



**MAKİNE ÖĞRENMESİ YÖNTEMLERİ İLE KISA SÜRELİ RÜZGÂR
ENERJİSİ TAHMİNİ**

Davut YENİLMEZ

**YÜKSEK LİSANS TEZİ
BİLGİSAYAR MÜHENDİSLİĞİ ANA BİLİM DALI**

**GAZİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

ARALIK 2023

ETİK BEYAN

Gazi Üniversitesi Fen Bilimleri Enstitüsü Tez Yazım Kurallarına uygun olarak hazırladığım bu tez çalışmasında;

- Tez içinde sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiğimi,
- Tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu,
- Tez çalışmasında yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi,
- Kullanılan verilerde herhangi bir değişiklik yapmadığımı,
- Bu tezde sunduğum çalışmanın özgün olduğunu,

bildirir, aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi beyan ederim.

Davut YENİLMEZ

28/12/2023

MAKİNE ÖĞRENMESİ YÖNTEMLERİ İLE KISA SÜRELİ RÜZGÂR ENERJİSİ TAHMİNİ

(Yüksek Lisans Tezi)

Davut YENİLMEZ

GAZİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Aralık 2023

ÖZET

Günümüz dünyasında nüfus artışı, gelişen teknoloji ve artan endüstriyel üretim temiz enerji kaynaklarından üretilen elektrik enerjisine olan talebi her geçen gün artırmaktadır. Ülkelerin ekonomik bağımsızlığının en temel göstergelerinden biri olan enerji bağımsızlığı artık ülkeler için bir ulusal güvenlik sorunu haline gelmiştir. Ayrıca en sürdürülebilir enerji kaynağı olan elektrik enerjisine yapılan yatırımlar tüm dünyada hızla artmaktadır. Elektrik enerjisi üretiminde artan talebe rağmen, elektrik üretiminde kullanılan fosil yakıtlı ürünlerin hava kirliliğine ve önlenemez iklim değişikliklerine neden olması nedeniyle tüm dünyada yenilenebilir temiz enerjiye olan talep hızla artmaktadır. Bu nedenle tüm dünyada yenilenebilir enerji kaynaklarından maksimum verim alabilmek için yenilenebilir enerji kaynakları ve elektrik üretim tahminleri üzerine birçok akademik çalışma yapılmaktadır. Bu çalışmada rüzgâr santrallerinde üretilen elektrik enerjisinin tahmini için literatürde en yüksek performansa sahip olan yapay zekâ modelleri yeni, gerçek ve güncel bir veri seti üzerinde uygulanarak yüksek başarıma sahip sonuçlar elde edilmiştir.

Bilim Kodu : 92432
Anahtar Kelimeler : Yapay zekâ, makine öğrenmesi teknikleri, yenilenebilir enerji, rüzgâr enerjisi
Sayfa Adedi : 81
Danışman : Dr. Öğr. Üyesi Öner BARUT

SHORT-TERM WIND ENERGY FORECASTING WITH MACHINE LEARNING
METHODS

(M. Sc. Thesis)

Davut YENİLMEZ

GAZİ UNIVERSITY

GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCES

December 2023

ABSTRACT

In today's world, population growth, developing technology and increasing industrial production increase the demand for electrical energy that can be produced from clean energy sources day by day. Energy independence, which is one of the most basic indicators of the economic independence of countries, has now become a national security problem for countries. In addition, investments in electrical energy, which is the most sustainable energy source, are increasing rapidly all over the world. Despite the increasing demand in electrical energy production, the demand for renewable clean energy is increasing rapidly all over the world due to the fact that fossil fuel products used in electricity production cause air pollution and unavoidable climate changes. For this reason, many academic studies are carried out on renewable energy sources and electricity production forecasting in order to get maximum efficiency from renewable energy sources all over the world. In this study, high performance results were obtained by applying artificial intelligence models, which have the highest performance in the literature, on a new, real and up-to-date data set for the forecasting of electrical energy produced in wind power plants.

Science Code : 92432

Key Words : Artificial intelligence, machine learning techniques, renewable energy,
wind energy

Page Number : 81

Supervisor : Asst. Prof. Öner BARUT

TEŐEKKÜR

Yüksek lisans tez sürecinde, bilgi birikimi ile bana her türlü desteęi veren Dr. Öğr. Üyesi Öner BARUT'a, her bir öğrencisiyle bire bir ilgilenen ve her türlü desteęi veren Gazi Üniversitesi Bilgisayar Mühendislięi Anabilim Dalı'na ve Gazi Üniversitesi Fen Bilimleri Enstitüsü'ne, annem Özgül YENİLMEZ'e teşekkür ederim.

İÇİNDEKİLER

	Sayfa
ÖZET	iv
ABSTRACT.....	v
TEŞEKKÜR.....	vi
İÇİNDEKİLER	vii
ÇİZELGELERİN LİSTESİ.....	ix
ŞEKİLLERİN LİSTESİ.....	x
SİMGELER VE KISALTMALAR.....	xiii
1. GİRİŞ.....	1
2. ALAN BİLGİSİ.....	5
2.1. Dünyada Elektrik Enerjisi	5
2.1.1. Dünyada yenilenebilir enerji kaynaklarına dayalı elektrik enerjisi üretimi	11
2.2. Türkiye’de Elektrik Enerjisi.....	14
2.2.1. Türkiye’de yenilenebilir enerji kaynaklarına dayalı elektrik enerjisi üretimi	18
3. LİTERATÜR ÖZETİ	21
3.1. Kısa Süreli Rüzgâr Enerjisi Tahmini Problemlerinde Kullanılan Yapay Zekâ Teknikleri.....	21
3.1.1. Basit doğrusal regresyon (Simple linear regression).....	21
3.1.2. Çoklu doğrusal regresyon (Multiple lineer regression).....	22
3.1.3 Polinom regresyon (Polynomial regression)	23
3.1.4. Destek vektör regresyonu (Support vector regression)	24
3.1.5. Karar ağacı (Decision tree).....	25
3.1.6. Rassal orman (Random forest)	27
3.1.7. Yapay sinir ağları (Artificial neural network)	28
3.2. Literatürdeki Çalışmaların Özeti.....	33

	Sayfa
4. MATERYAL VE METOT	47
4.1. Makine Öğrenmesi Teknikleri ile Kısa Süreli Rüzgâr Enerjisi Tahmini.....	47
4.1.1. Veri seti.....	47
4.2. Yapay Sinir Ağları ile Kısa Süreli Rüzgâr Enerjisi Tahmini.....	50
4.2.1. Veri seti.....	51
5. DENEYLER VE SONUÇLARI.....	59
5.1. Makine Öğrenmesi Teknikleri ile Kısa Süreli Rüzgâr Enerjisi Tahmini.....	59
5.2. Yapay Sinir Ağları ile Kısa Süreli Rüzgâr Enerjisi Tahmini.....	61
6. SONUÇ VE ÖNERİLER	73
KAYNAKLAR	77
ÖZGEÇMİŞ	81

ÇİZELGELERİN LİSTESİ

Çizelge	Sayfa
Çizelge 4.1. Saatlik veri setinin istatistiksel özellikleri	48
Çizelge 4.2. Günlük veri setinin istatistiksel özellikleri	52
Çizelge 4.3. Normalizasyon yöntemleri.....	53
Çizelge 4.4. Toplama fonksiyonları.....	55
Çizelge 4.5. Transfer fonksiyonu.....	56
Çizelge 5.1. Performans metrikleri	59
Çizelge 5.2. Makine öğrenmesi algoritmalarının performansları	59
Çizelge 5.3. Üç günlük girdi verileri ile 1 günlük rüzgâr enerjisi üretim tahmini sonuçları	62
Çizelge 5.4. Yedi günlük girdi verileriyle 1 günlük rüzgâr enerjisi üretim tahmini sonuçları	64
Çizelge 5.5. On beş günlük girdi verileriyle 1 günlük rüzgâr enerjisi üretim tahmini sonuçları	66
Çizelge 5.6. ARIMA algoritmasında kullanılan parametreler	69
Çizelge 5.7. Algoritmaların tahmin performansı karşılaştırması.....	70

ŞEKİLLERİN LİSTESİ

Şekil	Sayfa
Şekil 2.1. Küresel elektrik tüketimi	5
Şekil 2.2. Sektörlere göre küresel elektrik tüketimi.....	6
Şekil 2.3. Küresel kişi başına tüketilen elektrik enerjisi	7
Şekil 2.4. Küresel elektrik üretiminin kaynaklara göre dağılımı	8
Şekil 2.5. Küresel elektrik üretimine dayalı CO2 emisyonu	10
Şekil 2.6. Küresel yenilenebilir enerji kaynaklarına göre elektrik üretimi	11
Şekil 2.7. Ülkelere göre yenilenebilir enerji kaynaklarına dayalı elektrik enerjisi üretimi	12
Şekil 2.8. Küresel yenilenebilir enerji kaynaklarının kurulu güce göre dağılımı	13
Şekil 2.9. Türkiye’de elektrik enerjisi tüketimi	14
Şekil 2.10. Türkiye’de elektrik enerjisi kurulu gücü	15
Şekil 2.11. Birincil enerji kaynaklarına göre Türkiye’nin elektrik üretimi kurulu gücü	16
Şekil 2.12. Türkiye’de elektrik üretimine dayalı CO2 emisyonu	17
Şekil 2.13. Türkiye’nin yenilenebilir enerji kaynaklarına göre elektrik üretimi	18
Şekil 2.14. Türkiye’de yenilenebilir enerji kaynaklarının kurulu güce göre dağılımı....	19
Şekil 3.1. Basit doğrusal regresyon.....	22
Şekil 3.2. Polinom regresyon	24
Şekil 3.3. Destek vektör regresyon	25
Şekil 3.4. Karar ağacı.....	26
Şekil 3.5. Rassal orman.....	27
Şekil 3.6. Yapay sinir ağı modeli.....	28
Şekil 3.7. Yapay sinir ağlarının (YSA) Sınıflandırılması	30
Şekil 3.8. Denetimli öğrenme yapısı.....	32
Şekil 3.9. Denetimsiz öğrenme yapısı.....	32
Şekil 3.10. Takviyeli öğrenme	33

Şekil	Sayfa
Şekil 3.11. Rüzgâr enerjisi tahmini yöntemleri	34
Şekil 3.12. Rüzgâr hızı / enerjisi tahmin sınıflandırılması	35
Şekil 3.13. Zaman skalasına göre rüzgâr enerjisi tahmini sınıflandırması	36
Şekil 3.14. 2020 yılında Web of Science’da yayınlanan çalışmalarda rüzgâr ve güneş enerjisi tahmin yöntemlerinde derin öğrenme metotlarının yapılarına göre kullanılma oranları	37
Şekil 3.15. Derin öğrenme temelli güneş ve rüzgâr enerjisi tahmini taksonomisi	38
Şekil 3.16. Rüzgâr enerjisi tahmini için çok amaçlı optimizasyon teknikleri	39
Şekil 4.1. Ardıçlı RES’e Önceden işlenmiş verilerin çizgi grafiği (x eksenini veri adedini; y eksenini normalizasyon aralığını göstermektedir).....	48
Şekil 4.2. Önerilen modelin akış şeması.....	49
Şekil 4.3. Önerilen çalışmanın ana yapısı.....	51
Şekil 4.4. Saatlik enerji üretim verilerinin günlük enerji üretim verilerine dönüşüm yapısı (MWh olarak).....	52
Şekil 4.5. Yahyalı RES’e ait önceden işlenmiş verilerin çizgi grafiği.....	54
Şekil 4.6. Nöron temel yapısı.....	55
Şekil 4.7. Transfer Fonksiyonlarının fonksiyon grafikleri a) Lineer Fonksiyon b) Step Fonksiyon c) Sigmoid Fonksiyon d)Eşik değeri Fonksiyon e) Hiperbolik Tanjant Fonksiyon	57
Şekil 5.1. Makine öğrenmesi algoritmalarının performansları a) RMSE, b) MSE, c) R^2	60
Şekil 5.2. Üç günlük girdi verileriyle 1 günlük rüzgâr enerjisi üretim sonuçlarının çubuk grafikleri: a) MSE (Eğitim) performansı, b) RMSE (Eğitim) performansı, c) R^2 (Eğitim) performansı, d) MSE (Test) performansı, e) RMSE (Test) performansı ve f) R^2 (Test) performansı.	63
Şekil 5.3. Yedi günlük girdi verileriyle 1 günlük rüzgâr enerjisi üretim sonuçlarının çubuk grafikleri: a) MSE (Eğitim) performansı, b) RMSE (Eğitim) performansı, c) R^2 (Eğitim) performansı, d) MSE (Test) performansı, e) RMSE (Test) performansı ve f) R^2 (Test) performansı.	65
Şekil 5.4. On beş günlük girdi verileriyle 1 günlük rüzgâr enerjisi üretim sonuçlarının çubuk grafikleri: a) MSE (Eğitim) performansı, b) RMSE (Eğitim) performansı, c) R^2 (Eğitim) performansı, d) MSE (Test) performansı, e) RMSE (Test) performansı ve f) R^2 (Test) performansı.	67

Şekil**Sayfa**

Şekil 5.5. a) MSE, b) RMSE, c) R^2 metriklerine göre algoritmaların tahmin performansının çubuk grafikleri	71
--	----

SİMGELER VE KISALTMALAR

Bu çalışmada kullanılmış simgeler ve kısaltmalar, açıklamaları ile birlikte aşağıda sunulmuştur.

Simgeler

Açıklamalar

MW	Megawatt
MWh	Megawattsaat
TJ	Terajoule
TWh	Terajoulesaat

Kısaltmalar

Açıklamalar

ADF	Augmented Dickey Fuller
AE	Autoencoder
ANN	Artificial Neural Network
ARIMA	Autoregressive Integrated Moving Average
BiGRU	Bayesian framework-based bidirectional gated logic unit
BR	Bayesian Regularization
CNN	Convolutional Neural Network
COP	Conference of the Parties
ED LSTM	Encoder Decoder Long Short-Term Memory
ELM	Extreme Learning Machine
EMD	Empirical Mode Decomposition
FFANN	Feed Forward Artificial Neural Network
HNN	Hermite Neural Network
IOWA	Induced Ordered Weighted Average
LM	Levenberg – Marquardt
LR	Linear Regression
LSTM	Long Short Time Memory
MAE	Mean Absolute Error
MLP	Multilayer Perception
mRMR	Minimum Redundancy Maximum Relevance

Kısaltmalar**Açıklamalar**

MSE	Mean Squared Error
NMAE	Normalized Mean Absolute Error
NMSE	Normalized Mean Squared Error
NREL	National Renewable Energy Laboratory
NRMSE	Normalized Root Mean Squared Error
NSGA- II	Non-dominated Sorting Genetic Algorithm II
NWF	Numeric Weather Forecasting
PDF	Probabilistic Distribution Function
PM	Persistence Model
PR	Polynomial Regression
QISTA	Quadratic Interpolation
R²	Decisive Coefficient
RBF	Radial Basis Function
RF	Random Forest
RFR	Random Forest Regression
RMSE	Root Mean Squared Error
RNN	Recursive Neural Network
SCG	Scaled Conjugate Gradient
sdt	Standart
SRNN	Stacked Recurrent Neural Network
SVM	Support Vector Machine
SVR	Support Vector Regression
VAR	Vector Autoregressive
WRF	Weather Research Forecasting
YSA	Yapay Sinir Ağları

1. GİRİŞ

Dünyadaki nüfus oranı ve bu nüfusun görece refah düzeyi hızla artmaktadır. Buna paralel olarak, küresel elektrik enerjisi talebi de artış eğilimi göstermektedir. Bu talebi karşılamak için üretilen elektrik enerjisi kaynaklarına göre incelendiğinde fosil yakıtlara dayalı elektrik üretimi oranı ilk sıralarda yer almaktadır [1]. Bu durum sera gazı emisyonlarında çok büyük artışa neden olmaktadır. Sera gazı emisyonlarının artmasıyla birlikte küresel ölçekte önlenemez iklim değişiklikleri ve doğal afetler meydana gelmektedir. Küresel ısınmaya bağlı olarak beslenme ve su temini güvenliği ülkeler için en önemli sorun haline gelmektedir.

Türkiye'de de nüfus artış trendi sürmektedir. Bu artışın bir sonucu olarak da elektrik enerjisine olan ihtiyaç giderek artmaktadır. Bu talebi karşılamak için ülkemizde fosil yakıtlara dayalı elektrik üretimi halen yüksek seviyelerdedir [1]. Bu durum çevre kirliliğine, küresel ısınmaya, iklim değişiklikleri, kuraklık ve doğal afetler gibi kaçınılmaz sonuçlara neden olan sera gazı emisyonlarını artırmaktadır. Türkiye Cumhuriyeti Ticaret Bakanlığı tarafından 2021 yılında yayınlanan dış ticaret verilerine göre fosil yakıtlı ürünler en çok ithal edilen ürünler arasında yer almaktadır [2]. Bu durum, elektrik üretiminin dengelenmesi için doğru tahmin ve planlamayı gerektiren ülkemizin dış ticaret açığının [3] en büyük nedeni olarak karşımıza çıkmaktadır.

Türkiye'de elektrik üretim tahminleri halen makro düzeyde ve istatistiksel yöntemler veya çalışanların tecrübelerinden kaynaklı tahminler gibi klasik yöntemlerle planlanmaktadır. Bu durum santrallerin hem kestirimci bakım ve planlı bakım maliyetlerini artırmakta hem de insan kaynakları planlamasını, kaynakların verimli kullanımını ve enerji yönetim sistemini olumsuz etkilemektedir. Ülkemizde mikro ölçekte yapay zekâ tabanlı bir enerji yönetim sisteminin uygulanmaması, yenilenebilir enerji kaynaklarından üretilen enerji üretiminin optimize edilememesi sorununu oluşturmaktadır. Bu sorun, sanayi ve tarım sektörlerinin en büyük girdi maliyetlerinden biri olan elektrik enerjisinin pahalı üretimine neden olmaktadır. Elektrik enerjisinin artan maliyeti ülkemizin küresel ticari rekabetini olumsuz etkilemektedir. Ayrıca elektrik üretim maliyetinin yüksek olması elektrik enerjisinin kaybını ve kaçak kullanımını artırmaktadır.

Aynı zamanda fosil yakıtların ithal edildiği ülkelerde arz sıkıntısı yaşandığında ülkemizin ulusal elektrik enerjisi arz güvenliği de zor duruma düşmektedir. Türkiye'de enterkonekte

elektrik iletim hatlarında frekansın fosil yakıtı dayalı santraller tarafından belirlendiđi bilinmektedir. Bu santrallerde meydana gelebilecek arızalarda veya fosil yakıtların temininde yaşanan sorunlarda lke genelinde elektrik enerjisi frekansında dalgalanmalara neden olacaktır. Bu durum lkenin tm elektrik enerjisi iletim hattının kullanılamaz hale gelmesine neden olabilir.

Dnyada fosil yakıtı dayalı elektrik retiminin maliyetindeki hızlı artış, kresel lekte lkelerin yenilenebilir elektrik retimine ynelik yatırımlarını artırmaktadır. ođu lke hem mevcut ekonomik dengelerini korumak hem de kresel ticarete rekabet edebilmek iin en byk girdi maliyetlerinden biri olan elektrik enerjisi retim planlamalarını yenilenebilir enerji kaynaklarına yneltmektedir [4].

Ayrıca bu lkeler, Paris Anlařması'na taraf devletlerin anlařma kapsamında beyan ettikleri Ulusal Amalanan Katkı Beyanlarını da Birleřmiř Milletlere sunmuřlardır. Paris Anlařması, kresel ısınmayı 2 santigrat derecenin altında sınırlamayı amalayan, yasal olarak bađlayıcı bir uluslararası iklim deđiřikliđi anlařmasıdır ve 12 Aralık 2015'te Paris'te dzenlenen COP (Conference of the Parties) 21'de 196 Taraf tarafından kabul edilmiř ve 4 Kasım 2016'da yrrlđe girmiřtir [5]. Bu beyannameler kapsamında taraf lkeler sera gazı emisyonlarını azaltacak taahhtlerde bulunmuřlardır. Bu taahhtlerini yerine getirmek iin elektrik enerjisi retim portfylerini hızla yenilenebilir elektrik enerjisi kaynaklarına ynlendirmektedir. Yenilenebilir enerji teknolojilerine yapılan yatırımlar ve kresel lekte yapılan arařtırma geliřtirme alıřmaları ile yenilenebilir enerji yatırım maliyetleri dřř trendine girmiřtir. Ayrıca Paris Anlařması sonucunda dnyada yenilenebilir enerji kurulu gc en yksek on lke ulusal yenilenebilir enerji stratejilerini uygulamaya bařlamıřtır.

Kresel geliřmelere paralel olarak lkemiz de fosil yakıtı dayalı elektrik retim modelinden hızla uzaklařmaktadır. Elektrik retiminde yenilenebilir enerji kaynaklarının oranı her geen gn artmaktadır. lkemizin dıř ticaretinde en byk cari aık kalemi olan fosil yakıtların byk blm elektrik retiminde kullanılmaktadır. Trkiye ekonomisinde cari aıđa neden olan bu durumu hızlı bir řekilde avantaja evirebilmek iin lkemiz, yenilenebilir enerji kaynaklarından maksimum verim alabilmek iin birok stratejik planı devreye sokmaktadır [6].

Günümüzde elektrik enerjisi üretiminde yenilenebilir enerji kaynaklarından daha fazla faydalanmak için elektrik enerjisi yönetimi ve planlaması en önemli unsurlardan biri haline gelmiştir. Bu planlardan maksimum verim alınabilmesi için yenilenebilir enerji kaynakları ile elektrik üreten santrallerin enerji üretim tahminleri klasik yöntemlerin dışında yüksek doğrulukta sonuç veren yapay zekâ tabanlı modellerle yapılmaya başlanmıştır.

Rüzgâr enerjisi sadece ülkemiz için değil tüm dünya için en önemli yenilenebilir temiz enerji kaynaklarından biridir. Türkiye'de yenilenebilir enerji kaynaklarına dayalı elektrik üretiminde rüzgâr enerjisi %20,4 ile 2. sırada yer alırken, küresel yenilenebilir enerji kaynaklarına dayalı elektrik üretiminde rüzgâr enerjisi %25,7 ile 3. sırada yer almaktadır [7]. Ancak rüzgâr enerjisinin kararsız yapısı nedeniyle bu kaynaktan üretilebilecek elektrik enerjisini tahmin etmek oldukça zordur. Bununla birlikte, elektrik enerjisi üretimi için diğer tüm yenilenebilir enerji kaynakları gibi rüzgâr enerjisinden de en üst düzeyde yararlanılmalıdır.


Bu çalışmada rüzgâr santrallerinde üretilen elektrik enerjisinin tahmini için literatürde en yüksek performansa sahip olan yapay sinir ağları yaklaşımı gerçek, yeni, güncel ve daha önce literatürde yer almayan veri seti üzerinde uygulanarak literatüre yeni bir katkı sağlanmıştır. Bu çalışma sayesinde elektrik enerjisi üretiminde yenilenebilir enerji kaynaklarından maksimum fayda sağlanabilmektedir. Ayrıca fosil yakıtlı ürünlere dayalı elektrik üretim oranı düşürülerek, fosil yakıtlı ürünlerden kaynaklanan iklim değişikliği ve çevre kirliliğinin önüne geçilebilir. Böylece iklim değişikliğinin neden olduğu büyük doğal afetler ve önlenemez zararlar kontrol altına alınabilir.

Tüm bunlara ek olarak elektrik enerjisi üretimini klasik yöntemlerle makro düzeyde planlamak yerine, her santrale özel mikro düzeyde yapay zekâ tabanlı üretim tahmin modelleri kullanılarak yenilenebilir enerji kaynakları ile elektrik üretimi maksimize edilerek enerji arz güvenliği en verimli şekilde gerçekleştirilebilir. Böylelikle sanayi ve tarım sektörünün en büyük girdi maliyetlerinden biri olan elektrik enerjisinin üretim maliyetleri kontrol altına alınabilmektedir.

2. ALAN BİLGİSİ


2.1. Dünyada Elektrik Enerjisi

Elektrik enerjisinin keşfiyle elektrik enerjisinin kullanımı hızla yaygınlaşmıştır. Elektrik enerjisinin pratik, temiz ve kullanılabilirliğinin yüksek olması gibi özelliklerinden dolayı bu enerji kaynağının kullanımının yaygınlaşmasının temel unsurları olarak karşımıza çıkmaktadır. Dünyada nüfusun hızla artması birçok sorunu da beraberinde getirmiştir. Nüfus artışına dayalı olarak insanların barınma, beslenme ve istihdam problemleri de artmıştır. İnsanların barınması için gereken konut talebine cevap vermek adına inşaat sektörünün gelişiminin ana unsurlarından biri elektrik enerjisiyle çalışan iş makineleri ve araç gereçlerin kullanımı yaygınlaşmıştır. Bunun yanında artan nüfusun beslenme ihtiyacını karşılamak adına bireysel yapılan tarım ve hayvancılık hızla endüstrileşerek bu sektörde faaliyet gösteren fabrikalar hızla artmıştır. Bununla birlikte tarım toplumundan sanayi toplumuna geçişte insan gücüyle yapılan birçok iş makineleştiği için dünya çapında işsizlik artmıştır. Bu işsizliği önlemek adına daha fazla fabrika faaliyete geçirilmiş bu da dünyanın elektrik enerjisine olan ihtiyacını hızla arttırmıştır. Dünyada elektrik enerjisi tüketimi Şekil 2.1.'de görüldüğü gibidir.



Şekil 2.1. Küresel elektrik tüketimi [1]


Şekil 2.1.'de görüldüğü gibi 1990 yılında 10.000 TWh olan elektrik enerjisi tüketimi hızla artarak 2020 yılında 25.000 TWh seviyelerine ulaşmıştır. Elektrik enerjisi tüketimi 30 yıl boyunca doğrusal olarak artmış olup halen de artma eğilimine devam etmektedir. Elektrik enerjisine olan talep küresel olarak toplumun refah seviyesinin artmasıyla doğru orantılı bir şekilde artmıştır. Elektrik enerjisi tüketiminin sektörlere göre dağılımı Şekil 2.2.'de gösterildiği gibidir.



Şekil 2.2. Sektörlere göre küresel elektrik tüketimi [1]

Şekil 2.2.'de görüldüğü üzere 1990 yılından 2020 yılına kadar tüm sektörlerde elektrik tüketimi artış göstermiştir. Sektörlere göre elektrik tüketimi incelendiğinde elektrik tüketiminin en yüksek olduğu sektör endüstri sektörü olarak karşımıza çıkmaktadır. 1990 yılında 15.000.000 TJ seviyelerinde olan elektrik enerjisi tüketimi hızla artarak 2020 yılında 35.000.000 TJ seviyelerine yaklaşmıştır. Artan dünya nüfusunun ihtiyaçlarını karşılamak için insan gücüne dayalı üretimden hızla uzaklaşarak elektrik enerjisine dayalı fabrikaların hızla çoğalması endüstri sektörünün hızla büyümesini sağlamıştır. Üretimde sürekliliğin öneminin artması, tedarik zincirinin sağlıklı sürdürülmesi, küresel pazarın ihtiyaçlarına zamanında cevap verilmesi, üretim kalitesinin artırılması gerekliliği endüstri sektöründe


hızlı bir artışa sebep olmuştur. Küresel talebe dayalı artan fabrikaların temel girdi unsurlarından biri elektrik enerjisi olmuştur. Gelişen ve hızla büyüyen sanayinin elektrik enerjisine dayalı üretim yapısı endüstri sektörünün elektriğe olan ihtiyacını giderek arttırmıştır. Endüstri sektöründen sonra elektrik tüketiminin en fazla olduğu ikinci sektör konut sektörü olmuştur. 1990 yılında 10.000.000 TJ seviyelerinde olan elektrik enerjisi tüketimi 2020 yılında 25.000.000 TJ seviyelerine yaklaşmıştır. Artan dünya nüfusunun barınma ihtiyacını karşılamak için gerçekleştirilen inşaat faaliyetleri sonucu konut sayısı hızla artmıştır. Ayrıca teknolojinin gelişmesiyle konutların içerisindeki elektrikli ev aletlerinin sayısı da her geçen gün artmaya devam etmektedir. Bunun sonucuna konutların elektrik tüketimi de artış eğilimini devam ettirmektedir. Elektrik tüketiminde konut sektörünü takip eden sektör ticari ve kamusal hizmetler sektörüdür. 1990 yılında 5.000.000 TJ seviyesinin üzerinde olan elektrik enerjisi tüketimi 2020 yılında 15.000.000 TJ seviyelerine kadar çıkmıştır. Bu sektördeki elektrik tüketimindeki artışın başlıca sebepleri arasında artan refah seviyesi ve teknoloji ile gelişen hizmet sektörü yatırımları gösterilebilir. Elektrik tüketiminde balıkçılık ve tarım sektörlerinde sınırlı bir oranda artış meydana gelmiştir. Bu sektörlerde kullanılan makinelerin ve sistemlerin birçoğu fosil yakıtlara dayalı çalıştığı için elektrik tüketimi sınırlı oranda artış göstermiştir.



