



**ŞEBEKE BAĞLANTILI GÜNEŞ ENERJİ
SANTRALİNİN GÜÇ VERİMLİLİĞİNİN
PERFORMANS ANALİZİ VE TAHMİNİ**

Fatih SULAN

Yüksek Lisans Tezi

Elektrik Elektronik Mühendisliği Anabilim Dalı

Danışman: Dr. Öğr. Üyesi Ali ÜNLÜTÜRK

2022

Her hakkı saklıdır.



**FEN BİLİMLERİ ENSTİTÜSÜ
YÜKSEK LİSANS TEZİ**

**ŞEBEKE BAĞLANTILI GÜNEŞ ENERJİ SANTRALİNİN
GÜÇ VERİMLİLİĞİNİN PERFORMANS ANALİZİ VE TAHMİNİ**

Fatih SULAN

Tez Danışmanı: Dr. Öğr. Üyesi Ali ÜNLÜTÜRK

Anabilim Dalı: Elektrik Elektronik Mühendisliği

Erzurum

2022

Her hakkı saklıdır

ETİK KURALLARA UYGUNLUK BEYANI

Erzurum Teknik Üniversitesi Fen Bilimleri Enstitüsü tez yazım kurallarına uygun olarak hazırladığım bu tez içindeki tüm bilgilerin doğru ve tam olduğunu, bilgilerin üretilmesi aşamasında bilimsel etiğe uygun davrandığımı, yararlandığım bütün kaynakları atıf yaparak belirttiğimi beyan ederim.

27 / 01 / 2022

Fatih SULAN

ÖZET

YÜKSEK LİSANS TEZİ

ŞEBEKE BAĞLANTILI GÜNEŞ ENERJİ SANTRALİNİN GÜÇ VERİMLİLİĞİNİN PERFORMANS ANALİZİ VE TAHMİNİ

Fatih SULAN

Erzurum Teknik Üniversitesi

Fen Bilimleri Enstitüsü

Elektrik Elektronik Mühendisliği Ana Bilim Dalı

Danışman: Dr. Öğr. Üyesi Ali ÜNLÜTÜRK

Bu tez çalışmasında, doğrudan şebeke bağlantılı ve üç fazlı merkezi invertör topolojisine sahip Şenyurt (Erzurum/Türkiye) Güneş Enerji Santralinin (GES) güç üretiminin gerçek zamanlı izlenebilmesi ve tahmini için parametrik ve nonparametrik regresyon modelleri geliştirilmiştir. Geliştirilen regresyon tabanlı güç tahmin modellerinde Şenyurt GES'in bünyesinde var olan hava istasyonu sensörlerine ait veriler kullanılmıştır. Şenyurt GES'in bünyesinde bulunan hava istasyonunda güneş ışınlama sensörü, Fotovoltaik (PV) hücre sıcaklık sensörü, dış ortam sıcaklık sensörü ve rüzgâr hızı sensörü bulunmaktadır. GES'in güç üretim tahmin modelinde 2020 yılına ait tüm hava istasyonu sensör verileri ile birlikte aktif güç üretim değerleri de kullanılmıştır. Güç üretim tahmin modelinde ilk olarak parametrik istatistiksel tekniklerden olan Çoklu Lineer Regresyon (ÇLR) analizi kullanılmıştır. Diğer parametrik analizlerde olduğu gibi ÇLR'de yeterli örneklem büyüklüğü, verilerin normal dağılımı, çoklu doğrusal bağıntı, tekliklik, uç değer gibi temel varsayımlar ayrıntılı olarak incelenmiştir. Güç üretim tahmin modelinde ikinci olarak parametrik olmayan istatistiksel tekniklerden olan K-En Yakın Komşuluk Regresyon (K-NNR) ve Torbalama Regresyon (BR) modelleri kullanılmıştır. Geliştirilen regresyon modellerinin performansları tez içerisinde ayrıntılı olarak ele alınmıştır. Sonuç olarak, GES'te üretilen gücün tahmini sayesinde işletmeciler verimli ve sürdürülebilir bir enerji üretimi yapıp yapmadıklarını takip edebileceklerdir.

2022, 78 sayfa

Anahtar Kelimeler: Güç Tahmini, Regresyon, K-En Yakın Komşuluk Regresyon, Torbalama Regresyon, Merkezi Invertör Topolojisi, Güneş Enerji Santrali

ABSTRACT

MS. Thesis

PERFORMANCE ANALYSIS AND FORECAST OF POWER EFFICIENCY OF GRID-CONNECTED SOLAR POWER PLANT

Fatih SULAN

Erzurum Technical University

Graduate School of Natural and Applied Sciences

Department of Electrical Electronic Engineering

Supervisor: Assistant Professor Ali UNLUTURK

In this thesis, parametric and nonparametric regression models have been developed for real-time monitoring and estimation of the power generation of Şenyurt (Erzurum/Turkey) Solar Power Plant (SPP) with direct grid connect and three-phase central inverter topology. In the developed regression based power prediction models, the data of the weather station sensors of Şenyurt SPP were used. The weather station within Şenyurt SPP has a solar radiation sensor, Photovoltaic (PV) cell temperature sensor, ambient temperature sensor and wind speed sensor. In the power generation forecast model of GES, active power generation values were used together with all weather station sensor data for 2020. Multiple Linear Regression (MLR) analysis, which is one of the parametric statistical techniques, was firstly used in the power generation estimation model. As in other parametric analyses, basic assumptions such as sufficient sample size, normal distribution of data, multiple linear correlation, singularity, and extreme value were examined in detail in MLR. K-Nearest Neighborhood Regression (K-NNR) and Bagging Regression (BR) models, which are non-parametric statistical techniques, were used secondly in the power generation forecasting model. The performances of the developed regression models were discussed in detail in the thesis. As a result, thanks to the estimation of the power produced in the SPP, the operators will be able to monitor whether they are producing an efficient and sustainable energy.

2022, 78 pages

Keywords: Power Estimation, Regression, K-Nearest Neighbours Regression, Bagging Regression, Central Inverter Topology, Solar Energy Plant

TEŞEKKÜR

Yüksek lisans eğitimim boyunca bilgi ve tecrübesi ile bana yol gösteren değerli danışmanım Dr. Öğr. Üyesi Ali ÜNLÜTÜRK'e saygılarımı ve teşekkürlerimi sunarım. Tez savunma jüri üyeleri olan değerli hocalarımız, Prof. Dr. Ahmet Afşin KULAKSIZ'a ve Dr. Öğr. Üyesi Turgay DUMAN'a da teşekkürlerimi sunarım. Ayrıca, çalışmama desteklerini sunan Numan YANIKLAR'a da teşekkür ederim.

Tez çalışmasının gerçekleşmesinde, Erzurum'da bulunan Şenyurt Güneş Enerji Santralinin altyapı ve imkanlarını sunan T Dinamik Enerji Üretim Sanayi ve Ticaret A.Ş.'nin Genel Müdürlük görevini yürüten Sayın, Doç. Dr. Mustafa TIRIS'a, bünyesinde çalışmaktan büyük onur duyduğum Tegnatia Enerji Üretim Sanayi ve Ticaret A.Ş.'nin değerli Yönetim Kurulu'na ve çalışanlarına da teşekkürü bir borç bilirim.

Evladı olmaktan her zaman gurur duyduğum babam ve anneme, canımdan çok sevdiğim kardeşlerime, yoğun çalışmalarım sırasında her zaman yanımda olan değerli eşime ve üzerimdeki emeğini kelimelerle ifade edemeyeceğim, dar-ı bekaya irtihal eden, her zaman rahmetle, minnetle ve özlemle anacağım kıymetli büyükbabam Nimet SULAN'a sonsuz teşekkürlerimi sunarım.

Fatih SULAN
Ocak 2022

İÇİNDEKİLER

Sayfa

ÖZET.....	i
ABSTRACT	ii
TEŞEKKÜR	iii
İÇİNDEKİLER	iv
SİMGELER VE KISALTMALAR DİZİNİ	vi
ŞEKİLLER DİZİNİ	ix
ÇİZELGELER DİZİNİ	xi
1. GİRİŞ	1
2. KAYNAK ÖZETLERİ	4
3. MATERYAL ve YÖNTEM.....	10
3.1. Güneş Enerji Santrali Teknolojisi	10
3.1.1. Yoğunlaştırılmış güneş enerjisi teknolojisi.....	10
3.1.1.1. Parabolik oluk konfigürasyonu	11
3.1.1.2. Güneş kulesi konfigürasyonu.....	13
3.1.1.3. Parabolik çanak konfigürasyonu	14
3.1.1.4. Lineer fresnel konfigürasyonu	15
3.1.2. Güneş fotovoltaik teknolojisi	16
3.1.2.1. Bağımsız ve hibrit fotovoltaik konfigürasyon.....	17
3.1.2.2. Şebekeye bağlı fotovoltaik konfigürasyon.....	18
3.2. Üç Fazlı Şebeke Bağlantılı Şenyurt Güneş Enerji Santrali	19
3.3. Lineer Regresyon ve Makine Öğrenme Tabanlı Regresyon Modelleri	20
3.3.1. Lineer regresyon.....	25
3.3.1.1. Basit doğrusal regresyon modeli	25
3.3.1.2. Çoklu doğrusal regresyon modeli	31
3.3.2. Makine öğrenme tabanlı regresyon modelleri.....	33
3.3.2.1. K-en yakın komşuluk regresyon modeli	33
3.3.2.2. Torbalama regresyon modeli	35
4. ARAŞTIRMA BULGULARI ve TARTIŞMA	37
5. SONUÇ ve ÖNERİLER.....	70
KAYNAKLAR	72

EKLER.....	78
EK 1: Yasal İzin Belgesi.....	78



SİMGELER VE KISALTMALAR DİZİNİ

<u>Simgeler</u>	<u>Açıklama</u>
Atm	Basınç birimi
Bar	Basınç birimi
C	Celcius
CO ₂	Karbondioksit
<i>Cov</i>	Kovaryans
F	Fahrenheit
F testi	ANOVA testi
<i>i</i>	Ölçüm sırası
I-V	Akım-Gerilim
<i>j</i>	Ölçüm sırası
<i>L</i>	Manhattan uzaklığı
m	Metre
<i>N</i>	Anakütle, toplam örnek
<i>n</i>	Örnek kesit
<i>p</i>	Minkowski metriği için güç parametresi
<i>R</i> ²	Belirleme katsayısı
s	Saniye
t	Test
<i>Var</i>	Varyans
W	Watt
$X_1, X_2, \dots, X_m$	Bağımsız değişken
<i>Y</i>	Bağımlı değişken
%	Yüzde
°	Derece
ε	Hata terimi
σ^2	Gözlemlerin varyansı
Σ	Toplam sembolü
∂	Kısmi türev
μ	Bağımsız değişkenlerin ortalama değerleri

Kısaltmalar

AB	Avrupa Birliđi
ABD	Amerika Birleşik Devletleri
AC	Alternatif Akım
AKT	Artık Kareler Toplamı
A.Ş.	Anonim Şirketi
BR	Torbalama Regresyon
CFS	Korelasyona Dayalı Özellik Seçimi
ÇLR	Çoklu Lineer Regresyon
DC	Doğru Akım
DŞB	Doğrudan Şebekeye Bağlı
DT	Karar Ağacı
DV	Destek Vektör
EBK	Elektrik Bağlantı Kutusu
EDŞ	Elektrik Dağıtım Şebekesi
EIA	Enerji Bilgi İdaresi
EKK	En Küçük Kareler Yöntemi
EPDK	Enerji Piyasası Denetleme Kurumu
GES	Güneş Enerji Santrali
GPR	Gauss Süreç Regresyonu
GW	Gigawatt
KNN	K-En Yakın Komşu
K-NNR	K-En Yakın Komşu Regresyonu
LR	Lineer Regresyon
LSTM	Uzun Kısa Süreli Bellek
MAE	Ortalama Mutlak Hata
MSE	Ortalama Kare Hata
MGM	Meteoroloji Genel Müdürlüğü
ML	Makine Öğrenmesi
Min.	Minimum
Mak.	Maksimum
MUK	Mahalanobis Uzaklık Katsayısı

MW	Mega Watt
NB	Naive Bayes
OECD	Ekonomik İş Birliği ve Kalkınma Örgütü
PV-GES	Fotovoltaik-Güneş Enerji Santrali
PV	Fotovoltaik
RF	Rastgele Orman
RKT	Regresyon Kareler Toplamı
SVR	Destek Vektör Regresyonu
SCADA	Merkezi Denetim ve Veri Toplama
STC	Standart Test Koşulu
SVM	Destek Vektör Makineleri
TKT	Toplam Kareler Toplamı
Tol	Tolerans
VIF	Varyans Artış Faktörü
Y-GES	Yoğunlaştırılmış-Güneş Enerji Santrali
Y-GET	Yoğunlaştırılmış-Güneş Enerji Teknolojisi
YSA	Yapay Sinir Ağları
YZ	Yapay Zekâ

ŞEKİLLER DİZİNİ

Şekil 3.1. Güneş enerji santrali teknolojilerinin sınıflandırılması	10
Şekil 3.2. Parabolik oluk konfigürasyonuna ait iş akış şeması	13
Şekil 3.3. Güneş kulesi konfigürasyonu	14
Şekil 3.4. Parabolik çanak konfigürasyonu	14
Şekil 3.5. Lineer fresnel konfigürasyonu	15
Şekil 3.6. Fotovoltaik sistem bileşenleri	16
Şekil 3.7. (a) Şebekeden bağımsız PV sistem (b) Şebekeden bağımsız hibrit sistem	17
Şekil 3.8. Şebekeye bağlı PV sistem şeması.....	18
Şekil 3.9. İnvertör topolojileri (a) merkezi (b) Dizi (c) Modül (d) Çoklu-Dizi	18
Şekil 3.10. Şenyurt GES'in güç akış diyagramı	19
Şekil 3.11. 3 fazlı ve merkezi invertör yapısına sahip Şenyurt/Erzurum GES	20
Şekil 3.12. İnsan ve makine arasındaki diyalog.....	22
Şekil 3.13. Denetimli ML süreci.....	24
Şekil 3.14. Önemli regresyon çeşitleri	25
Şekil 3.15. Serpilme diyagramı.....	26
Şekil 3.16. Torbalama Algoritması.....	36
Şekil 4.1. Şenyurt/GES'e ait hava istasyonu sensör verileri (Ocak-2020)	38
Şekil 4.2. Şenyurt/GES'in Ürettiği Aktif Güç (Ocak-2020).....	38
Şekil 4.3. Şenyurt/GES'e ait hava istasyonu sensör verileri (Şubat-2020).....	39
Şekil 4.4. Şenyurt/GES'in Ürettiği Aktif Güç (Şubat-2020)	39
Şekil 4.5. Şenyurt/GES'e ait hava istasyonu sensör verileri (Mart-2020).....	40
Şekil 4.6. Şenyurt/GES'in Ürettiği Aktif Güç (Mart-2020)	40
Şekil 4.7. Şenyurt/GES'e ait hava istasyonu sensör verileri (Nisan-2020)	41
Şekil 4.8. Şenyurt/GES'in Ürettiği Aktif Güç (Nisan-2020).....	41
Şekil 4.9. Şenyurt/GES'e ait hava istasyonu sensör verileri (Mayıs-2020).....	42
Şekil 4.10. Şenyurt/GES'in Ürettiği Aktif Güç (Mayıs-2020)	42
Şekil 4.11. Şenyurt/GES'e ait hava istasyonu sensör verileri (Haziran-2020).....	43
Şekil 4.12. Şenyurt/GES'in Ürettiği Aktif Güç (Haziran-2020).....	43
Şekil 4.13. Şenyurt/GES'e ait hava istasyonu sensör verileri (Temmuz-2020)	44
Şekil 4.14. Şenyurt/GES'in Ürettiği Aktif Güç (Temmuz-2020).....	44
Şekil 4.15. Şenyurt/GES'e ait hava istasyonu sensör verileri (Ağustos-2020).....	45
Şekil 4.16. Şenyurt/GES'in Ürettiği Aktif Güç (Ağustos-2020)	45

Şekil 4.17. Şenyurt/GES'e ait hava istasyonu sensör verileri (Eylül-2020).....	46
Şekil 4.18. Şenyurt/GES'in Ürettiği Aktif Güç (Eylül-2020).....	46
Şekil 4.19. Şenyurt/GES'e ait hava istasyonu sensör verileri (Ekim-2020).....	47
Şekil 4.20. Şenyurt/GES'in Ürettiği Aktif Güç (Ekim-2020).....	47
Şekil 4.21. Şenyurt/GES'e ait hava istasyonu sensör verileri (Kasım-2020)	48
Şekil 4.22. Şenyurt/GES'in Ürettiği Aktif Güç (Kasım-2020).....	48
Şekil 4.23. Şenyurt/GES'e ait hava istasyonu sensör verileri (Aralık-2020)	49
Şekil 4.24. Şenyurt/GES'in Ürettiği Aktif Güç (Aralık-2020).....	49
Şekil 4.25. Bağımsız değişkenlere ait kutu grafiği	51
Şekil 4.26. Bağımsız değişkenlere ait verilerin Mahalanobis değerleri.....	52
Şekil 4.27. Gerçek güç üretimi ve LR güç tahmini (1-100 arasındaki veriler).....	58
Şekil 4.28. Gerçek güç üretimi ve LR güç tahmini (101-200 arasındaki veriler).....	58
Şekil 4.29. Gerçek güç üretimi ve LR güç tahmini (201-300 arasındaki veriler).....	58
Şekil 4.30. Gerçek güç üretimi ve LR güç tahmini (301-400 arasındaki veriler).....	58
Şekil 4.31. Gerçek güç üretimi ve LR güç tahmini (401-500 arasındaki veriler).....	59
Şekil 4.32. Gerçek güç üretimi ve LR güç tahmini (501-600 arasındaki veriler).....	59
Şekil 4.33. Gerçek güç üretimi ve LR güç tahmini (601-687 arasındaki veriler).....	59
Şekil 4.34. Gerçek güç üretimi ve K-NNR güç tahmini (1-100 arasındaki veriler)	63
Şekil 4.35. Gerçek güç üretimi ve K-NNR güç tahmini (101-200 arasındaki veriler) ...	63
Şekil 4.36. Gerçek güç üretimi ve K-NNR güç tahmini (201-300 arasındaki veriler) ...	63
Şekil 4.37. Gerçek güç üretimi ve K-NNR güç tahmini (301-400 arasındaki veriler) ...	63
Şekil 4.38. Gerçek güç üretimi ve K-NNR güç tahmini (401-500 arasındaki veriler) ...	64
Şekil 4.39. Gerçek güç üretimi ve K-NNR güç tahmini (501-600 arasındaki veriler) ...	64
Şekil 4.40. Gerçek güç üretimi ve K-NNR güç tahmini (601-687 arasındaki veriler) ...	64
Şekil 4.41. Gerçek güç üretimi ve RF-R güç tahmini (0-100 arasındaki veriler).....	68
Şekil 4.42. Gerçek güç üretimi ve RF-R güç tahmini (101-200 arasındaki veriler).....	68
Şekil 4.43. Gerçek güç üretimi ve RF-R güç tahmini (201-300 arasındaki veriler).....	68
Şekil 4.44. Gerçek güç üretimi ve RF-R güç tahmini (301-400 arasındaki veriler).....	68
Şekil 4.45. Gerçek güç üretimi ve RF-R güç tahmini (401-500 arasındaki veriler).....	69
Şekil 4.46. Gerçek güç üretimi ve RF-R güç tahmini (501-600 arasındaki veriler).....	69
Şekil 4.47. Gerçek güç üretimi ve RF-R güç tahmini (600-687 arasındaki veriler).....	69

ÇİZELGELER DİZİNİ

Çizelge 4.1. 2020 yılı ocak ayına ait verilerin betimleyici istatistik değerleri	38
Çizelge 4.2. 2020 yılı şubat ayına ait verilerin betimleyici istatistik değerleri.....	39
Çizelge 4.3. 2020 yılı mart ayına ait verilerin betimleyici istatistik değerleri.....	40
Çizelge 4.4. 2020 yılı nisan ayına ait verilerin betimleyici istatistik değerleri.....	41
Çizelge 4.5. 2020 yılı mayıs ayına ait verilerin betimleyici istatistik değerleri	42
Çizelge 4.6. 2020 yılı haziran ayına ait verilerin betimleyici istatistik değerleri	43
Çizelge 4.7. 2020 yılı temmuz ayına ait verilerin betimleyici istatistik değerleri	44
Çizelge 4.8. 2020 yılı ağustos ayına ait verilerin betimleyici istatistik değerleri.....	45
Çizelge 4.9. 2020 yılı eylül ayına ait verilerin betimleyici istatistik değerleri.....	46
Çizelge 4.10. 2020 yılı ekim ayına ait verilerin betimleyici istatistik değerleri	47
Çizelge 4.11. 2020 yılı kasım ayına ait verilerin betimleyici istatistik değerleri	48
Çizelge 4.12. 2020 yılı aralık ayına ait verilerin betimleyici istatistik değerleri.....	49
Çizelge 4.13. Bağımsız değişkenlere ait Basıklık ve Çarpıklık.....	50
Çizelge 4.14. Dört adet bağımsız değişken için elde edilen katsayılar.....	53
Çizelge 4.15. Bağımsız değişkenlere ait Pearson Korelasyon tablosu	54
Çizelge 4.16. Üç adet bağımsız değişken için elde edilen katsayılar tablosu.....	54
Çizelge 4.17. İki adet bağımsız değişken için elde edilen katsayılar.....	55
Çizelge 4.18. İki adet bağımsız değişken için elde edilen model özeti	56
Çizelge 4.19. İki adet bağımsız değişken için elde ANOVA	56
Çizelge 4.20. K-NNR parametreleri ve performans kriteri değerleri	62
Çizelge 4.21. K-NN'nin en uygun parametreleri ve performans kriteri değerleri.....	62
Çizelge 4.22. Torbalama regresyon performansı (SVR ve DT-R temel tahmin edici)...	66
Çizelge 4.23. Torbalama regresyon performansı (RF-R ve AB-R temel tahmin edici) .	67
Çizelge 4.24. Farklı temel tahmin edicilere ait performans.....	67

1. GİRİŞ

Sanayi devriminin tamamlanmasıyla birlikte ülkeler arasındaki ticari faaliyetlerin hız kazanması, uluslararası pazarlarda üretime dayalı rekabetin artması, haberleşme, ulaşım ve bilgi teknolojisindeki olağanüstü ilerlemeler, toplumsal yaşam standardının yükselmesiyle birlikte teknolojik cihazların gündelik yaşamın her alanına entegre edilmesi ve kullanımlarının yaygınlaşması, dünya nüfusundaki dramatik büyüme toplumların enerjiye olan ihtiyacını sürekli olarak artırmaktadır. Örneğin, Amerika Birleşik Devletleri (ABD) Enerji Bilgi İdaresi'nin (EIA) uluslararası enerji istatistiklerine göre küresel elektrik tüketimi dünya nüfusundan daha hızlı artmaya devam etmektedir. Bu durum kişi başına tüketilen ortalama elektrik miktarında ciddi bir artış olduğunu göstermektedir (Kahan 2020). Enerjiye olan bu yoğun talebin karşılanabilmesi için çoğunlukla kömür, doğalgaz ve benzin gibi fosil yakıtlara dayalı enerji üretim yöntemleri tercih edilmektedir. Fosil yakıtların aşırı miktarda tüketimi ile enerji üretme yöntemi özellikle CO₂ (karbondioksit) başta olmak üzere birçok sera gazı atmosfere yayılmaktadır (Gurria and Van der Hoeven 2011). Atmosfere yayılan bu zararlı gazlar küresel iklim değişikliğine neden olmaktadır. Küresel iklim değişikliği hava sıcaklıklarının anormal artışı, biyolojik çeşitliliğin çöküşü ve hava kirliliğinin yükselmesi, buzulların erimesi, fırtınaların artması, kuraklığın ve çölleşmenin artışı gibi birtakım yıkıcı çevresel sorunları da ortaya çıkarmaktadır (MGM 2021). Aynı zamanda, iklim değişikliği mevcut ve gelecek nesillerin refahı için büyük sistemik riskler oluşturmaya devam etmektedir (OECD 2021).

