MAKİNE ÖĞRENİMİ TABANLI FOTOVOLTAİK ÇIKIŞ GÜCÜ TAHMİNLEMESİ

BERRİN ERYILMAZ

TEMMUZ 2022

DİYARBAKIR

DİCLE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

MAKİNE ÖĞRENİMİ TABANLI FOTOVOLTAİK ÇIKIŞ GÜCÜ TAHMİNLEMESİ

BERRİN ERYILMAZ

DİCLE ÜNİVERSİTESİ LİSANSÜSTÜ EĞİTİM-ÖĞRETİM VE SINAV YÖNETMELİĞİNİN BİR PARÇASI OLARAK YENİLENEBİLİR ENERJİ KAYNAKLARI ANA BİLİM DALINDA YÜKSEK LİSANS TEZİ OLARAK HAZIRLANMIŞTIR

TEMMUZ 2022

DİYARBAKIR

MAKİNE ÖĞRENİMİ TABANLI FOTOVOLTAİK ÇIKIŞ GÜCÜ TAHMİNLEMESİ

Berrin ERYILMAZ tarafından Dicle Üniversitesi Lisansüstü Eğitim-Öğretim ve Sınav Yönetmeliği'nin bir parçası olarak hazırlanan bu çalışma, aşağıda bilgileri yazılı jüri üyeleri tarafından değerlendirilerek **Yenilenebilir Enerji Kaynakları Ana Bilim Dalı**'nda **Yüksek Lisans Tezi** olarak kabul edilmiştir.

Prof. Dr. Neslihan DALKILIÇ
Müdür, **Fen Bilimleri Enstitüsü**

Doç. Dr. Fatih KOÇYİĞİT
Danışman, **Sivil Havacılık Yüksekokulu, Dicle Üniversitesi**

Dr. Öğr. Üyesi Heybet KILIÇ
İkinci Danışman, **Teknik Bilimler Meslek Yüksekokulu, Dicle Üniversitesi**

Sınav Jürisi:

Prof. Dr. Vedat Veli ÇAY**(*)**
Dicle Üniversitesi Sivil Havacılık Yüksekokulu
Uçak Bakım ve Onarım Bölümü

Doç. Dr. Fatih KOÇYİĞİT **(**)**
Dicle Üniversitesi Sivil Havacılık Yüksekokulu
Uçak Bakım ve Onarım Bölümü

Doç. Dr. Abid USTAOĞLU
Bartın Üniversitesi Müh. Mim. ve Tasarım Fak.
Makine Mühendisliği Bölümü

ONAY

Savunma Tarihi: 27 / 07 / 2022

(*) Sınav Jürisi kısmının birinci satırına Jüri Başkanının bilgilerini yazınız.
(**) Sınav Jürisi kısmının ikinci satırına Tez Danışmanının bilgilerini yazınız.

Annem Remziye ERYILMAZ ve abim Mahmut ERYILMAZ'a ithafen…

Dicle Üniversitesi Fen Bilimleri Enstitüsü Tez Yazım Kurallarına uygun olarak hazırlanan bu tez çalışmasında yer alan tüm bilgilerin akademik kurallara ve etik ilkelere uygun olarak elde edildiğini ve sunulduğunu beyan ederim. Ayrıca, bahse konu bu kural ve ilkelerin gerektirdiği üzere, bu çalışmada özgün olmayan tüm bilimsel içerikleri kurallara uygun biçimde alıntılayıp kaynak gösterdiğimi beyan ederim. Beyanımla çelişen herhangi bir delil bulunduğu takdirde tüm sorumluluğu üstleneceğimi kabul ederim.

Adı, Soyadı: Berrin ERYILMAZ

İmza: …….……

TEŞEKKÜR

Çalışmam boyunca her türlü destek ve katkılarını benden esirgemeyen danışmanım Sayın Doç. Dr. Fatih Koçyiğit'e ve ikinci danışmanım Sayın Dr. Öğr. Üyesi Heybet Kılıç'a çalışmamın fikir aşamasından, sonuç aşamasına kadar yol gösterdikleri için ve gösterdikleri sabır için teşekkür ederim. Ayrıca jüri üyelerime de bu tezin daha nitelikli bir hale gelmesi için yaptıkları eleştiri ve önerileri için teşekkür ederim.

Beni maddi ve manevi destekleriyle yalnız bırakmayan, akademik anlamda her zaman beni başarıya teşvik eden ve bana inanan aileme teşekkürü borç bilirim.

İÇİNDEKİLER

TEŞEKKÜR v
İÇİNDEKİLER vi
ŞEKİLLER LİSTESİ viii
TABLOLAR LİSTESİ xi
KISALTMALAR LİSTESİ xii
ÖZET xiv
ABSTRACT xv
1. GİRİŞ 1
1.1 Motivasyon 1
1.1.1 Net sıfıra giden yolda güneş enerjisinin rolü 7
1.2 Tezin Amacı ve Kapsamı 13
1.3 Tezin Katkısı 14
1.4 Tezin Yapısı 15
2. KAYNAK ÖZETLERİ 16
2.1 Tahmin Vadesi 16
2.1.1 Çok kısa vadeli veya ultra kısa vadeli tahmin 16
2.1.2 Kısa vadeli tahmin 16
2.1.3 Orta vadeli tahmin 17
2.1.4 Uzun vadeli tahmin 17
2.2 Tahmin Modeli Girdileri 17
2.3 PV Çıkış Gücü Tahmin Yaklaşımları 17
3. MALZEME VE YÖNTEM 24
3.1 PV Santral 24
3.2 Güneş ölçüm istasyonu 25
3.3 Data Seti 26
3.3.1 K katlamalı çapraz doğrulama 28

3.4 Gürültü Verisinin Elde Edilmesi 29
3.5 Kanonik Korelasyon Analizi (KKA) ile Hava Tipi Sınıflandırması 30
3.6 Orijinal Rastgele Vektör Fonksiyon Bağlantı (RVFL) Ağ Modeli 34
3.7 Regularized RVFLN (Düzenlenmiş RVFL Ağı) 37
3.8 Gürbüz Düzenlenmiş Rastgele Vektör Fonksiyon Bağlantı Ağı (GD- 38
3.9 Karşılaştırma Yöntemleri 41
3.9.1 Linear regressor (LR) 41
3.9.2 Lasso regressor (LAR) 42
3.9.3 Ridge regressor (RR) 42
3.9.4 Bayesian Ridge Regression (BRR) 42
3.9.5 Support Vector machine 43
3.9.6 Random forest regressor (RFR) 44
3.9.7 Gradient boosting regressor (GBR) 45
3.9.8 Gaussian Process Regression (GPR) 45
3.9.9 Extreme learning machine (ELM) 45
3.9.10 Yapay sinir Ağı (YSA) 47
4. BULGULAR VE TARTIŞMA 48
4.1 Değerlendirme Endeksleri 48
4.2 Tahmin Sonuçları 49
4.2.1 Hava tipi sınıflandırmasına dayalı GD-RVFLN modeli tahmin sonuçları.. 49
4.3 GD-RVFLN Modeli ile 10 Modelin Tahmin Sonuçlarının Karşılaştırılması…. 63
5. SONUÇLAR 78
KAYNAKLAR 79
ÖZGEÇMİŞ 87

ŞEKİLLER LİSTESİ

Şekil 1.1 Fosil Enerji kanyakları ve Endüstriden kaynaklı CO2 emisyonları, 1900-2021 1
Şekil 1.2 2019 yılına göre fosil enerji kaynaklı CO2 emisyonlarındaki değişim, 2019-2021 2
Şekil 1.3 Küresel Elektrik Üretimi (TWh,2019-2050) 3
Şekil 1.4 Kurulu Güç Dağılımı (GW,2020-205) 3
Şekil 1.5 Küresel Güner Enerji Kurulu Güç Gelişimi (GW, 2010-2050) 4
Şekil 1.6 Yıllık Yenilenebilir Enerji İlave Kurulu Güç Tahmini (GW, 2020-2026) ... 5
Şekil 1.7 Yıllık Güneş İlave Kurulu Güç (GW, 2015-2026) 5
Şekil 1.8 Güneş Kurulu Güç Projeksiyonları (GW, 2010-2040) 6
Şekil 1.9 2020 Yılı Güneş Kurulu Güç Projeksiyonları (TWh) 6
Şekil 1.10 Elektrik Üretimi İçerisinde Yenilenebilir Kaynakların Payı (%, 2019-2050) 7
Şekil 1.11 Bazı ülkelerin taahhütte bulundukları kömürden çıkış tarihi 8
Şekil 1.12 Elektrik Üretimi İçerisinde Güneş Enerjisi Payı (TWh, %, 2000-2050) ... 8
Şekil 1.13 Elektrik Kurulu Gücü İçerisinde Güneş Enerjisi Payı (GW, %, 2000-2050) 9
Şekil 1.14 Aralık 2021 enerji kaynaklarının kurulu güç payları 11
Şekil 3.1 PV güç istasyonunun veri toplama sistemi 25
Şekil 3.2 Dicle Üniversitesi güneş ölçüm istasyonu 26
Şekil 3.3 Her ayın 2'sinde PV çıkış gücü eğrileri 29
Şekil 3.4 KKA'ya bağlı hava tipi sınıflandırma süreci 33
Şekil 3.5 Hava tipi sınıflandırmasına dayalı PV tahmin yöntemi 34
Şekil 3.6 Hava tipi sınıflandırmasına dayalı RVFL ağ modeli 35
Şekil 3.7 Support vektörleri ve hiper düzlem kenarları 43
Şekil 3.8 YSA'nın temel yapısı 47
Şekil 4.1 02.04.2022 tarihinde ölçülen gerçek PV çıkış gücü 50
Şekil 4.2 02.04.2022 tarihinde ölçülen gerçek PV çıkış gücü ile GD-RVFLN modelinin tahmin sonucunun karşılaştırması 51
Şekil 4.3 02.03.2022 tarihinde ölçülen gerçek PV çıkış gücü 51
Şekil 4.4 02.03.2022 tarihinde ölçülen gerçek PV çıkış gücü ile GD-RVFLN modelinin tahmin sonucunun karşılaştırması 52

Şekil 4.5 02.02.2022 tarihinde ölçülen gerçek PV çıkış gücü 52
Şekil 4.6 02.02.2022 tarihinde ölçülen gerçek PV çıkış gücü ile GD-RVFLN modelinin tahmin sonucunun karşılaştırması..... 53
Şekil 4.7 02.01.2022 tarihinde ölçülen gerçek PV çıkış gücü 53
Şekil 4.8 02.01.2022 tarihinde ölçülen gerçek PV çıkış gücü ile GD-RVFLN modelinin tahmin sonucunun karşılaştırması..... 54
Şekil 4.9 02.12.2021 tarihinde ölçülen gerçek PV çıkış gücü 54
Şekil 4.10 02.12.2021 tarihinde ölçülen gerçek PV çıkış gücü ile GD-RVFLN modelinin tahmin sonucunun karşılaştırması..... 55
Şekil 4.11 02.11.2021 tarihinde ölçülen gerçek PV çıkış gücü 55
Şekil 4.12 02.11.2021 tarihinde ölçülen gerçek PV çıkış gücü ile GD-RVFLN modelinin tahmin sonucunun karşılaştırması..... 56
Şekil 4.13 02.10.2021 tarihinde ölçülen gerçek PV çıkış gücü 56
Şekil 4.14 02.10.2021 tarihinde ölçülen gerçek PV çıkış gücü ile GD-RVFLN modelinin tahmin sonucunun karşılaştırması..... 57
Şekil 4.15 02.09.2021 tarihinde ölçülen gerçek PV çıkış gücü 57
Şekil 4.16 02.09.2021 tarihinde ölçülen gerçek PV çıkış gücü ile GD-RVFLN modelinin tahmin sonucunun karşılaştırması..... 58
Şekil 4.17 02.08.2021 tarihinde ölçülen gerçek PV çıkış gücü 58
Şekil 4.18 02.08.2021 tarihinde ölçülen gerçek PV çıkış gücü ile GD-RVFLN modelinin tahmin sonucunun karşılaştırması..... 59
Şekil 4.19 02.07.2021 tarihinde ölçülen gerçek PV çıkış gücü 59
Şekil 4.20 02.07.2021 tarihinde ölçülen gerçek PV çıkış gücü ile GD-RVFLN modelinin tahmin sonucunun karşılaştırması..... 60
Şekil 4.21 02.06.2021 tarihinde ölçülen gerçek PV çıkış gücü 60
Şekil 4.22 02.06.2021 tarihinde ölçülen gerçek PV çıkış gücü ile GD-RVFLN modelinin tahmin sonucunun karşılaştırması..... 61
Şekil 4.23 02.05.2021 tarihinde ölçülen gerçek PV çıkış gücü 61
Şekil 4.24 02.05.2021 tarihinde ölçülen gerçek PV çıkış gücü ile GD-RVFLN modelinin tahmin sonucunun karşılaştırması..... 62
Şekil 4.25 02.04.2022 tarihindeki tüm modellerin tahmin sonuçları..... 63
Şekil 4.26 02.04.2022 tarihinde en iyi performans ile en kötü performans gösteren modellerin tahmin sonuçları..... 64

Şekil 4.27 02.03.2022 tarihindeki tüm modellerin tahmin sonuçları 64
Şekil 4.28 02.03.2022 tarihinde en iyi performans ile en kötü performans gösteren modellerin tahmin sonuçları 65
Şekil 4.29 02.02.2022 tarihindeki tüm modellerin tahmin sonuçları 65
Şekil 4.30 02.03.2022 tarihinde en iyi performans ile en kötü performans gösteren modellerin tahmin sonuçları 66
Şekil 4.31 02.01.2022 tarihindeki tüm modellerin tahmin sonuçları 66
Şekil 4.32 02.01.2022 tarihinde en iyi performans ile en kötü performans gösteren modellerin tahmin sonuçları 67
Şekil 4.33 02.12.2021 tarihindeki tüm modellerin tahmin sonuçları 67
Şekil 4.34 02.12.2021 tarihinde en iyi performans ile en kötü performans gösteren modellerin tahmin sonuçları 68
Şekil 4.35 02.11.2021 tarihindeki tüm modellerin tahmin sonuçları 68
Şekil 4.36 02.11.2021 tarihinde en iyi performans ile en kötü performans gösteren modellerin tahmin sonuçları 69
Şekil 4.37 02.10.2021 tarihindeki tüm modellerin tahmin sonuçları 69
Şekil 4.38 02.10.2021 tarihinde en iyi performans ile en kötü performans gösteren modellerin tahmin sonuçları 70
Şekil 4.39 02.09.2021 tarihindeki tüm modellerin tahmin sonuçları 70
Şekil 4.40 02.09.2021 tarihinde en iyi performans ile en kötü performans gösteren modellerin tahmin sonuçları 71
Şekil 4.41 02.08.2021 tarihindeki tüm modellerin tahmin sonuçları 71
Şekil 4.42 02.08.2021 tarihinde en iyi performans ile en kötü performans gösteren modellerin tahmin sonuçları 72
Şekil 4.43 02.07.2021 tarihindeki tüm modellerin tahmin sonuçları 72
Şekil 4.44 02.07.2021 tarihinde en iyi performans ile en kötü performans gösteren modellerin tahmin sonuçları 73
Şekil 4.45 02.06.2021 tarihindeki tüm modellerin tahmin sonuçları 73
Şekil 4.46 02.06.2021 tarihinde en iyi performans ile en kötü performans gösteren modellerin tahmin sonuçları 74
Şekil 4.47 02.05.2021 tarihindeki tüm modellerin tahmin sonuçları 74
Şekil 4.48 02.05.2021 tarihinde en iyi performans ile en kötü performans gösteren modellerin tahmin sonuçları 75

TABLOLAR LİSTESİ

Tablo 1.1 TEİAŞ-Yük Tevzi Dairesi Başkanlığı- Kurulu Güç Raporu-Aralık 2021.. 11
Tablo 1.2 TEİAŞ-Yük Tevzi Dairesi Başkanlığı- Kurulu Güç Raporu-Haziran 2022 12
Tablo 3.1 Viessmann Vitovolt 300 Panel Etiket Değerleri 25
Tablo 3.2 02.04.2020 Tarihli Veri seti 26
Tablo 3.3 PV güç çıkış seviyesine göre dört tip hava durumu sınıflandırması 32
Tablo 4.1 GD-RVFLN için OMYH ve OKH değerleri 50
Tablo 4.2 On bir makine öğrenimi modeli için OMYH (%) değerleri 75
Tablo 4.3 On bir makine öğrenimi modeli için OKH değerleri 76

KISALTMALAR LİSTESİ

Kısaltma	Açıklama
BRR	Bayesian Ridge Regressor
DEK	Dünya Enerji Konseyi
ELM	Extreme Learning Machine
GBR	Gradient Boosting Regressor
GD-RVFL	Gürbüz Düzenlenmiş Rastgele Vektör Fonksiyon Bağlantı
GPR	Gaussian Process Regressor
H	Bağıl nem
HT	Hava Tipi
KKA	Konikal Korelasyon Analizi
KKT	Karush-Kuhn-Tucker
LAR	Lasso Regressor
LR	Linear Regressor
nOKH	Normalleştirilmiş Ortalama Karekök Hata
OKH	Ortalama Karekök Hatası
OMH	Ortalama Mutlak Hata
OMYH	Ortalama Mutlak Yüzdelik Hata
PV	Photovoltaic
R	Güneş radyasyonu
R2	Regresyon Katsayısı
RFR	Random Forest Regressor

RR	Ridge Regressor
RVFLN	Rastgele Vektör Fonksiyon Bağlantı
SHT	Sayısal Hava Tahmini
SLFN	Single Shrouded Layer Feed-Forward Neural Network
SVM	Support Vector Machine
T	Ortam sıcaklığı
TEİAŞ	Türkiye Elektrik İletim A.Ş
UEA	Uluslararası Enerji Ajansı
W	Rüzgâr hızı
DMÖ	Dünya Meteoroloji Örgütü
YEK	Yenilenebilir Enerji Kaynakları
YSA	Yapay Sinir Ağı

ÖZET

MAKİNE ÖĞRENİMİ TABANLI FOTOVOLTAİK ÇIKIŞ GÜCÜ TAHMİNLEMESİ

ERYILMAZ, Berrin
Yüksek Lisans, Yenilenebilir Enerji Kaynakları Bölümü
Danışman: Doç. Dr. Fatih KOÇYİĞİT
İkinci Danışman: Dr. Öğr. Üyesi Heybet KILIÇ
Temmuz 2022, 104 sayfa

Fosil yakıt kaynaklarının sınırlı olması, çevreye zararlı etkilerinin olması gibi nedenlere ek olarak küresel enerji alanında yaşanan kötü gidişatın önünü almak için fotovoltaik (PV) sistemlerinin kurulum kapasitesi giderek artmaktadır. PV sistemlerinin hava koşularına bağımlılığı PV güç çıkışlarında kararsızlığa, gerilim, frekans dalgalanmaları ve kesintilere neden olmaktadır. Bu durum ise PV enerjisinin şebekelere entegrasyonunu zorlaştırmaktadır. Bu yüzden PV güç çıkışını önceden kısa süreli tahmin etmek karşılaşılan zorlukların üstesinden gelmek için çok önemlidir. Bu çalışmanın amacı, literatürde makine öğrenimi modellerinde yaygın olan aşırı öğrenme ve yavaş öğrenme dezavantajlarının üstesinden gelerek daha hızlı öğrenen ve yüksek doğrulukta performans gösteren Gürbüz Düzenlenmiş Rastgele Vektör Fonksiyon Bağlantı (GD-RVFL) ağı modelini kısa vadeli PV çıkış gücünü tahmin etmede kullanmak ve bu kapsamda önerilen modeli 10 farklı makine öğrenimi yöntemi olan Bayesian Ridge Regressor (BRR), Linear Regressor (LR), Gaussian Process Regressor (GPR), Support Vector Machine (SVM), Extreme Learning Machine (ELM), Yapay Sinir Ağı (YSA), Gradient Boosting Regressor (GBR), Random Forest Regressor (RFR), Lasso Regressor (LAR) ve Ridge Regressor (RR) yöntemleri ile karşılaştırılarak modellerinin performansını değerlendirmektir. Bu çalışmada makine öğrenimi modellerini oluşturmak ve uygulamak için MATLAB programı kullanılmıştır. Bu çalışmanın veri seti, Diyarbakır'ın Dicle Üniversitesi kampüsünde bulunan PV güç santralinden ve güneş enerji istasyonundan toplanmıştır. Veri seti, 10 dakikalık aralıklarla Mayıs 2019-Nisan 2022 tarihleri arasında elde edilmiştir. Bu çalışmada, ilk olarak, güneş ışınımı, güneşlenme süresi, rüzgâr hızı, ortam sıcaklığı, panel yüzey sıcaklığı, bulutluluk oranı, DC akım, gerilim ve bağıl nem parametreleri Konikal Korelasyon Analizi (KKA) modeli kullanarak hava tipi seviyelerine göre dört sınıfa ayrılmıştır. Daha sonra GD-RVFL modeli, bu dört sınıfa ayrılan hava tipini giriş olarak kullanılarak kısa vadeli (10 dakika) PV çıkış gücünü tahmin etmiştir ve sonuçlar 10 farklı makine öğrenimi modeli ile karşılaştırılmıştır. Yapılan bu karşılaştırma sonucunda GD-RVFL' nin etkinliği diğer 10 makine öğrenimi modeline göre önemli ölçüde daha iyi performans gösterdiği görülmüştür. Ayrıca bölgede meteorolojik koşullar nispeten sabit olduğu günlerde modellerin çoğu nispeten yüksek doğruluk göstermiştir. Hava koşullarının değişkenlik gösterdiği günlerde ise GD-RVFL daha iyi sonuç vermiştir. Meteorolojik koşulların sabit olduğu günlerin Ortalama Mutlak Yüzdelik Hata (OMYH) değerleri sırasıyla 1,68; 1,72 ve 1,82 olmuştur. Sonuç olarak seçilen özellikler ve yöntem tahmin doğruluğunun önemli ölçüde iyileştirmiştir.

Anahtar Kelimeler: GD-RVFLN, Hava tipi sınıflandırması, KKA, Makine öğrenimi, PV çıkış gücü tahmini

ABSTRACT

MACHINE LEARNING BASED PHOTOVOLTAIC OUTPUT POWER FORECASTING

ERYILMAZ, Berrin
Master of Science in Department of Renewable Energy Resources
Supervisor: Assoc. Prof. Dr. Fatih KOÇYIĞIT
Co-Supervisor: Assitant Professor Heybet KILIÇ
July 2022, 104 pages

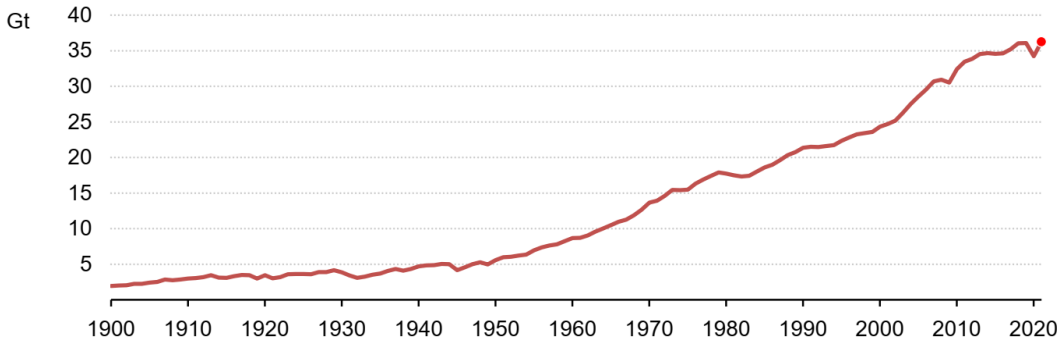
The installation capacity of photovoltaic (PV) systems is gradually increasing in order to prevent reasons such as limited fossil fuel resources, harmful effects on the environment and the bad course in the global energy field The dependence of PV systems on weather conditions causes instability, voltage, frequency fluctuations and interruptions in PV power outputs. This situation complicates the integration of PV energy into the grids. Therefore, short-term forecasting of PV power output is crucial to overcome the challenges. The aim of this study is to use the Robust Arranged Random Vector Function Interconnect (GD-RVFL) network model, which learns faster and performs with high accuracy, overcoming the excessive learning and slow learning disadvantages that are common in machine learning models in the literature, to predict the short-term PV output power and in this context by comparing the proposed model with Bayesian Ridge Regressor (BRR), Linear Regressor (LR), Gaussian Process Regressor (GPR), Support Vector Machine (SVM), Extreme Learning Machine (ELM), Artificial Neural Network (ANN), Gradient Boosting Regressor (GBR), Random Forest Regressor (RFR), Lasso Regressor (LAR) and Ridge Regressor (RR) methods, which are 10 different machine learning methods to evaluate the performance of the models. In this study, MATLAB program was used to create and implement machine learning models. The data set was collected from the PV power plant and the solar power station located on the Dicle University campus in Diyarbakır. The dataset has 10-minute periods between May 2019 and April 2022. First, solar radiation, sunshine duration, wind speed, ambient temperature, panel surface temperature, cloudiness, DC current, voltage and relative humidity parameters were divided into four classes according to weather type levels using Conical Correlation Analysis (KKA) model. Next, the RR-RVFL model estimated the short-term (10 minutes) PV output power using these four classes of air type as input, and the results were compared with 10 different machine learning models. As a result of this comparison, it was seen that the efficiency of RR-RVFL significantly outperformed the other 10 machine learning models. Also, on days when meteorological conditions in the region were relatively stable, most of the models showed relatively high accuracy. On days when weather conditions varied, RR-RVFL gave better results. Mean Absolute Percentage Error (OMYH) values of the days with constant meteorological conditions were 1.68, 1.72 and 1.82 respectively. As a result, the selected features and method significantly improved the prediction accuracy.

Keywords: KKA Machine learning, PV output power forecasting, RR-RVFL, Weather type classification

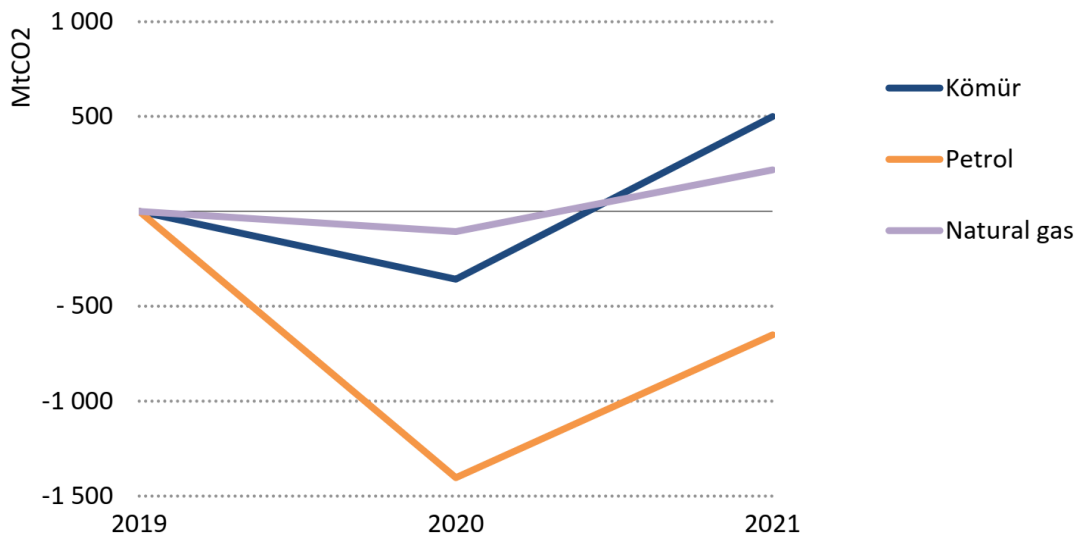
1. GİRİŞ

1.1 Motivasyon

Sanayinin gelişimi, hızlı kentleşme ve teknolojik büyüme enerjiye olan talebi gün geçtikçe daha önemli hale getirmektedir. Bu sürekli artan enerji talebini karşılamak için elektrik üretimi ve dağıtımına ihtiyaç vardır. Bilindiği gibi enerji üretimi yenilenebilir enerji kaynakları (YEK) (güneş, rüzgâr, su, biyokütle ve jeotermal gibi kaynaklar) ve yenilenebilir olmayan fosil enerji kaynakları (doğal gaz, kömür, nükleer ve petrol) tarafından üretilebilmektedir. Ancak fosil enerji kaynaklarının yapılarında hidrokarbon ve yüksek oranda karbon bulundurmaları atmosfere tehlikeli sera gazı (CO2) yayılımlarına yol açmakta bu durum ise çevre ve insan sağlığı için büyük risk oluşturmaktadır. Nitekim, Dünya Meteoroloji Örgütü'nün (DMÖ) "Küresel İklimin Durumu 2020 raporu", sera gazı konsantrasyonlarının, son on yılda emsalsiz artan küresel sıcaklığın sonucunda kara ve okyanus sıcaklarının yükselmesine, buzulların erimesine ve aşırı hava olaylarına (sel baskınları, yoğun kar yağışları, şiddetli fırtınalar ve kuraklıklar gibi) neden olduğunu belgelemektedir [1]. Uluslararası Enerji Ajansı (UEA) "Küresel Enerji İncelemesi: 2021'deki CO2 Emisyonları" raporuna göre Enerji yakıtlarına bağlı olarak kovid19 salgını nedeniyle düşen sera gazı yayılımı 2021'de bir önceki seneye göre %6'lık bir artışla 36.3 Gt (Gigaton)'a ulaşarak şimdiye kadar ki en yüksek yıllık seviyesine ulaştığını bildirmiştir (Şekil 1.1-1.2) [2]. Bu durum sera gazından kaynaklı felaketlerin devam edeceğinin göstergesidir.

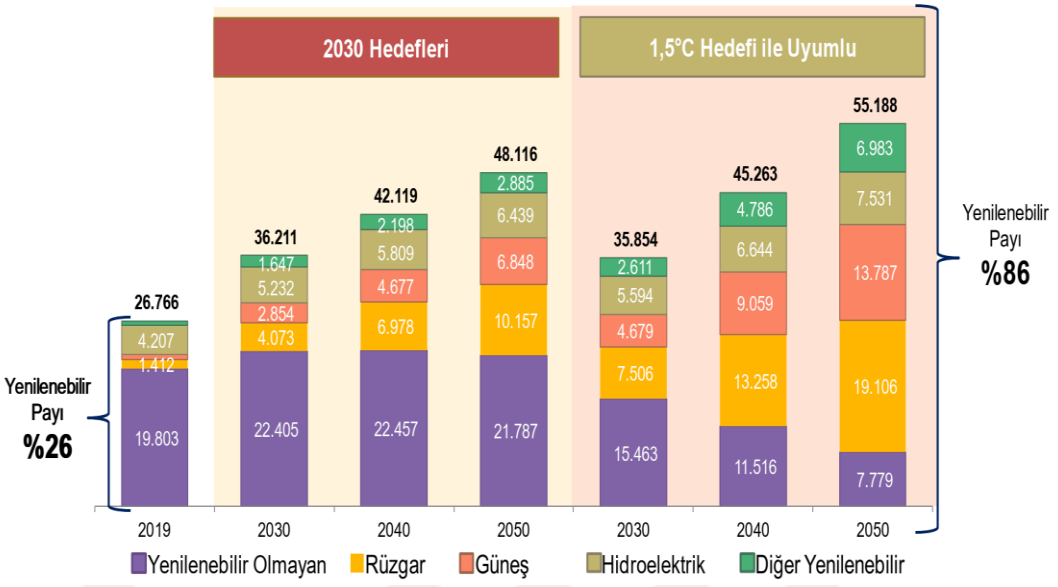


Şekil 1.1 Fosil Enerji kanyakları ve Endüstriden kaynaklı CO2 emisyonları, 1900-2021[2]

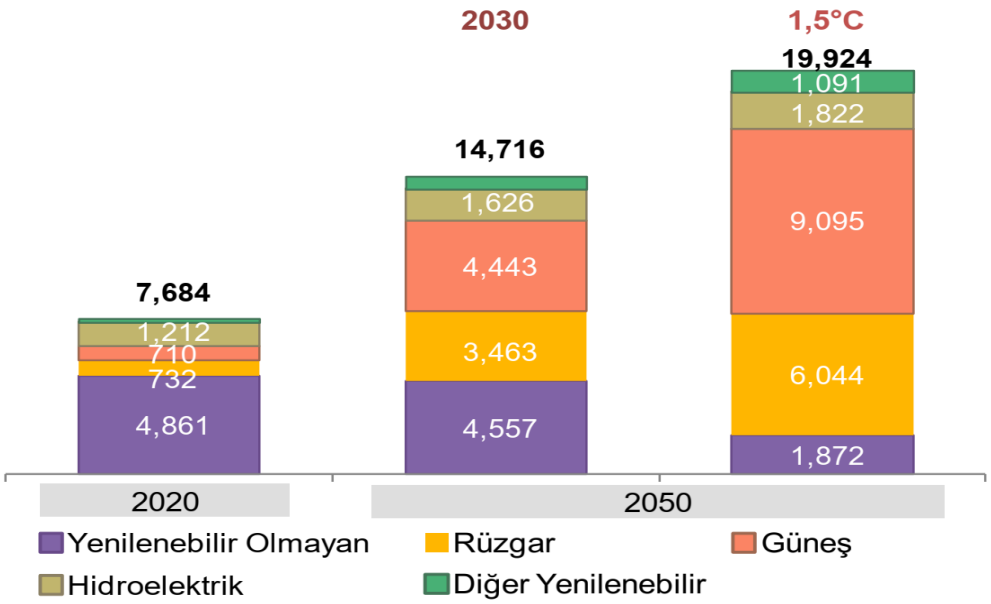


Şekil 1.2 2019 yılına göre fosil enerji kaynaklı CO2 emisyonlarındaki değişim, 2019-2021[2]

Ülkeler sera gazından kaynaklı iklim felaketlerinin önünü almak için $C0_2$ salınımını azaltmak için ortak bir çabada buluşmuşlardır. Paris iklim anlaşması bu çabanın bir ürünü olarak CO_2 salınımının neden olduğu sıcaklık artışını 2°C'nin altına (tercihen 1,5°C) düşürmek amacıyla 2015'te Paris'te COP21 adı altında gündeme getirilmiş ve 2016'da yürürlüğe girmiştir. Türkiye ise sera gazını azaltmak için ulusal katkı beyanını 2021 yılında BM (Birleşmiş Milletler)'e sunmuştur. Bu kapsamda Türkiye 2030 yılına kadar CO_2'yi %24 azaltmayı 2050 yılana kadar ise CO_2'yi sıfırlamayı hedeflemektedir [3]. Türkiye'nin de içerisinde bulunduğu G20 ülkeleri hedeflerini gerçekleştirebilmek için alınabilecek aksiyonlardan birini YEK yatırımlarının artırılması olarak belirlemişlerdir. Aşağıdaki şekillerde PwC Türkiye'nin Türkiye ve Dünyadaki Enerji Sektörü Raporundan alınan 2030 ile 2050 yıllarında beklenilen tahminler gösterilmektedir [3]. Şekil 1.3 Küresel Elektrik üretiminin Şekil 1.4 ise kurulu güç dağılımının 2030 hedefleri ile 1,5°C uyumlu enerji senaryosunu göstermektedir.

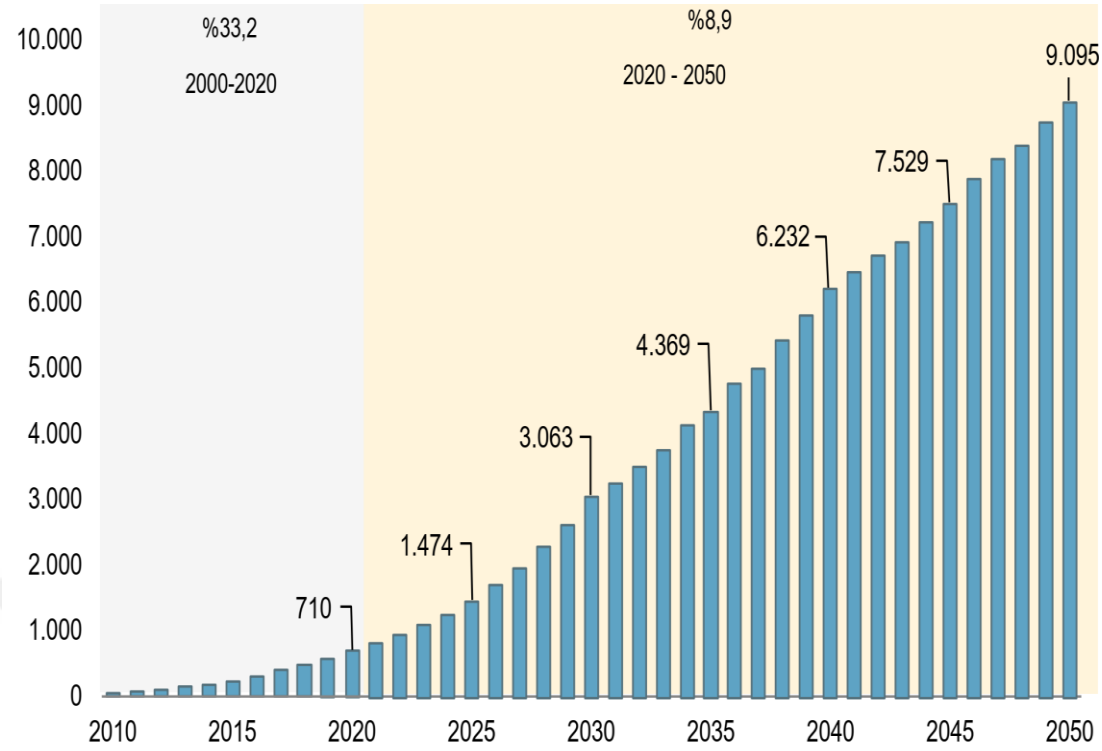


Şekil 1.3 Küresel Elektrik Üretimi (TWh,2019-2050) [3]



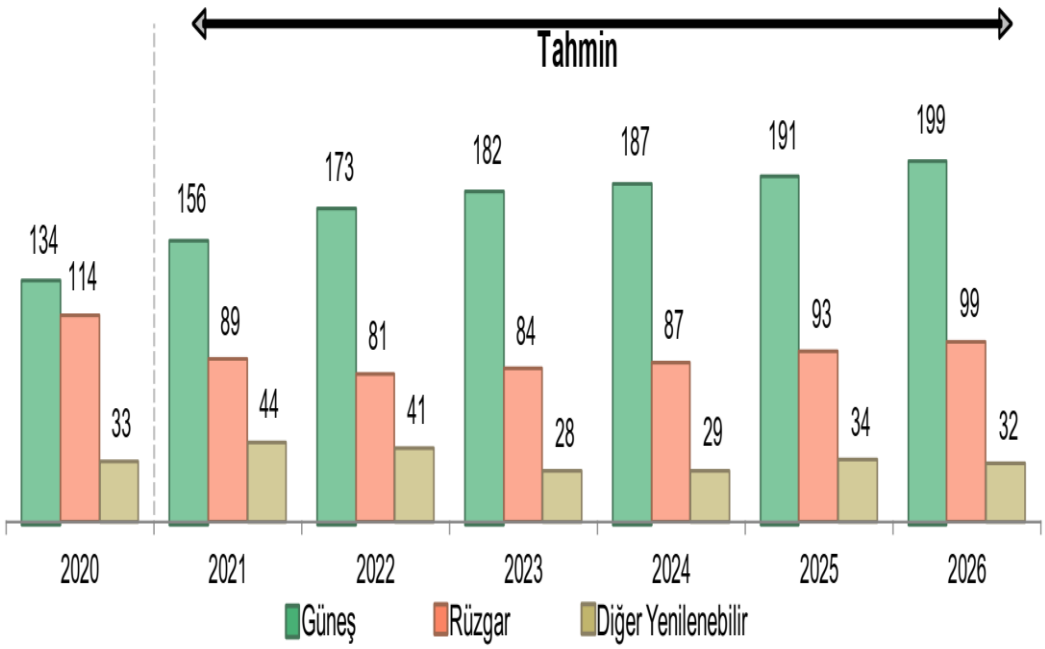
Şekil 1.4 Kurulu Güç Dağılımı (GW,2020-205) [3]

Yukardaki şekillerin (şekil 1.3 ve 4) senaryolarına göre 2050 yılında güneş ve rüzgâr enerjisi diğer YEK'lere göre daha yüksek paya sahip olacağı beklenmektedir [3].

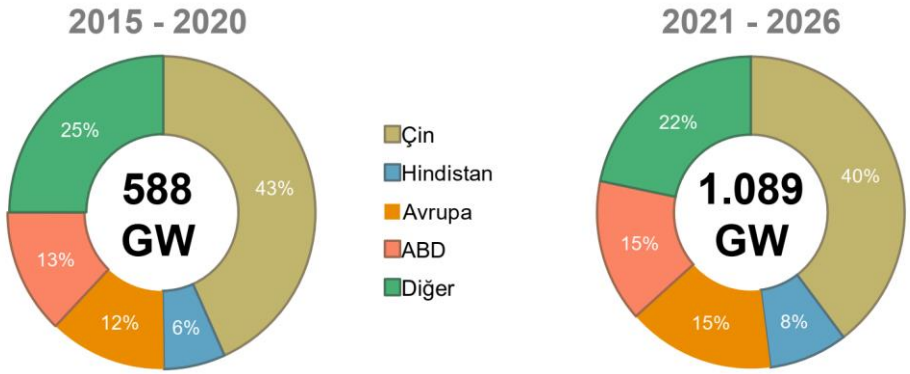


Şekil 1.5 Küresel Güner Enerji Kurulu Güç Gelişimi (GW, 2010-2050) [3]

2010- 2020 yılları arasında yaklaşık %33 büyüme gösteren küresel güneş enerjisinin 2030 yılına kadar toplam 3.063 GW seviyesine çıkması öngörülmektedir (şekil 1.5) [3].