Şekil 2.3. Küresel kişi başına tüketilen elektrik enerjisi [1]

Küresel elektrik tüketiminde kişi başına olan elektrik tüketiminde de büyük bir artış görülmektedir. Şekil 2.3.'te görüldüğü gibi 1990 yılında 2 MWh olan kişi başı elektrik tüketimi 2020 yılında 3 MWh seviyelerine yükselmiştir. Küresel olarak insanların refah seviyelerindeki artış ve teknolojinin gelişimine bağlı olarak elektrik elektronik ürünlerin kullanımının yaygınlaşması kişi başı elektrik tüketiminin artmasında büyük bir rol oynamaktadır.

Hızla artan bu elektrik tüketimini karşılamak adına dünyada elektrik üretimi de hızla artmıştır. Dünya genelinde elektrik enerjisi üretimi stratejik bir alan olarak görülmektedir. Birçok sektörde ana girdi kalemlerinden biri olan elektrik enerjisinin üretim maliyetleri ülkelerin ticari rekabetinde büyük bir öneme sahip hale gelmiştir. Küresel elektrik üretiminin kaynaklara göre dağılımı Şekil 2.4.'te gösterildiği gibidir.

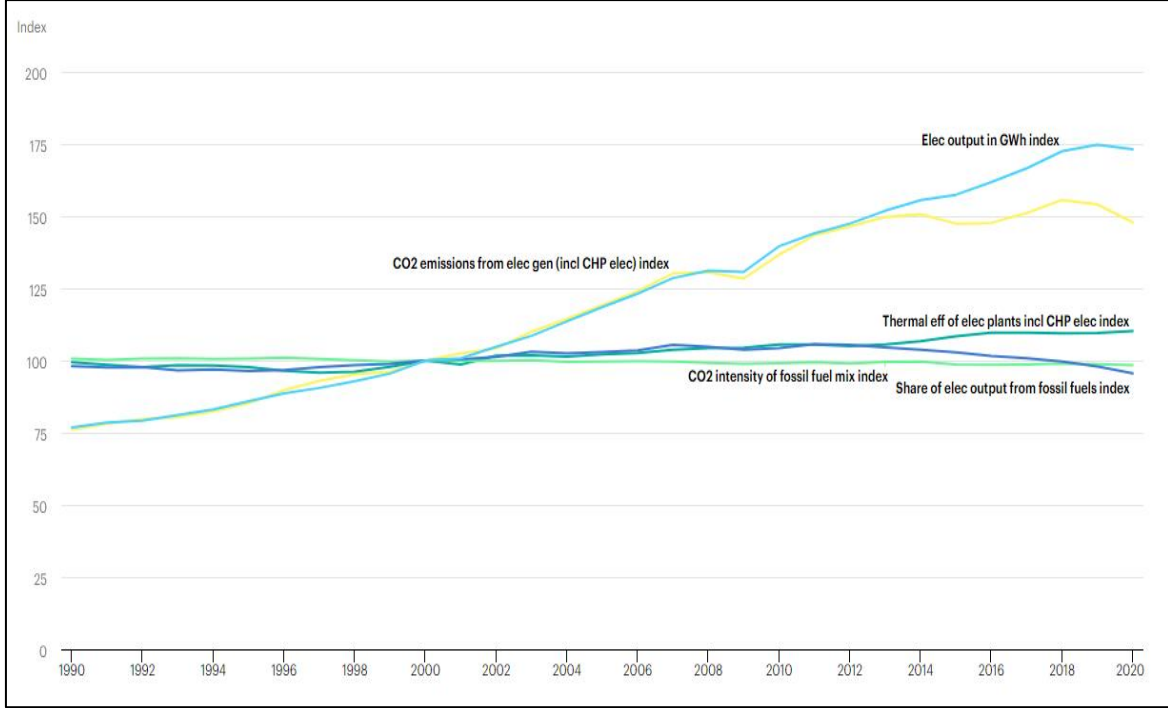


Şekil 2.4. Küresel elektrik üretiminin kaynaklara göre dağılımı [1]

Şekil 2.4.'te görüldüğü üzere küresel elektrik üretiminde en çok kullanılan kaynak kömür olarak karşımıza çıkmaktadır. 1990 yılında kömüre dayalı üretilen elektrik üretimi 4.000.000 GWh seviyelerindeyken 2020 yılında bu değer 10.000.000 GWh seviyelerine çıkmıştır. Artan nüfusun elektrik enerjisine olan talebini karşılamak adına kömüre dayalı elektrik üretimi de hızla artış göstermiştir. Doğalgaza dayalı elektrik üretimi, kömürden sonra en çok

kullanılan ikinci enerji kaynağı olarak karşımıza çıkmaktadır. 1990 yılında doğalgaza dayalı elektrik enerjisi üretimi 2.000.000 GWh seviyelerindeyken 2020 yılında 6.000.000 GWh seviyelerine çıkmıştır. Kaynaklara göre elektrik üretiminde hidroelektrik santrallerinde üretilen elektrik enerjisi üçüncü sırada yer almaktadır. 1990 yılında 2.000.000 GWh seviyelerinde olan Hidroelektrik santrallerinden üretilen elektrik enerjisi 2020 yılında 4.000.000 GWh seviyelerinde çıkmıştır. Nükleer kaynaklar dördüncü elektrik enerji kaynağı olarak karşımıza çıkmaktadır. Nükleer kaynaklardan elektrik enerjisi üretimi 1990 yılında 2.000.000 GWh seviyelerindeyken 2006 yılına kadar artış göstermiş bu yıldan sonra hafif azalma eğilimi göstermekle beraber 2020 yılında yine 2.000.000 GWh seviyelerinde bulunmaktadır. Nükleer kaynaklardan elektrik üretiminin artış göstermemesinin ana nedenleri arasında nükleer santrallerinin işletme ve bakım onarımı sırasında gerçekleştirilecek güvenlik endişeleri ve radyoaktif maddelerin artıklarının güvenli bir şekilde depolanma sorununun olmasıdır. Kaynaklara dayalı elektrik üretiminde beşinci sırada rüzgâr enerjisinden üretilen elektrik üretimi gelmektedir. Rüzgâr enerjisinden üretilen elektrik enerjisi 1990 yılından 2006 yılına kadar yok denilecek kadar az olmasına rağmen 2006 yılından sonra hızla artarak 2.000.000 GWh seviyelerine kadar çıkmıştır. Gelişen teknoloji ile yenilenebilir enerji kaynaklarından elektrik üretimi için üzerinde çalışılan ürünlerle birlikte rüzgâr enerjisinden elektrik üretimi için gerekli üretim altyapısı hızla tamamlanmıştır. Bu sayede yenilenebilir enerji kaynaklarına dayalı elektrik enerjisi üretim santrallerinin yatırım ve işletme maliyetleri hızla düşerek bu santrallerinin yaygınlaşması artmıştır. Rüzgâr enerjisine dayalı elektrik üretim santralleri yatırımlarının hızla artması sonucu bu enerji kaynağına dayalı elektrik üretimi hızla artmıştır. Rüzgâr enerjisinin en önemli yenilenebilir enerji kaynaklarından biri olarak çevre kirliliğinin ve iklim değişikliğinin önüne geçmesi rüzgâr enerjisi santrallerinin yatırımlarını hızla arttırmaktadır. Güneş enerjisine dayalı elektrik üretimi küresel ölçekte rüzgâr enerjisi ile elektrik üretiminden sonra en çok tercih edilen altıncı enerji kaynağı olarak görülmektedir. Güneş enerjisine dayalı elektrik üretimi için geliştirilen teknolojiler sayesinde güneş enerjisine dayalı elektrik üretimi santralleri yatırımları hızla artmaktadır. İleri teknolojik yöntemlerin kullanılması ile güneş enerjisi ile elektrik üretiminin yatırım ve işletme maliyetleri hızla gerilemektedir. Güneş enerjisinin sınırsız ve sürekli enerji kaynağı olması ve bu enerji kaynağına dayalı elektrik üretim santrallerinin kurulumunun görece kolay olması güneş enerjisine dayalı elektrik üretim santrallerinin hızla yaygınlaşmasını sağlamıştır.

Şekil 2.4'te görüldüğü üzere kaynaklara bağlı küresel elektrik üretiminde kömüre dayalı elektrik üretiminin hızla arttığı görülmektedir. Fosil bir yakıt olan kömürün elektrik enerjisi üretiminde halen birinci enerji kaynağı olarak kullanılması CO₂ emisyonuna neden olmaktadır. Küresel elektrik üretimine bağlı CO₂ emisyonu oranı Şekil 2.5.'te görüldüğü gibidir.




Şekil 2.5. Küresel elektrik üretimine dayalı CO₂ emisyonu [1]

Şekil 2.5.'te görüldüğü gibi elektrik üretimine bağlı CO₂ emisyonu hızla artmaktadır. Elektrik üretiminin fosil yakıtlara dayalı olması CO₂ emisyonunun hızla artmasına neden olmaktadır. CO₂ emisyonunun artışı ile çevre kirliliği, iklim değişikliği ve doğal afetler gibi olumsuzlukların arttığı görülmektedir. Elektrik enerjisi üretiminin neden olduğu CO₂ emisyonunun sebep olduğu iklim değişikliği kuraklığa neden olmaktadır. Bu kuraklık tarım ürünlerinin gelişimini olumsuz yönde etkileyerek küresel gıda arzını tehlikeye sokmaktadır. Azalan tarım ürünleri emtia fiyatlarını arttırarak küresel çapta enflasyona neden olmaktadır. Bunun yanında oluşan iklim değişikliğine dayalı yağışların azalması ve küresel ısınma nedeniyle hidroelektrik enerji santrallerinin verimi ciddi oranda azalma tehlikesiyle karşı karşıya kalmaktadır. Bu da elektrik enerjisinin daha fazla fosil yakıtlara dayalı üretilmesine neden olmaktadır.

2.1.1. Dünyada yenilenebilir enerji kaynaklarına dayalı elektrik enerjisi üretimi

Elektrik enerjisi küresel ekonomide rekabet gücünü etkileyen en önemli bir unsur haline gelmiştir. Ülkelerin kalkınma stratejilerinin tamamında yenilenebilir enerji kaynaklarına dayalı elektrik üretimi yer almaya başlamıştır. Yenilenebilir enerji kaynakları ile elektrik üretimi ülkelerin refah seviyelerini ve ekonomik üretkenliğini sürdürülebilir olması için temel bir hedef olarak tüm dünya ülkelerinin kalkınma planlarında yer almaya devam etmektedir. Bu eğilim yenilenebilir enerji kaynaklarına dayalı elektrik üretimini yıllara bağlı hızla artmasını sağlamıştır. Şekil 2.6'da küresel yenilenebilir enerji kaynaklarına göre elektrik üretimi görülmektedir.




Şekil 2.6. Küresel yenilenebilir enerji kaynaklarına göre elektrik üretimi [1]

Şekil 2.6'da görüldüğü gibi küresel yenilenebilir enerji kaynaklarına göre elektrik üretiminde birinci sırada hidroelektrik enerji santralleri yer almaktadır. 1990 yılında 2.000.000 GWh seviyelerinde olan üretim 2020 yılında 4.000.000 GWh seviyelerini aşmıştır. Hidroelektrik enerji santrallerini sırasıyla rüzgâr ve güneş enerjisi santralleri takip etmektedir. Rüzgâr enerjisine dayalı elektrik üretimi 1990 yıllarında hemen hemen hiç yokken 2020 yılında 2.000.000 GWh seviyelerine yaklaşmıştır. Güneş enerjisi ile elektrik üretimi rüzgâr enerjisinden sonra gelen en önemli yenilenebilir enerji kaynaklarından biridir.

1990 yılında bu kaynaktan üretilen elektrik enerjisi üretimi 2020 yılında güneş 1.000.000 GWh seviyelerine yaklaşmıştır. Gelişen mühendislik yöntemleri ve ileri teknolojilerin rüzgâr ve güneş enerjisinden elektrik üretimi için kullanılmaya başlandıktan sonra bu iki kaynaktan elektrik üretimi hızla artmıştır. Rüzgâr ve güneş enerjisinden sonra elektrik enerjisi üretimi için en çok kullanılan kaynak jeotermal enerji olmuştur. Bu enerji kaynağı kullanılarak kullanılan elektrik enerjisi çok sınırlı bir seviyede seyretmektedir. Jeotermal kaynakların sınırlı olması ve bu enerji kaynağının genelde tarım ve sağlık turizmi için kullanımı dolayısıyla bu kaynaktan üretilen elektrik enerjisi sınırlı kalmıştır.

Küresel elektrik enerjisi talebini karşılamak için dünya ülkeleri yenilenebilir enerji kaynaklarına hızla yatırım yapmaktadır. Şekil 2.7’de ülke bazında yenilenebilir enerji kaynaklarına dayalı elektrik enerjisi üretimi görülmektedir.

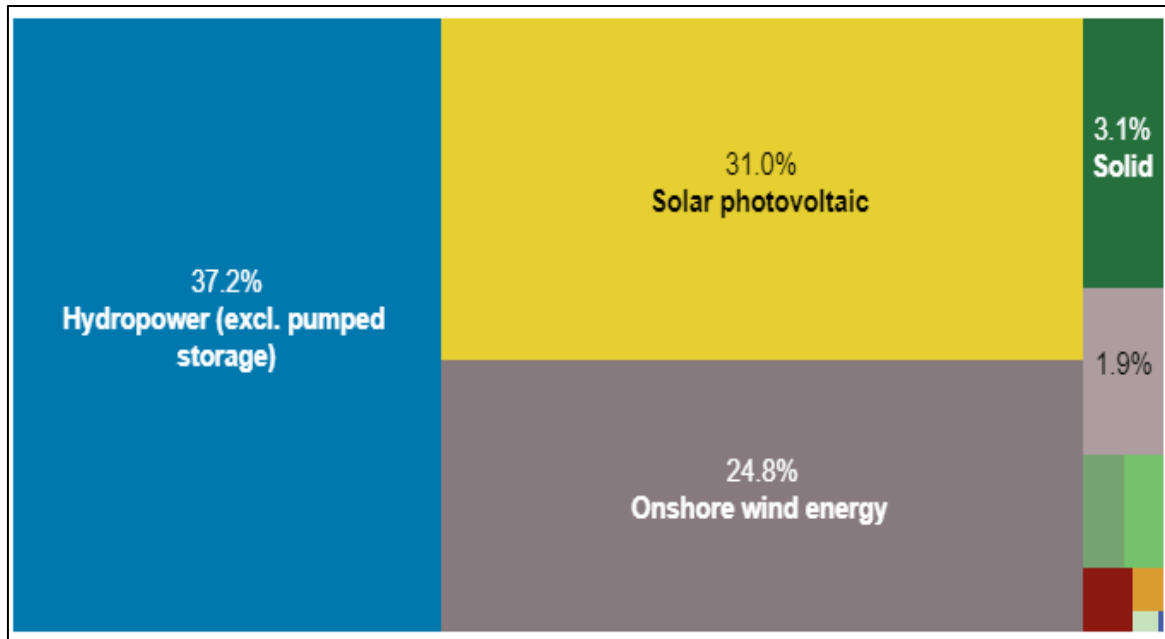


Şekil 2.7. Ükelere göre yenilenebilir enerji kaynaklarına dayalı elektrik enerjisi üretimi [9]

Şekil 2.7.’de görüldüğü üzere yenilenebilir enerji kaynaklarına dayalı elektrik enerjisi üretiminde birinci sırada Çin yer almaktadır. Çin ülkede artan nüfus artışı ve gelişen endüstri sektörünün elektrik enerjisi talebini karşılamak amacıyla temiz, ekonomik ve sürdürülebilir

yenilenebilir enerji kaynaklarına yatırımlarına hız vermiştir. Bu yatırımlarla dünyada bu konuda lider ülke konumuna ulaşmıştır. Amerika Birleşik Devletleri yenilenebilir enerji kaynaklarına dayalı elektrik enerjisi üretiminde Çin'den sonra gelen ülke olmuştur. Amerika Birleşik Devletleri yenilenebilir enerji kaynaklarından elektrik enerjisi üretimi konusunda AR-GE çalışmalarını ulusal çapta desteklemektedir. Bu destekler yenilenebilir enerji teknolojileri konusunda çalışan birçok girişimin ortaya çıkmasını sağlamıştır. Bunun yanında bu konuda kullanılan ileri mühendislik ve teknolojik yöntemler bu alanlarda yatırım ve işletme maliyetlerini düşürmüştür.

Yenilenebilir enerji kaynaklarına dayalı elektrik üretiminde Amerika Birleşik Devletleri'ni sırasıyla Brezilya, Hindistan, Almanya, Japonya, Kanada, İspanya, Fransa ve İtalya takip etmektedir. Yenilenebilir enerji kaynaklarına dayalı elektrik enerjisi üretiminde en zengin dünya ülkelerinin bu alanda yatırımları hızla artmaktadır. Şekil 2.8'de küresel yenilenebilir enerji kaynaklarının kurulu güce göre dağılımı görülmektedir.




Şekil 2.8. Küresel yenilenebilir enerji kaynaklarının kurulu güce göre dağılımı [9]

Şekil 2.8'de görüldüğü üzere yenilenebilir enerji kaynaklarının kurulu güce göre dağılımı incelendiğinde en yüksek kurulu güce sahip yenilenebilir enerji kaynağı olarak %37,2 oranında hidroelektrik santralleri yer almaktadır. Güneş enerjisi santralleri %31 oranıyla

ikinci yenilenebilir enerji kaynağı olmuştur. Bu enerji kaynaklarını %24,8 ile rüzgâr enerjisi santralleri izlemektedir.

2.2. Türkiye’de Elektrik Enerjisi

Artan nüfus ve gelişen teknoloji ile Türkiye’de elektrik tüketimi hızla artmıştır. Şekil 2.9’da görüldüğü gibi Türkiye’de elektrik enerjisi tüketimi hızla artmıştır

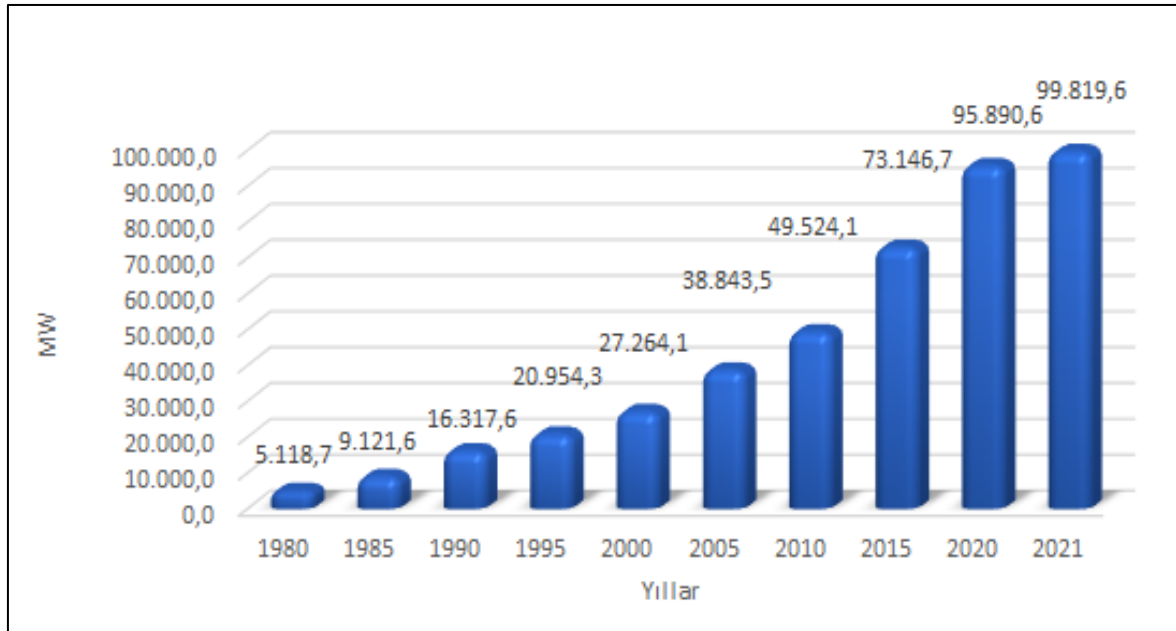


Şekil 2.9. Türkiye’de elektrik enerjisi tüketimi [1]

Elektrik tüketimi 1990 yılında 50 TWh değerinde olan elektrik enerjisi tüketimi 2020 yılında 300 TWh seviyesine çıkmıştır. Türkiye’de gerçekleşen nüfus artışı elektrik enerjisi tüketiminin artışına sebep olan başlıca nedenlerden biridir. Ayrıca nüfusun refah seviyesinin artması, gelişen endüstri ve ileri teknolojik ürünlerin toplumda hızla yaygınlaşması da Türkiye’de elektrik tüketiminin artmasına neden olan diğer unsurlardır.

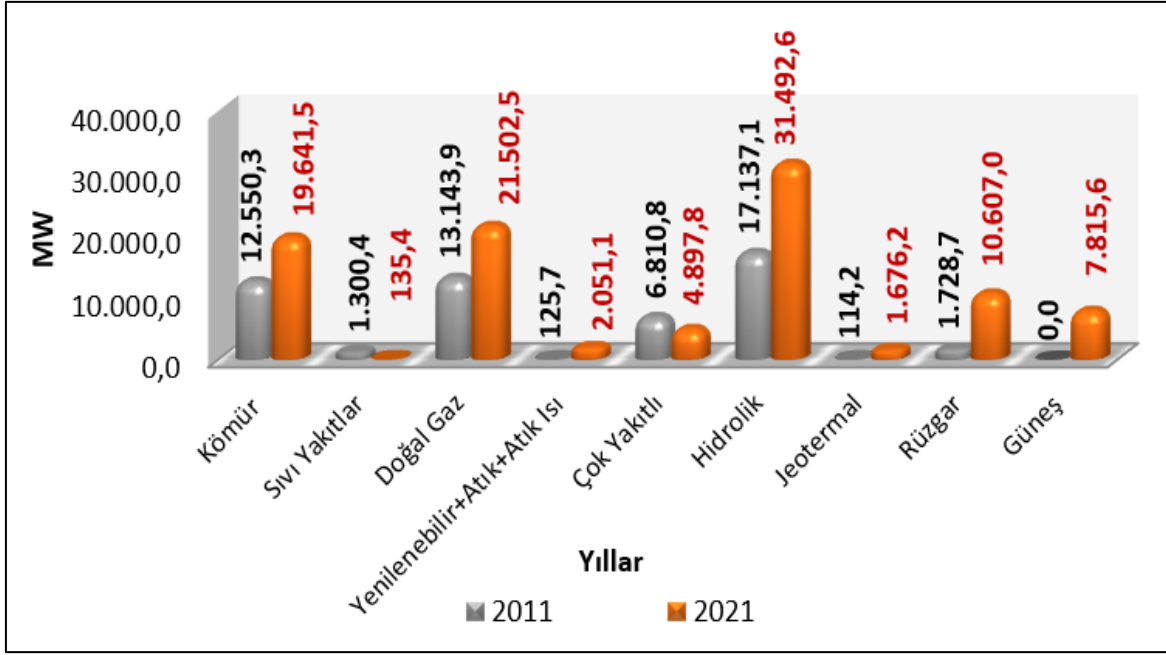
Türkiye’de artan elektrik tüketimi karşılamak için elektrik enerjisi üretimi de hızla artmıştır. Şekil 2.10’da görüldüğü gibi Türkiye’de artan elektrik tüketimini karşılamak için elektrik üretimi de hızla artmıştır. 1980 yılında 5.118,7 MW seviyelerinde olan elektrik üretimi kurulu gücü 2021 yılında 99.819,6 MW seviyelerine kadar çıkmıştır. Türkiye’nin elektrik

üretimi kurulu gücünün hızla artışının sebebi elektrik enerjisine olan talebin hızla artış göstermesidir. Türkiye’de nüfusun hızla artması toplumun beslenme ve barınma ihtiyaçlarının da hızla artmasına neden olmuştur. Bununla birlikte klasik yöntemlerle üretilen ürünlerin toplumun ihtiyaçlarını karşılayamaması üzerine endüstri sektörü hızlı bir şekilde gelişmiştir. Artan konut sayısı ve endüstri sektörünün elektrik enerjisine olan talebi giderek artmıştır. Bunun yanında artan refah seviyesi ile ilerleyen teknoloji sayesinde elektrik ve elektronik cihazların kullanımı da yaygınlaşmıştır. Bu gelişmeler elektrik tüketimini arttırmıştır. Artan elektrik tüketimini karşılamak için elektrik enerjisi üretimi de hızla artış eğilimine girmiştir.



Şekil 2.10. Türkiye’de elektrik enerjisi kurulu gücü [8]

Türkiye’de elektrik arz güvenliğini sağlamak adına birçok kaynaktan elektrik üretimi gerçekleştirmektedir. Şekil 2.11.’de birincil enerji kaynaklarına göre Türkiye’nin elektrik üretimi kurulu gücü görülmektedir.

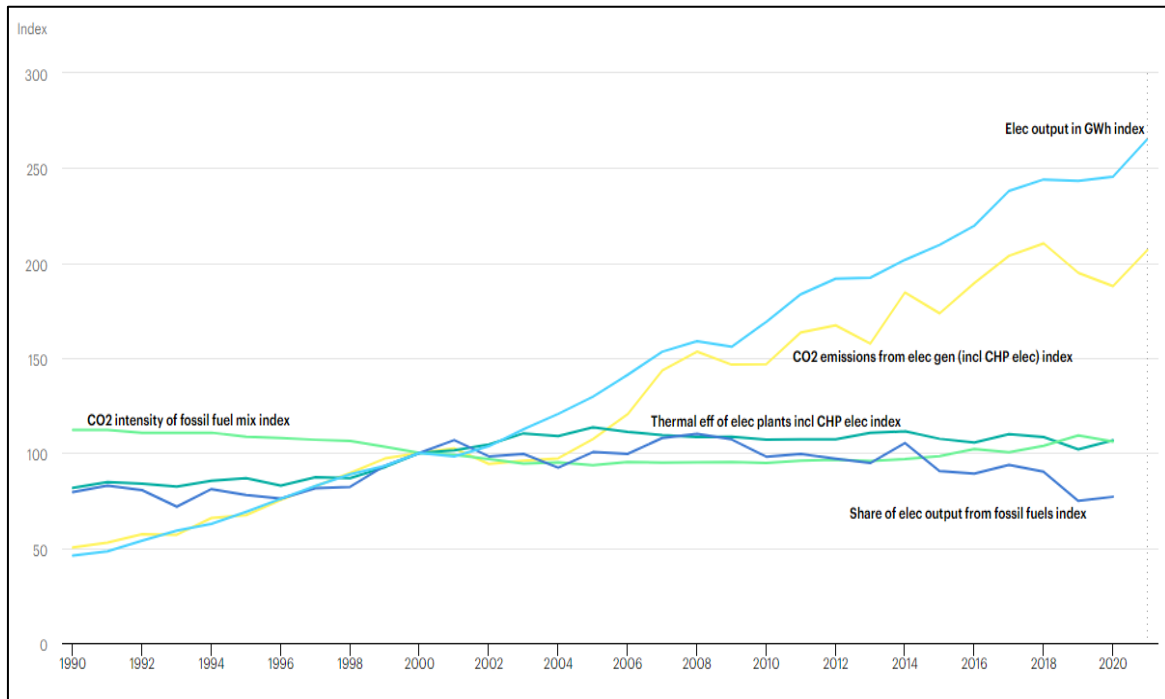


Şekil 2.11. Birincil enerji kaynaklarına göre Türkiye'nin elektrik üretimi kurulu gücü [8]

Şekil 2.11'de görüldüğü üzere Türkiye'de tüm kaynaklardan üretilen elektrik enerjisi üretimi artmıştır. 2011 yılında Türkiye'nin kaynaklarına göre elektrik üretiminde birinci sırada hidrolik enerji santralleri yer almaktadır. Türkiye'nin coğrafik özelliklerinden dolayı akarsu bakımından zengin olması ve akarsu yataklarının eğimli bir arazi üzerinde olmasından dolayı enerji potansiyellerinin yüksek olması dolayısıyla hidroelektrik santrallerinden üretilen elektrik enerjisi yüksek seviyelerde seyretmektedir. Hidroelektrik santrallerini doğalgaza dayalı elektrik üretim santralleri takip etmektedir. Doğalgaza dayalı elektrik üretiminin basit olması ve doğalgazın diğer fosil yakıtlara görece daha temiz bir enerji kaynağı olması, doğalgaza dayalı elektrik enerjisi üretimini arttırmaktadır. Bununla birlikte doğalgazın büyük bir kısmının ithal edilmesi Türkiye'nin bu konuda dışa bağımlılığını arttırarak dış ticaret açığına sebep olmaktadır. Kömüre dayalı elektrik enerjisi üretimi hidrolik ve doğal gaz ile elektrik enerjisi üretiminden sonra en çok tercih edilen üçüncü enerji kaynağı olmuştur. Türkiye'nin kömür madeni bakımından zengin olması kömürün elektrik enerjisi üretiminde tercih edilmesinin en önemli nedenleri arasında yer almaktadır. Elektrik üretiminde kullanılan dördüncü kaynak çok yakıtlı kaynaklara dayalı elektrik üretim enerjisi santralleri olmuştur. Yenilenebilir enerji kaynaklarına dayalı elektrik üretimi 2011 yılında çok düşük seviyelerde kalmıştır. 2021 yılında kaynaklara göre elektrik üretiminde birinci sırayı yine hidrolik enerji santralleri almıştır. Bu kaynağı sırasıyla doğalgaz ve kömür kaynaklarına dayalı elektrik üretim santralleri takip etmiştir. Yenilenebilir enerji

kaynaklarına dayalı elektrik üretimi rüzgâr enerji santrallerinde 10.607 MW ve güneş enerji santrallerinde 7815,6 MW seviyelerine kadar çıkmıştır. Bu artışın sebebi yenilenebilir enerji kaynaklarının çevreci ve sürdürülebilir olmasından kaynaklanmaktadır.

