların modellerdeki doğruluk analizini yapmak için; MAE (Ortalama Mutlak Hata), MAPE (Ortalama Mutlak Yüzde Hatası), MSE (Ortalama Kare Hatası) ve RMSE (Kök Ortalama Kare Hatası) performans değerlendirme parametreleri kullanılmıştır.

4.2. Verilerin Ön İşlemden Geçirilmesi

Veri seti içerisinde yaz saati ile kış saati uygulamalarının yapıldığı yıllara ait zaman dilimi değişiminden ve veri kayıt cihazlarına ait teknik arıza nedeni ile veri kayıt edilememesinden dolayı oluşan tanımsız (NULL) veriler için söz konusu tarih ve günde eksik veriye en yakın 3 günlük sayısal verinin aritmetik ortalaması alınarak bir değer kabulü yapılmıştır. Söz konusu verilerin, veri setinden çıkartılması günlük değer analizinde sapmalara sebebiyet vermemesi için ortalamaya bağlı bir kabul uygun görülmüştür.

Çalışmada kullanılan veri setinin son hali 6209 satır ve 22 sütundan oluşmuştur. MATLAB[®] programında veri işleme sürecinin zaman açısından daha kısa sürmesi hedeflendiği için normalizasyon işleminin excell programı üzerinde yapılması uygun görülmüştür. Normalizasyon işlemi yapılan veri setleri Database Explorer uygulaması üzerinden script (.m* file) kodları oluşturularak MATLAB[®] programına aktarılmıştır.

Analiz kapsamında birtakım parametreler oluşturulmuştur. Bu kapsamda tahmin sırasında kullanılacak belirleyici parametreler mevcut veri seti kullanılarak kısa dönem yük tahmini 30 gün, orta dönem yük tahmini 90 gün ve 180 gün olarak belirlenmiştir.

4.3. Doğrusal Regresyon Yöntemi ile Enerji Üretim Tahmini

Yapılan çalışmada birden fazla bağımsız değişken kullanıldığı için çoklu doğrusal regresyon yöntemi kullanılmıştır. Bu yöntem, çalışmada kullanılan çok fazla değişkenli veri setlerini aynı anda kontrol etmeyi amaçlar. Enerji üretim tahmini yapılan tesise ait brüt üretim verileri yıllara göre doğrusal diyagram oluşturduğu Şekil 4.1’de belirtilmiştir.

Brüt üretim veri setlerinin doğrusal diyagram oluşturması, KDÜT ve ODÜT çalışmalarında DR yöntemi ile enerji üretim tahmin sonuçlarının gerçek değerlere yakın değerler elde edilmesine avantaj sağlamaktadır.


Enerji üretim talep tahmininde “[$b, bint, r$]=regress(‘Bağımlı Değer’, ‘Bağımsız Değer’)” algoritması kullanılarak regresyon analizi yapılmıştır. b , bağımlı ve bağımsız değişkenler arasındaki ilişkiyi; $bint$, katsayılar için güven aralığını ve r bağımlı değer ile regresyon modeli arasındaki farkı göstermektedir.

Şekil 4.2’de, DR yöntemi ile yapılan 30 gün KDÜT çalışmasına ait tahmin edilen üretim değeri ile gerçek üretim değerlerinin karşılaştırıldığı grafik gösterilmiştir. Yapılan elektrik üretim tahmin verilerinin; doğruluk derecesini ölçmek için MAPE değeri 0,132; gerçek değerden farklılığını ölçmek için MSE değeri 0,000009; mutlak hata değerlerini toplamak için MAE değeri 0,0008 olarak hesap edilmiştir. Elde edilen hesaplama değerlerine ve oluşturulan grafiğe göre, yapılan çalışma sonucunda elde edilen verilerin gerçek enerji değerlerine çok yakın olduğu tespit edilmiştir.




Şekil 4. 2. 30 Günlük Enerji Üretiminin Gerçek Değer ve DR Yöntemi ile Tahmini Değer Grafikleri

Şekil 4.3'te, DR Yöntemi kullanılarak yapılan 90 gün ODÜT çalışmasına ait tahmin edilen üretim değeri ile gerçek üretim değerlerinin karşılaştırıldığı grafik gösterilmiştir. Yapılan enerji üretim tahmin verilerinden; MAPE değeri 0,199, MSE değeri 0,00004, MAE değeri 0,0005 ve RMSE değeri 0,006 olarak hesap edilmiştir. Elde edilen hesaplama değerlerine ve oluşturulan grafiğe göre yapılan çalışma sonucundaki verilerin gerçek değere çok yakın veriler olduğu tespit edilmiştir.



Şekil 4. 3. 90 Günlük Enerji Üretiminin Gerçek Değer ve DR Yöntemi ile Tahmini Değer Grafikleri

Şekil 4.4'te, DR ile yapılan 180 gün ODÜT çalışmasına ait tahmin edilen üretim değeri ile gerçek üretim değerlerinin karşılaştırıldığı grafik oluşturulmuştur. Yapılan çalışmaya ait sonuç değerleri için MAPE değeri 0,236, MSE değeri 0,0004, MAE değeri 0,007 ve RMSE değeri 0,020 olarak hesap edilmiştir. Yapılan hesaplamalara ve oluşturulan grafiğe göre tahmin değerleri gerçek değerlere yakın olup 180 günlük enerji üretim tahmini ve yatırım planlama faaliyetleri için kullanılabilir.



Şekil 4. 4. 180 Günlük Enerji Üretiminin Gerçek Değer ve DR Yöntemi ile Tahmini Değer Grafikleri

Tablo 4.1’de DR Yöntemi kullanılarak KDÜT ve ODÜT için yapılan çalışmalara ait MAPE, MSE, RMSE ve MAE değerleri verilmiştir. Bu sonuçlara göre, KDÜT ve ODÜT için yapılan çalışma verilerinin çok iyi olduğu gözlemlenmiştir. Ancak, DR ile yapılan çalışmalarda, çalışma yapılan gün sayısı (30 günden 180 güne doğru) arttıkça tahmin edilen üretim değerlerine ait MAPE, MSE ve RMSE değerlerinde artış olduğu ve gerçek değerlerin tahmin değerlerinden daha çok sapma gösterdiği gözlemlenmiştir. DR yöntemi ile yapılan tahminde, gerçek değere en yakın tahmin değerinin 30 gün KDÜT çalışması ile elde edildiği görülmüştür.


Tablo 4. 1. Performans Fonksiyonlarına Göre DR ile Enerji Üretim Tahmin Sonuçları

Performans Fonksiyonu	30 Gün Üretim Verisi	90 Gün Üretim Verisi	180 Gün Üretim Verisi
MAPE	0,132	0,199	0,236
RMSE	0,003	0,006	0,020
MSE	0,000009	0,00004	0,0004
MAE	0,0008	0,0005	0,007

4.4. Regresyon Karar Ağacı Yöntemi ile Enerji Üretim Tahmini


Regresyon Karar Ağacı (RKA) yöntemi, doğrusal regresyon sınırlamalarını aşmak ve daha karmaşık veri ilişkilerini modellemek için kullanılan bir tekniktir. MATLAB programında, *fitrtree* fonksiyonu kullanılarak tahmin işlemi gerçekleştirilir. *fitrtree* fonksiyonu, RKA problemleri için kullanılan İstatistik ve Makine Öğrenimi Araç Kutusundaki fonksiyonlardan biridir. Karar ağaçları, hem regresyon hem de sınıflandırma görevleri için kullanılabilen bir tür denetimli makine öğrenme algoritmasıdır. *fitrtree* işlevi özellikle regresyona odaklanır. Fonksiyon girdi veri setlerine göre regresyon ağacı oluşturur.

Şekil 4.5'te 30 gün KDÜT çalışmasına ait gerçek değer ve tahmin sonuç değerlerine ait grafik verilmiştir. Yapılan çalışmaya ait sonuç değerleri için MAPE değeri 0,691; MSE değeri 0,00008; MAE değeri 0,004 ve RMSE değeri 0,009 olarak hesap edilmiştir. Performans değerlendirme kriterlerine göre; yapılan çalışma sonucunda elde edilen değerler 30 günlük üretim tahmini için kullanılabilir.