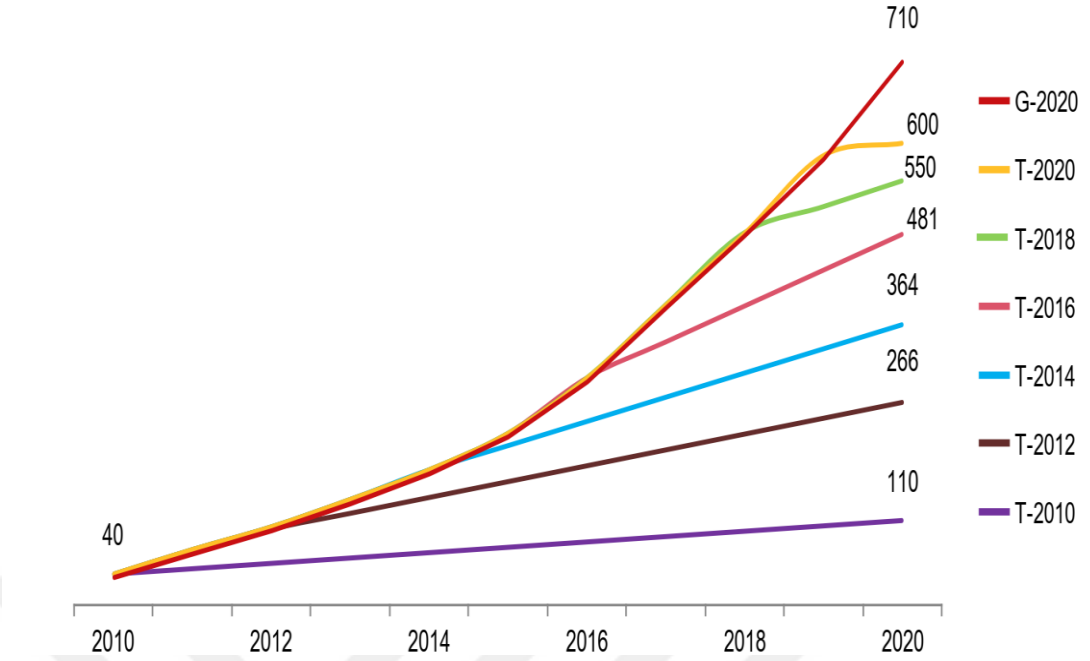


Şekil 1.6 Yıllık Yenilenebilir Enerji İlave Kurulu Güç Tahmini (GW, 2020-2026) [3]

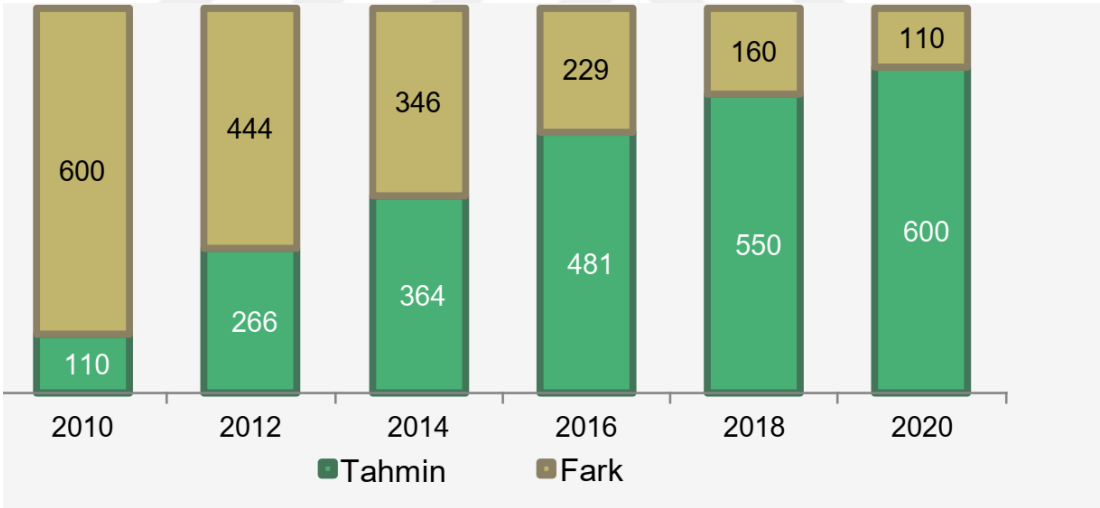


Şekil 1.7 Yıllık Güneş İlave Kurulu Güç (GW, 2015-2026) [3]

Şekil 1.6 ve 1.7'ye bakıldığında yenilenebilir ilave kurulu güçlerinin neredeyse %60'nı güneş enerjisi oluşturmaktadır. Diğer taraftan 2026 yılına kadar güneş kurulu gücünün 2020 yılana göre iki kat artacağı öngörülmektedir [3].



Şekil 1.8 Güneş Kurulu Güç Projeksiyonları (GW, 2010-2040)

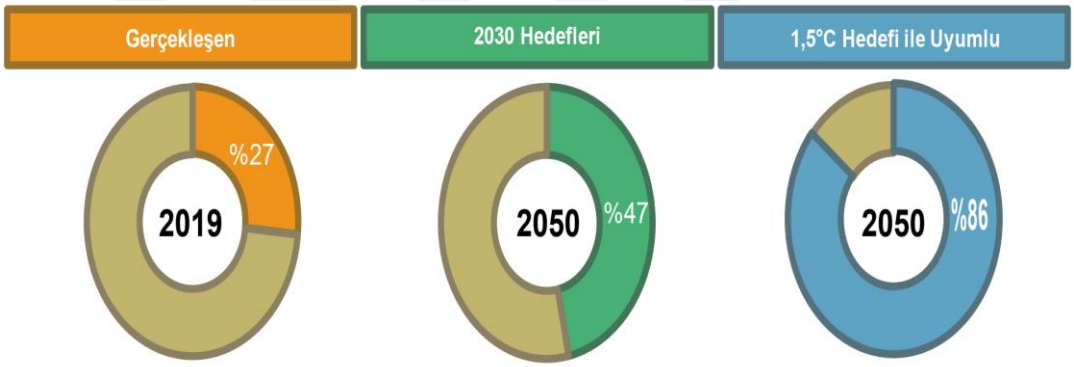


Şekil 1.9 2020 Yılı Güneş Kurulu Güç Projeksiyonları (TWh)

Şekil 1.8 ve 1.9'da UEA'nın 2010 yılı Dünya Enerji Görünümü raporunda belirtiği senaryoda 2020 yılı güneş enerji kurulu güç tahmini 600 GW civarlarındayken 2020 yılında gerçekleşen güneş enerjisi kurulu gücü 710 GW seviyesinde gerçekleşerek tahminin çok üzerinde kalmıştır [3].

1.1.1 Net sıfıra giden yolda güneş enerjisinin rolü

Net sıfıra giden hedefi gerçekleştirebilmek enerji dönüşümünü gerektirmektedir. Bütün ülkeler net sıfır hedefine ulaşabilmek için kendi önlem ve enerji politikalarını devreye koymaktadır. Sera gazı (CO_2) salınımını azaltmada elektrifikasyonun, daha verimli teknolojilerin ve YEK'lerin kullanımı önemli rol oynamaktadır. Özellikle karbon salınımından önemli bir paya sahip elektrik üretimi faaliyetlerinde karbon salınımının net sıfır seviyesine getirilmesi elzem olmaktadır. Yenilenebilir enerji kaynaklarından güneş enerjisinin özellikle giderek daha düşük maliyetli olması ve finansal getiride tercih edilmesi karbon salınımını azaltmada önemli ölçüde fayda sağlamaktadır. Ülkelerin net sıfır karbon seviyelerine gelebilmesi ve küresel ısınmayı 1,5 °C'sine sınırlandırabilmesi için toplam elektrik üretimi içerisinde yenilenebilir enerjinin payı %86 seviyesinde olması gerekmektedir [3].



Şekil 1.10 Elektrik Üretimi İçerisinde Yenilenebilir Kaynakların Payı (%, 2019-2050) [3]

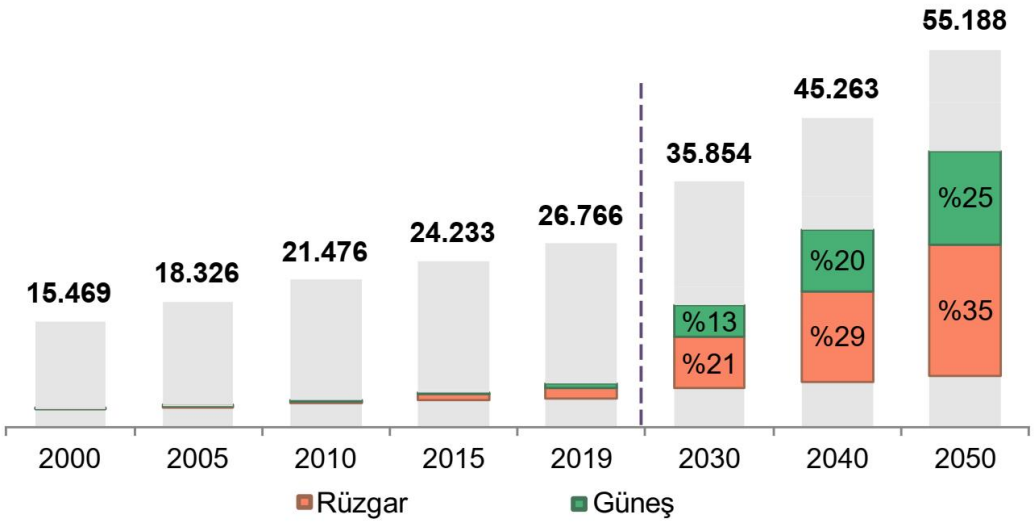
Fosil yakıtlardan özellikle kömür karbondioksit salımında en önemli paya sahiptir (şekil 1.2). Bu yüzden 1,5 °C sınırlaması hedefine ulaşılabilmesi için kömürden elektrik üretimine izin verilmemeli var olan tesisler de ya durdurulma ya da sınırlamalar getirilmelidir. Günümüzde küresel çapta 8.500 kömür termik santrali bulmaktadır ve 300'den fazla santralinde işlenmeye alınması planlanmaktadır. Bu durum kaçınılmaz olarak karbondioksit salınımı artıracaktır. Ancak bu santrallerin kapatılması ekonomik ve sosyal sorunları da beraberinde getirebilmektedir. Bu yüzden Bu santrallerin kapatılmasının ötesinde önemli finansal kaynak ve politikalara ihtiyaç vardır. Buna rağmen COP26 toplasında Çin ve Hindistan Kömür kullanımından aşamalı olarak çıkmaya beyan etmişlerdir. İsveç, Avusturalya ve Belçika ise kömür

kullanımından çıkışı tamamlamışladır. Aşağıdaki şekilde bazı ülkelerin taahhütte bulundukları kömürden çıkış tarihlerini göstermektedir.

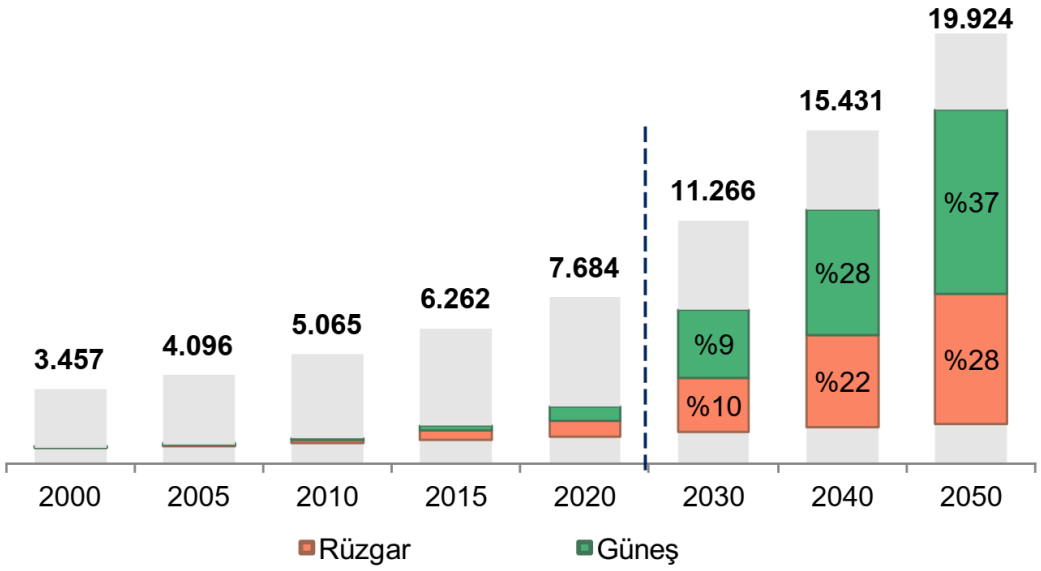


Şekil 1.11 Bazı ülkelerin taahhütte bulundukları kömürden çıkış tarihi

Kömürden çıkış elektrik piyasasındaki vergi ve karbon fiyatlandırması gibi yaptırımlarla hızlanabilecek böylelikle yenilenebilir enerji kaynaklarına hızla geçiş artacaktır. Bu duruma geçişin sinerjisi ise düşük maliyetli YEK teknolojisinden gelmektedir [3].



Şekil 1.12 Elektrik Üretimi İçerisinde Güneş Enerjisi Payı (TWh, %, 2000-2050) [3]



Şekil 1.13 Elektrik Kurulu Gücü İçerisinde Güneş Enerjisi Payı (GW, %, 2000-2050) [3]

Yapılan 2050 senaryolarına göre net sıfır karbon seviyesine ulaşılabilmesi için elektrik üretimin yenilenebilir enerji kaynaklarından elektrik üretimi payı %86 seviyesine ulaşması beklenmektedir. Rüzgâr enerjisiyle birlikte güneş enerjisinin payı ise %25 olması öngörülmektedir. Güneş enerjisinden kaynaklı karbondioksit salınımı diğer fosil yakıtlı kaynaklara göre %90 daha azdır. Bu çevre dostu özelliğiyle, Sürdürülebilirliği, düşük kurulum maliyetine sahip olması, teknolojik gelişime paralel olarak artan verimliliğiyle güneş enerjisi yenilenebilir enerji kaynakları arasında önümüzdeki yıllarda da öncülüğünü devam ettirmesi beklenmektedir.

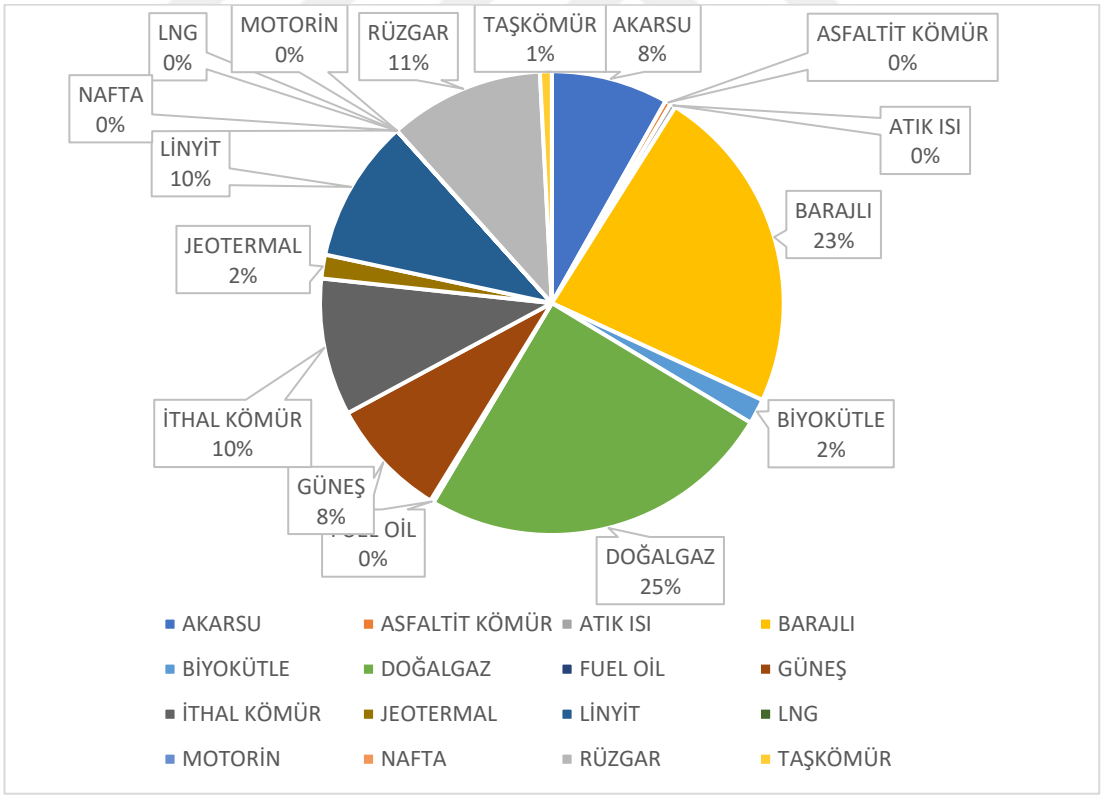
Dünya Enerji Konseyi (DEK) (World Energy Council)'nin 2021 Yenilenebilir Enerji Küresel Durum Raporuna göre, Yenilenebilir enerji kaynaklarına yapılan küresel yatırımlar 2020'de toplam 303,5 milyar ABD dolarına ulaşmıştır. Gelişmekte olan ülkeler ise yenilenebilir enerji yatırımında 153,4 milyar ABD dolarına ulaşmıştır. Yapılan bu yatırımların 148,6 milyar ABD doları güneş ve rüzgâr enerjisine yapılarak yenilenebilir enerji yatırımlarının neredeyse yarısını oluşturmuştur [4]. Uluslararası Enerji Ajansının (UEA) Dünya Enerji Yatırımı 2022'e göre, yenilenebilir enerji kaynakları, toplam enerji sektörü yatırımının %80'inden fazlasını oluşturduğunu, güneş enerjisi, bu yatırımların neredeyse yarısını oluşturduğunu ve 2022'de yenilenebilir enerji kaynaklarına yatırımın 1,4 trilyon ABD dolarını aşması

beklendiğini raporlamıştır [5]. Dahası DEK'e göre; elektrik enerjisi talebi 2060 yılına kadar iki katına çıkacağı ve elektrik enerjisi üretimi yenilenebilir kaynaklardan üretilmesi için uygun politikalar çıkarılarak önemli yatırımlar yapılacağı, yapılacak bu yatırımların da liderliğini güneş ve rüzgâr enerjilerinin yapacağı tahmin edilmektedir [4]. Güneş ve rüzgâr enerjisinde yaşanan bu olumlu yatırım artışları daha fazla enerji tesisinin kurulumunu artırmakta bu da bu tesislerin merkezi şebekelere entegrasyonunu gerektirmektedir. Nitekim, birçok hükümet, yenilenebilir enerji tesislerini merkezi şebekelere entegrasyonunu başarılı ve güvenli bir şekilde sağlamak için tasarlanmış enerji politikalarını uygulamaya koymaktadır. Bu politikalar, yenilenebilir enerji tesislerinin sisteme entegrasyonun yanı sıra, enerji depolama, güç sistemi kontrolü ve güç sistemi esnekliğini artırmaya odaklanır [4]. Nitekim T.C. Cumhurbaşkanlığı Strateji ve Bütçe Başkanlığının On birinci kalkınma planı p.491, yenilenebilir enerji kaynaklarından elektrik üretimi artırılacağını ve yenilenebilir enerji üretiminin şebekeye güvenli bir şekilde entegrasyonunun sağlanması amacıyla gerekli planlama ve yatırımlar gerçekleştirileceğini [6] bildirerek yenilenebilir enerji kaynaklarının güvenli şekilde şebekeye entegrasyonunu vurgulamıştır.

Yenilenebilir enerji kaynaklarında yaşanan artan yatırım trendlerine bağlı olarak güneş enerji kurulu gücünde dünya çapında önemli artış yaşanmıştır. Solar Power Europe'ın Güneş Enerjisi Küresel Piyasa Görünümü raporuna göre, dünya genelinde güneş enerjisi toplam kapasitesi, 2021 yılında gerçekleşen 168 GW'lık artış ile 940 GW'a seviyesine ulaşmıştır ve 2022 yılı için 200 GW'lık bir artış beklenmektedir [7]. Dünya genelinde yaşanan bu artışa paralel olarak Türkiye'de güneş enerji kurulu gücünde her geçen yıl artış yaşanmaktadır. TEiAŞ'ın 2021 Aralık raporuna göre güneş enerjisi 7.816 MW'lık kurulu güçle toplam kurulu gücün yüzde 8'lik payını oluşturmuştur. (tablo1.1 ve Şekil 1.14). TEİAŞ'ın Kurulu Güç Haziran 2022 raporuna göre ise 2021 yılına göre %8,5'lik artışla 8.479 MW seviyesine ulaşmıştır (Tablo 1.2). Raporlar, şekiller ve tablolardan anlaşılacağı üzere güneş enerjisine yapılacak yatırımların ve kurulu güçlerin her sene artarak devam edeceği açıktır.

Tablo 1.1 TEİAŞ-Yük Tevzi Dairesi Başkanlığı- Kurulu Güç Raporu-Aralık 2021

BİRİNCİL KAYNAKLARA GÖRE SANTRAL ADETLERİ VE KURULU GÜÇ		
BİRİNCİL KAYNAK	**SANTRAL ADEDİ**	**KURULU GÜÇ (MW)**
AKARSU	604	8.212,2
ASFALTİT KÖMÜR	1	405,0
ATIK ISI	94	390,9
BARAJLI	141	23.280,4
BİYOKÜTLE	380	1.644,5
DOĞALGAZ	352	25.573,6
FUEL OİL	9	251,9
GÜNEŞ	8.389	7.815,6
İTHAL KÖMÜR	15	8.993,8
JEOTERMAL	63	1.676,2
LİNYİT	47	10.119,9
LNG	1	2,0
MOTORİN	1	1,0
NAFTA	1	4,7
RÜZGAR	355	10.607,0
TAŞKÖMÜR	4	840,8
TOPLAM	10.457	99.819,6



Şekil 1.14 Aralık 2021 enerji kaynaklarının kurulu güç payları

Tablo 1.2 TEİAŞ-Yük Tevzi Dairesi Başkanlığı- Kurulu Güç Raporu-Haziran 2022

BİRİNCİL KAYNAKLARA GÖRE SANTRAL ADETLERİ VE KURULU GÜÇ		
BİRİNCİL KAYNAK	**SANTRAL ADEDİ**	**KURULU GÜÇ (MW)**
AKARSU	608	8.283,2
ASFALTİT KÖMÜR	1	405,0
ATIK ISI	94	390,9
BARAJLI	141	23.275,2
BİYOKÜTLE	381	1.781,0
DOĞALGAZ	347	25.285,0
FUEL OİL	9	251,9
GÜNEŞ	8.792	8.479,1
İTHAL KÖMÜR	16	9.713,8
JEOTERMAL	63	1.686,3
LİNYİT	47	10.142,5
LNG	1	2,0
MOTORİN	1	1,0
NAFTA	1	4,7
RÜZGAR	356	10.975,8
TAŞKÖMÜR	4	840,8
TOPLAM	10.862	101.518,3

Temelde güneş kaynağından elde edilen; termal sistem ve fotovoltaik sistem olmak üzere iki tür mevcut güneş enerjisi santralleri vardır. Güneş termal sistemlerinde, özel aynalar vasıtasıyla, güneş ışınları belli bir noktada yoğunlaştırılır, bu noktada bulunan sıvının (yağ veya su) sıcaklığı artar ve buhar üretir, üretilen bu buhar elektrik üretimi için buhar türbinlerinde kullanılır [8]. Buna karşılık, fotovoltaik sistemlerde, güneşten gelen ışınlar yarıiletken malzemenin üzerine düşerek elektronları uyarır, uyarılan elektronlarla iletken üzerinde yük birikir bu da panel uçlarında bir gerilim oluşmasına ve elektrik üretmesine neden olur. Fotovoltaik paneller genelde çatılarda veya açık alanlarda farklı ölçeklerde işlev görmektedirler. Bu paneller binalarda, araçlarda veya büyük diziler halinde tarlalarda kullanılmaktadır. Fotovoltaik panellerin artan kullanım alanlarıyla birlikte geçtiğimiz son on yılda güneş enerjisine yapılan yatırımların artmış, PV sistemler geniş çapta kurulmuş bu da tarife ücretlerin azalmasına bunun beraberinde ise PV sistemlere olan talebin artmasına neden olmuştur [9,10]. Ancak, PV santrallerin hava koşullarına bağımlılığı nedeniyle bu panellerde elektrik elde edimi ve dağıtımı zor olmaktadır. Gün boyunca güneş ışınımı yoğunluğunun istikrarsız doğası, PV güç üretiminde dalgalanmalara neden olmaktadır

[11]. PV güç üretimindeki beklenmedik bu dalgalanmalar, santrallerin ya aşırı elektrik üretmesine ya da hiç elektrik üretmemesinden dolayı şirketlerin ek elektrik satın almasına neden olabilmektedir. Her iki durumda da güneş enerjisi kullanmanın faydası ortadan kalkabilmektedir [12]. Sonuç olarak, PV gücünün yüksek entegrasyonu, yaşanan dalgalanmalar (aşırı elektrik üretimi veya elektrik üretilmemesi) nedeniyle mevcut şebeke sistemlerinin çalışması için birçok yeni sorunları da beraberinde getirmektedir [13]. Bu sorunlar, PV güç kaynağının meteorolojik koşullara duyarlılığını, yüksek kurulum maliyetlerini ve elektrik üretiminin kesintisini içerir [14]. Yaşanan bu sorunlara PV güç santrallerinden üretilen enerjinin depolanması bir çözüm olarak görülürken, sistemi önceden kontrol için mevcut enerjinin kesin bir tahmini gerekmektedir [11]. Bu duruma etkili bir çözüm ise PV güç çıkışı için doğru bir tahmin modeli bulmaktır.

1.2 Tezin Amacı ve Kapsamı

Bu tezin amacı makine öğrenimi ile PV çıkış gücünü kısa dönemli (10 dakika) olarak tahmin etmektir. Çıkış gücü tahmin etmek için literatürde birçok çalışma vardır. Bu çalışmada amaç literatürde kullanılan yöntemlerin iki temel dezavantajının üstesinde gelip tahmini daha kolay ve yüksek doğrulukta yapmaktır. Literatürdeki tahmin için kullanılan yöntemler dezavantajları, çok fazla giriş parametresinin olması (hem meteorolojik istasyondan hem de PV santrallerden gelen) ve kullanılan makine öğrenmelerinin geç öğrenme, aşırı öğrenme, yavaş olması gibi bazı sorunlarının üstesinden gelmeyi amaçlamaktadır. Giriş parametrelerini azaltmak için her PV santralde ulaşılabilen güneş ışınımı, güneşlenme süresi, rüzgâr hızı, ortam sıcaklığı, panel yüzey sıcaklığı, bulutluluk oranı, DC akım, gerilim ve bağıl nem 9 özellik(parametre) kullanılarak hava tipi modellenmiş ve 4 hava tipi modeli oluşturulmuştur. Bu hava tipi modelleri de kullanılarak GD-RVFLN yardımıyla PV çıkış gücü tahmini yapılmaya çalışılmıştır. RVFLN'nin seçilme amacı öğrenme süresinin birçok makine öğrenmesine oranla kısa olmasıdır. Ayrıca Klasik RVFLN'de çıkış ağırlıkları en küçük kareler (EK) kullanılarak hesaplanmaktadır. EK kullanılması hem ağı gürültülere karşı hassas hale getirmekte, öğrenme süresi yavaşlatmakta, aşırı ya da az öğrenmeye neden olmaktadır. Bunun üstesinden gelmek için gürbüz düzenlenmiş bir yaklaşım modeliyle ağın çıkış ağırlıkları hesaplanmış böylece ağın öğrenme süresi kısaltılarak ağ aşırı, az öğrenme gibi sorunlarında üstesinden

gelinmiştir. Ayrıca yöntemin doğruluğunu test etmek için istatistiksel belirteçlere ek olarak 10 farklı makine öğrenme yöntemi Bayesian Ridge Regressor (BRR), Linear Regressor (LR), Gaussian Process Regressor (GPR), Support Vector Machine (SVM), Extreme Learning Machine (ELM), Yapay Sinir Ağı (YSA), Gradient Boosting Regressor (GBR), Random Forest Regressor (RFR), Lasso Regressor (LAR) ve Ridge Regressor (RR) yöntemleri) ile karşılaştırılarak etkinliği test edilmesi amaçlanmıştır.

1.3 Tezin Katkısı

Bu çalışmanın katkıları şu şekilde özetlenebilir:

Katkı 1: Literatürde PV çıkış gücü tahminlemesi yapan birçok model bulunmaktadır. Ancak girdi parametrelerinin fazla sayıda olması, verilerin yüksekli boyutlu olması ve karmaşıklığından kaynaklı modellerin yavaş sonuç vermesi veya aşırı örenme durumlarıyla karşı karşıya kalınmaktadır. Bu sorunun üstesinden gelmek için öğrenme süresi diğer modellere göre daha kısa olan GD-RVFLN modeli PV çıkış gücü tahminlemesinde kullanılmıştır. Böylelikle, hava tipi sınıflandırmasına dayalı olarak GD-RVFLN modelinin geçmiş verilere dayalı olarak PV çıkış gücünü tahmin etmede kullanılabileceği gösterilmiştir.

Katkı 2: Klasik RVFLN modeli ayarlama ihtiyacı duymadan rastgele gizli parametrelerini atama yeteneğine sahiptir. Bu model diğer modellere kıyasla daha iyi performans doğruluğu göstermekte ve eğitim süresini oldukça kısaltmaktadır. Bu tezde önerilen model klasik RVFLN modelinin sağlamlaştırılıp hali olan GD-RVFLN modeli verileri önemli ölçüde iyileştirdiği için diğer modellere kıyasla daha yüksek performans doğruluğuna ve eğitim süresi kısalığına sahip olduğu gösterilmiştir.

Katkı 3: Önerilen GD-RVFLN yöntemi yalnızca performans doğruluğunu iyileştirmekle kalamamış ayrıca aykırı değerlere karşı sağlamlığını da artırmıştır.

Katkı 4: Bu tezde bir gün öncesinden 10 dakikalık aralıklarla PV güç çıkışını tahmin etmek için hava tipi sınıflandırmasına dayalı olarak 10 farklı makine öğrenimi modelleri kullanıldı. Son olarak, bu modelleri analiz için Dicle üniversitesi PV güç santralinden alınan büyük bir veri kümesi kullanıldı. Analiz, GD-RVFLN modelinin tahmin doğruluğunu iyileştirebileceğini göstermiş ve bu modelin OMYH ve OKH

istatistiklerine göre diğer 10 modelden daha iyi performans gösterdiğini ortaya koymuştur.

1.4 Tezin Yapısı

Bu tezin yapısı sırasıyla şu şekilde sıralanmıştır: Bölüm 2'de literatür taramasıyla PV Güç tahminlemesi için kullanılan yaklaşımlar ve yapılan çalışmalara yer verilmiştir. Bölüm 3, bölgenin konumu, iklimi hakkında ve data seti hakkında bilgi vermektedir. Önerilen yöntem ve karşılaştırma yöntemleri açıklanmıştır. Bölüm 4'te tahmin sonuçları verilip değerlendirilmiştir. Bölüm 5'te çalışma sonuca bağlanmıştır.

Bölüm 2: Literatürdeki PV tahminlemesi incelemesi
- PV tahminlemesi için yapılan tahmin yaklaşımları incelenmiştir.
- Tahminleme için yapılan tahmin ufukları incelenmiştir.
- PV tahminlemesi için hangi girdilerin kullanılması gerektiği araştırılmıştır.
- Literatürdeki PV tahminleme için kullanılan modeller araştırılmıştır.

Bölüm 3: Sistem Açıklaması yapılmış ve önerilen yöntem açıklanmıştır.
- PV santrali, istasyonu ve data seti hakkında bilgi verilmiştir.
- KKA yöntemi, Orijinal RVFLN yöntemi ile GD-RVFLN Yöntemlerinin detayları verilmiştir.
- Önerilen model için karşılaştırma modelleri açıklanmıştır.

Bölüm 4: Sonuç ve Bulgular
-Tahminleme sonuçları elde edilip sonuçlar karşılaştırılarak değerlendirilmiştir.

Bölüm 5: Sonuç
- Sonuçlar özetlenmiştir.

2. KAYNAK ÖZETLERİ

Fosil enerji kaynaklarının gittikçe tükenmesi ve atmosfere saldığı zararlı gazlar nedeniyle bu enerji kaynaklarına sınırlandırmalar getirilmiş, sürdürülebilirliği ve çevreye olan zararsız etkisi nedeniyle Yenilenebilir enerji kaynaklarına dünya çapında bir yönelim söz konusu olmuştur. Yenilenebilir enerji kaynaklarından, özellikle rüzgâr ve fotovoltaik santrallerin kurulumu son on yılda katlanarak artış göstermiştir. Ancak bu santrallerin hava koşullarına bağımlılığı enerji üretiminde dalgalanmalara neden olduğu için bu santrallerden enerji elde edilmesi ve dağıtımı zor olmaktadır. Ve bu durum bu santrallerin elektrik şebeklerine entegrasyonunu zorlaştırmaktadır. Sonuç olarak, bu santrallerden üretilen gücün tahmini, şebekenin güvenilirliği, emniyeti ve istikrarı için esastır.

PV güç tahminlemesi üç faktöre bağlıdır; bunlar, tahmin vadesi, girdi ve tahmin modelidir.

2.1 Tahmin Vadesi

Çıktı tahmini için yapılan zaman aralıklarını ifade eder. Genel olarak kısa vadeli, orta vadeli ve uzun vadeli olmak üç tür tahmin ufku vardır. Ancak bazı araştırmacılar akıllı veya mikro şebekeler için karar verme sürecinin gereksinimlerini göz önünde bulundurarak "çok kısa vadeli veya ultra kısa vadeli tahmin ufku" olarak adlandırılan "dördüncü" bir kategori eklemişlerdir [15].

2.1.1 Çok kısa vadeli veya ultra kısa vadeli tahmin

Saniyeden 30 dakikaya kadar olan tahmin süresidir. Bu tür tahminler, elektrik pazarlaması veya fiyatlandırması, gerçek zamanlı elektrik dağıtımının izlenmesi ve PV depolama kontrolü için kullanılmaktadır [16].

2.1.2 Kısa vadeli tahmin

Yapılan araştırmalara göre bazı kaynaklar bu tahmin süresini saniyelik, dakikalık veya saatlik olarak ele almıştır. Ancak genel olarak bu tahmin süresi bir ila birkaç saati, bir günü veya 1 haftaya kadar olan zaman dilimini içermektedir. Ekonomik yük dağıtımı,

güç sistemi operasyonları ve Yenilenebilir enerji entegre güç yönetim sistemlerinin kontrolü gibi elektrik piyasalarında kullanılabilmektedir [17].

2.1.3 Orta vadeli tahmin

Bir gün, bir hafta ve bir aya kadar olan zaman dilimi bu kategoride değerlendirilir. Geleneksel(elektro-mekanik) veya güneş enerjisi entegre güç sistemlerinin bakım planlaması için gereklidir [16].

2.1.4 Uzun vadeli tahmin

Bir aydan bir yıla kadar olan dönemler uzun vadeli tahmin olarak sınıflandırılır.
Bu tür bir tahmin ufku, uzun vadeli enerji üretimi, iletimi, dağıtımı ve güneş enerjisi oranlaması ve ayrıca mevsimsel eğilimleri hesaba katmada kullanılabilmektedir [18].

2.2 Tahmin Modeli Girdileri

PV sistemleri için girdiler çoğunlukla meteorolojik parametreler kullanılmaktadır. PV sistemleri için girdiler: güneş radyasyonu, sıcaklık, modül sıcaklığı, rüzgâr hızı, nem, barometrik basınç ve aerosol değişiklikleri gibi parametrelerdir. Ancak bu parametreler iklim koşullarına bağımlı olmaları nedeniyle PV çıkış gücü ile aralarındaki korelasyon hava koşullarına bağlı olarak negatif veya pozitif yönde değişmektedir [16].

Bu çalışmada tahmin vadesi olarak kısa vadeli tahmin ufku seçilmiştir.

2.3 PV Çıkış Gücü Tahmin Yaklaşımları

PV güç çıkışı için doğrudan ve dolaylı olmak üzere iki ana tahmin yaklaşımı vardır [19,25,29,50]. Doğrudan tahmin yöntemleri [39-47], PV güç çıkışını tahmin etmek için genellikle meteorolojik ve PV çıkış gücü gibi geçmiş verileri kullanır. Bu yöntem için kullanılan teknikler [48-56], YSA, hibrit YSA, çok katmanlı algılayıcı sinir ağı (MLPNN), tek örtülü katmanlı ileri beslemeli sinir ağı (single shrouded layer feed-forward neural network) (SLFN), tekrarlayan sinir ağı (RNN), ileri beslemeli sinir ağı (FFNN), Geri Beslemeli sinir ağıdır (FBNN), aşırı öğrenme makine (ELM) ve destek vektör regresyonu (SVR) gibi yöntemlerdir. Doğrudan yöntemlerin dolaylı yöntemlere kıyasla gün öncesi PV güç çıkışı tahmini açısından daha iyi sonuç verdiği

kanıtlanmıştır [62]. Dolaylı tahmin yöntemleri [19-22,24] güneş radyasyonu, ortam sıcaklığı gibi meteorolojik parametreleri ve çevresel parametreleri matematiksel modeller kullanarak tahmin eder. Dolaylı tahmin yöntemlerindeki sonraki adım eşdeğer diyot modeli, basit verimlilik modeli ve Sandia modeli gibi modelleri kullanarak PV çıkış gücü tahmin etmektir. Dolaylı tahmin için kullanılan teknikler [32-38] Sayısal Hava Tahmini (SHT), uydu gökyüzü görüntüsü, hibrit yapay sinir ağı ve istatiksel tabanlı yöntemlerdir.

Yukarıda isimleri verilen modeller PV güç çıkışı tahminlemesinde faydalı olsa da her modelin kendi zorlukları vardır. Değinilen bu modellerden SVR modeli [26-28, 30] hem büyük hesaplama sürecine ihtiyaç duyar hem de büyük veri kullanımı durumlarına yanıt vermez. Öte yandan, YSA modeli [57-61], iyi bir performans göstermesi için kullanıcıların ağ topolojisini ve parametreleri belirlemesine ihtiyaç duyar. Kısacası tahminleme için kullanılan modeller doğru kullanılmadığı takdirde iyi sonuçlar vermeyebilir. Bu yüzden tahminleme için iyi bir model seçimi gerekmektedir. Literatürde PV çıkış gücü tahminlemesi için oldukça fazla sayıda çalışma vardır. Bu kapsamda kısa vadeli PV çıkış gücü tahmini için yapılan bilimsel çalışmaların bir kısmı aşağıda verilmiştir.

Zhou ve arkadaşları, PV çıkış gücünü tahmin etmek için aşırı öğrenme makinesi (ELM), genetik algoritma (GA) ve özelleştirilmiş Benzer Gün Analizi (BGA) tabanlı bir hibrit model (BGA-GA-ELM) geliştirilmiştir. BGA için beş meteorolojik girdiye dayalı olarak farklı günler arasındaki benzerliği ölçmek için Pearson Korelasyon katsayısı kullanılmış. Yüksek korelasyona sahip parametreler ELM için eğitim seti olarak seçilmiştir. Daha sonra tahmin doğruluğunu iyileştirmek için ELM' de gizli önyargı ve girdi ağırlığının optimal değerleri GA tarafından belirlenmiştir. Önerilen tahmin modelinin performansı, regresyon katsayısı (R^2), ortalama mutlak hata (OMH) ve normalleştirilmiş ortalama karekök hata (nOKH) ile değerlendirilmiştir. Sonuçlar, BGA-GA-ELM modelinin gün öncesi PV çıkış gücü tahmininde daha yüksek doğruluk ve kararlılığa sahip olduğunu göstermiştir [62].

Pan ve arkadaşları, ultra kısa vadeli PV çıkış gücünü tahmini için support vektör makinesi (SVM) ile karınca kolonisi optimizasyonu (KKO) modelini önermişlerdir.

İşlenen verilere dayalı olarak SVM modeli oluşturulmuş daha sonra parametreler KKO kullanarak iyileştirilmiştir. Önerilen model R^2 değeri 0,997 çıkarak model yüksek doğruluk göstermiştir [63].

VanDeventer ve arkadaşları kısa vadeli PV güç tahmini için Genetik algoritmaya dayalı bir support vektör makinesi (GASVM) modeli geliştirdiler. GASVM modelinde, başlangıçta SVM sınıflandırıcı olarak geçmiş hava durumu verileri sınıflandırılmış, daha sonra genel uyum tekniği kullanılarak genetik algoritma (GA) tarafından optimize edilmiştir. Önerilen GASVM modelinin tahmin doğruluğu, OKH ve OMYH temelinde değerlendirilmiştir. Deneysel sonuçlar, önerilen GASVM modelinin, OKH değerinde yaklaşık 669.624W ve OMYH hatasının%98,76 lık farkla geleneksel SVM modelinden daha iyi performans gösterdiğini göstermiştir [64].

Massaoudi ve arkadaşları Bayesian Ridge Regresyon (BRR) modelini, Sürekli Dalgacık Dönüşümünü (SDD) ve Gradient Boosting kategorik özelliklerle (Catboost) birleştiren bir BBR-SDD-Catboost hibrit modelini önermişlerdir. Bu modelde, en alakalı özellikleri seçmek için bir Bayesian Ridge Regresyon modeli kullanır. Ardından, SSD ayrıştırma tekniği seçilen özellikleri bir zaman-frekans alanına dönüştürür. Catboost modeli, bir gün öncesi için tahmin çıktısını üretir. Son olarak sonuçlar, ters SSD kullanılarak çıkarılır. Hibrit model, OKH=3.81 ile kısa vadeli 24 saat ilerisi tahmininde doğru sonuçlar elde etmiştir [65].

Atique ve arkadaşları, PV çıkış gücü tahmini için zaman serisi olarak iyi bilinen klasik yöntem otomatik regresif tümleşik hareketli ortalamanın (ARIMA) mevsimsel modeli (SARIMA) modelini önermiştir. Daha sonra bu modelin performansını diğer iki popüler makine öğrenme yöntemi olan destek vektör makinesi (SVM) ve yapay sinir ağı (YSA) ile karşılaştırmıştır. Sonuç SVM modelinin YSA ve SARIMA'ya göre yüksek performansa sahip olduğunu göstermiştir [66].