Türkiye’de son yıllarda yenilenebilir enerji kaynaklarına dayalı elektrik üretimi hızla artmasına rağmen fosil yakıtlara dayalı elektrik üretimi halen çok üst seviyelerde yer almaktadır. Bu durum elektrik üretiminde CO2 emisyonuna neden olmaktadır. Şekil 2.12’de Türkiye’de elektrik üretimine dayalı CO2 emisyonu görülmektedir.




Şekil 2.12. Türkiye’de elektrik üretimine dayalı CO2 emisyonu [1]

Türkiye’de 2011 yılından itibaren yenilenebilir enerji kaynaklarına dayalı elektrik üretim santralleri yatırımlarına hız verilmiştir. Buna rağmen hızla artan elektrik enerjisi talebini karşılamak için yenilenebilir enerji kaynaklarına dayalı elektrik enerjisi üretimi yeterli olmamaktadır. Bu yüzden fosil yakıtlara dayalı elektrik enerjisi üretimi halen üst seviyelerde yer almaktadır. Bu durum CO2 emisyonuna neden olmaktadır. Sera gazı emisyonu çevre kirliliğine ve iklim değişikliğine neden olmaktadır. Bu olumsuz durumların sebep olduğu doğal afetler ulusal çapta maddi ve manevi zararlara yol açmaktadır.

2.2.1. Türkiye’de yenilenebilir enerji kaynaklarına dayalı elektrik enerjisi üretimi

Türkiye’de dijital ve yeşil dönüşüm vazgeçilmez unsurlarından biri olarak görülen yenilenebilir enerji kaynaklarına dayalı elektrik enerjisi üretimi yıllar boyu artma trendini sürdürmektedir. Ulusal enerji güvenliği stratejisinin en önemli başlıklarından birini oluşturan yenilenebilir enerji yatırımları artarak devam etmektedir. Şekil 2.13.’te görüldüğü üzere Türkiye’nin yenilenebilir enerji kaynaklarına göre elektrik üretimi görülmektedir.



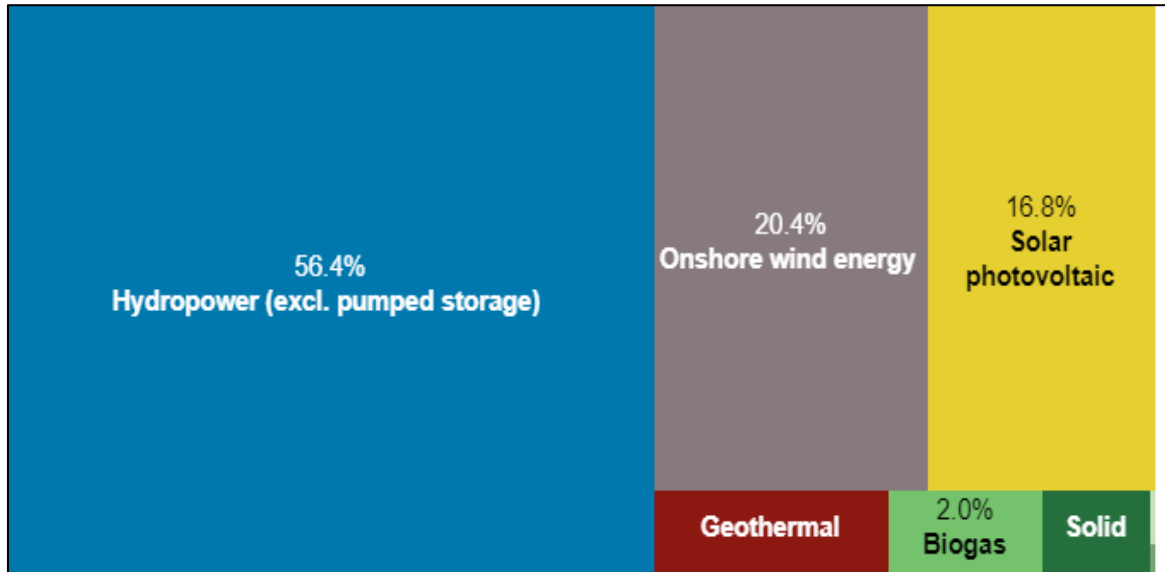
Şekil 2.13. Türkiye’nin yenilenebilir enerji kaynaklarına göre elektrik üretimi [1]

Şekil 2.13.’te görüldüğü üzere yenilenebilir enerji kaynaklarına göre elektrik üretimi incelendiğinde hidroelektrik santrallerinin birinci sırada yer aldığı görülmektedir. 1990 yılında 20.000 GWh seviyelerinde olan elektrik enerjisi üretimi 2020 yılında 60.000 GWh seviyelerini aşmıştır. Türkiye’de yağışların düzensiz olması, iklim değişiklikleri ve çevre kirliliğinin artması dolayısıyla hidroelektrik santrallerinde üretilen elektrik enerjisi değerleri zamana bağlı değişiklik göstermektedir. Hidroelektrik santrallerini sırasıyla rüzgâr enerji santralleri ve güneş enerji santralleri takip etmektedir. 1990 yılında hemen hemen hiç elektrik üretiminin olmadığı rüzgâr enerji santrallerinin üretimi 2020 yılında 30.000 GWh seviyelerine çıkmıştır. Özellikle 2011 yılından sonra hızla artan rüzgâr enerjisi santralleri yatırımları ile bu enerji kaynağından üretilen elektrik enerjisi seviyesi hızla artmıştır. Güneş enerji santralleri ile elektrik üretimi üçüncü en büyük yenilenebilir enerji kaynağı olmuştur.

Gelişen teknoloji ile güneş enerjisi üretim santrallerinde kullanılan ürünlerin maliyetinin hızla azalması bu alanda yatırımları hızla arttırmıştır. Ayrıca ulusal çapta verilen teşvikler bu alanda yatırım seviyesini üst sıralara çıkarmıştır.

Şekil 2.14.'te görüldüğü gibi Türkiye'de yenilenebilir enerji kaynaklarına dayalı elektrik üretimini incelendiğinde birinci sırada %56,4 ile hidroelektrik enerji santralleri yer almaktadır.

Hidroelektrik santrallerini %20,4 oranla rüzgâr enerjisi santralleri izlemektedir. Türkiye'nin akarsu bakımından zengin olması ve akarsu yataklarının eğimli olması hidroelektrik santrallerinin sayısını ve verimini arttırmıştır. Bu sayede bu santrallerin kurulu gücü halen üst seviyelerde yer almaktadır. Güneş enerji santralleri, hidroelektrik ve rüzgâr enerjisi santrallerinden sonra üçüncü en yüksek elektrik üretim kurulu gücüne sahip santrallerdir. Türkiye'nin matematiksel ve coğrafi konumundan kaynaklı rüzgâr ve güneş enerjisi potansiyeli oldukça yüksek bir düzeydedir.



Şekil 2.14. Türkiye'de yenilenebilir enerji kaynaklarının kurulu güce göre dağılımı [9]

2011 yılında yenilenebilir enerji kaynaklarına dayalı elektrik üretimine yapılan yatırımlar hızla artmıştır. Bunun yanında yenilenebilir enerji kaynaklarına dayalı mühendislik ve teknolojik ilerleme ile bu alandaki ürünlerin üretiminin milli imkanlarla yapılmaya başlanması bu alanda yapılan yatırım ve işletme maliyetlerinin de düşürmektedir. Bu sayede

ulusal yenilenebilir enerji kaynaklarına dayalı elektrik üretim santralleri yatırımları artmaktadır.

3. LİTERATÜR ÖZETİ

3.1. Kısa Süreli Rüzgâr Enerjisi Tahmini Problemlerinde Kullanılan Yapay Zekâ Teknikleri

Kısa süreli rüzgâr enerjisi tahmini probleminde kullanılan birçok yapay zekâ tekniği bulunmaktadır. Bunlardan başlıcaları:

- Basit Doğrusal Regresyon (Simple Linear Regression)
- Çoklu Doğrusal Regresyon (Multiple Linear Regression)
- Polinom Regresyon (Polynomial Regression)
- Destek Vektör Regresyonu (Support Vector Regression)
- Karar Ağacı (Decision Tree)
- Rassal Ağaçlar (Random Forest)
- Yapay Sinir Ağları (Artificial Neural Network) teknikleridir.

3.1.1. Basit doğrusal regresyon (Simple linear regression)

Basit doğrusal regresyon modeli, tek bir bağımsız değişken ile tanımlanan bağımlı değişken arasında doğrusal bir ilişki kurulduğunda, bağımsız değişkene bağlı olarak bağımlı değişkeni tahmin etme için kullanılan bir modeldir.

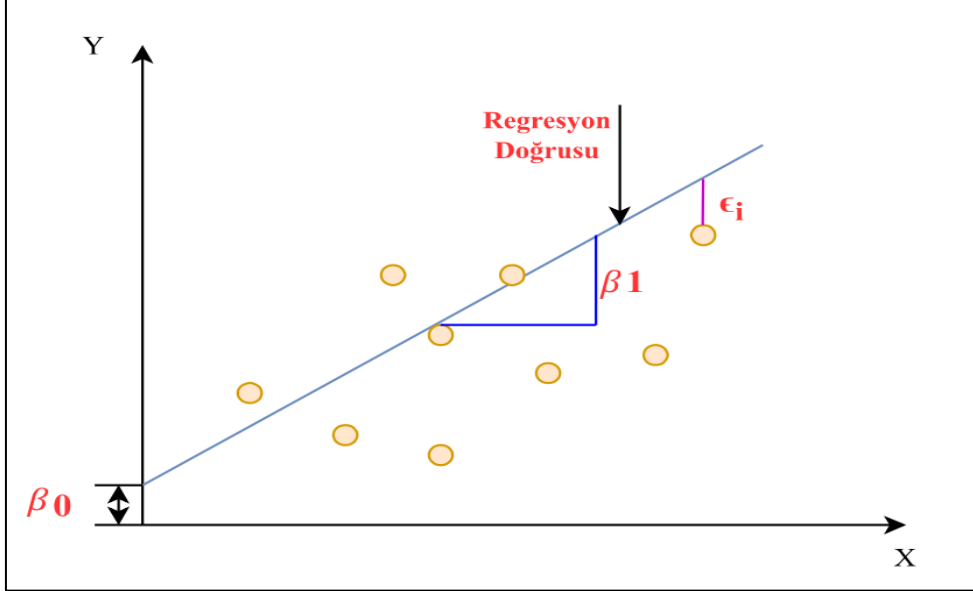
Basit doğrusal regresyonun avantajları aşağıdaki gibidir:

- Basit yapıdadır
- Uygulaması kolaydır.
- Yorumlanabilmesi kolaydır.

Basit doğrusal regresyonun dezavantajları aşağıdaki gibidir:

- Aykırı verilere karşı hassastır.

Şekil 3.1.'de görüldüğü gibi bağımsız değişken ile bağımlı değişken arasında bir doğru uydurularak tahmin yöntemi gerçekleştirilir.



Şekil 3.1. Basit doğrusal regresyon

Basit doğrusal regresyon (simple linear regression) modeli Eş. 4.1'deki gibidir:

$$Y = \beta_0 + \beta_1 X + \epsilon_i \quad (4.1)$$

X=Bağımsız Değişken Değeri

Y=Bağımlı Değişken Değeri

β_0 =Regresyon doğrusunun kesişim katsayısı

β_1 =Regresyon doğrusunun eğim katsayısı

ϵ_i = Hata değeri

3.1.2. Çoklu doğrusal regresyon (Multiple linear regression)

Çoklu doğrusal regresyon, birden fazla bağımsız değişkene bağlı olarak bir bağımlı değişkenin tahmin edilmesi için kullanılan bir modeldir. Bu yöntemde bağımsız değişken ile birden çok bağımlı değişken arasında bir doğru uydurularak tahmin yöntemi gerçekleştirilir.

Çoklu doğrusal regresyonun avantajları aşağıdaki gibidir:

- Modelde bağımlı değişkeni etkileyen daha fazla bağımsız değişken dikkate alınır.

Çoklu doğrusal regresyonun dezavantajları aşağıdaki gibidir:

- Eksik verilere karşı hassastır.
- Modelde çok sayıda bağımsız değişken yer aldığı anda aşırı öğrenme meydana gelebilir.

Çoklu doğrusal regresyon (Multiple linear regression) modeli Eş. 4.2'deki gibidir:

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \epsilon_i \quad (4.2)$$

X_1 =Birinci Bağımsız Değişken Değeri

X_2 =İkinci Bağımsız Değişken Değeri

Y =Bağımlı Değişken Değeri

β_0 =Regresyon doğrusunun kesişim katsayısı

β_1 =Birinci bağımsız değişken için Regresyon doğrusunun eğim katsayısı

β_2 =İkinci bağımsız değişken için Regresyon doğrusunun eğim katsayısı

ϵ_i = Hata değeri

3.1.3 Polinom regresyon (Polynomial regression)

Polinom regresyon modeli bağımsız değişken ile bağımlı değişken arasında doğrusal bir ilişki olmadığı durumlarda kullanılan bir modeldir.


Polinom regresyon modelinin avantajları aşağıdaki gibidir:

- Basit yapıdadır
- Uygulaması kolaydır.

Polinom regresyon modelinin dezavantajları aşağıdaki gibidir:

- Aykırı verilere karşı hassastır.

Şekil 3.2.'de görüldüğü gibi bağımsız değişken ile bağımlı değişken arasında doğrusal olmayan ilişki polinomal olarak oluşturulmuştur.



Şekil 3.2. Polinom regresyon

Polinom Regresyon (polynomial regression) modeli Eş. 4.3'teki gibidir:

$$Y_i = \beta_0 + \beta_1 X_i + \beta_2 X_i^2 + \beta_3 X_i^3 \dots + \beta_k X_i^k + \epsilon_i, \quad i = 1, 2, \dots, \quad (4.3)$$

k=polinom derecesi

Y_i = Bağımlı değişken değeri

X_i = Bağımsız değişken değeri

ϵ_i = Hata değeri

3.1.4. Destek vektör regresyonu (Support vector regression)

Destek vektör regresyon modeli, doğrusal ve doğrusal olmayan regresyonları destekleyen bir modeldir. Bu model, Destek Vektör Makinesi prensibine göre çalışmaktadır.


Destek vektör regresyonun avantajları aşağıdaki gibidir:

- Aykırı değerlere karşı toleranslıdır.
- Oluşturulan karar model kolaylıkla güncellenebilir.
- Yüksek tahmin doğruluğuna sahiptir.

- Uygulaması kolaydır.

Destek vektör regresyonun dezavantajları aşağıdaki gibidir:

- Büyük veri setleri için uygun değildir.



Şekil 3.3. Destek vektör regresyon

Şekil 3.3'te görüldüğü üzere destek vektör regresyon modelinde bağımsız değişkenleri kapsayan en iyi marj aralığını tespit eden bir regresyon oluşturmaktır.

3.1.5. Karar ağacı (Decision tree)

Karar ağacı modeli regresyon problemlerinin çözümü için kullanılmakla beraber sınıflandırma problemlerinin çözümü içinde kullanılan bir modeldir. Yapısal olarak kök düğüm, dallar, alt düğümler ve yapraklardan oluşur. Bu model hiyerarşik bir ağaç yapısı şeklindedir.

Karar ağacı modelinin avantajları aşağıdaki gibidir:

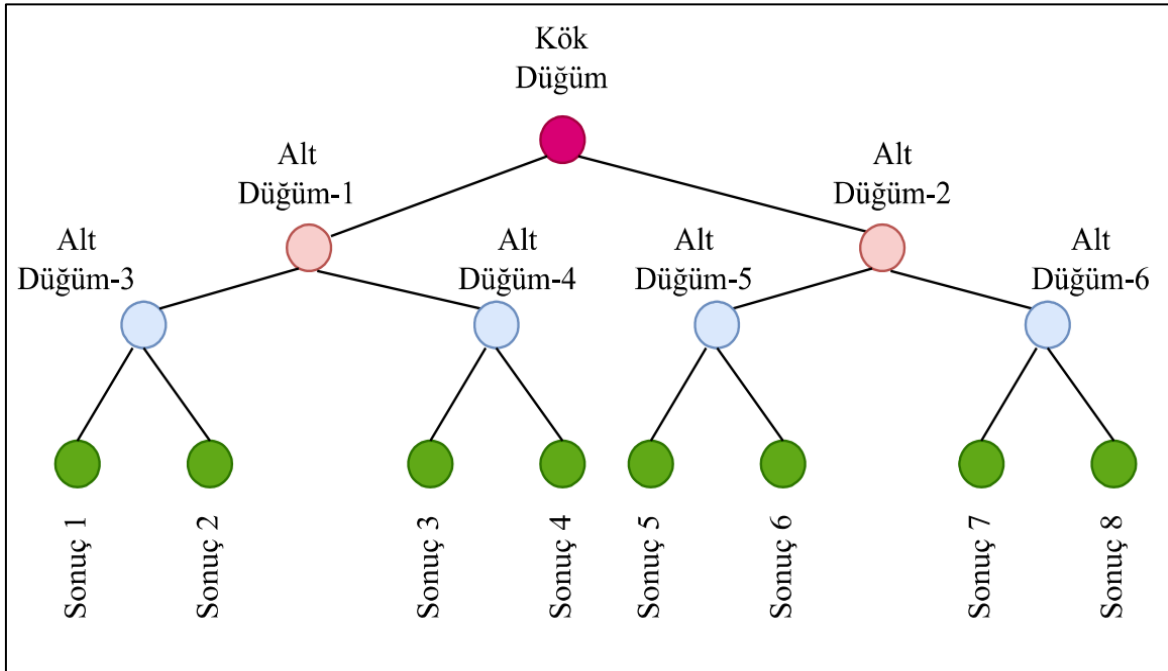
- Verileri normalize etmeye gerek duymaz

- Aykırı verilere karşı toleranslıdır.
- Eksik verilere karşı toleranslıdır.
- Lineer olamayan bir yapıya sahiptir.
- Veri ön işleme sırasında veri hazırlığı için daha az zaman gerektirir.

Karar ağacı modelinin dezavantajları aşağıdaki gibidir:

- Aşırı öğrenmeye yatkındır.
- Modeli eğitmek uzun sürer.
- Karar ağacının eğitimi karmaşık ve nispeten pahalıdır.
- Karar Ağacı algoritması regresyon uygulamak ve sürekli değerleri tahmin etmek için yetersizdir.

Şekil 3.4'te görüldüğü üzere karar ağacının hiyerarşik yapısı görülmektedir.



Şekil 3.4. Karar ağacı

3.1.6. Rassal orman (Random forest)

Rastgele orman algoritması, birden çok karar ağacının bir araya gelmesiyle oluşturulan bir topluluk öğrenme modelidir. Bu model regresyon problemlerinin çözümü için çok fazla kullanılmaktadır. Model regresyon problemlerinin çözümü için kullanıldığında her bir karar ağacının tahmin değerini alarak bu değerlerin ortalamasını alıp sonuç olarak döndürür.

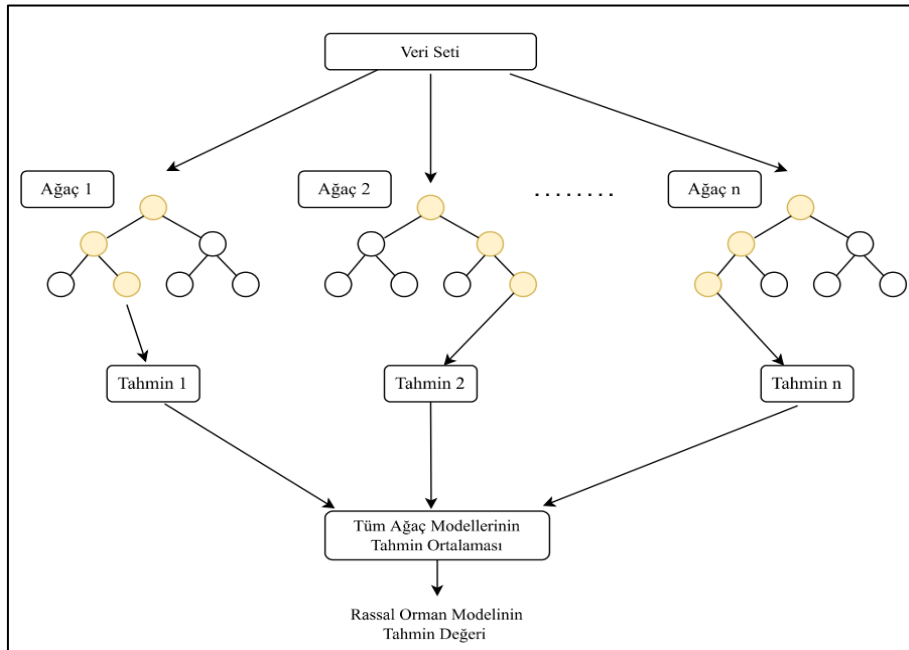
Karar ağacı modelinin avantajları aşağıdaki gibidir:

- Aşırı öğrenme gibi olumsuzluklara karşı güçlü bir yapıdadır.
- Anlaşılması kolay hiper parametrelere sahiptir.
- Yüksek tahmin başarısına sahiptir.

Karar ağacı modelinin dezavantajları aşağıdaki gibidir:

- Fazla ağaç sayısı modeli yavaşlatmaktadır.
- Daha iyi performans için daha fazla ağaç ihtiyacı gereklidir.

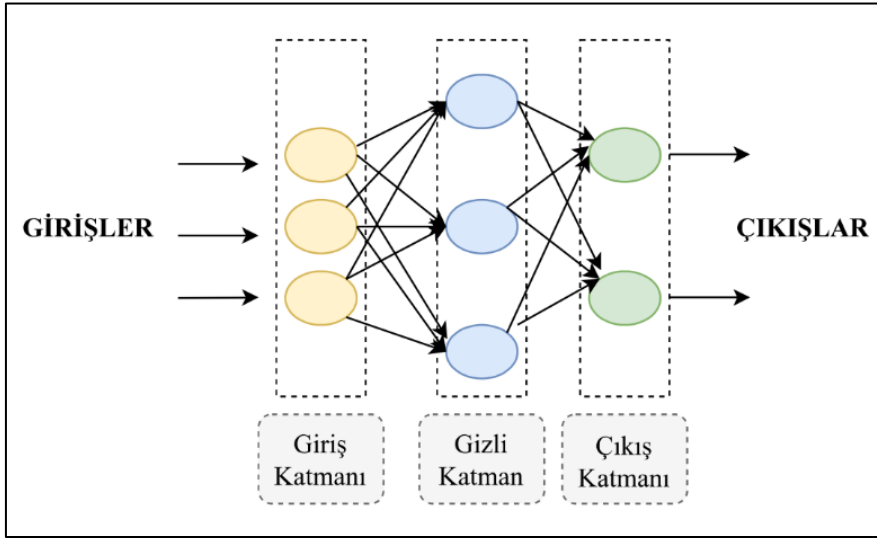
Şekil 3.5'te rassal orman modelinin yapısı görülmektedir.



Şekil 3.5. Rassal orman

3.1.7. Yapay sinir ağıları (Artificial neural network)

Yapay sinir ağıları insan beynini model olarak öğrenmeyi matematiksel olarak gerçekleştirerek oluşturulmuştur. Bu model beyindeki biyolojik sinir ağlarının yapısını taklit ederek öğrenmeyi gerçekleştirerek yeni bilgileri üretme amacıyla yapılandırılan sistemlerdir. Şekil 3.6’da görüldüğü üzere yapay sinir ağı modeli giriş katmanı, gizli katman ve çıkış katmanından meydana gelmektedir.



Şekil 3.6. Yapay sinir ağı modeli

Yapay sinir ağlarının diğer yapay zekâ modellerinden farklı birçok özelliği bulunmaktadır. Bu özellikleri aşağıdaki gibi sıralayabiliriz;

Doğrusal olmama

Yapay Sinir Ağlarının yapısını oluşturan nöronların doğrusal olmamasından dolayı Yapay Sinir Ağları da doğrusal olmayan bir yapıdadır. Yapay sinir ağlarının doğrusal olmayan yapısı sayesinde karmaşık problemlerinin çözümünde başarılı sonuçlar alınmaktadır.

Hata toleransına sahip olma

Bilgisayar sistemlerinde bir problem çözümünde gerçekleşen hataya karşı hassasiyet göstermektedir. Yapay sinir ağlarının yapısında yer alan nöronların birbirleri ile bağlanarak

bir ağ yapısı oluşturması bu modelin hata toleransına sahip olmasını sağlamaktadır. Yapay sinir ağlarının yapısında yer alan bir takım nöron üzerinde meydana gelecek hata bu yapıdaki çözümü büyük oranda etkilemeyecektir.

Uyum sağlama özelliği

Yapay sinir ağları modeli bir problemin çözümü sırasında, problemde oluşan değişikliklere uyum sağlama özelliğine sahip bir yapıdadır. Uyum sağlama özelliği yapay sinir ağları modelinin sinyal işleme, örüntü tanıma gibi problemlerin çözümü için avantaj sağlamaktadır.

Genelleme yeteneğine sahip olma

Yapay Sinir Ağları daha önce bir problemin çözümü için eğitilmişse başka bir problem çözümünde eksik veya gürültülü giriş verilerine rağmen başarılı sonuçlar verme yeteneğine sahiptir.

Öğrenebilen bir yapıda olma

Yapay sinir ağları giriş katmanında yer alan giriş verileri ile eğitilerek öğrenme yeteneğine sahip olmaktadır.