Şekil 4. 5. 30 Günlük Enerji Üretiminin Gerçek Değer ve RKA Yöntemi ile Tahmini Değer Grafikleri

Şekil 4.6’da, RKA yöntemi ile 90 gün ODÜT çalışmasına ait veri değerleri için grafik oluşturulmuştur. Tahmin edilen veri değerlerine ait $MAPE = 3,476$; $MSE = 0,052$; $MAE = 0,020$ ve $RMSE$ değeri 0,227 olarak hesap edilmiştir.



Şekil 4. 6. 90 Günlük Enerji Üretiminin Gerçek Değer ve RKA Yöntemi ile Tahmini Değer Grafikleri

Şekil 4.7’de, RKA yöntemi kullanılarak yapılan 180 gün ODÜT çalışmasına ait veriler ile grafik oluşturulmuştur. Yapılan çalışmaya ait sonuç değerleri için $MAPE$ değeri 2,018; MSE değeri 0,024; MAE değeri 0,062 ve $RMSE$ değeri 0,154 olarak hesap edilmiştir.



Şekil 4. 7. 180 Günlük Enerji Üretiminin Gerçek Değer ve RKA Yöntemi ile Tahmini Değer Grafikleri

Tablo 4.2’de, RKA kullanılarak KDÜT ve ODÜT çalışmalarının tahmin sonuçlarına ait performans fonksiyon değerleri oluşturulmuştur. Bu değerlere göre, RKA kullanılarak KDÜT ve ODÜT için yapılan çalışmalara ait enerji üretim tahmin değerlerinin çok iyi olduğu gözlemlenirken, en güvenilir değerlerin 30 gün KDÜT çalışması sonucu elde edildiği görülmektedir.


Tablo 4. 2. Performans Fonksiyonlarına Göre RKA Yöntemi ile Enerji Üretim Tahmin Sonuçları

Performans Fonksiyonu	30 Gün Üretim Verisi	90 Gün Üretim Verisi	180 Gün Üretim Verisi
MAPE	0,691	3,476	2,018
RMSE	0,009	0,227	0,154
MSE	0,00008	0,052	0,024
MAE	0,004	0,020	0,062

4.5. Destek Vektör Regresyon Yöntemi ile Enerji Üretim Tahmini


Destek Vektör Regresyon (DVR) yöntemi, DR'ye göre daha esnek bir modele sahiptir. Bu esneklikten dolayı veri setleri arasındaki ilişkiyi daha iyi yakalayarak daha doğru tahminler sunabilir. Doğrusal olmayan regresyon problemlerinde kullanılabilecek güçlü bir makine öğrenme tekniğidir. Çalışmada MATLAB® programında DVR Yöntemi ile model oluşturulmasına olanak tanıyan *fitrsvm* fonksiyonu kullanılmıştır. Fonksiyon modelin eğitilmesini ve çapraz doğrulama yapılmasını sağlamaktadır.

Şekil 4.8'de, DVR Yöntemi ile 30 gün KDÜT çalışmasına ait grafik oluşturulmuştur. Çalışmada, MAPE değeri 0,115; RMSE değeri 0,002; MSE değeri 0,000004 ve MAE değeri 0,0007 olarak hesaplanmıştır.




Şekil 4. 8. 30 Günlük Enerji Üretiminin Gerçek Değer ve DVR Yöntemi ile Tahmini Değer Grafikleri

Şekil 4.9'da, DVR Yöntemi ile 90 gün ODÜT çalışmasına ait gerçek değer ile tahmin edilen değerlere ait grafik oluşturulmuştur. Yapılan hesaplamalar ile tahmin edilen veri değerlerine ait MAPE değeri 1,340; MSE değeri 0,009; MAE değeri 0,074 ve RMSE değeri 0,096 olarak bulunmuştur. Performans fonksiyonlarına ait hesaplanan değerler kabul edilen aralıklarda çıktığı için 90 gün ODÜT çalışması sonuç değerleri yapılacak üretim planlamasında kullanılabilir.



Şekil 4. 9. 90 Günlük Enerji Üretiminin Gerçek Değer ve DVR Yöntemi ile Tahmini Değer Grafikleri

Şekil 4.10'da, DVR yöntemi ile 180 gün ODÜT çalışmasına ait tahmin sonuç grafiği oluşturulmuştur. Yapılan çalışmaya ait sonuç değerleri için MAPE değeri 2,991; MSE değeri 0,032; MAE değeri 0,092 ve RMSE değeri 0,178 olarak hesap edilmiştir. Performans fonksiyonları kullanılarak yapılan hesaplamalara göre; yapılan çalışma sonucunda elde edilen değerler, 6 aylık elektrik üretim tahmini ve bütçeleme faaliyetleri için kullanılabilir.



Şekil 4. 10. 180 Günlük Enerji Üretiminin Gerçek Değer ve DVR Yöntemi ile Tahmini Değer Grafikleri

Tablo 4.3'te, DVR Yöntemi kullanılarak yapılan KDÜT ve ODÜT çalışmalarının tahmin sonuçlarına ait performans hesaplama değerleri gösterilmektedir. Bu sonuçlara göre DVR Yöntemi kullanılarak KDÜT ve ODÜT için yapılan çalışmaya ait çıktı değerlerinin iyi olduğu gözlemlenirken, yapılan çalışmada en iyi enerji üretim tahmin değerlerinin 30 gün KDÜT çalışması sonucu elde edildiği görülmektedir.

Tablo 4. 3. Performans Fonksiyonlarına Göre DVR Yöntemi ile Enerji Üretim Tahmin Sonuçları

<i>Performans Fonksiyonu</i>	<i>30 Gün Üretim Verisi</i>	<i>90 Gün Üretim Verisi</i>	<i>180 Gün Üretim Verisi</i>
MAPE	0,115	1,340	2,991
RMSE	0,002	0,096	0,178
MSE	0,000004	0,009	0,032
MAE	0,0007	0,074	0,092

4.6. Gauss Süreç Regresyon Yöntemi ile Enerji Üretim Tahmini

Gauss Süreç Regresyonu (GSR), esnek modelleme yapısına sahip ve doğrusal olmayan veri setleri ile çalışabilen makine öğrenmesi yöntemidir. Çalışmada MATLAB® programında GSR ile model oluşturulmasına olanak tanıyan **fitrgp** fonksiyonu kullanılmıştır. **fitrgp** fonksiyonu modelin nasıl eğitileceğini ve hangi özellikleri kullanacağını belirler (Mahmoodzadeh vd., 2020).


Çalışmada, GSR modelinin kaybı **loss** fonksiyonu ile hesaplanmaktadır. Kullanılan **loss** fonksiyonu , **fitrgp** fonksiyonu kullanılarak tahmin edilen enerji değeri ve gerçek enerji değerlerine ait verilerin arasındaki farkı hesaplamaktadır. **loss** fonksiyonu, tahmin edilen ve gerçek değerler arasındaki kaybı hesaplamak amacıyla regresyon modellerinde yaygın olarak kullanılmaktadır.

Kayıp fonksiyonunun belirli ayrıntıları, GSR modelinin uygulanmasına ve kullanılan kayıp türüne (örneğin ortalama karesel hata, ortalama mutlak hata vb.) bağlıdır. **loss** hesaplama sonuç değeri sıfıra ne kadar yakın ise değeri o kadar gerçek değere yakındır. Tablo 4.4'te GSR loss değerleri gösterilmektedir.

Tablo 4. 4. GSR Loss Değerleri


Parametre	Hata Fonksiyonu	Değer
LGSR30gun	loss	0,015
LGSR90gun	loss	0,037
LGSR180gun	loss	0,054

Şekil 4.11'de GSR yöntemi kullanılarak yapılan 30 gün KDÜT çalışmasına ait veriler ile grafik oluşturulmuştur. Yapılan çalışmaya ait elde edilen verilerin; MAPE değeri 0,326; MSE değeri 0,00005; MAE değeri 0,002 ve RMSE değeri 0,007 olarak hesap edilmiştir. Performans fonksiyonlarına ait elde edilen bu hesaplama değerlerine göre yapılan çalışma sonucunda elde edilen tahmin sonuçlarının güvenilir değerler olduğu belirtilebilir.