Son yıllarda küresel ısınmayla mücadele etmek ve fosil yakıtlara dayalı enerji üretiminin çevre üzerindeki yıkıcı etkilerini azaltmak için güvenilir bir çözüm yöntemi olarak yenilenebilir enerji üretim santralleri büyük ilgi görmektedir (Hashemi vd 2020). Yenilebilir enerji 2020 küresel durum raporuna göre, yenilebilir enerji üretiminin kurulu güç kapasitesi 200 Gigawatt'dan daha fazla büyüyerek 2019'da bir rekor kırmıştır (REN21 2020). 2020'de ise dünyada hemen hemen bütün hükümetler COVID-19 salgınının yayılmasını yavaşlatmak ve ortaya çıkan küresel sağlık krizine yanıt vermek için sokağa çıkma kısıtlamaları uygulamışlardır. Bu durum ülke ekonomilerini durma noktasına getirmiş ve enerjiye olan talebi düşürmüştür. Genel olarak, dünya çapında birincil enerji talebi yıl boyunca yaklaşık %5'in üzerinde düşeceği ve pandemi öncesi seviyelere dönmesinin ise 2023'ün başına kadar süreceği tahmin edilmektedir (IEA

1. GİRİŞ

2020). Yenilenebilir enerji, büyük ölçüde düşük işletme maliyetleri ve düşük elektrik talebinin olduğu dönemlerde elektrik şebekelerine tercihli erişim nedeniyle 2020'de tahmini olarak %29 ile en yüksek payına ulaşmıştır. Bu arada, yıl boyunca küresel olarak 256 Gigawatt'dan (GW) fazla yenilenebilir enerji kapasitesi eklenilmiş payı ise yaklaşık %30'a ulaşmıştır. (REN21 2020). Güneş enerjisinden elektrik üretmenin maliyetleri son yıllarda önemli ölçüde düşmüştür. 2020'de, şebeke ölçeğinde güneş Fotovoltaiklerinden (PV) elde edilen küresel ağırlıklı ortalama seviyelendirilmiş elektrik maliyeti, 2010'dan bu yana %85 azalmıştır. Bu düşüşler, dünya nüfusunun çoğu için yenilenebilir kaynaklardan elektrik üretiminin kömürle çalışan elektrik santrallerinden daha uygun maliyetli olduğu anlamına gelmektedir. Çin'in bazı bölümleri, Avrupa Birliği (AB), Hindistan ve Amerika Birleşik Devletleri de dahil olmak üzere artan sayıda bölgede, yeni PV santraller inşa edilerek, mevcut kömürle çalışan santralleri işletmekten daha ucuz hale gelmiştir (REN21 2020).

Güneş enerji santrallerinde verimli ve sürdürülebilir bir şekilde enerji üretiminin gerçekleştirilebilmesi için santrale ait güç üretim değerlerinin anlık olarak takibi gerekmektedir. Çünkü, GES işletmecisi üretilen enerjiyi doğrudan Elektrik Dağıtım Şebekesine (EDŞ) vermektedir. Elektrik Piyasası Denetleme Kurumu'nun (EPDK) yönetmeliğine göre EDŞ'ye verilen elektrik enerjisinin ilgili dağıtım şirketleri tarafından satın alınması zorunluluğu bulunmaktadır (EPDK 2021). Bundan dolayı, GES'e ait donanım bileşenlerinden kaynaklı herhangi bir arızadan dolayı enerji üretim kaybı istenmeyen bir durumdur. Bununla birlikte, GES işletmecisi sahip olduğu GES'den beklenen güç üretim miktarı ile santralden elde edilen gerçek güç üretim miktarını kısa ve uzun vadede tahmin edebilmesi ve karşılaştırabilmesi de gerekmektedir. Çünkü, işletme sahibinin GES'in bulunduğu bölgede yeni yatırımlar yapıp yapmayacağı, GES'den günlük, aylık veya yıllık bazda elde edebileceği gelir tahminini yapabilmesi oldukça önemlidir.

Uzmanlar ve araştırmacılar tahmin gerektiren işlerde (nüfus artışı tahmini, hava durumu tahmini, güncel borsa tahmini, ortalama yaşam süresi tahmini vb.) regresyon algoritmaları kullanmaktadırlar. Regresyon algoritmaları ile değişkenler arasındaki ilişki matematiksel olarak modellenir. Regresyon yöntemleri istatistikle doğrudan bağlantılıdır. Aynı zamanda Regresyon yöntemleri, altyapısı ileri istatistiksel yöntemlere dayanan

Makine Öğrenimine (ML) de entegre edilmiştir. En temel ve sıklıkla kullanılan regresyon analizlerinden bazıları basit doğrusal regresyon, çoklu regresyon ve lojistik regresyondur. Bununla birlikte, Karar Ağaçları (DT), Naive Bayes (NB), Destek Vektör (SV), Rastgele Orman (RF), AdaBoost (AB) gibi birçok ML tabanlı algoritma yapıları da tahminlerde yaygın olarak kullanılmaktadır.

Bu tez çalışması Doğrudan Şebeke Bağlantılı (DŞB) ve üç fazlı merkezi inverter topolojisine sahip Şenyurt (Tegnatia Enerji Üretim Sanayi ve Ticaret A.Ş. tarafından Erzurum/Türkiye’de kuludur) Güneş Enerji Santralinde (GES) gerçekleştirilmiştir. Şenyurt GES’in güç üretiminin gerçek zamanlı izlenebilmesi, tahmini, denetimi ve işletimi için hava tahmin istasyonu sensörlerine ihtiyaç duyulmaktadır. Şenyurt GES’in bünyesinde bulunan hava tahmin istasyonunda güneş ışıınımı sensörü, PV hücre sıcaklık sensörü, dış ortam sıcaklık sensörü ve rüzgâr hızı sensörü bulunmaktadır. Bu sensörlerden elde edilen gerçek zamanlı veriler GES’de bulunan Merkezi Denetim ve Veri Toplama (SCADA) sistemi ile uyumlu olan uzaktan izleme arayüzü vasıtasıyla denetlenmekte ve kaydedilmektedir. Şenyurt/GES’in güç üretim tahmin modelinde 2020 yılına ait gerçek zamanlı veriler kullanılmıştır. Şenyurt/GES 3.36 MW kurulu güce sahip bir santraldir. GES tarafından üretilen aktif gücün (bağımlı değişken) tahmini için üretimi etkileyen bağımsız değişken parametreler (Güneş ışıınımı, PV modül sıcaklığı, rüzgâr hızı ve dış ortam sıcaklığı) dikkate alınmıştır. Geliştirilen güç üretim tahmin modelinde ilk olarak klasik Çoklu Lineer Regresyon (ÇLR) analizi ele alınmıştır. Daha sonra ML tabanlı K-En Yakın Komşuluk Regresyon (K-NNR) ve Torbalama Regresyon (BR) gibi ileri regresyon yöntemleri ile güç üretim tahmin modeli başarısı geliştirilmiştir.

2. KAYNAK ÖZETLERİ

Güneş Enerji Santrallerinin (GES) güç verimliliğine etki eden faktörler ve güç tahmini konusunda birçok akademik yayın çalışmaları gerçekleştirilmiştir. Bu akademik çalışmalardan bazıları şöyledir;

Heidari et al. (2015) çalışmalarında, PV panel yüzeyinde biriken karın neden olduğu enerji kayıplarını incelemiştir. Amerika'nın karlı bir bölgesinde kurdukları yedi dikey yönlü PV modülü dört farklı eğimde (0° , 15° , 30° ve 45°) yerleştirmişlerdir. Düz bir eğimli çatıya benzer şekilde en iyi kar tutma konfigürasyonu olarak, test modüllerinden üçü, sürtünmeyi önleyecek kadar yüksek bir yapıya monte edilmiştir. Çatılara kurulan PV sistemlere benzer şekilde maksimum yüzey sürtünmesinin etkisi, diğer dört modülün aynı seviyede monte edilmesiyle ortaya çıkarılmıştır. Platform, Ekim 2013'ten itibaren bir yıl süreyle izlenmiştir. O kış normal olan kar yağışı: 5,3 m (209 inç) olmuştur. Karla ilgili yıllık enerji kayıpları, yükseltilmiş engelsiz modüller için %5 ile %12 arasında değişirken, en dik eğim açısı en az miktarda enerji kaybını yaşanmıştır. Bu çalışmada engellenen modüller için, kayıp enerjiye çok az açısal etki oluşmuş olup yıllık enerji kayıplarıyla birlikte %29 ile %34 arasında değişiklik göstermiştir. Bu durum oluşan açısal farklılıklar varken kaybedilen enerjideki üç ila altı kat artış, portatif PV sistemleri için engelleri en aza indirmenin ve anında kar temizlemenin önemine işaret etmektedir.

Bhol et al. (2015) çalışmalarında, farklı çevresel faktörlerin fotovoltaiik panel performansı üzerindeki etkisini incelemişlerdir. PV sistem uygulamalarının güvenilirliği ve verimliliği birçok faktöre bağlıdır. PV sisteminin çıkış gücü esas olarak ışığın dalga boyu, ışık şiddeti, gölgeleme, toz vb. gibi farklı çevresel faktörlerden etkilenmektedir. Bu çalışmada, farklı çevresel faktörlerin birikmesinden kaynaklanan çıkış gücü kayıpları farklı deneyler (toz etkisi, ışığın farklı renklerinin etkisi, gölgelenme etkisi ve ışık şiddeti etkisi deneyleri) yapılarak incelenmiştir. Deneysel veriler, sistemin verimliliği ve güç çıkışını hesaplamakta kullanılmıştır. Sonuçlar, PV sistemin çıkış gücünün ve verimliliğinin çevresel faktörlerden etkilendiğini göstermektedir.

Bosman and Darling (2016) çalışmalarında, karın güneş panelleri üzerindeki etkisini daha iyi tahmin etmek için mevcut güneş enerjisi performans modellerinin

değiştirilmesi gerekliliğini vurgulamışlardır. Çalışmada model geliştiricilere, büyük ölçekli GES işletmecilerine ve küçük ölçekli yatırımcılara karlı ortamlarda bulunan güneş enerjisi sistemleri için yatırımın geri dönüşünü daha iyi anlama fırsatı sağlamak amacıyla yeni bir yöntem önerilmiştir.

Bayrak vd (2017) çalışmalarında, 75 W güce sahip PV panellerin gölgelenme şekillerini ve gölgelenme oranları altında elektriksel performans ve termodinamik analizlerini incelenmiştir. Bu amaçla deneysel bir kurulum oluşturulmuş ve gölgeleme oranı ve konumları gibi farklı parametreler için seri deneyler yapılmıştır. Farklı yüzdelerde olacak şekilde PV hücrenin, yatay ve dikey gölgeleme alacak şekilde üç farklı gölgeleme etkisi durumu oluşturulmuşlardır. Deneysel sonuçlardan PV hücrenin gölgelenme etkisinin, sistemin enerji verimliliği üzerinde önemli bir etki yaptığını belirlemişlerdir. Maksimum güç kaybı %100 gölgeleme oranında hücrelerde %69,92 dikeyde %66,93 yatay gölgelendirmede %99,98 olarak gerçekleşmiştir.

Ejgar et al. (2017) çalışmalarında, gerçek zamanlı bir GES'in akıllı izleme ve bakım sistemleri üzerinde durmuşlardır. Güneş enerjisi santrallerinin genel enerji üretimi ve performansının, güneş paneli dizileri, invertörler ve transformatörler gibi farklı cihazların etkin ve zamanında bakımına bağlı olduğunu vurgulamışlardır. Bu cihazların zamanla veya ekipmandaki belirli bir arıza nedeniyle bozulabildiğine işaret etmişlerdir. Tesisteki enerji üretimi sadece iç faktörlerden değil, aynı zamanda toz, ıslanma, modül sıcaklığı vb. gibi dış faktörlerden de etkilenmektedir. Bu makalede, bu tür cihazların çeşitli arızalarını ve olası arızalarını gerçek zamanlı olarak tespit etmek için bir sistem sunulmuştur. Anormallik tespit edildiğinde sistem acil bir şekilde servis mühendisine bilgi vererek ve aksiyon alınmasına yardımcı olarak GES tesisinin performansının ve verimliliğinin artmasına yardımcı olmaktadır.

Andenaes et al. (2018) çalışmalarında, karın optik özelliklerine ilişkin önceki çalışmaları incelemişler ve bunların PV güneş panelleri üzerindeki gölgelendirmesinin etkileri üzerine yapılan çalışmalarla bir araya getirmeye çalışmışlardır. Karın yansıma (albedo) ve spektral geçirgenlik gibi genel optik özelliklerini incelemişlerdir. Kar örtüleri için ortak geçirgenlik profilleri de incelenmiştir. Çalışmada ayrıca gölgelendirmenin fotovoltaik paneller üzerindeki yaygın olarak kabul edilen hem tek tip gölgeleme (zayıf

ışık) hem de kısmi gölgeleme altındaki bazı etkilerini de ortaya konmuştur. Çalışmada, bir PV sistemin kurulumunda karla ilgili sorunlardan bazılarını, özellikle binalara entegre edilen sistemlerde kar yükleri ve eriyen karların oluşturduğu riskle de ele alınmıştır. Bu çalışmada karla ilgili zorlukları ele almak için yaygın yöntemler hem malzeme hem de mimari düzeyde özetlenmiştir.

Sobri et al. (2018) çalışmalarında, güneş fotovoltaiik güç tahmini alanındaki son gelişmeler hakkında kapsamlı bir inceleme sunmuşlardır. Çalışmalarında, çeşitli fotovoltaiik güneş enerjisi tahmin yöntemlerinin özelliklerini ve performans açısından analiz etmeyi ve karşılaştırmayı amaçlamışlardır.

Solanki et al. (2018) çalışmalarında, birbirine bağlı şebeke sistemini daha esnek hale getirmek için, kabul edilebilir sınırlar altında güneş enerjisi üretim tahmini yapma gereksinimini ortaya koymuşlardır. Bu makale, hava durumu verilerini ve tesis özelliklerini dikkate alarak haftalık güneş enerjisi üretim miktarını hesaplamayı sağlayan matematiksel bir modelden oluşan bir güneş enerjisi tahmin modeli sunmaktadır. Güneş enerjisi üretimini etkileyen faktörler, ortam sıcaklığı, güneş ışıınımı, panellerin verimliliği ve tesis bileşenleri olan invertör, kablolar, PV modül kurulumu vb. gibi maddelerin verimliliğidir.

Akhter et al. (2019) gerçekleştirdikleri çalışmalarında, meta-sezgisel ve makine öğrenimi yöntemlerine odaklanarak PV güç çıkışını tahmin etmek için kullanılan yöntemler hakkında sistematik ve eleştirel bir inceleme yapmışlardır. Kullanılan bütün yöntemlerin avantajları ve dezavantajları, tahmin beklentisi ve girdi parametreleriyle birlikte geçmiş verilere dayalı olarak özetlemişlerdir. Son olarak, bu konu ile ilgilenen araştırmacıların en iyi güç tahmin tekniğini seçmelerine yardımcı olmak için makine öğrenimi ve meta-sezgisel yöntemler arasında kapsamlı bir karşılaştırma derlemişlerdir.

Hashemi et al. (2019) çalışmalarında, PV panellerin yüzeyinde kar birikmesi nedeniyle enerji veriminde kısmen veya tamamen azalma olduğunu belirtmişlerdir. Makalede meteorolojik veriler ve makine öğrenimine dayanan algoritmalar kullanılarak günlük kar kaybı için tahmin modelleri geliştirilmiştir. Ele alınan bu algoritmalar,

regresyon ağaçları, gradyan artırılmış ağaçlar, rastgele orman, ileri beslemeli ve yinelenen yapay sinir ağlarını ve destek vektör makineleridir.

Golam et al. (2019) çalışmalarında, Güneş ışıınımı tahmininin, Fotovoltaik (PV) güç yönetim sisteminin vazgeçilmez bir çalışma alanı olduğunu vurgulamışlardır. Bununla birlikte, PV güç yönetiminin, güneş radyasyonuna bağlı olan PV çıkış gücünün değişkenlik gösteren modeli nedeniyle ciddi cezalara tabi olabileceğini belirtmişlerdir. Bu çalışmada, bu sorunun üstesinden gelmek ve güneş ışıınımını kısa bir zaman aralığında tahmin etmek için SIPNet adlı yüksek hassasiyetli Uzun Kısa Süreli Bellek (LSTM) tabanlı bir sinir ağı modeli önerilmiştir. Güneş radyasyonu, ölçümde farklı boyutlar olan sıcaklık, basınç, nem, rüzgâr hızı ve yönü gibi meteorolojik bilgilerin çevresel olarak algılanmasına bağlıdır. LSTM sinir ağı, çeşitli lojistik kapılar aracılığıyla çok değişkenli giriş özelliklerinin zaman-uzamsal olarak eş zamanlı olarak öğrenebilir. Ayrıca SIPNet aracılığıyla, meteorolojik bilgilerin ve radyasyon verilerinin tarihsel gözlemi göz önüne alındığında gelecekteki güneş ışıınımının tahmin edebileceğini göstermişlerdir. Çalışmada SIPNet modeli ile simülasyon gerçekleştirilmiştir. Daha sonra gerçek ve tahmin edilen veri dizileri karşılaştırılarak Ortalama Mutlak Hata (MAE), Hatanın Karesinin Ortalaması (MSE) ve Hatanın Karesinin Ortalamasının Karekökü (RMSE) ile değerlendirilmiştir. Deneysel sonuçlarda, SIPNet'in MAE, MSE ve RMSE değerlerinin sırasıyla 0,0413, 0,0033 ve 0,057 olduğu gösterilmiştir. Sonuç olarak SIPNet'in etkinliğini ve diğer mevcut modellerden daha iyi performans gösterdiğini, çalışmalarında belirtmişlerdir.

Pawluk et al. (2019) makalelerinde, kar birikimlerinin fotovoltaik (PV) sistemlerin elektrik üretimi üzerindeki etkisini incelemişlerdir. PV panellerde kar birikimlerinin üretim tahmini üzerindeki etkisini azaltmak için stratejiler belirlemişlerdir. Fotovoltaik sistemlerdeki kar birikimlerinden kaynaklanan yıllık ve aylık elektrik üretim kayıpları bildirilen verilere göre, çoğu iklimde yıllık elektrik üretim kayıplarının %10'undan az olduğunu gösterir; ancak kış boyunca aylık üretim kayıpları genellikle %25'in üzerinde olmuştur. Kar örtüsü nedeniyle oluşan elektrik üretim kayıpları için tahmin teknikleri özetlenmiştir. Nispeten doğru tahminler, ortam sıcaklığı, güneş ışıınımı ve kar derinliği dikkate alındığında birkaç model tarafından elde edilebilmiştir. Karın PV sistemdeki elektrik üretimi üzerindeki etkisini azaltma potansiyeline sahip olan on azaltma yöntemi belirlenmiş ve niteliksel olarak tartışılmıştır.

Van Tai (2019) gerçekleştirdiği çalışmada çeşitli çevresel parametrelerin PV sistem çıktısı üzerindeki etkileri araştırılmıştır. PV sistem tarafından toplanan veriler kullanılarak regresyon yöntemleri ve Yapay Sinir Ağı (YSA) tabanlı ağlar kullanılarak PV güç çıkışı tahmin etmek için tasarlanmıştır. Parametre seçiminde Korelasyona Dayalı Özellik Seçimi (CFS) ve Relief tabanlı özellik seçimi olmak üzere iki yöntem kullanılmıştır. Sonuç olarak YSA modeli, tartışılan diğer tüm tekniklerden (basit doğrusal regresyon modeli, M5P (M5-Prime) karar ağacı modeli ve Gauss Süreç Regresyonu (GPR)) daha iyi performans gösterir.

Su et al. (2019) çalışmalarında kısa vadeli PV güç tahmininde literatürdeki on adet yeni sinir ağı ve akıllı algoritmayı değerlendiren kapsamlı bir karşılaştırmalı analiz yapmışlardır. Tüm yöntemler düzgün bir şekilde detaylı ayarlanmış ve Birleşik Krallık'ta bulunan 406 MW'lık bir PV santralinin bir yıllık veri seti kullanılarak değerlendirilmiştir. Ayrıca, en iyi performans gösteren tahmin modellerinin bir toplamı olarak türetilen yeni bir hibrit tahmin stratejisi önerilmiş ve değerlendirilmiştir. MATLAB'deki simülasyon sonuçları ile yıl içerisindeki mevsimlerin tüm yöntemlerin doğruluğunu etkilediğini, önerilen hibrit yöntemin genel olarak en iyi performansı verdiği gösterilmiştir.