Shedbalkar ve More lineer, ridge ve Bayesian regresyon modelleri ile güneş enerjisi üretim tahmininin deneysel sonuçlarını karşılaştırmışlarıdır. En iyi performans gösteren Bayes modeli, toplu işleme yaklaşımında 15 dakikalık zaman aralığı verileri

için ortalama kare hata (0,61-0,82) açısından Bayes modelinin daha iyi performans gösterdiği bulunmuştur [67].

Gutiérrez ve arkadaşları fotovoltaik güç üretimini tahmin etmek için Makine Öğrenimi ve Yapay Zeka yöntemleriyle uyumlu tekniklerden dört tahmin modeli önermiştir: K-En Yakın Komşular (KNN), Doğrusal Regresyon (LR), Yapay Sinir Ağları (ANN) ve Destek Vektör Makineleri (SVM). Elde edilen sonuçlar, dört yöntemin yeterli fotovoltaik enerji üretimi tahminleri ürettiğini ancak OKH ve OMH'ye göre en iyi tahmin YSA tahmin modeline ait olduğunu göstermiştir [68].

Afzal ve arkadaşları, termal faktörlere dayalı enerji tesisin üretimini tahmin etmek için Ridge, Lineer regresör (LR) ve destek vektör regresörü(SVR) algoritmalarını kullanmışlardır. Kombine çevrim santralini enerji çıktı verileri egzoz vakumu, ortam sıcaklığı, bağıl nem ve ortam basıncı gibi termal girdi değişkenlerinin bir faktörü olarak toplanmıştır. İlk olarak, Ridge algoritması tabanlı modelleme ayrıntılı olarak gerçekleştirilmiş ve ardından SVR (LR) olarak adlandırılan SVR tabanlı LR, SVR tabanlı radyal tabanlı fonksiyon—SVR (RBF) ve SVR tabanlı polinom regresyon SVR (Poly.) algoritmalar uygulanmıştır. Enerji çıkış verilerinin modellenmesinden, diğer algoritmalara kıyasla çok yakın tahminler sağlamada SVR'nin (RBF) en uygun olduğu görülmüştür. Elde edilen SVR (RBF) eğitimi R^2 =0,98 iken diğer tüm eğitimler 0,9-0,92 olmuştur [69].

Teo ve arkadaşları, Extreme Learning Machine eğitim algoritması ile Yapay Sinir Ağı kullanarak fotovoltaik gücü tahmin etmişlerdir. Önerdikleri model fotovoltaik gücü yüksek doğrulukla tahmin ettiğini göstermiştir [70].

Jang ve arkadaşları çeşitli uydu görüntülerine dayalı bir güneş enerjisi tahmin modeli ve bir destek vektör makinesi (SVM) öğrenme şeması önermişlerdir. Bulutların hareket vektörleri, atmosferik hareket vektörlerinin (AHV'ler) uydu görüntüleri kullanılarak tahmin edilmiştir. 4 yıllık geçmiş uydu görüntülerini analiz edilerek SVM öğrenimi için çok sayıda giriş ve çıkış veri setini yapılandırmak için kullanılmıştır Önerilen SVM tabanlı modeli, geleneksel zaman serisi modeli ve bir yapay sinir ağı (YSA) modeli tahmin doğruluğu açısından karşılaştırılmıştır. Sonuç,karşılaştırlan

modellere göre önerilen SVM tabanlı tahmin modeli en yüksek tahmin doğruluğunu göstermiştir [71].

Khalyasmaa ve arkadaşları kısa vadeli gün öncesi PV çıkış gücü tahmini için Random Forest Regressor modelini önermişlerdir. Önerilen modelin Ortalama tahmin doğruluğu yaklaşık %93 olduğu görülmüştür [72].

Mishra ve arkadaşları, PV çıkış gücünü tahmin etmek için 5 dakikalık ve 1 saatlik zaman aralığı için çevrimiçi bir veri setini kullanarak sağlam bir Genişletilmiş Aşırı Öğrenme Makinesi (EELM) modelini önermiştir. Daha sonra bu modelin performans üstünlüğünü kanıtlamak için önerilen modelin OKH ile OMH değerleri ELM ve Functional Link Neural Network (FLNN)'in OKH ile OMH değerleri ile karşılaştırılmıştır. Sonuç önerilen model üstün performansla diğer iki modele kıyasla daha iyi sonuç göstermiştir [73].

Khalyasmaa ve arkadaşları, meteorolojik verilere dayalı fotovoltaik enerji santrallerinin üretim tahmin için Random Forest regresörü, Gradient Boosting Regressor, Lineer Regresyon ve Karar Ağaçları regresyonu dahil olmak üzere farklı makine öğrenimi algoritmalarının uzaktan elde edilen verilere uygulanmasını incelemişledir. Hiper parametre optimizasyonu ve algoritmaların ardışık düzeni ile ilgili hesaplama deneylerine dayanarak, PV santral enerji çıktısı tahmin sisteminin optimal yapısı ve ayarları, algoritmaların her biri için uygulama kısıtlamaları ile birlikte belirlenip uygulanmıştır. Bu hesaplamalar sonucu performans iyileştirme Lineer Regresyon için %55'ten %94'e ve karar ağaçları için %88'den %91'e, topluluk algoritmalarının doğruluğu ise, Random Forest regresörü, Gradient Boosting Regressor gibi, önemli ölçüde değişmediği görülmüştür [74].

Theocharides ve arkadaşları, PV sistemlerinin güç çıkışını tahmin etmek için farklı makine öğrenme modellerinin performansını değerlendirmişlerdir. Bunun için YSA, support vektör regresyonu (SVR) ve regresyon ağaçları (RT) dahil olmak üzere çeşitli yöntemler araştırmışlardır. Her modelin çıkış gücü tahmin performansı, bir yıllık bir süre boyunca elde edilen gerçek PV üretim veri setleri üzerinde test edilmiş ve mevcut bir kalıcılık modeliyle (KM) karşılaştırılmıştır. Farklı optimal olarak tasarlanmış

modeller arasındaki karşılaştırmalı analiz, ANN'nin diğer modellerden daha iyi performans gösterdiğini, sırasıyla OMYH= %0,6 ve nOKH= %0,76'lık değer elde ettiğini göstermiştir. Son olarak, beceri puanı (SS) %86 ile %92 arasında değiştiğinden, tüm modeller KM'ye göre daha yüksek göreli iyileştirme göstermiştir [75].

Erduman, PV çıkış gücünü tahmin etmek için YSA tabanlı bir model önermiştir. Sıcaklık, rüzgâr hızı, basınç ve nem parametrelerini sinir ağı öğrenme modeline uygulayarak en yaygın olarak kullanılan monokristal, polikristal ve ince film güneş panellerinin çıkış gücünü kısa vadeli olarak tahmin etmiştir. Sonuç, üretim değerlerinin %97 doğrulukta olduğunu göstermiştir [76].

Behera ve Nayak , kısa vadeli PV güç tahmini için ampirik mod ayrıştırma (EMD) tekniği, sinüs kosinüs algoritması (SCA) ve aşırı öğrenme makinesi (ELM) tekniğini birleştirerek oluşturulan 3 aşamalı bir yaklaşım önermişlerdir. Eğitim ve tahmin aşaması için 15dk, 30dk ve 60dk olmak üzere üç farklı zaman aralığı veri serisi seçilmiştir. Sonuçlar, önerilen EMD-SCA-ELM modelinin kısa vadeli PV güç tahmin problemlerini ele alma konusunda yüksek performansa sahip olduğunu göstermektedir. Özellikle, 15dk veri yaklaşımına sahip EMD-SCA-ELM, çoğu durumda en iyi performansa sahip olduğunu göstermiştir (OMYH=%1,88) [77].

Chahboun ve Maaroufı, Fotovoltaik gücün saatlik tahmini için birkaç güncel makine öğrenme algoritmasının performansı karşılaştırmışlardır. Kullanılan yöntemler, bayesian regularized sinir ağları, k-nearest neighbors, gradient boosting, random forest, support vector regression, ve multivariate adaptive regression olmuştur. Daha sonra bu yöntemler R^2, OKH ve OMH ile değerlendirilmiştir. Sonuçlar, bayesian regularized sinir ağlarının en iyi tahmin doğruluğuna R^2=99,99% sahip olduğunu göstermiştir [78].

Obiora ve arkadaşarı saatlik güneş ışınımını iki ardışık yılın tarihsel meteorolojik verilerini kullanarak tahmin etmek için YSA, SVR ve Random Forest Regression (RFR) olmak üzere üç makine öğrenme tekniğini kullanıp karşılaştırmıştır. Sonuçlar,

%7.2'lik nOKH ile Suppour Vektör Regresyonunun (SVR) en iyi genel performansa sahip olduğunu bunu sırasıyla YSA ve RFR takip ettiğini göstermiştir [79].

Bu çalışmada önerilen yöntem, bir tek örtülü katmanlı ileri beslemeli sinir ağı (single shrouded layer feed-forward neural network) (SLFN) türü olan Rastgele Vektör Fonksiyonel Bağlantı(link) Ağ (Network) olarak adlandıran RVFLN'nin gerekli algoritmalara geliştirmiş hali olan Robust Regularized Random Vector Functional Link Network (GD-RVFLN) modelidir. Yapılan diğer literatür araştırmalarında RVFLN modelini kullanarak PV güç tahmini yapan iki çalışmaya rastlanılmıştır. Arpit ve Tripathi, PV gücünü tahmin etmek için tek örtülü katmanlı ileri beslemeli sinir ağı (single shrouded layer feed-forward neural network) (SLFN), rastgele ağırlıklı tek örtülü ileri beslemeli sinir ağı (random weight single shrouded layer feed-forward neural network) (RWSLFN) ve rastgele vektör fonksiyonel bağlantı ağı (random vector functional link) (RVFL) olmak üzere üç modeli karşılaştırmıştır. Bu karşılaştırma sonucunda RVFL' nin diğer RWSLFN' lerden ve SLFN' lerden daha iyi performans gösterdiği tespit edilmiştir [80].

Mishra ve arkadaşları güneş ışınımı, PV çıkış gücünü ve rüzgâr hızının tahmin etmek için Gürbüz Düzenlileştirilmiş Rastgele Vektör Fonksiyonel bağlantı (GD-RVFL) ağı olarak bilinen ultra kısa bir Tahmin modeli önermişlerdir. Önerilen metodolojinin doğruluğunu elde etmek için test, farklı atmosfer koşullarında çeşitli zaman aralıklarında gerçekleştirilmiştir. Önerilen yönteminin diğer modellere (yani Rastgele vektör fonksiyonel bağlantı (RVFL) ve Robust Extreme learning machine (R-ELM) vb.) kıyasla çok üstün performans gösterdiği görülmüştür [81].

Bu çalışmanın amacı, literatürde makine öğrenimi modellerinde yaygın olan aşırı öğrenme ve yavaş öğrenme dezavantajlarının üstesinden gelerek daha hızlı öğrenen ve yüksek doğrulukta performans gösteren GD-RVFL ağı modelini kısa vadeli PV çıkış gücünü tahmin etmede kullanmak ve bu kapsamda önerilen modeli, 10 farklı makine öğrenimi yöntemi olan BRR, LR, GPR, SVM, ELM, YSA, GBR, RFR, LAR ve RR yöntemleri ile karşılaştırılarak modellerinin performansını değerlendirmektir.

3. MALZEME VE YÖNTEM

Çalışmada makine öğrenimi modellerinin oluşturulup uygulanmasında MATLAB programı kullanılmıştır. Bu çalışmada MATLAB programının seçilmesinin sebebi programın, hem kodlarının diğer yazılım programlarına göre nispeten kolay olması hem matris ve vektörlerle çalışmak için uygun bir ortam sunması hem de yoğun matematik gerektiren işlemlere imkân tanımasıdır.

3.1 PV Santral

Bu çalışmada, Diyarbakır ili Dicle Üniversitesi kampüsünde bulunan bir PV elektrik santralinden [82,83,84] ve meteorolojik istasyondan [85,86,87, 88] Mayıs 2019-Nisan 2022 tarihlerinde tarihsel veriler elde edilmiştir. Diyarbakır ili sert bir kara iklimine sahiptir ve güneş radyasyon değerleri ile güneşlenme süreleri yüksek olduğundan Güneş enerjisi potansiyeli açısından zengindir. Ortalama güneşlenme süresi günlük ortalama 7,94 saat/Gün'dür ve yıllık ortalama yağış yaklaşık 495 milimetredir. Yaz aylarında (10 Haziran-17 Eylül arası) ortalama en yüksek sıcaklığı 35 ○C'nin üzerindedir. Gök yüzünün açık olduğu tarihler 18 Mayıs- 10 Ekim olup 4,7 ay boyuncadır, bulutlu gökyüzü 10 Ekim- 18 Mayıs tarihleri olup 7,3 ay boyuncadır.

Dicle Üniversitesinde kurulu olan PV Santrali 40016'E boylam, 37054'N enlem koordinatlarında bulunmaktadır. PV santralinin gücü 250 kWp'dir. Bu santralin ortam hava sıcaklığı ortalaması yıl boyunca 31,1 °C- 1,7 °C arasında değişiklik göstermektedir. PV Santralinde kullanılan modüller Viessmann Vitovolt 300 P250 polikristal modülleridir. Bu sistemdeki her modülünde 60 güneş hücresi olan 1000 modül 00'lık azimut açısı ve 30 derecelik bir eğim açısı ile güneye bakacak şekilde konumlandırılmıştır [82]. Şekil 3.1 PV santralini göstermektedir. Tablo 3.1 Viessmann Vitovolt 300 P250 polikristal modüllerinin etiket değerini göstermektedir.



Şekil 3.1 PV güç istasyonunun veri toplama sistemi [82]

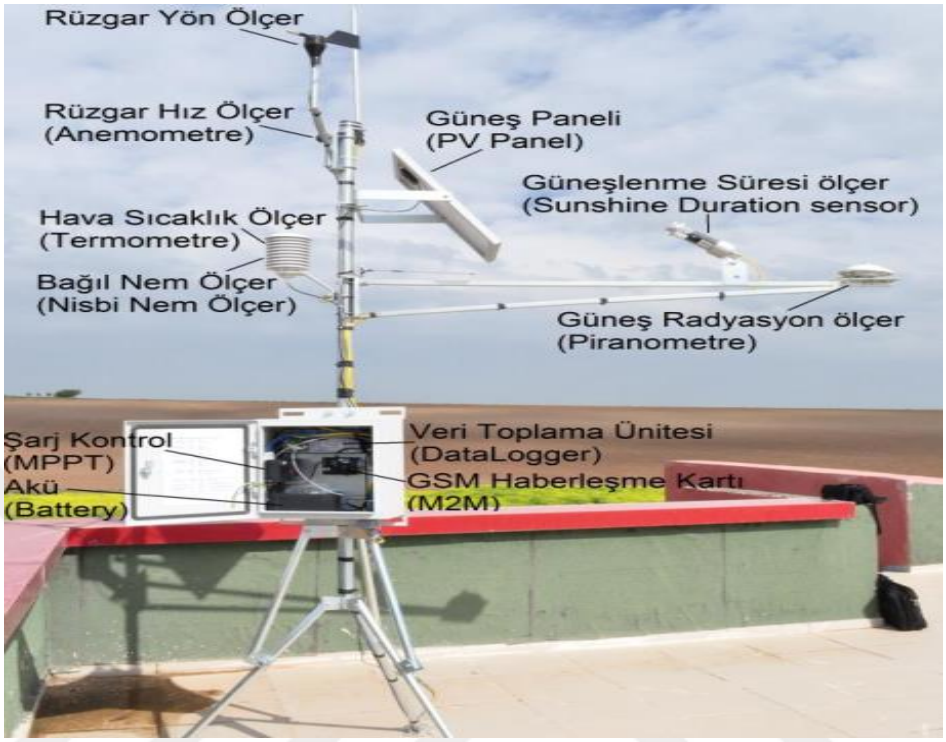
Tablo 3.1 Viessmann Vitovolt 300 Panel Etiket Değerleri [82]

	Ölçülen Değerler	**Oran Değerler**
Nominal Güç	253,1438 W	250 W
Maksimum güçte gerilim	30,3639 V	30,38 V
Maksimum akım	8,337 A	8,29 A
Açık devre gerilimi	37,1664 V	37,12 V
Kısa devre akımı	8,796 A	8,76 A
Maksimum sistem gerilimi		1000 V

3.2 Güneş ölçüm istasyonu

Bu çalışmada kullanılan güneş ışınımı, güneşlenme süresi, rüzgâr hızı, ortam sıcaklığı, panel yüzey sıcaklığı, bulutluluk oranı ve bağıl nem parametreleri şekil 3.2'de gösterilen, Diyarbakır (Enlem: 37º55' D, Boylam: 40º14' K) Dicle Üniversitesi Bilim ve Teknoloji Uygulama ve Araştırma Merkezi (DÜBTAM) binası çatısında bulunan güneş ölçüm istasyonundan alınmıştır. Güneş ölçüm istasyonu üstünde bulunan, piranometre, duyargaç ve veri kaydedici sayesinde nem, sıcaklık, rüzgar yönü, rüzgar hızı, güneş ışınımı ve güneşlenme süresi olmak üzere 8 farklı parametreyi

ölçebilmektedir (şekil 3.2) [86]. Bu istasyonda elde edilen veriler 10 dakikalık periyotlarla elde edilmiştir.



Şekil 3.2 Dicle Üniversitesi güneş ölçüm istasyonu [86]

3.3 Data Seti

Bu çalışmadaki girdi verileri güneş ışınımı(R), ortam sıcaklığı(T), panel yüzey sıcaklığı, güneşlenme süresi, bulutluluk oranı, Rüzgâr hızı (W), DC akım, gerilim ve bağıl nem (H) parametreleridir. Bu çalışmada Mayıs 2019 ile Nisan 2022 tarihleri arasına elde edilen veri seti 10 dakikalık zaman aralıklarına sahiptir. Bu veriler üzerinde K katlamalı çapraz doğrulama tekniği uygulanmıştır. Tablo 3.2 Nisan 2020 tarihinde alınan 10 dakikalık verileri göstermektedir.

Tablo 3.2 02.04.2020 Tarihli Veri seti

Tarih-Saat	Voltaj(volt)	Akım(amper)	Sıcaklık(santigrat)	Rüzgâr Hızı(km/s)
2020-04-02 06:05	191,59	0,06	1,50	0,00
2020-04-02 06:15	191,70	0,07	1,70	0,00
2020-04-02 06:25	192,19	0,13	2,00	0,00
2020-04-02 06:35	192,03	0,54	2,00	0,00
2020-04-02 06:45	192,38	0,79	3,10	0,00
2020-04-02 06:55	192,20	1,00	5,00	0,00

Tablo 3.2 (Devam)

2020-04-02 07:05	192,34	1,31	7,10	0,00
2020-04-02 07:20	192,12	2,09	9,20	0,00
2020-04-02 07:30	191,66	3,50	11,50	0,00
2020-04-02 07:40	191,66	5,97	14,20	1,12
2020-04-02 07:50	191,88	5,33	12,60	0,22
2020-04-02 08:00	193,22	4,48	11,40	0,00
2020-04-02 08:10	196,33	4,82	10,30	0,00
2020-04-02 08:20	196,64	6,02	10,60	0,00
2020-04-02 08:30	197,20	9,14	12,20	0,00
2020-04-02 08:40	197,19	10,39	14,90	0,00
2020-04-02 08:50	197,19	9,42	14,90	0,00
2020-04-02 09:05	197,53	12,70	15,50	0,00
2020-04-02 09:15	197,52	15,14	18,40	0,00
2020-04-02 09:25	197,18	12,22	18,50	0,00
2020-04-02 09:35	197,63	16,62	21,30	0,00
2020-04-02 09:45	197,49	15,19	22,60	0,00
2020-04-02 09:55	197,54	12,42	19,70	0,00
2020-04-02 10:05	197,59	13,13	21,30	0,00
2020-04-02 10:15	197,64	16,96	22,90	0,00
2020-04-02 10:25	198,01	22,47	24,20	2,24
2020-04-02 10:35	197,98	18,26	25,00	0,67
2020-04-02 10:50	199,18	28,41	24,80	0,67
2020-04-02 11:00	200,29	33,61	31,10	2,68
2020-04-02 11:10	200,26	33,54	34,40	2,91
2020-04-02 11:20	198,39	21,80	33,60	1,57
2020-04-02 11:30	200,01	32,30	35,20	4,47
2020-04-02 11:40	197,96	19,54	29,60	2,68
2020-04-02 11:50	199,92	31,21	31,20	0,45
2020-04-02 12:00	199,67	32,46	35,50	1,57
2020-04-02 12:10	199,61	29,99	33,10	0,00
2020-04-02 12:20	197,20	12,18	28,70	0,00
2020-04-02 12:35	197,24	12,79	24,40	3,36
2020-04-02 12:45	197,44	18,78	26,00	5,59
2020-04-02 12:55	197,08	12,73	24,40	2,46
2020-04-02 13:05	197,42	14,90	24,60	5,82
2020-04-02 13:15	198,29	19,17	24,60	3,58
2020-04-02 13:25	198,07	19,96	27,70	4,92
2020-04-02 13:35	197,26	13,96	28,40	2,01
2020-04-02 13:45	196,76	11,63	24,60	2,46
2020-04-02 13:55	196,84	10,32	23,40	1,79
2020-04-02 14:05	198,54	23,56	27,30	1,57
2020-04-02 14:20	199,40	29,61	32,00	0,45
2020-04-02 14:30	196,21	7,13	25,20	0,45
2020-04-02 14:40	197,84	17,62	24,40	0,22
2020-04-02 14:50	197,60	16,36	27,10	0,00

Tablo 3.2 (Devam)

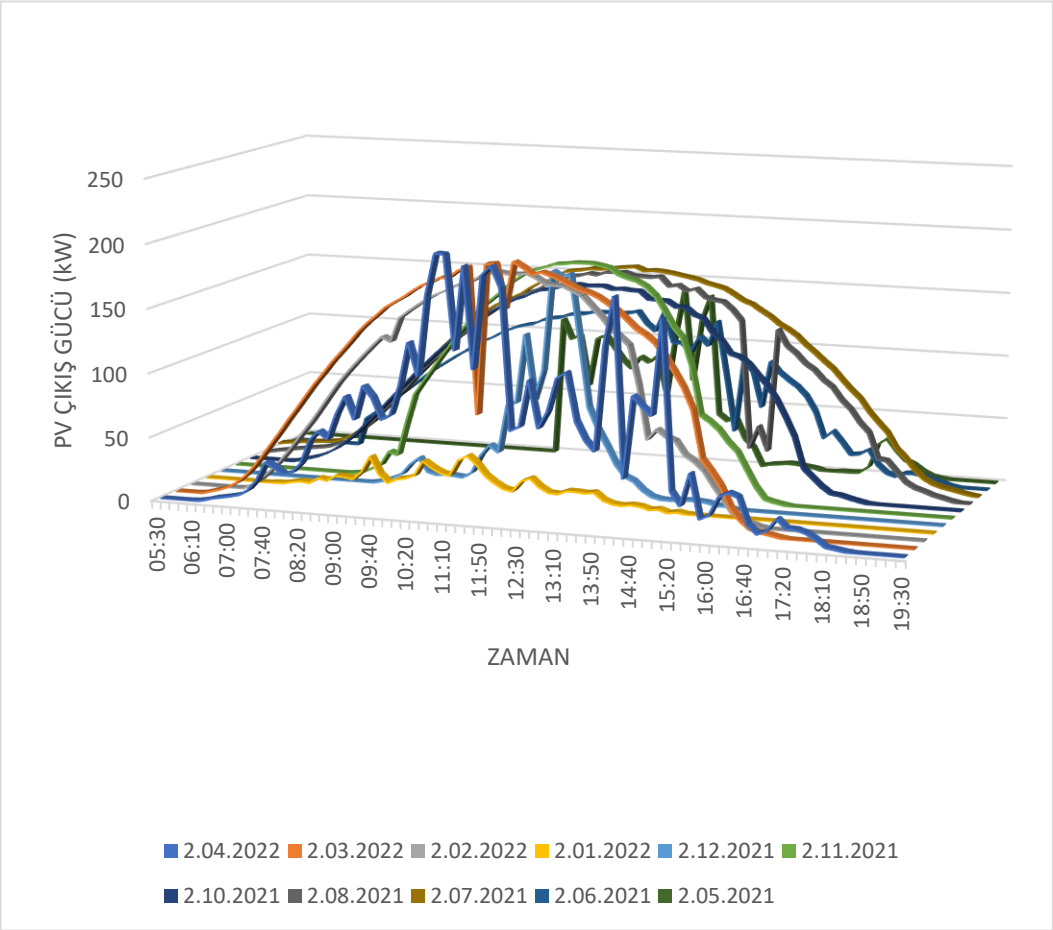
2020-04-02 15:00	197,23	15,27	23,70	0,00
2020-04-02 15:10	199,13	27,24	27,70	0,00
2020-04-02 15:20	196,11	5,98	22,40	0,00
2020-04-02 15:30	195,77	4,24	19,30	1,57
2020-04-02 15:40	196,33	8,47	19,00	2,24
2020-04-02 15:50	195,60	2,74	18,00	0,00
2020-04-02 16:05	195,52	3,32	16,60	0,00
2020-04-02 16:15	196,03	5,76	16,90	0,00
2020-04-02 16:25	196,12	6,39	19,30	0,00
2020-04-02 16:35	196,02	5,92	18,80	0,00
2020-04-02 16:45	195,30	2,50	18,20	0,67
2020-04-02 16:55	195,20	1,41	14,50	0,67
2020-04-02 17:05	195,20	1,99	13,70	0,00
2020-04-02 17:15	195,20	3,57	14,90	0,00
2020-04-02 17:25	195,08	2,46	14,50	0,00
2020-04-02 17:35	195,17	2,39	13,70	0,45
2020-04-02 17:45	195,16	2,06	13,10	0,67
2020-04-02 18:00	195,13	1,31	12,90	0,22
2020-04-02 18:10	195,07	0,43	11,90	0,00
2020-04-02 18:20	194,96	0,23	11,70	0,00
2020-04-02 18:30	194,90	0,10	11,00	0,00
2020-04-02 18:40	194,52	0,07	10,50	0,22
2020-04-02 18:50	193,90	0,06	9,50	0,00
2020-04-02 19:00	48,31	0,06	8,60	0,00

3.3.1 K katlamalı çapraz doğrulama

K-katlamalı çapraz doğrulama, doğru modeli seçmek için makine öğrenimi modellerinin doğruluğunu test etmede uygulanmaktır. Bu teknik, makine öğrenim modellerinin çalışma sürecinde eksik ve aşırı öğrenmeyi tespit edip eksik ve aşırı öğrenmeyi önleyerek test aşamasında en iyi modeli oluşturmayı amaçlamaktadır. Bu teknikte veri seti eğitim seti ve test seti olarak ayrılır. Daha sonra eğitim seti k adet alt kümeye bölünür. Bu işlem k- kez tekrarlanır. Her tekrarda sıradaki alt küme eğitim setinden çıkarak test seti olarak kullanılır. Bu işlem tamamlandığında modelin başarısı veya genel hatası (E), $E = \frac{1}{k}\sum_{i=1}^{K} E_i$ eşitliğindeki gibi k kadar ortalaması alınarak bulunur.

Bu tezde k=10 alınarak veri seti için veri setinin %75'i eğitim verisi (Mayıs 2019-Temmuz 2021), %25'i ise test verisi (Ağustos 2021- Nisan 2022) olarak kullanılmıştır. Dicle Üniversitesinde kurulu olan PV Santralinden ve PV güç istasyonundan elde

edilen bu veri kümeleri PV çıkış gücü ve ilgili meteorolojik verilerinden oluşmaktadır. Şekil 3.3 Mayıs 2021-Nisan 2022 tarihleri arası her ayın 2'sindeki PV güç çıkış eğrilerini göstermektedir. PV güç çıkış eğrilerindeki dalgalanmaların nedeni PV santrallerinin meteorolojik koşullara bağımlılığından kaynaklanmaktadır.



Şekil 3.3 Her ayın 2'sinde PV çıkış gücü eğrileri

3.4 Gürültü Verisinin Elde Edilmesi

PV santrali ve güneş istasyonunda toplanan gerçek veriler kullanılarak iki veri kümesi tasarlanmıştır: İlk veri kümeleri, farklı orantılarda aykırı değerler nedeniyle önerilen yöntemin aykırı değer sağlamlığını test etmek için kullanılır. Bunun için önce rastgele %0, %5, %10, %15, . . . , %50 olarak normal eğitim veri setinden örnekler seçildi. Ardından, hedef çıktı Y = [y1, . . . , y4] olarak seçilen bu normal örnekler ön işlemden geçirilerek aykırılar üretilebilir;

$$y_i, Aykırı = y_i + sign \text{ x } [\text{ rand}(0,1)(\max(y_i) - \min(y_i))] \quad (3.1)$$

Burada rand (0,1), (0, 1) içinde rastgele bir sayıdır ve max(yi) ve min(yi) sırasıyla normal çalışma koşulunda yi'nin maksimum ve minimum değerini belirtir. Uygulamada yaygın olarak karşılaşılan aykırı değerleri daha dengesiz hale getirmek için, seçilen örnek noktalarındaki pozitif sapma aykırı değerlerin ve negatif sapma aykırı değerlerin oranı 2:1 olarak ayarlanır. Ayrıca, pozitif sapma aykırı değerleri eklerken, işaret = 1, negatif sapma aykırı değerler için işaret = -1 olur. Eğitim veri kümesinden farklı olarak, test veri kümesi herhangi bir aykırı değer eklemez.
İkinci veri seti, farklı aykırı değerler nedeniyle önerilen yöntemin aykırı değer sağlamlığını test etmek için kullanılır.

Önce normal eğitim veri setinden örneklerin %25'sini rastgele seçildi. Ardından, aykırılar elde etmek içi seçilen örneklerin hedef çıktısını şu şekilde ön işlendi:

$$y_i, Aykırı = y_i + \alpha + sign \text{ x } [\text{ rand}(0,1)(\max(y_i) - \min(y_i))] \quad (3.2)$$

Burada α = 0, 0,5, 1, 1.5, . . ., 5 aykırı değerlerin genliğini belirlemek için kullanılır. Benzer şekilde, seçilen örnek noktalarında eklenen pozitif sapma aykırı değerleri ve negatif sapma aykırı değerleri, aykırı değerleri daha dengesiz hale getirmek için 2:1'e ayarlanır. Ayrıca, test veri seti herhangi bir aykırı değer eklemez.

3.5 Kanonik Korelasyon Analizi (KKA) ile Hava Tipi Sınıflandırması

Bu çalışmada KKA yöntemi, girdi parametrelerini hava tipine göre sınıflandırmak için kullanılmıştır.

Kanonik korelasyon analizi, iki değişken grubu arasındaki ilişkileri belirlemek ve ölçmek için kullanılan istatiksel bir tekniktir. Diğer bir değişle, kanonik korelasyon analizi yüksek korelasyonlu iki vektörün düşük boyutlu doğrusal izdüşümünü bulmada kullanılır [89, 90]. KKA, birbiriyle ilişkili birden çok sonuç değişkeninin olduğu durumlarda kullanıma uygundur. Kanonik korelasyon analizi kümeler içindeki ve kümeler arasındaki değişkenliği en iyi açıklayan bir dizi kanonik değişkeni, her bir

küme içindeki değişkenlerin ortogonal doğrusal kombinasyonlarını belirlemeye yarar. [91].

KKA'de $F_i = [F_{i1}, F_{i2}, ..., F_{iN}]^T \in R^n$, özellik vektörüdür. Özellik vektörü ana ve yardımcı olmak üzere iki özellik vektörüne ayrılır. Burada F_1 ana özelliği ve N boyutlu F_2 yardımcı özelliği temsil etmektedir. $(F_1, F_2, Y) \sim F_{F1, F2, Y}$ çiftinde Y, sınıf etiketidir. $(F_1, F_2, Y) \sim F_{F1, F2, Y}$ çiftini sağlayan c: $R^n \rightarrow \{1, \ldots, M\}$ M sınıfı sınıflandırıcı olması durumunda, KKA, ana özellik F_1 ve yardımcı özellik F_2'yi temel alan izdüşüm A'yı türetmek için (F_1, F_2) çiftine uygulanabilir. $\boldsymbol{A} = A(\boldsymbol{F_1}, \boldsymbol{F_2})$, KKA'nin izdüşümüdür ve her $i, j = 1,2, ...r$ için $\{a_i\}$ ve $\{a_j\}$ kanonik vektörlerinin iki setini bulma sorunu, $a_i' \boldsymbol{F_1}$ ve $a_j' \boldsymbol{F_2}$ arasındaki korelasyonu en üst düzeye çıkarmak için ele alınabilir. Bir sınıflandırma işleminden önce F_1 için boyut küçültme R^n 'den R^r 'ye elde edilir $(n>r)$. Daha sonra aşağıdaki 3.3 denkleminde belirtilen bir çift konik vektör kümesi tanımlanır.

$$\{a_1, a_j\} = argmin \frac{a_1' \sum F_1 F_2 a_j'}{\sqrt{a_1' \sum F_1 a_1} \sqrt{a_j' \sum F_2 a_j}} \tag{3.3}$$

F_1 için bir matris, KKA izdüşüm matrisi olarak tanımlanır ve izdüşüm özellik vektörü $F_1^p = A' F_1 \in R^r$ olur. Burada $(F_1, F_3, F_5, F_7, F_9)$ana özellikler ve $(F_2, F_4, F_6, F_8, F_{10})$ yardımcı özellikler olarak belirlenir ve $A' = [a_1, ..., a_r]$ dir [92].

Bu çalışma Kanonik korelasyon analizine bağlı olarak, bir günün gündüz dilimlerini yarımşar saatlik periyodlara böler ve ardından her yarımşar saatlik periyodu meteorolojik koşullara göre sınıflandırır ve etiketler. Burada dikkat edilmesi gereken husus, zaman aralığı uzunluğu yerel meteorolojik koşullara bağlı olduğu için zaman aralığı uzunluğu tüm bölgeler için farklılık göstermektedir. Genellikle, zaman aralığının uzun olması, meteorolojik koşulların stabil olma durumuna bağlıdır.

Bu çalışmada, ilk adımda belli bir günün gündüz dilimleri yarımşar saatlik zaman aralıklarına bölündü. İkinci adımda, her bir yarımşar saatlik zaman aralığına 4 farklı hava tipi etiketleri verildi. Üçüncü adımda bu hava tiplerinin yarımşar saatlik zaman aralıkları 4 farklı PV güç çıkış seviyesine göre sınıflandırıldı. Etiketler ve bunlara

karşılık gelen sınıflandırmalar sırasıyla şu şekildedir; PV güç üretimlerine göre Hava Tipi A (HT-A) en uygun, Hava Tipi B (HT-B) en uygun ikinci hava tipidir ve bu şekilde en az uygun tip olan Hava Tipi D (HT-D)'e kadar devam eder. Çalışmada belli bir tarih ve saatin hava tipini belirlemek için önceki yıllara ait en yakın benzer günlerden alınan zaman aralığındaki veri kümesinin bir bölümü seçildi. Bu veri kümeleri, 10 dakikalık PV güç çıkış verileri ile güneş ışınımı, ortam sıcaklığı, panel yüzey sıcaklığı, güneşlenme süresi, bulutluluk oranı, rüzgâr hızı, DC akım, gerilim ve bağıl nem verilerinden oluşmaktadır. Tablo 3.2'de PV güç çıkışlarının A-D hava tiplerine göre dört seviyede sınıflandırılabileceği gösterilmektedir.

Tablo 3.3 PV güç çıkış seviyesine göre dört tip hava durumu sınıflandırması

Hava Tipi	PV Çıkış Gücü (yi) Aralığı
Hava Tipi A	$yi > AVGy + \frac{MAXy - AVGy}{2}$
Hava Tipi B	$AVGy < yi \leq AVGy + \frac{MAXy - AVGy}{2}$
Hava Tipi C	$AVGy - \frac{AVGy - MINy}{2} < yi \leq AVGy$
Hava Tipi D	$0 < yi \leq AVGy - \frac{AVGy - MINy}{2}$

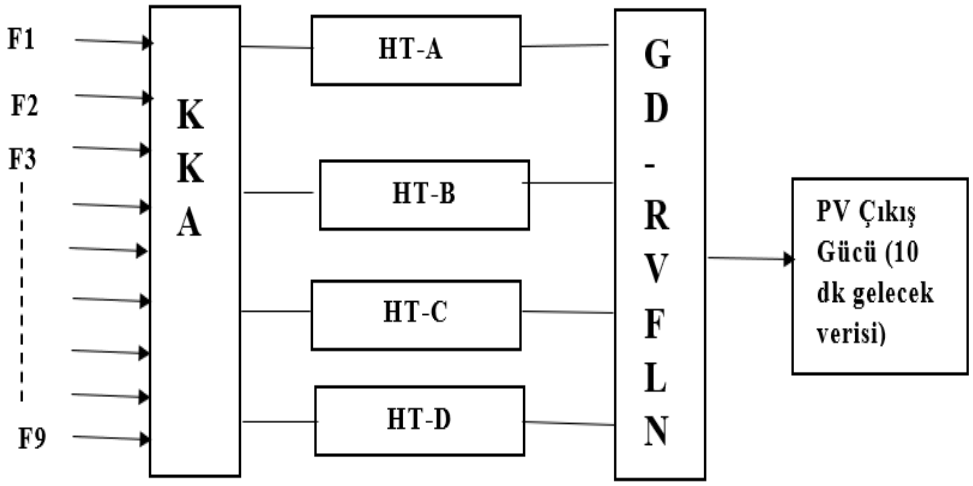
Bu çalışmada kullanılan hava tipi sınıflandırma yöntemi diğer geleneksel yöntemlere göre kullanımı daha kolaydır ve istenildiği takdirde zaman aralıkları uzunluğuna göre dörtten daha az veya daha fazla seviyeye değiştirilebilir.

$$AVG_Y = \frac{1}{n}\sum_{i=1}^{n} y_i \quad y_i \in T \tag{3.4}$$

Denklem 3.4'de T, 2 Haziran 05:30- 06:00 gibi yarımşar saatlik bir zaman aralığında seçilen veri setini ifade eder. Sırasıyla; n veri noktalarının sayısını, y_i PV çıkış gücünü ($y_i \in T$), AVGy veri setinin ortalama PV çıkış gücünü temsil eder ve MAXy ve MINy ise sırasıyla seçilen veri setinin maksimum PV güç çıkışını ile minimum PV güç çıkışını temsil eder.

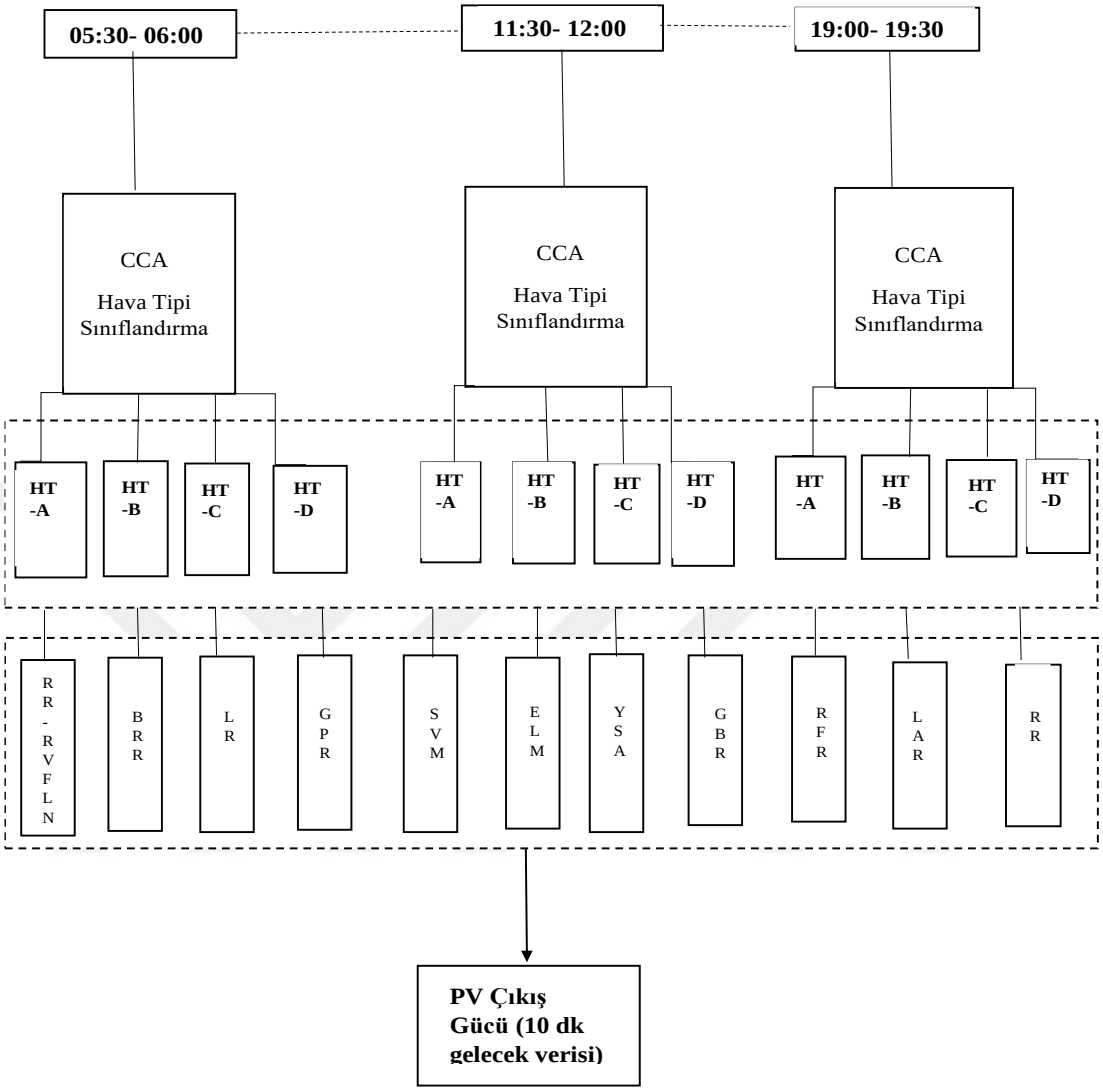
Bu çalışmanın algoritması Şekil 3.4'de gösterildiği gibidir. Bu çalışmada Gürbüz Düzenlenmiş Random Vektör Fonksiyon ağı (GD-RVFLN) modelinin işlevi, hava tipini belirlenen verileri girdi olarak kullanıp PV çıkış gücünü tahmin etmektir.