Şekil 4. 11. 30 Günlük Enerji Üretiminin Gerçek Değer ve GSR Yöntemi ile Tahmini Değer Grafikleri

Şekil 4.12’de, GSR Yöntemi ile 90 gün ODÜT çalışmasına ait tahmin sonuç grafiği oluşturulmuştur. Şekil 4.12’ye göre, tahmin edilen değerler gerçek değerlere yakın olarak çıkmıştır. Çalışmaya ait performans fonksiyonu sonuçları Tablo 4.5’te belirtilmiştir. 90 gün üretim verisi sonucu olarak belirtilen hesaplama değerlerine göre çalışma sonucu elde edilen tahmin sonuçlarının güvenilir değerler olduğu belirtilebilir.



Şekil 4. 12. 90 Günlük Enerji Üretiminin Gerçek Değer ve GSR Yöntemi ile Tahmini Değer Grafikleri

Şekil 4.13’te, 180 gün ODÜT çalışmasına ait tahmin sonuç grafiği oluşturulmuştur. Yapılan çalışmaya ait elde edilen verilerin; MAPE değeri 5,582; MSE değeri 0,054; MAE değeri 0,171 ve RMSE değeri 0,233 olarak hesap edilmiştir. Hesaplaması yapılan performans fonksiyonu değerleri istenilen aralıkta çıkmasından dolayı, tahmin edilen değerler 180 günlük üretim verisi olarak kullanılabilir.



Şekil 4. 13. 180 Günlük Enerji Üretiminin Gerçek Değer ve GSR Yöntemi ile Tahmini Değer Grafikleri

Tablo 4.5'te, GSR Yöntemi kullanılarak KDÜT ve ODÜT çalışmalarının tahmin sonuçlarına ait performans fonksiyon sonuçları oluşturulmuştur. Bu sonuçlara göre, gsr Yöntemi kullanılarak KDÜT ve ODÜT için yapılan 3 ayrı tahmin çalışmasında gerçek değere yakın tahmin değerleri elde edilirken; en güvenilir veriler 30 gün KDÜT çalışması sonucunda elde edildiği görülmektedir.

Tablo 4. 5. Performans Fonksiyonlarına Göre GSR Yöntemi ile Enerji Üretim Tahmin Sonuçları

Performans Fonksiyonu	30 Gün Üretim Verisi	90 Gün Üretim Verisi	180 Gün Üretim Verisi
MAPE	0,326	1,817	5,582
RMSE	0,007	0,192	0,233
MSE	0,00005	0,037	0,054
MAE	0,002	0,100	0,171

4.7. Yapay Sinir Ağları Yöntemi ile Enerji Üretim Tahmini

MATLAB® programı kullanılarak YSA yöntemi ile model oluşturulmasına olanak sağlayan **sim** fonksiyonu kullanılmıştır. **sim** fonksiyonu, girdi verileri üzerindeki sinir

ağını simüle etmek için uygulanır ve tahmin edilen değerlere ait verilerin çıktı değerlerini üretir.

YSA modelinin gizli katmanındaki nöron sayısı **HiddenLayerSize** değişkeni ile tanımlanır. Sinir ağları bağlamında bu gizli katman, modelin verilerdeki karmaşık modelleri yakalamayı öğrendiği giriş ve çıkış katmanları arasındaki katmandır.

Çalışmada, gizli katmana ait nöron sayısı 21 olarak ayarlanmıştır. Gizli katmandaki nöron sayısının seçimi, verilerin özelliklerine ve verinin karmaşıklığına göre ayarlanabilen bir hiper parametredir.

MATLAB programında **TF (Transfer Fonksiyonu)** hücre dizisi, sinir ağıımızdaki katmanlar için aktarım fonksiyonu olarak tanımlanmıştır. **TF** içerisinde 'tansig' ve 'purelin' fonksiyonları yer almaktadır.

'tansig' hiperbolik tanjant sigmoid transfer fonksiyonudur. Giriş değerlerini -1 ile 1 arasındaki bir aralıkta eşlediği için genellikle gizli katmanlarda kullanılır. Bu fonksiyon sinir ağlarının eğitilmesine yardımcı olur.


'purelin' fonksiyonu, genellikle regresyon görevleri için çıktı katmanında kullanılan doğrusal transfer fonksiyonudur. Diğer bir ifade ile, girdilerin doğrusal birleşimini hesaplar (Özsandıkçioğlu vd., 2015).

Eğitim parametreleri olarak;

- net7t.trainParam.lr = 0.01; %Learning rate
- net7t.trainParam.epochs = 1000; % Number of training epochs
- net7t.trainFcn = 'trainlm'; % Levenberg-Marquardt

kullanılmıştır. **train** fonksiyonu, çalışmada eğitim verilerini kullanarak sinir ağını eğitmek için kullanılır.

Şekil 4.14'te, YSA Yöntemi kullanılarak 30 gün KDÜT çalışmasına ait veriler ile grafik oluşturulmuştur. Yapılan tahmin çalışması sonucunda elde edilen verilere ait MAPE değeri 0,175; MSE değeri 0,00003; MAE değeri 0,001 ve RMSE değeri 0,005 olarak hesap edilmiştir. Hesaplanan değerlere göre, 30 gün KDÜT çalışması sonucunda elde edilen tahmin verileri gerçeğe yakın güvenilir değerler olup; 30 günlük üretim tahmini olarak aylık raporda kullanılabilir.




Şekil 4. 14. 30 Günlük Enerji Üretiminin Gerçek Değer ve YSA Yöntemi ile Tahmini Değer Grafikleri


Şekil 4.15'te YSA ile 30 Gün Tahminine ait Regresyon (R) verileri Eğitim için 0,914, Doğrulama için 0,879, Test için 0,882 ve Tümü için 0,905 olarak elde edilmiştir. Regresyon katsayısı 0 ile 1 arasında değişmektedir. Bu aralıktaki değer 1'e yakınsaması, oluşturulan ağı başarılı olup olmadığını göstermektedir (Doğan vd., 2008).

Şekil 4.16'da, 90 gün ODÜT çalışmasına ait veriler ile grafik oluşturulmuştur. Yapılan çalışmaya ait elde edilen veriler kullanılarak performans fonksiyonlarına ait hesaplamalar Tablo 4.6'da belirtilmiştir. Tablo 4.6'ya göre, 90 gün ODÜT çalışması tahmin verilerinin gerçek değere yakın olarak elde edildiği söylenebilir.


Şekil 4.17’de ,YSA ile 90 Gün tahminine ait R verileri olan Eğitim=0,870, Doğrulama = 0,807, Test = 0,824 ve Tümü = 0,854 olarak elde edilmiştir. Şekil 4.18’de, YSA Yöntemi ile 180 gün ODÜT çalışmasına ait tahmin sonuç grafiği oluşturulmuştur. Tablo 4.6’da belirtilen hesaplama değerlerine göre, 180 gün için yapılan çalışmada elde edilen enerji üretim değerleri 180 günlük enerji üretim tahmini ve üretim raporlamasında kullanılabilir.




Şekil 4. 15. YSA Yöntemi ile 30 Günlük Enerji Üretim Tahminine ait R Değer Grafikleri



Şekil 4. 16. 90 Günlük Enerji Üretiminin Gerçek Değer ve YSA Yöntemi ile Tahmini Değer Grafikleri




Şekil 4. 17. YSA Yöntemi ile 90 Günlük Enerji Üretim Tahminine ait R Değer Grafikleri



Şekil 4. 18. 180 Günlük Enerji Üretiminin Gerçek Değer ve YSA Yöntemi ile Tahmini Değer Grafikleri

Şekil 4.19'da, YSA ile ODÜT 180 Gün Tahminine ait R verileri Eğitim için 0,880, Doğrulama için 0,851, Test için 0,855 ve Tümü için 0,871 olarak elde edilmiştir.