Chung (2020) yaptığı çalışmada mevcut hava koşullarını dikkate alarak bir sonraki günün güneş ışınımını tahmin eden çok katmanlı ileri beslemeli sinir ağı tabanlı bir model önermiştir. Önerilen güneş tahmin modeli, Güney Kore'de bulunan gerçek bir PV sisteminin enerji üretimini tahmin etmek için kullanılmıştır. Modelin tahmini enerji üretimi ile PV sistem çalışması sırasında ölçülen enerji üretimi verileri karşılaştırılarak doğrulanmıştır. Hatanın Karesinin Ortalaması (MSE), ortalama sapma hatası ve ortalama mutlak hatayı içeren optimal model için doğruluk endeksleri sırasıyla 1,43 kWh/m²/gün, -0,09 kWh/m²/gün ve 1,15 kWh/m²/gün olmuştur. Elde ettikleri bu değerlerin sonucu olarak önerdikleri modelin makul güneşlenme tahminleri üretebildiğini ifade etmişlerdir. Buna rağmen, enerji alım satımında doğru tahminler elde etmek için ek çalışmalara ihtiyaç olduğunu vurgulamışlardır.

Anuradha et al. (2021) yaptıkları çalışmalarında Hindistan'da bulunan bir GES'de PV sistemin çıkış gücünü doğru bir şekilde tahmin edebilen makine öğrenimi (SVR, LR ve RF) tabanlı yaklaşımlar sunmuşlardır. PV sistemin çıkış gücünü tahmin etmek için

2. KAYNAK ÖZETLERİ


GES'in üretimi etkileyen hava sıcaklığı, nem, rüzgâr hızı, rüzgâr yönü, gök yüzünün görünürlük derecesi, basınç gibi çevresel veriler toplanmış ve analiz edilmiştir. Gerçekleştirilen analizler sonucunda RF tabanlı makine regresyon modelinde PV sistemin çıkış gücü en yüksek oranda tahmin edilmiştir.



3. MATERYAL ve YÖNTEM

3.1. Güneş Enerji Santrali Teknolojisi

Genel olarak Güneş Enerji Santralleri (GES), Yoğunlaştırılmış-Güneş Enerjisi Santrali (Y-GES) ve Fotovoltaik-Güneş Enerji Santrali (PV-GES) teknolojisi olmak üzere iki ana gruba ayrılabilir (Rahman et al. 2019). Yoğunlaştırılmış-Güneş Enerjisi Teknolojisinde (Y-GET) ilk olarak güneş ışınımı yoğunlaştırılarak ısıya dönüştürülür. Daha sonra elde edilen bu ısı enerjisi uygun bir termodinamik çevrim ile işe dönüştürülür (Aydar vd 2010). Y-GET’de güneş ışınımı yoğunlaştırma yönteminde genellikle buhar türbinlerinin çalışması için gerekli olan su buharı üretilerek dolaylı elektrik üretimi gerçekleştirilir. PV-GES’te ise güneş ışınımı, PV paneller kullanılarak doğrudan elektrik enerjisine dönüştürülür. Genel olarak Y-GES’ler dört farklı gruba ayrılırken PV-GES’ler ise üç farklı topolojiye sahiptirler. Şekil 3.1’de Y-GES’in ve PV-GES’in ayrıntılı olarak sınıflandırılması gösterilmiştir (Rahman et al. 2019).



Şekil 3.1. Güneş enerji santrali teknolojilerinin sınıflandırılması

3.1.1. Yoğunlaştırılmış güneş enerjisi teknolojisi

Yoğunlaştırılmış-Güneş Enerjisi Teknolojisinde (Y-GET), güneş ışınımı dolaylı olarak ucuz optik yoğunlaştırıcılar (aynalar ve reflektörler) vasıtasıyla biriktirilerek ısı yöntemlerle elektrik enerjisi üretilir (Sadineni and Boehm). Isıl yöntemlerle elektrik enerjisi üretmek, yoğunlaştırmalı sistemler ile mümkündür (Özgören vd 2012). Y-GET sisteminde konsantre güneş ışığı ile bir sıvı ısıtılır ve elde edilen kızgın buharla klasik yöntemlerle elektrik enerjisi üretilir. Bu sistemler güneş enerjisini toplama yöntemleri, yani kullanılan kolektör bakımından farklılık gösterirler. Y-GET’ler doğrusal ve noktasal

olarak ikiye ayrılmaktadır. Doğrusal yoğunlaştırıcıları, parabolik oluk kollektörler ve lineer Fresnel yansıtıcı sistemleri; noktasal yoğunlaştırıcıları ise, merkezi alıcılı (güneş kulesi) sistemler ve çanak kollektörler oluşturmaktadır (Aydar vd 2010). Y-GET'e dayanan önemli GES konfigürasyonları aşağıda ayrıntılı olarak ele alınmıştır.

3.1.1.1. Parabolik oluk konfigürasyonu

Parabolik oluk konfigürasyonuna sahip GES'lerde, reflektörlerin odak noktasında konumlandırılmış, oluğun uzunluğu boyunca uzanan sıvı (bu sıvı alıcı, soğurucu veya toplayıcı olarak da adlandırılır ve genellikle ısı emici bir yağdır) içeren bir cam tüp üzerine doğrudan güneş ışınımını yansıtan kavisli, aynalı bir oluk kullanılır (Bhatia 2014; Patel 2006). Parabolik oluk toplaçlarından oluşan ısıl güç santralleri temel olarak aşağıdaki ünitelerden oluşur.

- 1) Güneş enerjisi toplama ünitesi
- 2) Termal enerji depolama ünitesi
- 3) Elektrik gücü üretme ünitesi (Öztürk 2013; Zarza-Moya 2012).

Güneş enerjisi toplama ünitesi; bağımsız üniteler şeklinde birbirine paralel bağlanmış parabolik oluk toplaç gruplarından oluşur. Bu sistemlerde genellikle, harici bir yüzey alıcısı oluşturmak için odak hattı boyunca boru şeklinde doğrusal bir tüp yerleştirilir. Parabolik oluk kollektör üniteleri, gelen güneş ışınımını 4 mm kalınlığında ve yüksek yansıtma oranına (%94) sahip aynalar vasıtasıyla doğrusal tüp üzerine yansıtırlar (Öztürk 2013; Patel 2006). Tüpün boyutu ve dolayısıyla konsantrasyon oranı, yansıyan güneş ışınım miktarına ve oluk kollektörlerin üretim toleransına göre belirlenir (Vician et al. 2018). Bu tüp içerisinde ısı transfer akışkanı olarak yüksek sıcaklıklara dayanıklı ısıl yağ bulunur (Öztürk 2013; Patel 2006). Alıcıdan konvektif (taşınımlı) ısı kaybı katsayısını azaltmak için genellikle alıcı borunun etrafına bir cam kapaklı boru yerleştirilir. Cam kapak tüpünün dezavantajı, kollektörden yansıyan güneş ışığının soğurucuya ulaşmak için camdan geçmesidir. Cam tüp temiz olsa bile yaklaşık 0.9'lük bir geçirgenlik kaybına neden olmaktadır. Parabolik oluk kollektörlerin alıcı tüp uzunluğu genellikle 25 m ile 150 m arasındadır (Vician et al. 2018). Alıcı tüp, yüzeyi yaklaşık %97'lik bir absorbtiviteye sahip paslanmaz çelik boru ve cam-metal birleştiricilerden

oluşur. Paslanmaz çelik boruların (soğurucu borular) özel dış kaplaması, güneş ışıını için yüksek bir absorpsiyona, ancak termal radyasyon kaybı için ise düşük bir emisyonu sahiptir (IEA 2010; Vician et al. 2018). Alıcı boru üzerinde meydana gelen yüksek sıcaklık nedeniyle oluşan ısı kayıplarını azaltmak için, cam tüp ile alıcı boru arasındaki hava 0,1 Atm'e vakumlanmıştır (Aydar vd 2010; Öztürk 2013). Ayna dizileri, 5 m ile 6 m çapında kavisli yüzey ile 100 m'den daha uzun olabilir. Bu sistemde, kollektör aynaları otomatik olarak yıkanabilir, bu da bakım maliyetini büyük ölçüde azaltır (Morrison 2001). Çoğunlukla kuzey-güney doğrultusunda yerleştirilmiş kollektör modüllerinin tek eksenli olarak güneşi doğudan-batıya doğru takibini kullanmak yeterlidir; bu nedenle uzun kollektör modülleri üretilmektedir (Fernandez-Garcia et al. 2010; Vician et al. 2018). Tek eksenli güneş takip sistemi güneşin hareketini takip eder. Sonuç olarak güneş takip sistemi ve yerel kontrol üniteleri sayesinde her kollektör grubu ayrı ayrı kontrol edilerek daha verimli bir enerji dönüşümü sağlanır.


Termal Enerji Depolama Ünitesi; tesisin çalışması için gerekli değildir. Bununla birlikte, bir termal depolama sistemi, yalnızca yıllık çalışma saatlerini ve dolayısıyla üretilen elektrik miktarını artırmakla kalmayıp, aynı zamanda güneş sahasında üretilen tüm termal enerjiyi güç bloğu yerine depolama sistemine göndererek üretimin talebe göre yönlendirilmesini sağlar ve bulut geçişleri sırasında enerji santralinin çalışmasını iyileştirir. Bu çalışma stratejisi, güç sahası ve güç bloğu arasında termal bir tampon görevi görerek, dengesiz buhar parametrelerinden buhar türbininin zarar görmesini engeller. Kısaca, buhar türbininin sahip olduğu termal ataleti, güneş enerjisi toplama ünitesi çıkışındaki sıcaklıkla ilgili oluşabilecek bir dengesizliğe karşı filtreleyerek korumuş olur (Zarza-Moya 2012).

Güç Dönüştürme Ünitesi; güneş enerjisi toplama ünitesi tarafından sağlanan termal enerjiyi elektriğe dönüştürür. Sentetik yağdaki ısı, eşanjörler (heat exchanger) vasıtasıyla suya iletilerek ön-ısıtma (preheater), buharlaştırma (evaporator) ve kızdırma (superheated) işlemleriyle 390 °C ve 70 – 90 bar kızgın buhar (superheated steam) elde edilmektedir. Yüksek sıcaklık farkına sahip buhar geleneksel termik santrallerde olduğu gibi türbini döndürerek elektrik üretilmiş olur.

3. MATERYAL ve YÖNTEM

Buhar türbininden çıkan ve ayrıştırılan doymuş buhar, yeniden giriş sıcaklığına ısıtılır ve eş eksenli ikinci türbine gönderilir.

Uzun kollektör yansıtıcılar güneş ışınlarını alıcı boru üzerine odaklar ve borunun içinde bulunan termal yağı 150 – 400 °C sıcaklığa kadar ısıtır ve sıvıyı ısı kaynağı durumuna getirir (Fernandez-Garcia et al. 2010). Buhar türbininin kanatlarına çarpan buhar, geleneksel bir buhar santralinde olduğu gibi senkron bir jeneratöre akuple olan mili (şaftı) döndürür (Belyakov 2019). Buhar, türbinin kanatları boyunca akarken soğur ve genleşir. Buhar türbinine bağlı senkron jeneratör kinetik enerjiyi elektrik enerjisine dönüştürülür. Senkron jeneratör çıkışı yükseltici bir trafo ile enerji nakil hattına verilir. Parabolik oluk konfigürasyonuna Şekil 3.2’de verilmiştir (Yılmaz vd 2017).



Şekil 3.2. Parabolik oluk konfigürasyonuna ait iş akış şeması


3.1.1.2. Güneş kulesi konfigürasyonu

Güneş kulesi ("merkezi kule" santralleri veya "heliostat" enerji santralleri olarak da bilinir) konfigürasyonu ile yaklaşık iki mil karelik bir alanda binlerce izleme aynası (heliostat olarak adlandırılır) ile güneşin termal enerjisi yakalanır ve odaklanır (Bhatia 2014). Şekil 3.3’de Güneş kulesi konfigürasyonu verilmiştir (Bhatia 2014; Estela 2021).

Akışkan veya gazın termal enerjisi elektrik gücüne dönüştürülür. Diğer yoğunlaştırılmış güneş tesisleriyle karşılaştırıldığında, en yüksek ısı-elektrik dönüşüm verimliliğine sahip sistemlerdir (%30'a kadar). Ek olarak, çanak sistemleri sadece yıkama amacıyla az miktarda su gerektirir. Genel olarak parabolik çanak sistemleri 10–25 kW boyutlarındadır. Bu sistemin son derece esnek tasarımı, küçük ölçekli (10 kW'a kadar) uygulamaların yanı sıra şebeke desteği sağlayan yardımcı uygulamalar için büyük ölçekli kurulumlara (300 MW veya daha fazla) uygundur. Ancak çanak sisteminin enerji depolaması yoktur, bu nedenle üretilen gücün anında kullanılması veya şebekeye gönderilmesi gerekir. Tasarımda yeterli depolama kapasitesi, parabolik çanak güneş enerjisi santralini gelecekte daha arzu edilir ve çekici bir teknoloji haline getirebilir (Rahman et al. 2019).

3.1.1.4. Lineer fresnel konfigürasyonu

Lineer fresnel konfigürasyonunda, Şekil 3.5'te görüldüğü gibi, parabolik ayna kullanmak yerine yan yana çok sayıda dar, uzun ve düz aynaların yansıttığı güneş ışınımı ayrı bantlar halinde orta üst kısımdaki yükseltilmiş lineer alıcı boru bir tüpe doğrudan odaklanır (Livatyalı ve Yıldırım 2012; Blanco and Miller 2017).




Şekil 3.5. Lineer fresnel konfigürasyonu

Konsantre güneş enerjisi, tüplerden akan suyu buhara dönüştürür. Bu tesiste kullanılan düz aynalar yansıtıcı yüzey sağlar, bu da daha fazla güneş ışığını yakalar. Diğer yoğunlaştırılmış güneş teknolojileriyle karşılaştırıldığında, bu tesislerin yatırım maliyetleri, basit kurulumu, daha ucuz reflektör malzemeleri ve soğurucu bileşenler

nedeniyle daha düşük olma eğilimi göstermektedir. Ayrıca, sabit alıcı, daha fazla tasarım esnekliği sağlayan döner mekanizmaya ihtiyaç duymaz. Bu nedenle, lineer fresnel reflektörlü güneş enerjisi santralleri, düşük maliyetin yanı sıra yüksek termal performans da sunarlar (Rahman et al. 2019).

3.1.2. Güneş fotovoltaik teknolojisi

Fotovoltaik hücreler, atomları üç boyutlu bir dizide düzenlenmiş kristalli silikondan yapılmıştır ve bu da onu verimli bir yarı iletken yapmaktadır. Fotovoltaik hücreler, en az iki kat yarı iletken malzemeden yapılmış olup bir katmanında pozitif diğer katmanında negatif yük vardır. Işık hücreye girdiğinde, ışıktaki yer alan fotonların bir kısmı yarı iletken atomlar tarafından emilir ve elektronları hücrenin negatif katmanından serbest bırakarak harici bir devreden geçip pozitif katmana geri döner ve bu elektron akışı elektrik akımını üretir. Oluşan akımı arttırmak için bir dizi fotovoltaik hücre modül adı verilen su geçirmez dış hava koşullarına dayanıklı bir yapıda birbirine bağlanır. İki modül seri olarak bağlandığında akım sabit kalırken voltaj iki katına çıkmakta paralel bağlantıda ise voltaj sabit kalıp akımları iki katına çıkmaktadır. İstenen voltaj ve akımı elde edebilmek için modüller bir PV dizisine seri ve paralel olarak bağlanmaktadır (Bhatia 2014). Şekil 3.6'da tipik bir PV sistemin bileşenleri verilmiştir (Anonim 2021e).




Şekil 3.6. Fotovoltaik sistem bileşenleri

Fotovoltaik panellerin performansı genellikle standart test koşulları altındaki Doğru Akım (DC) güç çıkışına göre belirlenir. Standart Test Koşulları (STC), 25 °C'lik hücre çalışma sıcaklığı, 1000 W/m²'lik düşen güneş ışınım seviyesi ve 1.5 spektral dağılımlı hava kütlesi altında tanımlanır. Bu koşulların her zaman PV panellerin sahalarda çalışma altındaki koşulları olamayacağından gerçek performans genellikle STC çıktılarının %85-90'ı kadar olmaktadır. (Bhatia 2014). PV paneller Monokristal, Polikristal, İnce Film, Esnek ve Saydam Güneş Panelleri olmak üzere sınıflandırılmaktadır.

3.1.2.1. Bağımsız ve hibrit fotovoltaik konfigürasyon


Şebekeden bağımsız güneş enerji santralleri, elektrik şebekesinden bağımsız olarak çalışacak şekilde tasarlanmıştır. Genellikle belirli DC veya AC elektrik yüklerini beslemek için boyutlandırılmıştır. Şekil 3.7 (a)'da tipik bir şebekeden bağımsız PV sistem verilmiştir. Şebekeden bağımsız PV sistemlerinin enerji sürekliliğinin artırılabilmesi için içerisinde jeneratör, rüzgâr türbini veya yedek bir şebeke ile desteklenen sistemlerde mevcuttur. Bu sistemler hibrit sistem olarak adlandırılmaktadır. Şekil 3.7 (b)'de tipik bir hibrit PV sistem verilmiştir.



Şekil 3.7. (a) Şebekeden bağımsız PV sistem (b) Şebekeden bağımsız hibrit sistem


3.1.2.2. Şebekeye bağlı fotovoltaiik konfigürasyon

Dünyadaki şebeke bağlantılı PV sistemleri, akü kullanan bağımsız sistemlere kıyasla kurulu kapasitenin yaklaşık %99'unu oluşturmaktadır. Üretilen güç doğrudan iletim, dağıtım ve tüketim için şebekeye yüklendiğinden, şebekeye bağlı güneş santralinde üretilen enerjinin akülere depolanmasına gerek yoktur (Sreedevi 2016). Şekil 3.8'de şebekeye bağlı PV sistem şeması verilmiştir.



Şekil 3.8. Şebekeye bağlı PV sistem şeması


Elektrik güç şebekesi ile etkileşime giren güç eviricileri, merkezi, dizi, modül ve çok dizili invertör olacak şekilde tasarlanabilir. Şekil 3.9'da, şebekeye bağlı güneş enerjisi santrallerinde kullanılan farklı invertör topolojileri verilmiştir (Hassaine 2014). Her bir invertör konfigürasyonu, seri ve/veya paralel PV modüllerinin bir kombinasyonundan oluşmaktadır (Freddy 2016).



Şekil 3.9. İnvertör topolojileri (a) Merkezi (b) Dizi (c) Modül (d) Çoklu-Dizi

3.2. Üç Fazlı Şebeke Bağlantılı Şenyurt Güneş Enerji Santrali


Tegnatia Şirketi tarafından işletilen Şenyurt (Erzurum/Türkiye), üç fazlı merkezi inverter topolojisine sahip 3,36 MW DC kurulu güce sahip lisansız bir GES'dir. Bu GES tesisi her biri 1 MW gücünde olan üç eşit üniteden oluşmaktadır. Bu üniteler Plot-A, Plot-B ve Plot-C olarak adlandırılmaktadır. Bu tesisteki her bir 1 MW'lık GES ünitesi (Plot-A, Plot-B ve Plot-C) için 1000V'luk merkezi inverter kullanılmıştır. Ünitelerdeki 1000V'luk invertörlere toplamda 1,12 MW DC güç bağlanmıştır. 1,12 MW'lık DC güç oluşturulabilmesi için 8 adet Elektrik Bağlantı Kutusu (EBK) kurulmuş olup güçleri 140 KW olarak ayarlanmıştır. 140 kW'lık bir EBK'de ise 24 adet dizi (string) bulunmaktadır. Her bir dizide ise 22 adet 265 W gücündeki paneller seri olarak bağlanmıştır. Bu konfigürasyona sahip GES'lerden elde edilen DC güç üç fazlı merkezi inverter aracılığıyla AC güce dönüştürülmektedir. Dönüştürülen bu AC güç 1250 kVA gücündeki bir güç trafosu yardımıyla şehir şebekesi olan 34,5 kV seviyesine ayarlanarak doğrudan elektrik dağıtım şebekesine entegrasyonu sağlanmaktadır. Şekil 3.10'da Şenyurt GES'in güç akış diyagramı verilmiştir.



Şekil 3.10. Şenyurt GES'in güç akış diyagramı

GES'in güç üretiminin izlenmesi, denetimi ve tahmini için hava istasyonu sensörleri de bulunmaktadır. Bunlar güneş ışıınımı, Fotovoltaik (PV) modül sıcaklığı, dış ortam sıcaklığı ve rüzgâr hızı sensörleridir. Bu sensör gruplarından elde edilen gerçek zamanlı veriler GES'de bulunan Merkezi Denetim ve Veri Toplama (SCADA) sistemi ile uyumlu olan uzaktan izleme ara yüzüne aktarılmaktadır. Böylece GES'in kesintisiz aktif

güç üretiminin denetimi gerçekleştirilmektedir. Bu sensörlerin verileri kayıt altına alınmakta ve uzaktan anlık olarak izlenebilmektedir. Şekil 3.11 (a)'da üç fazlı ve merkezi invertör yapısına sahip olan doğrudan şebeke bağlantılı Şenyurt/Erzurum GES görülmektedir. Şekil 3.11 (b)'de Şenyurt GES'de yapılan kar temizliği işlemi görülmektedir. Şekil 3.11 (c)'de Şenyurt GES'de bulunan hava istasyonu sensörleri verilmiştir. Şekil 3.11 (d)'de panellerin I-V karakteristiklerini ölçen cihaz görülmektedir. Şekil 3.11 (e)'de ise Şenyurt GES'de gerçekleştirilen termal görüntüleme yer almaktadır.