Bu çalışmada ilk olarak, Kanonik Korelasyon Analizi kullanarak girdi parametreleri ile PV güç çıktısı arasındaki korelasyonlar belirlendi, son günlere ait her yarım saatte bir PV güç çıkış verileri ile bu verilere karşılık gelen meteorolojik veriler veri setleri olarak toplandı daha sonra, geçmiş veri setlerinden öznitelikler çıkarıldı, sonra her yarım saatlik dilimlere hava tipi etiketleri verildi ve ardından GD-RVFLN modeli eğitildi (Şekil 3.5).



Şekil 3.4 KKA'ya bağlı hava tipi sınıflandırma süreci

Şekil 3.5'te gösterilen tahmin süreci, eğitim ve tahmin olmak üzere iki adımdan oluşur.

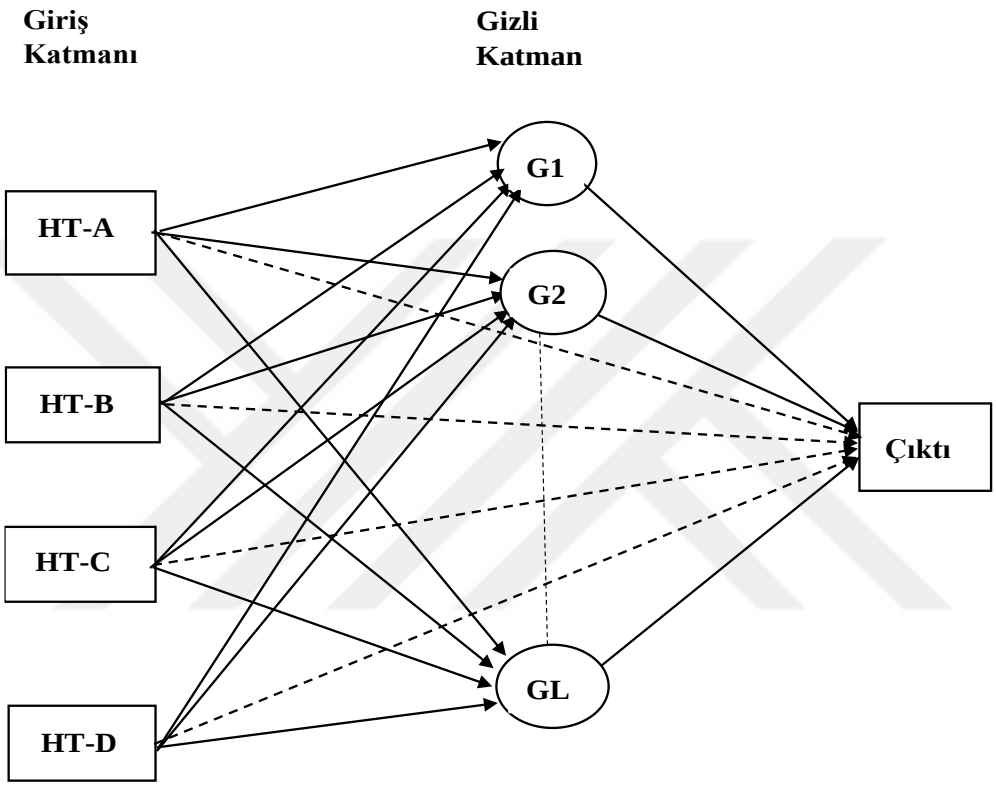


Şekil 3.5 Hava tipi sınıflandırmasına dayalı PV tahmin yöntemi

3.6 Orijinal Rastgele Vektör Fonksiyon Bağlantı (RVFL) Ağ Modeli

Rastgele Vektör Fonksiyon Bağlantı (RVFL) ağı, sınıflandırma, görsel izleme, regresyondan tahmine kadar çeşitli alanlardaki üstün performansı nedeniyle araştırmacılar arasında önemli ölçüde ilgi görmüştür. RVFL, gizli nöronların ağırlıklarının ve sapmalarının uygun bir aralıkta rastgele oluşturulduğu ve çıktı ağırlıkları basit bir kapalı form çözümü ile hesaplanırken sabit tutulduğu tek katmanlı ileri beslemeli bir sinir ağı (SLFN)'dır [93, 94]. RVFL ağında giriş katmanından çıkış katmanına doğrudan bağlantılardan büyük ölçüde yararlanır. Doğrudan bağlantıların

işlevi, rastgeleleştirme için bir düzenleme yapmasıdır. Ayrıca Extreme Learning Machine (ELM) gibi diğer muadillerine kıyasla RVFL ağı, giriş katmanı ile gizli katman arasındaki ağırlıkları rastgele ataması ve ayarlama işlemine ihtiyaç duymaması nedeniyle model karmaşıklığının düşük tutulmasına yardımcı olur [95]. Şekil 3.6 Hava tipine dayalı RVFL ağ modelini göstermektedir.



Şekil 3.6 Hava tipi sınıflandırmasına dayalı RVFL ağ modeli

Eğitim örneklerinin belirli bir veri seti göz önünde bulundurulduğunda $S = \{(X_i, Y_i | i = 1, \dots, N)\} \subset R^d x\ R$, RVFLN, aşağıdaki gibi L gizli düğümüne sahip özel bir tek katmanlı ileri beslemeli bir sinir ağı türü olarak tanımlanabilir.

$$f(x) = \sum_{j=1}^{L} \beta_j h_j(v_j, b_j, x) \tag{3.5}$$

3.5 nolu denklemde v_j ve b_j, sırasıyla gizli düğüm parametreleri olan girdi ağırlığı ve gizli katman düğüm sapmasını ifade eder. β_j, j'ninci gizli katman düğümü ile çıktı

düğümü arasındaki çıktı ağırlığını ve hj, aktivasyon fonksiyonunu temsil eder. Genel olarak, aşağıdaki radyal tabanlı fonksiyon kullanılabilir.

$$h_j = h\left(\frac{\|x - v_j\|}{b_j}\right) \qquad v_j \in R^d,\ b_j \in R^+ \tag{3.6}$$

N örnek (xi, yi) ⊂ R^d ×R için, karesel hataların toplamı olarak kullanılır.

$$J = \sum_{i=1}^{N} \left\| \sum_{j=1}^{L} \beta_j h_j(v_j, b_j, x) - y_i \right\|^2 \tag{3.7}$$

RVFLN'de gizli düğüm parametreleri olan vj ve bj rastgele atanabilir, burada ağ yaklaşımı performansını sağlamak için yalnızca çıkış katmanının doğrusal parametrelerinin analitik olarak hesaplanması gerekir. Böylece denklem 3.9 aşağıdaki gibi ikinci dereceden optimizasyon problemi olarak tanımlanabilir.

$$\arg\min_{\beta} = \|G\beta - Y\|^2 \tag{3.8}$$

Burada

$$G = \begin{bmatrix} h(v_1, b_1, x_1) & \cdots & h(v_L, b_L, x_1) \\ \vdots & \ddots & \vdots \\ h(v_1, b_1, x_N) & \cdots & h(v_L, b_L, x_N) \end{bmatrix}_{NxL} \tag{3.9}$$

$$\beta = \begin{bmatrix} \beta_1 \\ \vdots \\ \beta_L \end{bmatrix}_{Lx1} \quad \text{ve} \quad Y = \begin{bmatrix} y_1 \\ \vdots \\ y_L \end{bmatrix}_{Nx1} \tag{3.10}$$

G, gizli katman çıktısıdır. Y ve β sırasıyla örneklenen çıktı ve çıktı ağırlığını temsil eder. Genel olarak, optimal çıktı ağırlığı β aşağıdaki gibi tanımlanabilir.

$$\beta = G^+ Y \tag{3.11}$$

Burada G^+, G matrisinin Moore-Penrose'a göre genelleştirilmiş transpozesidir, yani tersidir.

3.7 Regularized RVFLN (Düzenlenmiş RVFL Ağı)

Düzenlenmiş (D)-RVFL ağının avantajı, modelin etkili bir şekilde uyum göstermesinin yanında çıktı ağırlığının büyüklüğünü azaltarak model karmaşıklığını da azaltmasıdır.

Normal düzenlenmiş RVFLN, hedef fonksiyonunda düzenlileştirilmiş terimi (l_2 normu) tanıtan ridge regresyon yöntemi [96] kullanılarak oluşturulabilir. Belirli bir N farklı örneklem için (x_i, y_i), l_2 normlu D-RVFL ağı denklem 3.12'daki gibi tanımlanabilir.

$$min: J = \frac{1}{2}\|\beta\|_2^2 + \frac{C}{2}\sum_{i=1}^{N}{\varepsilon_i}^2, \qquad s.t: h(xi)\beta = y_i - \varepsilon_i, \quad \forall i. \tag{3.12}$$

Burada C, eğitim hatasını ve çıktı ağırlık normunu dengeleyen düzenlileştirme parametresini temsil eder. $\sum_{i=1}^{N}{\varepsilon_i}^2$ Ampirik kaybı $\|\beta\|_2^2$ yapısal kaybı temsil eder. Düzenlileştirilmiş en küçük kareler algoritmasına göre, çözüm β aşağıdaki gibi ifade edilebilir:

$$\beta = \begin{cases} \left(G^T G + \frac{I}{C}\right)^{-1} G^T Y, & N \geq L \\ G^T \left(GG^T + \frac{I}{C}\right)^{-1} Y, & N < L \end{cases} \tag{3.13}$$

Denklem 3.13 düzenlenmiş RVFLN' nin çevrimdışı öğrenme formu olarak ifade edilir. Çevrimiçi öğrenme formu ise, eşitlik 3.14'de tanımlanan özyinelemeli bir çözüme atıfta bulunur.

$$\begin{cases} J_k = J_{K-1} + G_k^T G \\ \beta_k = \beta_{k-1} + J_k^{-1} G_k^T (Y_k - G_k \beta_{k-1}) \end{cases} \tag{3.14}$$

Burada G_k, k'nıncı örneklem için oluşturulmuş gizli katman çıktısını belirtir. Modelin başlangıç değerleri aşağıdaki gibidir:

$$\begin{cases} J_0 = G_0^T G_0 + \frac{I}{C} \\ \beta_0 = J_0^{-1} G_0^T Y_0 \end{cases} \tag{3.15}$$

Gizli düğüm sayısından daha fazla sayıda örnek gerektiren geleneksel RVFLN' nin aksine, düzenlileştirilmiş RVFLN, modeli az miktarda örnek kullanarak başlatabilir. Ayrıca, düzenlileştirilmiş RVFLN' nin çıktı ağırlığı normu nispeten küçük olduğundan, model iyi performans göstermektedir. Ancak aykırı değerli verilerle karşılaştığında, düzenlenmiş RVFLN' nin kalitesi bozulabilir ve model uyumsuzluğuna yol açabilir. Bu yüzden C düzenleme parametresini tam olarak kullanmayabilir. Bu nedenle, RVFLN 'nin geliştirilmesine ihtiyaç duyulmuştur. Aşağıdaki bölümde, sağlam düzenlileştirilmiş (Robust Regularized) RVFLN sunulmaktadır [97].

3.8 Gürbüz Düzenlenmiş Rastgele Vektör Fonksiyon Bağlantı Ağı (GD-RVFLN)

RVFLN modelinin sağlamlığını iyileştirmek için kernel density estimation (NKDE) yöntemi ve ağırlıklı ampirik kayıplı ridge-tip düzenlenmiş RVFL ağı yöntemleri çalışmaya dahil edilmiştir. Gürbüz Düzenlenmiş RVFLN yönteminde, ampirik kayıp ağırlıkları, NKDE yönteminin tahmin ettiği örnek güvenilirliğe göre belirlenmektedir. Böylelikle yüksek ve düşük örnek güvenirliğe sahip kayıp ağırlıklarının değerlerinin düşürülmesi ve artırılması istenmeyen aykırı değerlerin etkisini azaltmakta veya ortadan kaldırmaktadır [98].

Bir optimizasyon yöntemi olan Robust regularized RVFLN yöntemi, belirli bir N farklı örnek (xi, yi) için, aşağıdaki matematiksel formülle ifade edilebilir.

$$\min: \frac{1}{2}\|\beta\|_2^2 + \frac{C}{2}\sum_{i=1}^{N} pi \ \|\varepsilon i\|_2^2$$

$$s.t: h(x_i)\beta = y_i - \varepsilon_i, \ \forall i. \qquad (3.16)$$

Bu formüldeki pi, i'inci örneğin ampirik kayıp ağırlığını ifade eder. β optimal çıkış ağırlığıdır. C, düzenleme parametresidir ve ε, artık hatadır. Karush-Kuhn-Tucker (KKT) teoremine göre, yukarıdaki optimizasyon formülü matematiksel olarak aşağıdaki ikili optimizasyon formülüyle ifade edilebilir.

$$J_{\ell_2}(\beta, \varepsilon, \alpha) = \frac{1}{2} \|\beta\|_2^2 + \frac{1}{2} C \sum_{i=1}^{N} pi\varepsilon i^2 - \sum_{i=1}^{N} \alpha i(h(xi)\beta - yi + \varepsilon i) \quad (3.17)$$

Burada i'ninci giriş örneği için αi, Lagrange çarpanı ve h aktivasyon fonksiyonudur. Burada, β,ε,α değerleri, yukardaki ikili optimizasyon formülünün kısmi türevi alınarak bulunabilir. Dolayısıyla, formül şu şekilde türetilebilir:

$$\frac{\partial J_{\ell_2}}{\partial \beta} = 0 \rightarrow \beta = G^T \alpha \quad (3.18)$$

$$\frac{\partial J_{\ell_2}}{\partial \varepsilon} = 0 \rightarrow \alpha = CP\varepsilon \quad (3.19)$$

$$\frac{\partial J_{\ell_2}}{\partial \alpha} = 0 \rightarrow G\beta - Y + \varepsilon = 0 \quad (3.20)$$

Burada, P ampirik kayıp ağırlık matrisini ifade eder. Farklı büyüklükteki eğitim örneği setleri için yukarıdaki formüllere aşağıdaki alternatif çözümler elde edilebilir.

N <L olduğu durumda
3.20. formülden 3.21. formül elde edilir:

$$PG\beta - PY + P\varepsilon = 0 \quad (3.21)$$

3.19. ve 3.18. Formüllerden 3.20. Formüle ulaşılır.

$$\left(\frac{1}{C} + PGG^T\right)\alpha = PY \quad (3.22)$$

3.22. formüldeki α'yı yalnız bırakır 3.18. Formüldeki yerine koyarsak 3.23. Formül elde edilir.

$$\beta = G^T \left(\frac{1}{C} + PGG^T\right)^{-1} PY \quad (3.23)$$

N> L olduğu durumda
3.19. formüldeki α değerini 3.18. Formüldeki yerine yazıldığında 3.24. Formül elde edilir.

$$\beta = G^T CP\varepsilon \quad (3.\ 24)$$

3.24. formüldeki Pε aşağıda gösterildiği gibi yalnız bırakılır.

$$P\varepsilon = \frac{1}{C}(G^T)^{-1}\beta \tag{3.25}$$

3.25. formül, 3.21. Formülün yerine yazılarak 3.26. Formül elde edilir.

$$PG\beta - PY + \frac{1}{C}(G^T)^{-1}\beta = 0 \tag{3.26}$$

Böylece,

$$G^T PG\beta - G^T PY + \frac{1}{C}\beta = 0 \tag{3.27}$$

3.27. formüldeki β yalnız bırakıldığında aşağıdaki 3.28. Formül elde edilir.

$$\beta = \left(\frac{1}{C} + G^T PG\right)^{-1} G^T PY \tag{3.28}$$

Sonuç olarak, yukardaki çıktı ağırlıkları (β) kısaca aşağıdaki formüldeki gibidir.

$$\beta = \begin{cases} G^T\left(\frac{1}{C} + PGG^T\right)^{-1} PY, & N < L \\ \left(\frac{1}{C} + G^T PG\right)^{-1} G^T PY, & N \geq L \end{cases} \tag{3.29}$$

İ=1, … ,N sayıda örneklem için Ampirik kayıp ağırlığı pi, C parametresi hariç optimal çıkış ağırlığı β çözümü için oldukça önemli bir parametredir. Çünkü model sağlamlığının iyileştirilmesi pi'nin hesaplanmasıyla elde edilir. Burada pi örneklerin çözüme katkısıdır. Dolayısıyla, amaca ulaşmak için bu katkının örneğin güvenirliliğine yakın olmasına izin verildi. Örnek güvenirliliği, artık olasılık yoğunluk fonksiyonu kullanılarak NKDE yöntemi ile tahmin edilebilir. Bu yolla, düşük yoğunluklu aykırı değerler ayarlanarak çözüme küçük ya da sıfır katkı sağlanır. Artık olasılık dağılımı ise Robust regularized RVFLN yöntemindeki P' nin bir kimlik matrisi olarak ayarlanması ile elde edilebilir. Yani;

$$\varepsilon j = \sum_{\mathrm{i}=1}^{L} \beta_i h_i(v_i, b_i, x_i) - y_i \quad j = 1, 2, \ldots, N \tag{3.30}$$

Daha sonra, artıkların olasılık yoğunluğu $f(x)$, aşağıdaki gibi NKDE yöntemi ile elde edilir.

$$f(x) = \frac{1}{hN} \sum_{j=1}^{N} \phi(\frac{x-\varepsilon j}{h}) \tag{3.31}$$

$$\phi(x) = \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}x^2} \tag{3.32}$$

Burada, sırasıyla ϕ, Gauss çekirdek fonksiyonu, $\hat{\sigma}$ artıkların standart sapmasını ve h=1.06$\hat{\sigma}N^{-1/5}$ tahmin edilen pencere genişliğini ifade etmektedir.

Formül 3.29 kullanılarak, her artık hata εi'nin olasılığı, yani, $f(\varepsilon i)$ elde edilebilir. Diğer taraftan $f(\varepsilon j)$ fonksiyonu ile örneğin güvenilirliği doğru orantılıdır. Yani, $f(\varepsilon j)$'nun değeri yüksek olduğunda örnek güvenirliği yüksek olur, küçük olduğunda örnek güvenirliliği de küçük olur. Bu nedenle, $f(\varepsilon j)$'yi ayarlanarak doğrudan pi ağırlığı da ayarlanabilir.

Çıktı ağırlığı hesaplama Formülü (3.29) ile numune ağırlığı değerlendirme denklemi formül (3. 31) arasındaki yinelemeli değişim, yenilemeli olmayan yönteme göre daha doğru örnek güvenirliliği sağlamaktadır. Ancak yinelemeli değişim daha yüksek hesaplama yüküne sahip olduğu için bu çalışmada yinelemeli olmayan yöntem kullanılmıştır.

3.9 Karşılaştırma Yöntemleri

3.9.1 Linear regressor (LR)

Doğrusal (linear) regresyon, tek değişkenli ve çok değişkenli regresyon için çok yaygın kullanılan oldukça basit bir makine öğrenimi algoritmasıdır. Algoritma, bağımlı değişkenle bağımsız değişken arasındaki lineer ilişkiyi bulmaya çalışır. X öznitelik uzayı ve Y tahmin edilecek vektör ise, matematiksel olarak doğrusal regresyon şu şekilde temsil edilebilir:

$$X\beta + e = Y \tag{3.33}$$

$$X^T X\beta + X^T e = X^T Y \tag{3.34}$$

$$\beta = (X^T X)^{-1} X^T Y \tag{3.35}$$

Burada, e, X' nın sütun uzayına dik olan hata vektörüdür. β, her bir özellik vektörüne göre optimize edilmiş doğrunun eğim ve kesişim değerlerini içeren regresyon katsayısıdır.

3.9.2 Lasso regressor (LAR)

Lineer regresyon üzerinde geliştirilen En Az Komşu Büzülme ve Seçim Operatörü (LASSO), tahminleri gerçekleştirmek için katsayıların büyüklüğünün mutlak değerine eşit bir ceza ekleyen L1 düzenlemesini gerçekleştirir. Bu tür modellerin temel amacı, seyrek özelliklerle bile iyi sonuçlar elde etmektir. Matematiksel denklem aşağıdaki gibi tanımlanabilir.

$$L_{lasso} = \min_{\beta}(\|Y - X\beta\|^2 + \lambda\|\beta\|_1^2) \tag{3.36}$$

Burada λ düzenleme cezasıdır.

3.9.3 Ridge regressor (RR)

Ridge regresyonu, fonksiyonunda tıpkı LASSO regresyonun orijinal fonksiyona eklenen bir ceza terimi vardır. Ancak, tepe regresörünün cezası, aynı L-1 normu olan LASSO regresöründen farklı olarak katsayıların L-2 normu olarak gerçekleştirir. Denklem aşağıdaki gibidir:

$$L_{ridge} = \min_{\beta}(\|Y - X\beta\|^2 + \lambda\|\beta\|_2^2) \tag{3.37}$$

3.9.4 Bayesian Ridge Regression (BRR)

Bayesian ridge regresyonu, lineer regresyona benzeyen bir makine öğrenme yöntemidir. Ancak lineer bir fonksiyon yapmak yerine, eğitim verilerine dayalı bir olasılık dağılımı yapılır. Bu bir ridge regresyonu olduğundan, katsayılar belirli bir

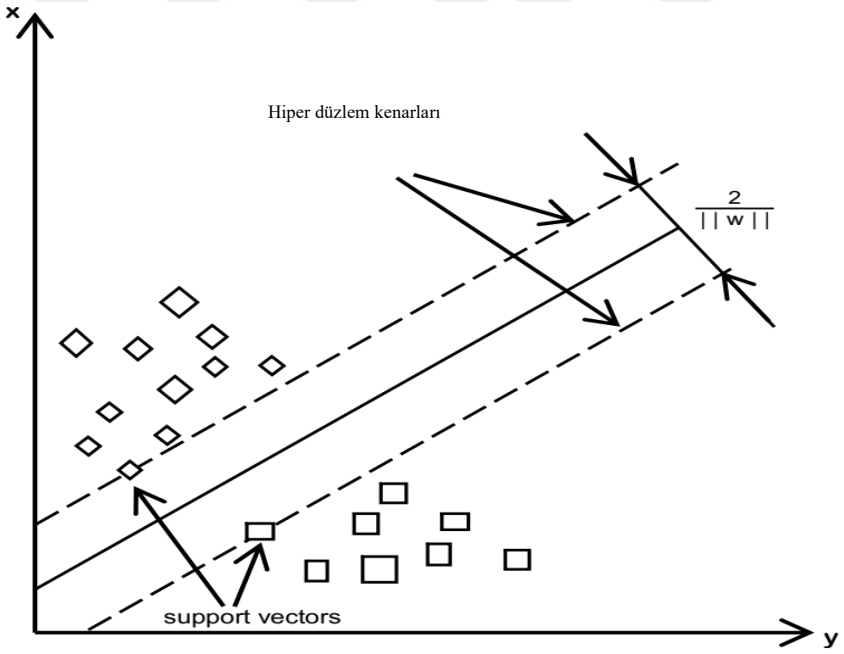
eşiğin üzerindeyse hataya bir ceza eklenir. i = 1, . . . , n için verilen k × 1 tahmin vektörü xi, yi' nin koşullu dağılımının ortalaması şu şekilde verilir:

$$y_i = x_i{}^T \beta + e_i \tag{3.38}$$

Burada β bir k × 1 vektörüdür ve εi rastgele değişkenlerdir.

3.9.5 Support Vector machine

Destek vektör makineleri (SVM), ilişkili öğrenme algoritmaları ile denetimli öğrenme algoritmalarını kullan makine öğrenme modelleridir. Başlangıçta, veriler düzensiz bir şekilde ayrılır. Veri noktaları hiper düzlemin yanlış tarafındaysa, optimizasyonun amacı yanlışlığı minimize etmektir. SVM'nin resimli temsili Şekil 3.7'te gösterilmiştir.



Şekil 3.7 Support vektörleri ve hiper düzlem kenarları

$$\left[\frac{1}{n}\sum_{i=1}^{n} max\left(0,1 - y_i(\overrightarrow{w}.\ \overrightarrow{x_i} - b)\right)\right] + \lambda\|\overrightarrow{w}\|^2 \tag{3.39}$$

Burada yi i' ninci hedef ve $\overrightarrow{w}.\overrightarrow{x_i} - b$, i' ninci çıktıdır. λ parametresi, xi'nin kenar boşluğunun doğru tarafında olmasını sağlar.

3.9.6 Random forest regressor (RFR)

RFR, birkaç regresyon modelinin sonuçlarını birleştirmek için toplu öğrenmeyi kullanan bir makine öğrenimi yöntemidir. Bu yöntemde her model bir ağaç olarak gösterilebilir. Bu nedenle, RFR, kendi ortalama tahminini veren, birbiriyle etkileşime girmeyen birçok ağacın birleşiminden oluşmaktadır [99]. Yöntem iki ana fikri birleştirir: torbalama yöntemi ve rastgele alt uzay metodolojisi. Bu yöntem genel olarak sınıflandırma, regresyon ve kümeleme için kullanılır.

Yöntemin algoritmasında yatan temel fikir, her biri çok düşük kaliteli sınıflandırma sonucu oluşan, ancak çok sayıda oldukları yine de doğru sonucu vere büyük bir karar ağaçları topluluğu kullanmaktır.

Rastgele alt uzay metodolojisi, ağaçlar arasındaki korelasyonu azalttığı ve fazla uydurmayı önlediği için temel algoritmalar, rastgele tahsis edilen çeşitli alt kümeler kullanılarak eğitilir.

Ağaçlardan oluşan rastgele bir orman oluşturma algoritması aşağıdaki gibidir:
Her n = 1 ..., N için:
- önyükleme kullanarak bir Xn örneği oluşturulur.
- bir Xn örneği için bn karar ağacı oluşturulur:
• belirli bir kritere göre, en iyi özellik seçilir ve numune tükenene kadar ağacın bir bölümü oluşturulur;
• n_{min} koşulu sağlanana veya karar ağacının belirli bir düzeyine ulaşana kadar bir ağaç oluşturulur;
• her bölmede, orijinal n öznitelikten rastgele öznitelikler m seçilir ve bunlar arasında en iyi bölümü aranır. Algoritma aşağıdaki gibidir:

$$a(x) = \frac{1}{N}\sum_{i=1}^{N} b_i(x) \tag{3.40}$$

3.9.7 Gradient boosting regressor (GBR)

GBR, öğrenmede zorluk yaşayan verileri, yinelemeli bir şekilde güçlendirerek iyi bir öğrenicide birleştirir. Bir eğitim veri kümesi $D = \{x_i, y_i\}_1^N$ verildiğinde, gradyan artırmanın amacı, L (y, F(x)) minimize ederek, x örneklerini çıktı değerleri y ile eşleştiren $F^*(x)$ fonksiyonunun bir $\hat{F}$ (x) yaklaşımını bulmaktır, belirli bir kayıp fonksiyonunun beklenen değerini Gradyan artırma, ağırlıklı bir işlevler toplamı olarak $F^*(x)$ 'nin toplamsal bir yaklaşımını oluşturur.

$$F_m(x) = F_{m-1}(x) + \rho_m h_m(x) \tag{3.41}$$

Burada ρ_m, $h_m(x)$ fonksiyonunun m'inci ağırlığını belirtir. Algoritma yinelemeli olarak oluşturulur ve bir F∗(x) fonksiyonu şu şekilde elde edilir:

$$F_0(x) = argmin_\alpha \sum_{i=1}^N L(y_i, \alpha) \tag{3.42}$$

3.9.8 Gaussian Process Regression (GPR)

Gauss Süreç Regresyonu (GPR), karmaşık sistemi rastgele olarak modelleyen parametrik olmayan bir algoritmadır. Belirsizlik temsillerini sağlama esnekliği özelliğinden dolayı çoğu tahmin probleminde GPR tercih edilir.

$$\bar{f_*} = K(X, X_*)(K(X, X) + \sigma_n^2 I)^{-1} y = W_{GPR} Y \tag{3.43}$$

Burada $\bar{f_*}$ tahmin sonuçlarını temsil eder. x ve y, eğitim veri kümesindeki girdi ve çıktıyı belirtir. K, Kernel matrisidir. W_{GPR}, standart GPR için ağırlık matrisidir.

3.9.9 Extreme learning machine (ELM)

ELM'nin temel özelliği, giriş ağırlıkları ve sapmaları dahil olmak üzere gizli düğümlerin öğrenme parametrelerinin rastgele atanmasıdır ve bunun yanı sıra çıkış ağırlıkları basit genelleştirilmiş ters işlemle analitik olarak belirlenebilirken ayarlama yapmasına ihtiyaç duymamasıdır. Ayrıca SLFN'nin bir türü olan ELM'nin tanımlanması gereken tek parametre, gizli düğümlerin sayısıdır [100].

Verilen N farklı eğitim örneği $(x_i, y_i) \in R^n X R^m (i = 1, 2, \dots, N)$, N gizli düğümlü (toplamsal) bir SLFN'nin çıktısı aşağıdaki gibi tanımlanır:

$$o_j = \sum_{i=1}^{\tilde{N}} \beta_i f_i(x_i) = \sum_{i=1}^{\tilde{N}} \beta_i f(x_i; a_i, b_i), \quad j = 1, \dots, N \tag{3.44}$$

Burada oj, çıktı vektörüdür. $a_i = [a_{i1}, a_{i2}, \dots, a_{in}]^T$ ve bi, sırasıyla j'ninci gizli düğümden rastgele oluşturulan öğrenme parametrelerini belirtir. $\beta_i = [\beta_{i1}, \beta_{i2}, \dots, \beta_{im}]^T$, j'ninci gizli düğümü ve çıkış düğümlerini birbirine bağlayan parametredir.

$f(x_i; a_i, b_i)$ ELM'nin aktivasyon fonksiyonu olarak adlandırılır. ai. xj', ai ve xj'nin iç çarpımı olarak ayarlanır. Eşitlik (3.44), küçültülmüş olarak aşağıdaki şekilde yazılabilir:

$$H\beta = 0 \tag{3.45}$$

Burada,

$$H = \begin{bmatrix} f(a_1.x_1 + b_1) & \cdots & f(a_{\tilde{N}}.x_1 + b_{\tilde{N}}) \\ \vdots & \cdots & \vdots \\ f(a_1.x_N + b_1) & \cdots & f(a_{\tilde{N}}.x_N + b_{\tilde{N}}) \end{bmatrix}_{NX\tilde{N}}$$

$$\beta = \begin{bmatrix} \beta_1^T \\ \vdots \\ \beta_{\tilde{N}}^T \end{bmatrix}_{\tilde{N}xm}, \qquad 0 = \begin{bmatrix} 0_1^T \\ \vdots \\ 0_N^T \end{bmatrix}_{Nxm}$$

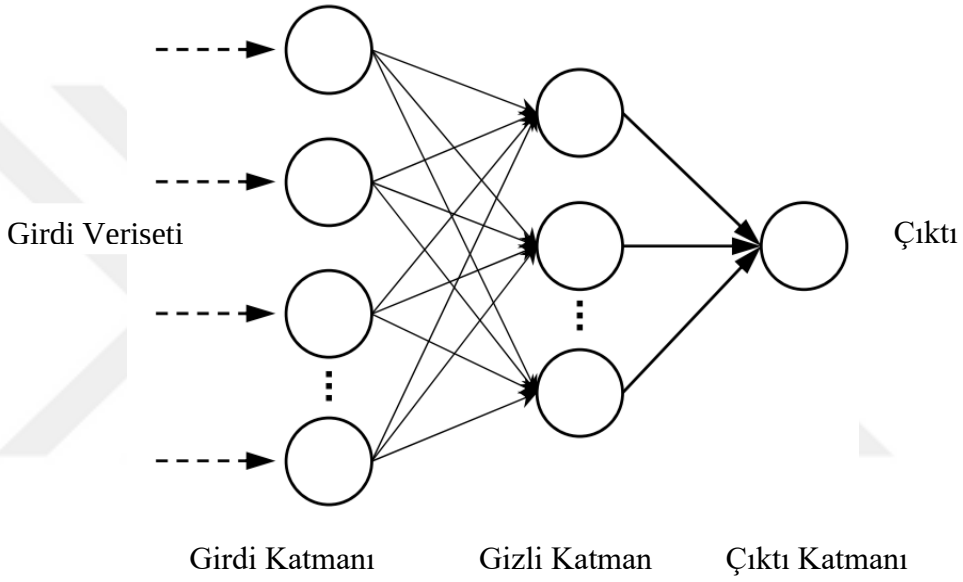
Burada H gizli katmanın çıktı matrisidir. Ağ maliyet fonksiyonu olan $\|0 - T\|$'yi en aza indirmek için, ELM modeli, gizli düğümlerin öğrenme parametreleri ai ve bi'nin girdi verilerini dikkate almadan rastgele atayabilir. Daha sonra, denk. (3.45) doğrusal bir sistem haline gelir ve çıktı ağırlıkları b analitik olarak aşağıdaki gibi bir en küçük kareler çözümü bulunarak belirlenir.

$$\hat{\beta} = H^+ T \tag{3.46}$$

Burada H^+, H'nin tersidir.

3.9.10 Yapay sinir Ağı (YSA)

YSA, insan beyninin bilgi işleme mekanizmasını taklit eden makine öğrenimi yöntemlerinden biridir. YSA, doğrusal olmayan işlevleri yüksek doğruluğa yaklaştırma konusunda benzersiz bir yeteneğe sahiptir. Bu makine örenimi meteorolojik tahminler, mühendislik, fizik, tıp ve finans, gibi çok çeşitli alanlarda kullanılmaktadır. Şekil 3.8, ağın temel bir temsilidir.



Şekil 3.8 YSA'nın temel yapısı [83]

Giriş katmanı, gizli katman ve yapay nöronlar ve bağlantılardan oluşan çıktı katmanı olmak üzere YSA'nın yapısı üç bölüme ayrılmıştır. Yapısında bulunan bir sinir ağının her bir yapay nöronu, tüm bilgi işleme ve karar verme faaliyetlerinin gerçekleştiği bir aktivasyon düğümüdür. Makine öğrenimi parametrelerini uygulayarak; belirli bir etkinleştirme düğümü, önceki bir düğümden girdi alır ve ağırlıklı toplamı oluşturur. Bu işlemlerden elde edilmiş bilgiler, daha sonra bileşik tahmini hesaplamak için bir aktivasyon fonksiyonuna aktarılır. Oluşturulan bu tahmin, yenilemeli olarak istenen çıktıya ulaşıncaya kadar aşamalı olarak devam eder. En sık kullanılan aktivasyon fonksiyonları Gauss radyal temeli, Sigmoid, Hiperbolik tanjant sigmoid, Lineer, Bipolar adım fonksiyonu, Unipolar adım fonksiyonu, Unipolar lineer fonksiyon ve Bipolar lineer fonksiyondur [101].

4. BULGULAR VE TARTIŞMA

PV çıkış gücü, güneş radyasyonu, ortam sıcaklığı ve rüzgâr hızı vb. gibi meteorolojik parametrelerle yakından ilişkilidir. Bu çalışmada 10 dakika aralıklara sahip Makine öğrenimi modellerini test etmek için kullanılan eğitim verileri, Mayıs 2019 ile Nisan 2022 arasındadır. Bu çalışmada farklı modellerin tahmin performansını göstermek ve karşılaştırmak için her ayın 2'si seçildi.

4.1 Değerlendirme Endeksleri

Bir modelin tahmin doğruluğunu değerlendirmeye ve kıyaslamaya, standartlaştırılmış performans ölçüleri, yardımcı olur. Sırasıyla denklem (4.1) ve (4.2)'de gösterildiği gibi Ortalama Mutlak Yüzdelik Hata (OMYH/OMYH) ve Ortalama Karesel Hatası (OKH), bu çalışmadaki modellerinin doğruluğunu değerlendirmede kullanılmıştır:
OMYH, tahminin doğruluğunu ölçen ve gerçek veri kümeleri için tahmin çeşitliliğini doğrulayan standart bir tahmin tekniğidir.

Ortalama Mutlak Yüzdelik Hata (OMYH):

$$\text{OMYH} = \frac{1}{\text{N}}\sum_{i=1}^{\text{n}} \frac{|\text{p}_{\text{Gerçek}}(i) - \text{P}_{\text{Tahmin}}(i)|}{\text{P}_{Gerçek}(i)} \text{X}100\% \qquad (4.1)$$

Ortalama göreli hata'nın aralıklarına karşılık gelen ifadeler sırasıyla şu şekildedir;

0≤ OMYH ≤10 mükemmel tahmin doğruluğu,
10≤ OMYH ≤20 iyi tahmin doğruluğunu,
20≤ OMYH≤50, idare eder, tahmin doğruluğunu,
OMYH ≥ 50, ise yanlış tahmini ifade etmektedir.

OKH, tahmin edilen değerler ile gerçek gözlemler arasındaki karesel farklılıkların ortalamasının karekökünü kullanarak hatanın ortalama değerini tahmin eder. Bu nedenle, özellikle istenmeyen büyük sapmalarla baş etmede daha sağlamdır ve araştırmacıya aykırı değerleri belirleme ve ortadan kaldırma yeteneği verir.
Ortalama Karekök Hatası (OKH):

$$\text{OKH} = \sqrt{(\frac{1}{\text{N}} \text{x} \sum_{\text{i}=1}^{\text{N}} \left(\text{p}_{\text{Tahmin}}(\text{i}) - \text{P}_{\text{Gerçek}}(\text{i})\right)^2} \quad (4.2)$$

Yukardaki formüllere göre P_{Tahmin} ve $P_{Gerçek}$ sırasıyla PV tahmin gücünü, ölçülen PV gücünü temsil eder. N, veri ölçümlerinin sayısıdır. OKH değeri 0≤ OKH <∞'a kadar değişebilir. Negatif eğilimli düşük değerler daha iyi performans gösterir. OKH=0 olma durumu modelin hatasız olduğunu gösterir.

Tahmin için belirlenen test verileri Mayıs 2021'de başlayıp Nisan 2022'ye kadardır.

4.2 Tahmin Sonuçları

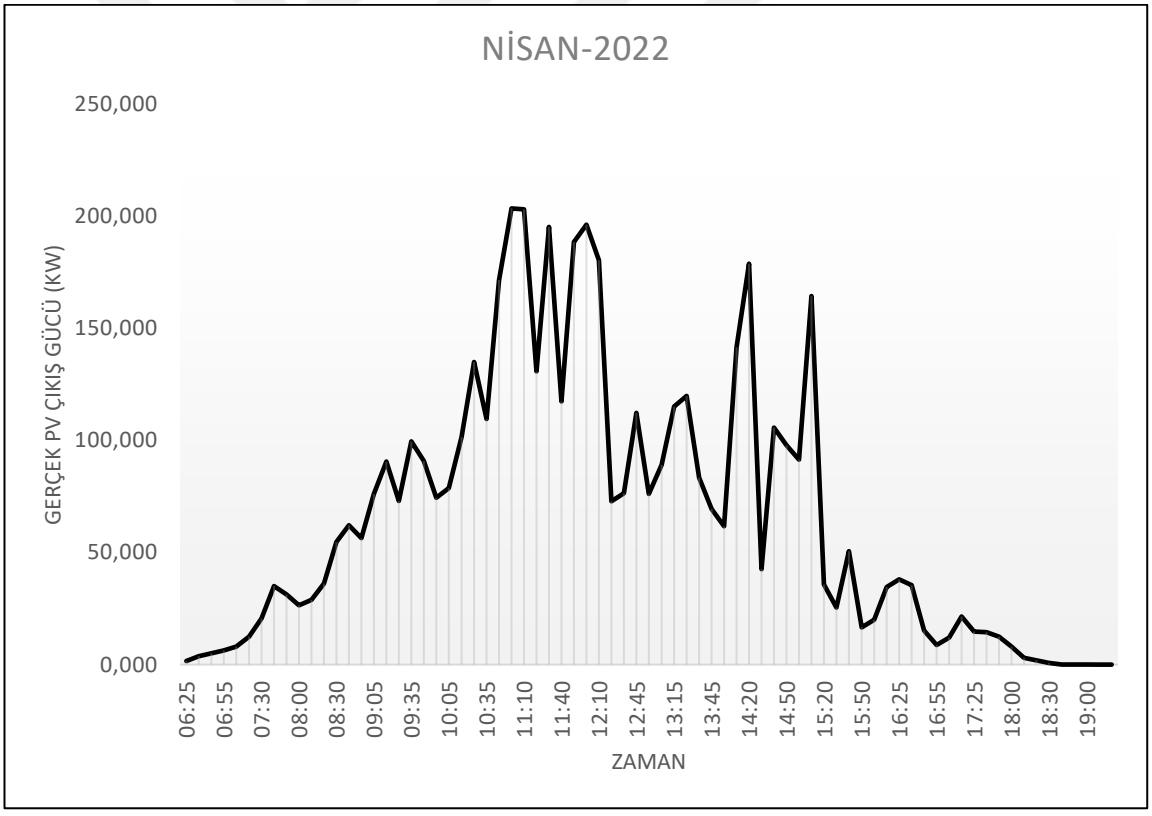
Bu çalışmada kullanılan büyük veri kümesi, Dicle üniversitesi kampüsünde kurulu olan PV güç santralinden ve güneş istasyonundan toplanmıştır; makine öğrenimi modellerinin büyük verilere ihtiyaç duymasının nedeni test sonuçlarının diğer koşullara uygulanabilir olması için etkin bir şekilde eğitilmesi içindir. Bu aşamada, modellerin tahmin doğruluğunu değerlendirmede kullanmak için her ayın 2'si seçilmiştir.