Şekil 4. 19. YSA Yöntemi ile 180 Günlük Enerji Üretim Tahminine ait R Değer Grafikleri

YSA ile oluşturulan modellerin, birden fazla veri setine uyum sağlayarak güvenilir tahmin sonuçları oluşturduğu Tablo 4.6’da belirtilen performans fonksiyonlarına ait çıktılar ile görülmektedir. YSA girdi veri setleri içerisinde değişken, karmaşık ve non-lineer verileri modelleyerek kolayca tahmin değeri elde edebilir. Ayrıca, YSA girdi verilerini sürekli kendi içerisinde modelleyerek çok fazla miktardaki veri setleri ile entegre sağlayarak güvenilir tahmin sonuçları elde eder.

YSA çalışmalarında R değeri modelin aşırı uyum ve ezber yapabilme ihtimalinden dolayı tek başına güvenilir sonuçlar vermeyebilir. R değer sonuçlarının yanında performans fonksiyon sonuçlarını da değerlendirerek modelin güvenilirliğinden emin olmak gerekir. YSA modeli kullanılarak yapılan KDÜT ve ODÜT çalışmalarına ait elektrik üretim tahmin değerlerinin çok iyi ve güvenilir olduğu görülmektedir. Ancak, en iyi tahmin değerinin KDÜT 30 gün çalışmasından elde edildiği görülmektedir. Çünkü, KDÜT 30 gün çalışmasında Test değeri 0,882 ve MAPE değeri 0,175 olarak elde edilmiştir.

Tablo 4. 6. Performans Fonksiyonlarına Göre YSA Yöntemi ile Enerji Üretim Tahmin Sonuçları

<i>Performans Fonksiyonu</i>	<i>30 Gün Üretim Verisi</i>	<i>90 Gün Üretim Verisi</i>	<i>180 Gün Üretim Verisi</i>
<i>MAPE</i>	0,175	2,073	5,400
<i>RMSE</i>	0,005	0,208	0,257
<i>MSE</i>	0,00003	0,043	0,066
<i>MAE</i>	0,001	0,114	0,166

5. DEĞERLENDİRME VE SONUÇ

Bu bölümde tez kapsamında uygulanan makine öğrenmesi yöntemlerine ait belirtilen beş model kullanılarak KDÜT ve ODÜT çalışmaları için elde edilen veriler, gerçek veriler ile karşılaştırma yapılarak grafikler oluşturulmuş ve elde edilen tahmin verileri için performans fonksiyonlarına göre sonuçlar hesap edilmiştir. Performans fonksiyonları olan MAPE, MAE, MSE ve RMSE değerlerine ait sonuç değerleri sıfıra ne kadar yakın olursa, tahmin modeline ait başarı da o kadar yüksek olur (Tekin ve Patır, 2023).


5.1. 30 Gün KDÜT Enerji Üretim Tahmin Değerlendirmesi

30 gün KDÜT çalışmasına ait MAPE, MAE, MSE ve RMSE performans fonksiyonlarının sonuç değerleri Tablo 5.1’de oluşturulmuştur. Aynı çalışmaya ait beş yöntem için 30 günlük tahmin çıktı değerleri ile gerçek enerji üretim değerlerine ait grafik Şekil 5.1’de oluşturulmuştur.

Tablo 5.1’de belirtilen performans fonksiyon sonuç değerlerine göre, çalışma yapılan tüm yöntemler için tahmin edilen enerji üretim değerlerinin güvenilir sonuçlar verdiği görülmektedir. Ancak, 30 günlük KDÜT çalışmasında en güvenilir tahmin sonucunun, MAPE’ye ait 0,115; RMSE’ye ait 0,002; MSE’ye ait 0,000004 ve MAE’ye ait 0,0007 hesaplanan değerleri ile DVR yöntemi kullanılarak elde edildiği görülmektedir.

Tablo 5. 1. Performans Fonksiyonlarına Göre 30 Gün KDÜT için Enerji Üretim Tahmin Sonuçlarının Karşılaştırılması

Makine Modeli	MAPE	RMSE	MSE	MAE
Doğrusal Regresyon	0,132	0,003	0,000009	0,0008
Regresyon Karar Ağacı	0,691	0,009	0,00008	0,004
Destek Vektör Regresyon	0,115	0,002	0,000004	0,0007
Gauss Süreç Regresyon	0,326	0,007	0,00005	0,002
Yapay Sinir Ağları	0,175	0,005	0,00003	0,001



Şekil 5. 1. 30 Gün KDÜT Enerji Üretiminin Gerçek Değer ile Tahmin Edilen Değerlere ait Karşılaştırma Grafikleri

5.2. 90 Gün ODÜT Enerji Üretim Tahmin Değerlendirmesi


90 günlük ODÜT çalışmasına ait MAPE, MAE, MSE ve RMSE performans fonksiyonlarının sonuç değerleri Tablo 5.2’de oluşturulmuştur. Çalışmada kullanılan beş yönteme ait çıktı değerleri ile gerçek enerji üretim değerlerine ait grafik Şekil 5.2’de oluşturulmuştur.

Tablo 5.2’de belirtilen performans fonksiyonu hesaplama değerlerine göre, tüm yöntemlere ait enerji üretim tahmin çıktı verilerinin gerçek değerlere yakın ve güvenilir sonuçlar oluşturduğu görülmektedir.

Şekil 5.2’ye ve Tablo 5.2’ye göre bütün yöntemlerin sonucunda güvenilir tahmin verileri elde edilirken; en iyi tahmin yönteminin MAPE = 0,199, RMSE = 0,006, MSE = 0,00004 ve MAE = 0,0005 değerlerine sahip Doğrusal Regresyon Yöntemi ile oluşturulduğu görülmektedir.

Tablo 5. 2. Performans Fonksiyonlarına Göre 90 Gün ODÜT için Enerji Üretim Tahmin Sonuçlarının Karşılaştırılması

Makine Modeli	MAPE	RMSE	MSE	MAE
Doğrusal Regresyon	0,199	0,006	0,00004	0,0005
Regresyon Karar Ağacı	3,476	0,227	0,052	0,020
Destek Vektör Regresyon	1,340	0,096	0,009	0,074
Gauss Süreç Regresyon	1,817	0,192	0,037	0,100
Yapay Sinir Ağları	2,073	0,208	0,043	0,114



Şekil 5. 2. 90 Gün ODÜT Enerji Üretim Gerçek Değer ile Tahmin Edilen Değerlere ait Karşılaştırma Grafikleri

5.3. 180 Günlük ODÜT Enerji Üretim Tahmin Değerlendirmesi


180 günlük ODÜT çalışması, yılın yarısı olan 180 günde yapılacak olan enerji üretimini görebilmek için yapılmak istenilmiştir. 180 günlük ODÜT çalışmasında kullanılan beş yöntemin MAPE, MAE, MSE ve RMSE performans fonksiyonlarının sonuç değerleri

Tablo 5.3'te oluşturulmuştur. Aynı çalışmaya ait beş yöntemin 90 günlük enerji üretim tahmin değerleri ile gerçek üretim değerlerine ait grafik de Şekil 5.3'te oluşturulmuştur.

Tablo 5.3'de belirtilen performans fonksiyonu sonuçlarına göre tüm modellere ait MAPE değerinin 10'un altında olduğu görülmektedir. Bu durum tüm yöntemlerde 180 gün ODÜT çalışması için başarılı sonuçlar alındığı görülürken; en güvenilir sonucun 0,236 MAPE değeri, 0,020 RMSE değeri, 0,0004 MSE değeri ve 0,007 MAE değeri ile DR yöntemine ait çalışma olduğu görülmektedir.