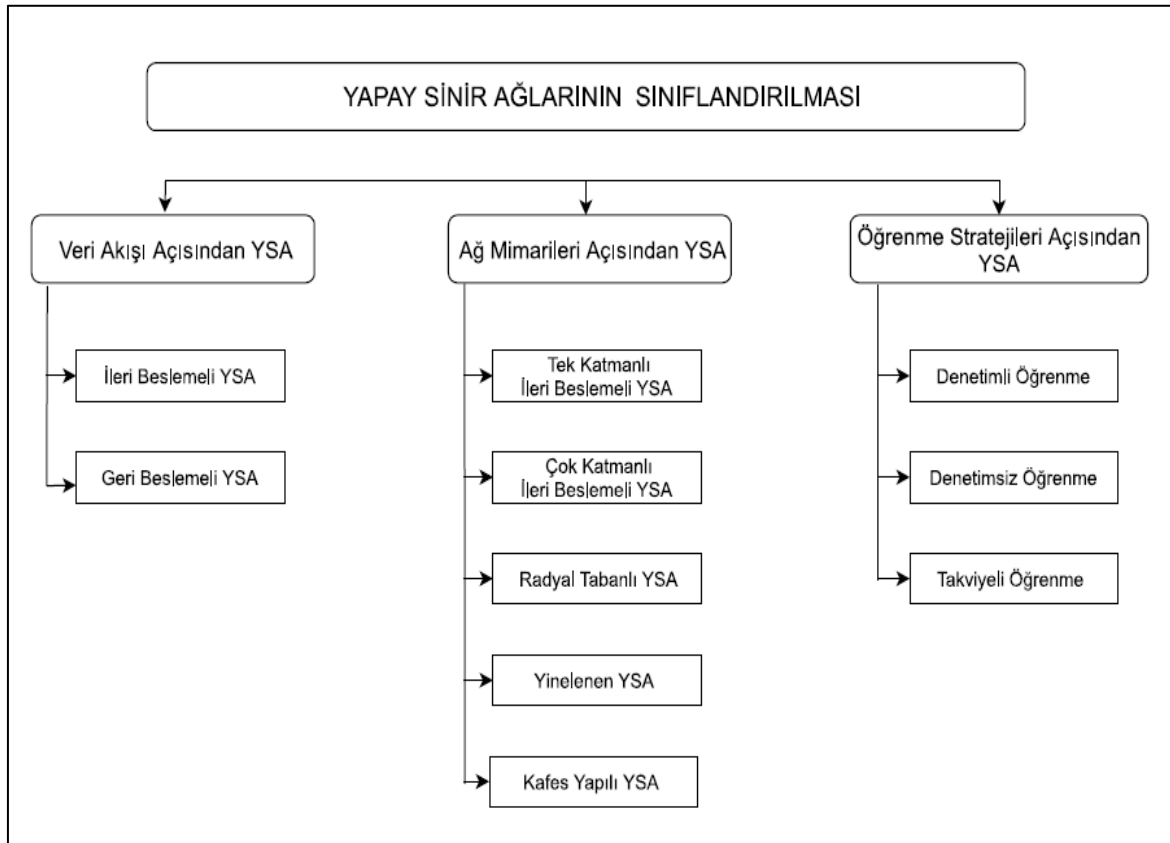
Yapay sinir ağlarının diğer yapay zekâ modellerine karşı birçok avantaja sahiptir. Bunları aşağıdaki gibi sıralayabiliriz;

- Uyum sağlama özelliği sayesinde nöron ağırlıkları gibi değişen parametrelere göre problem çözümü gerçekleştirilir.
- Verileri analiz ederek keşfedilmemiş ilişkileri ortaya koyabilirler.
- Genelleme yapma özellikleri sayesinde giriş verilerinden öğrenme gerçekleştirilip tahmin problemlerini çözebilirler.
- Hataya karşı toleransa sahiptirler. Problem çözümü sırasında karşılaşılan hatadan çok fazla etkilenmeden sonuç üretebilirler.
- İşlem yaparken önceden belirlenmiş bir matematiksel modele ihtiyaç duymazlar.

Yapay sinir ağlarının sahip olduğu birçok avantaja rağmen bazı dezavantajları da bulunmaktadır. Bunları aşağıdaki gibi sıralayabiliriz;

- Yapay Sinir Ağları sayısal verilerle işlem yaptığından dolayı verilerin sayısal değerlere çevrilmesi gerekmektedir.
- Yapay sinir ağlarının parametreleri belli bir kurala bağlı değildir. Bu yüzden problemin çözümü için performanslarının kestirilmesi zordur.
- Problemlerin çözümü için uygun yapay sinir ağı modelinin belirlenmesi zaman alabilmektedir.
- Yapay sinir ağı modelinin öğrenmesi uzun zaman alabilmektedir.

Yapay sinir ağı modeli genel olarak 3.7'deki gibi sınıflandırılabilir.



Şekil 3.7. Yapay sinir ağlarının (YSA) Sınıflandırılması

Veri akışı açısından yapay sinir ağları

Yapay sinir ağları veri akışı açısından İleri Beslemeli yapay sinir ağları ve Geri Beslemeli yapay sinir ağları olmak üzere iki ana başlık altında ele alınabilir.

- İleri Beslemeli Yapay Sinir Ağları: Veri akışının bir döngü oluşturmadan ileri doğru olduğu yapay sinir ağlarıdır.
- Geri Beslemeli Yapay Sinir Ağları: Yapay sinir ağlarının sahip olduğu yapı sayesinde veri akışının geriye doğru olduğu yapay sinir ağlarıdır.

Ağ mimarileri açısından yapay sinir ağları

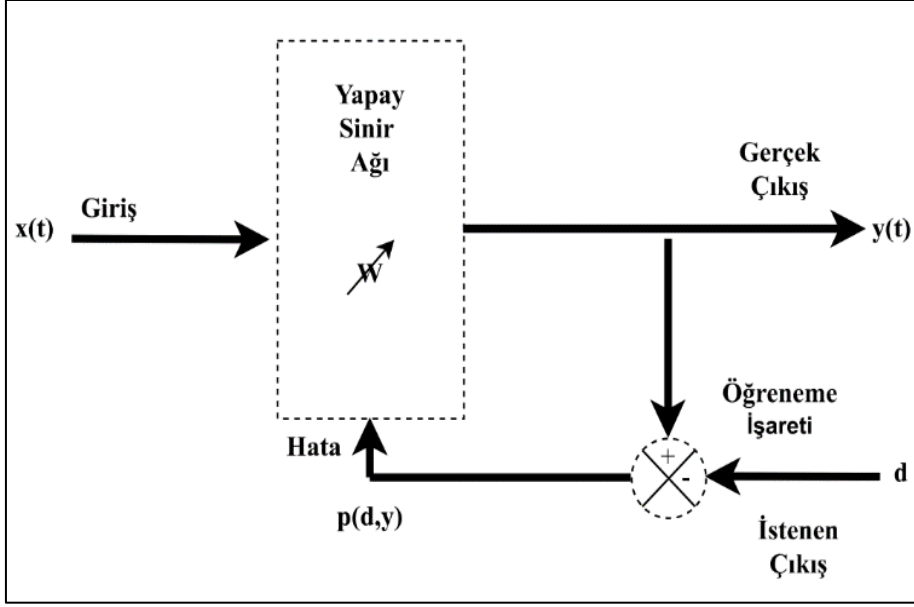
Ağ mimarilerine göre Yapay Sinir Ağları incelendiğinde beş ana başlık ön plana çıkmaktadır. Bunlar Tek Katmanlı İleri Beslemeli YSA, Çok Katmanlı İleri Beslemeli YSA, Radyal Tabanlı YSA, Yinelenen YSA ve Kafes Yapılı YSA olarak sıralanmaktadır.

- Tek Katmanlı İleri Beslemeli Yapay Sinir Ağları: En temel yapay sinir ağı yapısıdır. Giriş ve çıkış katmanından oluşmaktadır.
- Çok Katmanlı İleri Beslemeli Yapay Sinir Ağları: Yapısında bir veya birden fazla gizli katman yer almaktadır.
- Radyal Tabanlı Yapay Sinir Ağları: Giriş katmanı, gizli katman ve çıkış katmanından oluşan bir yapıdadır. Eğitim süreleri görece uzundur.
- Yinelenen Yapay Sinir Ağları: En az bir adet geri besleme çevrimine sahip yapıdadır. Geri besleme bağlantıları, ağın öğrenme başarımını arttıran faktörlerden biri olarak karşımıza çıkmaktadır.
- Kafes Yapılı Yapay Sinir Ağları: Çıkış nöronları satır ve sütun halinde oluşturulmuş ileri beslemeli ağ modelidir.

Öğrenme stratejileri açısından yapay sinir ağları


Yapay Sinir Ağları, öğrenme stratejileri açısından Denetimli Öğrenen Yapay Sinir Ağları, Denetimsiz Öğrenen Yapay Sinir Ağları ve Takviyeli Öğrenen Yapay Sinir Ağları olarak sıralanabilmektedir.

- Denetimli Öğrenme: Denetimli öğrenmede yapay sinir ağları parametreleri hata sinyaline göre ayarlanmaktadır. Toplam hata, belirlenen eşik değerinin altına düştüğünde eğitim sonlandırılır. Şekil 3.8’de denetimli öğrenme yapısı görülmektedir.



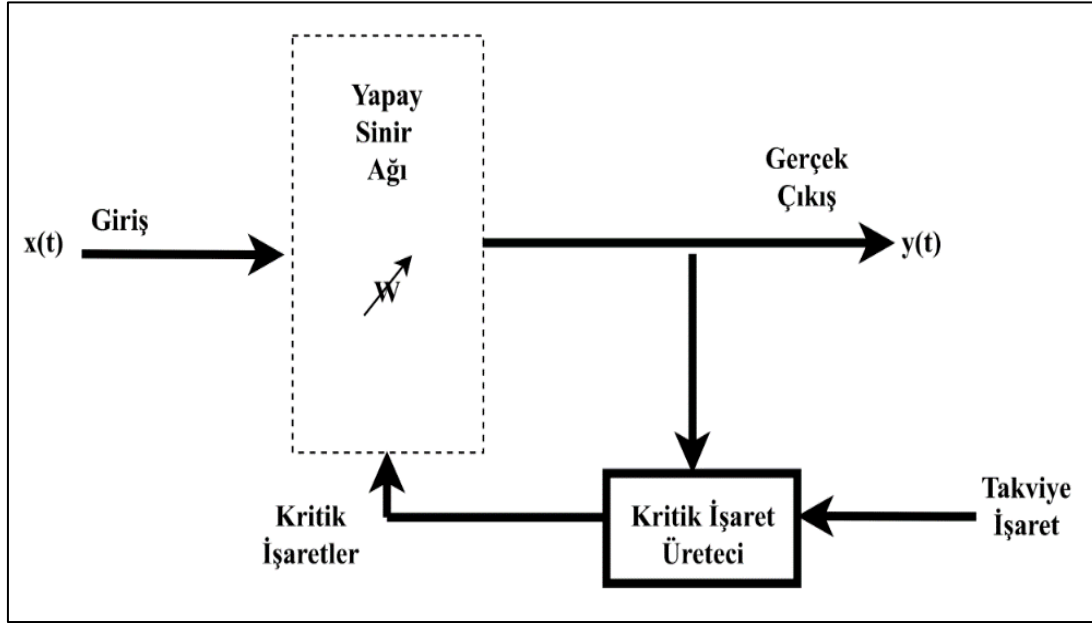
Şekil 3.8. Denetimli öğrenme yapısı

- Denetimsiz Öğrenme: Yapay Sinir Ağı parametreleri, giriş değerine göre ayarlanır. Bu yöntemde sistemin öğrenmesi sona erdiğinde çıkış parametrelerinin etiketlenmesinin kullanıcı tarafından yapılması gerekmektedir. Şekil 3.9’da denetimsiz öğrenme yapısı görülmektedir.



Şekil 3.9. Denetimsiz öğrenme yapısı

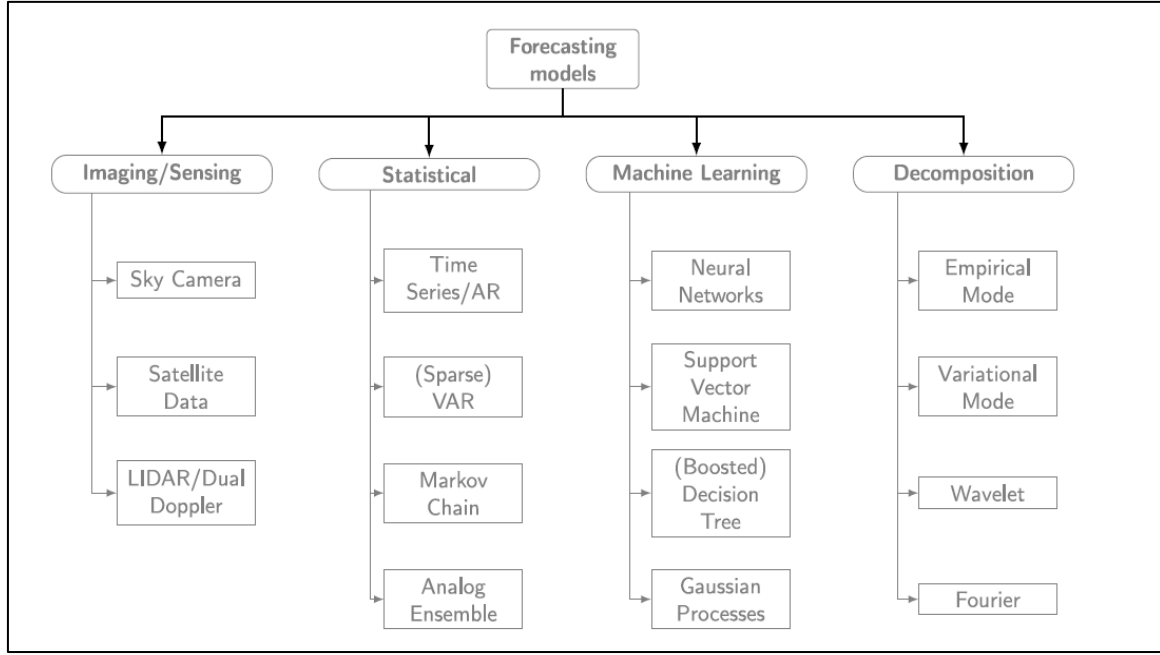
- Takviyeli Öğrenme: Takviyeli öğrenen YSA modelinde, eğitici öğrenme sürecine görece yardımcı olur. Eğitici giriş verileri ile çıkış verilerini de vermek yerine model tarafından üretilen çıkışın doğru veya yanlış olduğunu belirten bir sinyal üretmektedir. Bu sinyale uyumlu olarak yapay sinir ağı eğitimi devam ettirilir. Şekil 3.10'da denetimsiz öğrenme yapısı görülmektedir.



Şekil 3.10. Takviyeli öğrenme

3.2. Literatürdeki Çalışmaların Özeti

Yapay zekâ teknikleri kullanılarak kısa süreli rüzgâr enerjisi tahmini için yapılan birçok çalışma bulunmaktadır. Yapılan literatür taramalarında elektrik enerjisi üretimi tahmini yöntemleri için farklı gruplamalar ve farklı bakış açıları ortaya konulmuştur. R.Tawn ve arkadaşları [10] yaptığı çalışmada rüzgar enerjisi için yapılan tahmin modellerini Şekil 3.11'deki gibi sınıflandırmıştır. Şekil 3.11'de görüldüğü üzere tahmin modelleri dört ana başlıkta incelenmiştir. Bunlar; görüntüleme algılama modelleri, istatistiksel modeller, makine öğrenmesi modelleri ve ayrıştırma modelleridir [10].



Şekil 3.11. Rüzgâr enerjisi tahmini yöntemleri [10]

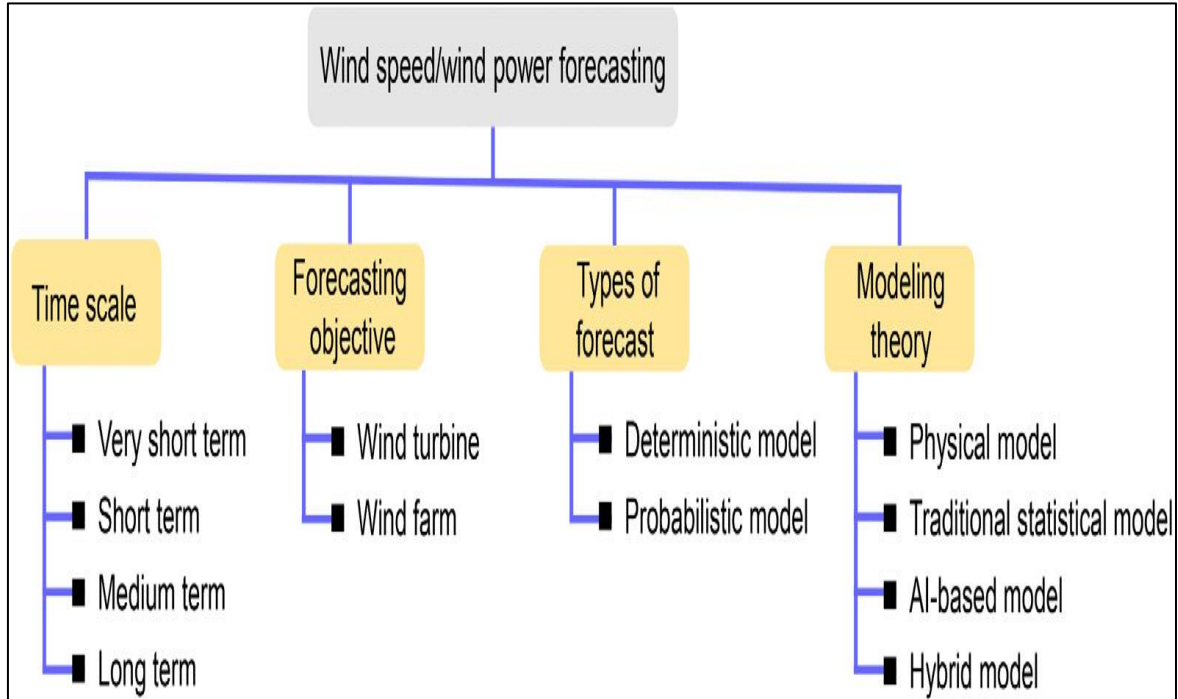
Görüntüleme ve algılama yöntemleri başlığı altında uydu kameraları, uydu verileri ve LIDAR / Dual Doppler sensörleri ile tahmin modellemeleri yer almaktadır. LIDAR, nesnelerin görüntülenmesi için ultraviyole veya kızılötesi ışın kullanır. Bu yöntemle nesnelerin fiziksel özelliklerini yüksek çözünürlükte eşleyebilir. Dual Doppler sensörleri uzak nesneler için hız verisine ulaşmak için kullanılan bir yöntem olarak karşımıza çıkmaktadır. Hedef nesneye bir mikrodalga sinyali göndererek nesneden dönen sinyalin frekansının değişimini analiz ederek nesnenin hızı hakkında tahminde bulunur [10].

İstatistiksel Yöntemler başlığı altında Zaman Serileri, VAR (Vector Autoregressive), Markov Zinciri ve Analog Ensemble modelleri yer almaktadır. VAR modeli, coğrafi olarak dağınmık alanlar arasındaki mekânsal bağımlılıklardan yararlanmak için önerilmiş bir modeldir. Markov Zinciri, bir olayın olasılığının yalnızca önceki olayda elde edilen duruma bağlı olduğu olası olaylar dizisini tanımlayan stokastik bir model olarak tanımlanmıştır. Sistemin şimdiki durumuna bağlı olarak gelecekteki durumu tahmin eden bir model olan Markov Zinciri tahminlemelerde olayın geçmiş durumuna bakmaksızın güncel durumdan gelecekteki değişimleri temizleyebilmektedir. Analog Ensemble metodu, en iyi sonuç vermiş deterministik tahmini bir olasılık dağılım fonksiyonu (Probabilistic Distribution Function - PDF) oluşturmak için kullanmaya dayalı olarak geliştirilmiştir [10].

Makine Öğrenmesi temelli tahmin yöntemleri Yapay Sinir Ağları, Destek Vektör Makinesi, Karar Ağacı ve Gaussian Processes yöntemleri olarak dört ana başlıkta incelenmiştir. Bu yöntemlerin hiper parametrelerinin optimizasyonlarının iyi gerçekleştirilmesi sonucu tahmin problemlerinde çok iyi sonuçlar verdiği belirtilmiştir [10].


Diğer bir tahminleme metodu olan Ayırıştırma Teknikleri dört başlık altında incelenmiştir. Bunlar; Deneysel Mod, Variational Mod, Dalgacık Mod ve Fourier Mod olarak sıralanmıştır. Empirical Mode Decomposition (EMD), verilere dayanan bir modeldir ve orijinal zaman serilerini, her biri zamanla değişen frekansa sahip olabilen birkaç dahili mod işlevine dönüştürmektedir. Dalgacık ayırıştırması, bir zaman serisini farklı tipik frekanslara sahip çoklu sinyallere ayırıştırılmasıyla da sonuçlanan bir modeldir. Variational Mod, her modun sınırlı bir bant genişliğine sahip olduğu başka bir ayırıştırma tekniğidir [10].

Rüzgâr enerjisi tahmini için farklı sınıflandırma yaklaşımları da mevcuttur. Wang [11] ve arkadaşları rüzgâr enerjisi tahmini için Şekil 3.12’de görülen farklı bir sınıflandırma yapmıştır.



Şekil 3.12. Rüzgâr hızı / enerjisi tahmin sınıflandırılması [11]

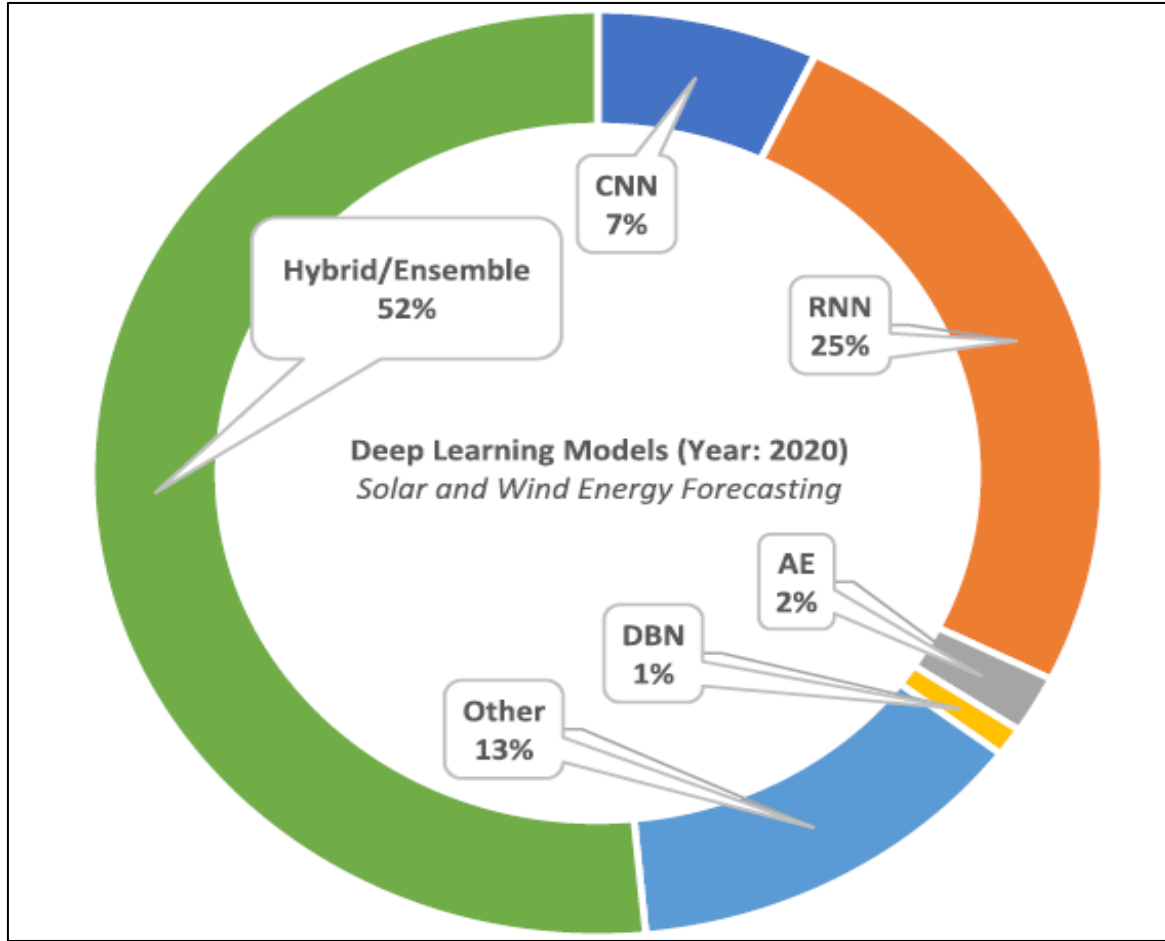
Şekil 3.13'te görüldüğü üzere zamana bağlı rüzgâr enerjisi tahmini; çok kısa zamanlı, kısa zamanlı, orta zamanlı ve uzun zamanlı tahmin modeli olarak karşımıza çıkmaktadır. Çok kısa zamanlı tahminler, türbin kontrolü ve gerçek zamanlı elektriksel yük denetimi için kullanışlıdır. Yük dağıtım planlaması için kısa zamanlı tahminler kullanılmaktadır. Orta vadeli tahmin modelleri, elektrik enerjisi ticareti için ve güç sistemleri yönetimi için oldukça kullanışlı bir yöntemdir. Uzun vadeli tahminlerde enerji santrallerinin kaynak planlaması, işgücü planlaması ve bakım planlaması için bir referans göstergesidir.