4.2.1 Hava tipi sınıflandırmasına dayalı GD-RVFLN modeli tahmin sonuçları

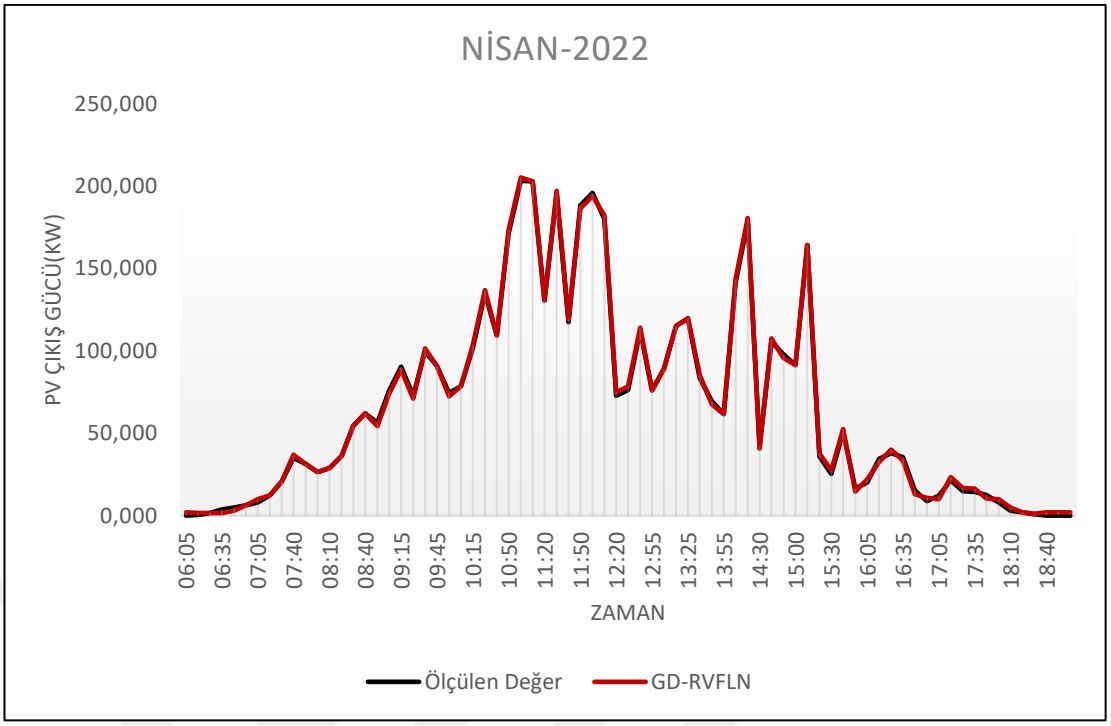
Bu tezde, modelin performans doğruluğunu artırmak için klasik RVFLN modeli geliştirilerek oluşturulan ve hava tipi sınıflandırmasına dayalı olan GD-RVFLN modelini önerilmiştir. Önerilen bu modelin tahmin sonuçları göstermiştir ki Mayıs 2022-Nisan 2021 tarihleri arasındaki tüm aylarda GD-RVFLN modeli 0≤ OMYH ≤10 aralığında değerler alarak mükemmel tahmin doğruluğuna sahiptir (tablo 4.1'de gösterildiği gibidir). Aşağıdaki şekil 4.1'de şekil 4.24'e kadar olan şekiller ölçülen gerçek PV çıkış gücü sonuçları ile GD-RVFLN modelinin tahmin sonuçlarını göstermektedir.

Tablo 4.1 GD-RVFLN için OMYH ve OKH değerleri

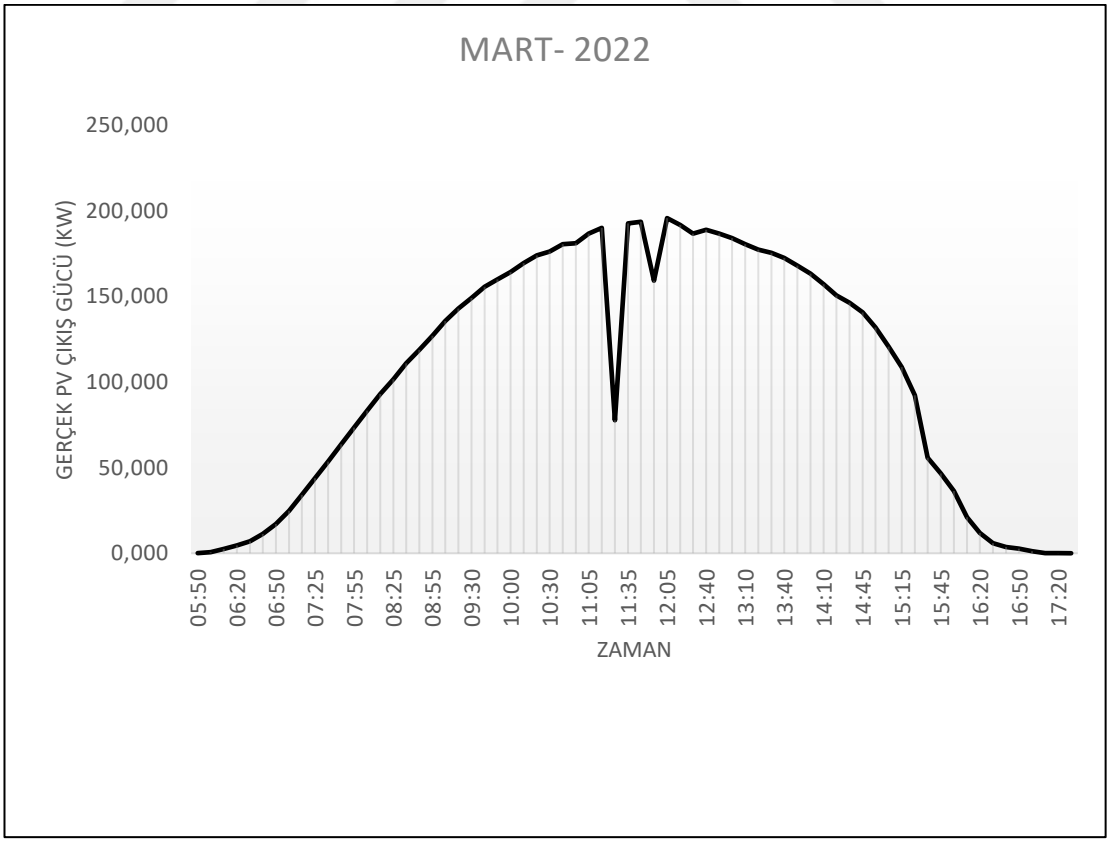
GD-RVFLN TAHMİN DOĞRULUĞU		
TARİH	**OMYH (%)**	**OKH**
2.04.2022	3,919	1,646
2.03.2022	1,724	1,684
2.02.2022	1,687	1,680
2.01.2022	9,767	1,398
2.12.2021	8,886	1,445
2.11.2021	1,895	1,732
2.10.2021	2,254	1,499
2.08.2021	1,861	1,345
2.07.2021	1,811	1,664
2.06.2021	4,741	1,570
2.05.2021	5,407	1,358



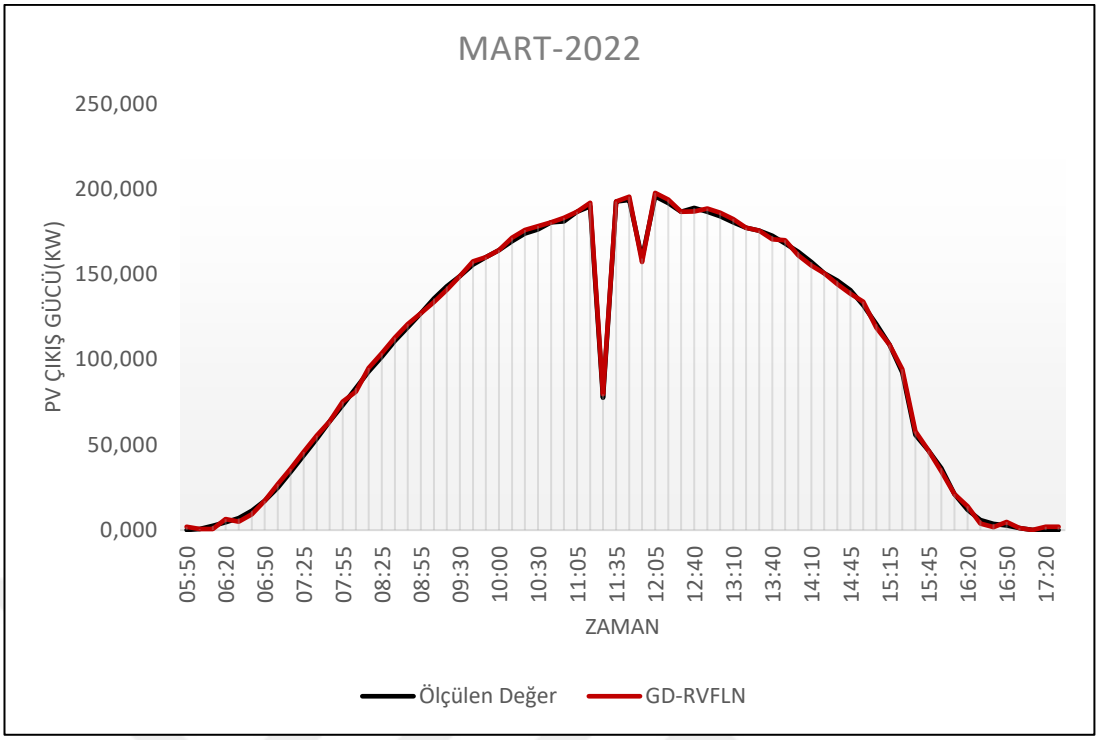
Şekil 4.1 02.04.2022 tarihinde ölçülen gerçek PV çıkış gücü



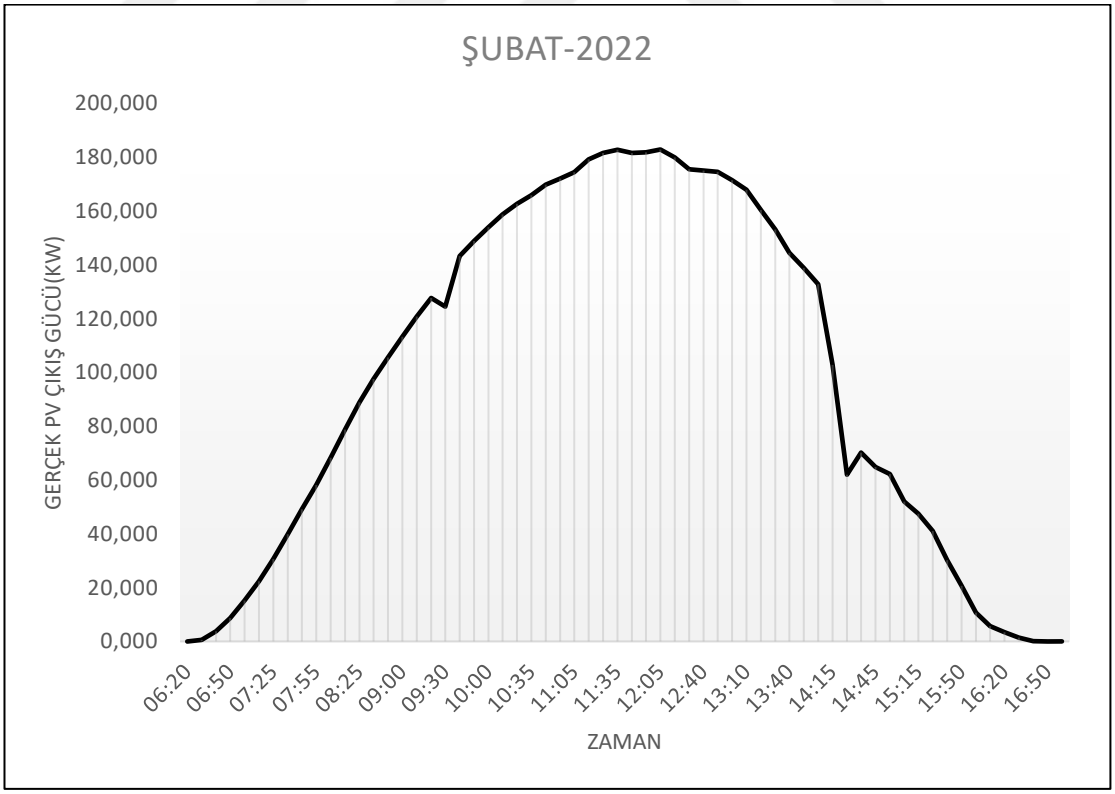
Şekil 4.2 02.04.2022 tarihinde ölçülen gerçek PV çıkış gücü ile GD-RVFLN modelinin tahmin sonucunun karşılaştırması



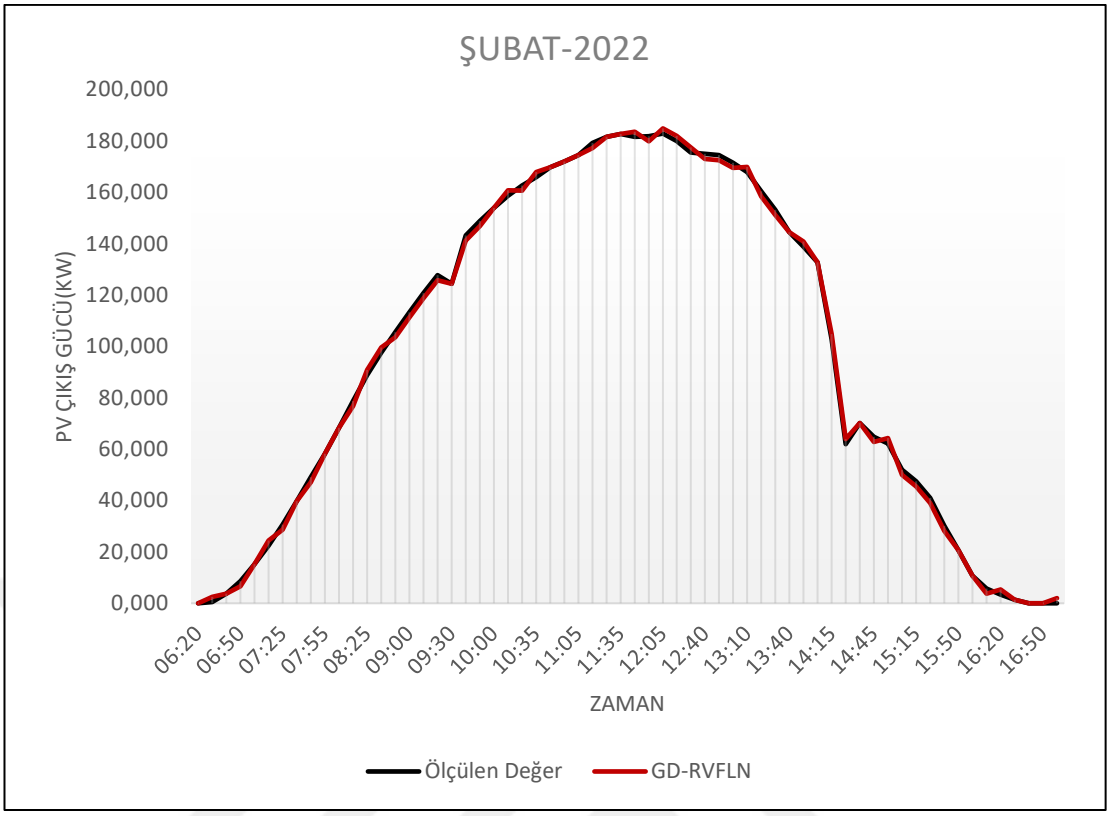
Şekil 4.3 02.03.2022 tarihinde ölçülen gerçek PV çıkış gücü



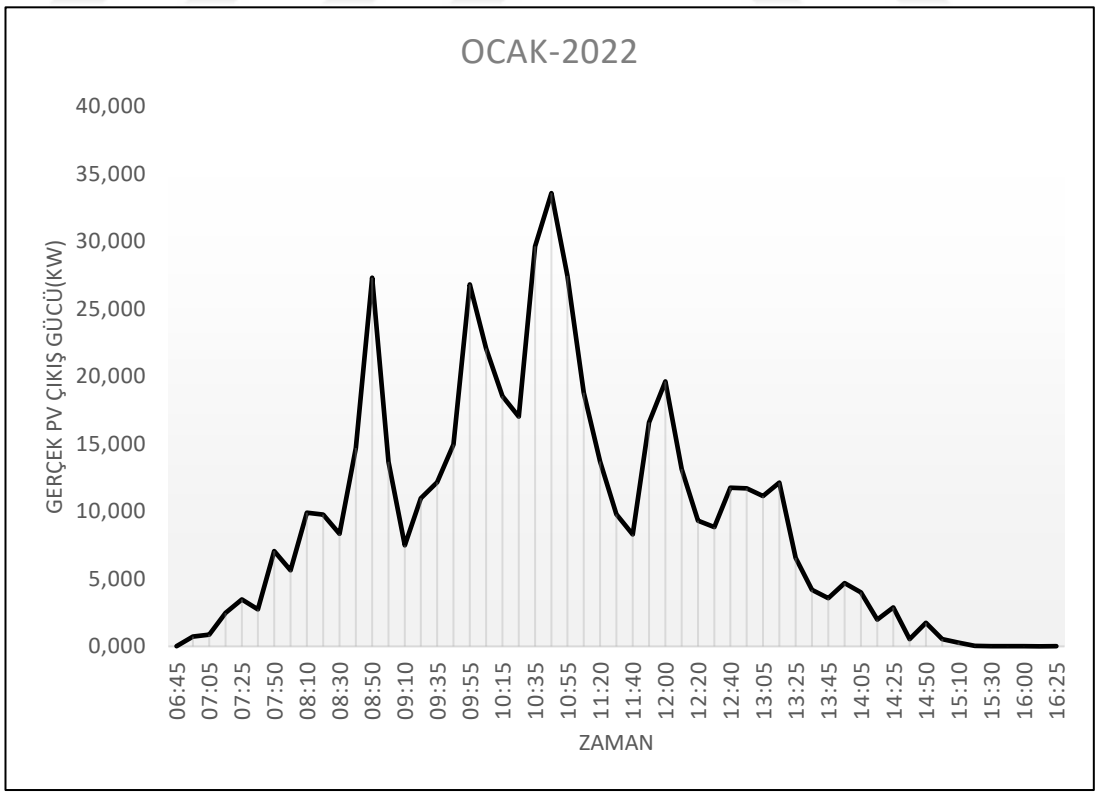
Şekil 4.4 02.03.2022 tarihinde ölçülen gerçek PV çıkış gücü ile GD-RVFLN modelinin tahmin sonucunun karşılaştırması



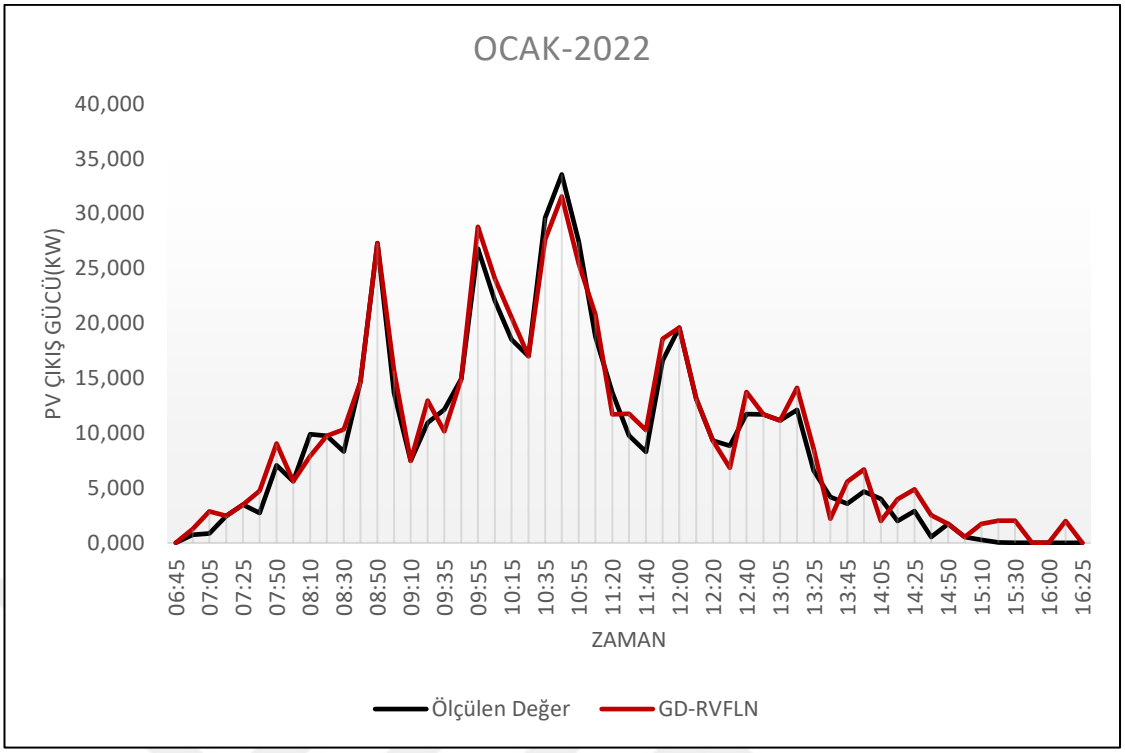
Şekil 4.5 02.02.2022 tarihinde ölçülen gerçek PV çıkış gücü



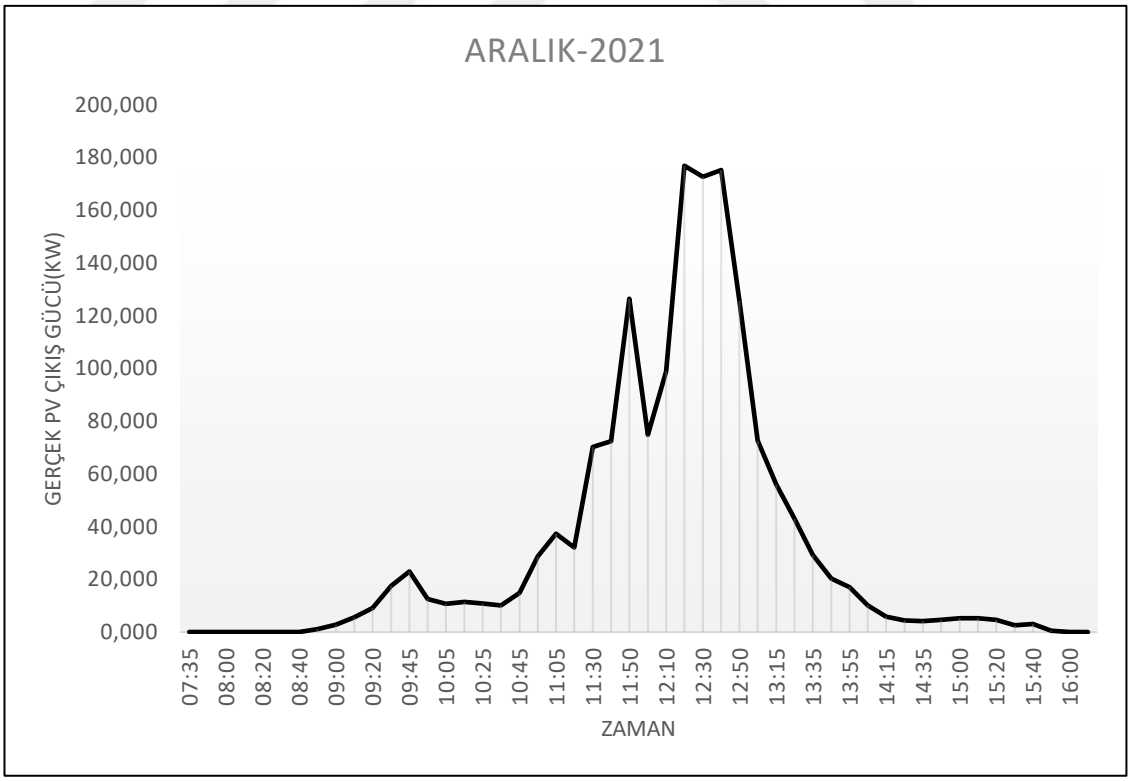
Şekil 4.6 02.02.2022 tarihinde ölçülen gerçek PV çıkış gücü ile GD-RVFLN modelinin tahmin sonucunun karşılaştırması



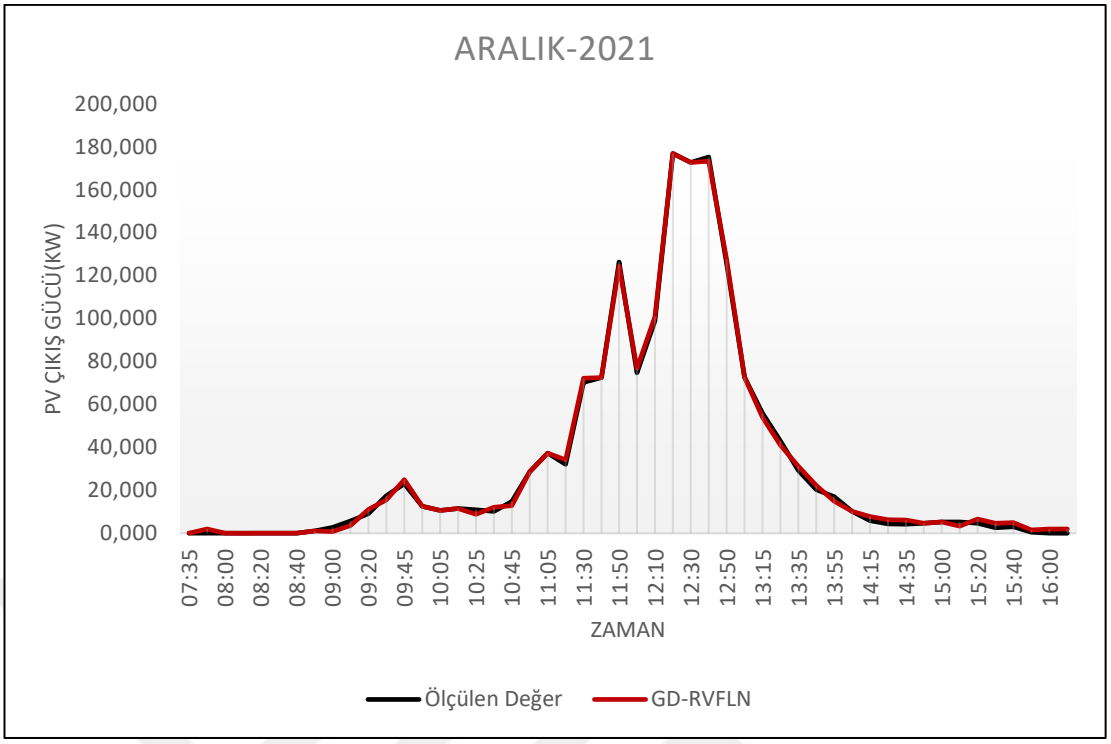
Şekil 4.7 02.01.2022 tarihinde ölçülen gerçek PV çıkış gücü



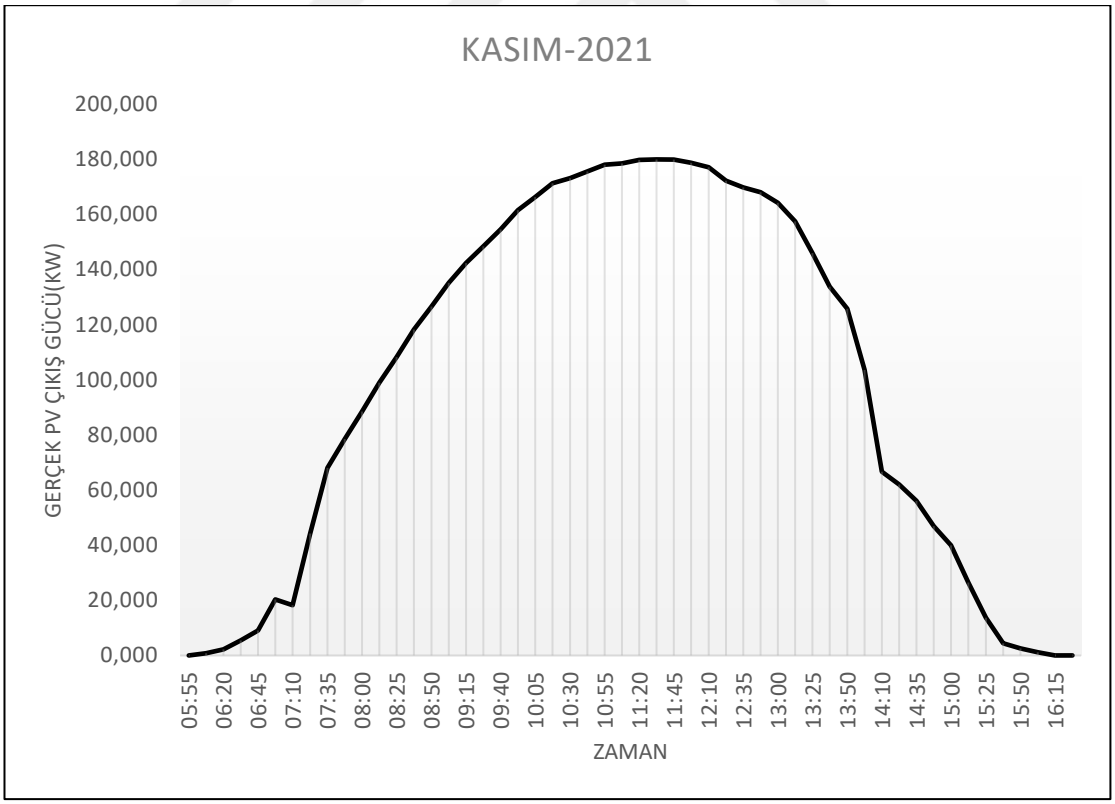
Şekil 4.8 02.01.2022 tarihinde ölçülen gerçek PV çıkış gücü ile GD-RVFLN modelinin tahmin sonucunun karşılaştırması



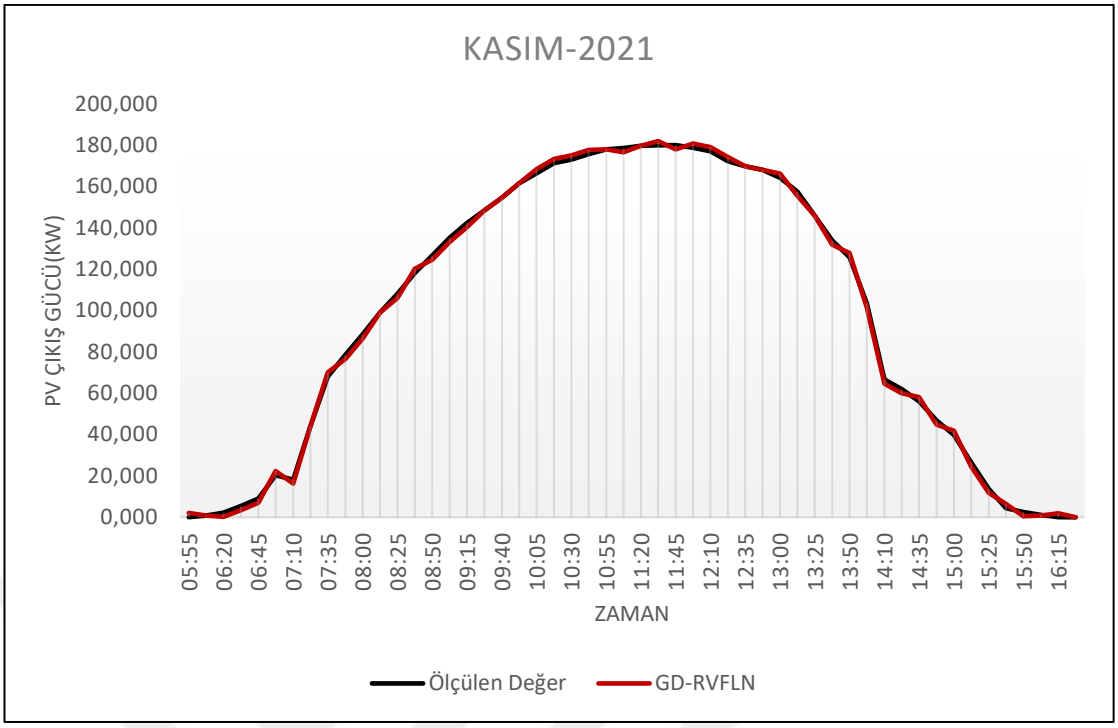
Şekil 4.9 02.12.2021 tarihinde ölçülen gerçek PV çıkış gücü



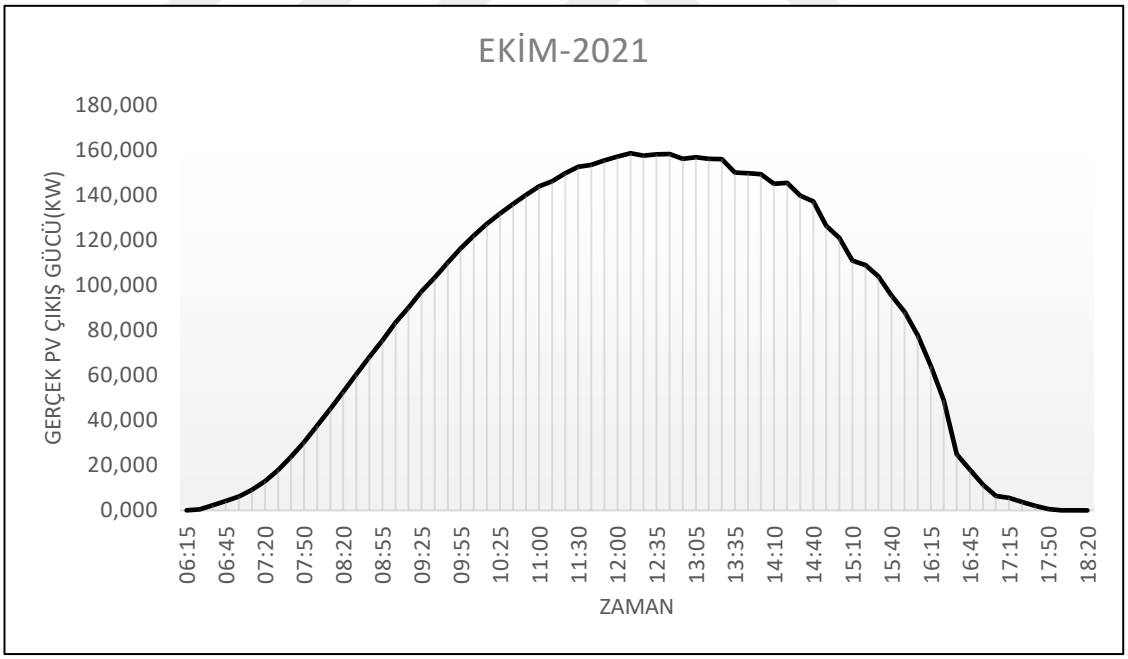
Şekil 4.10 02.12.2021 tarihinde ölçülen gerçek PV çıkış gücü ile GD-RVFLN modelinin tahmin sonucunun karşılaştırması



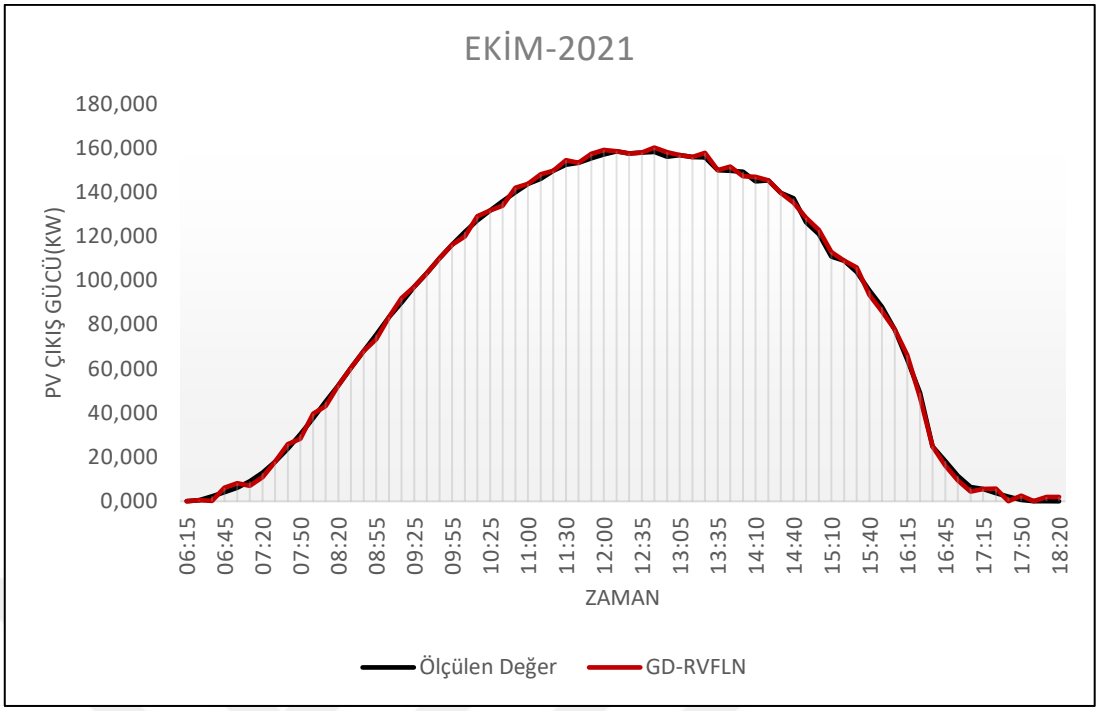
Şekil 4.11 02.11.2021 tarihinde ölçülen gerçek PV çıkış gücü



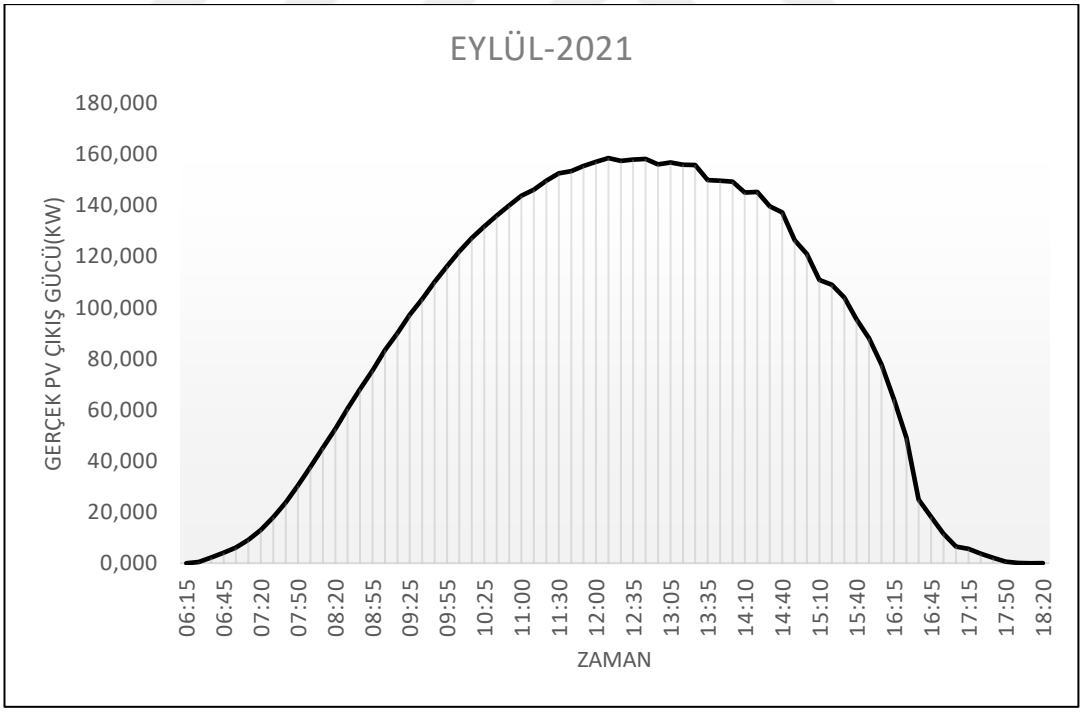
Şekil 4.12 02.11.2021 tarihinde ölçülen gerçek PV çıkış gücü ile GD-RVFLN modelinin tahmin sonucunun karşılaştırması



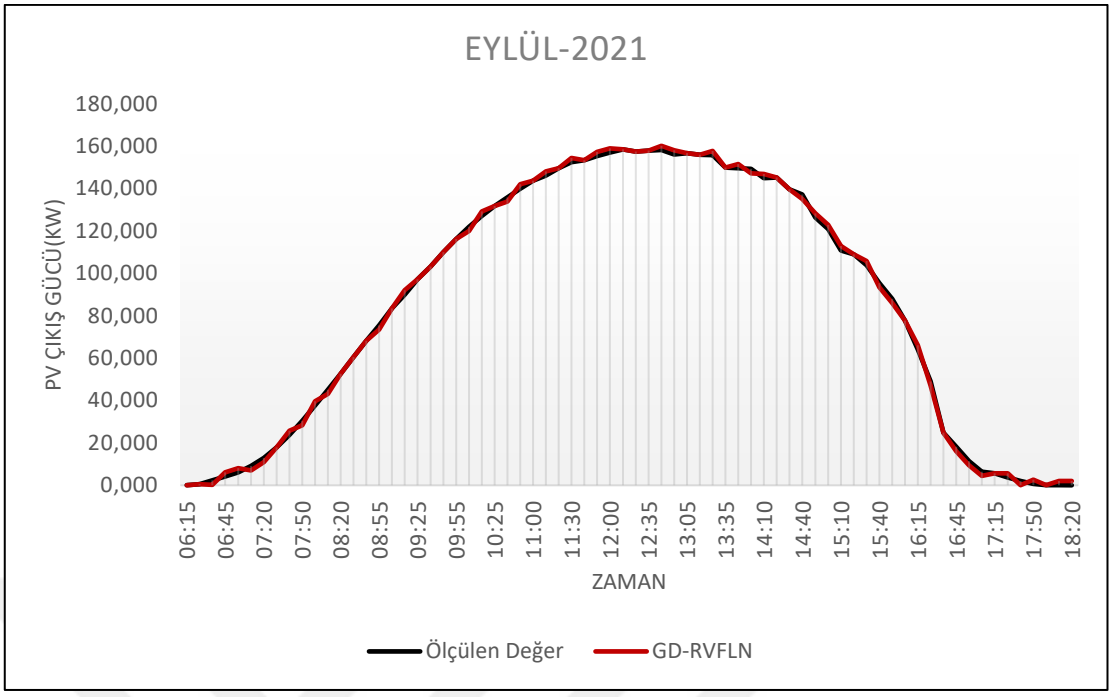
Şekil 4.13 02.10.2021 tarihinde ölçülen gerçek PV çıkış gücü