Tablo 5. 3. Performans Fonksiyonlarına Göre 180 Gün ODÜT için Enerji Üretim Tahmin Sonuçlarının Karşılaştırılması

Makine Modeli	MAPE	RMSE	MSE	MAE
Doğrusal Regresyon	0,236	0,020	0,0004	0,007
Regresyon Karar Ağacı	2,018	0,154	0,024	0,062
Destek Vektör Regresyon	2,991	0,178	0,032	0,092
Gauss Süreç Regresyon	5,582	0,233	0,054	0,171
Yapay Sinir Ağları	5,400	0,257	0,066	0,166



Şekil 5. 3. 180 Gün ODÜT Enerji Üretiminin Gerçek Değer ile Tahmin Edilen Değerlere ait Karşılaştırma Grafikleri

5.4. Sonuç

HES’lerde üretilen enerji, birincil enerji olan hidrolik gücün dönüşümünden elde edilen, ikincil enerji kaynağı olarak kullanılan, alternatif akım olarak üretilen ve depolanamadığından dolayı hemen tüketilmesi gereken bir enerji türüdür. Üretilen enerji depolanamadığı için gelecek zamanı kapsayan yapılacak tahminler, enerji üretiminin devamlılığı ve güvenilirliği açısından son derece önem arz etmektedir.

Bu çalışmada, kanal tipi bir HES’e ait veriler ve HES lokasyonuna yakın meteorolojik istasyon verileri kullanılarak çeşitli makine öğrenmesi yöntemleri ile HES için KDÜT ve ODÜT çalışması yapılmıştır. Makine öğrenmesi yöntemleri ile veri setlerini kullanarak yapılan çalışmadaki amaç, KDÜT ve ODÜT çalışmaları için en uygun yöntemi belirleyerek enerji üretim tahminlerinde kullanmaktır. Çalışma yapılan HES’de, üretim ve bütçe programları 30 gün olan 1 aylık, 90 gün olan 3 aylık (yıllardaki çeyrek dönemler için) ve 180 gün olan 6 aylık (yılın 1. yarısı, 2. yarısı şeklindeki çalışmalarda kullanılmak üzere) zaman dilimleri kullanılmıştır.

Makine öğrenmesi yöntemleri kullanılarak elde edilen sonuçlar incelendiği zaman;

- 30 günlük KDÜT çalışması için, yapılacak enerji üretim tahmin çalışmasında belirtilen makine öğrenmesi yöntemleri ile kararlı üretim değerleri elde edilirken en kararlı değerler $MAPE = 0,115$ değeri ile DVR yöntemi ile elde edilebilir.
- 90 günlük ODÜT çalışması için, yapılacak enerji üretim tahmin çalışmasında belirtilen makine öğrenmesi yöntemleri ile güvenilir üretim değerleri elde edilirken; en iyi tahmin verisi $MAPE = 0,199$, $RMSE = 0,006$, $MSE = 0,00004$ ve $MAE = 0,005$ performans fonksiyon değerlerine sahip DR Yöntemi kullanılarak elde edilebilir.
- 180 günlük ODÜT çalışması için, yapılacak enerji üretim tahmin çalışmasında belirtilen makine öğrenmesi yöntemleri ile gerçek enerji değerlerine yakın tahmin değerleri elde edilirken; en iyi tahmin $MAPE = 0,236$, $RMSE = 0,020$, $MSE = 0,0004$ ve $MAE = 0,007$ performans fonksiyon değerlerine sahip DR Yöntemi kullanılarak elde edilebilir.

- Kullanılan makine öğrenmesi yöntemlerine ait tahmin verilerinin MAPE değerlerine ait hesaplama sonuçları 10'un altında hesaplandığı için bu yöntemlerin kanal tipi santrallerde, santral verileri ve meteorolojik veriler ile birlikte kullanıldığı çalışmalarda güvenilir enerji üretim tahmin verilerinin elde edileceği görülmektedir.

Bu tez çalışmasında, kanal tipi santral için öğrenme yöntemleri kullanılarak tahmin çalışması gerçekleştirilmiştir. Aynı öğrenme yöntemleri, rezervuarlı santrale ait veri setleri kullanılarak rezervuarlı HES'ler için de enerji üretim tahmin çalışmasında kullanılabilir. Ayrıca, yakın zamanda kurulumuna başlanılan mevcut HES'lerin yanında inşaa edilen/edilecek olan Güneş Enerji Santrali ile birlikte işletilen hibrit yenilenebilir enerji üretim sistemlerine ait yapılacak tahmin çalışmaları ile de literatüre farklı kazanımlar sağlamak için yeni bir yöntem olarak kullanılabilir.

Bu tez çalışmasında çeşitli makine öğrenmesi yöntemleri ile yapılan tahmin sonuçlarının gerçek değerlere olan uyumu makine öğrenmesi yöntemlerinin tahmin konusunda başarısını göstermektedir. Geleceğe yönelik enerji üretim tahmin çalışması yapmak, üretim tesisleri için uzun vadede inovasyon planı ile yatırım bütçesi oluşturmak, küresel ısınmadan dolayı üretimdeki farklılığı görebilmek ve yenilenebilir enerji üretimin toplam enerji üretimindeki yerini görmek adına büyük avantajlar sağlayacaktır.

KAYNAKÇA

- Aalen, O. O. (1989). A Linear Regression Model For The Analysis of Life Times. *Statistics in Medicine*, 8(8), 907-925.
- Acı, M., Avcı, M. ve Acı, Ç. (2017). Destek Vektör Regresyonu Yöntemiyle Karbon Nanotüp Benzetim Süresinin Kısaltılması. *Journal of The Faculty Of Engineering and Architecture of Gazi University*, 32(3), 901-907.
- Açıkkar, M. ve Sivrikaya, O. (2020). Yıkanmış Türk Linyit Kömürlerinin Üst Isıl Değerinin Destek Vektör Regresyonu ile Tahmini. *Avrupa Bilim ve Teknoloji Dergisi*, 16-24.
- Ağyar, Z. (2015). Yapay Sinir Ağlarının Kullanım Alanları ve Bir Uygulama. *Mühendis ve Makine*, 56(662), 22-23.
- Al-Falahi, M. D., Jayasinghe, S. D. G., & Enshaei, H. J. E. C. (2017). A review on recent size optimization methodologies for standalone solar and wind hybrid renewable energy system. *Energy Conversion and Management*, 143, 252-274.
- Amber, K. P., Ahmad, R., Aslam, M. W., Kousar, A., Usman, M., & Khan, M. S. (2018). Intelligent Techniques for Forecasting Electricity Consumption of Buildings. *Energy*, 157, 886-893.
- Arslan, K. (2020). Eğitimde Yapay Zekâ ve Uygulamaları. *Batı Anadolu Eğitim Bilimleri Dergisi*, 11(1), 71-88.
- Aslay, F. (2013). *Meteorolojik Parametreler Kullanılarak Yapay Sinir Ağları ile Toprak Sıcaklığının Tahmini*. (Doktora Tezi), Yükseköğretim Kurulu Ulusal Tez Merkezi'nden edinilmiştir. (Tez No. 326946)
- Ataseven, B. (2013). Yapay Sinir Ağları ile Öngörü Modellemesi. *Öneri Dergisi*, 10(39), 101-115.
- Atalay, M. ve Çelik, E. (2017). Büyük Veri Analizinde Yapay Zekâ ve Makine Öğrenmesi Uygulamaları - Artificial Intelligence and Machine Learning Applications in Big Data Analysis. *Mehmet Akif Ersoy Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 9(22), 155-172.
- Aydın, S. ve Özkul, A. E. (2015). Veri Madenciliği ve Anadolu Üniversitesi Açıköğretim Sisteminde Bir Uygulama. *Eğitim ve Öğretim Araştırmaları Dergisi*, 4(3), 36-44.