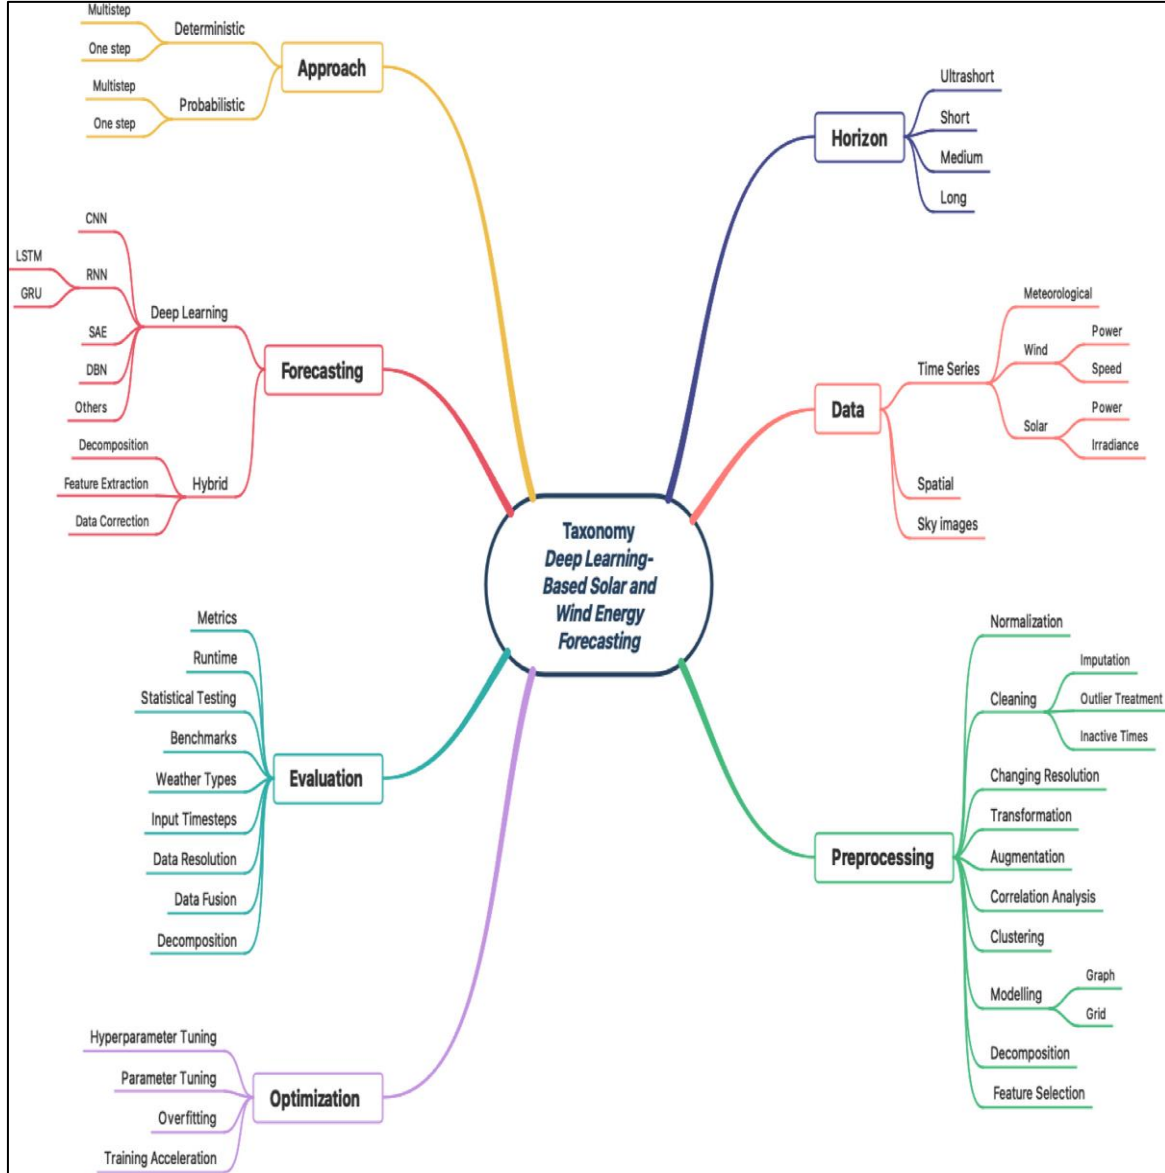
Şekil 3.13. Zaman skalasına göre rüzgâr enerjisi tahmini sınıflandırması [11]

Rüzgâr enerjisi tahmini sınıflandırması başlığı altında model teorisine göre sınıflandırma dört alt başlık altında incelenmiş olup bunlar; fiziksel modeller, geleneksel istatistiksel modeller, yapay zekâ temelli modeller ve hibrid modeller olarak karşımıza çıkmaktadır. Fiziksel modeller, genellikle meteorolojik olayları (hava basıncı, nem, sıcaklık vb.) dikkate alarak tahmin yapan modellerdir. Bu modellere örnek olarak NWF (Numeric Weather Forecasting) ve WRF (Weather Research Forecasting) modelleri verilebilir. Geleneksel istatistiksel modellerin başında ARIMA (Autoregressive Integrated Moving Average) modeli gelmektedir. Bu model kararsız zaman serisi verileri üzerinde başarılı tahmin sonuçları ortaya koyan bir modellerdir. Yapay Zekâ temelli modellemelerde, derin öğrenme modellerinin rüzgâr enerjisi tahmini üzerinde çok başarılı sonuçlar vermesi bu problemin çözümünde LSTM (Long Short Time Memory), RNN (Recursive Neural Network), CNN (Convolutional Neural Network) ve AE (Autoencoder) gibi derin öğrenme modellerinin kullanılma oranını gittikçe arttırmaktadır. Rüzgâr enerjisi tahmini için kullanılan hibrid modellerde iki bakış açısı geliştirilmiştir. Bunlardan biri yığın tabanlı modeller diğeri ise ağırlık tabanlı modellerdir. Yığın tabanlı modeller, bir temel modelin tahminini başka üst düzey model için girdi olarak kullanan modellerdir [11]. Yığın tabanlı tahmin modelleri, genellikle bir veya daha fazla temel modelin tahminlerini, daha sonra başka bir üst düzey modelle birleştirilen özellikler olarak kabul eder. Ağırlık tabanlı modellemede, birden fazla tahmin edici model bir problem için uygulanır ve ağırlık katsayılarının optimizasyonu yapılarak en doğru sonuç bulunmaya çalışılmıştır [11]

Rüzgâr enerjisi tahmini için yapay zekâ temelli birçok model kullanılmaktadır. Ghadah Alkhayat ve arkadaşları [12], yaptığı çalışmada derin öğrenme ile yapılan rüzgâr enerjisi ve güneş enerjisi tahmin yöntemlerinin taksonomisini çıkarmışlardır. Şekil 3.14'te görüldüğü gibi bu çalışma sonunda 2020 yılı için derin öğrenme yöntemleri ile rüzgâr enerjisi ve güneş enerjisi tahmin yöntemlerinin ilk sırasında %52 ile Hibrid Modeller ile yapılan çalışmalar yer alırken %25'lik pay ile RNN modeli ikinci sırada yer almaktadır. CNN modeli de en çok tercih edilen derin öğrenme modellerinde biri olmayı başarmıştır. Yazar çalışmasında derin öğrenme yöntemlerinin rüzgâr ve güneş enerjisi tahmini problemlerinde nasıl kullanıldığını da Şekil 3.15'te bir taksonomi haline getirip sunuştur [12].

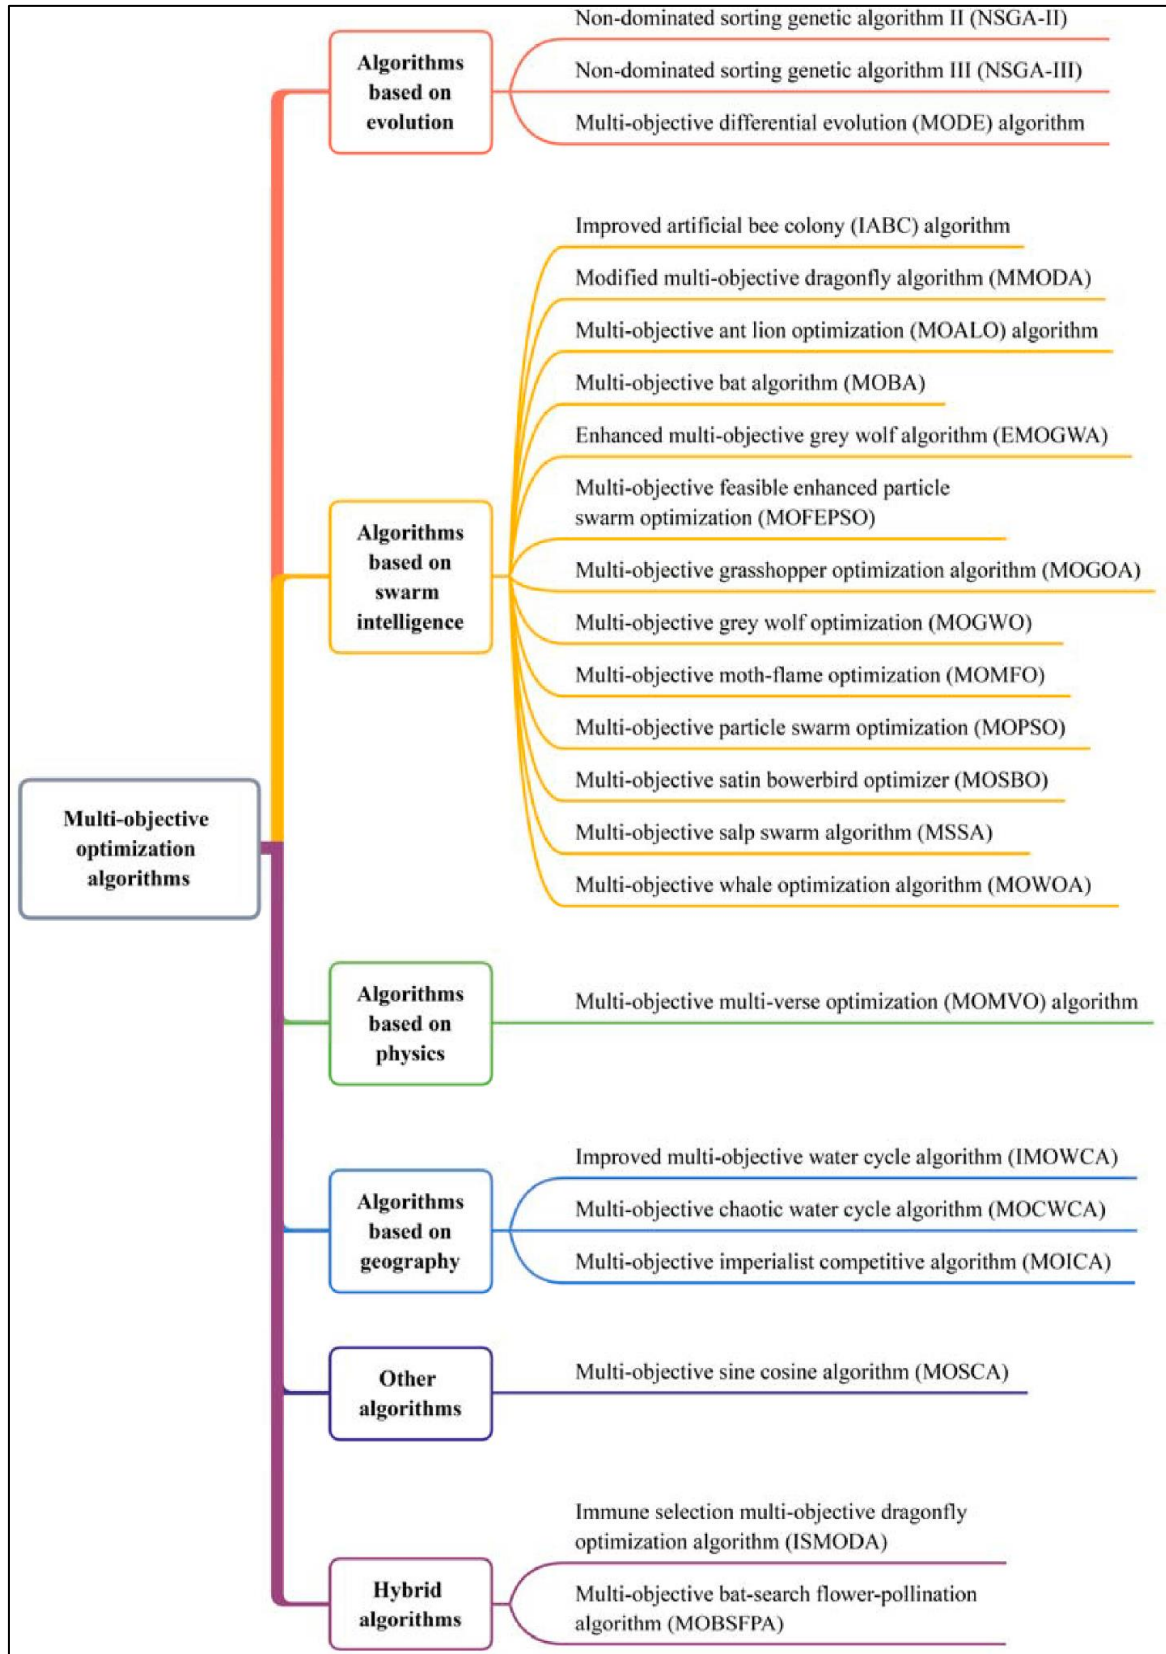


Şekil 3.14. 2020 yılında Web of Science'da yayınlanan çalışmalarda rüzgâr ve güneş enerjisi tahmin yöntemlerinde derin öğrenme metotlarının yapılarına göre kullanılma oranları [12]



Şekil 3.15. Derin öğrenme temelli güneş ve rüzgâr enerjisi tahmini taksonomisi [12]

Hui Liu ve diğerleri, [13], yaptığı araştırma makalesi çalışmasında rüzgâr enerjisi tahmin yöntemlerinde kullanılan çok amaçlı optimizasyon tekniklerini Şekil 3.16’da görüldüğü gibi gruplandırmıştır. Ayrıca rüzgâr tahmin yöntemlerini temel olarak deterministik ve olasılıksal tahmin yöntemleri olarak 2 ana gruba ayırmıştır. Deterministik tahmin yöntemlerinde optimizasyon tekniklerinin amacının yüksek doğruluk ve yüksek güvenilirlik sağlamak olduğunu ifade etmektedir. Olasılıksal tahmin yöntemlerinde optimizasyon tekniklerinin kullanılma amacının ise tahmin aralıklarının güvenilirliğini sağlamak, dağılımlar için mantıksal çıkarımların sonuçları olumsuz yönde etkilemesini engellemek ve tahmin aralıklarının keskinliğini sağlamak olduğunu belirtmiştir.



Şekil 3.16. Rüzgâr enerjisi tahmini için çok amaçlı optimizasyon teknikleri [13]

Hao Chen [14], rüzgâr enerjisi tahmini için Kodlayıcı Kod Çözücü Uzun Kısa Süreli Bellek / Encoder Decoder Long Short-Term Memory (ED LSTM) tahmin modelini önermiştir. Bu çalışmada ilk olarak Norveç Meteoroloji Enstitüsünden alınan Sayısal Hava Durumu Tahmini / Numerical Weather Prediction (NWP) rüzgâr hızı verileri, Fakken rüzgâr çiftliğinden ölçülen rüzgâr gücü ve rüzgâr hızı verileri ham veri olarak birleştirilmiştir. Bu ham veriler üzerinde veri odaklı yaklaşımlar yöntemi ile veri çoğaltma işlemi gerçekleştirilmiştir. Beş kez çoğaltılan veriler, ED LSTM tahmin modelini eğitmek için kullanılmıştır. Yazar, ED LSTM tahmin modelinin karmaşık bir derin öğrenme modeli olduğundan, bu modelin başarılı olabilmesi için çok sayıda girdi verisi olması gerektiğini belirtmiştir. Fizik odaklı yaklaşımlarla veri çoğaltma yöntemi oldukça zor ve maliyetli olduğundan, girdi verilerini yapay olarak yeniden üretmeyi seçmiştir. Önerilen modelin karşılaştırılan diğer yöntemlere göre daha başarılı olduğu ifade edilmiştir. Önerilen modelde RMSE (Root Mean Squared Error) metriğine göre %7,87 ile %11,36 arasında bir iyileşme sağlanmıştır. MAE (Mean Absolute Error) metriğine göre %5,24 ile %8,97 arasında bir iyileşme sağlanmaktadır.

Sahara Khzaei [15], kısa vadeli rüzgâr enerjisi tahmini için hibrit bir model önermiştir. Önerilen bu model, aykırı değer tespiti, dalgacık dönüşümü tekniği kullanılarak zaman serilerinin ayrıştırılması, verimli öznitelik seçimi ve Çok Katmanlı Algılama / Multilayer Perception (MLP) sinir ağı kullanılarak ayrıştırılan her bir zaman serisinin tahmininden oluşur. Modelde, aykırı değer tespiti için Automatic Ensemble ve T^2 istatistiklerinin bir kombinasyonu kullanılmıştır. Özellik çıkarımı, Baskın Olmayan Sıralama Genetik Algoritması II / Non-dominated Sorting Genetic Algorithm II (NSGA- II) ve Radyal Tabanlı Fonksiyon / Radial Basis Function (RBF) sinir ağı kullanılarak sağlanmıştır. Yazar önerilen modeli, İspanya Galiçya'da bulunan 24 rüzgâr türbinine sahip toplam kurulu gücü 17.56 MW olan bir rüzgâr çiftliğinden elde edilen veri seti üzerinde incelemiştir. Önerilen yöntemin performansının oldukça yüksek olduğu belirtilmektedir. Önerilen yöntemin sonuçları, çalışmada belirtilen diğer yöntemlerden daha iyi performans göstererek NRMSE (Normalized Root Mean Squared Error) metriğinde 0,1020 ve NMAE (Normalized Mean Absolute Error) metriğinde 0,0803 değerine ulaşmıştır.

Bangru Xiong [16], kısa vadeli rüzgâr enerjisi tahmini için dikkat mekanizması ve derin öğrenmenin bir kombinasyonundan oluşan hibrit bir model önermiştir. Önerilen model Dikkat Mekanizması / Attention Mechanism, CNN ve LSTM modellerinin bir

kombinasyonu olup AMC – LSTM olarak adlandırılmıştır. Yazar, rüzgâr enerjisinin fiziksel özelliklerinin çok gürültülü verilere sahip olduğunu ve tahmin performansını olumsuz etkilediğini belirtmektedir. Modelde kullanılan Dikkat Mekanizması / Attention Mechanism modeli, gözlenen olayların bazı önemli kısımlarını ihtiyaçlarına göre seçici bir şekilde elde etme eğiliminde olan insan beynini taklit eden, önemsiz kısımları görmezden gelen bir yöntemdir. Dikkat Mekanizması yöntemi ile gürültülü veriler göz ardı edilip girdi katmanındaki fiziksel özelliklere farklı ağırlıklar verilerek performansı artıracak temel bilgilere odaklanılır. Kısa süreli soyut özellikler ve uzun süreli zamanlama varyasyon özellikleri için CNN (Convolutional Neural Network) ve LSTM (Long Short-Term Memory) modelleri kullanılmaktadır. Çıkarılan zamansal özellikler ve fiziksel özellikler, rüzgâr gücünü tahmin etmek için birleştirilir. Model, Moğolistan'da bir rüzgâr çiftliğinde bulunan 1500 kW nominal güce sahip 5 numaralı Huachuang CCWE1500 tipi bir rüzgâr türbininden elde edilen veri seti üzerinde gerçekleştirilmiştir. Yapılan deneyler sonucunda önerilen sistemin etkili ve uygulanabilir olduğu belirtilmiştir. Önerilen modelde, klasik LSTM (Long Short-Term Memory) modellerine göre MAE (Mean Absolute Error) metrik değeri 0,0553'ten 0,0505'e düşürülerek performans değeri arttırılmıştır.

Yingchao Dong [17], Extreme Learning Machine (ELM), Bernstein Model ve Hermite Neural Network (HNN) modellerini birleştiren rüzgâr tahmini için bir kümeleme topluluğu modeli önermektedir. Önerilen modelde, veri ön işleme için Quadratic Interpolation (QISTA) optimizasyon tekniğine dayalı bir durum geçiş algoritması kullanılarak veriler optimal olarak ayrılmıştır. İşlenen veriler, Bernstein Model ve Hermite Neural Network (HNN) modellerinin parametrelerini optimize etmek için kullanılmıştır. Önerilen yöntem ile farklı modellerin veri yapılarından tam olarak yararlanılarak birbirinden öğrenmesi mümkündür. Modelin performansını test etmek için Çin'in Sincan bölgesindeki bir rüzgâr çiftliğinden alınan rüzgâr enerjisi verileri kullanılmıştır. Deney sonucunda önerilen yöntemin $R^2=0,9761$ değerine ulaşmıştır ve R^2 (Decisive Coefficient) metriğine göre çalışmada bahsedilen diğer modellerden daha iyi performans gösterdiği belirtilmiştir.

Boyu He [18], kısa vadeli rüzgâr enerjisi tahmini için hibrit bir model önermiştir. Önerilen modelde, minimum Yedeklilik Maksimum İlişki / minimum Redundancy Maximum Relevance (mRMR) algoritmasına göre Sayısal Hava Durumu Tahmini / Numerical Weather Prediction (NWP) verilerinden birkaç faktör dikkate alınmıştır. Ele alınan faktörlerden farklı özellikler çıkarılmakta ve bu özelliklere dayalı farklı hava türleri, k-means kümeleme

algoritması kullanılarak ortaya çıkarılmaktadır. İki derin öğrenme algoritması, CNN (Convolutional Neural Network) ve LSTM (Long Short-Term Memory) hava durumu türlerine uygulanmaktadır ve son olarak, her modele farklı ağırlıklandırma katsayıları atamak için İndüklenmiş Sıralı Ağırlıklı Ortalama / Induced Ordered Weighted Average (IOWA) operatörü kullanılmıştır. Önerilen model, Kuzey Çin'de kurulu gücü 249,9 MW olan rüzgâr enerjisi santralının 01.01.2017 ve 31.12.2018 dönemine ait rüzgar enerjisi verileri ve Sayısal Hava Tahmini / Numerical Weather Prediction (NWP) verileri üzerine uygulanmıştır. Önerilen yöntemin Extreme Learning Machine (ELM), Radial Basis Function (RBF), Support Vector Machine (SVM) gibi modellere göre daha başarılı olduğu belirtilmiştir. Önerilen yöntem, çalışmada bahsedilen diğer yöntemlere göre RMSE (Root Mean Squared Error) metriğine göre %12,1540 ve MAE (Mean Absolute Error) metriğine göre %8,0608 daha iyi performans göstermiştir.

Cristian Dragos Dumitru [19], makale çalışmasında rüzgâr enerjisi tahmini için iki farklı zaman serisi modelini, stokastik model tabanlı ARIMA (Autoregressive Integrated Moving Average) ve FFANN (Feed Forward Artificial Neural Network) modellerini karşılaştırmıştır. FFANN üzerindeki çalışmalarını Python Keras kütüphanesini kullanarak, Stokastik Modelleme ise StatsModels paketi üzerinden gerçekleştirmiştir. Yazar, Mart 2018'de üretilen ve Romanya Ulusal Güç Sistemi Operatörü'nün web sitesinde bulunan rüzgâr enerjisi verilerini kullanmıştır. Önerilen FFANN modeli, NMSE (Normalized Mean Squared Error) metriğine dayalı olarak ARIMA modeline göre %60,77'lik bir iyileşme sağlamıştır.

Xin Liu [20] makale çalışmasında kısa dönem rüzgâr enerjisi tahmini için SRNN (Stacked Recurrent Neural Network) modelini kullanmış ve yaptığı deney sonucunda tahmin sonuçlarının çok yüksek olduğunu belirtmiştir. Yazar, Amerika Birleşik Devletleri Ulusal Yenilenebilir Enerji Laboratuvarı / United States National Renewable Energy Laboratory (NREL) tarafından 2007 ile 2012 yılları arasında kaydedilen toplam 631286 veriyi kullanmıştır. Önerilen model, çalışmada bahsedilen diğer modellerden daha iyi performans göstermiştir ve R^2 (Decisive Coefficient) metriğine göre 0,7847 ve MSE (Mean Squared Error) metriğine göre 0,0143 değerini almıştır.

Emanuele Ogliari [21] makale çalışmasında günlük rüzgâr enerjisi tahmini için iki modeli bir arada kullandığı fiziksel yöntem ve yapay sinir ağlarının kombinasyonu olan hibrit bir

model ile deneysel çalışma yapmıştır. Yaptığı çalışma sonucunda tahmin performansı en iyi olan yöntemin hibrit yöntem olduğunu belirtmiştir. Bu deney için yazar, İtalya'da nominal gücü 0,66 MW olan 24 rüzgâr türbininden oluşan bir rüzgâr çiftliğinden iki saatlik elektrik üretim verilerini kullanılmıştır. Önerilen model, persistence modeline göre karşılaştırıldığında MAE (Mean Absolute Error) performans metriği bazında %44,85 ve NRMSE (Normalized Root Mean Squared Error) performans metriğini bazında %47,82 oranında daha başarılı olmuştur.

Pelin Görgel ve diğerleri, [22] yaptığı çalışmada rüzgâr enerjisi tahmini için Uzun Kısa Süreli Hafıza ve Evrişimsel Sinir Ağları metodunu bir arada kullanarak hibrit bir model önermiştir. Önerilen model için 01.05.2017 – 31.05.2018 tarih aralığında bir rüzgâr türbini için elde edilen rüzgâr hızı veri seti kullanılarak tahmin yapılmıştır. Önerilen modelin tahmin başarımı Mean Squared Error (MSE) başarı metriğine göre 1,17 olarak gerçekleşmiştir.

Andres L. Suarez-Cetrulo ve diğerleri, [23] yaptığı çalışmada gün sonrası enerji ticareti için topluluk öğrenmesi modeli ile rüzgâr enerjisi tahmini gerçekleştirmiştir. Önerilen modelin test edilmesi için İrlanda'da yer alan 8 adet rüzgâr çiftliğinin SCADA sistemi üzerinden alınan 2 yıllık veriler kullanılmıştır. Veri seti üzerinde Bayesian Ridge, Boosting Ensemble, Dense LSTM (Dense Long Short Term Memory), LSTM (Long Short Term Memory), Linear Regression, SVR (Support Vector Regressor) ve xGBoost algoritmaları karşılaştırılmıştır. Yapılan deneyler sonrasında en başarılı algoritma Root Mean Square Error (RMSE) = 0.17791 değeriyle xGBoost algoritması olmuştur.

Ling-Ling Li ve diğerleri, [24] yaptıkları çalışmada Geliştirilmiş Yusufçuk algoritmasını, Destek Vektör Makinesinin optimal parametrelerini seçmesi için kullanmıştır. Önerilen model Fransa'daki La Haute Borne rüzgâr çiftliğinden elde edilen 8778 adet 1 saatlik rüzgâr enerjisi üretim verilerinden oluşan gerçek zamanlı veri seti üzerinde doğrulanmıştır. Önerilen modelin Back Propagation Neural Network ve Gaussian Process Regression modeline göre daha başarılı olduğu görülmüştür.

Justin Heinemann ve diğerleri, [25] yaptığı çalışmada rüzgâr gücü tahmini için karar ağaçları ve destek vektör regresyonu destekleyen heterojen topluluk algoritmasının kombinasyonu olan hibrit bir model önermektedir. Çalışmada deneyler için eğitim veri seti olarak 5 farklı rüzgâr parkının güç çıkış verileri kullanılmıştır. Çalışmalar Python Scikit

learn makine öğrenmesi kütüphanesi kullanılarak gerçekleştirilmiştir. Deneyde önerilen model destek vektör regresyonu ve k-NN makine öğrenmesi algoritmalarıyla karşılaştırılmıştır. Elde edilen sonuçlara göre önerilen modelin rüzgâr gücü tahmini performansı destek vektör regresyonuna göre %37 oranında daha iyi olduğu gözlemlenmiştir. Ayrıca önerilen model MSE başarımlarına göre k-NN algoritmasından daha başarılı sonuçlar elde etmiştir.

Lahouar ve diğerleri, [26] Rastgele Orman (Random Forest) algoritması kullanarak kısa süreli rüzgâr enerjisi tahmini çalışması yapmıştır. Çalışmada Rastgele Orman algoritmasının diğer makine öğrenmesi algoritmaları gibi parametre ayarlamalarına ve optimizasyonuna gerek olmadan yüksek performans gösterdiği için bu algoritmanın tercih edildiği belirtilmiştir. Önerilen model Tunus'taki Sidi Daoud rüzgâr çiftliğinde bulunan 70 adet rüzgâr türbininin 2010 ve 2011 yılları arasında 10 dakikalık aralıklarla kaydedilen rüzgâr enerjisi güç verileri kullanılarak test edilmiştir. Önerilen model Yapay Sinir Ağları modeli ile karşılaştırılmış olup RMSE başarımlarına göre %6,55 daha iyi performans göstermiştir.

Lei Liu ve diğerleri, [27] yaptığı çalışmada Derin Bayes modeli kullanarak kısa süreli rüzgâr gücü tahmini gerçekleştirmiştir. Çalışmada kısa süreli rüzgâr enerjisi tahmini için Bayesian framework-based bidirectional gated logic unit / Bayes çerçevesi tabanlı çift yönlü kapılı mantık birimi (BiGRU) modeli önerilmiştir. Önerilen modelde Bayes Sinir Ağı ve kodlayıcı – kod çözücü mimarisi bir arada kullanılmıştır. Modelin test edilmesi için kullanılan veriler 1 Ağustos 2017 ile 1 Ekim 2018 tarihleri arasında bir rüzgâr santralının 47 adet rüzgâr türbininden toplanmıştır. Her 15 dakikada bir, günde 96 kayıt noktası kaydedilerek toplam 40.896 veri elde edilmiştir. Her bir rüzgâr türbini 2 MW ve rüzgâr santralının toplam kurulu gücü 94 MW'tır. Önerilen model karşılaştırılan diğer modellere göre $R^2=0.7907$ değeri ile daha iyi bir performans göstermiştir.

Şenol ve diğerleri, [28] yaptığı çalışmada yapay sinir ağları modeli ile rüzgâr enerjisi üretim tahmini yapmıştır. Önerilen modelin giriş verisi olarak Aydın ilinin Çine ilçesinin Turguttepe mevkiinde 2015 yılında 90 m yükseklikte ölçülmüş rüzgâr hızı verilerinden yararlanılmıştır. Gamesa G97, Suzlon S.88, Siemens SWT2.3, Nordex N100, Enercon E82, Vestas V117 tipi rüzgâr türbinlerinin rüzgâr hızına bağlı ürettiği elektrik enerjisi de önerilen modelin çıkış verisi olarak kullanılmıştır. Önerilen model Matlab yazılımı kullanılarak

gerçekleştirilmiştir. Önerilen modelin R^2 başarımlı metriğine göre 1'e yakın performansa sahip olduğu belirtilmiştir.