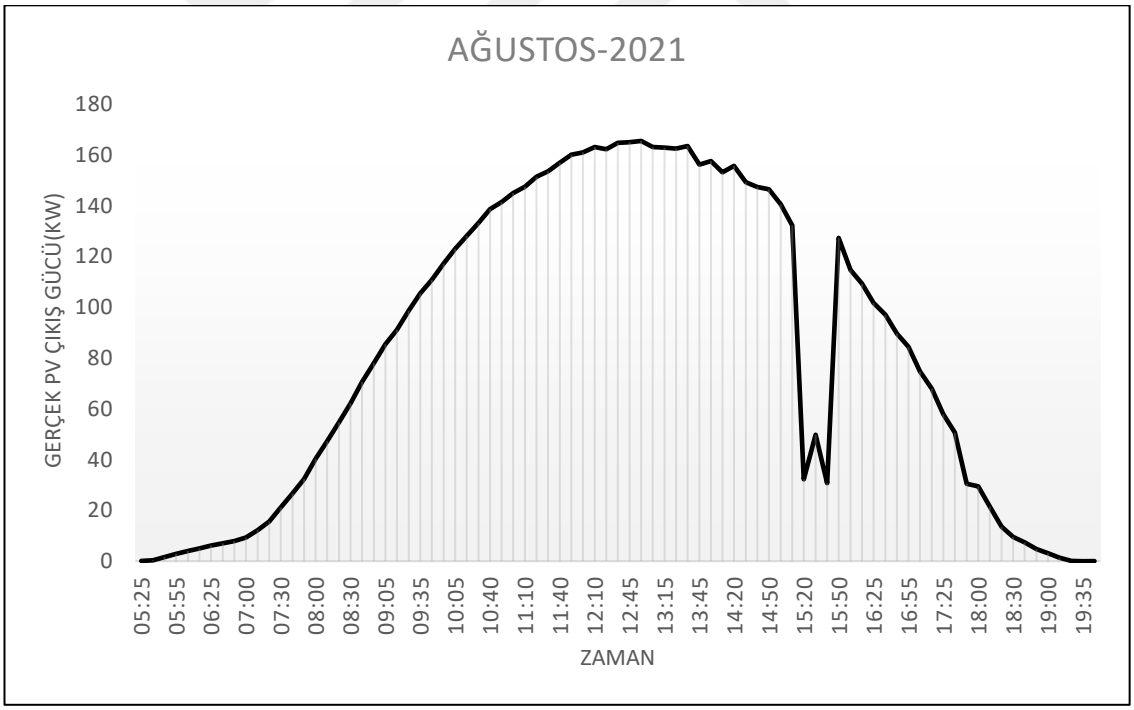
Şekil 4.14 02.10.2021 tarihinde ölçülen gerçek PV çıkış gücü ile GD-RVFLN modelinin tahmin sonucunun karşılaştırması



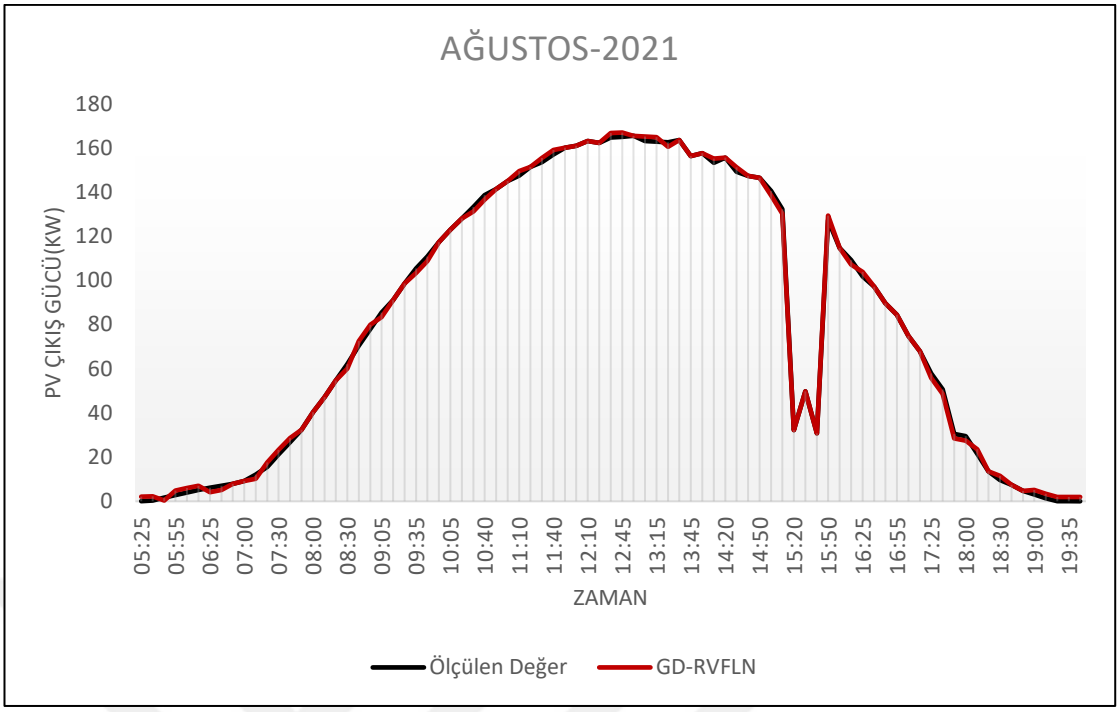
Şekil 4.15 02.09.2021 tarihinde ölçülen gerçek PV çıkış gücü



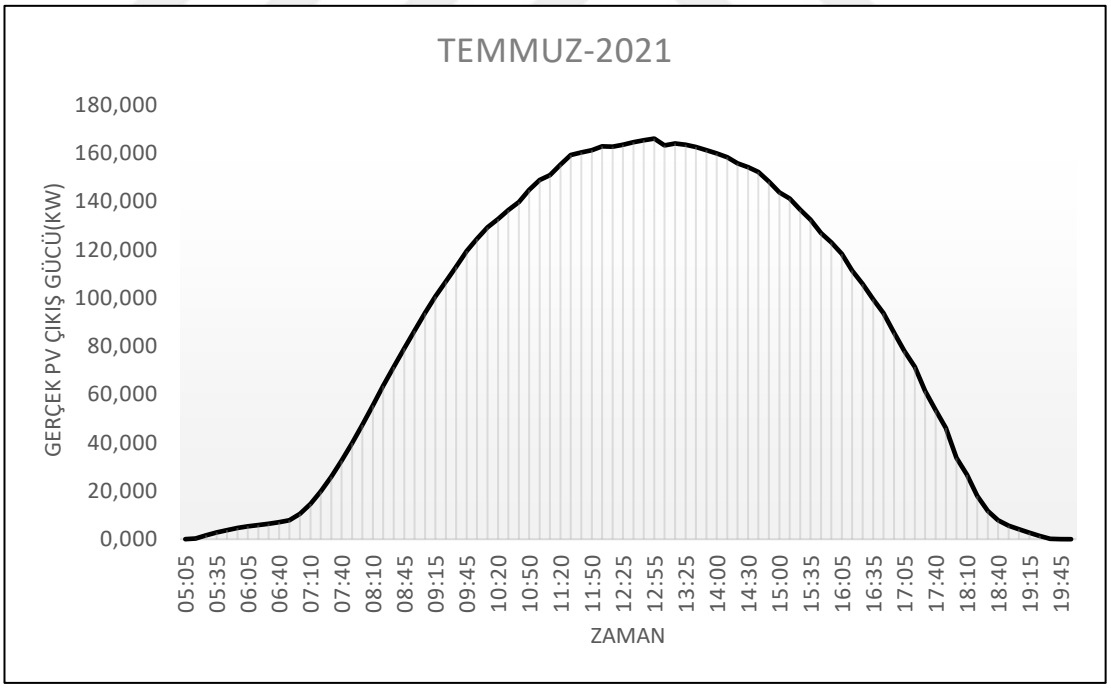
Şekil 4.16 02.09.2021 tarihinde ölçülen gerçek PV çıkış gücü ile GD-RVFLN modelinin tahmin sonucunun karşılaştırması



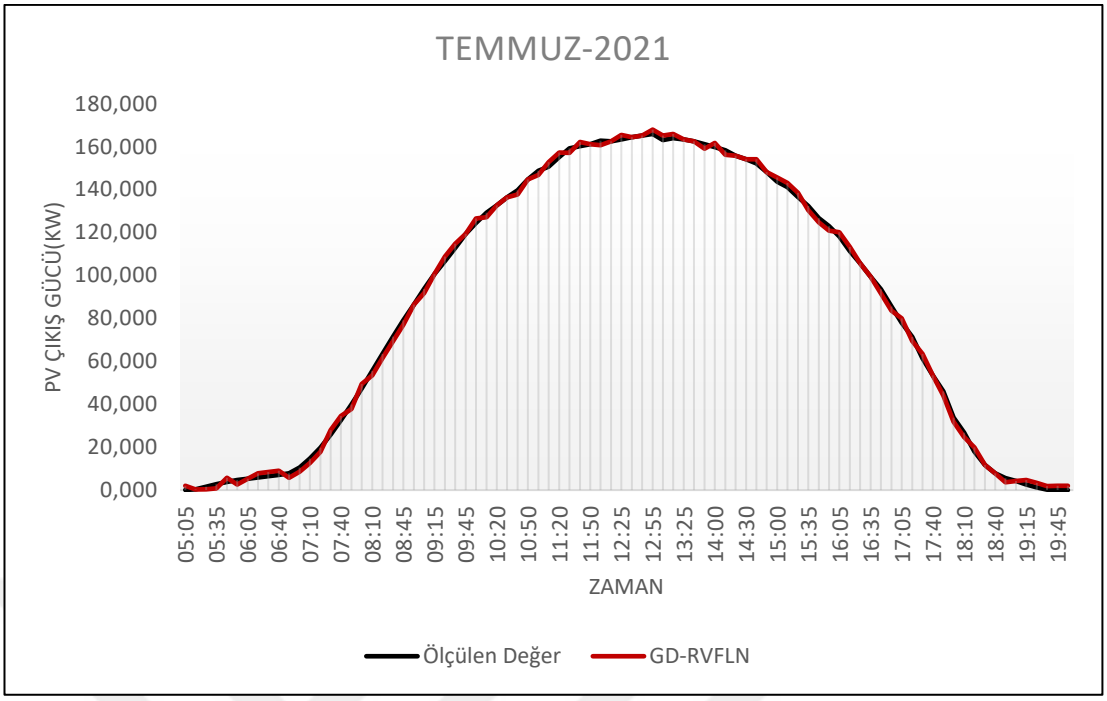
Şekil 4.17 02.08.2021 tarihinde ölçülen gerçek PV çıkış gücü



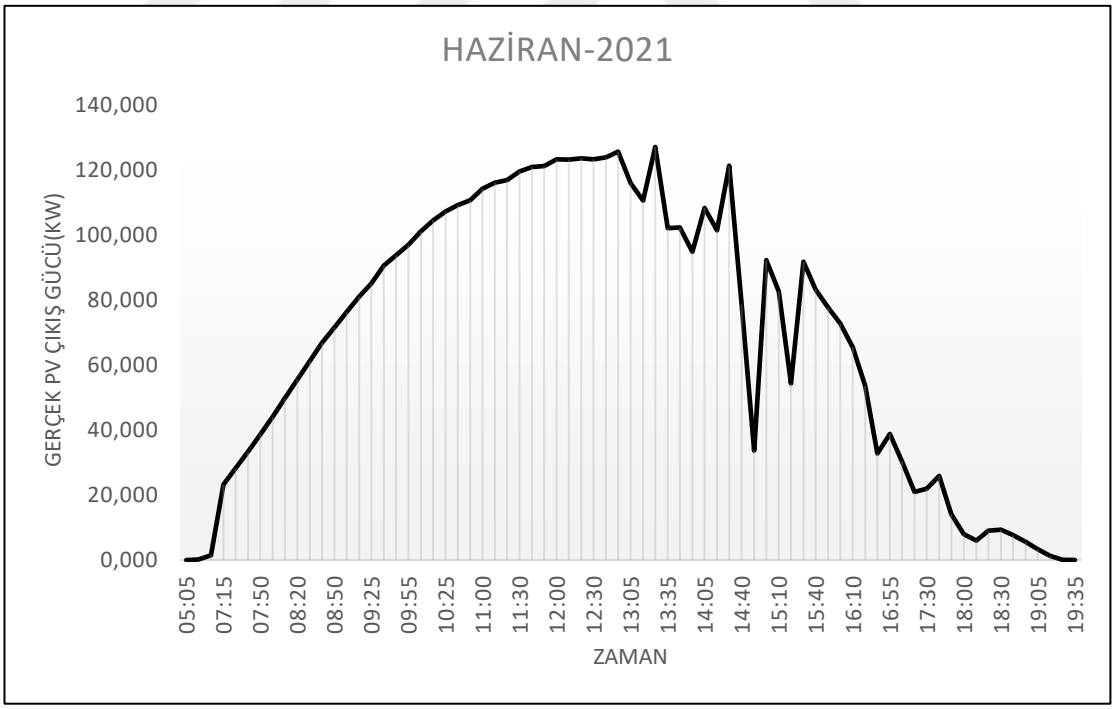
Şekil 4.18 02.08.2021 tarihinde ölçülen gerçek PV çıkış gücü ile GD-RVFLN modelinin tahmin sonucunun karşılaştırması



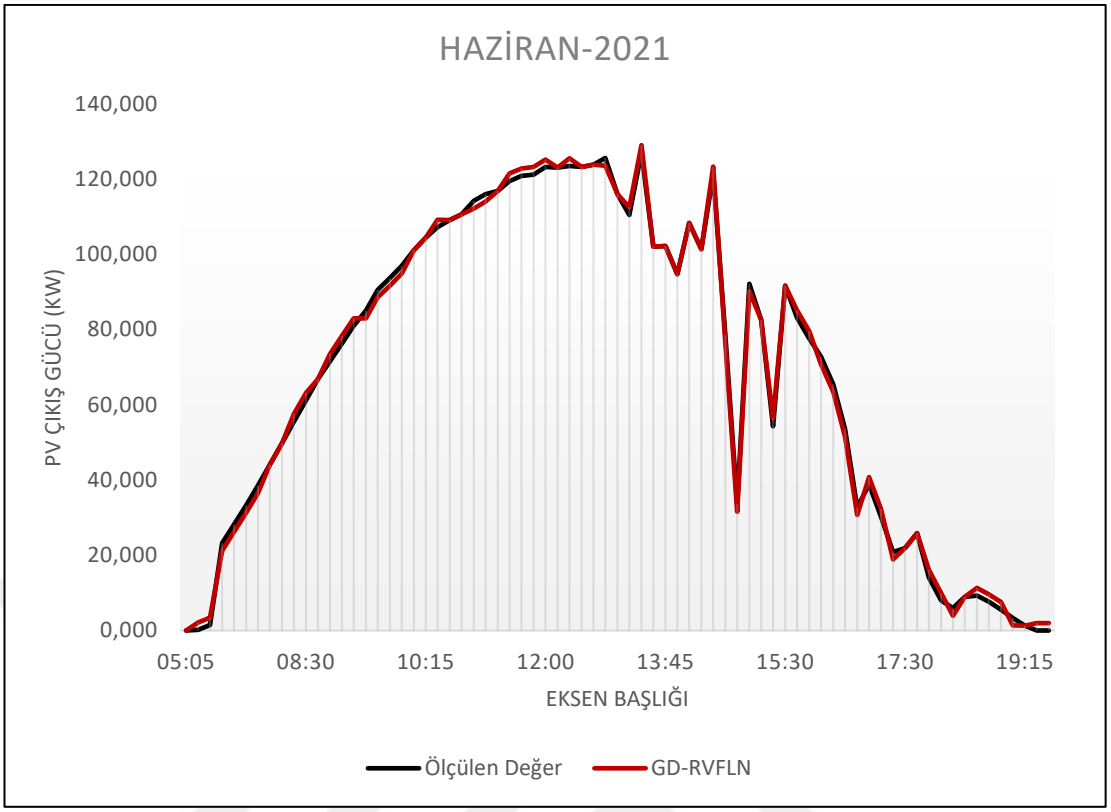
Şekil 4.19 02.07.2021 tarihinde ölçülen gerçek PV çıkış gücü



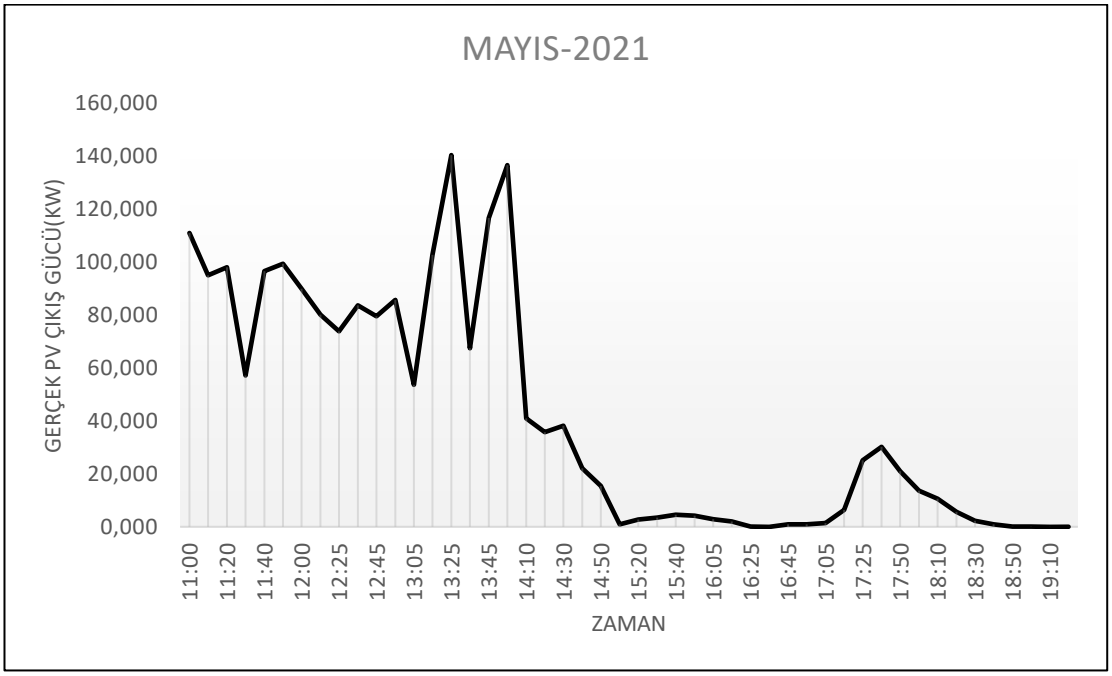
Şekil 4.20 02.07.2021 tarihinde ölçülen gerçek PV çıkış gücü ile GD-RVFLN modelinin tahmin sonucunun karşılaştırması



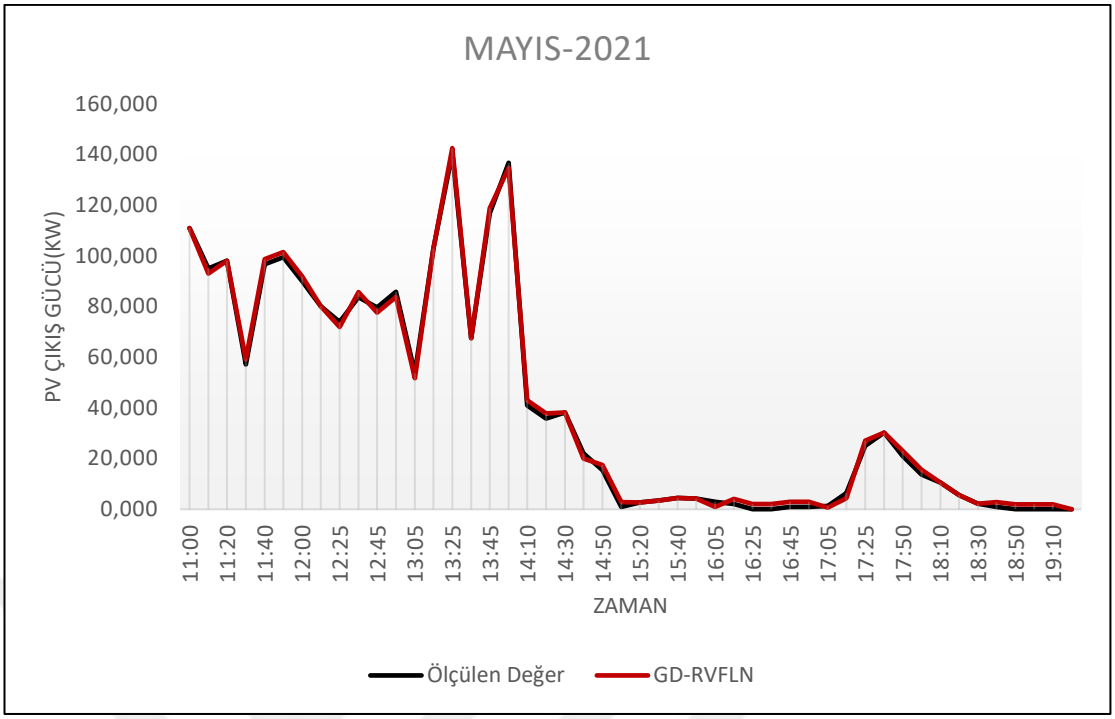
Şekil 4.21 02.06.2021 tarihinde ölçülen gerçek PV çıkış gücü



Şekil 4.22 02.06.2021 tarihinde ölçülen gerçek PV çıkış gücü ile GD-RVFLN modelinin tahmin sonucunun karşılaştırması



Şekil 4.23 02.05.2021 tarihinde ölçülen gerçek PV çıkış gücü

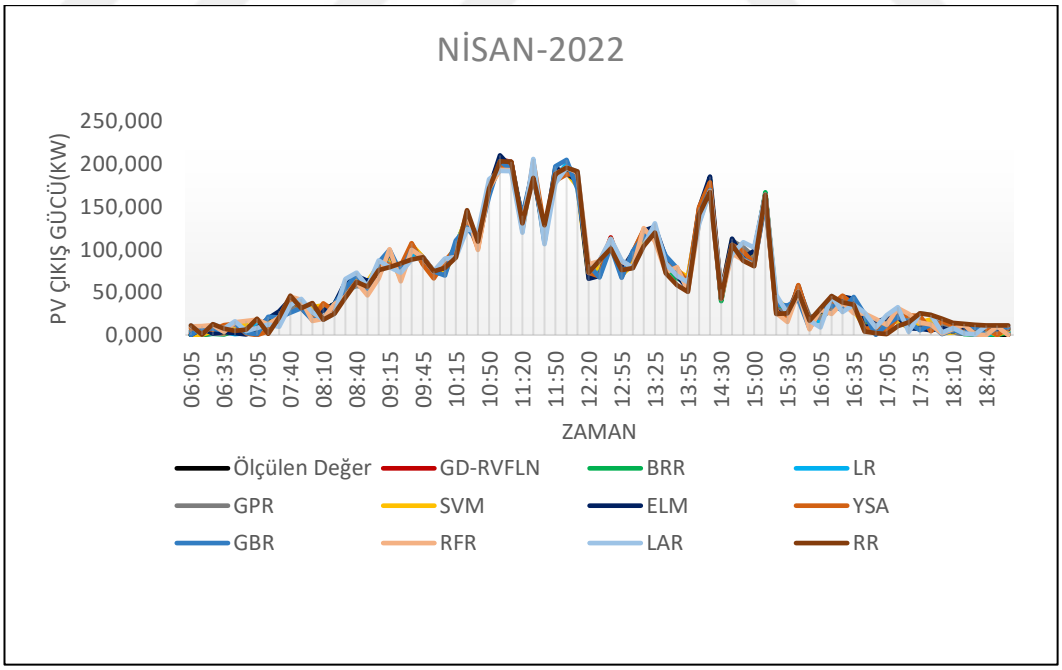


Şekil 4.24 02.05.2021 tarihinde ölçülen gerçek PV çıkış gücü ile GD-RVFLN modelinin tahmin sonucunun karşılaştırması

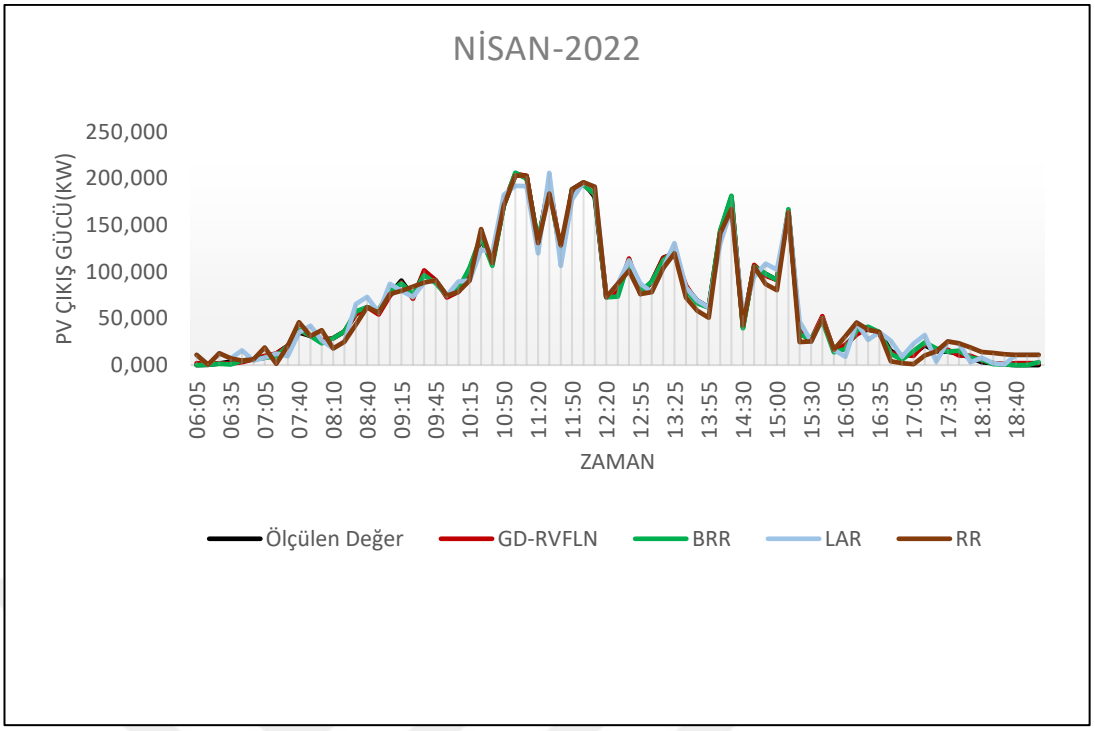
Yukarıdaki şekillerde görüldüğü üzere önerilen GD-RVFLN modeli gerçek PV çıkış gücü ile yüksek doğrulukta performans göstermiştir. Şekillere bakıldığında bazı aylar arasında ölçüm sonuçlarında uyumsuzluk görülmektedir. Örneğin, şekil 4.6 ile şekil 4.8'e bakıldığında, Ocak 2022 de modelin tahmin doğruluğu OMYH=9,76 iken, Şubat 2022'deki doğruluk değeri, OMYH=1,68 çıkmıştır. Şekil 4.8'deki grafiğe bakıldığında grafikte PV çıkış gücünde inişler çıkışlar görülmektedir ayrıca o gün PV çıkış gücünün en yüksek değeri yaklaşık 35 kW'tır. PV sistemleri büyük oranda meteorolojik koşullara bağımlıdır. Havanın bulutlu ya da yağmurlu olduğu günlerde PV çıkış gücü ya hiç üretilmemekte ya da düşük değerler üretmektedir bu da PV çıkış güç çıkışında iniş ve çıkışlara neden olmaktadır. Şekil 4.8'deki grafiğin inişli çıkışlı olmasının nedeni de bu durumdan kaynaklanmaktadır. Bu yüzden Ocak 2022 ile Şubat 2022 arasındaki tahmin sonuçların farkının yüksek olmasının nedeni Ocak ayının 2'sinde yaşanan hava durumunun tutarsızlığından kaynaklanmaktadır. Buna rağmen havanın kararsız olduğu günlerde bile GD-RVFLN modeli 0≤ OMYH ≤10 aralığında kalmaya devam ederek gerçek PV çıkış gücüyle yüksek benzerlik göstermiştir.

4.3 GD-RVFLN Modeli ile 10 Modelin Tahmin Sonuçlarının Karşılaştırılması

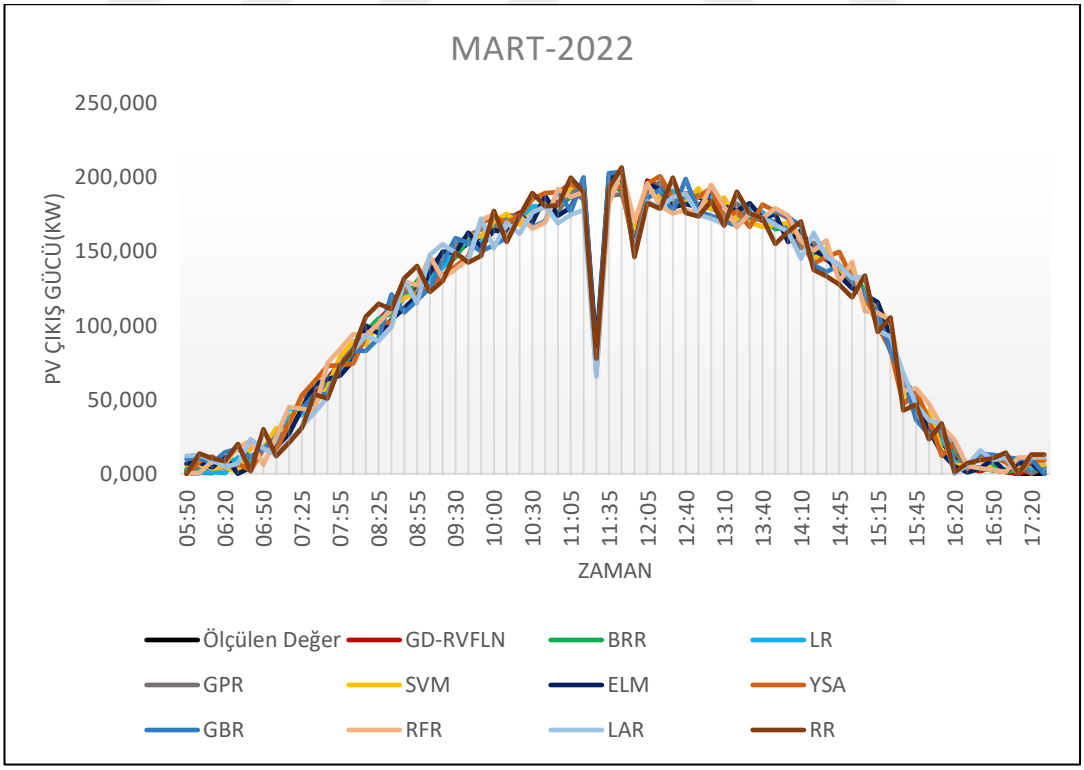
Bu tezde önerilen GD-RVFLN tahmin modelinin performans doğruluğunu göstermek için GD-RVFLN modeli, on farklı makine öğrenimi modeller ile karşılaştırılmıştır. Her ayın 2'sinde 11 modelin tümünün karşılaştırma sonuçlarının şekil çizgileri karmaşık görüntüye neden olduğu göz önüne alındığında, ayrıca şekillerde yalnızca en iyi performans gösteren model ile kötü performans gösteren modellerin performansları gösterilmiştir. Şekil 4.25'den şekil 4.48' e kadar olan şekiller, her ayın 2'sindeki 11 modelin tümünün tahmini PV çıkış gücü karşılaştırma sonuçları ile en iyi ve nispeten daha kötü performans gösteren modellerin tahmin sonuçlarını göstermektedir. Her ayın 2'si için 11 modelin performans hataları (OMYH ve OKH) Tablo 4.2 ve Tablo 4.3 'te gösterilmiştir. Şekillerde, her bir modelin performansı belirli bir zaman diliminde iyi performans gösterdiği görülmektedir. Tablo 4.2 ve Tablo 4.3'teki OMYH ve OKH verilere göre GD-RVFLN ve BRR makine öğrenimi modelleri diğer makine öğrenimi modellere göre daha iyi performansa sahip olduğu göstermektedir. Ayrıca Tablo 4.2 ve Tablo 4.3'teki sonuçlara büyük ölçüde istikrarsızlık gösteren en kötü performansa sahip modellerin ise GBR, RFR, LAR, RR olduğu görülmüştür.



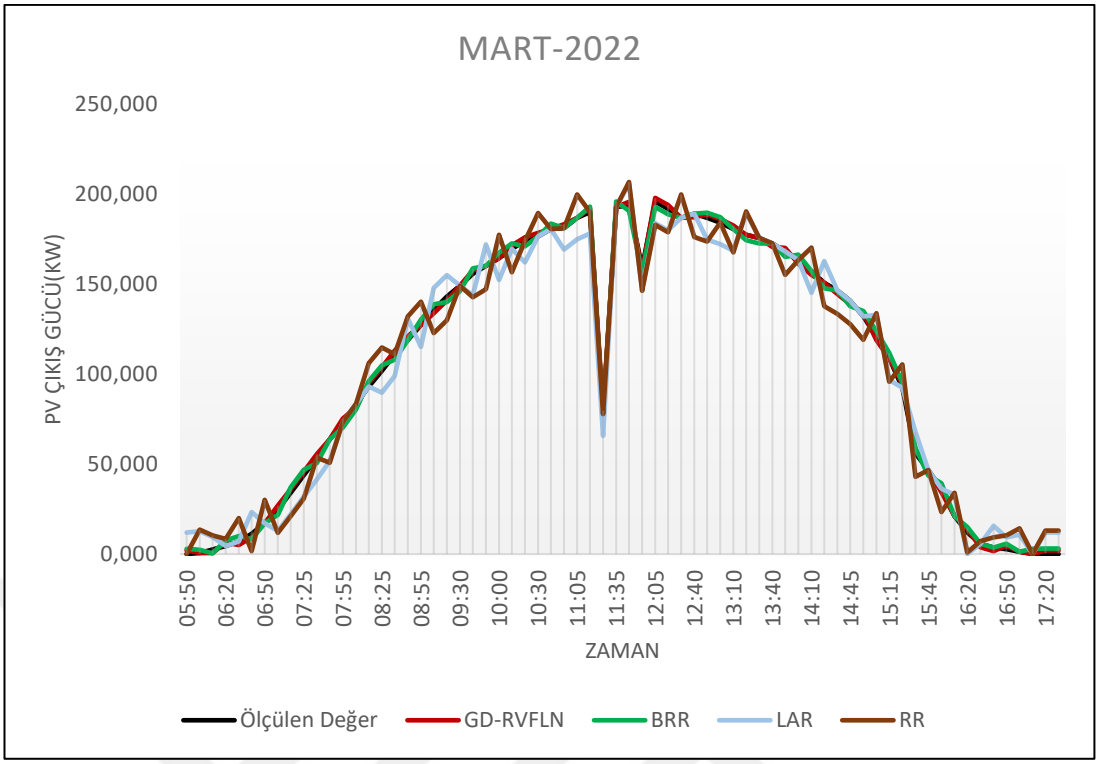
Şekil 4.25 02.04.2022 tarihindeki tüm modellerin tahmin sonuçları



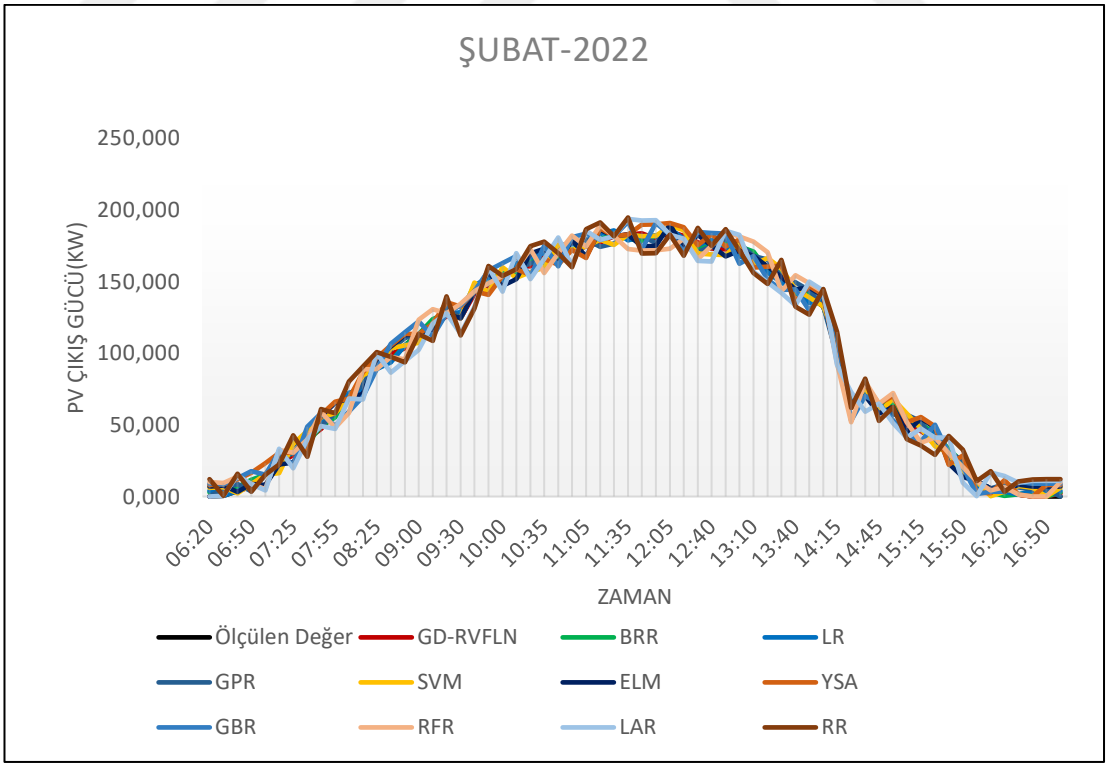
Şekil 4.26 02.04.2022 tarihinde en iyi performans ile en kötü performans gösteren modellerin tahmin sonuçları



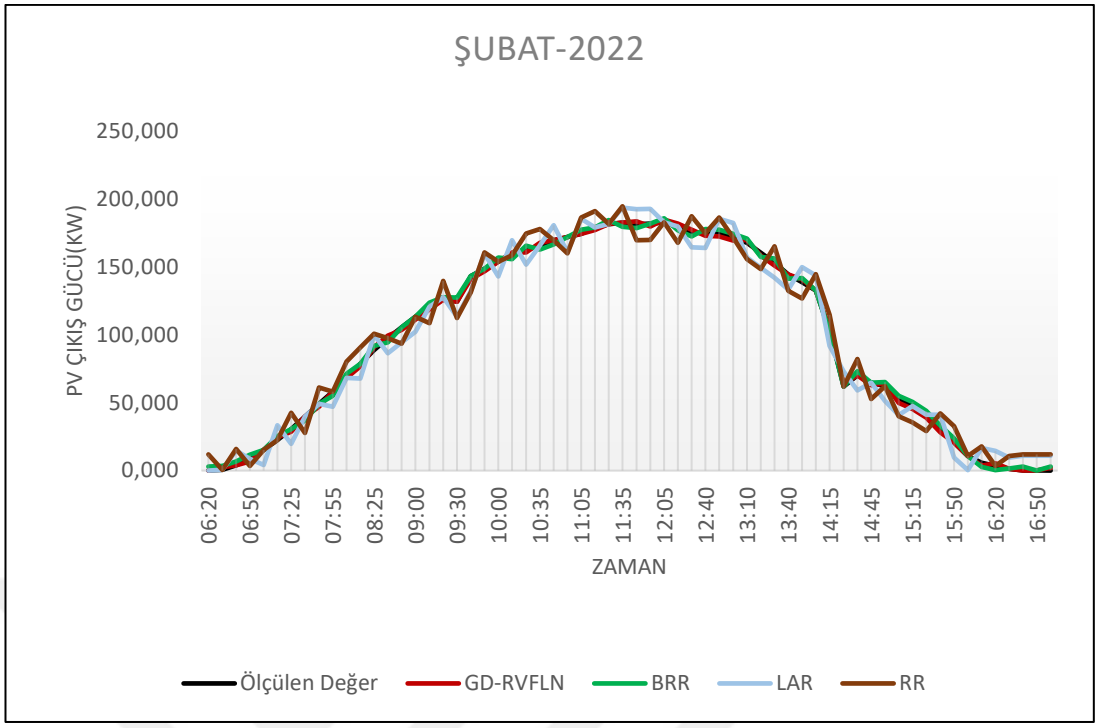
Şekil 4.27 02.03.2022 tarihindeki tüm modellerin tahmin sonuçları



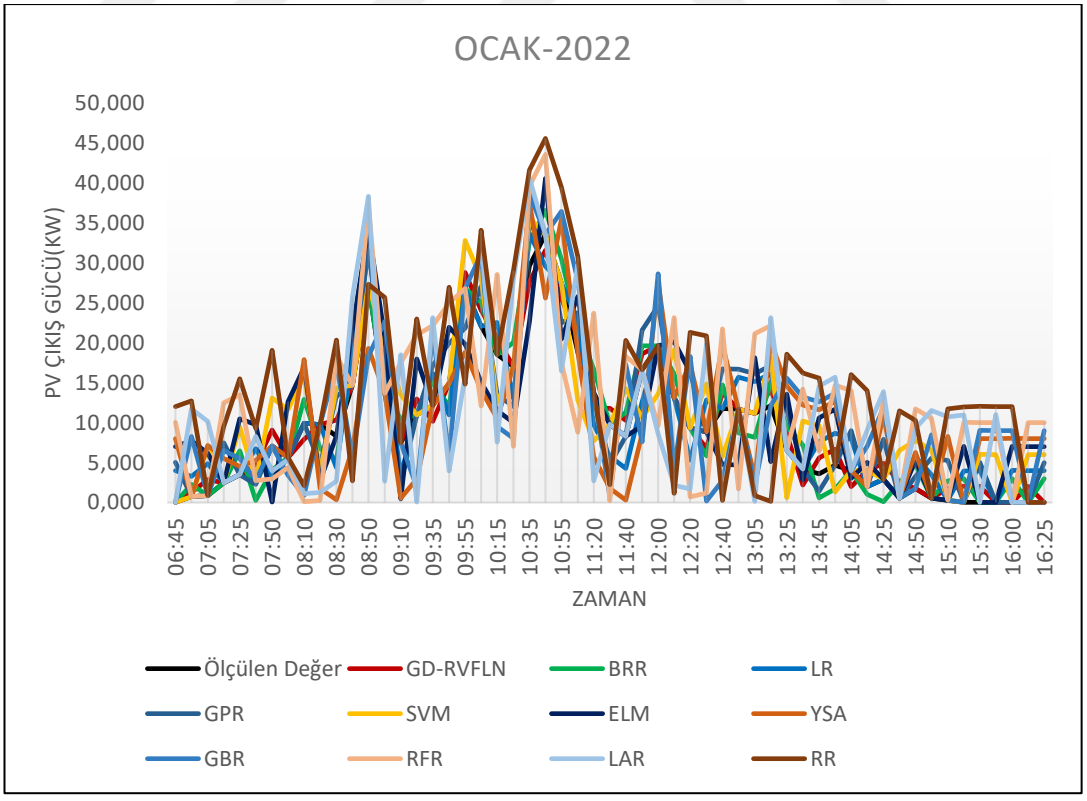
Şekil 4.28 02.03.2022 tarihinde en iyi performans ile en kötü performans gösteren modellerin tahmin sonuçları