- Aydın, C. (2018). Makine Öğrenmesi Algoritmaları Kullanılarak İtfaiye İstasyonu İhtiyacının Sınıflandırılması. *Avrupa Bilim ve Teknoloji Dergisi*, (14), 169-175.
- Ayhan, S. ve Erdoğan, Ş. (2014). Destek Vektör Makineleriyle Sınıflandırma Problemlerinin Çözümü için Çekirdek Fonksiyonu Seçimi. *Eskişehir Osmangazi Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 9(1), 175-201.
- Baysal, H. ve Daşdemir, İ. (2021). Fen Bilimleri Öğretmenlerinin Yenilenebilir Enerji Kaynakları Hakkındaki Farkındalık Düzeylerinin Belirlenmesi. *Milli Eğitim Dergisi*, 52(237), 255-278.
- Blum, M., & Riedmiller M. (2013). Optimization of Gaussian Process Hyperparameters using Rprop. *European Symposium on Artificial Neural Networks, Computational Intelligence and Machine Learning*, Bruges-Belgium, 339-344.
- Bozkurt, S. ve Tür, R. (2015). Dünyada ve Türkiye’de Hidroelektrik Enerji Gelişimi ve Genel Değerlendirme. *Ulusal Su Yapıları Sempozyumu*, Antalya, 322-330.
- BP. (2022). Statistical Review of World Energy 2022. *1 St James’s Square London, SW1Y 4PD UK*.
- Božić, M., & Stojanović, M. (2011). Application of SVM methods for mid-term load forecasting Intelligent Techniques for Forecasting. *Serbian Journal of Electrical Engineering*, 8(1), 73-83.
- Bülbül, S. E. ve Çokluk, Y. (2017). Türkiye’de Gelişen Enerji Sektörü Hes’ler ve Kâr Kaybı Sigortaları. *Finansal Araştırmalar ve Çalışmalar Dergisi*, 9(17), 89-114.
- Ceylan, G. (2004). *Yapay Sinir Ağları ile Kısa Dönem Yük Tahmini* (Yüksek Lisans Tezi). İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul.
- Cihan, P., Kalıpsız, O. ve Gökçe, E. (2017). “Hayvan Hastalığı Teşhisinde Normalizasyon Tekniklerinin Yapay Sinir Ağı ve Özellik Seçim Performansına Etkisi. *Turkish Studies*, 12(11), 59-70.
- Çoban, T. (2018) *Sinemada Yapay Zeka*. (Yüksek Lisans Tezi), Yükseköğretim Kurulu Ulusal Tez Merkezi’nden edinilmiştir. (Tez No. 541965)
- Çobaner, M., Haktanır, T. ve Kisi, Ö. (2008). Prediction of Hydropower Energy Using ANN for the Feasibility of Hydropower Plant Installation to an Existing Irrigation Dam. *Water Resources Management*, 22, 757-774.
- Dampage, U., Gunaratne, Y., Bandara, O., De Silva, S. ., & Waraketiya, V. (2020). Artificial Neural Network for Forecasting of Daily Reservoir Inflow: Case Study

- of the Kotmale Reservoir in Sri Lanka. In *2020 5th International Conference on Computational Intelligence and Applications (ICCIA)* (pp 8-12), IEEE.
- Demren, D. (2011). *Electrical Load Demand Forecasting Application Using Support Vector Machines*. (Yüksek Lisans Tezi), Yükseköğretim Kurulu Ulusal Tez Merkezi'nden edinilmiştir. (Tez No. 311927)
- Demirezen, S. ve Çetin, M. (2021). Rastal Orman Regresyonu ve Destek Vektör Regresyonu İle Piyasa Takas Fiyatının Tahmini. *Nitel Bilimler Dergisi*, 3(1), 1-15.
- Devreyakan.(2021). *Performans Metrikleri*. [https:// devreyakan.com/performans-metrikleri/](https://devreyakan.com/performans-metrikleri/) adresinden 10.06.2024 tarihinde edinilmiştir.
- Diri, B. (2014). *Makine Öğrenmesine Giriş*. https://www.siskon.com.tr/dosya/PDF/Makale/Makina_Ogrenmesi.pdf adresinden 10.05.2024 tarihinde edinilmiştir.
- Doğan, E., Ates, A., Yılmaz, E. C. ve Eren, B. (2008). Application of Artificial Neural Networks to Estimate Wastewater Treatment Plant Inlet Biochemical Oxygen Demand. *Environmental Progress*, 27(4), 439-446.
- Efe, A. (2021). Yapay Zekâ Odaklı Siber Risk ve Güvenlik Yönetimi. *Uluslararası Yönetim Bilişim Sistemleri ve Bilgisayar Bilimleri Dergisi*, 5(2), 144-165.
- Erbaş, Ü. (2005). *Yapay Sinir Ağları ve Uygulama Alanları* (Yüksek Lisans Tezi), Yükseköğretim Kurulu Ulusal Tez Merkezi'nden edinilmiştir. (Tez No. 158866)
- ETKB (2022). *Güneş*. <https://enerji.gov.tr/eigm-yenilenebilir-enerji-kaynaklar-gunes> adresinden 30.03.2024 tarihinde edinilmiştir.
- ETKB (2023). *Nükleer Enerji*. <https://enerji.gov.tr/bilgi-merkezi-enerji-nukleer-enerji> adresinden 30.03.2024 tarihinde edinilmiştir.
- ETKB (2024). *Elektrik*. <https://enerji.gov.tr/bilgi-merkezi-enerji-elektrik> adresinden 30.03.2024 tarihinde edinilmiştir.
- Ersoy, E. ve Karal, Ö. (2012). Yapay Sinir Ağları ve İnsan Beyni. *İnsan ve Toplum Bilimleri Araştırmaları Dergisi*, 1(2), 188-205.
- Eskici, H. B. ve Koçak, N. A. (2018). SAS Enterprise Miner ile Metin Madenciliği. *Pusula Teknoloji ve Yayıncılık A.Ş.*, İstanbul.

- George, J., Janaki, L., & Parameswaran Gomathy, J. P. (2016). Statistical Downscaling Using Local Polynomial Regression for Rainfall Predictions – A Case Study. *Water Resources Management*, 30, 183-193.
- Gezer, M. ve Saylan, S. (2017). Açık Kaynaklı Makine Öğrenmesi Kütüphaneleri. O. Torkul, S. Gülseçen, Y. Uyaroglu, G. Çağıl ve MK Uçar. (Editörler). *Mühendislikte yapay zekâ ve uygulamaları*, 53-58.
- Gezmez, K. Ç. (2022). *Bir ilin elektrik tüketim verilerinin makine öğrenmesi yöntemleri ile analizi*. (Yüksek Lisans Tezi), Yükseköğretim Kurulu Ulusal Tez Merkezi'nden edinilmiştir. (Tez No. 755771)
- Ghanbari A., Naghavi, A., Ghaderi, S., & Sabaghian. M., (2009). Artificial Neural Network and Regression Approaches Comparison for Forecasting Iran's annual Electricity Load. In *2009 International Conference on Power Engineering, Energy and Electrical Drives (POWERENG)*, Lisbon, Portugal, 675-679, IEEE.
- Görgülü, Y. F. (2022). Enerji Krizi ve Yenilenemez Enerji Kaynakları. *Teknobilim-2022: Enerji Krizi ve Yenilenebilir Enerji*, 7.
- Hachino, T., Takata, H., Fukushima, S., & Igarashi, Y. (2014). Short-term electric load forecasting using multiple Gaussian process models. *International Journal of Electrical and Computer Engineering*, 8(2), 447-452.
- Hamzaçebi, C. ve Kutay, F. (2004). Yapay Sinir Ağları ile Türkiye Elektrik Enerjisi Tüketiminin 2010 Yılına Kadar Tahmini. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 19(3).
- Han, G., Sönmez, E. F., Avcı, S. ve Aladağ, Z. (2022). Uygun Normalizasyon Tekniği ve Yapay Sinir Ağları Analizi ile Otomobil Satış Tahminlemesi. *İşletme Ekonomi ve Yönetim Araştırmaları Dergisi*, 5(1), 19-45
- Hoogendoorn, M., & Funk, B. (2018). Machine Learning for the Quantified Self .*On the Art of Learning from Sensory Data*.
- Houcque, D. (2005). *Intoruction To MATLAB For Engineering Students*. <https://www.mccormick.northwestern.edu/documents/students/undergraduate/introduction-to-matlab.pdf> adresinden 10.06.2024 tarihinde edinilmiştir.
- Işık, H. ve Şeker, M. (2021). Yapay Sinir Ağı (YSA) Kullanarak Farklı Kaynaklardan Türkiye'de Elektrik Enerjisi Üretim Potansiyelinin Tahmini. *Computer Science*, 304-311.