Yapılan bu çalışmalarda klasik yöntemlerin aksine makine öğrenmesi tekniklerinin rüzgâr enerjisi ile kısa süreli elektrik üretim tahmini problemlerinde büyük bir başarı gösterdiği görülmektedir. Bu bilgiler ışığında yapay zekâ tabanlı rüzgâr enerjisi tahmin yöntemlerinin yüksek performans gösterdiği görülmektedir. Bu nedenle bu çalışmada kısa dönemli rüzgâr enerjisi üretim tahmin probleminin çözümü için yapay zekâ teknikleri yaklaşımı tercih edilmiştir. Bu çalışmayı genel olarak diğer çalışmalardan ayıran başlıca katkılar şunlardır:

- Günlük rüzgâr enerjisinden üretilen elektrik enerjisi verilerinin grafiğe dönüştürülüp bu grafikten yapay olarak sayısal veriler elde edilerek oluşturulan veri seti kullanımı yerine gerçek dünya verilerinden oluşan ve halen devrede olan rüzgâr enerji santrallerinden elde edilen elektrik üretimi verilerinden oluşan veri seti kullanılması,
- Karmaşık derin ağlar yerine, tek bir gizli katmana ve az sayıda veri giriş nöronuna sahip basit bir yapay sinir ağı yapısının kullanılması,
- Veri ön işlemede yüksek verimliliğe sahip bir normalleştirme tekniğinin seçilmesi,
- Aykırı verilerin saptanması için son teknoloji bir yöntemin kullanılması.

4. MATERYAL VE METOT

Yapay zekâ teknikleri ile kısa süreli rüzgâr enerji tahmini problemi çözümü için iki adet çalışma gerçekleştirilmiştir. İlk çalışmada öncelikle temel makine öğrenmesi tekniklerini analiz ederek hangilerinin yüksek başarımlı gösterdiği tespit edilmiştir. Daha sonra ortaya çıkan sonuçlara göre ikinci çalışmada YSA algoritması ile daha detaylı bir parametre araştırması ve sonuç kıyaslaması gerçekleştirilmiştir.

4.1. Makine Öğrenmesi Teknikleri ile Kısa Süreli Rüzgâr Enerjisi Tahmini

Bu çalışmada kısa süreli rüzgâr enerjisi ile elektrik üretimi tahmini için en bilinen ve en yaygın kullanılan makine öğrenimi algoritmaları olan Yapay Sinir Ağları, Basit Doğrusal Regresyon, Polinomal Regresyon, Destek Vektör Regresyon ve Rassal Orman algoritmaları kullanılarak başarımlı performansları karşılaştırılmıştır.

Bu çalışmada güncel ve gerçek enerji üretim değerlerinden oluşan bir veri seti üzerinde makine öğrenmesi teknikleri ile kısa süreli rüzgâr enerjisi tahmini gerçekleştirilmiştir.

4.1.1. Veri seti

Çalışma için EPIAŞ şeffaflık platformundan [29] gerçek zamanlı yayınlanan Ardıçlı Rüzgâr Santrali'nden 01.05.2022 ile 17.02.2023 tarihleri arasında bir saat aralıklarla kaydedilen 7014 adet ham veri kullanılmıştır.

Bu veri seti üzerinde kısa süreli rüzgâr enerjisi ile elektrik üretimi tahmini için Yapay Sinir Ağları, Basit Doğrusal Regresyon, Polinomal Regresyon, Destek Vektör Regresyon ve Rassal Orman makine öğrenimi algoritmalarının başarımlı performansları karşılaştırılmıştır. Bu çalışmanın yenilikçi unsuru ve diğer çalışmalardan ayıran yanı güncel ve gerçek enerji üretim değerlerinden oluşan bir veri seti üzerinde en bilinen ve en yaygın kullanılan makine öğrenmesi tekniklerinin başarımlarını karşılaştıran bir çalışma yapılmasıdır.

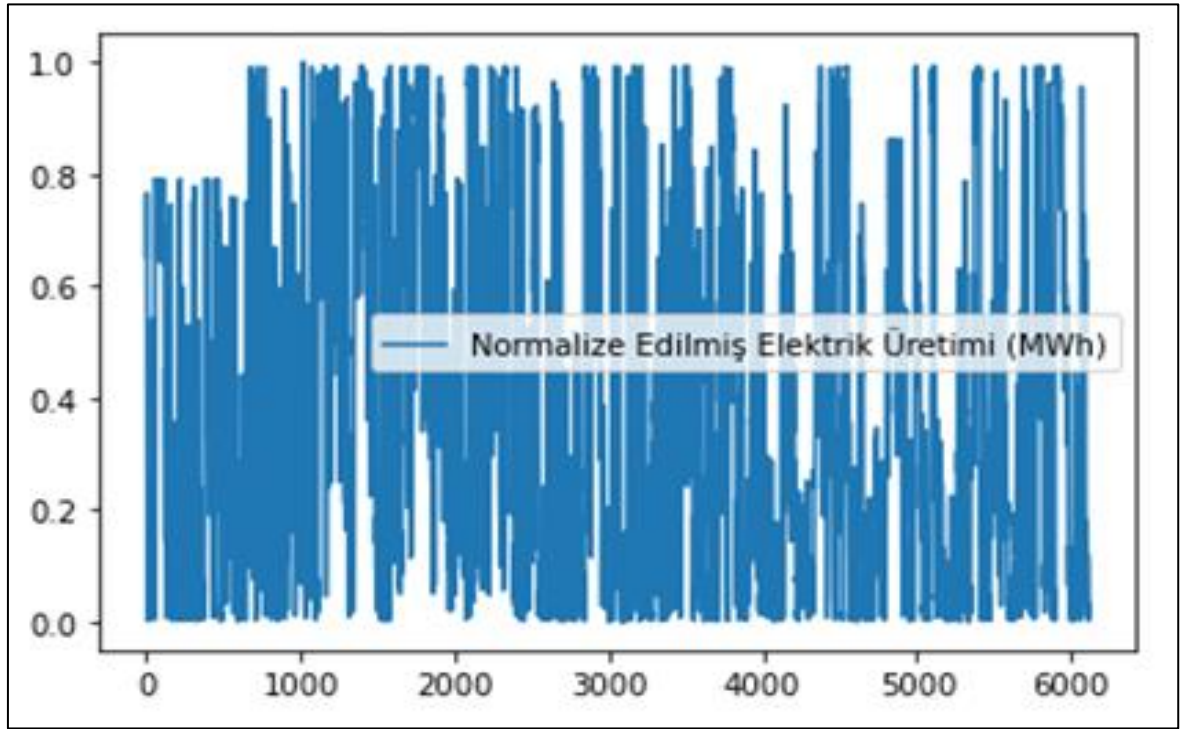
Çalışmada kullanılacak veri setindeki eksik veriler veri ön işleme aşamasında silinerek temizlenmiştir. Eksik verilerin temizlenmesiyle veri setindeki bir saatlik ham veri sayısı

6134 adet olarak belirlenmiştir. Çizelge 4.1’de veri setinin istatistiksel özellikleri görülmektedir.

Çizelge 4.1. Saatlik veri setinin istatistiksel özellikleri

count	6134.000000
mean	22.509779
std	19.999384
min	0.010000
25%	4.710000
50%	16.230000
75%	38.370000
max	62.700000

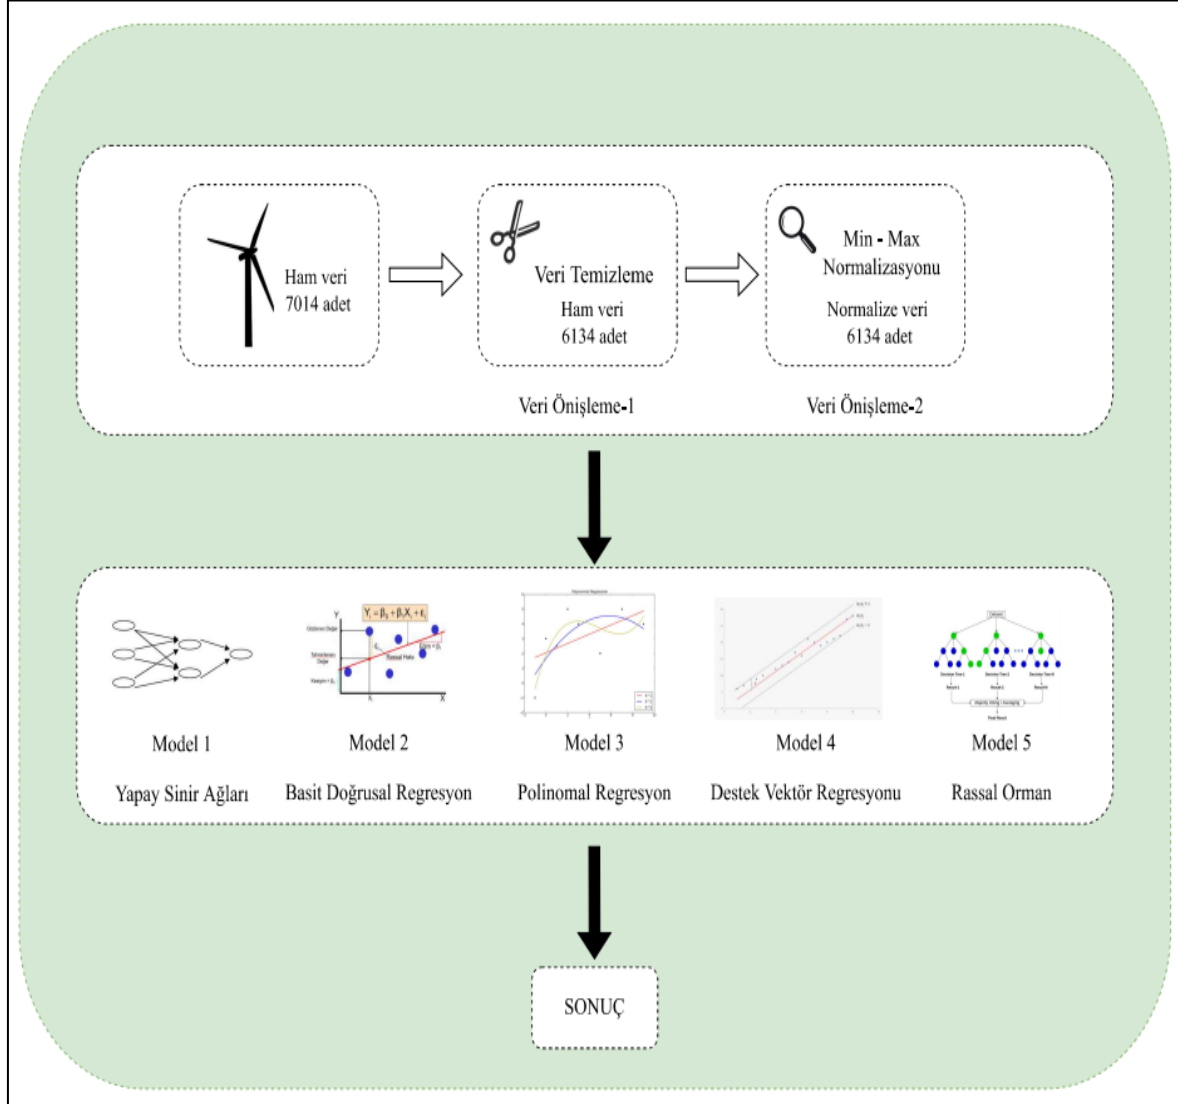
Rüzgâr enerjisi verilerinin içerisindeki aykırı verilerin makine öğrenmesi modellerinin öğrenme başarısına olumsuz etkilerini en aza indirmek adına Min – Max Normalizasyon tekniği kullanılarak veriler normalize edilmiştir. Normalize edilen veri seti Şekil 4.1’de görülmektedir.



Şekil 4.1. Ardıçlı RES’e Önceden işlenmiş verilerin çizgi grafiği (x eksenini veri adedini; y eksenini normalizasyon aralığını göstermektedir).

Normalize edilmiş 6134 adet veri sırasıyla Yapay Sinir Ağları, Basit Doğrusal Regresyon, Polinomal Regresyon ve Rassal Orman makine öğrenmesi metotları üzerinde kullanılarak

kısa süreli rüzgâr enerjisi tahmini gerçekleştirilmiştir. Bu çalışmada gerçekleştirilen süreç Şekil 4.2’de gösterildiği gibidir.



Şekil 4.2. Önerilen modelin akış şeması

Yapılan çalışmada makine öğrenmesi modellerinin gerçekleştirilmesi için Python programlama dilinin Scikit-Learn makine öğrenmesi kütüphanesi ve MATLAB yazılımının Neural Network Toolbox uygulaması kullanılmıştır. Yapılan deneylerin performansını değerlendirmek adına Root Mean Square Error (RMSE), Mean Squared Error (MSE) ve Decisive Coefficient (R^2) başarımleri kullanılmıştır. RMSE ve MSE başarımlerinin sıfıra yakın olması; R^2 metriğinin ise 1'e yakın olması yüksek başarıyı ifade etmektedir.

Birinci makine öğrenmesi modeli olarak Yapay Sinir Ağı kullanılmıştır. Yapay Sinir Ağı MATLAB yazılımının Neural Network Toolbox uygulaması kullanılarak tasarlanmıştır. Oluşturulan modelde 6134 adet normalize edilmiş veriden oluşan veri seti %80 eğitim verisi ve %20 test verisi olarak ayrılmıştır. Yapay Sinir ağı 24 adet giriş nöronu, 10 adet ara katman nöronu ve 1 adet çıkış nöronu olarak tasarlanmıştır. Öğrenme algoritması olarak Bayesian Regularization algoritması kullanılmıştır. Yapay Sinir Ağı modelinde 24 adet 1 saatlik veri giriş nöronu kullanılarak sonraki 1 saatlik rüzgâr enerjisi üretiminin tahmini gerçekleştirilmiştir.

İkinci makine öğrenmesi modeli olarak Basit Doğrusal Regresyon modeli kullanılmıştır. Modelin uygulanmasında Python programlama dilinin Numpy, Pandas ve Scikit-Learn makine öğrenmesi kütüphanesi kullanılmıştır. Modelin uygulanmasında veri seti %80 eğitim verisi %20 test verisi olarak kullanılmıştır.

Üçüncü makine öğrenmesi modeli olarak Polinomal Regresyon modeli kullanılmıştır. Model Python Scikit-Learn makine öğrenmesi kütüphanesi üzerinden tasarlanmıştır. Model parametresi PolynomialFeatures(degree=4) olarak belirlenmiştir. Bu parametre Polinomal Regresyonun 4. derece bir polinom olduğunu ifade etmektedir. Modelde kullanılan veri seti %80 eğitim verisi %20 test verisi olarak ayrılmıştır.

Dördüncü makine öğrenmesi modeli olarak Destek Vektör Regresyon modeli kullanılmıştır. Model Python Scikit-Learn makine öğrenmesi kütüphanesi üzerinden tasarlanmıştır. Algoritmanın temel parametresi olan çekirdek tipi olarak kernel='rbf' (Gaussian radial basis function kernel / Gauss dairesel tabanlı işlev çekirdeği) kullanılmıştır.

Beşinci makine öğrenmesi modeli olarak Rassal Orman modeli kullanılmıştır. Model Python Scikit-Learn makine öğrenmesi kütüphanesi üzerinden tasarlanmıştır. Model parametreleri olan ağaç sayısı (n_estimators) ve maksimum ağaç derinliği (max_depth) değerlerinin her ikisi de 50 olarak belirlenmiştir

4.2. Yapay Sinir Ağları ile Kısa Süreli Rüzgâr Enerjisi Tahmini

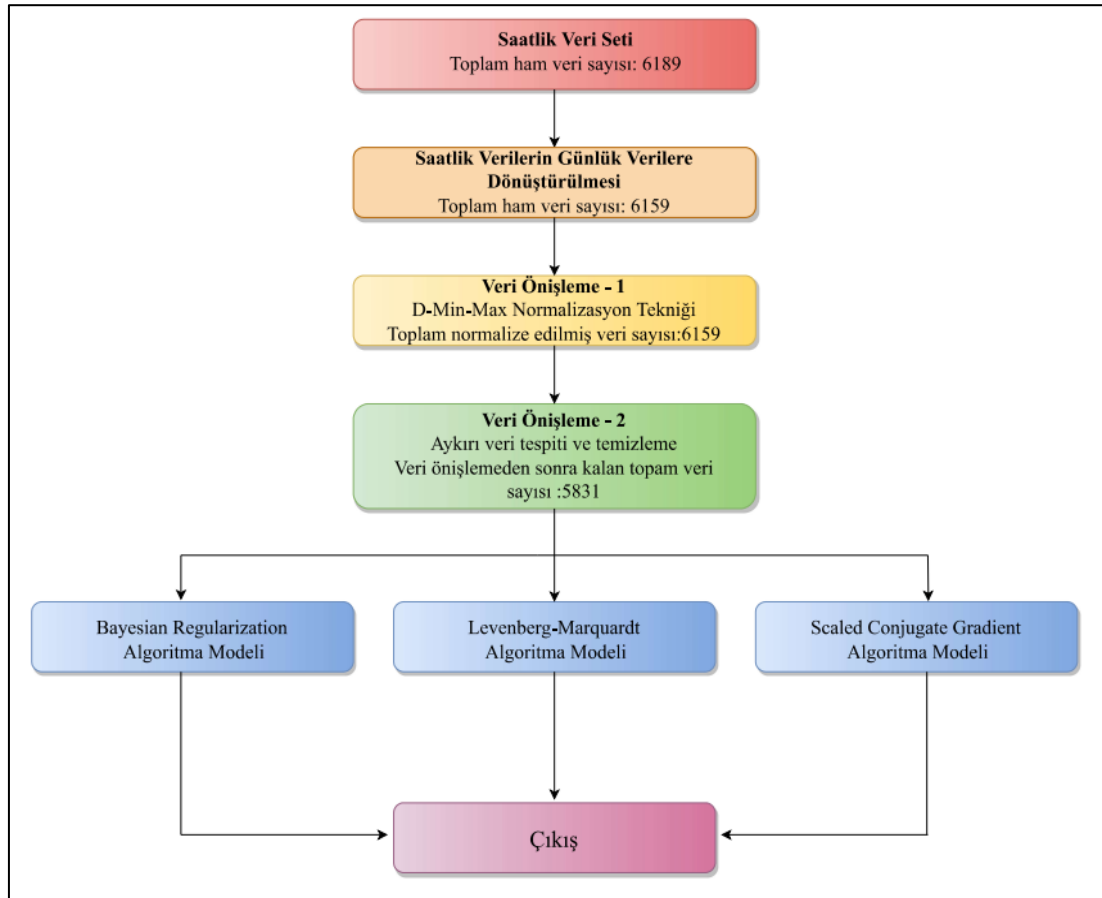
Bu çalışmada yapay sinir ağları modeli kullanılarak kısa süreli rüzgâr enerjisi tahmini yapılmış olup önerilen modelin başarısı bu alanda popüler olan diğer modeller ile

karşılaştırılmıştır. Bu çalışma, yapay sinir ağları ile kısa süreli rüzgâr enerjisinden elektrik üretimi tahmininin gerçekleştirilmesini ele almaktadır.

4.2.1. Veri seti

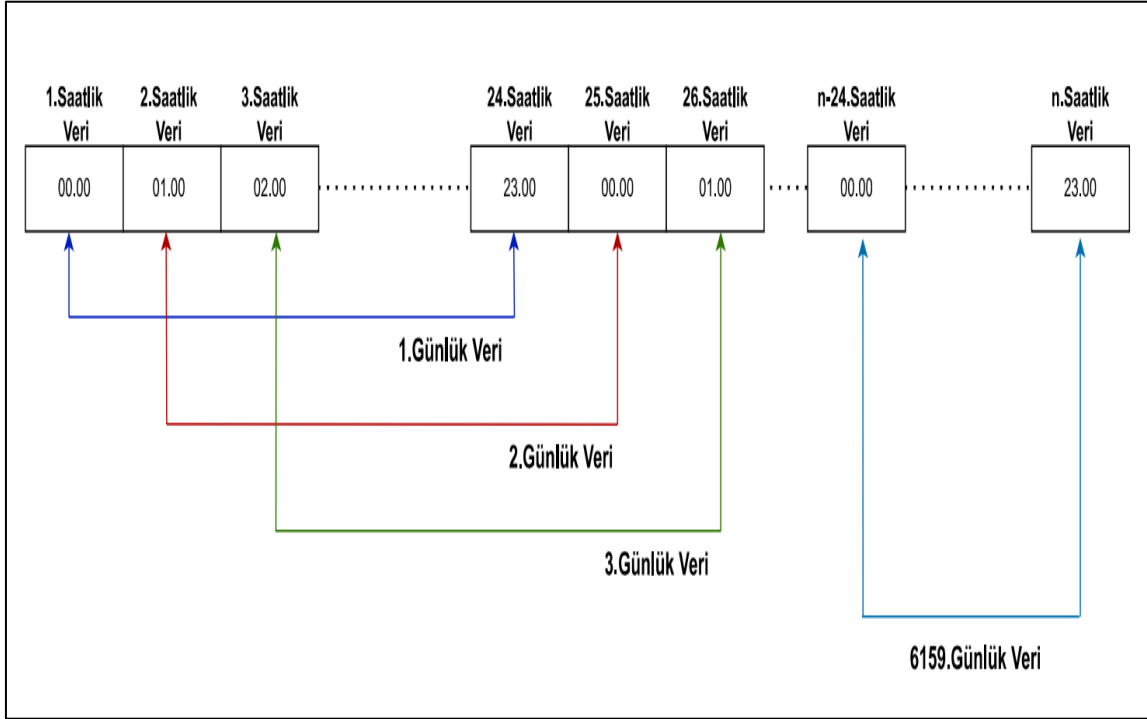
Bu çalışmada kullanılacak veri seti Türkiye'de Kayseri İli Yahyalı İlçesi'nde bulunan Yahyalı Rüzgâr Santrali'nden elde edilmiştir. Yahyalı Rüzgâr Santrali'nin kurulu gücü 52,8 MW olup, toplamda 22 adet Nordex N117-2,4 MW tipi rüzgâr türbini bulunmaktadır. Çalışmanın yürütüldüğü veriler, söz konusu rüzgâr santralinin Enerji Piyasaları İşletme A.Ş.'nin (EPIAŞ) şeffaflık platformunda kamuya açık olan 02.02.2021 ile 16.10.2021 tarihleri arasındaki saatlik elektrik enerjisi üretim gücü (MWh cinsinden) verilerini içermektedir [30].

Bu deneyde gerçekleştirilecek yöntem adımlarını gösteren genel akış şeması Şekil 4.3'te verilmiştir.



Şekil 4.3. Önerilen çalışmanın ana yapısı

Rüzgâr enerjisinin kararsız yapısı nedeniyle, yapay sinir ağları ile tahmin başarısını artırmak için, Şekil 4.4'te gösterildiği gibi, saatlik elektrik üretim verileri kayan 24 saatlik pencere yaklaşımı kullanılarak günlük elektrik üretim verilerine dönüştürülmüştür.



Şekil 4.4. Saatlik enerji üretim verilerinin günlük enerji üretim verilerine dönüşüm yapısı (MWh olarak)

Rüzgâr enerjisi üretim verileri, zaman içinde çok fazla değişiklik göstermektedir. Bu durum çok büyük ve çok küçük değerlerin olduğu rüzgâr enerjisi üretim değerlerinde istikrarsızlığa yol açmaktadır. Veri setindeki çok değişkenlik gösteren bu veriler, yapay sinir ağlarının tahmin performansını olumsuz yönde etkilemektedir. Günlük veri setinin istatistiksel özellikleri Çizelge 4.2.'de gösterildiği gibidir.

Çizelge 4.2. Günlük veri setinin istatistiksel özellikleri


count	6159.000000
mean	406.812233
std	271.538286
min	19.750000
25%	200.700000
50%	344.080000
75%	555.990000
max	1202.700000

Bu olumsuzluğu en aza indirmek için veri ön işleme tekniklerinin en önemlilerinden ve en sık kullanılanlarından biri olan normalizasyon tekniği kullanılarak veriler 6159 günlük veri için normalize edilmiştir. Çizelge 4.3.'te görüldüğü gibi, normalleştirme işlemi için birçok teknik vardır [31][32]. Daha önce yapılan deneyler sonucunda D-Min-Max Normalizasyon tekniğinin sinir ağlarında yüksek performans sunduğu belirtilmiştir [31]. Bu nedenle çalışmamızda normalizasyon tekniği olarak D – Min-Max Normalizasyon tekniği kullanılmıştır.

Çizelge 4.3. Normalizasyon yöntemleri

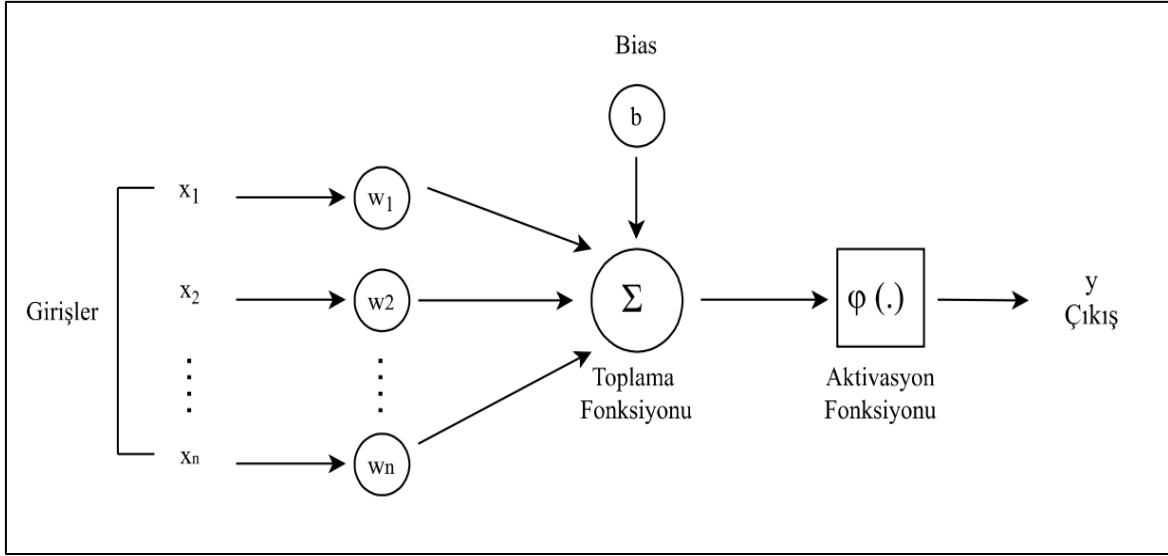
Normalizasyon Metodu	Eşitlik	Tip
Z- Score	$x' = \frac{x_i - \mu_i}{\sigma_i}$	Ölçekleme
Min - Max Normalizaion	$x' = \frac{x_i - x_{min}}{x_{max} - x_{min}}$	Ölçekleme
Median Normalization	$x' = \frac{x_i}{Median(a_i)}$	Ölçekleme
Sigmoid Normalization	$x' = \frac{e^{x_i} - e^{-x_i}}{e^{x_i} + e^{-x_i}}$	Ölçekleme
D - Min - Max Normalization	$x' = 0.8 * \frac{x_i - x_{min}}{x_{max} - x_{min}} + 0.1$	Ölçekleme
Mean Centered	$x' = x_i - \mu_i$	Ölçekleme
Pareto Scaling	$x' = \frac{x_i - \mu_i}{\sqrt{\sigma_i}}$	Ölçekleme

Normalleştirilmiş rüzgâr enerjisi üretim verilerinin yapay sinir ağlarının öğrenilmesinde kullanılabilmesi için belirli bir kararlılığa sahip olması gerekmektedir. Bu istikrarı bozan en önemli faktörlerden biri rüzgâr enerjisi üretim verilerinde çok sayıda aykırı veri bulunmasıdır. Bu aykırı veriler, sinir ağlarının tahmin yeteneğini önemli ölçüde etkiler. Çalışmada bir diğer önemli veri işleme adımı ise yapay sinir ağı modelinin performansını artırmak için normalize edilmiş veri setindeki aykırı değerlerin tespit edilmesi ve veri setinden silinmesi ile gerçekleştirilmiştir. Aykırı veri tespiti için Python Sklearn kütüphanesindeki LocalOutlierFactor metodu kullanılmaktadır. Tespit edilen aykırı değerler günlük veri setinden çıkarılmış ve bu işlem sonrasında nihai veri setinde toplam 5831 adet veri kalmıştır. Ön işlemeden sonra veri kümesindeki verilerin son durumu, Python Seaborn veri görselleştirme kütüphanesi kullanılarak bir çizgi grafiği olarak Şekil 4.5.'te gösterilmektedir.



Şekil 4.5. Yahyalı RES'e ait önceden işlenmiş verilerin çizgi grafiği (x eksenini veri adedini; y eksenini normalizasyon aralığını göstermektedir.)

Nihai veriler sinir ağlarının giriş katmanına sunulacak ve çıkış katmanı sonucu tahmin edecektir. Bu çalışmada, rüzgâr enerjisinden elektrik üretim tahmini için yapay sinir ağı tabanlı bir yaklaşım önerilmiştir. Yapay sinir ağları, insan beyninin öğrenme modelini taklit ederek gerçekleştirilen bir teknolojidir. Yapay sinir ağları bilgiyi öğrenebilen bir yapıya sahiptir. Bilgiyi depolamak için nöronlar arasındaki bağlantı ve etkileşimi çok iyi kullanan bir yapı oluşturmuştur. Yapay sinir ağlarının yapısında problem çözmede daha iyi sonuçlar elde etmek için birçok nöron birbirine bağlanır. Nöronlar, yapay sinir ağlarının en temel işlem birimidir. Nöronlar arasındaki etkileşim snapslar ile sağlanır. Bu snapsların belirli ağırlıkları vardır.



Şekil 4.6. Nöron temel yapısı

Şekil 4.6.'da görüldüğü gibi, $x \in \mathbb{R}^m$ giriş sinyallerini temsil eder, $w \in \mathbb{R}^m$ sapa ağırlığı, $b \in \mathbb{R}$ sapma olarak nitelendirilir. Giriş nöronlarının ağırlıklarının toplamı sıfır olduğunda öğrenmezler. Öğrenmenin gerçekleşmesi için giriş nöronlarının ağırlıklarının toplamının sıfırdan farklı bir değere sahip olması gerekir. Bias nöronlarının çıkışı 1 olduğundan, giriş nöronlarının ağırlıklarının toplamının her zaman sıfırdan farklı olmasını sağlar.

Çıkış sinyalini $y \in \mathbb{R}$ 'yi temsil etmektedir. y ifadesi Eş. 4.4'teki gösterildiği gibidir.

$$y = \varphi(\sum wx + b) \quad (4.4)$$

Nöron modelinde karşımıza çıkan bir diğer yapı ise Summing Function (Toplama Fonksiyonudur). Bu fonksiyon girişlerden gelen sinyalleri anlık ağırlıklarla çarparak toplar ve doğrusal olarak birleştirir. Çizelge 4.4.'te görüldüğü gibi toplama fonksiyonları toplama, çarpma, maksimum ve minimum gibi işlemlerden biri olarak ifade edilebilir.

Çizelge 4.4. Toplama fonksiyonları


Tanım	Eşitlik
Toplama	$NET = \sum_i^n W_{ji}x_i + \theta_j$
Çarpma	$NET = \prod_i W_{ji}x_i$
Minimum	$NET = Min(W_{ji}x_i)$
Maksimum	$NET = Max(W_{ji}x_i)$

Nöron yapısındaki Transfer Function (Transfer Fonksiyonu), toplama fonksiyonunun çıkış verilerini girdi olarak işler ve nöronun çıkış genliğini belirler. Transfer fonksiyonunun çeşitleri ve eşitlikleri Çizelge 4.5'teki gibidir.

Çizelge 4.5. Transfer fonksiyonu

Tanım	Eşitlik
Lineer Fonksiyon	$F(Net) = Net$
Step Fonksiyon	$F(Net) = \begin{cases} 1 & Net \geq \theta \\ 0 & Net < \theta \end{cases}$
Sigmoid Fonksiyon	$F(Net) = \frac{1}{1 + e^{-Net}}$
Threshold Fonksiyon	$F(Net) = \begin{cases} 0 & Net \leq 0 \\ Net & 0 < Net < 1 \\ 1 & Net \geq 1 \end{cases}$
Hyperbolic Tangent Fonksiyon	$F = \frac{e^{Net} + e^{-Net}}{e^{Net} - e^{-Net}}$

Transfer fonksiyonlarına ait fonksiyon grafikleri Şekil 4.7.'deki gibi tanımlanmaktadır.



Şekil 4.7. Transfer Fonksiyonlarının fonksiyon grafikleri a) Lineer Fonksiyon b) Step Fonksiyon c) Sigmoid Fonksiyon d)Eşik değeri Fonksiyon e) Hiperbolik Tanjant Fonksiyon

Genel literatürü incelediğimizde yapay sinir ağı algoritmalarının en önemlilerinden olan Bayesian Regularization, Levenberg – Marquardt ve Scaled Conjugate Gradient algoritmaları rüzgar enerjisi tahimini problemlerinde yüksek performans göstermektedir. Aynı zamanda bu algoritmalar MATLAB Neural Network Toolbox içinde yer almaktadır. Bu nedenle bu çalışmada 3 farklı yapay sinir ağı algoritması kullanılmıştır.

Ön işleme tamamlanan son veri seti, bahsedilen algoritmalarda öğrenme için kullanılmıştır. Önerilen modeli gerçekleştirmek için MATLAB Neural Network Fitting platformu kullanılmıştır. Bu çalışmada, rüzgâr enerjisi tahmin performansının gizli katman nöron sayısına, veri giriş nöron sayısına ve yapay sinir ağı algoritmasına bağlı olarak nasıl değiştiği karşılaştırılarak incelenmiştir.

5. DENEYLER VE SONUÇLARI

Yapay sinir ağları ve diğer yapay zekâ yöntemlerinin başarı düzeyini ölçmek için birçok performans metriği kullanılmaktadır. Çizelge 5.1’de bu performans metriklerinin neler olduğu görülmektedir. Bu tezde gerçekleştirilen her iki çalışma için MSE, RMSE ve R² performans metrikleri kullanılmıştır.

Çizelge 5.1. Performans metrikleri

Performans Metriği	Eşitlik
Mean Absolute Error	$MAE = \frac{1}{n} \sum_{i=1}^n y_i - y'_i $
Mean Squared Error	$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - y'_i)^2$
Root Mean Squared Error	$MSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - y'_i)^2}$
Mean Absolute Percentage Error	$MAPE = \frac{100}{n} \sum_{i=1}^n \left \frac{y_i - y'_i}{y_i} \right $
Decisive Coefficient	$R^2 = \left[\frac{\sum_{i=1}^n (y'_i - \bar{y}') (y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (y'_i - \bar{y}')^2 \sum_{i=1}^n (y_i - \bar{y})^2}} \right]^2$

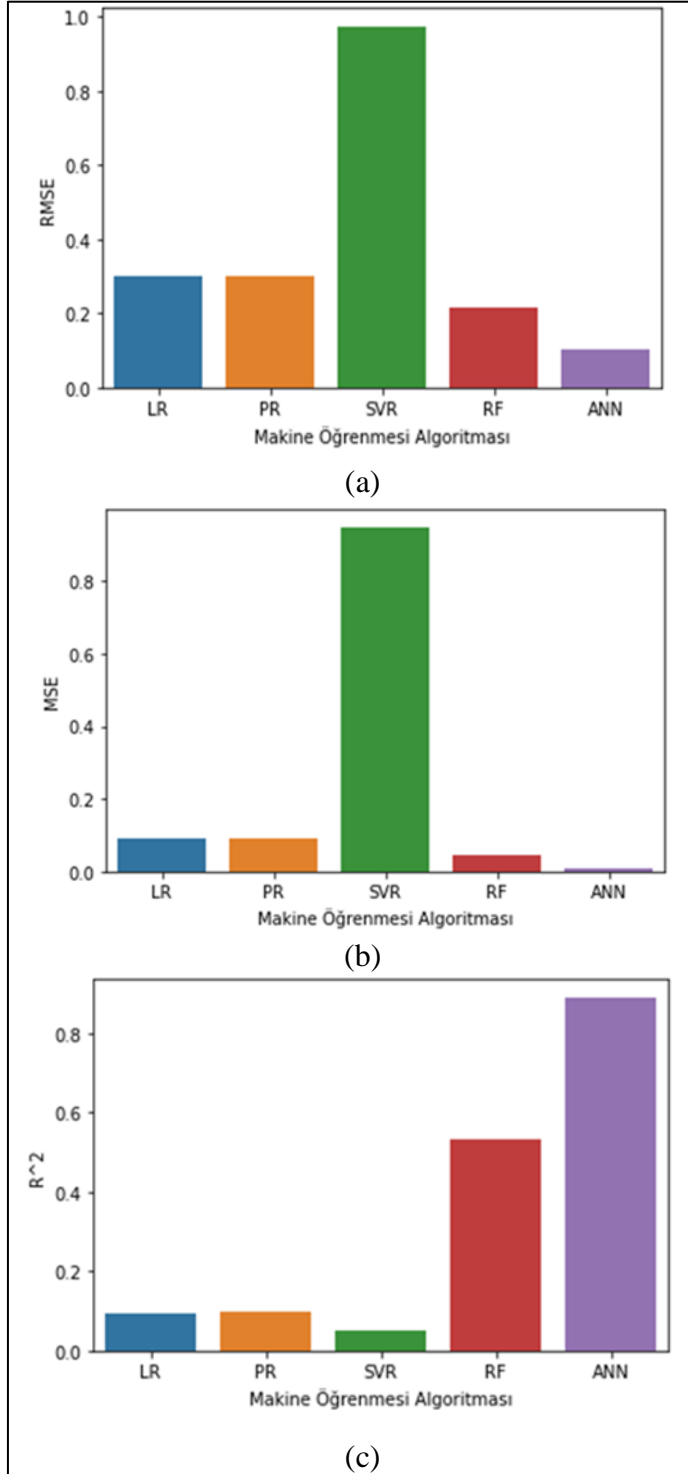
5.1. Makine Öğrenmesi Teknikleri ile Kısa Süreli Rüzgâr Enerjisi Tahmini

Kullanılan makine öğrenmesi modellerinin kısa süreli rüzgâr enerjisi tahminindeki performansı Çizelge 5.2’deki gibidir.

Çizelge 5.2. Makine öğrenmesi algoritmalarının performansları

Makine Öğrenmesi Algoritması	MSE	RMSE	R ²
Yapay Sinir Ağları	0.0107	0.1034	0.8905
Basit Doğrusal Regresyon	0.0901	0.3002	0.0935
Polinomal Regresyon	0.0914	0.3023	0.1004
Destek Vektör Regresyonu	0.9496	0.9745	0.0507
Rassal Orman	0.0474	0.2177	0.5331

Deney sonuçlarının daha iyi görülmesi adına Python Matplotlib kütüphanesi kullanılarak veri görselleştirme gerçekleştirilmiştir. Makine öğrenmesi algoritmalarının performanslarının grafiksel gösterimi Şekil 5.1.'de verilmiştir.



Şekil 5.1. Makine öğrenmesi algoritmalarının performansları a) RMSE, b) MSE, c) R²

(LR: Linear Regression / Doğrusal Regresyon - PR: Polynomial Regression / Polinomal Regresyon -SVR: Support Vector Regression / Destek Vektör Regresyonu – RF: Random Forest / Rassal Orman - ANN: Artificial Neural Network / Yapay Sinir Ağları)

Elde edilen sonuçlarda MSE, RMSE ve R^2 başarımlarına göre en iyi sonucu Yapay Sinir Ağları modeli elde etmiştir. Yapay Sinir Ağlarını sırasıyla Rassal Orman, Polinomal Regresyon ve Basit Doğrusal Regresyon algoritmaları takip etmiştir.

Deney sonuçları incelendiğinde Yapay Sinir Ağları modelinin lineer yapıda olmaması, eğitime kolayca adapte olabilme yeteneği, hataya karşı toleranslı olması gibi birçok avantaja sahip olması sayesinde bu problemin çözümü için en iyi performansı gösteren makine öğrenmesi algoritması olma başarısı göstermiştir. Rassal Orman algoritması sahip olduğu yapı sayesinde güçlü hiper parametreler kullanarak tahmin problemlerinde yüksek performans gösterebilmesine karşın yapılan deney sonuçlarına göre Rassal Orman algoritması, Yapay Sinir Ağları modeline göre daha düşük performans göstermektedir. Ayrıca rüzgâr enerjisinin sahip olduğu kararsız yapısından dolayı Basit Doğrusal Regresyon, Polinomal Regresyon ve Destek Vektör Makinesi algoritmalarının başarısının diğer iki modele göre düşük kaldığı görülmektedir.

5.2. Yapay Sinir Ağları ile Kısa Süreli Rüzgâr Enerjisi Tahmini

Bu çalışmada iki farklı deney yürütülmektedir. İlk bölümde, modelimizin elektrik üretimi tahmin performansını doğrulamayı amaçlayan deneyler, farklı sayıda günlük veriler kullanılarak gerçekleştirilmiştir. İkinci bölümde, önerilen yöntemin performansını literatüründeki diğer iyi bilinen modellerle karşılaştırmak için deneyler yapılmıştır.

Çalışmada sırasıyla 3 günlük, 7 günlük ve 15 günlük girdi verilerine dayalı olarak 1 günlük rüzgâr enerjisi üretim tahmini yapmak için 3 farklı deney yapılmıştır. Tüm bu deneyler, rüzgâr enerjisi üretim performanslarını farklı giriş nöron sayıları ve gizli katman nöron sayılarına göre karşılaştırmak için yukarıda belirtilen 3 yapay sinir ağı algoritmasını içermektedir. Her deneyde 1 giriş, 1 gizli ve 1 çıkış katmanı kullanılmış ve giriş katmanları 3 günlük, 7 günlük ve 15 günlük giriş verilerine uygun 3 nöron, 7 nöron ve 15 nöron olmak üzere 3 farklı formda seçilmiştir. Ayrıca gizli katmandaki nöron sayısı deneylerde kullanılan algoritmalarla birlikte 10 nöron, 15 nöron ve 20 nöron olarak değiştirilmiştir. Deneyler

sırasında çıkış katmanı nöron sayısı sürekli olarak 1 olup, 1 günlük rüzgâr enerjisi üretim tahminini temsil etmektedir.

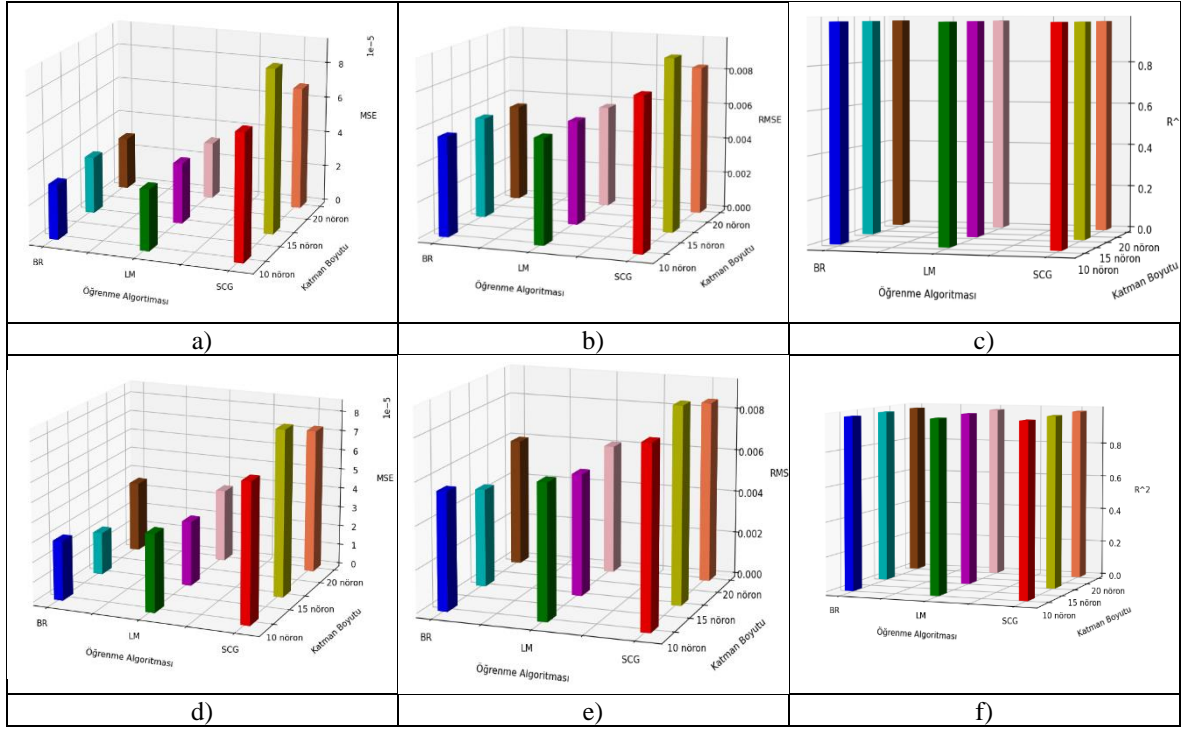
Tüm deneylerde eğitim verisi %70, doğrulama verisi %15 ve test verisi %15 olarak alınmıştır. Ayrıca tüm deneylerde eğitim, validasyon ve test süreçlerinde hesaplanan MSE, RMSE ve R^2 değerleri raporlanmaktadır. Bayesian Regularization algoritması validasyon işlemi yapmadığı için bu algortmada doğrulama işlemi için veri ayrılmamıştır. Bu nedenle verilen sonuç tablolarının bütünlüğü korunarak bu durumu belirtmek için Bayes Regularization algoritmasının doğrulama işlemi için MSE, RMSE ve R^2 değerleri aşağıdaki sonuçlarda “-” olarak gösterilmiştir. MSE ve RMSE metriklerinin sıfıra yakın olması yüksek başarıyı ifade ederken, R^2 metriğinin 1’e yakın olması yüksek başarıyı belirtmektedir.

İlk deneyde 3 günlük girdi verileri ile farklı gizli katman nöron sayıları ve öğrenme algoritmalarına dayalı 1 günlük rüzgâr enerjisi üretim tahmini yapılmıştır. Deneyin sayısal sonuçları Çizelge 5.3’te verilmiştir ve Şekil 5.2’te sonuçlar 3 boyutlu çubuk grafikler şeklinde gösterilmiştir.

Çizelge 5.3. Üç günlük girdi verileri ile 1 günlük rüzgâr enerjisi üretim tahmini sonuçları

Öğrenme Algoritması	Katman Boyutu	MSE (Eğitim)	MSE (Doğrulama)	MSE (Test)	RMSE (Eğitim)	RMSE (Doğrulama)	RMSE (Test)	R^2 (Eğitim)	R^2 (Doğrulama)	R^2 (Test)
BR	10 nöron	3.0459e-05	-	2.9855e-05	0.0055	-	0.0055	0.9990	-	0.9992
LM	10 nöron	3.3911e-05	3.6902e-05	3.9123e-05	0.0058	0.0061	0.0063	0.9990	0.9990	0.9990
SCG	10 nöron	7.0187e-05	1.0125e-05	6.9955e-05	0.0084	0.0032	0.0084	0.9980	0.9972	0.9980
BR	15 nöron	3.1709e-05	-	2.1427e-05	0.0056	-	0.0046	0.9990	-	0.9994
LM	15 nöron	3.3893e-05	3.9630e-05	3.2680e-05	0.0058	0.0063	0.0057	0.9990	0.9990	0.9990
SCG	15 nöron	9.1676e-05	8.8236e-05	8.4084e-05	0.0096	0.0094	0.0092	0.9974	0.9974	0.9974
BR	20 nöron	2.9271e-05	-	3.5750e-05	0.0054	-	0.0060	0.9990	-	0.9990
LM	20 nöron	3.1926e-05	2.9162e-05	3.6840e-05	0.0057	0.0054	0.0061	0.9990	0.9992	0.9988
SCG	20 nöron	6.8629e-05	7.9083e-05	7.2921e-05	0.0083	0.0089	0.0085	0.9980	0.9978	0.9980

(BR: Bayesian Regularization, LM: Levenberg – Marquardt, SCG: Scaled Conjugate Gradient)



Şekil 5.2. Üç günlük girdi verileriyle 1 günlük rüzgar enerjisi üretim sonuçlarının çubuk grafikleri: a) MSE (Eğitim) performansı, b) RMSE (Eğitim) performansı, c) R² (Eğitim) performansı, d) MSE (Test) performansı, e) RMSE (Test) performansı ve f) R² (Test) performansı.

Çizelge 5.3. ve Şekil 5.2.'de görüldüğü gibi 10 nöron için MSE ve RMSE performans metrik sonuçlarına göre BR algoritması eğitim ve test süreçlerinde diğer algoritmalara göre daha iyi sonuçlar elde etmiş, bunu sırasıyla LM ve SCG algoritmaları izlemiştir. Ayrıca doğrulama sürecinde en iyi sonucu SCG algoritması elde etmiş, bunu LM takip etmiştir. 10 nöron için, R² performans metriğine göre eğitim sürecinde en iyi performansı BR ve LM algoritmaları elde etmiş, bunu SCG takip etmiştir. Ayrıca LM algoritması, doğrulama sürecinde SCG'den daha iyi performans göstermiştir. Test sürecinde BR algoritması diğer algoritmalara göre daha iyi sonuçlar elde etmiş, bunu sırasıyla LM ve SCG algoritmaları izlemiştir.

15 nöron için, MSE ve RMSE performans metrikleri sonuçlarına göre, BR algoritması eğitim ve test süreçlerinde diğer algoritmalara göre daha iyi sonuçlar elde etmiş, bunu sırasıyla LM ve SCG algoritmaları izlemiştir. LM algoritması, doğrulama sürecinde SCG'den daha iyi performans göstermiştir. 15 nöron için, R² performans metriğine göre eğitim sürecinde en iyi performansı BR ve LM algoritmaları elde etmiş, bunu SCG takip etmiştir. Ayrıca doğrulama sürecinde LM algoritması SCG'den daha iyi sonuçlar elde etmiştir. Test

sürecinde BR algoritması diğer algoritmalara göre daha iyi sonuçlar elde etmiş, bunu sırasıyla LM ve SCG algoritmaları izlemiştir.

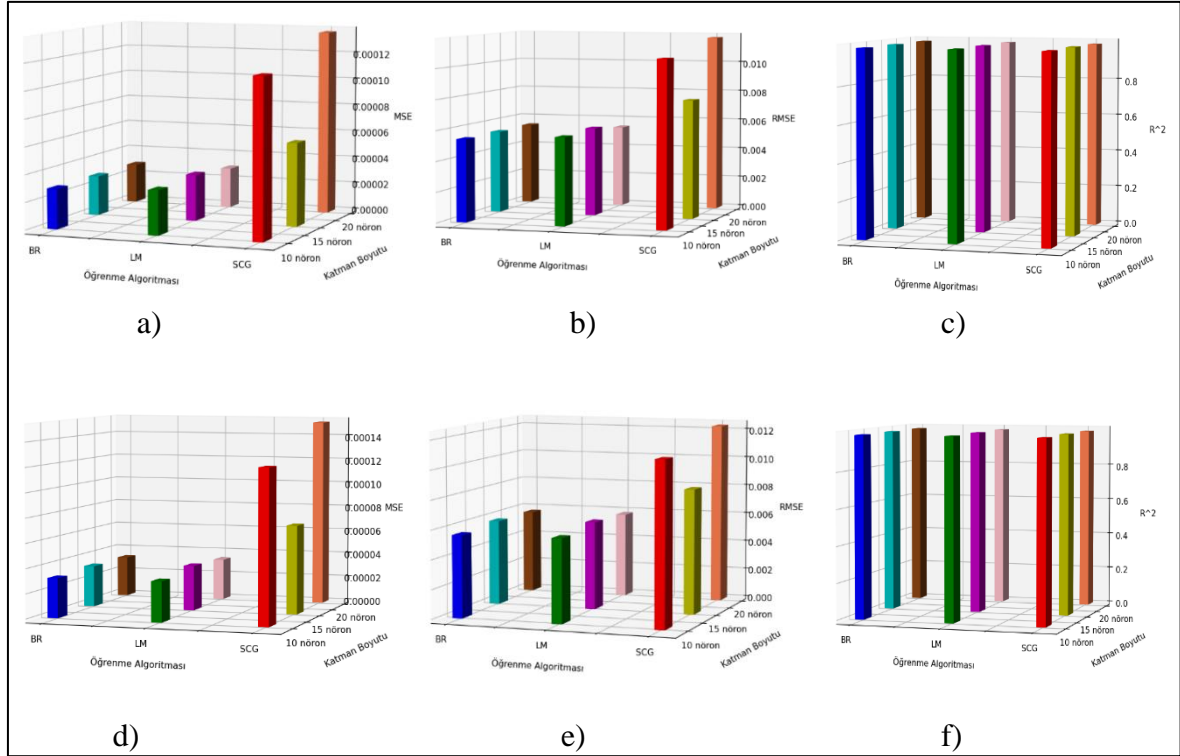
20 nöron için MSE ve RMSE performans metrikleri sonuçlarına göre eğitim ve test süreçlerinde en iyi başarıyı BR algoritması elde etmiştir. BR algoritmasından sonra en başarılı algoritmalar sırasıyla LM ve SCG olmuştur. LM, doğrulama sürecinde SCG'den daha iyi performans göstermiştir. 20 nöron için, R2 performans metriğine göre eğitim sürecinde en iyi performansı BR ve LM algoritmaları elde etmiş, bunu SCG takip etmiştir. Ayrıca doğrulama sürecinde LM algoritması SCG'den daha iyi sonuçlar elde etmiştir. Test sürecinde BR algoritması diğer algoritmalara göre daha iyi sonuçlar elde etmiş, bunu sırasıyla LM ve SCG algoritmaları izlemiştir.

İkinci deneyde ise 7 günlük girdi verileri ile farklı gizli katman nöron sayıları ve öğrenme algoritmalarına dayalı 1 günlük rüzgâr enerjisi üretim tahmini gerçekleştirilmiştir. Deneyin sayısal sonuçları Çizelge 5.4'te verilmiştir ve Şekil 5.3'te sonuçlar 3 boyutlu çubuk grafikler şeklinde gösterilmiştir.

Çizelge 5.4. Yedi günlük girdi verileriyle 1 günlük rüzgâr enerjisi üretim tahmini sonuçları

Öğrenme Algoritması	Katman Boyutu	MSE (Eğitim)	MSE (Doğrulama)	MSE (Test)	RMSE (Eğitim)	RMSE (Doğrulama)	RMSE (Test)	R ² (Eğitim)	R ² (Doğrulama)	R ² (Test)
BR	10 nöron	2.9243e-05	-	3.1698e-05	0.0054	-	0.0056	0.9992	-	0.9990
LM	10 nöron	3.2259e-05	3.2259e-05	3.2259e-05	0.0057	0.0057	0.0057	0.9990	0.9992	0.9990
SCG	10 nöron	1.1580e-04	1.3959e-04	1.2289e-04	0.0108	0.0118	0.0111	0.9966	0.9962	0.9962
BR	15 nöron	2.9057e-05	-	3.3076e-05	0.0054	-	0.0058	0.9992	-	0.9990
LM	15 nöron	3.3891e-05	4.1205e-05	3.6145e-05	0.0058	0.0064	0.0060	0.9990	0.9988	0.9988
SCG	15 nöron	6.0928e-05	6.2767e-05	7.1428e-05	0.0078	0.0079	0.0085	0.9982	0.9982	0.9978
BR	20 nöron	2.8767e-05	-	3.2469e-05	0.0054	-	0.0057	0.9992	-	0.9990
LM	20 nöron	2.9537e-05	3.3230e-05	3.3370e-05	0.0054	0.0058	0.0058	0.9992	0.9990	0.9990
SCG	20 nöron	1.3588e-04	1.3660e-04	1.5114e-04	0.0117	0.0117	0.0123	0.9960	0.9960	0.9956

(BR: Bayesian Regularization, LM: Levenberg – Marquardt, SCG: Scaled Conjugate Gradient)



Şekil 5.3. Yedi günlük girdi verileriyle 1 günlük rüzgâr enerjisi üretim sonuçlarının çubuk grafikleri: a) MSE (Eğitim) performansı, b) RMSE (Eğitim) performansı, c) R² (Eğitim) performansı, d) MSE (Test) performans, e) RMSE (Test) performansı ve f) R² (Test) performansı.

Çizelge 5.4. ve Şekil 5.3.'te görüldüğü gibi 10 nöron için MSE ve RMSE performans metrik sonuçlarına göre BR algoritması eğitim ve test süreçlerinde diğer algoritmalara göre daha iyi sonuçlar elde etmiş, bunu sırasıyla LM ve SCG algoritmaları izlemiştir. Ayrıca doğrulama sürecinde en iyi sonucu LM algoritması elde etmiş, bunu SCG takip etmiştir. 10 nöron için, R² performans metriğine göre eğitim sürecinde en iyi performansı BR algoritması elde etmiş, bunu sırasıyla LM ve SCG takip etmiştir. Ayrıca LM algoritması, doğrulama sürecinde SCG'den daha iyi performans göstermiştir. Test sürecinde, BR ve LM aynı performansı elde ederek SCG'nin performansını geride bırakmıştır.

15 nöron için, MSE ve RMSE performans metrikleri sonuçlarına göre, BR algoritması eğitim ve test süreçlerinde diğer algoritmalara göre daha iyi sonuçlar elde etmiş, bunu sırasıyla LM ve SCG algoritmaları izlemiştir. LM algoritması, doğrulama sürecinde SCG'den daha iyi performans göstermiştir. 15 nöron için, R² performans metriğine göre BR algoritması, eğitim ve test süreçlerinde diğer iki algoritmadan daha iyi performans göstermiştir. BR

algoritmasını sırasıyla LM ve SCG izlemiştir. Ayrıca doğrulama sürecinde LM algoritması SCG'den daha iyi sonuçlar elde etmiştir.

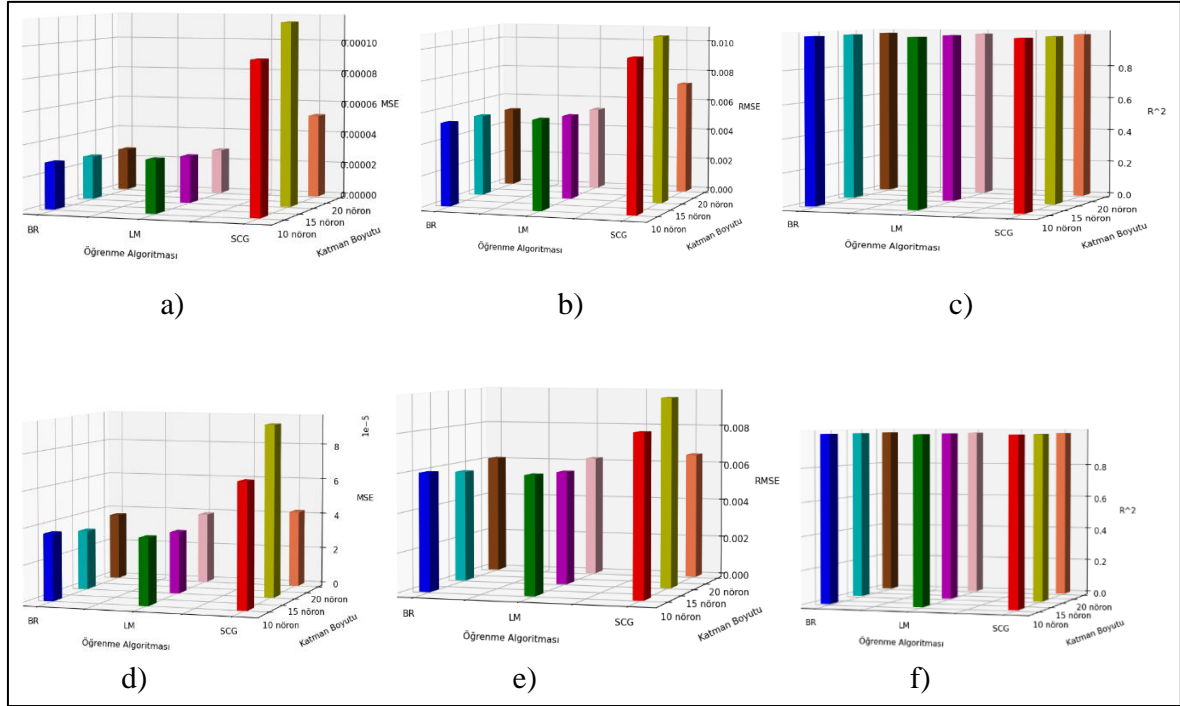
20 nöron için MSE ve RMSE performans metrikleri sonuçlarına göre eğitim ve test süreçlerinde en iyi başarıyı BR algoritması elde etmiştir. BR algoritmasından sonra en başarılı algoritmalar sırasıyla LM ve SCG olmuştur. LM, doğrulama sürecinde SCG'den daha iyi performans göstermiştir. 20 nöron için R^2 performans metriğine göre BR ve LM algoritmaları eğitim ve test süreçlerinde aynı performansı göstererek SCG'nin önünde yer almıştır. Ayrıca doğrulama sürecinde LM algoritması SCG'den daha iyi sonuçlar elde etmiştir.

Üçüncü deneyde ise 15 günlük girdi verileri ile farklı gizli katman nöron sayıları ve öğrenme algoritmalarına dayalı 1 günlük rüzgâr enerjisi üretim tahmini yapılmıştır. Deneyin sayısal sonuçları Çizelge 5.5'te verilmiştir ve Şekil 5.4'te sonuçlar 3 boyutlu çubuk grafikler şeklinde gösterilmiştir.

Çizelge 5.5. On beş günlük girdi verileriyle 1 günlük rüzgâr enerjisi üretim tahmini sonuçları

Öğrenme Algoritması	Katman Boyutu	MSE (Eğitim)	MSE (Doğrulama)	MSE (Test)	RMSE (Eğitim)	RMSE (Doğrulama)	RMSE (Test)	R^2 (Eğitim)	R^2 (Doğrulama)	R^2 (Test)
BR	10 nöron	2.8586e-05	-	3.6583e-05	0.0053	-	0.0060	0.9992	-	0.9988
LM	10 nöron	3.2572e-05	3.0942e-05	3.6394e-05	0.0057	0.0056	0.0060	0.9990	0.9990	0.9990
SCG	10 nöron	9.3712e-05	7.8849e-05	6.7910e-05	0.0097	0.089	0.0082	0.9972	0.9976	0.9990
BR	15 nöron	2.6816e-05	-	3.2728e-05	0.0052	-	0.0057	0.9992	-	0.9990
LM	15 nöron	2.9019e-05	3.5784e-05	3.3928e-05	0.0054	0.0060	0.0058	0.9992	0.9990	0.9990
SCG	15 nöron	1.1397e-04	1.0703e-04	9.4692e-05	0.0107	0.0103	0.0097	0.9968	0.9968	0.9972
BR	20 nöron	2.6200e-05	-	3.6798e-05	0.0051	-	0.0061	0.9992	-	0.9990
LM	20 nöron	2.7673e-05	3.6484e-05	3.8998e-05	0.0053	0.0060	0.0062	0.9992	0.9988	0.9988
SCG	20 nöron	5.1931e-05	4.1143e-05	4.2169e-05	0.0072	0.0065	0.0065	0.9984	0.9988	0.9988

(BR: Bayesian Regularization, LM: Levenberg – Marquardt, SCG: Scaled Conjugate Gradient)



Şekil 5.4. On beş günlük girdi verileriyle 1 günlük rüzgâr enerjisi üretim sonuçlarının çubuk grafikleri: a) MSE (Eğitim) performansı, b) RMSE (Eğitim) performansı, c) R^2 (Eğitim) performansı, d) MSE (Test) performans, e) RMSE (Test) performansı ve f) R^2 (Test) performansı.

Çizelge 5.5. ve Şekil 5.4.'te görüldüğü gibi, 10 nöron için, MSE ve RMSE performans metrikleri sonuçlarına göre, eğitim sürecinde en iyi sonuçları elde eden BR algoritmasıdır, bunu sırasıyla LM ve SCG takip etmiştir. LM algoritması doğrulama süreçlerinde en iyi sonuçları elde eden algoritma olmuştur. 10 nöron için, R^2 performans metriğine göre eğitim sürecinde en iyi performansı BR algoritması elde etmiştir. Bu algoritmayı sırasıyla LM ve SCG algoritmaları takip etmiştir. Ayrıca doğrulama sürecinde en iyi sonuçları LM algoritması elde etmiştir. SCG algoritması sırasıyla LM algoritmasından sonra en iyi performansı elde eden algoritma olmuştur. LM ve SCG algoritmaları, test sürecinde BR algoritmasından daha iyi performans göstermiştir.

15 nöron için MSE ve RMSE performans metrikleri sonuçlarına göre eğitim ve test süreçlerinde en iyi sonuçları BR algoritması elde etmiştir. Bu algoritmayı sırasıyla LM ve SCG algoritmaları takip etmektedir. Doğrulama sürecinde en iyi sonuçları LM algoritması elde etmiştir. 15 nöron için R^2 performans metriğine göre BR ve LM algoritmaları eğitim ve test süreçlerinde aynı performansı elde etmiştir. Bu algoritmaları SCG algoritması takip

etmektedir. Ayrıca doğrulama sürecinde LM algoritması SCG algoritmalarından daha iyi performans göstermiştir.

20 nöron için MSE ve RMSE performans metrikleri sonuçlarına göre eğitim ve test süreçlerinde en iyi sonuçları elde eden algoritma BR algoritması olmuştur. Bu algoritmayı sırasıyla LM ve SCG algoritmaları takip etmiştir. Ayrıca LM algoritması doğrulama sürecinde en iyi sonuçları elde eden algoritma olmuştur. 20 nöron için R^2 performans metriğine göre BR ve LM algoritmaları eğitim sürecinde aynı performansı elde etmiş ve SCG algoritmasından daha iyi sonuçlar elde etmiştir. LM ve SCG algoritmaları, doğrulama ve test sürecinde aynı performansı elde etmiştir. Ayrıca BR algoritması, test sürecinde LM ve SCG algoritmalarından daha iyi performans göstermiştir.

Ayrıca zaman serisi verileri üzerinde tahmin problemlerinde önerilen modeli diğer yöntemlerle karşılaştırmak için farklı deneyler yapılmıştır. Autoregressive Integrated Moving Average (ARIMA), Random Forest Regression (RFR) ve Persistence Model (PM) algoritmaları bu konuda en bilinen algoritmalarlardır. Bu nedenle, önceki doğrulama deneylerinde kullanılan aynı veri setinde karşılaştırma amacıyla seçilmiştir.

İlk olarak kısa süreli tahminler için oldukça doğru sonuçlar veren Persistence Model, bir referans oluşturmak için bu çalışmada hazırlanan veri seti üzerinde tahmin yapmak için kullanılmıştır. Persistence Model, genellikle bir tahmin modelinin performansını değerlendirmek için referans olarak kullanılır, önerilen modelin başarılı olduğunu tespit etmek için Persistence Model'den daha iyi sonuçlar vermesi beklenir.

Persistence Modelinin eğitimi için kullanılacak veri seti Python Numpy ve Pandas kütüphaneleri kullanılarak hazırlanmıştır. Python Jupyter geliştirme ortamı kullanılarak Persistence Modeli uygulanmıştır. Hazırlanan veri seti üzerinde ileri doğru doğrulama işlemi yapılarak gözlenen değerler eğitim verisine tekrar eklenmiş ve işlem tekrarlanmıştır. Persistence Modelinin tahmin performansı $R^2=0.8408$, $MSE=5.27e-02$ ve $RMSE=0.2297$ olarak gözlemlenmiştir.

Karşılaştırma için kullanılan ikinci tahmin modeli, zaman serisi verileri üzerinde tahmin problemlerini çözmede başarılı olan önemli bir model olan ARIMA'dır. ARIMA öncesinde zaman serisinin durağan olup olmadığını belirlemek için Augmented Dickey Fuller (ADF)

testi uygulanmıştır. Elde edilen sonuçlara göre sıfır hipotezi $p=0.01$ olarak reddedilmiştir, bu da zaman serisi verilerimizin durağan olduğu ve ARIMA'nın durağanlık varsayımını karşıladığı anlamına gelmektedir. ARIMA modelinin parametreleri Çizelge 5.5'teki gibi ayarlanmıştır. Ardından Python'da otomatik ARIMA paketi kullanılarak tahmin yapılmıştır. Sonuçlar, modelin otoregresif terim katsayısının 0,8816 değeri ile istatistiksel olarak anlamlı olduğunu ($p \approx 0$) ortaya koymuştur. Ljung-Box'ın 0.12'lik bir p değeri verdiği görülmüştür; bu, parazitler arasındaki korelasyonların anlamlı olmadığı ve modelin parazitlerinin bağımsız olduğu varsayımını da karşıladığı anlamına gelmektedir. Modelin tahmin doğruluğunu belirlemek için R^2 , MSE ve RMSE performans metrikleri kullanılmıştır. ARIMA modelinin tahmin performansı $R^2= 0.572$, $MSE=1.6995e-04$ ve $RMSE=0.0130$ olduğu gözlemlenmiştir.

Çizelge 5.6. ARIMA algoritmasında kullanılan parametreler

Parametre	Değer	Açıklama
p	0	Otoregresif modelin sırası
d	1	Farklılaşma derecesi
q	0	Hareketli Ortalama modelin sırası
P	0	Mevsimsel Oto Regresif modelin sırası – SAR Order
D	1	Mevsimsel Entegre sırası - SI Order
Q	0	Mevsimsel Hareketli Ortalama sırası - SMA Order

Üçüncü ve son olarak, regresyon için başarılı ve yaygın olarak kullanılan bir toplu öğrenme yöntemi olan Rastgele Orman Regresyonu kullanılmıştır. Bu model, daha doğru tahminler yapmak için çoklu karar ağaçları kullanmaktadır. Random Forest Regresyon modeli için belirlenen parametreler şu şekildedir: $n_estimators=50$ (ormandaki ağaç sayısı) ve $max_depth=50$ (ağaçların maksimum derinliği). Bu parametreler kullanılarak Python `sklearn.ensemble` modülünde yer alan `RandomForestRegressor` modeli kullanılarak tahmin yapılmıştır. Bu modelin performansı $R^2= 0.9911$, $MSE=3.01e-04$ ve $RMSE=0.0174$ olarak belirlenmiştir.


Bu karşılaştırma deneyleri setinde kullanılan modellerin tüm tahmin performansı sonuçları, önceki doğrulama deneyleri bölümünde elde edilen en iyi performans (3 günlük girdi verileriyle 1 günlük rüzgâr enerjisi üretimi tahmin sonuçları) ile Çizelge 5.6'da gösterilmektedir. Bu tabloda görüldüğü gibi önerilen model MSE ve RMSE performans ölçütlerine göre en yüksek başarıyı göstermiş, bunu ikinci sırada ARIMA, üçüncü sırada

RFR ve son sırada PM izlemiştir. Ayrıca, önerilen model aynı zamanda R^2 performans metriğine göre en başarılı algoritma olmuş, onu sırasıyla RFR, PM ve ARIMA izlemiştir.

Çizelge 5.7. Algoritmaların tahmin performansı karşılaştırması

Algoritma	MSE	RMSE	R^2
Önerilen Model	2.1427e-05	0.0046	0.9994
RFR	3.01e-04	0.0174	0,9911
ARIMA	1.6995e-04	0.0130	0,572
PM	5.27e-02	0.2297	0,8408

Bu sonuçların farkını daha net görebilmek için Çizelge 5.7’de belirtilen değerler Şekil 5.5’te çubuk grafikler olarak verilmiştir.



Şekil 5.5. a) MSE, b) RMSE, c) R^2 metriklerine göre algoritmaların tahmin performansının çubuk grafikleri

6. SONUÇ VE ÖNERİLER

Bu tezde iki farklı çalışma yapılmış olup birinci çalışmada kısa süreli rüzgar enerjisi tahmini için beş adet makine öğrenmesi tekniği kullanılmıştır. Deney sonuçlarından bu problemin çözümü için en iyi performans gösteren makine öğrenmesi tekniklerinin rassal orman (random forest) ve yapay sinir ağları modellerinin olduğu görülmektedir. Her iki algoritmanın sayısal verilerde yüksek performans göstermesi ve aykırı verilere karşı toleranslı olması rüzgar enerjisi gibi zamana bağlı kararsız yapıda olan bir zaman serisi şeklindeki veri seti üzerinde başarılı olmasını sağlayan unsurlar olarak karşımıza çıkmaktadır. Bu çalışmada yüksek performans gösteren yapay sinir ağları modeli için kullanılan öğrenme algoritmalarının performansını karşılaştırmak amacıyla ikinci bir çalışma yapılmıştır. İkinci çalışmada elde edilen bulgularda yapay sinir ağları için kullanılan öğrenme algoritmalarının yüksek performans gösterdiği görülmektedir.

Bu tezde gerçekleştirilen iki çalışma için yapılan deneylerde elde edilen yüksek başarı sayesinde elektrik enerjisi üretiminde yenilenebilir enerji kaynaklarından elde edilebilecek maksimum fayda, klasik yöntemler dışında daha basit yapay zekâ tabanlı tahmin yöntemleri ile daha verimli bir şekilde sağlanabilmektedir. Bu sayede fosil yakıt ürünlerine dayalı elektrik üretim oranı düşürülerek hem ekonomik cari denge sağlanabilecek hem de fosil yakıt ürünlerinin neden olduğu iklim değişikliği ve çevre kirliliği önlenilecektir. İklim değişikliğinin neden olduğu büyük doğal afetler ve önlenemez zararlar kontrol altına alınabilir.

Klasik yöntemlerle makro elektrik enerjisi üretimini planlamak yerine, her santrale özel mikro düzeyde yapay zekâ destekli üretim tahmin modelleri üreterek yenilenebilir enerji kaynakları ile elektrik üretimini maksimize ederek enerji arz güvenliği en verimli şekilde gerçekleştirilebilir. Bu sayede sanayi ve tarım sektörünün en büyük girdi maliyetlerinden biri olan elektrik enerjisinin üretim maliyetleri kontrol altına alınabilir.

Ayrıca bu çalışma sonucunda rüzgâr santrallerinde kestirimci bakım ve planlı bakım yönetimi daha verimli hale getirilebilir ve santral işletme maliyetleri minimize edilebilir.

Yapılan çalışmalarda rüzgâr enerjisinin kararsız yapısı dolayısıyla aykırı verilerin makine öğrenmesi yöntemlerinin öğrenmesini olumsuz etkilememesi için Min-Max Normalizasyon

ve D-Min-Max Normalizasyon tekniđi kullanılmıřtır. Farklı normalizasyon teknikleri kullanılarak yapılabilecek veri ön iřleme sürecinden sonra elde edilecek veri setleri üzerinde deneyde kullanılan makine öğrenmesi tekniklerinin performansı daha da arttırılabilir.

Tez çalışmasında veri ön iřleme tekniđi olarak, aykırı verileri temizleme ve normalizasyon teknikleri kullanılmıřtır. Literatürde veri ön iřleme için kullanılabilir bir çok teknik yer almaktadır. Bu tekniklerin kullanılması ile yapılan deneylerde kullanılan makine öğrenmesi modellerinin başarı oranı daha fazla arttırılabilir.

Bunun yanında, deneylerde kullanılan makine öğrenmesi tekniklerine ait çok sayıda parametrelerin katsayılarını optimize edilerek bu modellerin daha fazla başarılı olmasını sağlayabilir.

Tez çalışmasında, kısa süreli rüzgâr enerjisi tahmini problemi için en çok kullanılan makine öğrenmesi algoritmaları tercih edilmiřtir. Bu yüzden bu tezde yer almayan diđer makine öğrenmesi yöntemlerinin bu problemin çözümündeki başarısı ölçülememiřtir.

Ayrıca tez çalışmasında gerçek dünya verileri kullanıldığı için kısa süreli rüzgâr enerjisi tahmini problemlerinde yüksek başarı gösteren LSTM ve RNN gibi derin öğrenme teknikleri bu problemin çözümünde başarılı olamamıřtır. Literatürde bu problemin çözümünde kullanılan bu derin öğrenme tekniklerinin öğrenmesi için gereken veri miktarı yaklaşık 60.000 adet üzerindedir. Rüzgâr enerjisinden elektrik enerjisi elde etmek için kurulan rüzgâr elektrik santralleri yaklaşık on yıllık bir geçmiş sahip olduđu için bu miktardaki veriyi elde etmek bugün itibariyle oldukça zordur. İleriki zamanlarda veri adedi yükseldikçe derin öğrenme tekniklerinin kısa süreli rüzgâr enerjisi üretimi tahmini probleminin çözümünde kullanılma oranı artacaktır.

Gelecekte, kısa vadeli rüzgâr enerjisi tahmin problemlerinde hibrit modeller oluşturularak daha iyi performans elde edilebilir. Ayrıca uzun vadeli rüzgâr enerjisi tahmin problemlerinin çözümü için yapay sinir ađları modellerinin yüksek performansı için yeni modeller üzerinde çalışılabilir.

Gelecekte, kısa vadeli rüzgâr enerjisi tahmin problemlerinde hibrit modeller oluşturularak daha iyi performans elde edilebilir. Ayrıca uzun vadeli rüzgâr enerjisi tahmin problemlerinin

özümü için yapay sinir ađları modellerinin yüksek performansı için yeni modeller üzerinde çalışılabilir.

KAYNAKLAR

1. İnternet: International Energy Agency (2023). *Fuels and technologies electricity*, Web: <https://www.iea.org/fuels-and-technologies/electricity>, Son Erişim Tarihi:09.07.2023.
2. İnternet: Ticaret Bakanlığı (2022). *Republic of Turkey ministry of trade 20 chapters with the most imports*, Web: <https://ticaret.gov.tr/data/5d63d89d13b8762f7c43a738/4En%20Fazla%20Ithalat%20Yapilan%2020%20Fasil.pdf>, Son Erişim Tarihi: 22.01.2022.
3. İnternet: Ticaret Bakanlığı (2022). *Repuclic of Turkey ministry of trade foreign trade data by years*. Web: <https://ticaret.gov.tr/data/5d63d89d13b8762f7c43a738/1Yillara%20Gore%20Dis%20Ticaret.pdf>, Son Erişim Tarihi:22.01.2022.
4. İnternet: International Renewable Energy Agency (2022). *Country rankings*, Web: <https://www.irena.org/Statistics/View-Data-by-Topic/Capacity-and-Generation/Country-Rankings>, Son Erişim Tarihi:22.01.2022.
5. İnternet: United Nations Climate Change (2022). *The Paris agreement*, Web: <https://unfccc.int/process-and-meetings/the-paris-agreement/the-paris-agreement>, Son Erişim Tarihi:14.03.2022.
6. İnternet: Enerji.gov.tr (2022). *Republic of Turkey ministry of energy and natural resources 2019 - 2023 Stratejik Planı*. Web: https://sp.enerji.gov.tr/ETKB_2019_2023_Stratejik_Planı.pdf, Son Erişim Tarihi:22.01.2022
7. İnternet: International Renewable Energy Agency (2023). *Technologies*, Web: <https://www.irena.org/Statistics/View-Data-by-Topic/Capacity-and-Generation/Technologies>, Son Erişim Tarihi:09.07.2023
8. İnternet: Republic of Turkey Ministry of Energy and Natural Resources (2023). *Türkiye elektrik üretim iletişim istatistikleri*, Web:<https://www.teias.gov.tr/turkiye-elektrik-uretim-iletim-istatistikleri>, Son Erişim Tarihi:15.04.2023
9. İnternet: International Renewable Energy Agency (2022). *Country rankings*, Web: <https://www.irena.org/Statistics/View-Data-by-Topic/Capacity-and-Generation/Country-Rankings>,SonErişim Tarihi:22.01.2022
10. Tawn, R. and Browell, J. (2022). A review of very short-term wind and solar power forecasting. *Renewable and Sustainable Energy Reviews*, 153(2), 111758.
11. Wang, Y., Zou, R., Liu, F., Zhang, L. and Liu, Q. (2021). A review of wind speed and wind power forecasting with deep neural networks. *Applied Energy*, 304(2), 117766.
12. Alkhayat, G. and Mehmood, R. (2021). A review and taxonomy of wind and solar energy forecasting methods based on deep learning. *Energy and AI*, 4, 100060.

13. Liu, H., Li, Y., Duan, Z. and Chen, C. (2020). A review on multi-objective optimization framework in wind energy forecasting techniques and applications. *Energy Conversion and Management*, 224, 113324.
14. Chen, H., Birkelund, Y. and Zhang, Q. (2021). Data-augmented sequential deep learning for wind power forecasting. *Energy Conversion and Management*, 248, 114790.
15. Khazaei, S., Ehsan, M., Soleymani, S. and Mohammadnezhad-Shourkaei, H. (2022). A high-accuracy hybrid method for short-term wind power forecasting. *Energy*, 238, 122020.
16. Xiong, B., Lou, L., Meng, X., Wang, X., Ma, H. and Wang, Z. (2022). Short-term wind power forecasting based on Attention Mechanism and Deep Learning. *Electric Power Systems Research*, 206, 107776.
17. Dong, Y., Zhang, H., Wang, C. and Zhou, X. (2021). Wind power forecasting based on stacking ensemble model, decomposition and intelligent optimization algorithm. *Neurocomputing*, 462, 169–184.
18. He, B., Ye, L., Pei, M., Lu, P., Dai, B., Li, Z. and Wang, K. (2022). A combined model for short-term wind power forecasting based on the analysis of numerical weather prediction data. *Energy Reports*, 8, 929–939.
19. Dumitru, C. D. and Gligor, A. (2019). Wind energy forecasting: a comparative study between a stochastic model (ARIMA) and a model based on neural network (FFANN). *Procedia Manufacturing*, 32, 410–417.
20. Liu, X., Zhou, J. and Qian, H. (2021). Short-term wind power forecasting by stacked recurrent neural networks with parametric sine activation function. *Electric Power Systems Research*, 192, 107011.
21. Ogliari, E., Guilizzoni, M., Giglio, A. and Pretto, S. (2021). Wind power 24-h ahead forecast by an artificial neural network and an hybrid model: Comparison of the predictive performance. *Renewable Energy*, 178, 1466–1474.
22. Görgel, P. and Kavlak, E. (2020). Uzun kısa süreli hafıza ve evrimsel sinir ağları ile rüzgâr enerjisi üretim tahmini. *DÜMF Mühendislik Dergisi*, 11(1), 69–80.
23. Suárez-Cetrulo, A. L., Burnham-King, L., Haughton, D. and Carbajo, R. S. (2022). Wind power forecasting using ensemble learning for day-ahead energy trading. *Renewable Energy*, 191, 685–698.
24. Li, L. L., Zhao, X., Tseng, M. L. and Tan, R. R. (2020). Short-term wind power forecasting based on support vector machine with improved dragonfly algorithm. *Journal of Cleaner Production*, 242, 118447.
25. Heinermann, J. and Kramer, O. (2016). Machine learning ensembles for wind power prediction. *Renewable Energy*, 89, 671–679.
26. Lahouar, A. and Ben Hadj Slama, J. (2017). Hour-ahead wind power forecast based on random forests. *Renewable Energy*, 109, 529–541.

27. Liu, L., Liu, J., Ye, Y., Liu, H., Chen, K., Li, D. and Sun, M. (2023). Ultra-short-term wind power forecasting based on deep Bayesian model with uncertainty. *Renewable Energy*, 205, 598-607.
28. Şenol, Ü. and Musayev, Z. (2017). Rüzgâr enerjisinden elektrik üretiminin yapay sinir ağları ile tahmini. *Bilge Uluslararası Fen ve Teknoloji Araştırmaları Dergisi*, 1(1), 23-31.
29. İnternet: Energy Markets Operations Inc [EPIAS] (2023). *Gerçek zamanlı üretim*, Web:<https://seffaflik.epias.com.tr/transparency/uretim/gerceklesenuretim/gercek-zamanli-uretim.xhtml>, Son Erişim Tarihi:07.04.2023
30. İnternet: Energy Markets Operations Inc [EPIAS] (2022). *Gerçek zamanlı üretim*, Web: <https://seffaflik.epias.com.tr/transparency/uretim/gerceklesen-uretim/gercek-zamanli-uretim.xhtml>, Son Erişim Tarihi:10.03.2022
31. Yavuz, S. and Deveci, M. (2012). The effect of statistical normalization techniques on the performance of artificial neural network. *Erciyes University Journal of the Faculty of Economics and Administrative Sciences*, 3, 167-187.
32. Singh, D. and Singh, B. (2022). Feature wise normalization: An effective way of normalizing data. *Pattern Recognition*, 122, 108307.



Gazili olmak ayrıcalıktır...