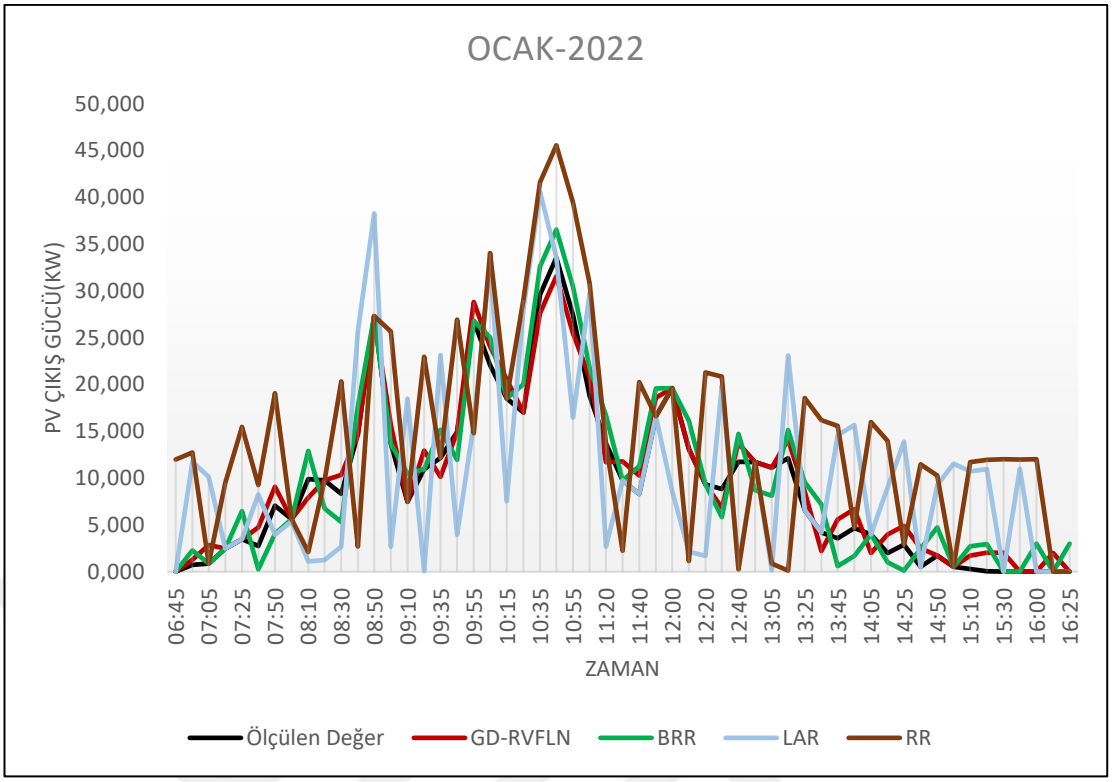
Şekil 4.29 02.02.2022 tarihindeki tüm modellerin tahmin sonuçları



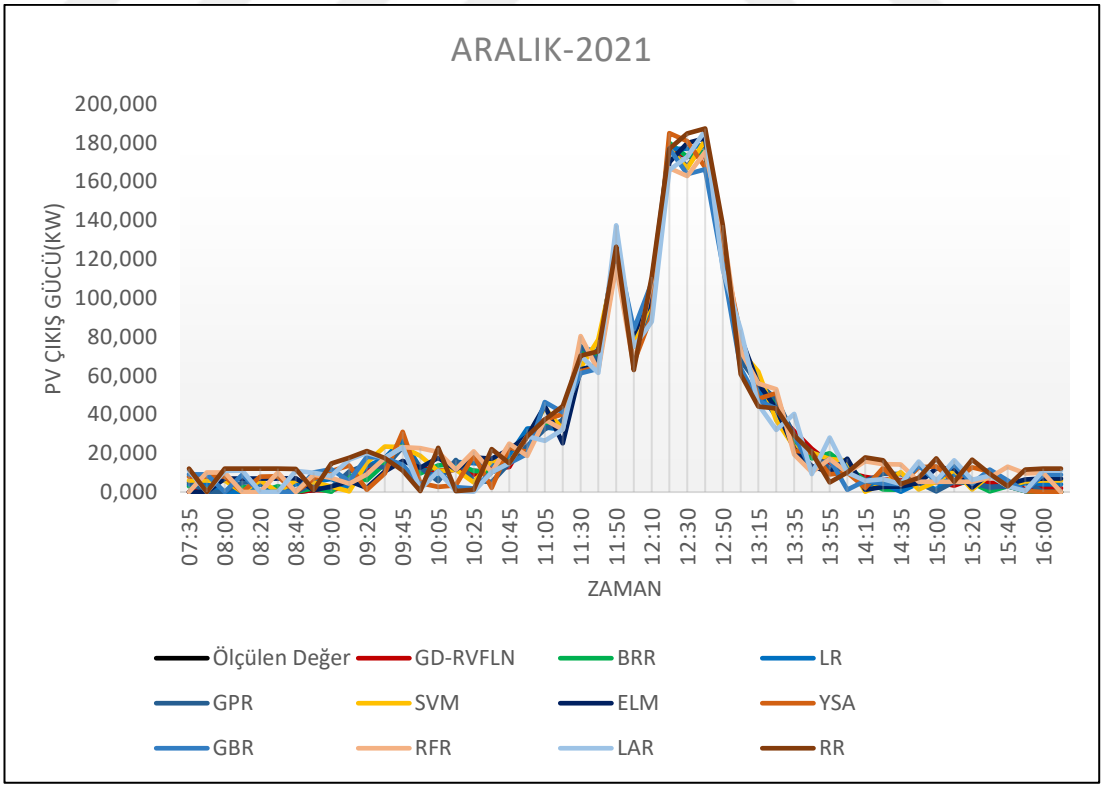
Şekil 4.30 02.03.2022 tarihinde en iyi performans ile en kötü performans gösteren modellerin tahmin sonuçları



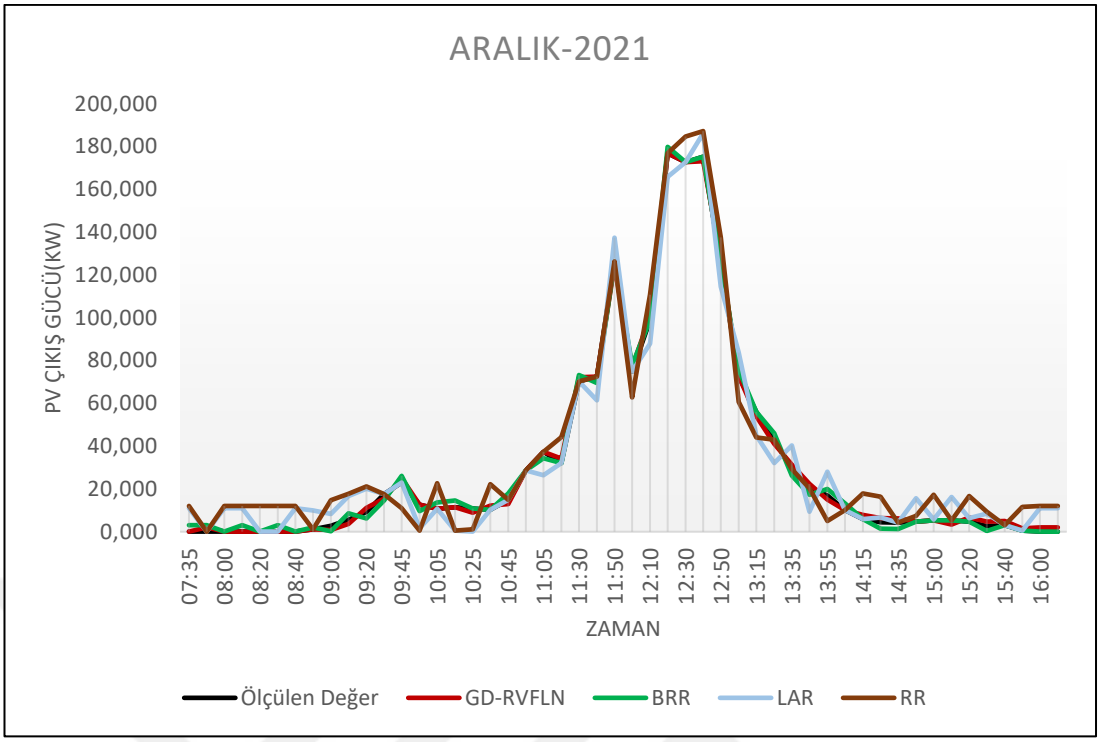
Şekil 4.31 02.01.2022 tarihindeki tüm modellerin tahmin sonuçları



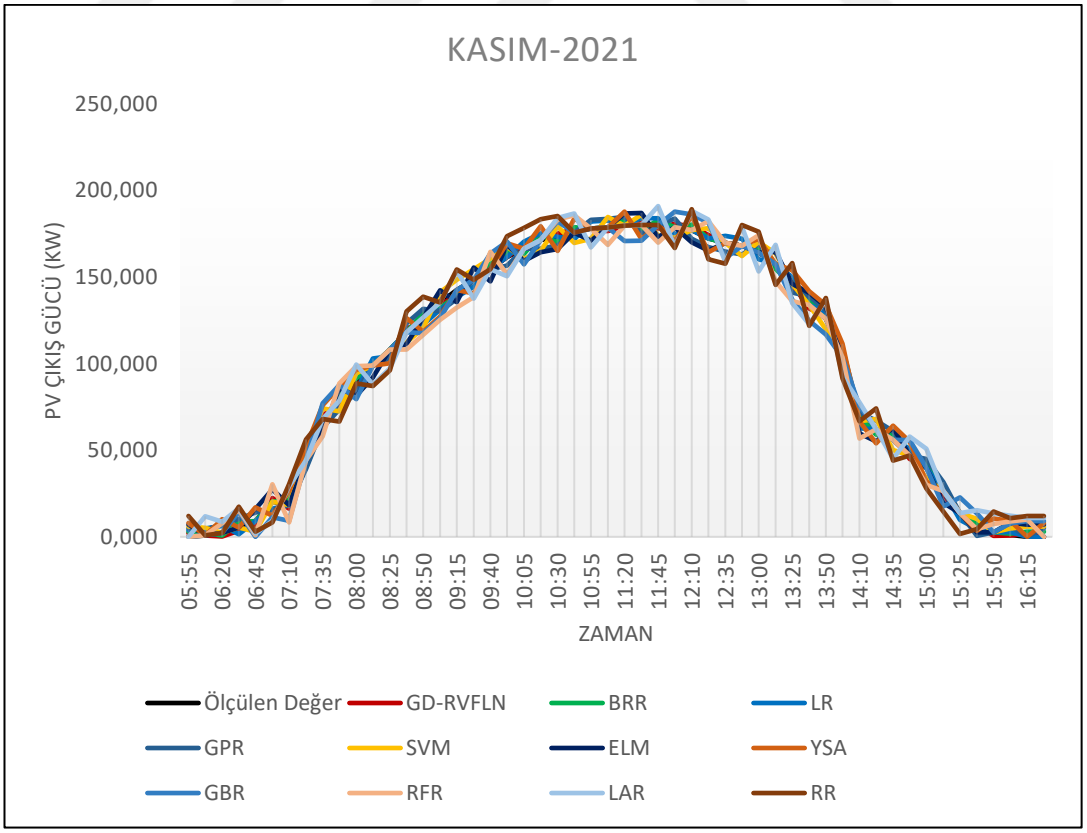
Şekil 4.32 02.01.2022 tarihinde en iyi performans ile en kötü performans gösteren modellerin tahmin sonuçları



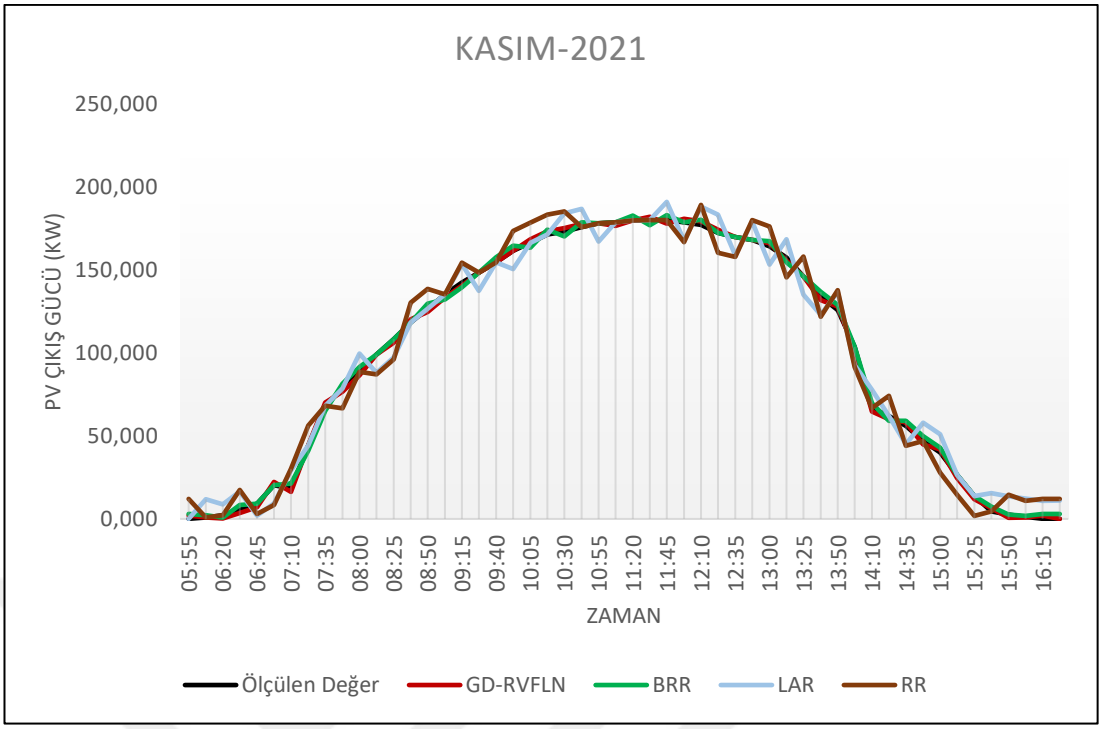
Şekil 4.33 02.12.2021 tarihindeki tüm modellerin tahmin sonuçları



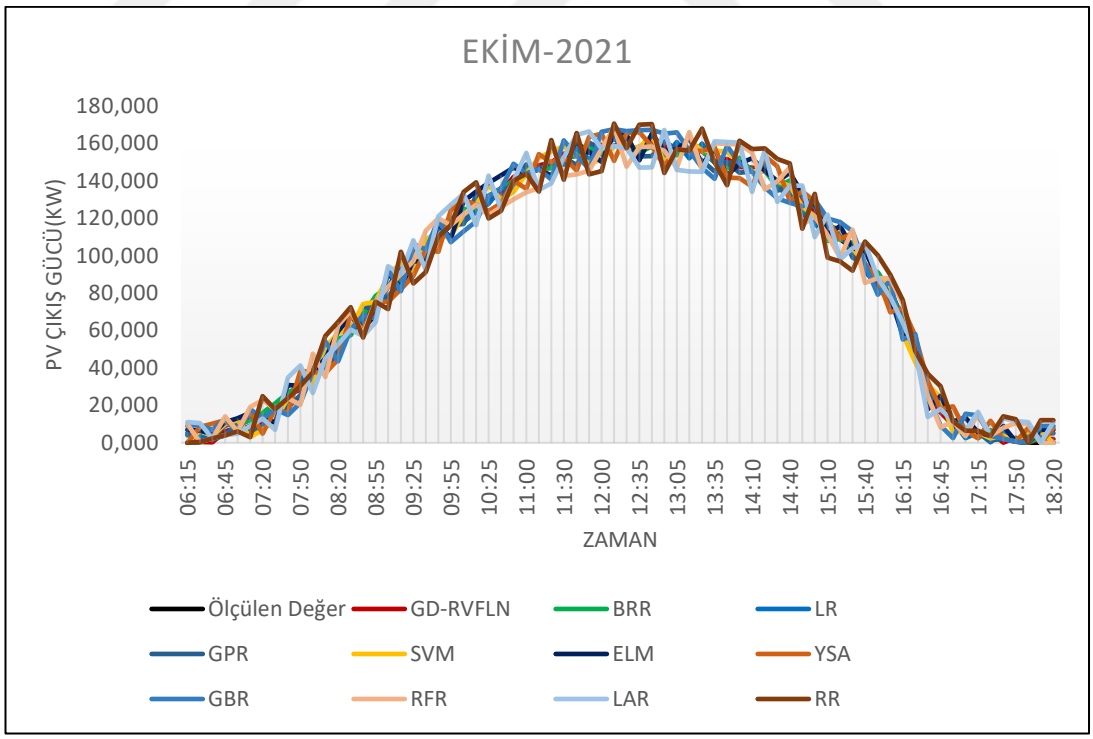
Şekil 4.34 02.12.2021 tarihinde en iyi performans ile en kötü performans gösteren modellerin tahmin sonuçları



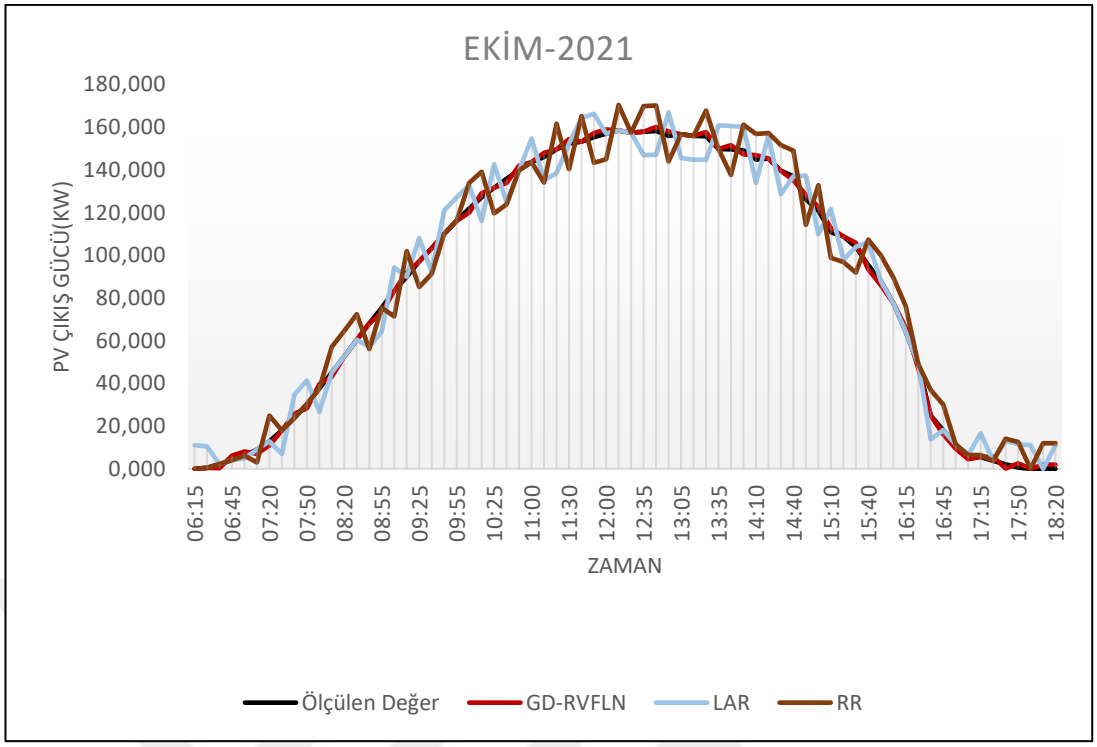
Şekil 4.35 02.11.2021 tarihindeki tüm modellerin tahmin sonuçları



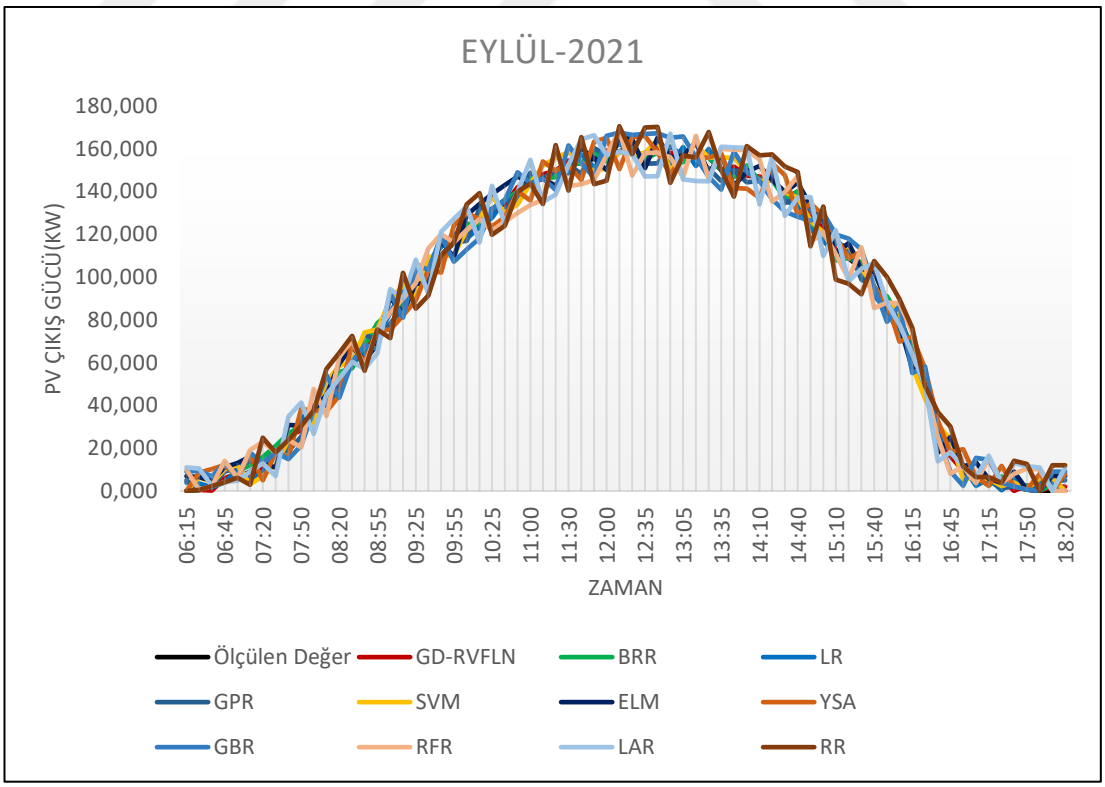
Şekil 4.36 02.11.2021 tarihinde en iyi performans ile en kötü performans gösteren modellerin tahmin sonuçları



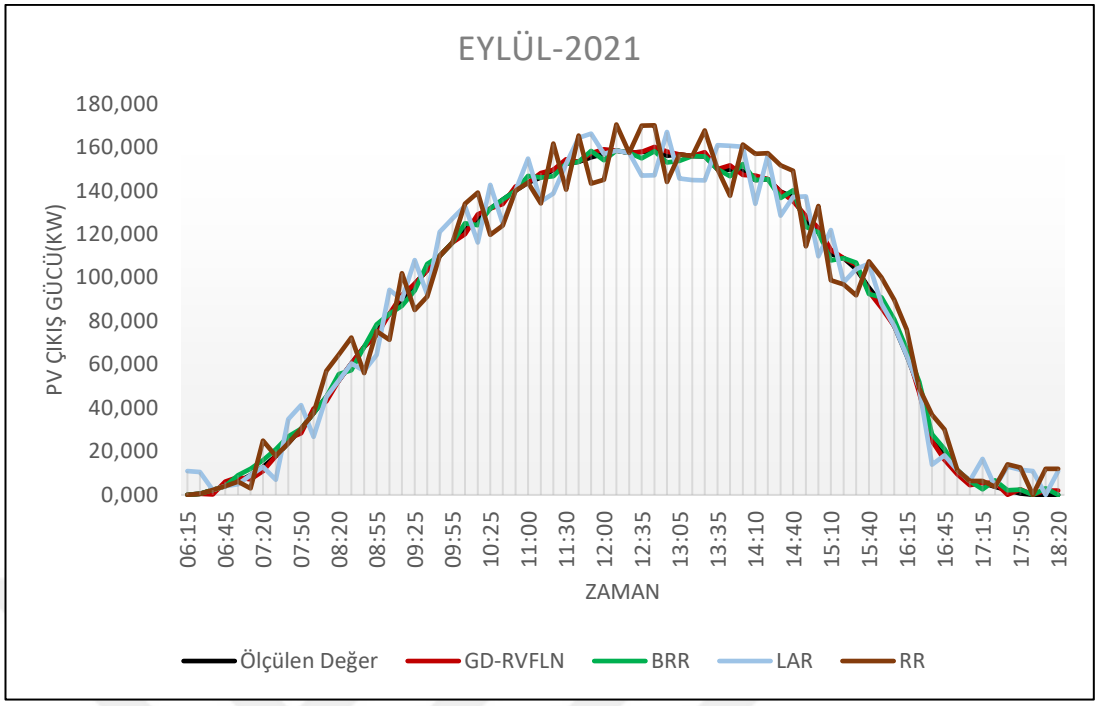
Şekil 4.37 02.10.2021 tarihindeki tüm modellerin tahmin sonuçları



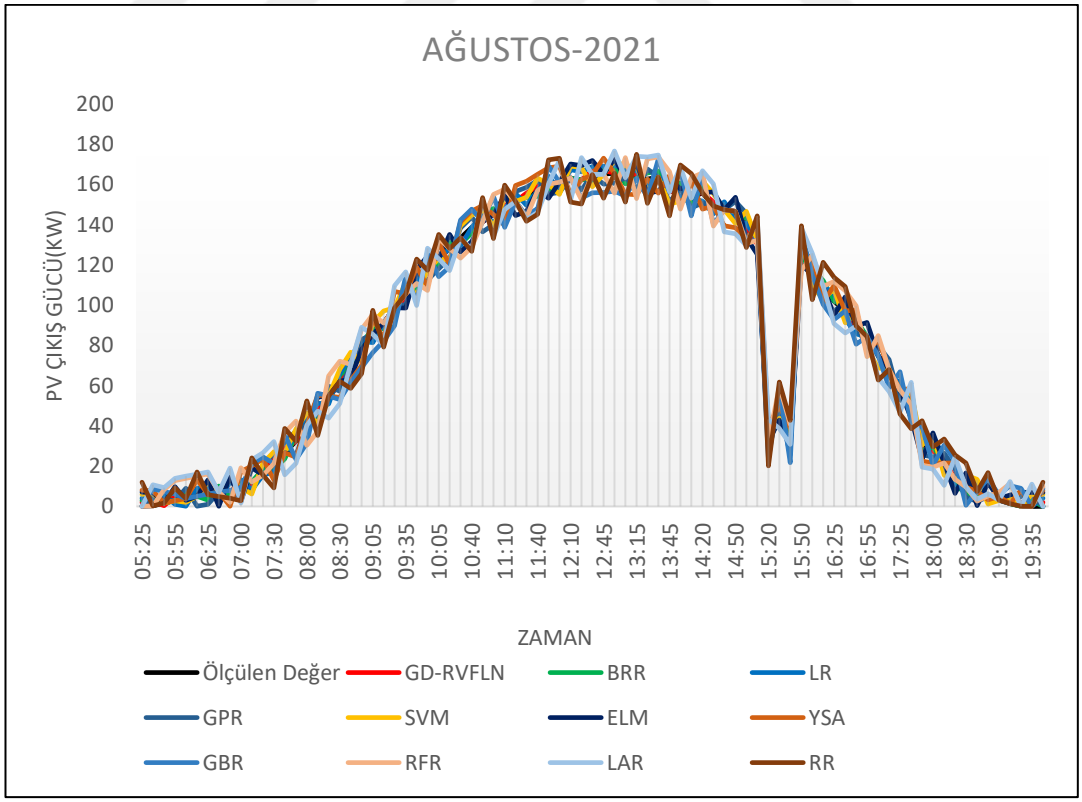
Şekil 4.38 02.10.2021 tarihinde en iyi performans ile en kötü performans gösteren modellerin tahmin sonuçları



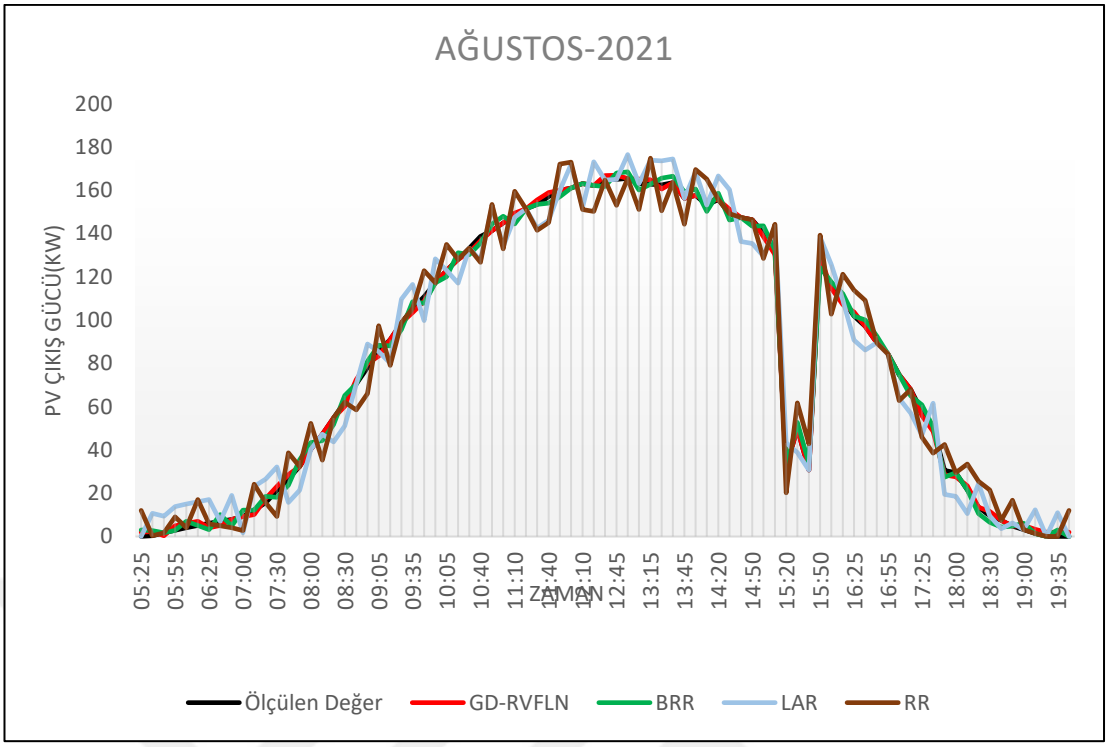
Şekil 4.39 02.09.2021 tarihindeki tüm modellerin tahmin sonuçları



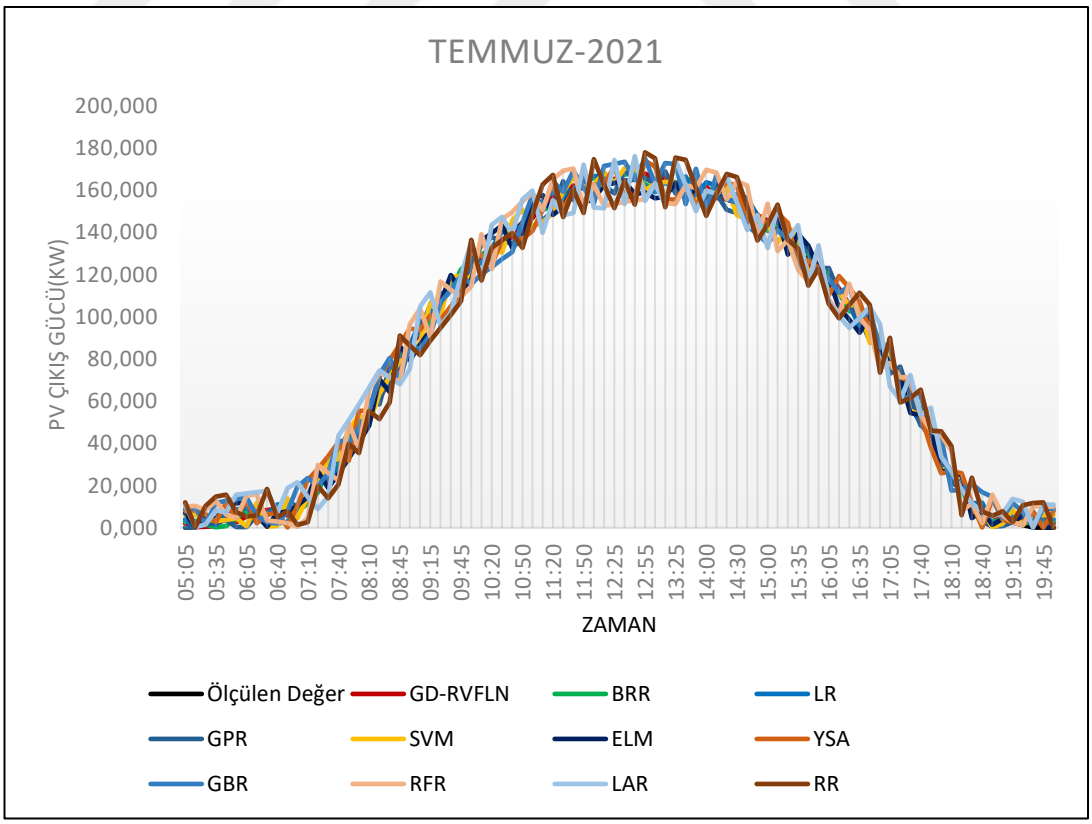
Şekil 4.40 02.09.2021 tarihinde en iyi performans ile en kötü performans gösteren modellerin tahmin sonuçları



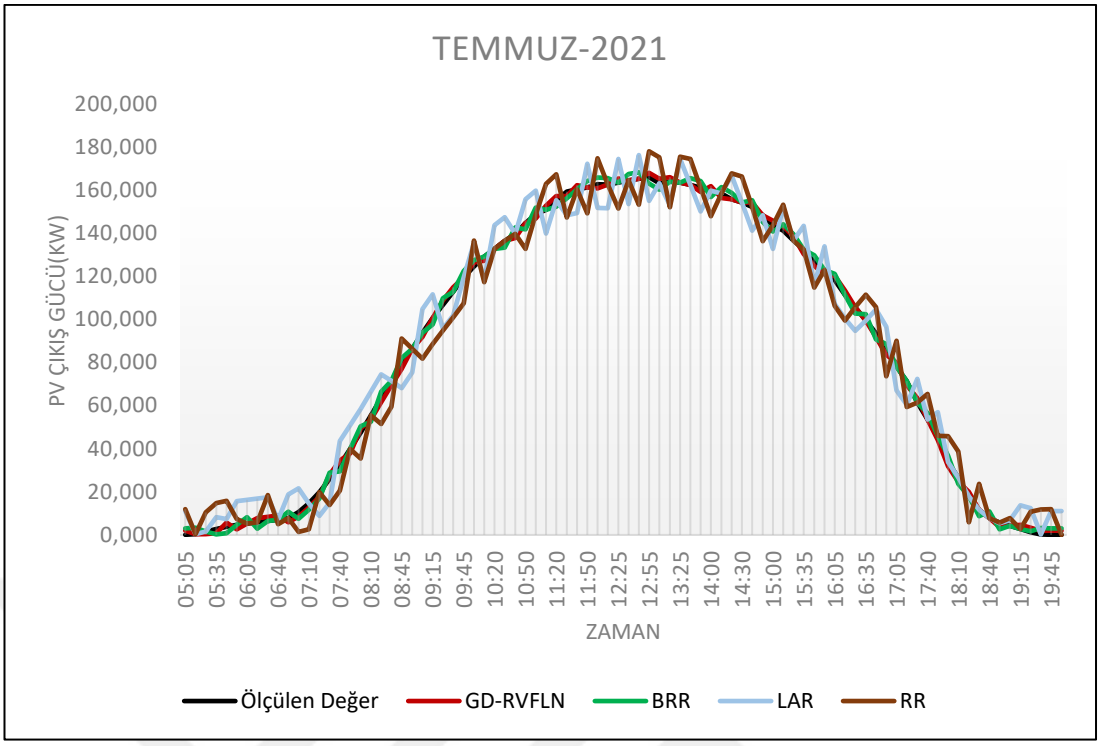
Şekil 4.41 02.08.2021 tarihindeki tüm modellerin tahmin sonuçları



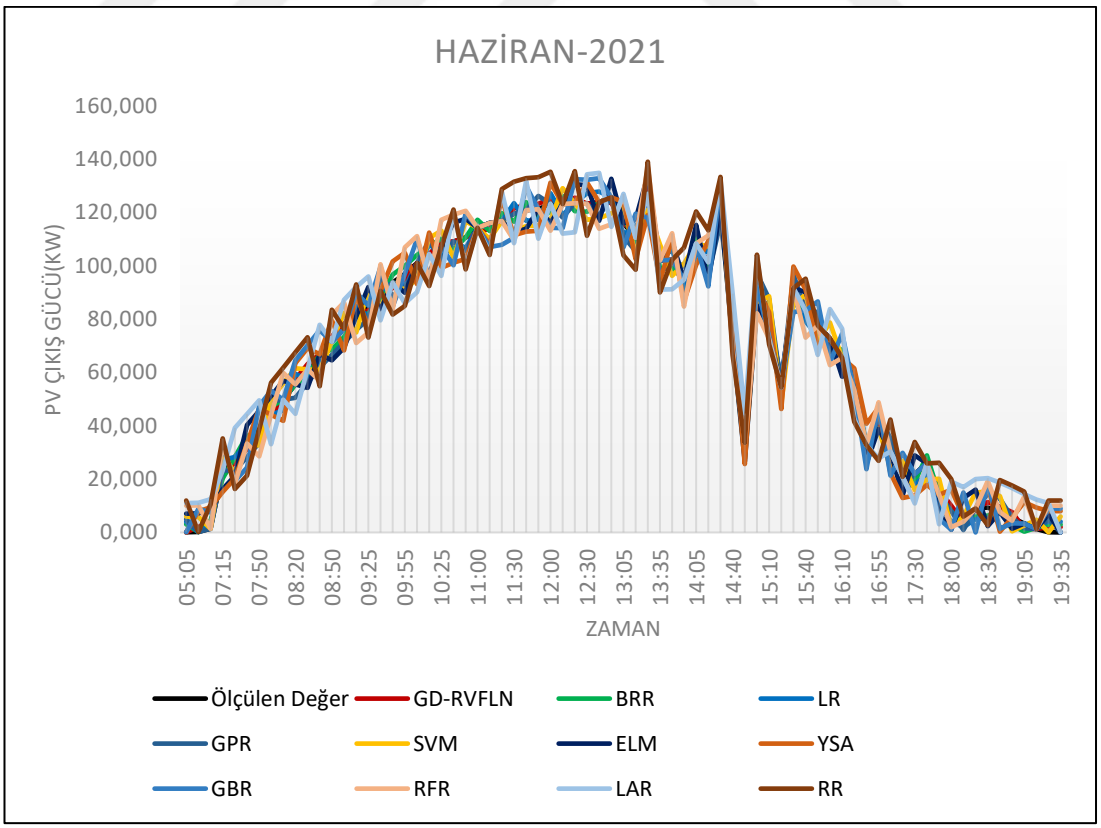
Şekil 4.42 02.08.2021 tarihinde en iyi performans ile en kötü performans gösteren modellerin tahmin sonuçları



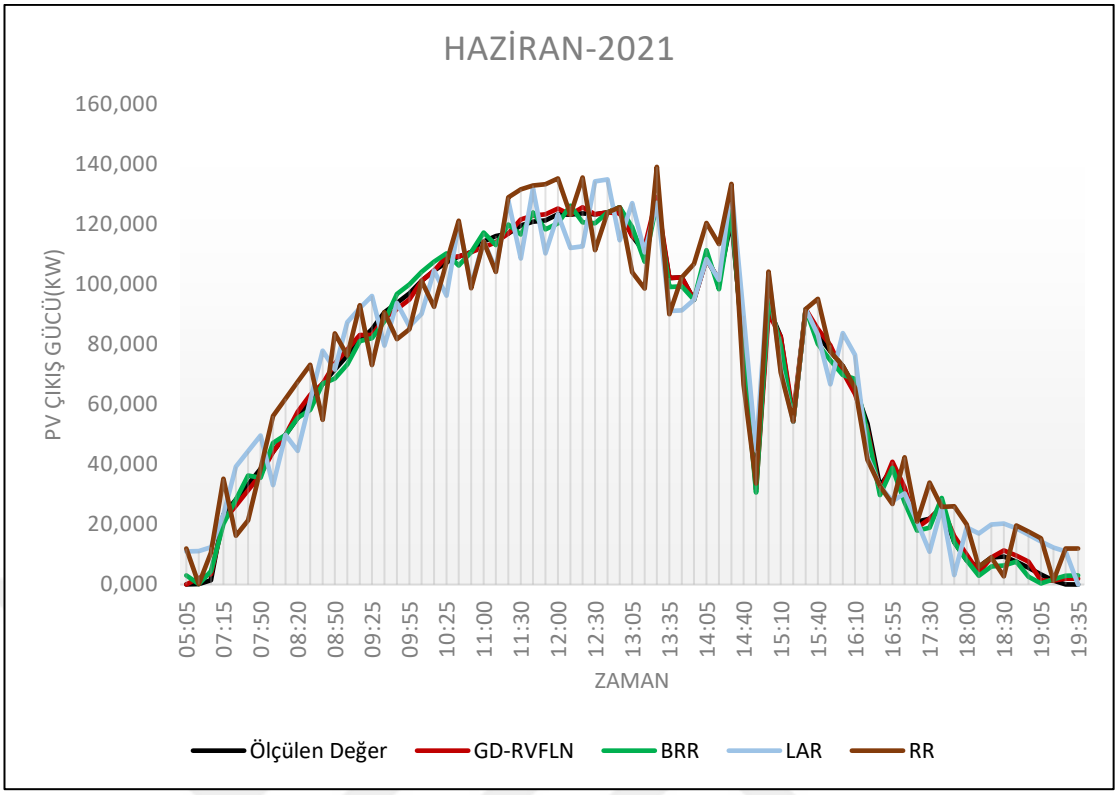
Şekil 4.43 02.07.2021 tarihindeki tüm modellerin tahmin sonuçları