- Jayalakshmi, T., & Santhakumaran, A. (2011). Statistical Normalization and Back Propagation for Classification. *International Journal of Computer Theory and Engineering*, 3(1), 1793-8201.
- Jones, D. (2022). *Global Electricity Review 2022*. <https://ember-climate.org/insights/research/global-electricity-review-2022/> adresinden 09.06.2024 tarihinde edinilmiştir.
- Kabalıcı, E. (2014). *Yapay Sinir Ağları*. <https://ekblc.files.wordpress.com/2013/09/ysa.pdf> adresinden 17.11.2023 tarihinde edinilmiştir.
- Karabay, B. ve Ulaş, M. (2017). *Büyük Veri İşlemede Yaygın Kullanılan Araçların Karşılaştırılması*. 8. Uluslararası İleri Teknolojiler Sempozyumu'nda sunulan bildiri, Fırat Üniversitesi, Elazığ, 1-18.
- Karagülle, F. (2008). *Destek Vektör Makinelerini Kullanarak Yüz Bulma*. (Yüksek Lisans Tezi), Yükseköğretim Kurulu Ulusal Tez Merkezi'nden edinilmiştir. (Tez No. 177378)
- Kanlı, U., Gülçiçek, Ç., Göksu, V., Önder, Ç. N. ve Oktay, Ö., (2014). Ulusal Fen Bilimleri ve Matematik Eğitimi Kongrelerindeki Fizik Eğitimi Çalışmalarının İçerik Analizi. *Gazi Eğitim Fakültesi Dergisi*, 34(2), 127-153.
- Kavzoğlu, T. ve Çölkesen, İ. (2010). Destek Vektör Makineleri ile Uydu Görüntülerinin Sınıflandırılmasında Kernel Fonksiyonlarının Etkilerinin İncelenmesi. *Harita Dergisi*, 144(7), 73-82.
- Kaur, M., Panwar, S., Joshi, A., & Gupta, K. (2021). Residential Electricity Demand Prediction using Machine Learning. *International Semantic Intelligence Conference*, New Delhi, 331-340.
- Kaya N.E (1). (2024). *IEA: 2026'ya Kadar Küresel Elektrik Talebindeki Artış Düşük Emisyonlu Kaynaklardan Karşılanacak*. <https://www.aa.com.tr/tr/ekonomi/iea-2026ya-kadar-kuresel-elektrik-talebindeki-artis-dusuk-emisyonlu-kaynaklardan-karsilanacak/3116913#> adresinden 26.03.2024 tarihinde edinilmiştir.
- Kaya N.E (2). (2024). *Küresel Elektrik Talebinde Son 20 Yılın En Hızlı Büyümesi Bekleniyor*. <https://www.aa.com.tr/tr/ekonomi/kuresel-elektrik-talebinde-son-20-yilin-en-hizli-buyumesi-bekleniyor-/3279369> adresinden 09.08.2024 tarihinde edinilmiştir.

- Kayademir, S. (2020). *Makine Öğrenmesi (Sınıflandırma Modelleri)*. <https://kayademirs.medium.com/makine-%C3%B6%C4%9Frenmesiacc2b18d875a> adresinden 9.06.2024 tarihinde edinilmiştir.
- Kaynar, O., Yüksek, A. G. ve Demirkoparan, F. (2016). Genetik Algoritma ile Eğitilmiş Destek Vektör Regresyon Kullanılarak Türkiye'nin Elektrik Tüketim Tahmini. *Journal of the Faculty of Economics / İktisat Fakültesi Mecmuası*, 66(2).
- Keleş, M. B., Keleş, A. ve Keleş, A. (2020). Makine Öğrenmesi Yöntemleri ile Uçuş Fiyatlarının Tahmini *Euroasia Journal of Mathematics, Engineering, Natural and Medical Sciences*, 7(11), 72-78.
- Keskenler, M. F. ve Keskenler, E. F. (2017). Geçmişten Günümüze Yapay Sinir Ağları Tarihçesi. *Takvim-i Vekayi* 5(2), 8-18
- Keramati, H., & Hamdullahpur, F. (2022). Deep convolutional surrogates and degrees of freedom in thermal design. *arXiv preprint arXiv:2208.07482*.
- Keskin, M. V. ve Yıldız, D. (2018). Büyük Veri Araçları ve R Kullanarak Amerikan Hava yolu Firmalarının Sorunlarının Keşfedilmesi. *Uygulamalı Sosyal Bilimler Dergisi*, 2(2), 1-19.
- Kılıç, S. (2013). Doğrusal Regresyon Analizi. *Journal of Mood Disorders*, 3(2), 90-92.
- Kılınç, D., Borandağ, E., Yücalar, F., Tunali, V., Şimşek, M. ve Özçift, A. (2016). KNN Algoritması ve R Dili ile Metin Madenciliği Kullanılarak Bilimsel Makale Tasnifi. *Marmara Fen Bilimleri Dergisi*, 28(3), 89-94.
- Koç, A., Yağlı, H., Koç, Y. ve Uğurlu, İ. (2018). Dünyada ve Türkiye'de Enerji Görünümünün Genel Değerlendirilmesi. *Mühendis ve Makina*, 59(692), 86-114.
- Koç, E. ve Şenel, M. C. (2013) Dünyada ve Türkiye'de Enerji Durumu–Genel Değerlendirme. *Mühendis ve Makina Dergisi*, 54(639), 32-44.
- Koç, E. ve Kaya, K. (2015). Enerji Kaynakları – Yenilenebilir Enerji Durumu. *Mühendis ve Makina*, 56(668), 36-47.
- Koyunbaba, B. K., Yilmaz, Z., & Ulgen, K. (2013). An Approach for Energy Modeling of a Building Integrated Photovoltaic (BIPV) Trombe Wall System. *Energy and Buildings*, 67, 680-688.
- Kubat, C. (2013). Yapay Zeka ve Mühendislik Uygulamaları. *Pusula Yayıncılık*.

- Kyrkou, C., Plastiras, G., Theocharides, T., Venieris, S. I., & Bouganis, C. S. (2018). DroNet: Efficient Convolutional Neural Network Detector for real-time UAV Applications. *In 2018 Design, Automation, Test in Europe Conference and Exhibition (DATE)*, Dresden-Germany, 967-972, IEEE.
- Mahmoodzadeh, A., Mohammadi, M., Daraei, A., Ali, H. F. H., Al-Salihi, N. K., & Omer, R. M. D. (2020). Forecasting maximum surface settlement caused by urban tunneling. *Automation in Construction*, 120, 103375.
- Mamun, M. A., & Nagasaka, K. (2004). Artificial neural networks applied to long-term electricity demand forecasting. *In Fourth International Conference on Hybrid Intelligent Systems (HIS'04)*, Kitakyushu, Japan, 204-209, IEEE.
- Meral, G. ve Saraçlı, S. (2020). Destek Vektör Makineleri ve Türkiye'deki Enerji Santrallerinde Doğal Gaz Tüketimi Üzerine Bir Uygulama. *Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 24(2), 411-418.
- Meral, M. E., Teke, A. ve Tümay, M. (2009). Elektrik Tesislerinde Enerji Verimliliği. *Uludağ Üniversitesi Mühendislik Fakültesi Dergisi*, 14(1).
- Mohd Aris, M. N., Daud, H., Dass, S. C., & Mohd Noh, K. A. (2019). Gaussian process methodology for multi-frequency marine controlled-source electromagnetic profile estimation in isotropic medium. *Processes*, 7(10), 661
- Murphy, K. P. (2012). Machine Learning: A Probabilistic Perspective. *The MIT Press*, London.
- NASA (2002). *Weather Forecasting Through the Ages*. <https://earthobservatory.nasa.gov/features/WxForecasting/wx2.php> adresinden 10.03.2024 tarihinde edinilmiştir.
- Özdemir, M. E. (2021). Yapay Sinir Ağları Kullanılarak Orta Dönem Elektrik Enerjisi Tüketim Tahmini: İskenderun Örneği. *Avrupa Bilim ve Teknoloji Dergisi*, (28), 489-492.
- Özden, Ü. H. ve Turanlı, M. (2023). Veri Bilimi İçin Yeni Bir Programlama Dili: Julia. *EKOIST Journal of Econometrics and Statistics*, (38), 223-241.
- Özen, N. S., Saraç, S. ve Koyuncu, M. (2021). COVID-19 Vakalarının Makine Öğrenmesi Algoritmaları ile Tahmini: Amerika Birleşik Devletleri Örneği. *Avrupa Bilim ve Teknoloji Dergisi*, (22), 134-139.

- Özsandıkçioğlu, Ü., Atasoy, A. ve Güney, S. (2015). Classification of different objects with Artificial Neural Networks using electronic nose. *In 2015 23rd Signal Processing and Communications Applications Conference (SIU)* (pp. 815-818). IEEE.
- Öztemel, E. (2003). Yapay Sinir Ağları. *Papatya Yayıncılık*, İstanbul.
- Özveren, U. (2006). *Pem Yakıt Hücrelerinin Yapay Sinir Ağları İle Modellenmesi*. (Yüksek Lisans Tezi), Yükseköğretim Kurulu Ulusal Tez Merkezi'nden edinilmiştir. (Tez No. 182655)
- Ritchie, H., Roser, M., & Roser, P. (2022). *Energy Our World in Data*. <https://ourworldindata.org/energy> adresinden 9.05.2024 tarihinde edinilmiştir.
- Saranya, C., & Manikandan, G. (2013). A Study on Normalization Techniques for Privacy Preserving Data Mining. *International Journal of Engineering and Technology (IJET)*, 5(3), 2701-2704.
- Sayar, A. ve Ergün, U. (2014). Fonksiyonel Programlama Dilleri ile Paralel Programlama. *Niğde Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi*, 3(2), 1-17.
- Sezgin, E. ve Çelik, Y. (2013). Veri Madenciliğinde Kayıp Veriler İçin Kullanılan Yöntemlerin Karşılaştırılması. *Akademik Bilişim Konferansı, Akdeniz Üniversitesi*, 23-25.
- Skagestad, A. B. (2018). *Identifying Lagrangian Coherent Structures Using Clustering*. (Master's Thesis) Norwegian University of Science and Technology, Norwegian.
- Snelson, E., & Ghahramani, Z. (2007). Local and global sparse Gaussian process approximations. *In Artificial Intelligence and Statistics*, San Juan, Puerto Rico, 524-531. PMLR.
- Solak, E., Murray-Smith, R., Leithead, W. E., Leith, D., & Rasmussen, C. E. (2002). Derivative Observations in Gaussian Process Models of Dynamic Systems. *Advances in Neural Information Processing Systems*, 15
- Şahinler, S. (2000). En küçük kareler yöntemi ile doğrusal regresyon modeli oluşturmanın temel prensipleri. *Mustafa Kemal Üniversitesi Ziraat Fakültesi Dergisi*, 5(1-2), 57-73.

- Şapıcı, B. (2022). *Mimarlıkta Makine Öğrenimi Uygulamaları: Fırsatlar, Zorluklar ve Geleceğe Dair Öngörüler*. (Yüksek Lisans Tezi), Yükseköğretim Kurulu Ulusal Tez Merkezi'nden edinilmiştir. (Tez No. 752745)
- TEİAŞ (2022). *2022 yılı Elektrik Üretim ve Tüketim Raporları İstatistikleri*. <https://www.teias.gov.tr/aylik-elektrik-uretim-tuketim-raporlari> adresinden 30.03.2024 tarihinde edinilmiştir.
- Tekin, T. G. ve Patır, S. (2023). Amerikan Dolar Kurunun Yapay Sinir Ağları Yöntemiyle Tahminlenmesi: 2009–2021 Dönemi. *R&S-Research Studies Anatolia Journal*, 6(1), 56-77.
- Tokar, A.S., & Markus, M. (2000). Precipitation-Runoff Modeling Using Artificial Neural Networks and Conceptual Models. *Journal of Hydrologic Engineering*, 5(2), 156-161.
- Töman, U. ve Çimer, S. O. (2016). Enerji Kavramının Farklı Öğrenim Seviyelerinde Öğrenilme Durumunun Araştırılması. *Bayburt Eğitim Fakültesi Dergisi*, 6(1), 31-43.
- Tran, C., Abraham, A., & Jain, L. (2008). Soft Computing Paradigms and Regression Trees in Decision Support Systems. *In Intelligent information technologies: Concepts, methodologies, tools and applications*, 1011-1035. IGI Global.
- Tungut, H. B. (2021). Algoritma ve Programlama Mantığı. *Kodlab Yayın Dağıtım Yazılım LTD. ŞTİ.*, Vol. 108
- Uçak, K. (2012). *Destek Vektör Regresyonu ile Pıd Kontrolör Tasarımı*. (Yüksek Lisans Tezi), Yükseköğretim Kurulu Ulusal Tez Merkezi'nden edinilmiştir. (Tez No. 310564).
- Vupa Ö. ve Alma, Ö. G. (2008). Regresyon Analizinde Kullanılan En Küçük Kareler ve En Küçük Medyan Kareler Yöntemlerinin Karşılaştırılması. *Süleyman Demirel University Faculty of Arts and Science Journal of Science*, 3(2), 219-229.
- Yayla, G. (2021). Matlab. *Kodlab Yayın Dağıtım Yazılım ve Eğitim Hizmetleri San. Ve Tic. Ltd. Şti.*, İstanbul.
- Yılankırkan, N. ve Doğan, H. (2020) Türkiye'nin Enerji Görünümü ve 2023 Yılı Birincil Enerji Arz Projeksiyonu., *Batman Üniversitesi Yaşam Bilimleri Dergisi*. 10(2), 77-92.

- Yıldıran, A. ve Kandemir, S. Y. (2018). Yağış miktarının yapay sinir ağları ile tahmini. *Bilecik Şeyh Edebali Üniversitesi Fen Bilimleri Dergisi*, 5(2), 97-104.
- Yıldırım, M. (2021). *Bazı Veri Madenciliği Yöntemleri ile Elektrik Tüketim Tahmini*. (Yüksek Lisans Tezi), Yükseköğretim Kurulu Ulusal Tez Merkezi'nden edinilmiştir. (Tez No. 683657)
- Yılmaz, M. (2012). Türkiye'nin Enerji Potansiyeli ve Yenilenebilir Enerji Kaynaklarının Elektrik Enerjisi Üretimi Açısından Önemi. *Ankara Üniversitesi Çevre Bilimleri Dergisi*, Sayı 4 (2), 33-54.
- Yılmazel, Ö., Afşar, A. ve Yılmazel, S. (2018). Konut Fiyat Tahmininde Yapay Sinir Ağları Yönteminin Kullanılması. *Uluslararası İktisadi ve İdari İncelemeler Dergisi*, (20), 285-300.
- Yurttabir, A. ve Kıymetli Şen, İ. (2021). Finansal Performans Tahmininde Prophet Modeli: İmalat Sektörü Uygulaması. *Journal of Economics Finance and Accounting*, 8(4), 160-166.
- Yüce H. ve Özkan, A. O. (2021). Normalizasyon Yöntemlerinin Biyomedikal Verilerde Sınıflandırma Performansına Etkisi. *Avrupa Bilim ve Teknoloji Dergisi*, (30), 35-43.
- Wang, Y., Liu, J., & Han, Y. (2020) Production Capacity Prediction of Hydropower Industries For Energy Optimization: Evidence Based on Novel Extreme Learning Machine Integrating Monte Carlo. *Journal of Cleaner Production*, 272, 122824
- Word Energy Council Turkey. (2021). *2021 Yılı Küresel Enerji Raporu Özeti*. <https://dunyaenerji.org.tr/2021-kuresel-enerji-raporu/#:~:text=K%C3%BCresel%20enerji%20talebi%2C%202021'de,piyasalar%20ve%20geli%C5%9Fmekte%20olan%20ekonomilerdedir> adresinden 27.03.2024 tarihinde edinilmiştir.
- Zhu, X., & Goldberg, A. B. (2009). Introduction to semi-supervised learning. *Synthesis Lectures on Artificial Intelligence and Machine Learning*, 3 (1), 1-130.