Şekil 3.11. 3 fazlı ve merkezi invertör yapısına sahip Şenyurt/Erzurum GES

3.3. Lineer Regresyon ve Makine Öğrenme Tabanlı Regresyon Modelleri

Regresyon analizi kavramsal olarak, değişkenler arasındaki fonksiyonel ilişkileri araştırmak için kullanılan istatistiksel bir yöntemdir (Gök ve Altuntaş 2017). Değişkenler arasındaki ilişkinin istatistiksel olarak incelenmesi söz konusu olduğunda regresyon ve korelasyon ilk olarak akla gelen yöntemlerdendir. Korelasyonda değişkenler arasındaki ilişkinin, derecesi ve yönü incelenirken regresyonda ilişkiyi açıklamak için bir model kurulur (Güriş vd 2017). Daha açık olarak, aralarında ilişki olan iki ya da daha fazla sürekli değişkenden birinin bağımlı değişken/(ler) (yordanan, açıklanan, dependent variable, response variable) diğerinin bağımsız değişken/(ler) (açıklayıcı, yordayan, independent variable, predictor variable) olarak ayrımı ile aralarındaki ilişkinin bir matematiksel eşitlik ile açıklanması sürecini anlatır (Büyüköztürk 2020; Karagöz 2019; Seçer 2017). Regresyon analizinde örnek alınması söz konusudur. Yatay kesit verilerinde n birimli bir örnek N birimli bir anakütleden tesadüfi olarak seçilirken, zaman serisi

verilerinde geçmişte başlayıp devam eden bir anakütleden n birimli bir birimi takip eden birimlerden oluşan bir örnek alınmaktadır. Bu nedenle önce anakütle ilişkisi veya anakütle ilişkisinin yapısı incelenmelidir (Güriş vd 2017). Genel olarak bir regresyon analizinde problemin tanımlanması, modelin belirlenmesi ve parametrelerin tahmini adımları gerçekleştirilir (Kurtner et al. 2005). Regresyon analizinde;

- a) Bağımlı değişken bir, bağımsız değişken bir ise, yöneme **basit regresyon analizi**,
- b) Bağımlı değişken bir, bağımsız değişken iki ya da daha fazla ise **çoklu regresyon analizi**,
- c) Bağımlı değişken iki ya da daha fazla ise **çok değişkenli regresyon analizi** denir (Büyüköztürk 2020).

Kişiler sahip oldukları beyni sayesinde düşünebilir, karar verebilir, geçmiş anımsayabilir ve geleceği planlayabilirler. Adına “Beyin” dediğimiz beden parçamızla ilgili bilinmesi gereken en önemli bilgi, bu evrendeki en karmaşık maddesel nesne olduğudur. Beyin, insanlar öğrendikçe değişen, fiziksel yapısını değiştirebilen ve uyum gösterebilen bir yapıya sahiptirler (Canan 2020). Bilim insanları son çeyrek asırda insanların beynini taklit edebilen “Yapay Zekâya” sahip makineler geliştirilmesine ve bunların aktif olarak hayatın içerisinde yer almasına yönelik büyük çaba göstermişlerdir (Unluturk 2019). Yapay Zekâ (YZ), 1950’li yıllarda yeni gelişmeye başlamış ve bilgisayar bilimcilerin bugün de cevap aradığı “bilgisayarlar düşünebilir mi?” sorusuna cevap ararken ortaya çıkmıştır (Chollet 2019). Makine Öğrenmesi (ML) ise şu temel soruya istinaden ortaya çıkmıştır: Bir makine bir insan gibi deneyimlerinden ve geçmiş verilerden öğrenebilir mi? Geliştiricilerin veriden öğrenmek için elle kurallar oluşturmaktan ziyade bilgisayarlar veriye bakarak bu kuralları kendileri öğrenebilir mi? (javaTpoint 2021; Chollet 2019). İnsanoğlunun cevap aradığı bu sorulara makinenin verdiği ironik cevap Şekil 3.12’deki diyalogda görülmektedir (javaTpoint 2021).



Şekil 3.12. İnsan ve makine arasındaki diyalog


Makine Öğrenimi, insan bilgisini ve muhakemesini inşa edilen makinelere uygun bir forma dönüştürerek aktararak otomatik sistemler geliştirilmesine yönelik girişim dizisinin en yenisidir (Deisenroth et al. 2019). Yaklaşık 40-50 yıl önce ML bilim kurguydu, ancak bugün hayatımızın vazgeçilmez bir parçasıdır. ML nöroloji, biyoloji, istatistik, matematik ve fizik gibi farklı bilim dallarını içinde barındıran çok disiplinli bir çalışma alanıdır (Marsland 2015). Son yıllarda doğru veri kümeleriyle birlikte ML tabanlı birçok farklı yapıya sahip algoritmalar kullanılarak birçok karmaşık gerçek problemler etkin ve hızlı bir şekilde çözülmüştür. ML ile sürücüsüz arabalardan Facebook tarafından görüntü etiketlemeye ve e-posta sağlayıcıları tarafından spam tespitine, öneri sistemlerine (bu sistemler arama motorları, e-ticaret siteleri (Amazon), eğlence platformlarına (Google Play, Netflix) ve birden çok web ve mobil uygulama tarafından her yerde kullanılmaktadır), müşteri segmentasyonuna (veri madenciliği ve makine öğrenimi kullanarak, bireysel pazarlama teklifleri ve teşvikler için doğru bir tahmin elde edilebilmektedir), görüntü ve video tanımayla, hileli işlemlere (finans sisteminde makine öğrenimi kullanılarak her türlü olası dolandırıcılık faaliyeti belirlenebilmekte ve otomatik olarak üstün doğru tahmine dayalı koruma modelleri oluşturulabilmektedir), sanal kişisel asistanlara (Alexa ve GoogleAsistan'dan Cortana ve Siri'ye kadar, birini aramak, e-posta açmak, randevu ayarlamak ve daha fazlası gibi sesli talimatlarımızı kullanarak doğru bilgileri bulmak için birden fazla sanal kişisel asistan bulunmaktadır), duygu analizine (konuşmacı veya yazarın duygu ve düşüncelerini belirlemeye yardımcı olmaktadır), müşteri hizmetleri otomasyonuna (artan sayıda çevrimiçi müşteri etkileşimlerini yönetilmektedir) kadar sayısız karmaşık problemler etkili ve hızlı bir şekilde çözülmüştür (Maruti Techlabs 2021; javaTpoint 2021).

ML algoritma çeşitlerinin nasıl tanımlanacağına dair bazı farklı yaklaşımlar bulunmaktadır. Ancak, genel olarak amaçlarına göre kategorilere ayrılabilir ve ana kategorileri şunlardır:

Denetimli Öğrenme (Supervised Learning): Sistemin gerçek giriş ve çıkış verilerine (hedeflerine) ait bir eğitim veri seti içerir. Ancak, kullanılan eğitim veri seti uzman bir kişi tarafından daha önceden doğru bir şekilde tanımlanır. ML algoritması tanımlanan bu eğitim veri setini kullanarak sistemin olası matematiksel modelini genelleştirir. Kısaca eğitim veri setinden öğrenme de denir (Marsland 2015). Sınıflandırma ve regresyon problemlerinde sıklıkla tercih edilir.

Denetimsiz Öğrenme (Unsupervised Learning): Sistemin gerçek giriş ve çıkış verileri uzman bir kişi tarafından tanımlanmaz. ML algoritması girdiler arasındaki benzerlikleri belirlemeye çalışır, böylece ortak bir yanı olan girdiler birlikte kategorize edilir. Denetimsiz öğrenmeye uygun istatistiksel yaklaşım “Yoğunluk Tahmini” olarak bilinir (Marsland 2015).


Takviyeli Öğrenme (Reinforcement Learning): Bu ML algoritması denetimli ve denetimsiz öğrenme arasında bir yeredir. Bu algoritma sistemin doğru matematiksel modelini oluşturmak için farklı olasılıklar keşfetmeli ve denemelidir. Bunun için uzman kişi, öğrenen algoritma karar verdiğinde bu kararın doğru olduğu durumlar için sistemi ödüllendirir ve yanlış olduğu durumları için ise cezalandırır. Fakat, burada denetimli öğrenmedeki gibi sisteme çok detaylı bir tanımlama bilgisi verilmez. Bu yöntem robotik, oyun programlama, tıbbi teşhis ve üretim otomasyonunda yaygın olarak kullanılmaktadır (Orhan 2020). Şekil 3.13’de, verilerin düzenlenmesi, modelin seçimi ve gerçekleştirme gibi denetimli ML modelleme sürecinin temel bileşenleri görülmektedir (Anonim 2019).



Şekil 3.13. Denetimli ML süreci

Regresyon analizi, genel olarak bağımlı değişkenler ile bunların tahmininde kullanılan bir veya daha fazla bağımsız değişken arasında matematiksel bir model belirlemektir. Genellikle regresyon analizinde, doğrusal regresyon gibi standart istatistiksel teknikler kullanılır. Halbuki birçok gerçek problem basit ve doğrusal bir regresyon projeksiyonuna sahip değildir. Örneğin, satış hacmi, hisse senedi fiyatları ve ürün arıza oranı tahmini gibi gerçek zamanlı problemler birden fazla değişkenin karmaşık etkileşimini içerebilmektedir (Imandoust and Bolandraftar 2013). Ele alınan problemin birden fazla değişkene bağlı olması ve her bir değişkenin de kendi içinde karmaşık bir etkileşim içerisinde olması durumunda genellikle denetimli makine öğrenme tabanlı regresyon modelleri tercih edilmektedir. Veri bilimi ve makine öğreniminde kullanılan çeşitli regresyon türleri bulunmaktadır. Her türün ele alınan probleme göre üstünlükleri ve dezavantajları vardır. Ancak özünde, tüm regresyon yöntemleri bağımsız

değişkenlerin bağımlı değişken üzerine etkisi analiz edilir. Şekil 3.14’de bazı önemli regresyon çeşitleri verilmiştir.



Şekil 3.14. Önemli regresyon çeşitleri

3.3.1. Lineer regresyon


3.3.1.1. Basit doğrusal regresyon modeli

Basit doğrusal regresyon modelinde bir bağımlı Y değişkeni ve bir bağımsız X değişkeni bulunur. Değişken çiftleri dizilirken tam bir doğrusal ilişki ortaya çıkmaz. Ancak anakütle ilişkisinin doğrusal model ile açıklanmasının uygun olacağı varsayımı ile anakütle regresyon modeli oluşturularak, alınan örnek ile örnek regresyon modelinin parametreleri hesaplanarak anakütle regresyon modelinin parametreleri tahmin edilmiş olur. Burada değişkenler arasındaki söz konusu ilişkinin örnek ilişkisi değil anakütle ilişkisi olduğu gözden kaçmamalıdır (Güriş vd 2017). Ayrıca regresyon modeller deterministik olmayıp rassal modellerdir ve hata terimi (ε) içerirler. Hata terimi tesadüfi

bir değişkendir. Bu durumda basit anakütle regresyon modeli Denklem 3.1'deki gibi yazılır.

$$Y_i = \beta_0 + \beta_1 X_i + \varepsilon_i \quad (3.1)$$

Burada β_1 regresyon doğrusunun eğimini ifade eder. β_1 'in işareti değişkenler arasındaki ilişkinin yönünü gösterir. Pozitif işaretli ise değişkenler arasında doğru yönlü, negatif işaretli ise değişkenler arasında ters yönlü ilişki vardır (Güriş vd 2017). β_0 regresyon doğrusunun y eksenini kesim noktasını ve ε da hata terimini ifade eder. Diğer bir deyişle hata terimi, Y değişkenini etkileyen X dışındaki tüm faktörleri temsil eder. Değişkenlerin değerlerinin dağılımını gösteren serpilme diyagramı grafiği Şekil 3.15'teki gibi oluşabilir.



Şekil 3.15. Serpilme diyagramı

Değişkenler arasındaki ilişkinin doğrusal olması demek, serpilme diyagramındaki dağılıma göre değişken çiftleri arasından geçen bir doğru ile ilişkinin açıklanabileceğini varsaymaktır (Güriş vd 2017). Denklem 3.1'deki β_0 ve β_1 katsayıları tam olarak bilinemez. Çünkü bu denklem, iki değişken arasında olduğunu varsaydığımız bir eşitliği göstermektedir. Bundan dolayı bu eşitlikteki β_0 ve β_1 katsayıları tahmin edilebilir. Anakütle doğrusal regresyon modelinin örnekten tahmini Denklem 3.2 ile verilmiştir.

$$Y_i = \hat{\beta}_0 + \hat{\beta}_1 X_i + e_i \quad (3.2)$$

Değişkenler üzerinde şapkalar tahmin edilen değerleri göstermektedir. i indisi ise ölçüm (gözlem) sırasını belirtmektedir. Burada e_i , anakütle hata teriminin örnekten elde edilen değerlerini gösterir ve artık (residual) olarak da adlandırılır. Artık terimi i . birimin

bağımlı değişken bakımından ölçüm (gözlem) değeri ile tahmin değeri arasındaki farktır (Gamgam ve Altunkaynak 2021).

$$e_i = Y_i - \hat{Y}_i \quad (3.3)$$

Denklem 3.3'deki e_i değeri Denklem 3.2'de yerine yazılırsa,

$$E(Y_i) = \hat{Y}_i = \hat{\beta}_0 + \hat{\beta}_1 X_i \quad (3.4)$$

Ayrıca regresyon analizinde sıklıkla kullanılan En Küçük Kareler yönteminin dayandığı birtakım temel varsayımlarda bulunmaktadır:

- Doğrusal regresyon modeline sahiptir.
- Hata terimi (ε_i) stokastiktir.
- Hata (ε_i) normal dağılımlıdır.
- Hatanın (ε_i) ortalaması sıfırdır.
- Hatanın (ε_i) varyansı sabittir.
- Hata (ε_i) ile X_i 'nin ortak varyansı sıfırdır.
- Hata terimleri arasında ardışık bağımlılık (otokorelasyon) yoktur.
- Tam çoklu doğrusallık (multicollinearity) yoktur.
- Gözlem sayısı, tahmin edilecek parametre sayısından fazla olmalıdır.
- X_i değerleri yinelenen örneklerde değişmez.
- Belli bir örneklerdeki X_i değerlerinin hepsi aynı değildir
- Regresyon modeli doğru kurulmuştur (Karagöz 2019; Güriş vd 2017).

Regresyon modelindeki katsayılar doğrusaldır. Değişkenler doğrusal olmayabilir. Hata terimi (ε_i), X 'in her bir değeri için şansa bağlı olarak pozitif, negatif veya sıfır değerlerini belirli bir olasılıkla almaktadır (Karagöz 2019). Hata terimlerinin dağılımının normal dağılıma sahip olması Normallik varsayımını ifade etmektedir. Sıfır ortalama varsayımı hata teriminin beklenen değerinin sıfıra eşit olmasıdır. Yani, $E(\varepsilon) = 0$. Sabit varyans varsayımı hata terimlerinin ayrı ayrı varyanslarının birbirine eşit olması gerektiğini ifade eder. Yani,

$$Var(\varepsilon_i) = E[\varepsilon_i - E(\varepsilon_i)]^2 \quad (3.5)$$

şeklinde ifade edersek, $E(\varepsilon_i) = 0$ olduğundan,

$$Var(\varepsilon_i) = E(\varepsilon_i)^2 = \sigma^2 \quad (3.6)$$

Burada σ^2 gözlemlerin varyansıdır ve sabit olduğunu ifade etmektedir. Bu varsayıma göre X_i 'ler hangi değeri alırlarsa alsınlar oluşacak artıkların varyansı aynı ve sabittir (Güriş vd 2017). Hata (ε_i) ile X_i 'nin ortak varyansının sıfır olması demek, hata terimi ile X açıklayıcı değişkeni ilişkisizdir. Simgesel olarak $E(\varepsilon_i, X_i) = 0$ yazılır.

$$Cov(\varepsilon_i, X_i) = E[(\varepsilon_i - E(\varepsilon_i))(X_i - E(X_i))] \quad (3.6)$$

$E(\varepsilon_i) = 0$ ise, $Cov(\varepsilon_i, X_i) = E[(\varepsilon_i)(X_i - E(X_i))]$ olur. $Cov(\varepsilon_i, X_i) = E(\varepsilon_i, X_i) - E(\varepsilon_i)E(X_i)$ ve $E(\varepsilon_i) = 0$ ise, $Cov(\varepsilon_i, X_i) = E(\varepsilon_i, X_i) = 0$ elde edilir (Karagöz 2019).

Otokorelasyon olmaması durumu ise ardı ardına gelen veya belirli aralıklarla birbirini izleyen hata terimleri arasında doğrusal ilişki olması otokorelasyon olarak adlandırılır. Hata terimleri arasındaki ilişki,

$$E[\varepsilon_i - E(\varepsilon_i)][\varepsilon_j - E(\varepsilon_j)] i \neq j \quad (3.7)$$

olarak ifade edilirse, $E(\varepsilon_i) = 0$ ve $E(\varepsilon_j) = 0$ olduğundan, otokorelasyon olmaması,

$$E(\varepsilon_i, \varepsilon_j) = 0 \quad i \neq j \quad (3.8)$$

Ayrıca bağımsız değişken olan X_i değişkeni tesadüfi değişken olmamalıdır. Aksi taktirde tekrarlanan örnekler için X_i değişkeni sabit olmayacaktır (Güriş vd 2017). Bunlara ilave olarak bağımsız değişkenler arasında tam doğrusal ilişki olmamalıdır. Çoklu bağlantı halinde bir bağımsız değişken, diğer bir bağımsız değişken veya

değişkenler tarafından tam olarak tahmin edilmesi durumunda gerçekleşen ekstrem duruma tekillik (singularity) denilmektedir. Çoklu bağlantı, bir bağımsız değişkenin diğer bağımsız değişkenlerle olan ilişkisinin derecesine göre bağımsız değişkenin tahmin gücünü azaltır (Karagöz 2019). $\hat{\beta}_0$ ve $\hat{\beta}_1$ 'in tahmininde sıklıkla en küçük kareler tahmin edicisi kullanılır. β_0 ve β_1 parametrelerinin tahmininde hata terimlerinin karelerinin toplamının en küçük olması istenir. Bu amaçla, n tane (x, y) gözlemine bağlı olarak belirlenecek hataların karelerinin toplamının minimum olması gerekir (Semiz 2009).

$$L = \sum_{i=1}^n \varepsilon_i^2 = \sum_{i=1}^n [Y_i - (\beta_0 + \beta_1 X_i)]^2 \quad (3.9)$$

Denklem 3.9'u minimum yapacak β_0 ve β_1 'in değerleri türev alınarak bulunabilir.

$$\frac{\partial L}{\partial \beta_0} = 2 \sum_{i=1}^n (Y_i - \hat{\beta}_0 - \hat{\beta}_1 X_i)(-1) \quad (3.10)$$

$$\frac{\partial L}{\partial \beta_1} = 2 \sum_{i=1}^n (Y_i - \hat{\beta}_0 - \hat{\beta}_1 X_i)(-X_i) \quad (3.11)$$

Denklem 3.10 ve 3.11 eşitlikleri sıfıra eşitlenerek katsayıların tahminleri bulunur.

$$-2 \sum_{i=1}^n (Y_i - \hat{\beta}_0 - \hat{\beta}_1 X_i) = 0 \quad (3.12)$$

ve

$$-2 \sum_{i=1}^n (Y_i - \hat{\beta}_0 - \hat{\beta}_1 X_i)(X_i) = 0 \quad (3.13)$$

$\bar{y} = \frac{1}{n} \sum_{i=1}^n y_i$ ve $\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i$ olarak ele alınırsa, Denklem 3.12 ve 3.13 eşitliğinden katsayılar tahmini,

$$\hat{\beta}_0 = \bar{y} - \hat{\beta}_1 \bar{x} \text{ ve } \hat{\beta}_1 = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sum_{i=1}^n (x_i - \bar{x})^2} \text{ olarak bulunur.}$$

Gerçekte, belirleme katsayısı modeldeki iki değişken arasındaki Pearson korelasyon katsayısının karesidir. Bu katsayı ile modelin toplam varyansı ne oranda açıkladığı belirlenir (Semiz 2009). Tahmin edilen bir regresyon modelinin başarısı yüzdelik bir derece olarak belirleme katsayısı (determinasyon katsayısı) R^2 ile değerlendirilir. Bunun için bağımlı değişkene ilişkin Toplam Kareler Toplamı (TKT) parçalara ayrılır. Bağımlı değişkendeki toplam değişkenliğin ölçüsü olan TKT'nin parçalara ayrılması aşağıdaki gibi gösterilebilir (Gamgam ve Altunkaynak 2021). Hata terimi daha önce Denklem 3.3'de tanımlanmıştı.

$e_i = Y_i - \hat{Y}_i$ eşitliğin sağ tarafına $\bar{Y}$ istatistiğini ekleyip çıkarırsak, $Y_i - \hat{Y}_i = Y_i - \hat{Y}_i + \bar{Y} - \bar{Y}$ Bu eşitliğin sağ tarafı aşağıdaki gibi düzenlenebilir.

$$Y_i - \hat{Y}_i = (Y_i - \bar{Y}) - (\hat{Y}_i - \bar{Y}) \quad (3.14)$$

Bu eşitliğin her iki tarafının karesi alınır ve n üzerinden toplanırsa

$$\sum_{i=1}^n (Y_i - \hat{Y}_i)^2 = \sum_{i=1}^n (Y_i - \bar{Y})^2 - \sum_{i=1}^n (\hat{Y}_i - \bar{Y}) \quad (3.15)$$

$$\sum_{i=1}^n (Y_i - \bar{Y})^2 = \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 + \sum_{i=1}^n (\hat{Y}_i - \bar{Y}) \quad (3.16)$$

Bu eşitliğin solundaki terim Toplam Kareler Toplamı (TKT), sağındaki ilk terim Regresyon Kareler Toplamı (RKT) ve ikinci terim de Artık Kareler Toplamı (AKT) olarak adlandırılır.

$$\sum_{i=1}^n (Y_i - \bar{Y})^2 = \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 + \sum_{i=1}^n (\hat{Y}_i - \bar{Y}) \rightarrow TKT = RKT + AKT \quad (3.17)$$

Toplam Kareler Toplamı (TKT), bağımlı değişkendeki toplam değişkenlik ölçüsüdür. Regresyon Kareler Toplamı (RKT), bağımlı değişkendeki toplam değişkenliğin kullanılan model veya bağımsız değişken ile açıklanabilen kısmıdır. Artık Kareler Toplamı (AKT) ise bağımlı değişkendeki toplam değişkenliğin kullanılan model veya bağımsız değişken ile açıklanamayan kısmıdır (Gamgam ve Altunkaynak 2021).

Belirleme (determinasyon) katsayısı $\hat{Y}_i = \hat{\beta}_0 + \hat{\beta}_1 X_i$ modeli için $R^2 = R_{Y.X}^2$ aşağıdaki gibi tanımlanır.

$$R_{Y.X}^2 = \frac{RKT}{TKT} = \frac{TKT - AKT}{TKT} = 1 - \frac{AKT}{TKT} \quad (3.18)$$

Yukarıdaki denklemden de görüldüğü gibi belirleme katsayısı $R_{Y.X}^2$ $0 \leq R^2 = R_{Y.X}^2 \leq 1$ arasında değişkenlik gösterir (Gamgam ve Altunkaynak 2021).

3.3.1.2. Çoklu doğrusal regresyon modeli

İki değişkenli regresyon modeli, uygulamada çoğu zaman yetersizdir (Karagöz 2019). Çoklu regresyon analizi, bağımlı değişkenle ilişkili olan iki ya da daha çok bağımsız değişkene dayalı olarak, bağımlı değişkenin tahmin edilmesine yönelik bir analiz türüdür (Büyüköztürk 2020). Y bağımlı değişkeninin $X_1, X_2, \dots, X_m$ gibi m bağımsız değişkenden etkilendiği kabul edilir ve aralarındaki ilişki için doğrusal bir denklem seçilirse Y 'nin regresyon denklemi şu şekilde yazılabilir:

$$Y = \alpha + b_1 X_1 + b_2 X_2 + b_3 X_3 + \dots + b_m X_m \quad (3.19)$$

Bu denklemde Y , bağımsız değişkenler $X_1 = x_1, X_2 = x_2, \dots, X_m = x_m$ değerini aldığı anda Y değişkeninin beklenen değerini göstermektedir. $a, b_1, b_2, \dots, b_m$ regresyon katsayıları basit regresyondakine benzer şekilde, gözlem noktalarının regresyon denkleminin gösterdiği çok boyutlu düzlemde ε_{yi} uzaklıklarının karelerinin toplamı,

$$\sum_{i=1}^N (e_{yi})^2 = \sum_{i=1}^N (Y_i - a - b_1 x_{1i} - b_2 x_{2i} - \dots - b_m x_{mi})^2 \quad (3.20)$$

ifadesini minimum yapacak şekilde hesaplanır (Bayazıt ve Yeğenoğuz 2013).

Y 'nin X_1 ve X_2 gibi iki bağımsız değişkene göre EKK tahmin edicileri bulabilmek için,

$$Y_i = \beta_0 + \beta_1 X_{1i} + \beta_2 X_{2i} + u_i \quad (3.21)$$

Ana kütle regresyon fonksiyonunun tahmini veren örneklem regresyon fonksiyonu

$$\hat{Y}_i = \hat{\beta}_0 + \hat{\beta}_1 X_{1i} + \hat{\beta}_2 X_{2i} + \hat{u}_i \quad (3.22)$$

biçiminde yazılır. İki değişkenli regresyon modelinde açıklandığı gibi, EKK yöntemi, $\sum \hat{u}_i^2$ ifadesini en küçük yapan $\hat{\beta}_0$, $\hat{\beta}_1$ ve $\hat{\beta}_2$ değerlerini verir. Yani, ana kütle katsayılarının bilinmeyen değerlerini, hata kareler toplamı olan $\sum \hat{u}_i^2$ 'yi en küçük yapacak biçimde seçmeyi sağlar. Yani, $\sum (Y - \hat{Y})^2 = \sum (Y - \hat{\beta}_0 + \hat{\beta}_1 X_1 + \hat{\beta}_2 X_2)^2 = \text{Minimum}$ olması için;

$\hat{\beta}_0$, $\hat{\beta}_1$ ve $\hat{\beta}_2$ katsayılarına göre kısmi türevler alınıp sıfıra eşitlenerek, birinci dereceden üç bilinmeyenli üç normal denklemi aşağıdaki gibi elde edilir.

$$\sum \hat{Y} = n\hat{\beta}_0 + \hat{\beta}_1 \sum X_1 + \hat{\beta}_2 \sum X_2 \quad (3.23)$$

$$\sum X_1 \hat{Y} = \hat{\beta}_0 \sum X_1 + \hat{\beta}_1 \sum X_1^2 + \hat{\beta}_2 \sum X_1 X_2 \quad (3.24)$$

$$\sum X_2 \hat{Y} = \hat{\beta}_0 \sum X_2 + \hat{\beta}_1 \sum X_1 X_2 + \hat{\beta}_2 \sum X_2^2 \quad (3.25)$$

Bu denklemlerin çözümü için, iki değişkenli regresyonda olduğu gibi, yok etme metodu, matris işlemleri metodu veya aşağıdaki formüller kullanılarak $\hat{\beta}_1 = \frac{(\sum y_i x_{1i})(\sum x_{2i}^2) - (\sum y_i x_{2i})(\sum x_{1i} x_{2i})}{(\sum x_{1i}^2)(\sum x_{2i}^2) - (\sum x_{1i} x_{2i})^2}$, $\hat{\beta}_1 = \frac{(\sum y_i x_{2i})(\sum x_{1i}^2) - (\sum y_i x_{1i})(\sum x_{1i} x_{2i})}{(\sum x_{1i}^2)(\sum x_{2i}^2) - (\sum x_{1i} x_{2i})^2}$, $\hat{\beta}_0 = \bar{Y} - \hat{\beta}_1 \bar{X}_1 - \hat{\beta}_2 \bar{X}_2$ değerleri elde edilebilir.

3.3.2. Makine öğrenme tabanlı regresyon modelleri

Bu tez çalışmasında, makalelerde sıklıkla tercih edilen Çoklu Lineer Regresyon (ÇLR), K-En Yakın Komşuluk Regresyon (K-NNR) ve Torbalama Regresyon (BR) yöntemleri kullanılmıştır. ÇLR yöntemi önceki bölümde detaylı olarak ele alınmıştır. K-NNR ve BR yöntemleri detaylı olarak aşağıdaki bölümde ayrıntılı olarak ele alınmıştır.

3.3.2.1. K-en yakın komşuluk regresyon modeli

Hem sınıflandırma hem de regresyon problemlerini çözmek için kullanılabilen basit, uygulaması kolay parametrik olmayan ve denetimli makine öğrenme yöntemlerden en iyi bilinenlerinden bir tanesi K-En Yakın Komşuluk (KNN) algoritmasıdır (Anonim 2021a). KNN, eğitim verilerini basitçe depoladığımız ve yeni tahminler yapmak için kullandığımız örnek tabanlı öğrenmeye bir örnektir (Jordan 2017). K-En Yakın Komşuluk Regresyonu (K-NNR), aynı komşuluktaki gözlemlerin ortalamasını alarak bağımsız değişkenler ve sürekli sonuç arasındaki ilişkiyi sezgisel bir şekilde tahmin eder (Anonim, 2021b). K-NNR’de çıktı, cismin özellik değeridir. Bu değer, en yakın komşuların değerlerinin ortalamasıdır (Anonim 2021c). Komşuluk boyutunun uzman tarafından ayarlanması gerekir veya ortalama kare hatasını en aza indiren boyutu seçmek için çapraz doğrulama kullanılarak seçilebilir (Anonim 2021b). K-NNR algoritmasının akış mantığı aşağıdaki gibidir (Lavrenko 2015).

- **Veri:**
 - Eğitim örnekleri $\{x_i, y_i\}$
 - x_i ... örneklerin öznitelik gösterimi
 - y_i ... reel değerli hedef
 - Hedefi tahmin etmek istediğimiz test noktası x
- **Algoritma:**
 - Her eğitim örneği x_i için $D = \{x, x_i\}$ uzaklığını hesapla
 - $x_{i1} \dots x_{ik}$ ’ya en yakın k örneklerini ve $y_{i1} \dots y_{ik}$ etiketlerini seç
 - $y_{i1} \dots y_{ik}$ ’nın ortalamasının çıktısı: $\hat{y} = f(x) = \frac{1}{k} \sum_{j=1}^k y_{ij}$

K-en yakın komşuları bulmak için bir “tahminde yakınlık” ölçüsü tanımlanır (diğer bir ifadeyle, uzaklık). Gözlemler n -boyutlu bir özellik uzayında bulunur. Gözlemler arasındaki benzerlik ya da benzemezlik ölçüleri uzaklıklar olarak ifade edilebilmektedir (Bulut 2019). Uzayda iki nokta arasındaki mesafeyi bulmanın birçok yolu vardır. Uzaklık ölçümünde kullanılan Manhattan Uzaklık Ölçüsü, Minkowski Uzaklık Ölçüsü, Mahalanobis Uzaklık Ölçüsü gibi birçok ölçüm teknikleri olsa da en yaygın şekilde kullanılanı Öklid Uzaklık ölçüm tekniğidir (Xing et al. 2012). Manhattan uzaklığı, bir veri noktasından diğerine gitmek için ızgara benzeri bir yol izlendiğinde kat edilen mesafe olarak tanımlanır. Bu mesafe taksi mesafesi veya blok mesafesi olarak da bilinmektedir. İki nokta arasındaki uzaklık, Kartezyen koordinatlarının mutlak farklarının toplamıdır (Gokte 2020). Manhattan uzaklığı L_1 norm olarak da bilinmektedir.

$$\text{Manhattan uzaklığı} = \sum_{i=1}^n |x_i - y_i| \quad (3.26)$$

Q sayıda değişkene bağlı bir uzaklık hesaplamak istendiğinde Minkowski yöntemi kullanılmaktadır (Özdemir 2019). Öklid ve Manhattan uzaklığının genelleştirilmiş halidir. L_n norm olarak da bilinmektedir. N boyut için Minkowski uzaklık formülü,

$$\text{Minkowski uzaklığı} = (\sum_{i=1}^n |x_i - y_i|^p)^{1/p} \quad (3.27)$$

Mahalanobis uzaklığı Hintli istatistikçi Prasanta Chandra Mahalanobis tarafından geliştirilmiş olan uzaklık ölçütlerinden biridir (Anonim 2021d). Bu uzaklık ölçütü, genellikle çok değişkenli veriler içerisindeki aykırı verilerin tespitinde istatistiksel teknik olarak da sıklıkla kullanılmaktadır (Hodge and Austin 2004). Mahalanobis değeri, ki kare tablo değeriyle karşılaştırılır. Hesaplanan Mahalanobis değeri, bulunan tablo değerinden küçükse, çok değişkenli normallik varsayımının sağlandığı kabul edilir. Hesaplanan Mahalanobis değeri, ki kare tablo değerinden büyükse, uç değerler olarak kabul edilir (Karagöz 2019). X çok değişkenli bir veri vektörü, μ bağımsız değişkenlerin ortalama değerlerinin vektörünü, Σ bağımsız değişkenlerin kovaryans matrisinin tersini ve T ise vektörün transpoze edilmesi gerekliliğini göstermektedir. Mahalanobis uzaklık formülü,

$$\text{Mahalanobis uzaklığı} = D(X, \mu) = \sqrt{(X - \mu)^T \Sigma^{-1} (X - \mu)} \quad (3.28)$$


Öklid uzaklığı (L_2 normu olarak da adlandırılır) iki noktayı doğrudan birbirine bağlayan bir doğrunun mesafesidir. Makine öğrenimi algoritmalarında sıklıkla tercih edilmektedir. Verilerin sürekli olduğu durumlarda oldukça elverişlidir. Öklid uzaklık formülü,

$$\text{Öklid uzaklığı} = D(X, Y) = \sqrt{\sum_1^n (X_i - Y_i)^2} \quad (3.29)$$

3.3.2.2. Torbalama regresyon modeli

Makine öğrenme algoritmaları ele alınan probleme göre tek başlarına optimum çözümleri bulmaktan oldukça uzak kalabilmektedir. Optimum çözümü bulamayan ancak %50'den daha iyi isabet oranı kaydedemeyen modeller zayıf modeller ya da zayıf öğrenciler olarak isimlendirilirler (Arslan 2020). Makine öğrenme modellerinin tek başlarına zayıf kaldığı durumlarda çok sayıdaki zayıf modelin bir araya geldiği topluluk modeli (ensemble model) kullanılır. Topluluk modelleri, temel öğrenciler adı verilen bir zayıf model koleksiyonundan şaşırtıcı derecede güçlü modeller oluştururlar (Lippert 2021). Buna ilave olarak, K-NN, Destek Vektör Makineleri (SVM) gibi modellerle kıyasla genellikle daha az parametre ayarı gerektirirler.

Torbalama (Bagging) Regresyon (BR) topluluk modellerinden bir tanesidir. Bag kelimesinin tercih edilmesinde bootstrap ve aggregation kelimeleri etkili olmuştur. Bootstrap, bir veri setinde rastgele alt kümeler seçmek anlamında kullanılmaktadır. Bagging modelinde, ana veri kümesinin çok sayıda alt kümesi seçilmektedir. Regresyonda tüm zayıf modellerin bulunduğu tahminlerin ortalaması, sınıflandırmada ise en çok oyu alan kategori nihai seçim olarak belirlenmektedir. Şekil 3.16'da BR algoritması özetlenmiştir (Arslan 2020).




Şekil 3.16. Torbalama Algoritması

4. ARAŞTIRMA BULGULARI ve TARTIŞMA


Geliştirilen güç üretim tahmin modelinde ilk olarak klasik Çoklu Lineer Regresyon (ÇLR) analizi ele alınmıştır. Daha sonra makine öğrenme tabanlı K-NN ve Torbalama (Bagging) gibi ileri regresyon analizleri ile güç üretim tahmin modeli geliştirilmiştir. Doğrudan şebeke beslemeli üç fazlı merkezi inverter yapısına sahip GES’lerde şebeke elektriğindeki kesinti GES’in üretimini durdurmaktadır. Ayrıca GES’lerde bulunan hava istasyonu sensör arızalarından kaynaklı veri alma problemleri olabilmektedir. Sensörlerden bilgi almak için oluşturulan SCADA tabanlı uzaktan izleme ve denetim sisteminden kaynaklı olarak sensör verilerin kaydedilmesinde de birtakım hatalar olabilmektedir. Bütün bunlara ilave olarak GES’lerin kuruldukları arazi koşullarında bulunabilen yabani hayvanlar da donanımsal arızalar oluşturabilmektedir. Bunların başında ise kemirgenler sınıfında yer alan farelerin kabloları zarar vermesidir. Yukarıda bahsedilen tüm istenmeyen durumlar göz önüne alınarak bazı günlere ait veriler tahmin modelinde kullanılmamıştır. Grafiklerde yer alan veriler GES’in aktif üretime geçtiği saat ve üretimden çıktığı saat dilimlerini kapsamaktadır. GES’in güç üretim tahmin modelinde 2020 yılına ait gerçek zamanlı veriler kullanılmıştır. Şenyurt/GES’te hava istasyonu sensörlerinden elde edilen rüzgâr, ortam sıcaklığı, güneş ışıınımı ve PV hücre sıcaklığı verilerinin 2020 yılı, Ocak ayına ait değişimi Şekil 4.1 (a)-(b)-(c)-(d)’de ayrıntılı bir şekilde görülmektedir. Şekil 4.1’de görüldüğü gibi 01.01.2020 tarihinde GES’e ait hava istasyonu verilerinin değişimi grafiklerde verilmemiştir. Bu tarihte Şenyurt/GES’te güç üretimi mevcuttur. Hava istasyonu sensörlerinden güneş ışıınımı sensöründen veri alınamamıştır. Bundan dolayı diğer sensör verileri ve GES’in aktif güç üretiminin değişimine yer verilmemiştir. Ayrıca 04.01.2020 tarihinde ise 09:00-10:00 saatleri arasında elektrik şebekesindeki kesintiden dolayı kısa süreli veri alınamamıştır. 04.01.2020 tarihindeki diğer saatlerde Şenyurt/GES’in aktif elektrik üretimi mevcuttur. Anlık kısa süreli elektrik kesintisinden dolayı 04.01.2020 tarihi Ocak-2020 grafiğinde yer verilmemiştir. Şenyurt/GES güç tahmini için saatte bir örneklem alındığı için hem günlük hem de aylık bazda yeterince veri mevcuttur. Yıllık bazda yeterince veri çeşitliliği elde edilebildiği için bazı günlerdeki verilerin olmaması güç tahminine herhangi bir olumsuz etkisi olmamıştır.

4. ARAŞTIRMA BULGULARI ve TARTIŞMA



Şekil 4.1. Şenyurt/GES'e ait hava istasyonu sensör verileri (Ocak-2020)

Şekil 4.2'de 2020 yılı Ocak ayına ait GES'in aktif güç üretimi verilmiştir.




Şekil 4.2. Şenyurt/GES'in Ürettiği Aktif Güç (Ocak-2020)

Şekil 4.1-4.2'de sırasıyla bağımsız değişkenlerin ve bağımlı değişkenin toplam örneklem sayısı N_{Ocak} , minimum (min.), maksimum (mak.) ve ortalama (ort.) gibi betimleyici istatistik değerleri Çizelge 4.1'de verilmiştir.

Çizelge 4.1. 2020 yılı Ocak ayına ait verilerin betimleyici istatistik değerleri


Bağımsız ve Bağımlı Değişken (Ocak)	N_{Ocak}	Min.	Mak.	Ort.
Rüzgâr hızı (m/s) - (Bağımsız)	183	0,62	3,13	1,63
Ortam Sıcaklığı (°C) - (Bağımsız)	183	-13,81	6,8	-2,7
Güneş Işınımı (Watt/m ²) - (Bağımsız)	183	0,02	937,51	343,37
PV Modül Sıcaklığı (°C) - (Bağımsız)	183	0,06	32,94	11,20
Üretilen Aktif Güç (kW) - (Bağımlı)	183	1	968	374,08

4. ARAŞTIRMA BULGULARI ve TARTIŞMA



Şekil 4.3. Şenyurt/GES'e ait hava istasyonu sensör verileri (Şubat-2020)

Şekil 4.4'de 2020 yılı, Şubat ayına ait Şenyurt/GES'in aktif güç üretimi verilmiştir. Şekil 4.3 (a)-(b)-(c)-(d)'de 2020 yılı Şubat ayına ait GES'in sensör verileri verilmiştir.




Şekil 4.4. Şenyurt/GES'in Ürettiği Aktif Güç (Şubat-2020)

Çizelge 4.2'de, Şekil 4.3-4.4'deki verilerin betimleyici istatistikleri verilmiştir.

Çizelge 4.2. 2020 yılı Şubat ayına ait verilerin betimleyici istatistik değerleri

Bağımsız ve Bağımlı Değişken (Şubat)	N _{şubat}	Min.	Mak.	Ort.
Rüzgâr hızı (m/s) - (Bağımsız)	218	0,65	3,31	1,96
Ortam Sıcaklığı (°C) - (Bağımsız)	218	-14,38	10,96	0,41
Güneş Işınımı (Watt/m ²) - (Bağımsız)	218	0,20	1118,87	375,74
PV Modül Sıcaklığı (°C) - (Bağımsız)	218	0,07	44,73	14,23
Üretilen Aktif Güç (kW) - (Bağımlı)	218	1	968	382,85


4. ARAŞTIRMA BULGULARI ve TARTIŞMA



Şekil 4.5. Şenyurt/GES'e ait hava istasyonu sensör verileri (Mart-2020)

Şekil 4.6'da 2020 yılı, Mart ayına ait Şenyurt/GES'in aktif güç üretimi verilmiştir.

Şekil 4.5 (a)-(b)-(c)-(d)'de 2020 yılı Mart ayına ait GES'in sensör verileri verilmiştir.




Şekil 4.6. Şenyurt/GES'in Ürettiği Aktif Güç (Mart-2020)

Çizelge 4.3'de, Şekil 4.5-4.6'daki verilerin betimleyici istatistikleri verilmiştir.

Çizelge 4.3. 2020 yılı Mart ayına ait verilerin betimleyici istatistik değerleri


Bağımsız ve Bağımlı Değişken (Mart)	N _{mart}	Min.	Mak.	Ort.
Rüzgâr hızı (m/s) - (Bağımsız)	342	0,59	3,12	1,61
Ortam Sıcaklığı (°C) - (Bağımsız)	342	-5,85	11,42	4,80
Güneş Işınımı (Watt/m ²) - (Bağımsız)	342	0,28	1169,01	456,63
PV Modül Sıcaklığı (°C) - (Bağımsız)	342	0,07	45,56	20,40
Üretilen Aktif Güç (kW) - (Bağımlı)	342	1	970	426,13

4. ARAŞTIRMA BULGULARI ve TARTIŞMA



Şekil 4.7. Şenyurt/GES'e ait hava istasyonu sensör verileri (Nisan-2020)

Şekil 4.8'de 2020 yılı, Nisan ayına ait Şenyurt/GES'in aktif güç üretimi verilmiştir. Şekil 4.7 (a)-(b)-(c)-(d)'de 2020 yılı Nisan ayına ait GES'in sensör verileri verilmiştir.




Şekil 4.8. Şenyurt/GES'in Ürettiği Aktif Güç (Nisan-2020)

Çizelge 4.4'de, Şekil 4.7-4.8'daki verilerin betimleyici istatistikleri verilmiştir.

Çizelge 4.4. 2020 yılı Nisan ayına ait verilerin betimleyici istatistik değerleri


Bağımsız ve Bağımlı Değişken (Nisan)	N _{nisan}	Min.	Mak.	Ort.
Rüzgâr hızı (m/s) - (Bağımsız)	163	0,52	3,34	1,79
Ortam Sıcaklığı (°C) - (Bağımsız)	163	-1,26	14,82	7,07
Güneş Işınımı (Watt/m²) - (Bağımsız)	163	0,77	1206,28	491,29
PV Modül Sıcaklığı (°C) - (Bağımsız)	163	1,37	42,48	21,11
Üretilen Aktif Güç (kW) - (Bağımlı)	163	1	968	462,40

4. ARAŞTIRMA BULGULARI ve TARTIŞMA



Şekil 4.9. Şenyurt/GES'e ait hava istasyonu sensör verileri (Mayıs-2020)

Şekil 4.10'da 2020 yılı, Mayıs ayına ait Şenyurt/GES'in aktif güç üretimi verilmiştir. Şekil 4.9 (a)-(b)-(c)-(d)'de 2020 yılı Mayıs ayına ait GES'in sensör verileri verilmiştir.




Şekil 4.10. Şenyurt/GES'in Ürettiği Aktif Güç (Mayıs-2020)

Çizelge 4.5'de, Şekil 4.9-4.10'daki verilerin betimleyici istatistikleri verilmiştir.

Çizelge 4.5. 2020 yılı mayıs ayına ait verilerin betimleyici istatistik değerleri


Bağımsız ve Bağımlı Değişken (Mayıs)	N _{mayıs}	Min.	Mak.	Ort.
Rüzgâr hızı (m/s) - (Bağımsız)	301	0,41	3,30	1,92
Ortam Sıcaklığı (°C) - (Bağımsız)	301	-0,33	26,61	15,35
Güneş Işınımı (Watt/m ²) - (Bağımsız)	301	2,66	1176,84	571,16
PV Modül Sıcaklığı (°C) - (Bağımsız)	301	5,07	56,29	31,39
Üretilen Aktif Güç (kW) - (Bağımlı)	301	1	969	536,02

4. ARAŞTIRMA BULGULARI ve TARTIŞMA



Şekil 4.11. Şenyurt/GES’e ait hava istasyonu sensör verileri (Haziran-2020)

Şekil 4.12’de 2020 yılı, Haziran ayına ait Şenyurt/GES’in aktif güç üretimi verilmiştir. Şekil 4.11 (a)-(b)-(c)-(d)’de 2020 yılı Haziran ayına ait GES’in sensör verileri verilmiştir.




Şekil 4.12. Şenyurt/GES’in Ürettiği Aktif Güç (Haziran-2020)

Çizelge 4.6’da, Şekil 4.11-4.12’deki verilerin betimleyici istatistikleri verilmiştir.

Çizelge 4.6. 2020 yılı Haziran ayına ait verilerin betimleyici istatistik değerleri


Bağımsız ve Bağımlı Değişken (Haziran)	N _{haziran}	Min.	Mak.	Ort.
Rüzgâr hızı (m/s) - (Bağımsız)	286	0,65	3,17	1,84
Ortam Sıcaklığı (°C) - (Bağımsız)	286	5,58	28,30	18,47
Güneş Işınımı (Watt/m ²) - (Bağımsız)	286	5,04	1124,51	503,11
PV Modül Sıcaklığı (°C) - (Bağımsız)	286	10,14	56,88	32,96
Üretilen Aktif Güç (kW) - (Bağımlı)	286	1	969	482,58

4. ARAŞTIRMA BULGULARI ve TARTIŞMA



Şekil 4.13. Şenyurt/GES'e ait hava istasyonu sensör verileri (Temmuz-2020)

Şekil 4.14'de 2020 yılı, Temmuz ayına ait Şenyurt/GES'in aktif güç üretimi verilmiştir. Şekil 4.13 (a)-(b)-(c)-(d)'de 2020 yılı Temmuz ayına ait GES'in sensör verileri verilmiştir.




Şekil 4.14. Şenyurt/GES'in Ürettiği Aktif Güç (Temmuz-2020)

Çizelge 4.7'de, Şekil 4.13-4.14'deki verilerin betimleyici istatistikleri verilmiştir.

Çizelge 4.7. 2020 yılı Temmuz ayına ait verilerin betimleyici istatistik değerleri


Bağımsız ve Bağımlı Değişken (Temmuz)	N _{temmuz}	Min.	Mak.	Ort.
Rüzgâr hızı (m/s) - (Bağımsız)	390	0,66	3,12	1,83
Ortam Sıcaklığı (°C) - (Bağımsız)	390	10,69	32,26	22,17
Güneş Işınımı (Watt/m ²) - (Bağımsız)	390	4,40	1148,76	556,46
PV Modül Sıcaklığı (°C) - (Bağımsız)	390	16,12	59,29	37,58
Üretilen Aktif Güç (kW) - (Bağımlı)	390	1	969	513,65

4. ARAŞTIRMA BULGULARI ve TARTIŞMA



Şekil 4.15. Şenyurt/GES'e ait hava istasyonu sensör verileri (Ağustos-2020)

Şekil 4.16'da 2020 yılı, Ağustos ayına ait Şenyurt/GES'in aktif güç üretimi verilmiştir. Şekil 4.15 (a)-(b)-(c)-(d)'de 2020 yılı Ağustos ayına ait GES'in sensör verileri verilmiştir.




Şekil 4.16. Şenyurt/GES'in Ürettiği Aktif Güç (Ağustos-2020)

Çizelge 4.8'de, Şekil 4.15-4.16'daki verilerin betimleyici istatistikleri verilmiştir.

Çizelge 4.8. 2020 yılı Ağustos ayına ait verilerin betimleyici istatistik değerleri


Bağımsız ve Bağımlı Değişken (Ağustos)	Nağustos	Min.	Mak.	Ort.
Rüzgâr hızı (m/s) - (Bağımsız)	364	0,67	3,15	1,76
Ortam Sıcaklığı (°C) - (Bağımsız)	364	10,15	31,52	21,56
Güneş Işınımı (Watt/m ²) - (Bağımsız)	364	12,54	1160,75	610,60
PV Modül Sıcaklığı (°C) - (Bağımsız)	364	16,91	60,25	38,48
Üretilen Aktif Güç (kW) - (Bağımlı)	364	2	969	554,83

4. ARAŞTIRMA BULGULARI ve TARTIŞMA



Şekil 4.17. Şenyurt/GES'e ait hava istasyonu sensör verileri (Eylül-2020)

Şekil 4.18'da 2020 yılı, Eylül ayına ait Şenyurt/GES'in aktif güç üretimi verilmiştir. Şekil 4.17 (a)-(b)-(c)-(d)'de 2020 yılı Eylül ayına ait GES'in sensör verileri verilmiştir.




Şekil 4.18. Şenyurt/GES'in Ürettiği Aktif Güç (Eylül-2020)

Çizelge 4.9'da, Şekil 4.17-4.18'deki verilerin betimleyici istatistikleri verilmiştir.

Çizelge 4.9. 2020 yılı Eylül ayına ait verilerin betimleyici istatistik değerleri


Bağımsız ve Bağımlı Değişken (Eylül)	N _{Eylül}	Min.	Mak.	Ort.
Rüzgâr hızı (m/s) - (Bağımsız)	355	0,54	3,28	1,72
Ortam Sıcaklığı (°C) - (Bağımsız)	355	7,81	33,19	22,61
Güneş Işınımı (Watt/m ²) - (Bağımsız)	355	2,15	1086,39	580,92
PV Modül Sıcaklığı (°C) - (Bağımsız)	355	13,43	59,15	39,64
Üretilen Aktif Güç (kW) - (Bağımlı)	355	1	968	540,53

4. ARAŞTIRMA BULGULARI ve TARTIŞMA



Şekil 4.19. Şenyurt/GES'e ait hava istasyonu sensör verileri (Ekim-2020)

Şekil 4.20'de 2020 yılı, Ekim ayına ait Şenyurt/GES'in aktif güç üretimi verilmiştir. Şekil 4.19 (a)-(b)-(c)-(d)'de 2020 yılı Ekim ayına ait GES'in sensör verileri verilmiştir.




Şekil 4.20. Şenyurt/GES'in Ürettiği Aktif Güç (Ekim-2020)

Çizelge 4.10'da, Şekil 4.19-4.20'deki verilerin betimleyici istatistikleri verilmiştir.

Çizelge 4.10. 2020 yılı Ekim ayına ait verilerin betimleyici istatistik değerleri


Bağımsız ve Bağımlı Değişken (Ekim)	Nekim	Min.	Mak.	Ort.
Rüzgâr hızı (m/s) - (Bağımsız)	301	0,67	3,36	1,71
Ortam Sıcaklığı (°C) - (Bağımsız)	301	2,02	23,98	16,11
Güneş Işınımı (Watt/m ²) - (Bağımsız)	301	0,02	1045,46	547,69
PV Modül Sıcaklığı (°C) - (Bağımsız)	301	6,24	50,52	32,79
Üretilen Aktif Güç (kW) - (Bağımlı)	301	2	969	529,99

4. ARAŞTIRMA BULGULARI ve TARTIŞMA



Şekil 4.21. Şenyurt/GES'e ait hava istasyonu sensör verileri (Kasım-2020)

Şekil 4.22'de 2020 yılı, Kasım ayına ait Şenyurt/GES'in aktif güç üretimi verilmiştir. Şekil 4.21 (a)-(b)-(c)-(d)'de 2020 yılı Kasım ayına ait GES'in sensör verileri verilmiştir.




Şekil 4.22. Şenyurt/GES'in Ürettiği Aktif Güç (Kasım-2020)

Çizelge 4.11'de, Şekil 4.21-4.22'deki verilerin betimleyici istatistikleri verilmiştir.

Çizelge 4.11. 2020 yılı Kasım ayına ait verilerin betimleyici istatistik değerleri


Bağımsız ve Bağımlı Değişken (Kasım)	N _{kasım}	Min.	Mak.	Ort.
Rüzgâr hızı (m/s) - (Bağımsız)	266	0,57	2,93	1,51
Ortam Sıcaklığı (°C) - (Bağımsız)	266	-9,40	14,17	4,49
Güneş Işınımı (Watt/m ²) - (Bağımsız)	266	1,02	1032,51	421,56
PV Modül Sıcaklığı (°C) - (Bağımsız)	266	0,07	41,78	18,85
Üretilen Aktif Güç (kW) - (Bağımlı)	266	1	952	424,68

4. ARAŞTIRMA BULGULARI ve TARTIŞMA



Şekil 4.23. Şenyurt/GES'e ait hava istasyonu sensör verileri (Aralık-2020)

Şekil 4.24'de 2020 yılı, Aralık ayına ait Şenyurt/GES'in aktif güç üretimi verilmiştir. Şekil 4.23 (a)-(b)-(c)-(d)'de 2020 yılı Aralık ayına ait GES'in sensör verileri verilmiştir.



Şekil 4.24. Şenyurt/GES'in Ürettiği Aktif Güç (Aralık-2020)

Çizelge 4.12'de, Şekil 4.23-Şekil 4.24'deki verilerin betimleyici istatistikleri verilmiştir.

Çizelge 4.12. 2020 yılı Aralık ayına ait verilerin betimleyici istatistik değerleri


Bağımsız ve Bağımlı Değişken (Aralık)	N _{Aralık}	Min.	Mak.	Ort.
Rüzgâr hızı (m/s) - (Bağımsız)	265	0,51	3,00	1,42
Ortam Sıcaklığı (°C) - (Bağımsız)	265	-17,68	6,85	-0,85
Güneş Işınımı (Watt/m ²) - (Bağımsız)	265	0,03	1105,32	351,74
PV Modül Sıcaklığı (°C) - (Bağımsız)	265	0,06	36,58	13,69
Üretilen Aktif Güç (kW) - (Bağımlı)	265	1	917	374,46

Ayrıntılı olarak ele alınan grafik ve tablolarda 2020 yılına ait Şenyurt/GES'in hava istasyonu sensör verileri ve aktif güç üretim değerleri aylık bazda ayrıntılı olarak ele alınmıştır. Geliştirilen güç üretim tahmin modelinde ilk olarak parametrik istatistiksel tekniklerden olan klasik Çoklu Lineer Regresyon (ÇLR) analizi ele alınmıştır. ÇLR analizinin diğer parametrik analizlerde olduğu gibi yeterli örneklem büyüklüğü, verilerin normal dağılımı, çoklu doğrusal bağıntı, tekillik, uç değer gibi temel varsayımları ayrıntılı olarak ele alınmalıdır. Geliştirilen güç üretim tahmin modelinde örneklem büyüklüğü 3434'dür. Bu örneklem büyüklüğü güç üretim tahmin modeli için yeterli düzeydedir. Sayısal verilerin analizinin yapılabilmesinin şartlarından biri de verilerin normal dağılmasıdır. Verilerin dağılımının normal olmaması analiz sonuçlarının yanlış çıkmasına sebep olmaktadır (Karagöz 2019). Güç üretim tahmin modelinde bağımsız değişken olarak kullanılan rüzgâr, ortam sıcaklığı, güneş ışıınımı ve PV hücre sıcaklığı verilerinin normal dağılıma sahip olup olmadığına karar verebilmek için her bir bağımsız değişken için Çarpıklık (Skewness) ve Basıklık (Kurtosis) değerleri incelenmiştir. Çizelge 4.13'de her bir bağımsız değişken için elde edilen Basıklık ve Çarpıklık değerleri ayrıntılı olarak görülmektedir. Çarpıklık ve Basıklık değerleri kimi akademik makalelerde $\pm 1,5$ arasında kimisinde ise ± 2 arasında normallik koşulu için kabul görmektedir. Bazı akademik çalışmalarda ise farklı aralıklarda olması gerektiği vurgulanmıştır. Bu durum çalışılan disipline/projeye göre farklılık gösterebilmektedir (Şener 2020). Bu çalışmada Çarpıklık ve Basıklık değerleri için $\pm 1,5$ aralığı kabul edilebilir sınır olarak alınmıştır.

Çizelge 4.13. Bağımsız değişkenlere ait Basıklık ve Çarpıklık

	Rüzgâr	Ortam Sıcaklığı	Güneş Işınımı	PV Modül Sıcaklığı
Çarpıklık (Skewness)	0,248	-0,165	0,2002	0,044
Basıklık (Kurtosis)	-0,453	-1,001	-1,288	-0,858

Yukarıdaki Çizelge 4.13 ayrıntılı olarak incelendiğinde her bir bağımsız değişken için bulunan Çarpıklık ve Basıklık değerleri kabul edilebilirlik sınırları ($\pm 1,5$) içerisinde. Bundan dolayı bağımsız değişkenlere ait verilerin normal dağılıma sahip olduğu söylenebilir. Şekil 4.25'de bağımsız değişkenlere ait kutu grafiği (boxplot chart) verilmiştir. Bu grafikten de görüldüğü gibi verilerin normal dağılmamasına neden olabilecek herhangi bir uç değer de görülmemektedir.




Şekil 4.25. Bağımsız değişkenlere ait kutu grafiği

Bunlara ilave olarak birden fazla bağımsız değişkene sahip güç üretim tahmin modeli için çok değişkenli normallik analizi’de (MANOVA, Regresyon vb.) incelenmiştir. Mahalanobis Uzak Değeri (MUD), çoklu normal verilerde ve geniş örneklemelerde, değişken sayısına bağlı olarak elde edilen serbestlik derecesi ile ki-kare dağılımına uyar ve örneklem sayısı artıkça da kestirimin daha iyi hale geldiği görülmüştür (Johnson and Wichern 2002). Pearson ve Hartly bağımsız değişken sayısına göre MUD değerinin aşağıda belirtildiği gibi alınması gerektiğini belirtmişlerdir (Pearson and Hartly 1958). Mahalanobis Uzaklık Değerleri;

- 2 bağımsız değişken için : 13,82
- 3 bağımsız değişken için : 16,27
- 4 bağımsız değişken için : 18,47
- 5 bağımsız değişken için : 20,52
- 6 bağımsız değişken için : 22,46
- 7 bağımsız değişken için : 24,32

Bağımsız değişkenler arasındaki yüksek korelasyon ilişkilerinin olma ihtimali de dikkate alınarak 2, 3 ve 4 adet bağımsız değişkenler için MUK değerleri’nin değişimi güç

üretim tahmin modeli için Şekil 4.26’da verilmiştir. Şekil 4.26’da görüldüğü gibi farklı sayıdaki (kırmızı: 4 bağımsız değişken, siyah: 3 bağımsız değişken, mavi: 2 bağımsız değişken) bağımsız değişkenlere ait verilerin MUD’un değişimi Pearson ve Hartly’nin belirttiği değerler arasında gerçekleşmiştir.



Şekil 4.26. Bağımsız değişkenlere ait verilerin Mahalanobis değerleri

Güç üretim tahmin modeli için bağımsız değişkenler arasında çoklu doğrusal bağıntının tespiti için gerçekleştirilen regresyon analizinde “katsayılar” tablosu incelenmiştir. Söz konusu tabloda her bir bağımsız değişken için Tolerans (Tol.) değerinin 0,10’dan düşük olmaması ve Varyans Artış Faktörleri (VIF, Variance Inflation Factors) değerinin 10’dan düşük olması doğru bir çoklu regresyon analiz modelinin oluşturulması açısından önemlidir (Akbulut 2011). Bununla birlikte Pallant bağımsız değişkenler arasında 0,90 ve üzerindeki bir korelasyonun analizde sıkıntı oluşturacağını belirtmiştir (Pallant 2001). Katz ise bağımsız değişkenler arasında 0,80 ve üzerindeki bir korelasyonun analizde sıkıntı oluşturacağını belirtmiştir (Katz 2011). Bu çalışmada 0,80 ve üzerindeki bir korelasyon değeri anlamlı olarak dikkate alınmıştır. Dört adet bağımsız değişken için elde edilen katsayılar Çizelge 4.14’te verilmiştir.

Çizelge 4.14. Dört adet bağımsız değişken için elde edilen katsayılar

Katsayılar ^a							
1. Model 4 Bağımsız Değişkenli	Std. laştırılmamış Katsayı		Std. laştırılmış Katsayı	t	Sig.	Doğrusallık İstatistikleri	
	B	Std. Sapma Hatası	Beta			Tol.	VIF
(Sabit)	$\beta_0 = -225,810$	9,458		-23,874	0,000		
Işınım	$\beta_1 = 0,278$	0,013	0,291	21,549	0,000	0,256	3,913
Rüzgâr	$\beta_2 = 69,605$	4,251	0,120	16,375	0,000	0,874	1,144
Ortam Sıcaklığı	$\beta_3 = -27,708$	0,568	-0,855	-48,744	0,000	0,151	6,607
PV Modül Sıcaklığı	$\beta_4 = 28,274$	0,544	1,234	51,971	0,000	0,083	12,108
a. Bağımlı Değişken: Üretilen Aktif Güç (Şenyurt/GES)							

Çizelge 4.14’de görüldüğü gibi sabit değer için t testinin significance değeri 0,05’ten küçük olduğundan ($0,00 < 0,05$), β_0 parametresi önemlidir. Işınım için t testinin significance değeri 0,05’ten küçük olduğundan ($0,00 < 0,05$), β_1 parametresi önemlidir. Yani, ısıtımın PV güneş santralının güç çıkışına etkisi vardır. Rüzgâr için t testinin significance değeri 0,05’ten küçük olduğundan ($0,00 < 0,05$), β_2 parametresi önemlidir. Yani, rüzgârın PV güneş santralının güç çıkışına etkisi vardır. Ortam sıcaklığı için, t testinin significance değeri 0,05’ten küçük olduğundan ($0,00 < 0,05$), β_3 parametresi önemlidir. Yani, ortam sıcaklığını PV güneş santralının güç çıkışına etkisi vardır. PV modül sıcaklığı için, t testinin significance değeri 0,05’ten küçük olduğundan ($0,00 < 0,05$), β_4 parametresi önemlidir. Yani, PV Modül sıcaklığının PV güneş santralının güç çıkışına etkisi vardır. Katsayılar tablosundaki “Doğrusallık İstatistikleri” bölümünde ise Tolerans değerleri ısıtım için 0,256, rüzgâr için 0,874, ortam sıcaklığı için 0,151 ve modül sıcaklığı için 0,083’dir. Güç tahmin modelinde Akbulut’un belirttiği Tolerans değerinin 0,10’dan düşük olmaması ve VIF değerinin 10’dan küçük olması gerekliliği dikkate alınmıştır (Akbulut 2011). Sonuç olarak ısıtım, rüzgâr ve ortam sıcaklığı için tolerans ve VIF değerinin istenilen düzeyde olduğu söylenebilir. Ancak, PV modül sıcaklığı tolerans değerinin 0,10’dan düşük olması ve PV modül sıcaklığı VIF değerinin 10’dan büyük olması bağımsız değişkenler arasında yüksek düzeyde korelasyon olduğuna işaret etmektedir. Çizelge 4.15’de bağımsız değişkenler için elde edilen Pearson korelasyon katsayıları görülmektedir.

Çizelge 4.15. Bağımsız değişkenlere ait Pearson Korelasyon tablosu

	Pearson Korelasyon	Işınım	Rüzgâr	Ortam Sıcaklığı	Modül Sıcaklığı
Işınım	Pearson Korelasyon	1	0,199**	0,482**	0,763**
Rüzgâr	Pearson Korelasyon	0,199**	1	0,166**	0,113**
Ortam Sıcaklığı	Pearson Korelasyon	0,482**	0,166**	1	0,869**
Modül Sıcaklığı	Pearson Korelasyon	0,763**	0,113**	0,869**	1

Çizelge 4.15’de görüldüğü gibi PV modül sıcaklığı ve ortam sıcaklığı arasındaki korelasyon katsayısı 0.869’dur. Bu değer oldukça yüksektir. Bundan dolayı çoklu doğrusal bağlantıya sebep olan ortam sıcaklığı Şenyurt/GES’in güç üretiminin tahmin modelinden çıkarılarak katsayı analizi tekrar gerçekleştirilmiştir. Üç adet bağımsız değişken (ışınım, rüzgâr ve PV modül sıcaklığı) için elde edilen yeni katsayılar Çizelge 4.16’da verilmiştir.

Çizelge 4.16. Üç adet bağımsız değişken için elde edilen katsayılar tablosu

Katsayılar^a							
2. Model 3 Bağımsız Değişkenli	Std. laştırılmamış Katsayı		Std. laştırılmış Katsayı	t	Sig.	Doğrusalılık İstatistikleri	
	B	Std. Sapma Hatası	Beta			Tol.	VIF
(Sabit)	$\beta_0 = 6,177$	10,633		0,581	0,561		
Işınım	$\beta_1 = 0,661$	0,013	0,691	49,493	0,000	0,405	2,469
Rüzgâr	$\beta_2 = 8,813$	5,286	0,015	1,667	0,096	0,957	1,045
PV Modül Sıcaklığı	$\beta_3 = 4,532$	0,315	0,198	14,374	0,000	0,416	2,402
a. Bağımlı Değişken: Üretilen Aktif Güç (Şenyurt/GES)							

Çizelge 4.16’da görüldüğü gibi sabit değer için t testinin significance değeri 0,05’ten büyük olduğundan ($0,561 > 0,05$), β_0 parametresi önemsizdir. Işınım için t testinin significance değeri 0,05’ten küçük olduğundan ($0,00 < 0,05$), β_1 parametresi önemlidir. Yani, ışıınının PV güneş santralinin güç çıkışına etkisi vardır. Rüzgâr için t testinin significance değeri 0,05’ten büyük olduğundan ($0,096 > 0,05$), β_2 parametresi

önemsizdir. Yani, rüzgârın PV güneş santralinin güç çıkışına etkisi yoktur. PV modül sıcaklığı için, t testinin significance değeri 0,05'ten küçük olduğundan ($0,00 < 0,05$), β_2 parametresi önemlidir. Yani, PV Modül sıcaklığının PV güneş santralinin güç çıkışına etkisi vardır. Katsayılar tablosundaki “Doğrusallık İstatistikleri” bölümünde ise Tolerans değerleri ısıtım için 0,405, rüzgâr için 0,957 ve PV modül sıcaklığı için 0,416’dır. ısıtım, rüzgâr ve PV modül sıcaklığı için tolerans ve VIF değerlerinin istenilen düzeyde olduğu söylenebilir. Bu durum bağımsız değişkenler arasında düşük düzeyde korelasyon olduğuna işaret etmektedir. Bağımsız değişkenlerden rüzgârın t testinin significance değeri 0,05’ten büyük olduğundan ($0,096 > 0,05$), β_2 parametresi önemsizdir. Yani, rüzgârın PV güneş santralinin güç çıkışına etkisi yoktur. Bundan dolayı Şenyurt/GES’in güç üretim tahmin modelinde yer alan bağımsız değişkenlerde rüzgâr değişkeni çıkarılarak katsayı analizi tekrar gerçekleştirilmiştir. Böylece güç üretim tahmini daha az bağımsız değişkene bağlı olarak modellenmiştir. İki adet bağımsız değişken (ısıtım ve PV modül sıcaklığı) için elde edilen yeni katsayılar Çizelge 4.17’de verilmiştir.

Çizelge 4.17. İki adet bağımsız değişken için elde edilen katsayılar

Katsayılar ^a							
3. Model 2 Bağımsız Değişkenli	Std.laştırılmamış Katsayı		Std.laştırılmış Katsayı	t	Sig.	Doğrusallık İstatistikleri	
	B	Std. Sapma Hatası	Beta			Tol.	VIF
(Sabit)	$\beta_0 = 20,350$	6,388		3,186	0,001		
Isıtım	$\beta_1 = 0,664$	0,013	0,695	50,559	0,000	0,418	2,393
PV Modül Sıcaklığı	$\beta_2 = 4,499$	0,315	0,196	14,295	0,000	0,418	2,393
a. Bağımlı Değişken: Üretilen Aktif Güç (Şenyurt/GES)							

Çizelge 4.17’de görüldüğü gibi sabit değer için t testinin significance değeri 0,05’ten küçük olduğundan ($0,001 < 0,05$), β_0 parametresi önemlidir. ısıtım için t testinin significance değeri 0,05’ten küçük olduğundan ($0,00 < 0,05$), β_1 parametresi önemlidir. Yani, ısıtımın PV güneş santralinin güç çıkışına etkisi vardır. PV modül sıcaklığı için, t testinin significance değeri 0,05’ten küçük olduğundan ($0,00 < 0,05$), β_2 parametresi önemlidir. Yani, PV Modül sıcaklığının PV güneş santralinin güç çıkışına etkisi vardır. Katsayılar tablosundaki “Doğrusallık İstatistikleri” bölümünde ise Tolerans değerleri ısıtım için 0,418 ve PV modül sıcaklığı için 0,418’dir. ısıtım ve PV modül sıcaklığı için tolerans ve VIF değerlerinin istenilen düzeyde olduğu söylenebilir. Bu durum bağımsız değişkenler arasında düşük düzeyde korelasyon olduğuna işaret

4. ARAŞTIRMA BULGULARI ve TARTIŞMA

etmektedir. Sonuç olarak güç üretim tahmini ışıınım ve PV modül sıcaklığı değişkenlerine göre modellenmiştir. İki bağımsız değişken için elde edilen güç üretim regresyon modeline ilişkin bulguları içeren değerler Çizelge 4.18’de verilmiştir.

Çizelge 4.18. İki adet bağımsız değişken için elde edilen model özeti

Model Özeti ^b					
Model	R	R ²	Düzeltilmiş Regresyon Katsayısı	Standart Tahmin Hatası	Durbin-Watson
1	0,854 ^a	0,73	0,73	172,293	1,193
a. Tahmin parametreleri: (Sabit), Işıınım, PV Modül Sıcaklığı					
b. Bağımlı Değişken: Üretilen Aktif Güç (Şenyurt/GES)					

Yukarıdaki tabloda, değişkenler arasındaki determinasyon katsayısı $R^2 = 0,730$. Bu nedenle GES çıkış gücü değişkenindeki toplam değişiminin %73’ü “Işıınım” ve “PV Modül Sıcaklığı” bağımsız değişkenleri tarafından belirlenmektedir. Geriye kalan %27’lik değişimini sebebi ise bilinmemektedir. Ayrıca, $R^2 = 0,730$ olması, modelin uyum iyiliğinin yüksek olduğunu göstermektedir. Durbin-Watson değeri de otokorelasyon olmama (1,5 – 2,5) sınırını geçmemiştir. Güç üretim regresyon modeline ilişkin olarak ANOVA tablosunun da incelenmesi gerekmektedir. Çizelge 4.19’da iki bağımsız değişkenli güç üretim modeline ilişkin ANOVA istatistik değerleri verilmiştir.

Çizelge 4.19. İki adet bağımsız değişken için elde ANOVA

ANOVA ^a					
3. Model	Kareler Toplamı	df	Ortalama Kare	F	Sig.
2 Bağımsız Değişkenli					
Regresyon	274475585,0	2	137237792,5	4623,143	0,000 ^b
Residual	101849091,1	3431	29684,958		
Toplam	376324676,1	3434			
a. Bağımlı Değişken: Üretilen Aktif Güç (Şenyurt/GES)					
a. Tahmin parametreleri: (Sabit), Işıınım, PV Modül Sıcaklığı					


Çizelge 4.19’da verilen ANOVA tablosu incelendiğinde F değerinin 4623,143 olduğu ve istatistiksel olarak anlamlı olduğu (Sig. = p = 0,000 < 0,05) görülmektedir. Sonuç olarak bağımsız değişkenlerin (Işıınım ve PV modül sıcaklığı) güç üretim modeli

üzerinde anlamlı etkiye sahip olduğu görülmüştür. Bu regresyon denklemi tahminde kullanılabilir. Yukarıdaki ANOVA (F) testi ve t testleri önemli çıktığı için regresyon denklemi, Tablo 4.16 kullanılarak aşağıdaki gibi bulunabilir.


$$\hat{Y} = \beta_0 + \beta_1 * X_1 + \beta_2 * X_2 \quad \text{veya} \quad \hat{Y} = 20,350 + 0,664 * X_1 + 4,499 * X_2 \quad (4.1)$$

$$\widehat{ÜAG} = 20,350 + 0,664 * Işınım + 4,499 * FV \text{ Modül Sıcaklığı} \quad (4.2)$$


Güneş santralinin çıkış gücü tahmini denklemindeki toplam değişiminin %73'ü Işınım ve PV Modül Sıcaklığı bağımsız değişkenleri tarafından belirlenmektedir. Geriye kalan %27'lik değişimini sebebi ise bilinmemektedir. Görüldüğü gibi parametrik yöntemlerden olan basit lineer regresyon analizinin uyumu genellikle basittir. Yukarıda gerçekleştirilen GES güç üretim tahmin modelinde örneklem büyüklüğü $N = 3434$ 'dür. Lineer regresyon tabanlı güç tahmin modelinin geliştirilen parametrik olmayan tahmin modelleriyle eşit koşullarda başarısının kıyaslanabilmesi için verilerin belli bir yüzdesi modelin eğitimi (tahmin modellerimizde verilerin %80'i modeli eğitmek için kullanılmıştır) için kullanılmıştır. Verinin kalan diğer yüzdesi ise modelin başarısını test (tahmin modellerimizde verilerin %20'si modelin başarısını test etmek için kullanılmıştır) etmek için kullanılmıştır. Geliştirilen GES güç üretim tahmin modelinde örneklem büyüklüğü $N = 3434$ 'dür. Bu örneklem büyüklüğünün 2747'si başarılı bir lineer regresyon tabanlı güç tahmin modelini geliştirmek için eğitim verisi olarak kullanılmıştır. Örneklem büyüklüğünün 687 tanesi ise geliştirilen lineer regresyon güç tahmin modelinin başarısının testi için kullanılmıştır. Bundan dolayı azda olsa bulunan değerler arasında farklılıklar bulunmaktadır. Test verisi (Örneklem büyüklüğünün 687) üzerinden gerçekleştirilen analizlerde, $R^2 = 0,715$ ve $RMSE = 174,30982$ olarak elde edilmiştir. Şekil 4.27-4.33'de GES'in gerçek güç üretim değeri ve lineer regresyon modeli ile elde edilen tahmini güç üretim değeri grafikleri verilmiştir.




Şekil 4.27. Gerçek güç üretimi ve LR güç tahmini (1-100 arasındaki veriler)




Şekil 4.28. Gerçek güç üretimi ve LR güç tahmini (101-200 arasındaki veriler)




Şekil 4.29. Gerçek güç üretimi ve LR güç tahmini (201-300 arasındaki veriler)




Şekil 4.30. Gerçek güç üretimi ve LR güç tahmini (301-400 arasındaki veriler)



Şekil 4.31. Gerçek güç üretimi ve LR güç tahmini (401-500 arasındaki veriler)



Şekil 4.32. Gerçek güç üretimi ve LR güç tahmini (501-600 arasındaki veriler)



Şekil 4.33. Gerçek güç üretimi ve LR güç tahmini (601-687 arasındaki veriler)

Modelin doğrusal regresyon analizinde, katsayıların basit yorumları vardır ve istatistiksel anlamlılık testleri kolayca gerçekleştirilebilir. Ancak parametrik yöntemlerin yapılabilmesi için veriler; rassal ve bağımsız olarak elde edilmesi, normal dağılması, en az interval ölçek kullanılması, ana kütle varyasyonlarının homojen olması gibi koşullarla birlikte, her testin kendine has ek şartları da vardır (Karagöz 2019).

Parametrik olmayan bir yaklaşımda model yapısı eğitim verileri tarafından belirlenir. Model genellikle sabit bazı parametrelere sahiptir, ancak sayıları veya türleri verilerle birlikte büyür. Parametrik olmayan modeller, parametrik modellerden çok daha

esnek ve anlamlıdır (Ungar 2021). Parametrik olmayan testin açık avantajlarından bir tanesi de ana kitle hakkında hiçbir şey bilinmediği zaman güvenle kullanılabilir olmasıdır (Karagöz 2019). Bundan dolayı parametrik olmayan, makine öğrenme tabanlı K-NN ve torbalama regresyon modelleri ile tahmin başarısı geliştirilmiştir. Makine öğrenme tabanlı regresyon modelleri açık kaynak olarak kullanılabilen ve Python yazılımı ile uyumlu makine öğrenme kütüphaneleri (scikit-learn kütüphanesi geliştiricileri) yardımıyla geliştirilmiştir (Scikit-Learn Developers 2021). Makine öğrenme tabanlı regresyon modellerinde verilerin belli bir yüzdesi modelin eğitimi (tahmin modellerimizde verilerin %80'i modeli eğitmek için kullanılmıştır) için kullanılır. Verinin kalan diğer yüzdesi ise modelin başarısını test (tahmin modellerimizde verilerin %20'si modelin başarısını test etmek için kullanılmıştır) etmek için kullanılır. Geliştirilen GES güç üretim tahmin modelinde örneklem büyüklüğü $N = 3434$ 'dür. Bu örneklem büyüklüğünün 2747'si başarılı bir makine öğrenimi tabanlı model geliştirmek için eğitim verisi olarak kullanılmıştır. Örneklem büyüklüğünün 687 tanesi ise geliştirilen makine öğrenimi modeli başarısının testi için kullanılmıştır. İlk olarak ML tabanlı K-NNR modeli ele alınmıştır. Tahmin başarısının yüksek çıkması için K-NNR modeli için birtakım parametrelerin optimum değerlerinin bulunması gerekmektedir. K-NNR olağan ilk modeli;

```
model=(n_neighbors=5,weights='uniform',algorithm='auto',leaf_size=30,p=2,metric='minkowski',metric_params=None,n_jobs=None)
```

K-NN regresyon modelindeki parametreler ayrıntılı olarak aşağıda verilmiştir:

- **n_neighbors:int,default=5**

K-NN aramaları için kullanılacak olan komşu sayısıdır.

- **weights:{ 'uniform' , 'distance' }or callable,default='uniform'**

Tahminde kullanılan ağırlık fonksiyonunun olası değerleridir. Uniform ağırlıklar varsayılan değer olarak kullanılmaktadır.

✓ **'uniform':**

Uniform ağırlıklar. Her komşudaki tüm ağırlıklar eşit ağırlıktadır.

✓ **'distance':**

Uzaklıkların tersi ile orantılı ağırlık noktaları. Bu durumda bir arama noktasının daha yakın komşuları, uzaktaki komşulardan daha büyük bir etkiye sahip olacaktır.

✓ **'collable':**

Uzaklıklar dizisini kabul eden ve ağırlıkları içeren aynı şekle sahip bir dizi döndüren kullanıcı tanımlı bir işlevdir.

- **Algorithm: {'auto', 'ball_tree', 'kd_tree', 'brute'}, default='auto'**

En yakın komşuları hesaplamak için kullanılan algoritmalarıdır. 'auto', uygunluk yöntemine iletilen değere göre en uygun algoritmaya karar vermeye çalışacaktır.

- **leaf_size:int, default=30**

BallTree ve KDTree'ye geçen yaprak boyutudur. Bu ağaç yapısını depolamak için gereken belleğin yanı sıra, yapıyı ve aramanın hızını da etkileyebilir. Optimum değer, sorunun doğasına bağlıdır.

- **p:int, default=2**

Minkowski metriği için güç parametresidir. p=1 olduğunda, manhattan_distance (11) kullanımına eşdeğerdir. p=2 olduğunda, euclidean_distance (12)'dir. İsteğe bağlı p için minkowski_distance (l_p) kullanılır.

- **metric:str or callable, default='minkowski'**

Ağaç yapısı için kullanılacak mesafe metriğidir. Varsayılan metrik minkowski'dir ve p=2 ile standart Öklid metriğine eşdeğerdir.

- **metric_params:dict, default=None**

Metrik fonksiyonu için ek anahtar parametrelerdir.

- **n_jobs:int, default=None**

Komşu araması için çalıştırılacak paralel iş sayıdır. -1 ise tüm işlemcileri kullanmak anlamına gelir. Hiçbiri, `joblib.parallel_backend` bağlamında olmadığı sürece 1 anlamına gelir.

4. ARAŞTIRMA BULGULARI ve TARTIŞMA

GES'in aktif güç üretiminin tahmini için elde edilen bazı K-NNR parametrelerine ait performans kriteri Çizelge 4.20'de verilmiştir.

Çizelge 4.20. K-NNR parametreleri ve performans kriteri değerleri


K-NNR Parametreleri					Performans Kriteri	
$n_{\text{komşular}}$	Ağırlıklar	Algoritma	Yaprak Boyutu	P	RMSE	R^2
1	distance	brute	1	2	191,64191	0,65505
2	distance	brute	1	2	170,20287	0,72792
3	distance	brute	1	2	163,87758	0,74776
4	distance	brute	1	2	162,07906	0,75327
5	distance	brute	1	2	160,94282	0,75672
6	distance	brute	1	2	159,39459	0,76137
7	distance	brute	1	2	159,87766	0,75993
8	distance	brute	1	2	159,35244	0,76150
9	distance	brute	1	2	159,81955	0,76010
10	distance	brute	1	2	160,98491	0,75659

GES'in aktif güç üretiminin tahmini için elde edilen en uygun K-NNR parametreleri "GridSearchCV" optimizasyon metodu ile bulunmuştur. Çizelge 4.21'de verilmiştir.


Çizelge 4.21. K-NN'nin en uygun parametreleri ve performans kriteri değerleri

K-NNR Parametreleri	Performans Kriteri	
$n_{\text{komşular}} = 8$, Ağırlıklar=Distance, Algoritma=Brute, Yaprak boyutu=1, P = 2	RMSE	R^2
	159,35244	0,76150


Şekil 4.34-4.40'da GES'in gerçek güç üretim değeri ve en uygun K-NNR parametreleri ile elde edilen tahmini güç üretim değeri grafiği verilmiştir.




Şekil 4.34. Gerçek güç üretimi ve K-NNR güç tahmini (1-100 arasındaki veriler)




Şekil 4.35. Gerçek güç üretimi ve K-NNR güç tahmini (101-200 arasındaki veriler)




Şekil 4.36. Gerçek güç üretimi ve K-NNR güç tahmini (201-300 arasındaki veriler)




Şekil 4.37. Gerçek güç üretimi ve K-NNR güç tahmini (301-400 arasındaki veriler)



Şekil 4.38. Gerçek güç üretimi ve K-NNR güç tahmini (401-500 arasındaki veriler)



Şekil 4.39. Gerçek güç üretimi ve K-NNR güç tahmini (501-600 arasındaki veriler)



Şekil 4.40. Gerçek güç üretimi ve K-NNR güç tahmini (601-687 arasındaki veriler)

İkinci olarak ML tabanlı Torbalama regresyon modeli ele alınmıştır. Torbalama regresyonda tahmin başarısının yüksek çıkması için bazı önemli parametrelerin en uygun değerlerinin tespit edilmesi gerekmektedir. Torbalama regresyonunun olağan ilk modeli;

```
model=(base_estimator=None,n_estimators=10,max_samples=1.0,max_features=1.0,bootstrap=True,bootstrap_features=False,oob_score=False,warm_start=False,n_jobs=None,random_state=None,verbose=0)
```

Torbalama regresyon modelindeki parametreler ayrıntılı olarak aşağıda verilmiştir:

- **base_estimator:object,default=None**

Veri kümesinin rastgele alt kümelerine uygun olan temel tahmin edici,

None ise temel tahmin edici Karar Ağacı Regresyondur

(DecisionTreeRegressor).n_estimators:int,default=10

Topluluktaki temel tahmin edicilerin sayısıdır.

- **max_samples:int or float,default=1.0**

Her bir tahmin ediciyi eğitmek için veri setinden (X) yararlanılan örnek sayısıdır.

- **max_features:int or float,default=1.0**

Her bir tahmin ediciyi eğitmek için veri setinden (X) yararlanılan özellik sayısıdır.

- **bootstrap:bool,default=True**

Örneklerin değiştirilerek çekilip çekilmediğini gösterir. Eğer **False** ise değiştirme yapılmadan örnekleme yapıldığını gösterir.

- **bootstrap_features:bool,default=False**

Özelliklerin değiştirilerek çekilip çekilmediğini gösterir.

- **oob_score:bool,default=False**

Genelleme hatasını tahmin etmek için torba dışı örneklerin kullanılıp kullanılmayacağını gösterir. Yalnızca **bootstrap=True** ise kullanılır.

- **warm_start:bool,default=False**

True olarak ayarlandığında uydurmak için önceki aramanın çözümünü yeniden kullanın ve topluluğa daha fazla tahmin edici ekleyin, aksi taktirde tamamen yeni bir topluluğa uydurun.

- **n_jobs:int,default=None**

Hem uyum hem de tahmin için paralel olarak çalıştırılacak iş sayısıdır. Hiçbiri, bir `joblib.parallel_backend` bağlamında olmadığı sürece 1 anlamına gelir. -1 ise tüm işlemcileri kullanmak anlamına gelir.

- **Random_state:int,RandomState instance or None, default=None**

Orijinal veri kümesinin rastgele yeniden örneklenmesini kontrol eder.

- **Verbose:int,default=0**

Uydurma ve tahmin etme sırasında ayrıntı düzeyini kontrol eder.

Çizelge 4.22 ve 4.23’de Torbalama regresyon performansları farklı parametreler için verilmiştir.

Çizelge 4.22. Torbalama regresyon performansı (SVR ve DT-R temel tahmin edici)

Torbalama Regresyon Parametreleri		Performans Kriteri		Torbalama Regresyon Parametreleri		Performans Kriteri	
n	Temel Tahminci	RMSE	R ²	n	Temel Tahminci	RMSE	R ²
1	SV-R	54,618011	0,975205	1	DT-R	1,106793	0,999990
2	SV-R	56,131593	0,973812	2	DT-R	0,906544	0,999993
3	SV-R	56,845875	0,973141	3	DT-R	0,924437	0,999993
4	SV-R	57,778542	0,972253	4	DT-R	0,810282	0,999995
5	SV-R	56,353987	0,973604	5	DT-R	0,843335	0,999994
6	SV-R	57,882100	0,972153	6	DT-R	0,672257	0,999996
7	SV-R	56,411896	0,973550	7	DT-R	0,728956	0,999996
8	SV-R	57,098070	0,972902	8	DT-R	0,646244	0,999997
9	SV-R	57,455113	0,972562	9	DT-R	0,694085	0,999996
10	SV-R	57,180221	0,972825	10	DT-R	0,858190	0,999994

Çizelge 4.23. Torbalama regresyon performansı (RF-R ve AB-R temel tahmin edici)


Torbalama Regresyon Parametreleri		Performans Kriteri		Torbalama Regresyon Parametreleri		Performans Kriteri	
n	Temel Tahminci	RMSE	R ²	n	Temel Tahminci	RMSE	R ²
1	RF-R	1,180462	0,999988	1	AB-R	29,155062	0,992935
2	RF-R	0,714019	0,999996	2	AB-R	21,322926	0,996221
3	RF-R	0,561792	0,999997	3	AB-R	17,193903	0,997543
4	RF-R	0,507282	0,999998	4	AB-R	23,967081	0,995226
5	RF-R	0,730006	0,999996	5	AB-R	23,064854	0,995578
6	RF-R	0,582742	0,999997	6	AB-R	18,364099	0,997197
7	RF-R	0,513871	0,999998	7	AB-R	15,993369	0,997874
8	RF-R	0,516801	0,999998	8	AB-R	19,293125	0,996906
9	RF-R	0,582687	0,999997	9	AB-R	18,965782	0,997010
10	RF-R	0,476579	0,999998	10	AB-R	17,564124	0,997436

Çizelge 4.22 ve 4.23'den elde edilen en yüksek performans kriter değerleri Çizelge 4.24'de özetlenmiştir.


Çizelge 4.24. Farklı temel tahmin edicilere ait performans

n	Temel Tahmin Ediciler	Performans Kriteri	
		RMSE	R ²
1	SV-R	54,618011	0,975205
8	DT-R	0,646244	0,999997
10	RF-R	0,476579	0,999998
7	AB-R	15,993369	0,997874


Çizelge 4.24'den de görüldüğü gibi GES'in en yüksek güç tahmini n=10 için temel tahmin edici RF-R olduğunda elde edilmiştir. Şekil 4.41-4.47'de GES'in gerçek güç üretim değeri ve en uygun torbalama regresyon parametreleri (n=10 için RF-R temel tahmin edici) ile elde edilen tahmini güç üretim değeri grafiği verilmiştir.




Şekil 4.41. Gerçek güç üretimi ve RF-R güç tahmini (0-100 arasındaki veriler)




Şekil 4.42. Gerçek güç üretimi ve RF-R güç tahmini (101-200 arasındaki veriler)




Şekil 4.43. Gerçek güç üretimi ve RF-R güç tahmini (201-300 arasındaki veriler)




Şekil 4.44. Gerçek güç üretimi ve RF-R güç tahmini (301-400 arasındaki veriler)



Şekil 4.45. Gerçek güç üretimi ve RF-R güç tahmini (401-500 arasındaki veriler)



Şekil 4.46. Gerçek güç üretimi ve RF-R güç tahmini (501-600 arasındaki veriler)



Şekil 4.47. Gerçek güç üretimi ve RF-R güç tahmini (600-687 arasındaki veriler)

Yukarıdaki sonuçlardan da görüldüğü gibi BR güç tahmin modelinin en yüksek başarısı, RF temel tahmin edici ve $n_{\text{tahminci}} = 10$ iken elde edilmiştir. BR güç tahmin modeli için test verisi üzerinden gerçekleştirilen analizlerde, $R^2 = 0,999998$ ve $RMSE = 0,476579$ olarak elde edilmiştir.

5. SONUÇ ve ÖNERİLER

Bu çalışmada DŞB’li ve üç fazlı merkezi inverter topolojisine sahip Şenyurt (Erzurum/Türkiye) Güneş Enerji Santralinin (GES) güç üretiminin gerçek zamanlı tahmini için çok değişkenli regresyon analizi, ML tabanlı K-NN ve torbalama gibi ileri regresyon tahmin modelleri geliştirilmiştir.

İlk olarak güç üretim tahmin modelinde parametrik istatistiksel tekniklerden olan klasik Çoklu Lineer Regresyon (ÇLR) analizi kullanılmıştır. Güç üretim tahmin modeli için bağımsız değişkenler arasında çoklu doğrusal bağıntının tespiti için ÇLR analizinde “katsayılar” tablosu ayrıntılı olarak elde edilmiştir. Söz konusu tabloda çoklu regresyon analiz modelinin oluşturulması açısından değişkenler arasındaki korelasyon ilişkileri dikkate alınmıştır. Sonuç olarak güç üretim tahmini ışıyım ve PV modül sıcaklığı değişkenlerine göre modellenmiştir. ÇLR güç tahmin modelinde test verisi üzerinden gerçekleştirilen analizlerde, $R^2 = 0,715$ ve $RMSE = 174,30982$ olarak elde edilmiştir.

İkinci olarak güç üretim tahmin modelinde parametrik olmayan istatistiksel tekniklerden olan ML tabanlı KNN ve Torbalama Regresyon (BR) modelleri kullanılmıştır. Optimum K-NNR parametrelerinde, test verisi üzerinden gerçekleştirilen analizlerde, $R^2 = 0,76150$ ve $RMSE = 159,35244$ olarak elde edilmiştir. Torbalama Regresyon (BR) modelinde ise güç tahmin başarısının yüksek çıkması için bazı önemli parametrelerin en uygun değerlerinin tespit edilmesi gerekmektedir. BR güç tahmin modelinde ML tabanlı farklı temel tahmin ediciler olan Destek Vektör (SV), Karar Ağacı (DT), Rastgele Orman (RF) ve AdaBoost (AB) yapıları kullanılmıştır. BR güç tahmin modelinde önemli parametrelerden bir tanesi de tahmin edici sayısıdır. Bu çalışmada tahmin edici sayısı 1 ile 10 arasındaki değerler için ele alınmıştır. BR güç tahmin modelinin en yüksek başarısı, RF temel tahmin edici ve $n_{\text{tahminci}} = 10$ iken elde edilmiştir. Başarının en yüksek çıktığı BR güç tahmin modeli için test verisi üzerinden gerçekleştirilen analizlerde, $R^2 = 0,999998$ ve $RMSE = 0,476579$ olarak elde edilmiştir.

Geliştirilen BR tabanlı güç üretim tahmin modeli sürdürülebilir bir PV enerji dönüşümü ve işletme verimliliği açısından GES santrallerinde aktif olarak kullanılabilir. Aynı zamanda güç üretim tahmini için ML tabanlı farklı parametrik olmayan istatistiksel teknikler de kullanılabilir.



KAYNAKLAR

- Akbulut, Y. 2011. Sosyal Bilimlerde SPSS Uygulamaları, İdeal Kültür ve Yayıncılık, 1-200, İstanbul.
- Akhter, M. N. Mekhilef, S., Mokhlis, H. and Shah, N. M. 2019. Review on forecasting of photovoltaic power generation based on machine learning and metaheuristic techniques. IET Renewable Power Generation, 13(7), 1009-1023.
- Andenæs, E. Jelle, B. P., Ramlo, K., Kolås, T., Selj, J. ve Foss, S. E. 2018. The influence of snow and ice coverage on the energy generation from photovoltaic solar cells. Solar Energy, 159, 318-328.
- Anonymous, 2021a. Web Sitesi: https://www.tutorialspoint.com/machine_learning_with_python, Erişim Tarihi: 24.11.2021.
- Anonymous, 2021b. Web Sitesi: https://bookdown.org/tp_into_home/Regression-and-Classification/k-nearest-neighbours-regression.html, Erişim Tarihi: 24.11.2021.
- Anonim, 2021c. Web Sitesi: <https://veribilimcisi.com/2017/07/20/k-en-yakin-komsu-k-nearest-neighborsknn/>, Erişim Tarihi: 28.11.2021.
- Anonymous, 2021d. Web Sitesi: <https://artsandculture.google.com/exhibit/father-of-indian-statistics-prof-prasantachandra-mahalanobis/0AISK23-669ILA>, Erişim Tarihi: 04.12.2021.
- Anonymous, 2021e. Web Sitesi: https://commons.wikimedia.org/wiki/File:From_a_solar_cell_to_a_PV_system.svg, Erişim Tarihi: 10.12.2021.
- Anuradha, K., Erlapally, D., Karuna, G., Srilakshmi, V. ve Adilakshmi, K., 2021. Analysis Of Solar Power Generation Forecasting Using Machine Learning Techniques. In: E3S Web of Conferences, ICMED 2021, 07 October, Vol. 309, 01163, Telengana, India.
- Arslan, İ. 2020. Python ile Veri Bilimi. Pusula 20 Teknoloji ve Yayıncılık A.Ş., 3. Baskı 420, Ümraniye, İstanbul.
- Aydar, E., Üresin, E. ve Livatyalı, H. 2010. Yoğunlaştırılmış güneş enerjisinden elektrik üretimi. Tübitak Marmara Araştırma Merkezi, 10(08), 35-40.
- Bayazıt, M. ve Yeğenoğuz, E. B. 2013. Mühendisler İçin İstatistik. Birsen yayınevi, 1. Baskı, 1-97, İstanbul, Türkiye.
- Bayrak, F., Ertürk G. ve Oztop, H. F. 2017. Effects of partial shading on energy and exergy efficiencies for photovoltaic panels. Journal of Cleaner Production, 164, 58-69.

- Belyakov, N. 2019. Sustainable Power Generation: Current Status, Future Challenges, and Perspectives. Academic Press, 417-459, London.
- Bhatia, S. C. 2014. Advanced Renewable Energy Systems. Woodhead Publishing India Pvt. Ltd., 100-106, New Delhi, India.
- Bhol, R., Pradhan, A., Dash, R. ve Ali, S. M. 2015. Environmental Effect Assessment on Performance of Solar PV Panel, 2015 International Conference on Circuit, Power and Computing Technologies [ICCPCT], IEEE, 19-20 March, 1-5, Nagercoil, India.
- Blanco, M. J. ve Miller, S. 2017. Introduction to concentrating solar thermal (CST) technologies. In: Advances in Concentrating Solar Thermal Research and Technology. Blanco, M. J. ve Santigosa, L. R. (eds), Woodhead Publishing Series in Energy, Elsevier, 12-13.
- Bosman, L. and Darling S. 2016. Difficulties and Recommendations for More Accurately Predicting the Performance of Solar Energy Systems during the Snow Season, 5th International Conference on Renewable Energy Research and Applications, 20-23 November, IEEE, 567-571, Birmingham, UK.
- Bulut, H. 2019. R Uygulamaları ile Çok Değişkenli İstatistiksel Yöntemler. Nobel Akademik yayıncılık, 1. Baskı, 528, Ankara.
- Büyüköztürk, Ş. 2020. Sosyal Bilimler İçin Veri Analizi El Kitabı: İstatistik, Araştırma Deseni SPSS Uygulamaları ve Yorum. Pegem Akademi, 28. Baskı, 214 Ankara, Türkiye.
- Canan, S. 2020. Değişen Be(y)nim, Tutikitap, Nefes yayıncılık, 350, İstanbul, Türkiye.
- Chollet, F. 2019. Python ile Derin Öğrenme, Buzdağı yayınevi, 374, Ankara, Türkiye.
- Chung, M. H. 2020. Estimating solar insolation and power generation of photovoltaic systems using previous day weather data. Advances in Civil Engineering, 1-13, Korea.
- Deisenroth, M. P., Faisal, A. A. ve Ong, C. S. 2020. Mathematics for Machine Learning. Cambridge University Press, 411, Cambridge.
- EPDK, 2021. Web Sitesi: <https://www.epdk.gov.tr/Detay/Icerik/3-0-92/elektriklisans-siz-uretim>, Erişim Tarihi: 16.06.2021.
- Estela, 2021. Web Sitesi: <https://www.estelasolar.org/technologies-plants/the-4-types-of-csp-electricity-technologies/central-receiver/>, Erişim Tarihi: 20.12.2021.
- Ejgar, M., Momin, B. ve Ganu, T. 2017. Intelligent monitoring and maintenance of solar plants using real-time data analysis. International Conference on Consumer Electronics-Asia (ICCE-Asia) 5-7 October, IEEE, 133-138, Bengaluru, India.

- Fernandez-Garcia, A., Zarza, E., Valenzuela, L. ve Perez, M. 2010. Parabolic-trough solar collectors and their applications, *Renewable and Sustainable Energy Reviews*, 14(7), 1695-1721.
- Freddy, T. K. S. ve Abd Rahim, N. 2016. Photovoltaic inverter topologies for grid integration applications. In: *Advances in solar photovoltaic power plants*, Springer, 13-42, Heidelberg, Berlin.
- Golam, M., Akter, R., Lee, J. M. ve Kim, D. S. 2021. A long short-term memory-based solar irradiance prediction scheme using meteorological data. *IEEE Geoscience and Remote Sensing Letters*, 19, 1-5.
- Gök, M. ve Altuntaş, V. 2017. Regresyon Analizi, Çelik, U., Akçetin, E. ve Gök, M., (Ed.), *Rapidminer ile Uygulamalı Veri Madenciliği*, Pusula 20 Teknoloji ve Yayıncılık A.Ş., 268, Ümraniye, İstanbul.
- Gökte, S. A. 2020. Web Sitesi: <https://www.kdnuggets.com/2020/11/most-popular-distance-metrics-knn.html>, Erişim Tarihi: 04.12.2021.
- Gurria, A. ve Van der Hoeven, M. 2011. Report. OECD Green growth studies: Energy. International Energy Agency, 1, 10-13, London.
- Güriş, S., Akay, E. Ç. ve Güriş, B. 2017. EViews ile Temel Ekonometri, Der Yayınevi ve Dağıtım Paz. Ltd. Şti., 529, İstanbul.
- Hashemi, B., Cretu, A-M. ve Taheri, S. 2020. Snow loss prediction for photovoltaic farms using computational intelligence techniques. *IEEE Journal of Photovoltaics*, 10(4), 1044-1052.
- Hassaine, L., Olias, E., Quintero, J. ve Salas, V. 2014. Overview of power inverter topologies and control structures for grid connected photovoltaic systems. *Renewable and Sustainable Energy Reviews*, Vol. 30, 796-807.
- Heidari, N., Gwamuri, J., Townsend, T. ve Pearce, J. M. 2015. Impact of snow and ground interference on photovoltaic electric system performance. *IEEE Journal of Photovoltaics*, 5(6), 1680-1685.
- Hodge, Victoria J. ve Austin, J. 2004. A Survey of outlier detection methodologies, *Artificial Intelligence Review*, 22(2), 85-126.
- IEA, 2020. Web Sitesi: www.iea.org, Erişim Tarihi: 05.12.2021
- IEA, 2010. Technology Roadmap Concentrating Solar Power, International Energy Agency, 26-29 March, International Energy Agency's Renewable Energy Division, Vol 15, 9-11, Paris, France.
- Imandoust, S.B. ve Bolandraftar, M. 2013. Application of k-nearest neighbor (KNN) approach for predicting economic events: Theoretical background. *Int. Journal of Engineering Research and Applications*, 3(5), 605-610.

- JavaTpoint, 2021. Web Sitesi: <https://www.javatpoint.com/machine-learning>, Eriřim Tarihi: 10.09.2021.
- Johnson, R. A. ve Wichern, D. W. 2002. Applied multivariate statistical analysis Prentice Hall, (5. Baskı), Upper Saddle River, NJ.
- Jordan, J. 2017. Web Sitesi: <https://www.jeremyjordan.me/k-nearest-neighbors/>, Eriřim Tarihi: 24.11.2021.
- Kahan, A. 2017 Web Sitesi: <https://www.eia.gov/todayinenergy/detail.php?id=44095>, Eriřim Tarihi: 14.07.2021.
- Kalogirou, S. A. 2014. Solar Energy Engineering Processes and Systems. Academic Press publications, Elsevier, 816, Kidlington, UK.
- Karagöz, Y. 2019. SPSS Amosmeta Uygulamalı İstatistiksel Analizler. Nobel Akademik Yayıncılık Eğitim Danışmanlık Tic. Ltd. Şti., 1336, Ankara, Türkiye.
- Katz, M. H. 2011. Multivariable Analysis: A Practical Guide for Clinicians and Public Health Researchers. Cambridge University Press, 233, Cambridge, UK.
- Lippert, R. 2012. Web Sitesi: <https://www.factual.com/blog/the-wisdom-of-crowds/>, Eriřim Tarihi: 17.09.2021.
- Livatyalı, H. ve Yıldırım, T. 2012. Yoğunlaştırılmış güneř enerjisi teknolojisindeki gelişmeler. Mühendis ve Makine, 53(633), 16-20.
- Marius, H. 2020. Web Sitesi: <https://towardsdatascience.com/tree-algorithms-explained-ball-tree-algorithm-vs-kd-tree-vs-brute-force-9746debcd940>, Eriřim Tarihi: 05.12.2021.
- Marsland, S. 2015. Machine Learning: An Algorithmic Perspective, CRC Press, Taylor & Francis Group, 406, Boca Raton, FL, USA.
- Maruti T. 2021. Web Sitesi: <https://marutitech.com/problems-solved-machine-learning/>, Eriřim Tarihi: 10.09.2021.
- MGM, 2021a. Web Sitesi: <https://www.mgm.gov.tr/genel/meteorolojiyegir.aspx? =19>, Eriřim Tarihi: 19.07.2021.
- Morrison, G. L. 2001. Solar Energy: The State of the Art. James & James (Science Publishers) Ltd., 724, London.
- OECD, 2021. Web Sitesi: <https://www.oecd.org/greengrowth/the-inequalities-environment-nexus-ca9d8479-en.htm>, Eriřim Tarihi: 19.07.2021.
- Özdemir, K. 2021. Web Sitesi: <https://medium.com/batech/k-en-yak%C4%B1n-kom%C5%9Fu-algoritmas%C4%B1-k-nearest-neighbors-algorithm-16e5ab69af2e>, Eriřim Tarihi: 04.12.2021.

- Özgören, M., Köse, F., Aksoy, M.H., Canlı, E., Solmaz, Ö., Doğan, S. ve Yağmur, S. 2012. Konya’da Yenilenebilir Enerji Kaynakları Malzeme Üretilebilirlik Araştırması. Yeryüzü Enerji Sistemleri Ltd. Şti., 69, Konya, Türkiye.
- Öztürk, H. H. 2013. Yenilenebilir Enerji Kaynakları. Birsen yayınevi, 442, İstanbul, Türkiye.
- Pallant, J. 2001. SPSS Survival Sanual. Maidenhead, PA: Open University Press. 351, New York.
- Patel, M.R. 2006. Wind and Solar Power Systems: Design, Analysis, and Operation. CRC Press, Taylor & Francis Group, 341-364, Boca Raton, Florida, USA.
- Pawluk, R. E., Chen, Y. ve She, Y. 2019. Photovoltaic electricity generation loss due to snow – A literature review on influence factors, estimation and mitigation. Renewable and Sustainable Energy Reviews, 107, 171–182.
- Pearson, E. S. ve Hartly, H. O. 1958. Biometrika tables for statistician. Cambridge University Press, 280, New York.
- Rahman, S., I. Sarwat, A. ve Aburub, H. 2019. Techno-Economic Potential of Large-Scale Solar Deployment in the US. In: Advances in Solar Energy Research. Tyagi, H., Agarwal, A. K., Chakraborty, P. R. and Powar, S., (eds), Springer Nature Singapore Pte Ltd., 13-43, Singapore.
- REN21, 2020. Web Sitesi: <https://www.ren21.net/gsr-2020/>, Erişim Tarihi: 19.07.2021.
- Sadineni, S., Boehm, R. 2010. Concentrator Solar Cell Installations at the University of Nevada, Las Vegas. Solar Cells and Their Applications. Fraas, L. ve Partain, L., (eds) Wiley, A John Wiley & Sons, Hoboken, 361-376, New Jersey.
- Schiel, W., Keck, T. 2012. Parabolic Dish Concentrating Solar Power (CSP) Systems, Woodhead Publishing Limited, 285-287, Germany.
- Seçer, İ. 2017. SPSS ve LISREL ile Pratik Veri Analizi: Analiz ve Raporlaştırma. Anı Yayıncılık Eğitim ve Danışmanlık San. Tic. Ltd. Şti., 218, Ankara, Türkiye.
- Semiz, M. 2009. Uygulamalı İstatistik. Selçuk Üniversitesi, Fen-Edebiyat Fakültesi, İstatistik Bölümü, Dizgi Ofset Matbaacılık, 405, Konya, Türkiye.
- Sicikit-Learn Developers, 2021. Web Sitesi: https://scikit-learn.org/stable/supervised_learning.html#supervised-learning, Erişim Tarihi: 05.12.2021.
- Sobri, S., Koohi-Kamali, S. ve Rahim, N. A. 2018. Solar photovoltaic generation forecasting methods: A review. Energy Conversion and Management, 156, 459-497.
- Solanki, D., Upadhyay, U., Chauhan, R. ve Desai, S. 2018. Solar Energy Prediction using Meteorological Variables, International Conference on Recent Innovations in

Electrical, Electronics & Communication Engineering, ICRIEECE, IEEE, 27-28 July, 1-8, India.

- Su, D., Batzelis, E. ve Pal, B. 2019. Machine Learning Algorithms in Forecasting of Photovoltaic Power Generation, In 2019 International Conference on Smart Energy Systems and Technologies (SEST), 9-11 September, IEEE, Vol 15, 1-6, Porto, Portugal.
- Sreedevi, J., Ashwin, N. ve Raju, M. N. 2016. A study on grid connected PV system. In 2016 National Power Systems Conference (NPSC), IEEE, 1-6, India.
- Şener, Y. 2020. Web Sitesi: <https://medium.com/datarunner/veri-biliminde-normal-da%C4%9F%C4%B1%C4%B1m%C4%B1n-r-ve-python-ile-testi-ve/>, Erişim Tarihi: 04.09.2021.
- Ungar, L. 2021. Web Sitesi: <https://alliance.seas.upenn.edu/~cis520/dynamic/2021/wiki/index.php?n=Lectures.LocalLearning>, Erişim Tarihi: 08.09.2021
- Ünlütürk, M. 2019. Fotovoltaik panel yüzeyinde görüntü işleme teknikleri kullanılarak kirlilik tespiti. Yüksek Lisans Tezi, Konya Teknik Üniversitesi, Lisansüstü Eğitim Enstitüsü, Elektrik Elektronik Mühendisliği Ana Bilim Dalı, 77, Konya.
- Van Tai, D. 2019. Solar Photovoltaic Power Output Forecasting Using Machine Learning Technique. In Journal Of Physics: Conference Series, 26-28 June, 1327(1), IOP Publishing, 012051, Russia.
- Vician, P., Palacka, M., Durcansky, P. ve Jandacka, J. 2018. Mathematical Model for Calculating Performance of Parabolic Trough Collector. In: Renewable Energy Sources: Engineering, Technology, Innovation. Mudryk, K. ve Werle, S., (eds) ICORES 2017, Springer International Publishing, 59-70, Switzerland.
- Xing, Z., Pei, J. ve Yu, P. S. 2012. Early classification on time series. Knowledge and information systems, Springer, 31(1), 105-127.
- Yilmaz, S., Ozcalik, H. R. ve Dincer, F. 2017. Modelling and designing of the solar thermal parabolic trough concentrator and its environmental effects. Environmental Progress & Sustainable Energy, American Institute of Chemical Engineers, John Wiley & Sons, 36(3), 967-974.
- Zarza-Moya, E. 2012. Parabolic-trough Concentrating solar power (CSP) systems. In: Concentrating Solar Power Technology: Principles, Developments and Applications. Lovegrove, K. ve Stein, W., (eds), Woodhead Publishing Limited, Cambridge, 197-239, UK.

EKLER

EK-1: Yasal İzin Belgesi

TEGNATIA ENERJİ ÜRETİM SANAYİ VE TİCARET

ANONİM ŞİRKETİ GENEL MÜDÜRLÜĞÜ'NE

İSTANBUL

Erzurum Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Elektrik-Elektronik Mühendisliği Anabilim Dalında Yüksek Lisans yapmaktayım. Yüksek Lisans tez çalışmamı Dr. Öğr. Üyesi Ali ÜNLÜTÜRK danışmanlığında devam ettirmekteyim. Yüksek Lisans tez konusu “Şebeke Bağlantılı Güneş Enerji Santralinin Güç Verimliliğinin Performans Analizi ve Tahmini” dir. Yüksek Lisans tez çalışmamda sahip olduğunuz “Şenyurt/Erzurum Güneş Enerji Santrali” nin SCADA verilerini ve PV panellere ait termal görüntüleri kullanmam konusunda onayınızı almak istiyorum.

Bilgilerinizi ve gereğini arz ederim.

İmza:
Tarih:
Fatih SULAN

Çalışanlarımızdan Fatih SULAN'ın Erzurum Teknik Üniversitesi, Fen Bilimleri Enstitüsü'ne bağlı Elektrik-Elektronik Mühendisliği Anabilim Dalında yapmış olduğu ve yukarıda adı geçen yüksek lisans tez çalışmasında Erzurum Bölgesinde kurulu olan Şenyurt Güneş Enerji Santralimizin SCADA verilerinin ve PV panellere ait termal görüntülerin kullanmasında herhangi bir mahsur görülmemiştir.

İmza:
Tarih:
TEGNATIA ENERJİ ÜRETİM SANAYİ
VE TİCARET ANONİM ŞİRKETİ
Kırmızı Mh. İnönü Sk. No:6/B Üsküdar-İSTANBUL
Tel: +90 216 524 12 34 Fax: +90 216 524 12 13
Mersis No.: 0833049592500019
Ünvanıye V.D. 633 049 5925
Sermaye: 1.250.000 TL