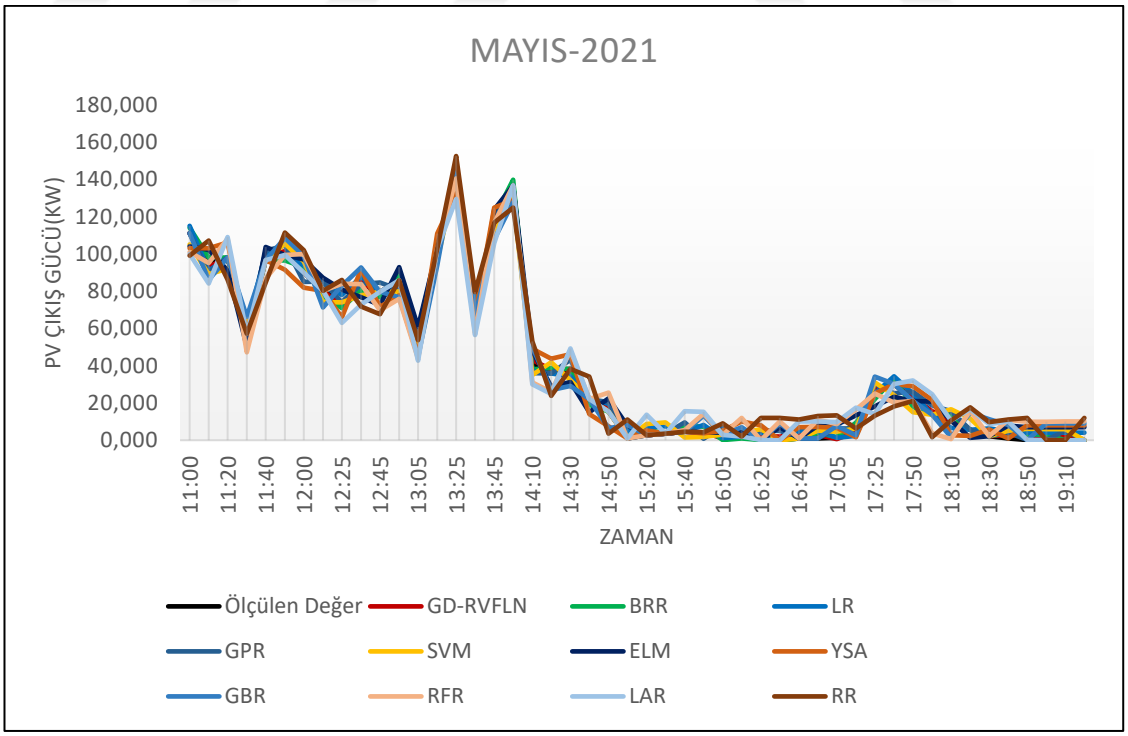
Şekil 4.44 02.07.2021 tarihinde en iyi performans ile en kötü performans gösteren modellerin tahmin sonuçları



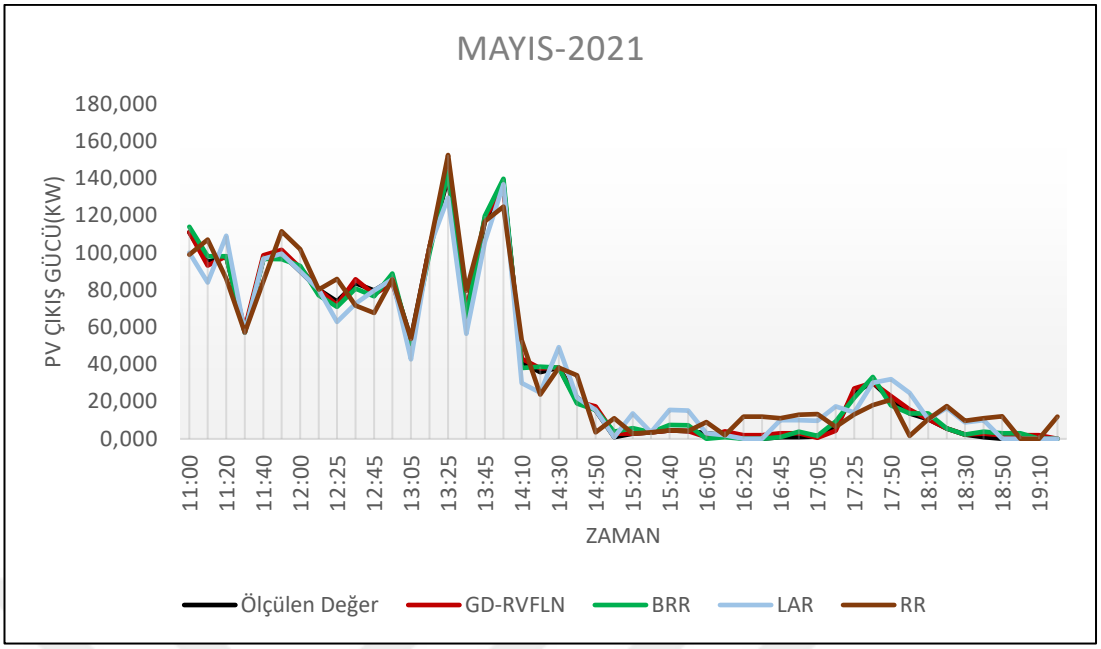
Şekil 4.45 02.06.2021 tarihindeki tüm modellerin tahmin sonuçları



Şekil 4.46 02.06.2021 tarihinde en iyi performans ile en kötü performans gösteren modellerin tahmin sonuçları



Şekil 4.47 02.05.2021 tarihindeki tüm modellerin tahmin sonuçları



Şekil 4.48 02.05.2021 tarihinde en iyi performans ile en kötü performans gösteren modellerin tahmin sonuçları

Tablo 4.2 On bir makine öğrenimi modeli için OMYH (%) değerleri

TARİH	GD-RVFLN	BRR	LR	GPR	SVM	ELM	YSA	GBR	RFR	LAR	RR
2.04.2022	3,919	5,497	8,477	10,599	12,288	12,020	13,022	11,714	14,613	15,251	12,175
2.03.2022	1,724	2,752	3,768	4,265	5,691	6,489	7,527	6,585	8,595	8,963	10,972
2.02.2022	1,687	2,564	3,031	3,777	4,762	6,347	7,806	7,771	7,656	10,954	10,654
2.01.2022	9,491	12,270	20,295	23,472	20,146	27,062	26,831	35,706	35,566	39,002	39,930
2.12.2021	4,861	7,858	9,662	13,114	10,997	19,920	27,952	18,916	21,252	22,488	29,255
2.11.2021	1,895	1,989	2,842	4,002	3,954	4,391	5,423	6,334	4,418	6,208	10,337
2.10.2021	2,254	3,364	4,021	4,921	5,453	6,170	8,564	8,647	7,910	8,949	9,722
2.08.2021	1,861	3,987	4,946	7,583	7,707	6,411	9,887	10,690	7,873	11,531	9,667
2.07.2021	1,811	3,137	4,020	4,337	5,102	6,620	6,235	6,549	9,427	8,490	9,901
2.06.2021	2,293	3,478	6,125	4,940	7,569	7,676	9,531	10,243	7,780	11,007	11,395
2.05.2021	3,828	7,947	7,255	6,047	11,172	10,434	12,828	6,654	8,777	7,068	9,723

Tablo 4.3 On bir makine öğrenimi modeli için OKH değerleri

TARİH	GD-RVFLN	BRR	LR	GPR	SVM	ELM	YSA	GBR	RFR	LAR	RR
2.04.2022	1,646	2,498	3,519	4,016	5,112	5,897	6,506	7,046	7,968	8,859	7,569
2.03.2022	1,684	2,590	3,368	4,369	5,117	5,894	7,180	8,202	9,022	9,295	10,806
2.02.2022	1,680	2,485	3,266	3,771	4,678	5,631	6,532	7,769	7,921	9,495	10,221
2.01.2022	1,789	2,450	3,425	4,282	4,382	5,994	6,197	7,349	8,165	8,981	9,498
2.12.2021	1,617	2,354	3,038	4,160	4,243	6,139	7,524	7,277	7,845	8,618	8,962
2.11.2021	1,732	2,419	3,162	4,402	5,109	5,643	6,573	6,675	7,071	8,696	9,859
2.10.2021	1,499	2,248	3,134	3,973	4,353	5,640	6,630	7,445	7,845	8,981	10,053
2.08.2021	1,345	2,458	3,244	4,179	4,832	4,984	6,560	7,448	7,237	8,650	9,102
2.07.2021	1,664	2,468	3,215	3,873	4,707	5,824	6,354	6,881	8,533	9,354	9,760
2.06.2021	1,574	2,563	3,383	3,934	5,182	5,436	6,761	7,260	7,346	8,765	9,562
2.05.2021	1,351	2,173	2,585	3,128	4,104	4,993	5,564	5,630	5,899	6,068	7,506

Hava tipi sınıflandırma yönteminin modellerde kullanılması çoğu makine öğrenimi modelinde kısa vadeli PV çıkış gücü tahmininin doğruluğunu artırdığı göstermiştir. Bununla birlikte hem hava tipi sınıflandırmasının hem de PV güç çıkış tahminin, güneş radyasyonu ile yüksek korelasyona sahip olduğu bilinmektedir. Dolayısıyla karasız hava koşullarında güneş radyasyonundaki yüksek dalgalanmalar modellerin doğruluğunu önemli ölçüde etkilemiştir. Şekillerden ve tablolardan (tablo 4.2-4.3) da anlaşıldığı gibi en iyi performans gösteren ilk dört model, GD-RVFLN, BRR, LR, GPR'dir. Tüm modeller arasında ise mükemmel doğruluk gösteren model bu tezde önerilen model olan GD-RVFLN modeli olmuştur.

Bu çalışmada veriler her ayın belli bir gününde alındığı için PV çıkışı gücü, o günün meteorolojik koşullarına bağlı olarak önemli ölçüde farklılık göstermektedir. Meteorolojik koşulların sabit olduğu günlerde bu çalışmada önerilen model olan GD-RVFLN' nin ortalama mutlak yüzdelik hata değerleri sırasıyla, 1,68; 1,72; 1,81; 1,86

ve 1,89 olmuştur. Öte yandan neredeyse tüm modeller meteorolojik koşulların sabit olduğu günlerde yüksek performans göstermiştir. Meteorolojik koşulların kötü olduğu günlerde ise (2 Ocak ve 2 Aralık) modellerin çoğu daha az iyi performans göstermiştir. Bu duruma rağmen önerilen GD-RVFLN modeli 0≤ OMYH ≤10 aralığında kalarak mükemmel doğruluk gösterme performansını korumuştur. Makine öğrenmesi modellerinde çıktıları tahmin etme, öncelikle büyük miktarda verilerin eğitilmesi ile gerçekleşir, ancak verilerdeki düzensizlikler tahmin doğruluğunu olumsuz etkileyen ana faktördür. Bu nedenle modellerde kullanılan verilerin en iyi hava koşullarında elde edilen verilerden oluşması önem arz etmektedir. Ancak bu çalışmada modellerin performansını analiz etmek için her ayın belli bir günü tercih edildi. Bu yüzden modellerin değerlendirmesi seçilen günün hava koşulunun iyi veya kötü olma durumuna bağlı olarak aylık değil tek bir gün için değerlendirmeler yapıldı. Bu anlamda, hava durumunun iyi olduğu günlerde diğer bir değişle, havanın yağışsız, gökyüzünün açık olduğu günlerde PV çıkış gücü tahmini tüm modellerde nispeten yüksek performans göstermiştir. Öte yandan, gökyüzünün bulutlu ve yağışlı olduğu kararsız hava koşullarının olduğu günlerde elde edilen eğitim ve tahmin veri setlerinde büyük dalgalanmalar olmaktadır. Bu dalgalanmalar daha düşük bir tahmin doğruluğuna yol açmaktadır. Kararsız hava koşullarında en iyi modeller arasında en iyi PV çıkış gücü tahmini sağlayan model GD-RVFLN modelidir.

5. SONUÇLAR

Bu çalışmada, gün öncesi PV çıkış gücünü tahmini on bir farklı makine öğrenimi modelleri üzerinde çalışıldı. İleri sürülen algoritmalar, PV çıkış gücünü tahmin etmek için hava koşullarına bağımlı olan meteorolojik verilerinin kullanılmasında hava koşullarının belirsizliği nedeniyle modellerin tahmin sonucunda hem periyodik hem de rastgele değişimlere sebep olduğunu göstermiştir. Bu yüzden istikrarı yakalamak için birden fazla saatlik meteorolojik veriler üzerinde hava tipi sınıflandırması yapmak gerekmektedir. Bu çalışmada hava tipi sınıfını bulmak ve PV çıkış gücü tahmini iyileştirmek için GD-RVFLN modeli önerildi ve analiz için 10 farklı makine öğrenimi modeli seçildi. Çıkan sonuçlarda, 11 farklı makine öğrenimi içinde en iyi performansı gösteren modellerin önerilen model GD-RVFLN ve BRR modelleri olduğu bulundu.
Bu çalışmadaki yenilik, geleneksel yapay zekâ modellemelerinde karşılaşılan sorunların; örneğin çok büyük sayıda veri kullanımından kaynaklı bazı verilerin göz ardı edilmesi, verilerdeki uyumsuzluk ve yetersiz genelleme gibi birtakım sorunların üstesinden gelmek için PV çıkış gücünün meteorolojik verilerle korelasyonu göz önüne alınarak makine öğrenimi modellerini birleştirmektir. Önerilen modeller, Diyarbakır Dicle üniversitesi kampüsünde bulunan PV güç santraline kısa vadeli PV güç tahmini uygulanarak analiz edildi. Sonuçlar, önerilen hava tipi sınıflandırmasına dayalı makine öğrenme modellerinin göstermiş oldukları yüksek doğrulukları nedeniyle pratik uygulamalar için büyük potansiyele sahip olduğunu göstermiştir.

PV çıkış gücünün sürekli değişmesi şebekede gerilim, frekans dalgalanmaları ve güç kalitesi problemlerine neden olmaktadır. İletim ve dağıtım şebekelerinde gerilim ve frekans kontrolü kısa zamanlı (saniyeler ve dakikalar seviyelerinde) yapılması gerektiği için kısa dönemli PV çıkış gücü tahminine ihtiyaç duyulmaktadır. Literatürde de hem PV çıkış gücü tahmini hem de gerilim ve frekans kontrolü yapan çalışmalar az sayıda bulunmaktadır. Bundan dolayı PV çıkış gücü tahmini, kontrol çalışmaları, güç iletim ve dağıtımda ciddi öneme sahiptir. Gelecek çalışmalarda PV çıkış gücü tahmin tabanlı gerilim, frekans kontrolü çalışmaları ve güç kalitesi iyileştirme çalışmaları yapılabilir.

KAYNAKLAR

[1] P. Markuse, *Provisional Report on the State of the Global Climate 2020*, World Meteorological Organization (WMO), 2021. Erişim Tarihi: 21 Ocak 2022. https://library.wmo.int/index.php?lvl=notice_display&id=21804#.YwThLEdBxPZ

[2] IEA, *Global Energy Review: CO2 Emissions in 2021*, IEA, Paris, 2022. Erişim Tarihi: 21 Temmuz 2022. https://www.iea.org/reports/global-energy-review-co2-emissions-in-2021-2

[3] M. Çolakoğlu, S. Aslan, E. İyikul vd. *Türkiye ve Dünyada Güneş Enerjisi Sektörü*, PwC, 2021. Erişim Tarihi: 21 Temmuz 2022. https://www.pwc.com.tr/tr/sektorler/enerji/turkiye-ve-dunyada-gunes-enerjisi-sektoru-raporu.pdf

[4] H.E. Murdock, D. Gibb, T. André vd. *Renewables 2021 Global Status Report*, World Energy Coucil, REN21, 2021. Erişim Tarihi: 21 Ocak 2022. https://www.ren21.net/reports/global-status-report/

[5] T. Gould, J. Coppel, T. Bienassis vd., *World Energy Investment 2022*, International Energy Agency, 2022. Erişim Tarihi: 21 Ocak 2022. https://www.iea.org/reports/world-energy-investment-2022

[6] Türkiye Cumhuriyeti Cumhurbaşkanlığı Strateji ve Bütçe Başkanlığı, *On Birinci Kalkınma Planı (2019-2023)*, 2019. Erişim Tarihi: 21 Ocak 2022. https://www.sbb.gov.tr/wp-content/uploads/2019/07/OnbirinciKalkinmaPlani.pdf

[7] W. Hemetsberger, M. Schmela ve DR. R. L. Sauaıa, *Global Market Outlook for Solar Power 2022-2026*, SolarPower Europe, 2022. Erişim Tarihi: 01 Temmuz 2022. https://www.solarpowereurope.org/insights/market-outlooks/global-market-outlook-for-solar-power-2022#downloadForm

[8] E. G. Cojocaru, J. M. Bravo, M. J. Vasallo, vd., "Optimal scheduling in concentrating solar power plants oriented to low generation cycling.", Renewable Energy, vol. 135, May 2019, s.789-799.

[9] S. Comello, S. Reichelstein, ve A. Sahoo, "The road ahead for solar PV power, ", Renewable and Sustainable Energy Reviews, vol. 92, Sep. 2018, s. 744-756.

[10] K. U. Das, S.K. Tey, M. Seyedmahmoudian, vd., "Forecasting of photovoltaic power generation and model optimization: A review," Renewable and Sustainable Energy Reviews, vol. 81, no.1, Jan. 2018, s. 912-928.

[11] F. Barbieri, S. Rajakaruna, ve A. Ghosh. "Very short-term photovoltaic power forecasting with cloud modeling: A review," Renewable and Sustainable Energy Reviews, 75, Aug. 2017, s. 242-263.

[12] G. Gowrisankaran, S. S. Reynolds, ve M. Samano, "Intermittency and the value of renewable energy," Journal of Political Economy, vol. 124, no.4, Aug 2016, s. 1187-1234.

[13] G. Stein ve T. M. Letcher, "Integration of PV generated electricity into national grids. In A comprehensive guide to solar energy systems" Academic Press, 2018, s.321-332.

[14] G. Cervone, L. Clemente-Harding, S. Alessandrini, ve L. Delle Monache, "Short-term photovoltaic power forecasting using Artificial Neural Networks and an Analog Ensemble," Renewable Energy, vol.108, Aug. 2017, s. 274–286.

[15] M.Q. Raza, M. Nadarajah, ve C. Ekanayake, "On recent advances in PV output power forecast," Sol Energy, vol.136, Oct. 2016, s.125–144.

[16] U. K. Das, K. S. Tey, M., Seyedmahmoudian, vd., "Forecasting of photovoltaic power generation and model optimization: A review," Renewable and Sustainable Energy Reviews, vol.81, no.1, Jan. 2018, s. 912-928.

[17] Y. Ren, P. N. Suganthan, ve N. Srikanth, "Ensemble methods for wind and solar power forecasting—a state-of-the-art review," Renew Sustain Energy Rev, Vol.50, Oct. 2015, s. 82–91.

[18] M.K. Behera, I. Majumder, ve N. Nayak, "Solar photovoltaic power forecasting using optimized modified extreme learning machine technique," Eng Sci Technol, Int J, vol.21, no.3, Jun. 2018, s.428–438.

[19] Z.L. Yang, M. Mourshed, K. Liu, vd., "A novel competitive swarm optimized RBF neural network model for short-term solar power generation forecasting," Neurocomputing, vol. 397, Jul. 2020, s.415-421.

[20] H.T. Yang, C.M. Huang, Y.C. Huang, vd., "A weather-based hybrid method for 1- day ahead hourly forecasting of PV power output." IEEE Trans. On Sustain. Energy, vol. 5, no. 3, Jul. 2014, s.917-926.

[21] S. Leva, A. Dolara, F. Grimaccia, vd., "Analysis and validation of 24 hours ahead neural network forecasting of photovoltaic output power," Math Comput Simulat, Vol.131, Jan. 2017, s.88-100.

[22] H.Z. Wang, H.Y. Yi, J.C. Peng, vd., "Deterministic and probabilistic forecasting of photovoltaic power based on deep convolutional neural network," Energy Convers Manag, vol. 153, Dec. 2017, s.409-422.

[23] U.K. Das, K.S. Teya, M. Seyedmahmoudian, vd., "Forecasting of photovoltaic power generation and model optimization: a review," Renew Sustain Energy Rev, vol.81, Jan. 2018, s. 912-928.

[24] Y.T. Li, Y. He, Y. Su, vd., "Forecasting the daily power output of a grid connected photovoltaic system based on multivariate adaptive regression splines," Appl Energy, vol.180, 15 Oct. 2016, s.392-401.

[25] M.Q. Raza, M. Nadarajah,ve C. Ekanayake, "Review on recent advances in PV output power forecast," Sol Energy, vol. 136, Oct. 2016, s.125-144.

[26] L.Y. Liu, Y. Zhao, D.L. Chang, vd., "Prediction of short-term PV power output and uncertainty analysis," Appl Energy, vol. 228, Oct. 2018, s.700-711

[27] D.W. van der Meer, J. Widen, ve J. Munkhammar, "Review on probabilistic forecasting of photovoltaic power production and electricity consumption," Renew Sustain Energy Rev, vol. 81, Jan. 2018, s.1484-1512.

[28] G. Cervone, L. Clemente-Harding, S. Alessandrini, vd., “Short-term photovoltaic power forecasting using artifificial neural networks and an analog ensemble,” Renew Energy, vol. 108, Aug. 2017, s.274-284.

[29] S. Sobri, S. Koohi-Kamali, ve N. Rahim Abd, “Solar photovoltaic generation forecasting methods: a review,” Energy Convers Manag, vol.156, Jan. 2018, s. 459-497.

[30] L.W. Zheng, Z.K. Liu, J.N. Shen, vd., “Very short-term maximum Lyapunov exponent forecasting tool for distributed photovoltaic output,” Appl Energy, vol. 229, Nov. 2018, s.1128-1139.

[31] P. Geurts, D. Ernst, ve L. Wehenkel, “Extremely randomized trees,” Mach Learn, vol. 63, Mar. 2006, s.3-42.

[32] R. Ahmed, V. Sreeram, Y. Mishra, vd., “A review and evaluation of the stateof-the-art in PV solar power forecasting: techniques and optimization,” Renew Sustain Energy Rev, vol. 24, May 2020, s.1-26.

[33] M.Z. Pan, C. Li, R. Gao, vd., “Photovoltaic power forecasting based on a support vector machine with improved ant colony optimization,” J Clean Prod, vol. 277, Dec. 2020, s.1-12.

[34] K.J. Wang, X.X. Qi, ve H.D. Liu, “A comparison of day-ahead photovoltaic power forecasting models based on deep learning neural network,” Appl Energy, vol. 251, Oct. 2019, s. 315-329.

[35] X. G. Agoua, R. Girard ve G. Kariniotakis, "Short-Term Spatio-Temporal Forecasting of Photovoltaic Power Production," in IEEE Transactions on Sustainable Energy, vol. 9, no. 2, Apr. 2018, s. 538-546,

[36] V. De, T. T. Teo, W. L. Woo ve T. Logenthiran, "Photovoltaic Power Forecasting using LSTM on Limited Dataset," 2018 IEEE Innovative Smart Grid Technologies - Asia (ISGT Asia), 2018, s. 710-715

[37] M. Abdel-Nasser ve K. Mahmoud, “Accurate photovoltaic power forecasting models using deep LSTM-RN,” Neural Comput Appl, vol. 31, no.7, Jul. 2019, s.27-40.

[38] D. Li and K. Sun, “Random Forest solar power forecast based on classification optimization,” Energy, vol. 187, Nov. 2019, s. 1-11.

[39] I. A. Ibrahim ve T. Khatib, “A novel hybrid model for hourly global solar radiation prediction using random forests technique and firefly algorithm,” Energy Convers Manag, vol.138, Apr. 2017, s.413-425.

[40] R. Prasad, M. Ali, P. Kwan, vd., “Designing a multi-stage multivariate empirical mode decomposition coupled with ant colony optimization and random forest model to forecast monthly solar radiation,” Appl Energy, vol. 236, Feb. 2019, s.778-792.

[41] Y.T. Hana, N.B. Wang, M. Ma, vd., “A PV power interval forecasting based on seasonal model and nonparametric estimation algorithm,” Sol Energy, vol. 184, May 2019, s.515-526.

[42] P. Lin, Z. Peng, Y. Lai, vd., "Short-term power prediction for photovoltaic power plants using a hybrid improved Kmeans-GRA-Elman model based on multivariate meteorological factors and historical power datasets," Energy Convers Manag, vol. 177, Dec.2018, s.704-717,

[43] A.T. Eseye, J. Zhang, ve D. Zheng, "Short-term photovoltaic solar power forecasting using a hybrid Wavelet-PSO-SVM model based on SCADA and Meteorological information," Renew Energy, vol.118, Apr. 2018, s.357-367.

[44] P. T. Li, K. L. Zhou, X. H. Lu, vd. "A hybrid deep learning model for shortterm PV power forecasting," Appl Energy, vol. 259, Feb. 2020, s. 1-11.

[45] T. Jamala, C. Cartera, T. Schmidtb, vd., "An energy flow simulation tool for incorporating short-term PV forecasting in a diesel-PV-battery off-grid power supply system," Appl Energy, vol. 254, Nov. 2019, s.21-43.

[46] X.Y. Qing ve Y.G. Niu, "Hourly day-ahead solar irradiance prediction using weather forecasts by LSTM," Energy, vol.148, Apr. 2018, s. 461-468.

[47] K.J. Wang, X.X. Qi, H.D. Liu, vd., "Deep belief network-based k-means cluster approach for short-term wind power forecasting," Energy, vol. 168, Dec. 2018, s. 840-852.

[48] K.J Wang, X.X. Qi, ve H.D. Liu, "A comparison of day-ahead photovoltaic power forecasting models based on deep learning neural network," Appl Energy, vol. 251, Oct. 2019, s. 1-14.

[49] F. Wang, Z.M. Xuan, Z. Zhen, vd., "A Day-ahead PV power forecasting method based on LSTM-RNN model and time correlation modification under partial daily pattern prediction framework," Energy Convers Manag, vol. 212, May 2020, s.1-14.

[50] H.Z. Wang, Z.X. Lei, X. Zhang, vd., "A review of deep learning for renewable energy forecasting," Energy Convers Manag, vol. 198, Oct 2019, s.1-16.

[51] H.J. Lu ve G.W. Chang, "A hybrid approach for day-ahead forecast of PV power generation," IFAC-PapersOnLine, vol.51, no. 28, 2018, s. 34-8.

[52] W. El-Baz, P. Tzscheutschler, ve U. Wagner, "Day-ahead probabilistic PV generation forecast for buildings energy management systems," Sol Energy, vol. 171, Sep. 2018, s. 478-490.

[53] M. Bou-Rabee, S.A. Sulaiman, M.S. Saleh, vd., "Using artificial neural networks to estimate solar radiation in Kuwait," Renew Sustain Energy Rev, vol. 72, May 2017, s. 434-438.

[54] E. Ogliari, A. Dolara, G. Manzolini, vd., "Physical and hybrid methods comparison for the day ahead PV output power forecast," Renew Energy, vol.113, Dec. 2017, s. 11-21.

[55] D. Koster, F. Minette, C. Braun, vd., "Short-term and regionalized photovoltaic power forecasting, enhanced by reference systems, on the example of Luxembourg," Renew Energy, vol.132, Mar. 2019, s. 55-70

[56] M.R. Douiri, "Particle swarm optimized neuro-fuzzy system for photovoltaic power forecasting model," Sol Energy, vol. 184, s.91-104, 2019.

[57] H. Wang ve J. Shen, "An Improved Model Combining Evolutionary Algorithm and Neural Networks for PV Maximum Power Point Tracking," in IEEE Access, vol. 7, 2019, s. 2823-2827.

[58] Y.M. Saint-Drenan, S. Vogt, S. Killinger, vd., "Bayesian parameterisation of a regional photovoltaic model e application to forecasting," Sol Energy, vol.188, 2019, s.60-74.

[59] Y.C. Sun, V. Venugopal, ve A.R. Brandt, "Short-term solar power forecast with deep learning: exploring optimal input and output configuration," Sol Energy, vol.188, 2019, s.30-41.

[60] J. Zhang, R. Verschae, S. Nobuhara, vd., "Deep photovoltaic nowcasting," Sol Energy, vol.176, 2018, s.67-76.

[61] X. Zhao, H. Wei, H. Wang, vd., "3d-cnn-based feature extraction of ground-based cloud images for direct normal irradiance prediction," Sol Energy, vol.181, 2019, s.510-518.

[62] Y. Zhou, N. Zhou, L. Gong, vd., "Prediction of photovoltaic power output based on similar day analysis, genetic algorithm and extreme learning machine," Energy, vol. 204, 2020, s. 117894.

[63] M. Pan, C. Li, R. Gao, vd., "Photovoltaic power forecasting based on a support vector machine with improved ant colony optimization," Journal of Cleaner Production, vol. 277, 2020, 123948.

[64] W. VanDeventer, E. Jamei, G. S. Thirunavukkarasu, vd., "Short-term PV power forecasting using hybrid GASVM technique," Renewable energy, vol.140, 2019, s.367-379.

[65] M. Massaoudi, S. S. Refaat, H. Abu-Rub, vd., "A Hybrid Bayesian Ridge Regression-CWT-Catboost Model For PV Power Forecasting," 2020 IEEE Kansas Power and Energy Conference (KPEC), 2020, s. 1-5

[66] S. Atique, S. Noureen, V. Roy, S. Bayne ve J. Macfie, "Time series forecasting of total daily solar energy generation: A comparative analysis between ARIMA and machine learning techniques," 2020 IEEE Green Technologies Conference (GreenTech), 2020, s. 175-180.

[67] K. H. Shedbalkar ve D. S. More, "Bayesian Regression for Solar Power Forecasting," 2022 2nd International Conference on Artificial Intelligence and Signal Processing (AISP), 2022, s. 1-4

[68] L. Gutiérrez, J. Patiño, ve E. Duque-Grisales, "A Comparison of the Performance of Supervised Learning Algorithms for Solar Power Prediction," Energies, vol.14, no. 15, 2021, s. 4424,

[69] A. Afzal, S. Alshahrani, A. Alrobaian, vd., "Power plant energy predictions based on thermal factors using ridge and support vector regressor algorithms" Energies, vol.14, no. 21, 2021, 7254.

[70] T. T. Teo, T. Logenthiran ve W. L. Woo, "Forecasting of photovoltaic power using extreme learning machine," 2015 IEEE Innovative Smart Grid Technologies - Asia (ISGT ASIA), 2015, s. 1-6.

[71] H. S. Jang, K. Y. Bae, H. -S. Park ve D. K. Sung, "Solar Power Prediction Based on Satellite Images and Support Vector Machine," in IEEE Transactions on Sustainable Energy, vol. 7, no. 3, July 2016, s. 1255-1263.

[72] A. Khalyasmaa, S. A. Eroshenko, T. P. Chakravarthy, vd., "Prediction of Solar Power Generation Based on Random Forest Regressor Model," 2019 International Multi-Conference on Engineering, Computer and Information Sciences (SIBIRCON), 2019, s. 0780-0785

[73] S. Mishra, L. Tripathy, P. Satapathy, P. K. Dash ve N. Sahani, "An Efficient Machine Learning Approach for Accurate Short Term Solar Power Prediction," 2020 International Conference on Computational Intelligence for Smart Power System and Sustainable Energy (CISPSSE), 2020, s. 1-6.

[74] A. I. Khalyasmaa, S. A. Eroshenko, V. A. Tashchilin, vd., "Industry experience of developing day-ahead photovoltaic plant forecasting system based on machine learning," Remote Sensing, vol. 12, no.20, 2020, 3420.

[75] S. Theocharides, G. Makrides, G. E. Georghiou ve A. Kyprianou, "Machine learning algorithms for photovoltaic system power output prediction," 2018 IEEE International Energy Conference (ENERGYCON), 2018, pp. 1-6.

[76] A. Erduman, "A smart short-term solar power output prediction by artificial neural network," Electrical Engineering, vol.102, no.3, 2020, s.1441-1449.

[77] M. K. Behera ve N. Nayak, "A comparative study on short-term PV power forecasting using decomposition based optimized extreme learning machine algorithm," Engineering Science and Technology, an International Journal, vol. 23, no.1, 2020, s.156-167.

[78] S. Chahboun ve M. Maaroufi, "Novel comparison of machine learning techniques for predicting photovoltaic output power," International Journal of Renewable Energy Research (IJRER), vol.11, no.3, 2021, s. 1205-1214.

[79] C. N. Obiora, A. Ali ve A. N. Hassan, "Predicting Hourly Solar Irradiance Using Machine Learning Methods," 2020 11th International Renewable Energy Congress (IREC), 2020, s. 1-6.

[80] A. Aggarwal ve M. M. Tripathi, "Short-term solar power forecasting using Random Vector Functional Link (RVFL) network," In Ambient Communications and Computer Systems, Springer, Singapore, 2018, s.29-39.

[81] S. P. Mishra, P. P. Padhi, J. Naik, vd., "An efficient Robust Random Vector Functional Link network for Solar Irradiance, Power and Wind speed prediction," 2021 1st Odisha International Conference on Electrical Power Engineering, Communication and Computing Technology(ODICON), 2021, s. 1-7.

[82] C. Haydaroğlu, "Dicle Üniversitesi Güneş Enerjisi Santralinin Performans Analizi," (Yayımlanmamış Yüksek Lisans Tezi), Dicle Üniversitesi, Fen Bilimler Enstitüsü, 2017.

[83] C. Haydaroğlu ve B. Gümüş, "Dicle Üniversitesi güneş enerjisi santralinin PVsyst ile simülasyonu ve performans parametrelerinin değerlendirilmesi," Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi, vol. 7, no. 3, 2016. s. 491-500.

[84] C. Haydaroğlu ve B. Gümüş, “Investigation of the effect of short-term environmental contamination on energy production in photovoltaic panels: Dicle University solar power plant example,” Applied Solar Energy, vol.53, no.1, 2017, s.31-34.

[85] H. Kılıç, “Güneş Enerjisi İle İlgili Meteorolojik Verilerin Tahmini İçin Yöntem Geliştirilmesi,” (Yayımlanmamış Yüksek Lisans Tezi), Dicle Üniversitesi, Fen Bilimler Enstitüsü, 2016.

[86] B. Gumus ve H. Kilic, “Time dependent prediction of monthly global solar radiation and sunshine duration using exponentially weighted moving average in southeastern of Turkey,” Thermal Science, vol.22, no.2, 2018, s. 943-951.

[87] H. Kılıç, B. Gümüş ve M. Yılmaz, “Diyarbakır İli İçin Güneş Enerjisi Verilerinin Meteorolojik Standartlarda Ölçülmesi ve Analizi,” EMO Bilimsel Dergi, vol.5, no.10, 2016, s.15-19.

[88] M. Yılmaz, B. Gümüş, H. Kılıç ve M. E. Asker, "Chaotic analysis of the gloabal solar irradiance," 2017 IEEE 6th International Conference on Renewable Energy Research and Applications (ICRERA), 2017, s. 1058-1066

[89] C. Shen, M. Sun, M., Tang, ve C. E. Priebe, “Generalized canonical correlation analysis for classification,” Journal of Multivariate Analysis, vol.130, 2014, s. 310-322.

[90] W. Zuobin, M. Kezhi ve G. -W. Ng, "Feature Regrouping for CCA - Based Feature Fusion and Extraction Through Normalized Cut," 2018 21st International Conference on Information Fusion (FUSION), 2018, s. 2275-2282.

[91] A. Afifi, V. A. Clark ve Susanne May, *Canonical Correlation Analysis | R Data Analysıs Examples*, UCLA: Statistical Consulting Group,2004, Erişim tarihi: 12 Temmuz 2022. https://stats.oarc.ucla.edu/r/dae/canonical-correlation-analysis/

[92] H. Kılıç, “Makine Öğrenmesi İle Fotovoltaik Dizilerde Elektriksel Arıza Tespiti”, Yayımlanmamış Doktora Tezi, Dicle Üniversitesi, Fen Bilimleri Enstitüsü, 2021.

[93] Y. H. Pao ve Y. Takefuji, "Functional-link net computing: theory, system architecture, and functionalities," in Computer, vol. 25, no. 5, May 1992, s. 76-79.

[94] Y.H. Pao, G.H. Park, ve D.J. Sobajic, “Learning and generalization characteristics of the random vector functional-link net,” Neurocomputing , vol.6, no.2, 1994, s.163–180.

[95] Q. Shi, R. Katuwal, P. N. Suganthan, ve M. Tanveer, “Random vector functional link neural network based ensemble deep learning” Pattern Recognition, vol.117, 2021, s.107978.

[96] A. E. Hoerl ve R. W. Kennard, ‘‘Ridge regression: Applications to nonorthogonal problems,’’ Technometrics, vol. 12, no. 1, 1970, s. 69–82.

[97] H. T. Huynh ve Y. Won, ‘‘Regularized online sequential learning algorithm for single-hidden layer feedforward neural networks,’’ Pattern Recognit. Lett., vol. 32, no. 14, Oct. 2011, s. 1930–1935.

[98] W. Dai, Q. Chen, F. Chu, X. Ma ve T. Chai, "Robust Regularized Random Vector Functional Link Network and Its Industrial Application," in IEEE Access, vol. 5, 2017, s. 16162-16172.

[99] A. Sivasubramanian, S. A. Krishna, D. H. Nair, vd., “Experimental validation of compressive strength prediction using machine learning algorithm,” Materials Today: Proceedings, vol. 64, 2022, s. 181-187.

[100] S. Ding, X. Xu, ve R. Nie, “Extreme learning machine and its applications,” Neural Computing and Applications, vol.25, no.3, 2014, s.549-556.

[101] R. Ahmed, V. Sreeram, Y. Mishra, ve M. D. Arif, “A review and evaluation of the state-of-the-art in PV solar power forecasting: Techniques and optimization,” Renewable and Sustainable Energy Reviews, vol. 24, 2020, s.109792.

ÖZGEÇMİŞ

Kişisel Bilgiler	
Soyad, Ad	Eryılmaz, Berrin
Web sayfası (Research Gate, Academia, vs.)	-

Eğitim Bilgileri

Derece	Kurum	Mezuniyet Yılı
Yüksek Lisans	Dicle Üniversitesi/Yenilenebilir Enerji Kaynakları	Devam ediyor
Lisans	Gediz Üniversitesi/Elektrik-Elektronik Mühendisliği	2014
Lise	N.Ö.Ş.Cizrelioğlu Lisesi	2007

İş Deneyimi

Dönem (Yıl)	Şirket, Kurum	Görev
2014-2019	NYZ İNŞAAT	Elk. Elktr. Mühendisi
2020-Devam	MED RESTORASYON	Elektrik Proje sorumlusu

Yabancı Dil

İngilizce

Yayınlar

1.
2.
3.
4.

Özel İlgiler

Bisiklet sürmek, Yüzmek, Bahçe bitkisi yetiştirmek, film izlemek, kitap okumak

DİCLE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
TEZ BENZERLİK BİLDİRİMİ FORMU

Öğrencinin Adı, Soyadı	Berrin ERYILMAZ		
Öğrenci No	20828007		
Ana Bilim Dalı	Yenilenebilir Enerji Kaynakları		
Program Türü	Proje ☐	Yüksek Lisans ☒	Doktora ☐
Tez Danışmanı (Ünvanı, Adı, Soyadı)	Doç. Dr. Fatih KOÇYİĞİT		
(Varsa) II. Tez Danışmanı (Ünvanı, Adı, Soyadı)	Dr. Öğr. Üyesi Heybet KILIÇ		
Tez Başlığı	Makine Öğrenimi Tabanlı Fotovoltaik Çıkış Gücü Tahminlemesi		
RAPOR BİLGİLERİ			
Raporlama Aşaması	Tez Savunma Sınavı Sonrası		
Sayfa Sayısı	104		
Raporlama Tarihi	22.08.2022		
Benzerlik Oranı (%)	7		

Yukarıda bilgileri verilen tez çalışmamın toplam 104 sayfalık kısmına ilişkin, 22/08/2022 tarihinde şahsım/tez danışmanım tarafından Turnitin isimli intihal tespit programından aşağıda belirtilen filtrelemeler uygulanarak alınmış olan intihal raporuna göre, tezimin benzerlik oranı %7 olarak tespit edilmiştir.

Uygulanan filtrelemeler:

☐Başlangıç Bölümleri (Kabul ve Onay sayfası, Teşekkür sayfası, Özet/Abstract) hariç

☐Kaynaklar hariç

☐Alıntılar hariç/dâhil

☒Diğer (Her şey dahil)

Tezimin benzerlik oranı, Dicle Üniversitesi Fen Bilimleri Enstitüsü İntihal Raporu Uygulama Esaslarında belirtilen üst sınır benzerlik oranını aşmamaktadır. Benzerlik oranım üst sınır benzerlik oranının altında olsa dahi aksinin tespit edilmesi durumunda her türlü yasal sorumluğu kabul ettiğimi ve hukuki sonuçlarına razı olduğumu bildirir,
gereğini arz ederim.

Öğrencinin Adı, Soyadı: Berrin Eryılmaz
Tarih: 24.08.2022
İmza:

Danışman Adı, Soyadı: Doç. Dr. Fatih Koçyiğit Tarih: 24.08.2022	İmza:
Ana Bilim Dalı Başkanı Adı, Soyadı: Doç. Dr. Fatih Koçyiğit Tarih: 24.08.2022	İmza: