
GAZİ ÜNİVERSİTESİ
Gazi
1926

GÜNEŞ ENERJİSİ SANTRALİ ELEKTRİK ÜRETİMİ TAHMİNİNİN MAKİNE ÖĞRENMESİ ALGORİTMALARIYLA GERÇEKLEŞTİRİLMESİ

Ali Rıza ÖZER

YÜKSEK LİSANS TEZİ
ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ ANA BİLİM DALI

GAZİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

AĞUSTOS 2022

ETİK BEYAN

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

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

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

Ali Rıza ÖZER
09/08/2022

GÜNEŞ ENERJİSİ SANTRALİ ELEKTRİK ÜRETİMİ TAHMİNİNİN MAKİNE ÖĞRENMESİ ALGORİTMALARIYLA GERÇEKLEŞTİRİLMESİ

(Yüksek Lisans Tezi)

Ali Rıza ÖZER

GAZİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Ağustos 2022

ÖZET

Elektrik enerjisi üretiminde yenilenebilir enerji kaynaklarının payının artması, yapay zekâ teknolojilerinin yenilenebilir enerji kaynaklarından üretilebilecek elektrik enerjisinin tahmin edilmesinde etkin bir şekilde kullanılması, dağıtık enerji üretim sistemleri ve mikro şebeke uygulamalarının geniş bir şekilde uygulanması; elektrik iletim ve dağıtım sistemlerinin en uygun şekilde çalışmasına, sistem esnekliği ve kararlılığına ve iletim-üretim-dağıtım sistemlerinde işletme maliyetlerinin azaltılmasına katkı sağlamaktadır. Elektrik dağıtım sektöründe Türkiye 21 dağıtım bölgesine ayrılmıştır. Dağıtım bölgelerinin yük tahmini yapılırken bu güneş enerji santrallerinin üretebileceği elektrik enerjisi potansiyeli dikkate alınmalıdır. Bu tez çalışmasında bir güneş enerjisi santralinden elde edilecek elektrik üretiminin tahmin edilmesi için polinom regresyon ve destek vektör regresyonu yöntemleri önerilmiştir. Bu çalışmada ele alınan güneş enerji santrali Osmaniye İl Özel İdaresi tarafından kurulmuştur. Osmaniye İl Özel İdaresine ait 990 kW kurulu gücündeki Güneş Enerjisi Santralinin 24.08.2021 ve 25.08.2021 günleri için 2 günlük elektrik üretim tahminleri yapılmıştır. Adım adım yapılan polinom regresyon yöntemi ile yaklaşık % 85 ve adım adım yapılan destek vektör regresyonu yöntemi ile yaklaşık % 90 oranında tahmin başarısı elde edilmiştir. Tek aşamada yapılan ile destek vektör regresyonundan Ortalama Mutlak Hata Yüzdesi % 12,68 olarak elde edilmiştir. Çalışmada sonuç olarak en başarılı tahmin %10,34 ortalama MAPE ile adım adım yapılan destek vektör regresyonundan elde edilmiştir.

Bilim Kodu : 90542
Anahtar Kelimeler : Güneş enerjisi santralleri, güneş enerjisinden elektrik üretiminin tahmini, destek vektör regresyonu, polinom regresyonu
Sayfa Adedi : 77
Danışman : Prof. Dr. Ömer Faruk BAY

PERFORMING SOLAR POWER PLANT ELECTRICITY GENERATION FORECASTING WITH MACHINE LEARNING ALGORITHMS

(M. Sc. Thesis)

Ali Rıza ÖZER

GAZİ UNIVERSITY

GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCES

August 2022

ABSTRACT

Increasing the share of renewable energy sources in electrical energy generation, effective use of artificial intelligence technologies in estimating the electrical energy that can be supplied from renewable energy sources, wide application of distributed energy generation systems and microgrid applications ensure optimal operation of electricity transmission and distribution systems, contribute to system flexibility and stability, and contribute to reducing operating costs in transmission-generation-distribution systems. In the electricity distribution sector, Turkey is divided into 21 distribution regions. Therefore, while estimating the load of the distribution region, the electrical energy potential that these solar power plants can generate should be considered. In this study, polynomial regression and support vector regression are suggested to predict electrical energy supplied from the solar power plant. 2-day electrical power generation were forecasted for the days 24.08.2021 and 25.08.2021 of the Osmaniye Special Provincial Administration Solar Power Plant with an installed power of 990 kW. Consequently, it was recorded that; approximately 85% success was obtained from the step by step polynomial regression, approximately 90% highest performance of prediction was yielded from the step-by-step support vector regression. It was obtained from single stage support vector regression with 12.68% MAPE (Mean Absolute Error Percentage), and the most successful estimation was obtained from step-by-step support vector regression with an average MAPE of 10.34%.

Science Code : 90542
Key Words : Solar Power Plant, estimation of electricity generation from solar energy, support vector regression, polynomial regression
Page Number : 77
Supervisor : Prof. Dr. Ömer Faruk BAY

TEŞEKKÜR

Yüksek lisans tezinde büyük emeği geçen kıymetli hocam Prof. Dr. Ömer Faruk BAY'a, Prof. Dr. Çetin ELMAS'a, Osmaniye İl Özel İdaresi'nden güneş enerji santralinin üretim verilerini almamda katkısı olan Osmaniye İl Özel İdaresi çalışanı Mehmet NARCIOĞLU'na, Enerjisa Toroslar Osmaniye İl Müdürlüğü'nde görev yapan Atilla ALICI'ya, Osmaniye Valiliği Yazı İşleri Müdürü Fatiş USTA'ya, EÜAŞ'ta Müdür Yardımcısı olarak görev yapan Ender AKILLAR'a ve Şube Müdürü Mehmet KAHRAMAN'a tez çalışmasına katkılarından dolayı teşekkürlerimi arz ederim.

İÇİNDEKİLER

Sayfa

ÖZET iv

ABSTRACT v

TEŞEKKÜR vi

İÇİNDEKİLER vii

ÇİZELGELERİN LİSTESİ ix

ŞEKİLLERİN LİSTESİ x

RESİMLERİN LİSTESİ xiv

SİMGELER VE KISALTMALAR xv

1. GİRİŞ 1

2. TÜRKİYE'DEKİ YENİLENEBİLİR ENERJİ KAYNAKLARINA GENEL BAKIŞ 5

3. LİTERATÜR İNCELEMESİ 7

4. TAHMİN ÇALIŞMASI YAPILAN GÜNEŞ ENERJİSİ SANTRALİNE AİT GENEL BİLGİLER VE SANTRAL ELEKTRİK ÜRETİM VERİLERİ 13

4.1. Fotovoltaik Sistemler 13

4.2. Santralin Tanıtımı 17

4.3. Santrale Ait Elektrik Üretim Verileri 18

4.4. Meteorolojik Veriler 25

5. MATERYAL VE METOT 29

5.1. Makine Öğrenmesi 29

5.2. Polinom Regresyonu 33

5.3. Destek Vektör Regresyonu 36

5.4. Jupyter Notebook 39

6. ÖNERİLEN ELEKTRİK ÜRETİM TAHMİNİ 41

Sayfa

6.1. Tek Adımda Yapılan Tahmin Çalışması 41

6.2. Adım Adım Olarak Yapılan Tahmin Çalışması (Step By Step Prediction) 56

7. SONUÇ VE ÖNERİLER 67

KAYNAKLAR 71

ÖZGEÇMİŞ 77

ÇİZELGELERİN LİSTESİ

Çizelge		Sayfa
Çizelge 2.1.	2021 yılı kaynak bazında elektrik üretimi (%)	5
Çizelge 2.2.	2020 ve 2021 yılının yenilenebilir enerji kaynaklarının kıyaslanması	6
Çizelge 4.1.	Aylara göre 2020-2021 yılları arasındaki elektrik üretim değerleri	23
Çizelge 4.2.	Hava durumu tahmin değerleri ve elektrik üretim verilerini birlikte ihtiva eden zaman serisi tablosu	26
Çizelge 6.1.	Polinom regresyonu derecelerine göre yapılan tahminler ve gerçekleşen değerler	49
Çizelge 6.2.	Polinom regresyonu derecelerine göre yapılan tahminlerin MAPE değerleri	50
Çizelge 6.3.	Destek vektör regresyonu hiperparametrelerine göre tek adımda yapılan tahminler ve gerçekleşen değerler	54
Çizelge 6.4.	Destek vektör regresyonu hiperparametrelerine göre tek adımda yapılan tahminlerin MAPE değerleri	56
Çizelge 6.5.	Adım adım olarak yapılan tahmin sonucunda polinom regresyonuyla tahmin edilen ve gerçekleşen üretim değerleri	59
Çizelge 6.6.	Adım adım olarak yapılan tahmin sonucunda polinom regresyonuyla 24.08.2021 gününde tahmin edilen ve gerçekleşen üretim değerleri için hesaplanan MAPE değerleri	60
Çizelge 6.7.	Adım adım olarak yapılan tahmin sonucunda polinom regresyonuyla 25.08.2021 gününde tahmin edilen ve gerçekleşen üretim değerleri için hesaplanan MAPE değerleri	60
Çizelge 6.8.	Adım adım olarak yapılan tahmin sonucunda destek vektör regresyonuyla tahmin edilen ve gerçekleşen üretim değerleri	64
Çizelge 6.9.	Adım adım olarak yapılan tahmin sonucunda destek vektör regresyonuyla 24.08.2021 gününde tahmin edilen ve gerçekleşen üretim değerleri için hesaplanan MAPE değerleri	65
Çizelge 6.10.	Adım adım olarak yapılan tahmin sonucunda destek vektör regresyonuyla 25.08.2021 gününde tahmin edilen ve gerçekleşen üretim değerleri için hesaplanan MAPE değerleri	66

ŞEKİLLERİN LİSTESİ

Şekil **Sayfa**

Şekil 2.1. Enerji kaynaklarına göre 2021 yılı elektrik üretimi 6

Şekil 3.1. SVM algoritmasında verilerin haritalanması 10

Şekil 4.1. Fotovoltaik hücrenin yapısı..... 14

Şekil 4.2. Şebekeden bağımsız fotovoltaik sistemlerin bileşenleri 14

Şekil 4.3. Şebekeye bağlı fotovoltaik sistemlerin bileşenleri..... 15

Şekil 4.4. Tek diyotlu fotovoltaik hücre modeli..... 16

Şekil 4.5. PV Hücrenin gerilim değişimine karşı akım ve güç karakteristiği 17

Şekil 4.6. 2020 Ağustos – 2021 ağustos arasındaki aylık GES üretim verileri..... 20

Şekil 4.7. 2020 Ağustos ayına ait günlerin saatlerine göre GES üretim verileri..... 21

Şekil 4.8. 2020 Eylül ayına ait günlerin saatlerine göre GES üretim verileri 21

Şekil 4.9. 2021 Temmuz ayına ait günlerin saatlerine göre GES üretim verileri 22

Şekil 4.10. 2021 Ağustos ayına ait günlerin saatlerine göre GES üretim verileri..... 22

Şekil 4.11. Radyasyon (Ghi) ve üretilen enerji (KWh) arasındaki ilişki 23

Şekil 4.12. Bulutluluk ve üretilen enerji (KWh) arasındaki ilişki..... 24

Şekil 4.13. Sıcaklık ve üretilen enerji (KWh) arasındaki ilişki..... 24

Şekil 4.14. Meteorolojik verilerin temin edilmesi..... 25

Şekil 4.15. Sıcaklık ve radyasyon (Ghi) arasındaki ilişki 27

Şekil 4.16. Bulutluluk ve radyasyon (Ghi) arasındaki ilişki 27

Şekil 5.1. Karesel regresyon modelinin noktasal dağılımı..... 35

Şekil 5.2. Kübik regresyon modelinin noktasal dağılımı 35

Şekil 5.3. SVM Algoritmasında hiper düzlemin belirlenmesi 36

Şekil 5.4. Doğrusal olmayan regresyon fonksiyonu için ϵ tüpü 37

Şekil 6.1. Polinom regresyonu için akış şeması 42

Şekil 6.2. Destek vektör regresyonu için akış şeması 43

Şekil **Sayfa**

Şekil 6.3. Üretim tahmini (Target Value) için öznitelik (Feature) seçim haritaları (Heat Map) 44

Şekil 6.4. Üretim tahmini (Target Value) için öznitelik (Feature) seçim skalası (Pair Plot) 45

Şekil 6.5. 2. Derece Polinom regresyonu ile eğitim verisinin fit etme seviyesi ($R2$ skoru = %96,87)..... 46

Şekil 6.6. 2. Derece Polinom regresyon sonucu yapılan tahmin ile gerçekleşen üretim karşılaştırması (MAPE= %14,58) 46

Şekil 6.7. 3. Derece Polinom regresyonu ile eğitim verisinin fit etme seviyesi ($R2$ skoru = %97,22)..... 47

Şekil 6.8. 3. Derece Polinom regresyon sonucu yapılan tahmin ile gerçekleşen üretim karşılaştırması (MAPE=%16,78) 47

Şekil 6.9. 4. Derece Polinom regresyonu ile eğitim verisinin fit etme seviyesi ($R2$ skoru =%97,63)..... 48

Şekil 6.10. 4. Derece Polinom regresyon sonucu yapılan tahmin ile gerçekleşen üretim karşılaştırması (MAPE =%18,23) 48

Şekil 6.11. C=500, cache_size=3000, epsilon=0,1; kernel=’poly’ iken destek vektör regresyonu ile eğitim verisinin fit etme seviyesi ($R2$ skoru = %85,72)..... 50

Şekil 6.12. C=500, cache_size=3000, epsilon=0,1; kernel=’poly’iken yapılan tahmin ve gerçekleşen üretim karşılaştırması (MAPE=%12,68)..... 51

Şekil 6.13. C=500, cache_size=3000, epsilon=0,1; kernel=’rbf’iken destek vektör regresyonu ile eğitim verisinin fit etme seviyesi ($R2$ skoru = %90,45)..... 51

Şekil 6.14. C=500, cache_size=3000, epsilon=0,1 ve kernel=’rbf’ iken yapılan tahmin ve gerçekleşen üretim karşılaştırması (MAPE=%26,69)..... 52

Şekil 6.15. C=50, cache_size=3000, epsilon=0,1; kernel=’rbf’ iken destek vektör regresyonu ile eğitim verisinin fit etme seviyesi ($R2$ skoru = %89,25)..... 52

Şekil 6.16. C=50, cache_size=3000, epsilon=0,1 ve kernel=’rbf’ iken yapılan tahmin ve gerçekleşen üretim karşılaştırması (MAPE=%25,54)..... 53

Şekil 6.17. C=500, cache_size=3000, epsilon=0,01; kernel=’rbf’ iken destek vektör regresyonu ile eğitim verisinin fit etme seviyesi ($R2$ skoru = %90,45)..... 53

Şekil 6.18. C=500 cache_size=3000 epsilon=0,01; kernel=’rbf’iken yapılan tahmin ve gerçekleşen üretim karşılaştırması (MAPE=%26,74)..... 54

Şekil **Sayfa**

Şekil 6.19. Step By Step Prediction 24.08.2021 Günü 4. dereceden polinom regresyonu tahmin edilen ve gerçekleşen üretim karşılaştırması (MAPE=%15,89) 56

Şekil 6.20. Step By Step Prediction 24.08.2021 Günü 3. dereceden polinom regresyonu tahmin edilen ve gerçekleşen üretim karşılaştırması (MAPE=%18,27) 57

Şekil 6.21. Step By Step Prediction 24.08.2021 Günü 2. dereceden polinom regresyonu tahmin edilen ve gerçekleşen üretim karşılaştırması (MAPE=%18,58) 57

Şekil 6.22. Step By Step Prediction 25.08.2021 Günü 4. dereceden polinom regresyonu tahmin edilen ve gerçekleşen üretim karşılaştırması (MAPE=%13,76) 58

Şekil 6.23. Step By Step Prediction 25.08.2021 Günü 3. dereceden polinom regresyonu tahmin edilen ve gerçekleşen üretim karşılaştırması (MAPE=%16,27) 58

Şekil 6.24. Step By Step Prediction 25.08.2021 Günü 2. dereceden polinom regresyonu tahmin edilen ve gerçekleşen üretim karşılaştırması Üretimi (MAPE=%16,40) 59

Şekil 6.25. 24.08.2021 Günü C=3, cache_size=9000, kernel='rbf', epsilon=0,1 destek vektör regresyonu tahmin edilen ve gerçekleşen elektrik üretimi (MAPE=%11,44) 60

Şekil 6.26. 25.08.2021 Günü C=3, cache_size=9000, kernel='rbf', epsilon=0,1 destek vektör regresyonu tahmin edilen ve gerçekleşen elektrik üretimi (MAPE=%12,11) 61

Şekil 6.27. 24.08.2021 Günü C=30, cache_size=9000, kernel='rbf', epsilon=0,01 destek vektör regresyonu tahmin edilen ve gerçekleşen elektrik üretimi (MAPE=%11,44) 61

Şekil 6.28. 25.08.2021 Günü C=30, cache_size=9000, kernel='rbf', epsilon=0,01 destek vektör regresyonu tahmin edilen ve gerçekleşen elektrik üretimi (MAPE=%12,11) 62

Şekil 6.29. 24.08.2021 Günü C=3, cache_size=9000, kernel='poly', epsilon=0,1 destek vektör regresyonu tahmin edilen ve gerçekleşen elektrik üretimi (MAPE=%11,44) 62

Şekil 6.30. 25.08.2021 Günü C=3, cache_size=9000, kernel='poly', epsilon=0,1 destek vektör regresyonu tahmin edilen ve gerçekleşen elektrik üretimi (MAPE=%12,11) 63

Şekil **Sayfa**

Şekil 6.31. 24.08.2021 Günü C=30, cache_size=9000, kernel="poly", epsilon=0,01 destek vektör regresyonu tahmin edilen ve gerçekleşen elektrik üretimi (MAPE=%11,44) 63

Şekil 6.32. 25.08.2021 Günü C=30, cache_size=9000, kernel="poly", epsilon=0,01 destek vektör regresyonu tahmin edilen ve gerçekleşen elektrik üretimi (MAPE=%12,11) 64

RESİMLERİN LİSTESİ

Resim **Sayfa**

Resim 1.1. Osmaniye İl Özel İdaresi GES 3

Resim 4.1. Osmaniye İl Özel İdaresi GES konumu 18

SİMGELER VE KISALTMALAR

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

Simgeler	**Açıklamalar**
T	Sıcaklık (°K)
$\boldsymbol{\varepsilon}$	Epsilon Tüpü
$\boldsymbol{\beta}$	Regresyon Katsayısı
$\boldsymbol{\zeta}$	Yapay Zekâ Değişkeni

Kısaltmalar	**Açıklamalar**
MAPE	Ortalama mutlak hata yüzdesi
POLY	Polinom temelli çekirdek fonksiyonu
RBF	Radyal temelli çekirdek fonksiyonu
SVM	Destek vektör makinesi
SVR	Destek vektör regresyonu

1. GİRİŞ

Günümüzde sanayileşme ve nüfus giderek artmakta buna bağlı olarak enerji kaynaklarına talep de bir o kadar artmaktadır. Dünyadaki değişme ve gelişmelere paralel olarak enerji Türkiye'de çok büyük önem arz etmekte, önemli bir girdi ve çıktı kalemi olarak ekonomide yerini almaktadır.

Türkiye'nin 7 coğrafi bölgesinde EPİAŞ (Enerji Piyasaları İşletme Anonim Şirketi) sistemine kayıtlı, yenilenebilir ve geleneksel enerjiyle elektrik üretimi yapan santrallerin toplam kurulu gücü Nisan 2022 itibariyle 100.341,2 MW seviyesinde olup bu santrallerin sayısı 10.629 olarak tespit edilmiştir. Türkiye'de EPİAŞ sistemine kayıtlı güneş enerjisi santrallerinin (GES) toplam sayısı Nisan 2022 itibariyle 8.566 olup bu santrallerin toplam kurulu gücü 8.084,9 MW olarak belirlenmiştir. Nisan 2021'de Türkiye'de EPİAŞ sistemine kayıtlı güneş enerjisi santrallerinin toplam sayısı 7.837 ve toplam kurulu güç değeri 7.065,4 MW olarak kaydedilmiştir. 2021 yılından 2022 yılına gelindiğinde güneş enerjisi santrallerinin Türkiye genelindeki toplam kurulu gücünün 1.019,5 MW arttığı tespit edilmiştir. 1 yıl içerisinde güneş enerjisi santrallerinin toplam kurulu gücünde kaydedilen bu artış, tüm dünyada olduğu gibi Türkiye'de de güneş enerjisi santrallerinden elde edilecek elektrik enerjisi miktarının elektrik üretim planlamasında dikkate alınmasının gerekliliğini ortaya koymaktadır. Elektrik üretim planlaması Türkiye Elektrik İletim Anonim Şirketi'ne (TEİAŞ) bağlı Milli Yük Tevzi Merkezi (MYTM) tarafından günlük olarak yapılmaktadır. Bu planlamanın yapılması için Türkiye'nin 21 dağıtım bölgesindeki yetkili perakende satış şirketleri tarafından kendi dağıtım bölgelerinde yer alan, EPİAŞ sistemine kayıtlı ve lisanssız tüm yenilenebilir enerji santrallerinin ve bu santrallerin içerisinde yer alan güneş enerjisi santrallerinin günlük olarak üretebilecekleri enerji miktarları günlük olarak tahmin edilmektedir. Yenilenebilir enerji kaynaklarından elde edilebilecek enerji miktarının tahmini yenilenebilir enerji kaynakları destekleme mekanizması (YEKDEM) ile yasal bir zorunluluk haline getirilmiştir. 21 dağıtım bölgesinde yer alan tüm perakende satış şirketleri kendi bölgelerinde yer alan tüm lisanssız yenilenebilir enerji santrallerinden ve bunların içerisinde yer alan güneş enerjisi santrallerinden elde edilebilecek 1 günlük elektrik enerjisi miktarını günün her bir saatini ihtiva edecek şekilde tahmin etmelidir. Tahmin edilen bu elektrik üretim değerleri her gün EPİAŞ sistemine kaydedilmelidir. Özetle, 21 perakende bölgesinde güneş enerjisi üretim tahmini, *"Yenilenebilir Enerji Kaynaklarının Belgelendirilmesi ve Desteklenmesine İlişkin Yönetmelik"* gereğince ilgili elektrik perakende satış şirketleri

tarafından günlük olarak yapılmak zorundadır. Sadece lisanssız güneş değil yanı zamanda lisanssız rüzgâr, biyokütle, jeotermal ve hidrolik enerji santrallerinden elde edilecek günlük elektrik üretim miktarları da santrallerin yer aldığı bölgedeki ilgili perakende satış şirketi tarafından tahmin edilip EPİAŞ sistemine kaydedilmelidir. Bu çalışmada söz konusu mevzuatta yer alan güneş enerjisi santralinden elde edilebilecek elektrik enerjisinin tahmini ele alınmıştır.

Güneş enerjisi hava durumuna bağlı olarak değişim göstermektedir. Hava durumunu meydana getiren başlıca parametreler güneş ışınımı, sıcaklık, nemlilik, rüzgâr hızı ve bulutluluktur. Tüm bu parametreler güneş kaynaklı elektrik enerjisi arzını belirlemektedir. Hava durumunu teşkil eden bu parametrelerdeki değişmeler güneş kaynaklı elektrik enerjisi arzında anlık artma ya da azalmalara neden olduğu için güneş enerjisinden sürekli ve düzenli elektrik enerjisi tedarik etmek neredeyse imkânsızdır. Diğer taraftan güneş enerjisinin kesin olarak hesap edilememesi ve hava durumuna göre değişiklik arz etmesi, güneş kaynaklı elektrik enerjisinin beslediği şebekede ani gerilim değişmelerine neden olabileceğinden günlük güneş kaynaklı enerjinin tahmin edilmesi önemlidir. Günlük güneş kaynaklı elektrik enerjisi tahmini güneş enerjisindeki ani değişimleri dengeler, bu şekilde şebekede meydana gelebilecek işletme arızaları çözüme kavuşturulur ve arz kalitesi artırılır. Başarılı bir tahmin sayesinde elektrik enerji arzı öngörülebilecek ve bu sayede Türkiye elektrik piyasasında elektriğin birim fiyatının artmasının önüne geçilebilecektir [1-3]

Çalışmada, Osmaniye İl Özel İdaresine bağlı 990 kW kurulu gücündeki güneş enerjisi santrali (Osmaniye İl Özel İdaresi GES) için 2020-2021 yılı elektrik üretim verileri kullanılmıştır. Bu verilerle söz konusu santrale ait 24.08.2021 ve 25.08.2021 günleri için 2 günlük elektrik üretimi tahmin edilmeye çalışılmıştır. Bu tahmin çalışmasının neticesinde ortaya çıkacak sonuç sadece 2 günü ihtiva etmektedir. Santrale ait 1 yıllık üretim verilerine ulaşılabilmiştir. Kişisel Verileri Koruma Kanunu (KVK) gereği güneş enerjisi santrali olan hiçbir özel kurum ve kuruluş tarafından bu santrallere ait üretim verileri paylaşılmamıştır. Sonuçta Osmaniye İl Özel İdaresinden 2020 yılının Ağustos 2021 yılının Ağustosuna kadar 1 yıllık verileri elde edilebilmiştir. Eğer 1 yıldan daha fazla bir veri seti elde edilebilseydi 2 günden daha fazla elektrik üretim tahmini gerçekleştirilebilirdi. Çünkü daha fazla satırda elde edilen veri setiyle %10'dan daha düşük hata oranına sahip ve daha uzun süreyi kapsayan tahminler yapılabilmektedir. Veri seti çok büyük satırlar içerse hatta derin öğrenme algoritmaları dahi kullanılabilir ve böylelikle %10'dan daha az hatalı ve daha uzun günleri

kapsayan tahminler ortaya konabilirdi. Zira Levis'in talep tahminleri kitabında %10'dan daha düşük tahmin hatası başarılı olarak kabul edilmektedir. Bu çalışmadaki ana hedef 2021 Ağustos ayına ait sadece 2 günlük elektrik üretim tahminin gerçekleştirilmesidir. Osmaniye İl Özel İdaresi GES Resim 1.1.'de verilmiştir.



Resim 1.1. Osmaniye İl Özel İdaresi GES [4]

Bu çalışmanın bir diğer amacı da Osmaniye İl Özel İdaresi ve birçok devlet kurumunda mevcut güneş enerjisi santrallerinin yanı sıra yapılması planlanan güneş enerjisi santrallerinin üretebilecekleri elektrik enerjisinin tahmin edilmesi suretiyle bu GES yatırımlarının yüksek getiri potansiyeline sahip olup olmadığının belirlenmesidir. Örnek olarak, Osmaniye İl Özel İdaresi güneş enerji santrali 990 kW kurulu güce sahiptir. Bu santralin yakınına ya da yanı başına 990 kW civarında bir GES yatırımı daha yapılmak istese, bu yatırımın getiri potansiyeli mevcut olan GES'in üretim verileri ve bu mevcut GES'in üretebileceği elektrik enerjisinin tahmin edilmesiyle belirlenebilir. Yani planlanan yatırımın geri dönüş süresi, karlılığı ve uygunluğu hali hazırdaki güneş enerji santralinden elde edilecek verilerle yapılacak üretim tahmini sayesinde belirlenir. Böylece ilave GES yatırımı için etkili bir fayda maliyet analizi yapılmış olur. Birçok danışmanlık şirketleri, veri analizi (Yapay zekâ) teknikleriyle yaptıkları bu tip çalışmalar için yüksek ücretler talep etmektedirler. Ayrıca birçok özel şirket yaptığı GES yatırımının geleceğe yönelik ne kadar kazanç sağlayacağını tespit edebilmek için veri analistlerinden yardım almaktadırlar. Şu anda GES ve RES'ler için üretim tahmini, enerji sektörünün bir gerçeği ve parçası haline dönüşmüştür. Çalışmadaki temel amaç; Çalışma hayatında yatırımcıların gerektiğinde yüksek ücretler ödeyerek veri analistlerine yaptırmış oldukları üretim tahmini işinin

minyatürü niteliğindeki bir kök çalışmayı Osmaniye İl Özel İdaresi özelinde ortaya koyabilmektir.

Bu çalışma ilerleyen zamanlarda EÜAŞ özelinde yapılabilecek ya da Elektrik Üretim Anonim Şirketi'ne (EÜAŞ) yap-işlet-devret kapsamında devredilebilecek GES'lere de uygulandığı takdirde söz konusu yenilenebilir enerji santrallerinin EÜAŞ'a ne sağlayabileceği kazancın belirlenmesinde kullanılabilecektir.

Bazı GES yatırımcıları ise kendilerine ait santrallerde saatlik olarak birkaç günlük (Örneğin 7 gün) elde edilebilecek elektrik üretimini aşağıdaki gerekçelerle tahmin etmek istemektedirler:

- Gerçekleştirilen tahmin çalışması sonucunda üretimin düşük olacağı ön görülen zamanlarda santrale bakım yapmak,
- Uzun vadede mevcut GES yatırımının ne kadar gelir getirebileceğini öngörmek ve eğer ilave bir GES yatırımı yapacaklarsa yatırımın yapılan tahmin çalışması sayesinde karlılığının belirlemek,
- Bilhassa gün öncesi elektrik piyasasına teklif veren lisanslı GES, rüzgâr enerjisi santrali (RES), biyokütle enerji santralleri üretebilecekler saatlik elektrik enerjilerini EPİAŞ aracılığıyla piyasaya gün öncesinden arz etmektedirler. Bu yenilenebilir enerji santralleri de gün öncesi piyasa arzını gerçekleştirirken üretebilecekleri elektrik enerjisinin tahminini *"Yenilenebilir Enerji Kaynaklarının Belgelendirilmesi ve Desteklenmesine İlişkin Yönetmelik"* gereğince yapmak zorundadırlar.

Bu çalışma yedi bölümden meydana gelmektedir. Giriş bölümünde 990 kW kurulu gücündeki Osmaniye İl Özel İdaresi GES özelinde ele alınan çalışmanın amacı, hedefi ve Osmaniye İl Özel İdaresi GES hakkında genel bilgilere yer verilmiştir. İkinci bölümde yenilenebilir enerji kaynakları ve güneş enerjisi hakkında bilgiler sunulmuştur. Üçüncü bölümde literatür çalışmasına yer verilmiştir. Dördüncü bölümde söz konusu santral ve tahmin çalışmasında kullanılacak meteorolojik veriler hakkında detaylı veriler ortaya konmuştur. Beşinci bölümde kullanılan tahmin yöntemleri ve materyal hakkında bilgiler verilmiştir. Altıncı bölümde tahminler, söz konusu yöntemlere göre gerçekleştirilmiştir. Yedinci bölümde sonuçlara ve önerilere yer verilmiş olup bu bölümde ayrıca elde edilen bulgular değerlendirilmiştir.

2. TÜRKİYE'DEKİ YENİLENEBİLİR ENERJİ KAYNAKLARINA GENEL BAKIŞ

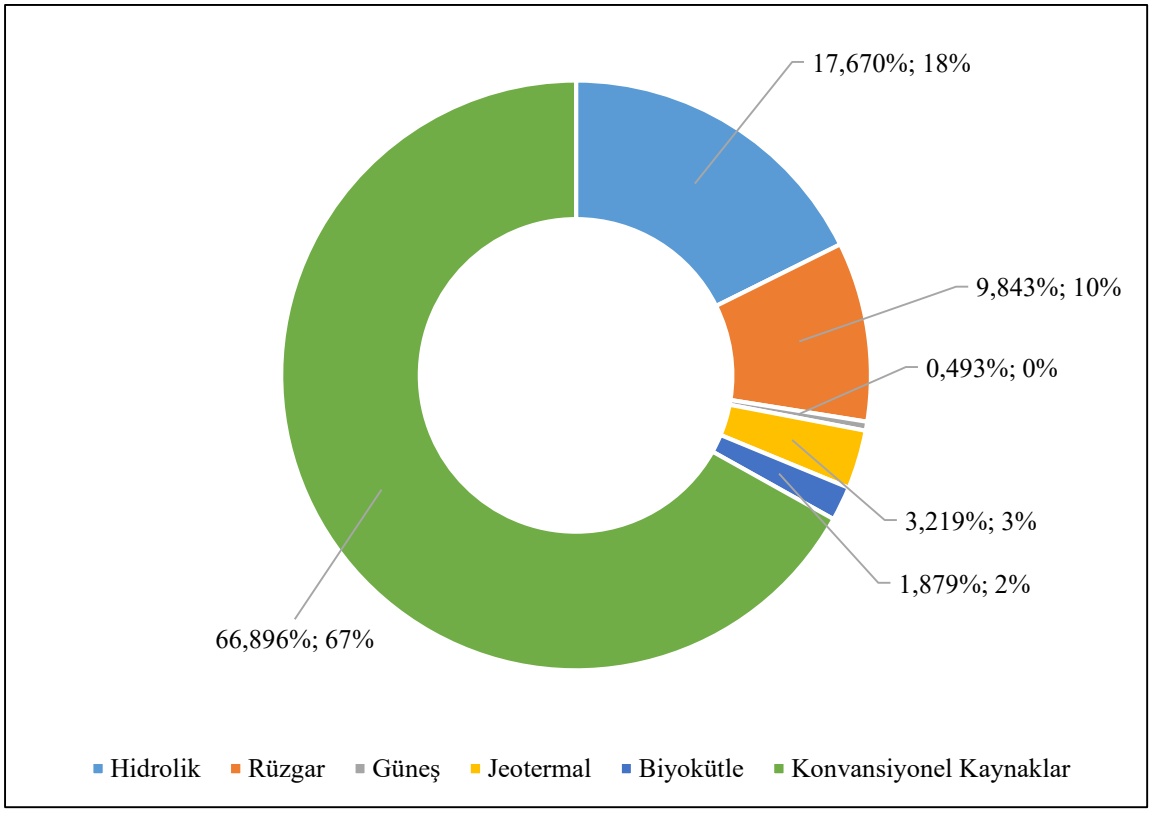
Başlıca yenilenebilir enerji kaynakları; rüzgâr, güneş (Fotovoltaik), biyokütle, jeotermal, hidrolik olmak üzere 5 ana gruba ayırılır. 2021 yılı içerisinde elektrik üretimi kaynak bazında incelendiğinde aşağıdaki Çizelge 2.1. elde edilir:

Çizelge 2.1. 2021 yılı kaynak bazında elektrik üretimi (%) [5]

2021 Yılı Kaynak Bazında Elektrik Üretimi	
Hidrolik	%17,670
Rüzgâr	%9,843
Güneş	%0,493
Jeotermal	%3,219
Biyokütle	%1,879
Konvansiyonel Kaynaklar	%66,896

Çizelge 2.1'den görüleceği üzere konvansiyonel kaynakların elektrik üretimindeki payı yenilenebilir enerji kaynaklarına ait payın tam iki katıdır. Güneş enerjisi ise henüz %1'lik bir paya sahip olamamıştır. Üretimde en büyük ve en önemli paya sahip olan yenilenebilen enerji kaynağı yine hidrolik olmuştur. Hidrolikten sonra ikinci en büyük pay ise rüzgar enerjisine aittir. Bunu sırasıyla jeotermal ve biyokütle takip etmektedir [5].

Son yıllarda yenilenebilir enerjinin payı artma eğilimi göstermiştir. İklim değişikliği ve kuraklık nedeniyle 2021 yılında Türkiye'deki barajlarda yeterli doluluk oranı elde edilememiştir. 2020 yılında yenilenebilir enerjinin tüm kaynaklar içerindeki payı %40 iken 2021 yılında bu oran %33'e gerilemiştir. Yenilenebilir enerjinin 2020'ye göre toplamdaki azalma oranı %7'dir. Bu azalmanın en önemli sebebi hidroelektrik santrallerin yeterince çalışmamasıdır. Zira 2020 yılında %26'larda olan hidrolik payı 2021'de %17'ler mertebesine gerilemiştir. 2020 ile 2021 hidrolik oranları arasındaki pay farkı yani azalma %9 olarak gerçekleşmiş, hidroliğin dışındaki diğer yenilenebilir kaynakların payında %2 artış meydana gelmiştir. %9 azalma ve %2 artmanın neticesi olarak yenilenebilir enerjide 2021 yılında toplamda %7'lik bir azalma kaydedilmiştir. Tüm bu değişimler Çizelge 2.2.'de verilmektedir. Şekil 2.1'de de 2021 yılında kaynaklara göre elektrik üretiminin payları gösterilmektedir [5].



Şekil 2.1. Enerji kaynaklarına göre 2021 yılı elektrik üretimi [5]

Çizelge 2.2. 2020 ve 2021 yılının yenilenebilir enerji kaynaklarının kıyaslanması [5]

Kaynaklar	Hidrolik (%)	Rüzgar (%)	Güneş (%)	Jeotermal (%)	Biyokütle (%)	Toplam (%)
2020	26,818	8,437	0,145	3,210	1,400	40,011
2021	17,669	9,842	0,493	3,218	1,879	33,103
Fark (%)	-9,148	1,405	0,348	0,009	0,478	-6,907

Güneş enerjisi, yenilenebilir enerji kaynakları içerisinde yadsınamaz bir rağbet gördüğü için bu çalışmada Osmaniye İl Özel İdaresine ait fotovoltaik santralin elektrik üretim tahminleri ele alınmıştır. Bu çalışmada Osmaniye İl Özel İdaresi Başkanlığına uhdesinde yer alan GES'e ait üretim tahminlerinin Polinom Regresyon ve Destek Vektör Regresyon yöntemleriyle tahmin edilmesi ve bu tahminlerin doğruluklarının birbirleriyle kıyaslanması ele alınacaktır.

3. LİTERATÜR İNCELEMESİ

Güneş ışınımının tahmin edilmesinde literatürde genel olarak yapay sinir ağları ve ARIMA (Autoregressive Integrated Moving Average) modellerinden yararlanılmaktadır[6]. Günümüzde ise destek vektör makinelerinden ve k-ortalamalar yöntemlerinden daha sık bir şekilde faydalanıldığı gözlemlenmektedir [6]. Ayıca Boosting, Regresyon ağaçları, Rastgele ormanlar gibi modeller daha az tercih edilmektedir [6]. Tahmin başarısının artması için araştırmacılardan bazıları hibrit modelleri tavsiye etmektedirler [7]. Mesela, Saklı Markov modeli ve Destek Vektör Regresyonu ile değişik iklim şartlarında 5-30 dakika sonraki güneş ışınımının uygun bir şekilde tahmin edildiği gözlemlenmiştir [7].

Das ve arkadaşları tarafından yapılan bir başka çalışmada ise değişik hava şartlarında fotovoltaik pillerinden enerji üretimini başarılı bir şekilde tahmin etmek için bir destek vektör regresyon ile yapılmış bir model tavsiye edilmiştir. Bu model üç değişik fotovoltaik güç ünitesine uygulanmış ve ardından başarısı tetkik edilmiştir. Gerçekleşen ve tahmin edilen fotovoltaik güçleri arasındaki farklılıklar makul bir aralıkta (%10'dan büyük olmamak şartıyla) olduğu ve herhangi bir nokta için kayda değer dalgalanmalara rastlanmadığı belirtilmiştir. Kullanılan modelin başarı metrikleri RMSE, MAE (Ortalama mutlak hata) ve MBE olmak üzere başarı değerleri sırasıyla %34,57 ve %11,34 ve %3,08 şeklinde bulunmuştur [8].

Theocharides ve arkadaşları tarafından yapılan bir çalışmada fotovoltaik güç çıkışını tahmin edilmesi için yapay sinir ağları, destek vektör makineleri ve regresyon ağaçları dahil farklı modellerden elde edilen sonuçlar gözlemlenmiştir. Her yöntemin çıkış gücünü tahmin etme başarısı; 1 yıl boyunca elde edilen, gerçek üretim verileri üzerinde yapılan testler ile ölçülmüştür. Değişik yapay zekâ yöntemleri arasında karşılaştırma yapıldığında, yapay sinir ağları yönteminin diğer modellerden daha başarılı olduğu, MAPE ve RMSE başarı metrik değerlerinin sırasıyla % 0,6 ve % 0,76 olarak gerçekleştiği belirtilmiştir [9].

Gala ve arkadaşları tarafından yapılan bir çalışmada destek vektör regresyonu, artan eğimli regresyon ve rastgele orman regresyonu ile Nümerik Hava Tahmini (NHT) yapılmış, elde edilen toplam 3 saatlik güneş ışınımı tahmini için bu üç yöntem ile hibrit bir yöntem oluşturulmuştur. Diğer taraftan, elde edilen 3 saatlik tahminler kullanılarak 1 saatlik tahminler elde edilmeye çalışılmıştır. Makine öğrenmesi yöntemlerinin yani bu çalışma için

hibrit yapay zekâ modelinin başarılı bir yöntem olduğu ve güneş ışınımı tahmini yapmak için elverişli olduğu belirtilmiştir [10].

Assouline ve arkadaşları tarafında güneş enerjisi potansiyelini tahmin etmek için yapılan bir çalışmada destek vektör makinesi yöntemi ile coğrafi bilgi sistemleri vasıtasıyla İsviçre'de bulunan 2477 hanenin 1901 adedi için çatı güneş enerji potansiyeli tahmini yapılmış olup araştırmada veri seti k-kat çapraz doğrulama ile eğitim ve test kümelerine bölünmüştür. Farklı destek vektör makinesi modelleri oluşturularak başarıları RMSE ile kıyaslanmıştır [11].

Teo ve arkadaşları tarafından yapılan bir çalışmada PV gücünün tahmin edilebilmesi için yapay sinir ağları modelinden de yararlanılabilir. Model girdileri olarak, ortam ve panel yüzeyi sıcaklıkları (°C), günlük toplam enerji (J), radyasyon enerjisi (W/m^2) ve elektrik gücü (W) ile yapılan tahmin çalışmasında, 30 gün için 3 adet veri seti elde edilmiştir [12].

Bugünün en önemli sorunlarından olan küresel ısınmaya çözüm bulmak amacıyla akademisyenler araştırmalar ortaya koymaktadırlar [13-15]. Nüfusun artması ve endüstrileşme ve birincil enerji kaynaklarının kullanımındaki artış küresel ısınmaya neden olmaktadır [13-15]. Dünyanın daha yaşanılası bir yer haline gelmesi için dünya genelinde yenilenebilir enerji tesisleri inşa edilmektedir. Yenilenebilen enerji kaynaklarından güneş enerjisi son yıllarda enerji sektöründe gördüğü ilgi bakımından artan bir ivme yakalamıştır [13-15]. Dünya genelinde ve Türkiye'de devlet teşvikleri ile fotovoltaik kaynaklı elektrik üretiminde yakın dönemde hızlı bir artış kaydedilmiştir [13-15].

Son dönemde fotovoltaik kaynaklı enerjinin tahmin edilmesi üzerine literatüre bazı çalışmalar kazandırılmıştır. Demolli ve arkadaşları tarafından bir çalışma yapılmıştır. Bu çalışmada Destek Vektör Makinesi (DVM), Lasso Regresyon ve KNN algoritmalarından yararlanarak Niğde kentinin güneş enerjisi hakkında tahminde bulunmuşlardır. Bu metotlar birkaç performans metriği bakımından kıyaslanmış ve genel olarak değerlendirilmiştir. Edinilen sonuçlardan destek vektör makinesinden daha başarılı tahmin sonuçlarının elde edildiği açıklanmıştır [16].

Gök ve arkadaşları tarafından yapılan çalışmada yapay sinir ağlarından yararlanılmıştır. Veri seti güneş enerji santraline ait 1 yıllık güneş enerji verisi ve bulutluluk verisinden

oluşturulmuştur. Bir gün sonrasına ait güneş enerjisi tahmin edilmiştir. Bulutluluk verisi kullanılan ağ ve kullanılmayan ağ kıyaslanmıştır. Yapılan çalışmada bulutluluk verisinin yer aldığı ağın bütün performans metrik sonuçları bakımından daha başarılı olduğu ortaya çıkarılmıştır [17].

Wolff ve arkadaşları tarafından yapılan çalışmada güneş enerjisinin tahmin edilmesi amacıyla destek vektör makinesi temelinde hibrit bir yöntem tavsiye edilmiştir. Veri seti, 15 dakika aralıklarla elde edilmiş güneş enerjisi, aynı aralıkla elde edilmiş sıcaklık ve bulutluluk verisinden elde edilmiştir. İyileştirilmiş destek vektör makinesi yönteminden elde edilen sonuçlar fiziksel yaklaşım temelli tahmin metotlarıyla kıyaslanmış ve bütün metrik sonuçları detaylı olarak ele alınmıştır [18].

Yıldız ve arkadaşları tarafından kernel aşırı öğrenme makinesi tabanlı bir yöntemi Kilis ilinde yer alan bir güneş enerji santralinden elde edilen çıkış gücünün tahmin edilmesi için tavsiye edilmiştir. Tavsiye edilen tahmin yönteminin başarısını araştırmak amacıyla ayrıntılı kıyaslamalar yapılmıştır [19].

Li ve arkadaşları tarafından, kısa dönemli güneş radyasyon tahmin yöntemlerinin, makine öğrenme algoritmaları, Gizli Markov Modeli ve destek vektör regresyonu temelinde Avustralya Meteoroloji dairesinden edinilen veriler kullanılarak MATLAB ara yüzünde bir tahmin platformu oluşturulmuştur. Elde edilen deneysel sonuçlara göre, makine öğrenme temelindeki tahmin algoritmalarının, değişik meteorolojik şartlar altında gelecek 5-30 dakika solar radyasyonu büyük ölçüde tahmin edebildiği gözlemlenmiştir [7].

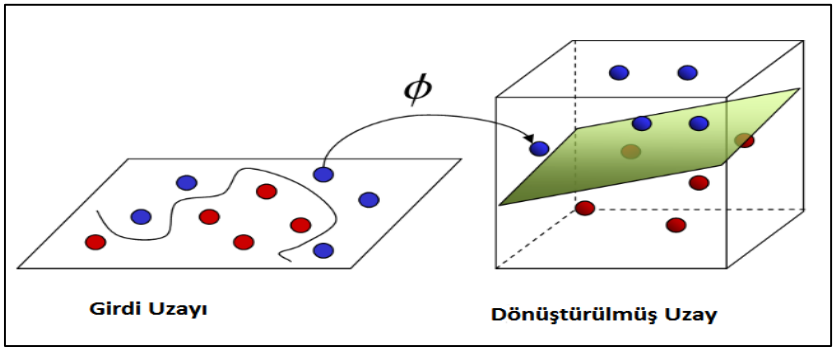
Goodale ve arkadaşları tarafından 1998 yılında yapılan çalışmada, basit polinom regresyon yönteminin, lokasyon değişkenliğini %52-93 oranında izah edebildiği, standart hataların asgari olduğu ortaya konmuştur. Polinom regresyon yöntemi kullanılan iklim tahmin modellerinin daha kısa zamanda elde edildiği ve daha küçük bir depolama alanı gerektirdiği ortaya çıkarılmıştır [20].

George ve arkadaşları tarafından 2016 yılında gerçekleştirilen çalışmada, Hindistan'ın Idukki havzası için yağış tahmini yapılmaya çalışılmıştır. Çalışmada; çoklu doğrusal regresyon, yapay sinir ağları ve bölgesel polinom regresyon olmak üzere 3 değişik yöntem ele alınmıştır. Ele alınan yöntemlerde öznitelikler; ortalama deniz seviyesi basıncı,

jeopotansiyel yükseklik, hava sıcaklığı, bağıl nem ve rüzgâr hızı olarak seçilmiştir. Her bir model birbiriyle mukayese edildiğinde, polinom regresyon yöntemiyle havzada yağış tahminlerinin daha başarılı bir şeklide elde edildiği ortaya konmuştur. Mevsimsellik faktöründen etkilenen havzalarda başarılı yağış tahminlerinin yapılabilmesi bakımından polinom regresyon esnek ve etkili bir yöntem olarak ortaya konmuştur [21].

Destek vektör makinelerinden genel olarak regresyon ve sınıflandırma problemlerinde yararlanılmaktadır. Destek vektör makineleri temelde iki sınıfa ait üyelerin birbirinden ayırt edilmesi amacıyla en iyi sınıflandırma fonksiyonunu tespit etmek için kullanılmaktadır. Diğer bir ifadeyle, destek vektör makineleri; marjını (Sınırı) en yüksek doğruyu seçer, sınıflandırma hatasını asgariye indirir ve iki sınıfı birbirinden ayırt etmek için öznitelikleri (Özellik girdileri) kullanarak sınıfları en iyi biçimde birbirinden ayıracak bir hiper düzlemi tespit etmeyi amaçlamaktadır [22]. Yapılan bu çalışma regresyon problemi olup çalışmada destek vektör regresyonu kullanılmıştır.

Destek vektör makineleri (Support Vector Machines – SVM) genellikle verilerin doğrusal şekilde birbirinden ayrıştığı hallerde kullanılmaktadır. Ayrıca, verilerin *sigmoid*, *polinomiyal*, lineer ve *radyal* tabanlı gibi çekirdek fonksiyonları kullanılarak lineer ayrışabilecek hale getirilmesinin mümkün olması nedeniyle lineer ayrışamayan verilerin veri setinde yer alması halinde de kullanılabilmektedir [22]. Bir başka ifadeyle, çekirdek fonksiyonları kullanılıp lineer olmayan veri kümelerinin daha büyük bir boyuta taşınması söz konusudur. Şekil 4.1.'de verilerin 2 boyutlu uzaydan 3 boyutlu uzaya haritalanması gösterilmiştir. Verilen şekilden anlaşılacağı üzere veriler doğrusal ayrıştırılabilir hale getirilmiştir [23].



Şekil 3.1. SVM algoritmasında verilerin haritalanması (Moreira, 2011)

Destek vektör makineleri bilhassa iki sınıf için ayrıştırma işlemi söz konusudur. Fakat bu ifadeden destek vektör makinelerinin ikiden çok sınıfın yer aldığı uygulamalarda da kullanılmasının mümkün olmadığı anlamı çıkarılmamalıdır. Bu nedenle, destek vektör makineleri çoklu sınıfa sahip çalışmalar için de kullanılabilmektedir. Burada, sınıfların ayrışabilmesi için bire karşı tümü yaklaşımı işletilebilmektedir. Yani, ilk olarak bir sınıf etiketi seçilip bu sınıfa 1, öteki sınıflara -1 etiketi verilir böylece bir sınıf ile diğer sınıfların tamamı karşılaştırılmış olur. Söz konusu işlem, sınıfların tamamında ayrı ayrı uygulanır ve sınıf sayısı kadar sınıflandırıcı bu işlem sonucunda elde edilir. Bir diğer ifadeyle, sınıf sayısı adedince destek vektör makinesi eğitilip, tahmin aşamasına gelindiğinde her bir destek vektör makinesinin çıktısı birbirleriyle mukayese edilerek en güvenli ve en başarılı netice bu sonuçların içerisinden seçilmektedir [24].

Destek Vektör Regresyon (Support Vector Regression - SVR) algoritmasında Kernel Trick dediğimiz çekirdek hilesi yöntemiyle aslında mevcut regresyon modelini çok boyutlu hale getirerek yüksek boyutta özellik vektörleri ihtiva eden tahmin modellerinin daha kolay ve etkin bir şekilde çözümlenmesini yani daha az hata ile tahmin yapabilmesini sağlanmaktadır. Polinom regresyon ile aslında modele daha fazla özellik katılarak bilhassa karmaşık problemlerin etkin bir şeklide çözülmesi sağlanmaktadır. Daha fazla özellik katılması ele alınan modelin yavaş çalışmasına neden olmaktadır. Burada Kernel Trick yani çekirdek hilesi devreye girerek ele alınan problemin hızlı bir şekilde çözümlemesine katkı sağlamaktadır. Örneğin polinom çekirdek hilesi ele alınan karmaşık bir probleme çok sayıda polinom özelliği katılmış gibi ele alınan problemi çözmektedir, fakat buradaki polinom çekirdek hilesinde modele aslında polinom özelliği katılmamıştır. Sadece çekirdek hilesiyle problem çok sayıda polinom özelliği katılmış gibi çözümlenmiştir. Çekirdek hilesinin en önemli özelliği ele alınan tahmin problem ya da modelinin hızlı ve etkin bir şekilde çözüme kavuşturulmasıdır [25]. Tahmin çalışmasında Radial Basis Function (Radyal Temelli Fonksiyon) ve Polynomial Kernel olmak üzere iki tür çekirdek hilesi (Kernel Trick) kullanılmıştır.

Destek vektör makineleri özellikle karmaşık ancak küçük ve orta ölçekli veri setlerinin sınıflandırma ve regresyon problemlerinde çok uygun bir yöntemdir [25]. Çalışmada ele alınan problem de az sayıda veri ihtiva ettiği için tahminin destek vektör regresyonu ile başarılı bir şekilde yapılabileceği öngörülmüştür. Ayrıca veri seti kısıtlı olduğu için ver seti üzerinde ezber yapılmaması amacıyla polinom regresyon önerilmiştir [25].

4. TAHMİN ÇALIŞMASI YAPILAN GÜNEŞ ENERJİSİ SANTRALİNE AİT GENEL BİLGİLER VE SANTRAL ELEKTRİK ÜRETİM VERİLERİ

4.1. Fotovoltaik Sistemler

Fotovoltaik pillerden oluşan fotovoltaik enerji sistemleri, güneş kaynaklı fotonların enerjisini DC elektrik enerjisine çeviren yenilenebilir enerji üretim sistemleridir [26]. Fotovoltaik (PV), güneşten gelen fotonları doğrudan elektrik enerjisine dönüştürmek için güneş pillerinden faydalanmaktadır. Bir fotovoltaik hücre oldukça küçük bir yapıdır ve yaklaşık olarak 1-2 watt güç üretebilir. Elde edilen bu gücü artırmak için hücreler birbirine eklenebilir ve birleştirilebilir (Şekil 4.1.) [27].

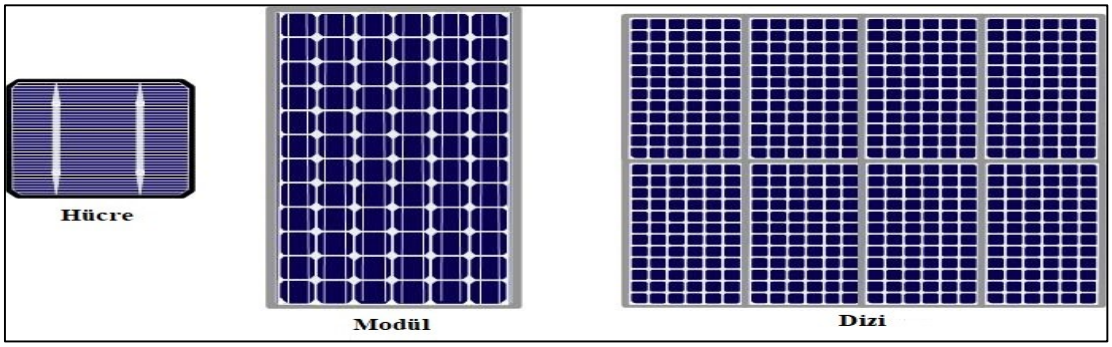
Bir fotovoltaik güç sistemi, doğru akımı alternatif akıma üzere invertörden, akülerden (depolama yapılacaksa), modüllerin montajı için mekanik bir yapıdan ve kablo ekipmanından meydana gelmektedir. Fotovoltaik (PV) sistemi, bir su pompasını, bir evdeki bazı elektronik cihazları ve aydınlatma sistemlerini beslemek için kullanılmaktadır [27].

Fotovoltaik hücreleri, farklı türlerde yarı iletken malzemelerden yapılabilir. İlk tür silikon, kristal formu (c-Si) veya amorf silikondur (a-Si). İkinci tür silikon ise, bakır indiyum galyum diselenid ($CuInGaSe_2$) ve kadmiyum tellür (CdTe) ve ince film silikon dahil polikristal ince film yarı iletkenlerdir. Üçüncü tür, galyum arsenit (GaAs) içeren tek kristalli ince filmlerdir [27].

Fotovoltaik (PV) sistemleri genel olarak 2 kategoride incelenebilir: düz plakalı sistemler veya yoğunlaştırıcı sistemler. Düz plakalı PV modülleri en yaygın dizi tasarımıdır. Bu modüller ya yerinde sabitlenebilir ya da bu modüllerde güneşin hareketini izlemesine izin verilebilir. Yoğunlaştırıcı sistemler, yoğunlaştırıcı olarak lensler veya aynalar kullanarak yoğun güneş ışığı altında çalışır, küçük bir güneş pilinin oldukça geniş bir alanda parlayan güneş enerjisini yakalamasını sağlar. Bu, ihtiyaç duyulan ve pahalı olan yarı iletkenlerden adet bakımından tasarruf sağlar, fakat sistemi karmaşık hale getirir [27].

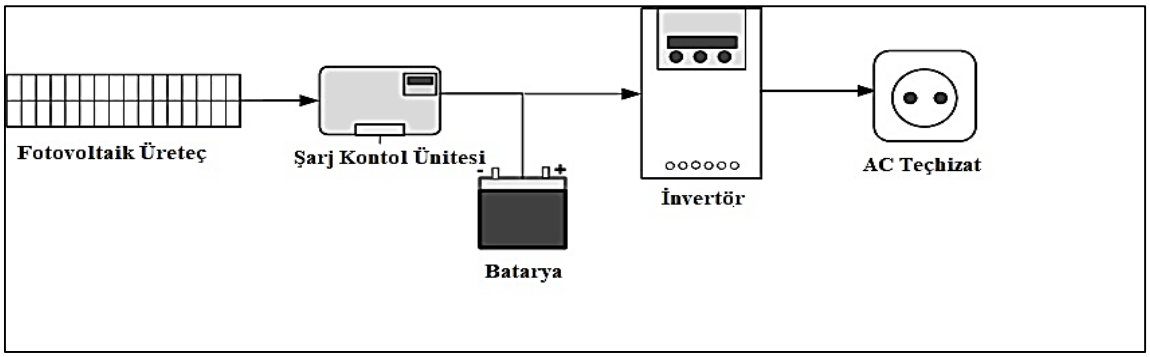
Böylelikle fotovoltaik piller seri ya da paralel birleştirilerek modülleri, modüller bir araya gelerek panelleri meydana getirirler. Yüklü miktarda elektrik enerjisi arzı sağlayabilmek için

fotovoltaik paneller paralel ya da seri birleştirilip fotovoltaik panel dizisini (array) meydana getirirler. (Şekil 4.1.) [27].



Şekil 4.1. Fotovoltaik hücrenin yapısı [27]

Depolama yapan (Akülü) PV sistemleri, şebeke gücünün bulunmadığı veya şebeke hattının uzatılmasının çok pahalı olacağı alanlarda elektrik sağlamak için güzel bir çözümdür. Fotovoltaik sistemler doğru veya alternatif akım gerektiren ekipmanlara enerji sağlamak için tasarlanabilir. Bazı cihazlar ve aydınlatma cihazları için alternatif akım gerektiğinden, aküler ve beslenecek olan yük arasına bir invertör bağlanmalıdır. Doğru akım (DC) alternatif akıma (AC) dönüştürülürken az miktarda enerji kaybı olmasına rağmen, bir invertör herhangi bir alternatif akımla çalışan cihazın ve aydınlatma sisteminin çalıştırılmasını mümkün kılar (Şekil 4.2.) [27].

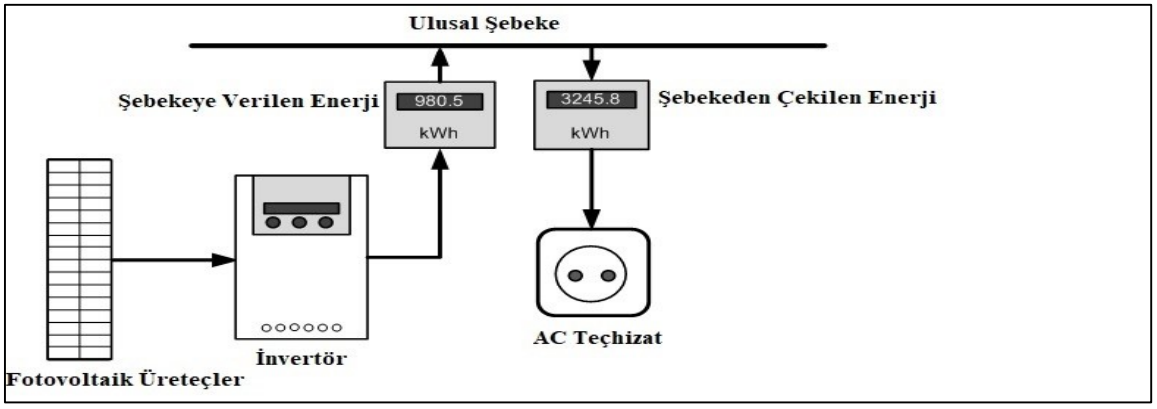


Şekil 4.2. Şebekeden bağımsız fotovoltaik sistemlerin bileşenleri [27]

Bataryalı (Akülü) PV sistemlerinde, PV modülleri bir bataryaya, batarya da yüke bağlanır. Gün boyunca, PV modülleri bataryayı (Aküyü) şarj eder ve ardından batarya, gerektiğinde yüke elektrik enerjisi sağlar. Şarj denetleyicisi adı verilen basit bir elektrikli cihaz, bataryanın uygun ve düzgün bir şekilde şarj edilmesini sağlar, aşırı şarj olmasını veya tamamen boşalmasını önleyerek ömrünün uzamasını sağlamaktadır [27].

Nikel-kadmiyum bileşenli şarj edilebilen akümülatörler (Bataryalar), birçok PV ile çalışan cihazlarda (Yükler için) kullanılır, ancak kurşun asit piller ve kapasitörler de kullanılabilir. PV sistemlerinde kullanılan bataryalar, araba akülerine benzer, ancak depolanan enerjinin daha fazlasının her gün kullanılması için farklı şekilde tasarlanırlar. PV projeleri için tasarlanan bataryalar, otomotiv akümülatörleriyle aynı riskleri taşırlar, taşıma ve depolamada aynı özeni gerektirirler. Mühürsüz bataryalardaki sıvı periyodik olarak muayene edilmeli ve akümülatör aşırı soğuk havalarda muhafaza edilmelidir [27].

PV sistemleri, uygun bir invertör aracılığıyla enterkonnekte sisteme bağlanabilir. Bu durumda enerji depolamaya gerek yoktur. PV sistem tarafından üretilen elektrik, ilk olarak evdeki herhangi bir elektrik enerjisi gereksinimini (Elektronik ev aletleri, aydınlatma armatürleri, vb.) karşılamak için kullanılır. PV sistem beslediği hanenin ihtiyaç duyduğundan daha fazla elektrik üretilirse, fazla enerji net ölçüm yoluyla bağlantılı olduğu şebekeye geri verilir. PV sisteminin ürettiğinden daha fazla elektrik gerektiğinde (Örneğin, akşamları veya bulutlu günlerde), hanenin ihtiyaç duyduğu elektrik enerjisi şebekeden alınır (Şekil 4.3.). Ay sonunda, şebekeye verilen elektrik enerji miktarından, şebekeden çekilen enerji miktarı tenzil edilir, yani verilen ve çekilen enerjiler mahsuplaştırılır. PV sistemi, her ay şebekeden satın alınan elektrik miktarını azaltır [27].



Şekil 4.3. Şebekeye bağlı fotovoltaik sistemlerin bileşenleri [27]

Şekil 4.4'te bir fotovoltaik pilin hücrenin basit bir model devresi verilmiştir. Bu model devrede, 5 parametre yer almaktadır. Bu 5 parametre şu şekilde sıralanabilir: I_{SC}, I_S, R_S, R_p, ve n. Burada, I_{SC}, fotovoltaik hücrenin ürettiği akımı, R_S , fotovoltaik hücrenin iç direncinin ve bağlantı dirençlerinin toplamını, R_P paralel kaçak akım direnci olarak tanımlanmaktadır. I_S ters yönlü saturasyon akımı olup n ise idealden uzaklaşma faktörü olarak tanımlanır.

Diyotla ilgili akım denklemi, Eş. 4.1'de verilmiştir. Bu denklemde; I_S ters yönlü satürasyon akımını, q elektron yükünü, n idealden uzaklaşma faktörünü, k boltzman sabitini, T Kelvin cinsinden çalışma sıcaklığını belirtmektedir [28].

$$I_D = I_S \left(e^{\frac{qV_a}{nkT}} - 1\right) \tag{4.1}$$

I_D: Diyottan geçen bağımsız akım

I_S : Ters yönlü saturasyon akımı

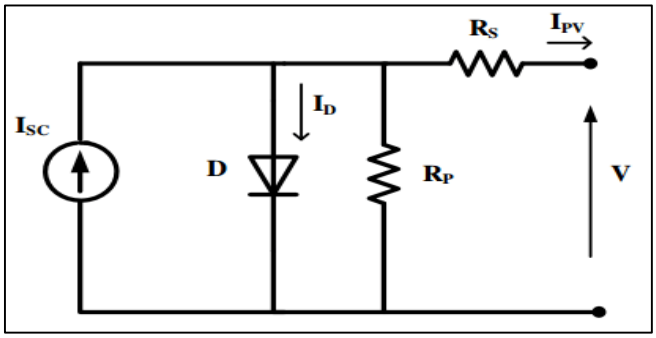
V_a: Diyotun üzerinde oluşan gerilim

q : Elektron yükü (1,602x10^{-19} Coulomb)

n : İdealden uzaklaşma faktörü ya da emisyon katsayısı

k : Boltzman sabiti (1,38x10^{-23} Joule/Kelvin)

T : Sıcaklık (°K)



Şekil 4.4. Tek diyotlu fotovoltaik hücre modeli [28]

I_{SC}: Foto (Kısa devre) akım

I_{PV}: Fotovoltaik hücrenin çıkış akımı

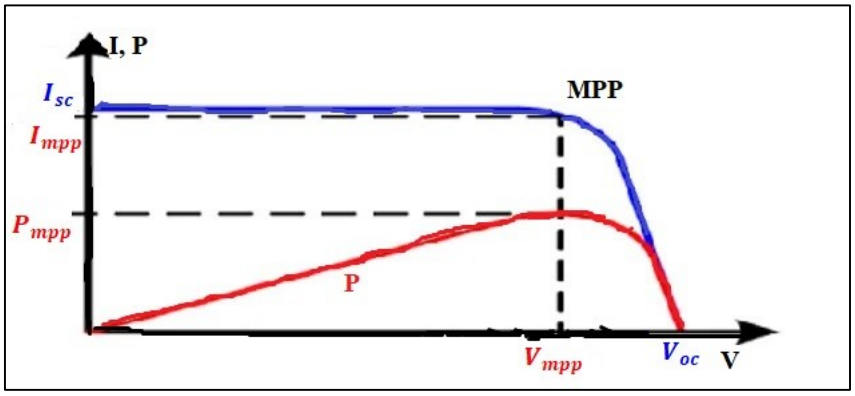
V: Fotovoltaik hücrenin çıkış gerilimi

I_D: Diyottan geçen bağımsız akım

R_S: Seri direnç

R_P: Şönt direnç

Böyle bir fotovoltaik devreye ait akım gerilim karakteristiği grafiği Şekil 3.5.'te gösterilmiştir:



Şekil 4.5. PV Hücrenin gerilim değişimine karşı akım ve güç karakteristiği [29]

Şekil 4.5.'teki parametrelerden

I_{SC}: Foto (Kısa devre) akım

I_{mpp}: Maksimum güç noktasındaki akım

V_{mpp}: Maksimum güç noktasındaki gerilim

MPP: Maksimum güç noktası

V_{OC}: Açık devre gerilimi

4.2. Santralin Tanıtımı

Osmaniye İl Özel İdaresi GES, Osmaniye İl Merkezine bağlı Cevdetiye Kasabasında kurulmuş olup 28.586,04 m^2 arsa üzerinde 3.640 panelden meydana gelen, 990 kW kurulu

güce sahip bir fotovoltaik güç santralidir. Bu santral 5 yıl kadar bir sürede kendi yatırım giderlerini amorti edecek ve ilerleyen yıllarda edinilecek gelir İl Özel İdaresi uhdesinde yapılacak başka yatırımların giderlerinde değerlendirilecektir. Osmaniye İl Özel İdaresi GES konumu Resim 4.1.'de verilmiştir. Ayrıca bu santrale ait elektrik üretim verileri Şekil 4.6.'da grafikler halinde (4.6.(a) ve 4.6.(b)) verilmiştir [30].

Kurulu gücü 990 kW olan, 20 dönüm arazi üzerinde tesis edilmiş, 3640 adet her biri 310 W_e gücünde monokristal panelden oluşan Cevdetiye GES'in Google Earth görünümü Şekil 4'te gösterilmiştir. Bu santral yaklaşık 9000 konutun 1 günlük elektrik enerjisini karşılayabilmektedir. Ayrıca her biri 60 kW olan 17 adet kesici kullanılmış olup 1250 kVA gücünde 0,4/36 kV yükseltici trafo kullanılmıştır. Solar panellerin sehpalarının yatay düzlemle yaptığı açı değeri 25°'dir. Panel sıraları arasındaki yatay mesafe 3,25 metredir. Panellerin her birinin verimi %18,76'dır. Her bir kesicinin nominal çıkış gücü 400 VAC'dir [31].



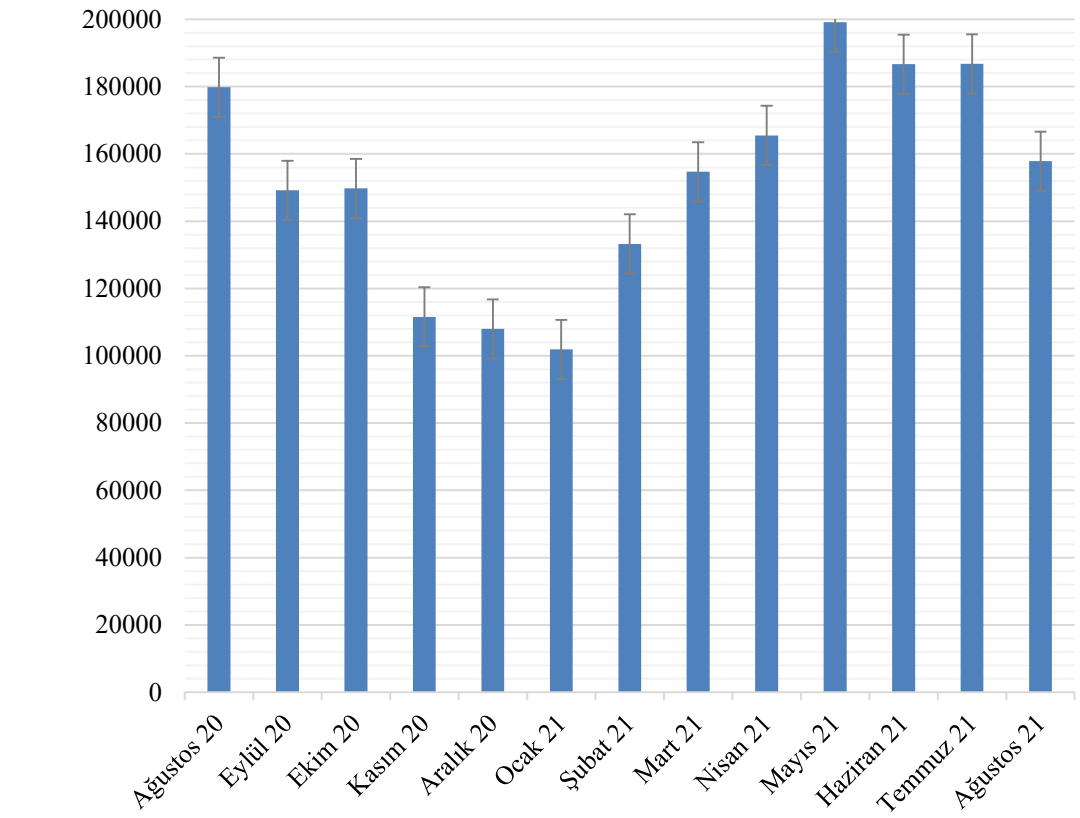
Resim 4.1. Osmaniye İl Özel İdaresi GES konumu (37.129621, 36.213784) [32]

4.3. Santrale Ait Elektrik Üretim Verileri

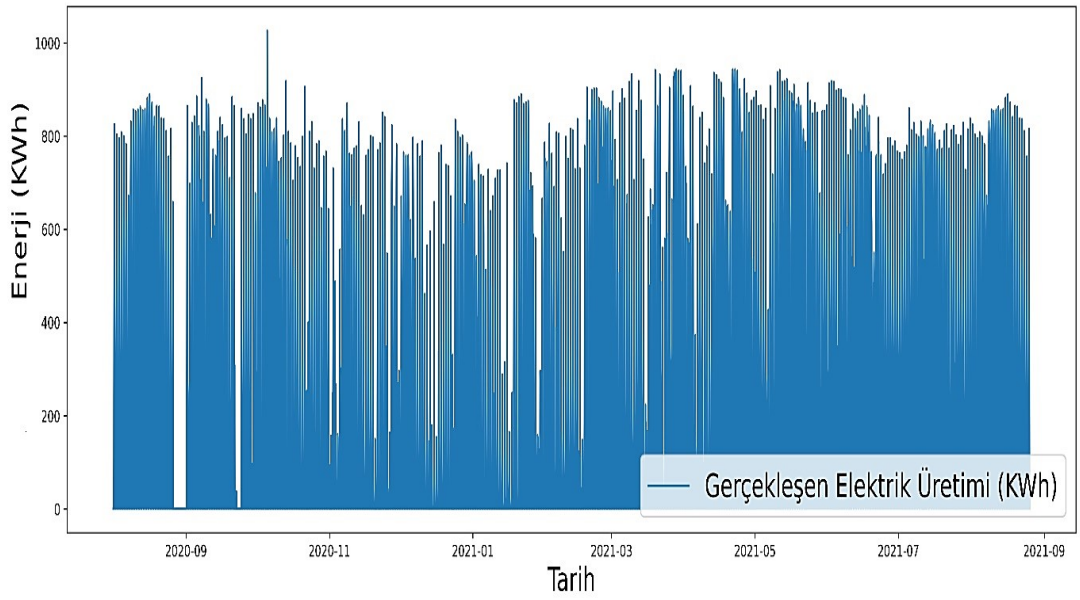
Osmaniye İl Özel İdaresi Güneş Enerji Santrali (GES) 2020-2021 yıllarına ait elektrik üretim verileri Şekil 3.6.'da verilmiştir. Şekil 3.6(a)'da gün bazında üretimler sürekli bir şekilde ifade edilmiş olup Şekil 3.6(b)'de ise bu üretim verileri 2020-2021 aralığında aylık olarak gösterilmiştir. Aslında bu iki grafik birbirinin aynısıdır, fakat (a)'da üretim verileri günlük olarak sürekli bir şekilde ifade edilmiştir. Üretim verilerinin değişim trendi ise (b)'den kolay bir şekilde anlaşılabilmektedir.

Şekil 4.7.- 4.10.'da ise sırasıyla 2020 Ağustos, 2020 Eylül, 2021 Temmuz ve 2021 Ağustos aylarına ait elektrik üretim verileri görsel olarak verilmiştir. Çizelge 4.1.'de 2020-2021 yılları arasındaki elektrik üretim değerleri aylık olarak verilmiştir. Şekil 4.6(a)'da 2021 Ocak ayında elektrik üretimi minimum olarak gözlemlenmiştir. Çizelge 4.1.'den de görüleceği üzere en az elektrik üretimi Ocak 2021'de mevcuttur, en çok üretim de Mayıs 2021'de gerçekleşmiştir.

Şekil 4.11 - 4.13'te ise sırasıyla radyasyon (Ghi), bulutluluk ve sıcaklık ile üretilen enerji (KWh) arasındaki ilişki verilmiştir. Bu grafiklerden Şekil 4.11.'de verilen radyasyon (Ghi) ve üretilen enerji (KWh) grafiğinde üretilen enerji ile radyasyonun artış ve azalışında paralellik olduğu yani, radyasyon azaldığında üretilen enerjinin de azaldığı, radyasyon arttığında üretilen enerjinin de arttığı gözlemlenebilir. Şekil 4.12.'de bulutluluk ile üretilen enerji arasında ters orantı olduğu söylenebilir. Bulutluluk arttığında üretilen enerji (KWh) azalmış, bulutluluk azaldığında ise üretilen enerji (KWh) artmıştır. Şekil 4.13.'te sıcaklık ve üretilen enerji (KWh) arasındaki ilişki verilmiştir.

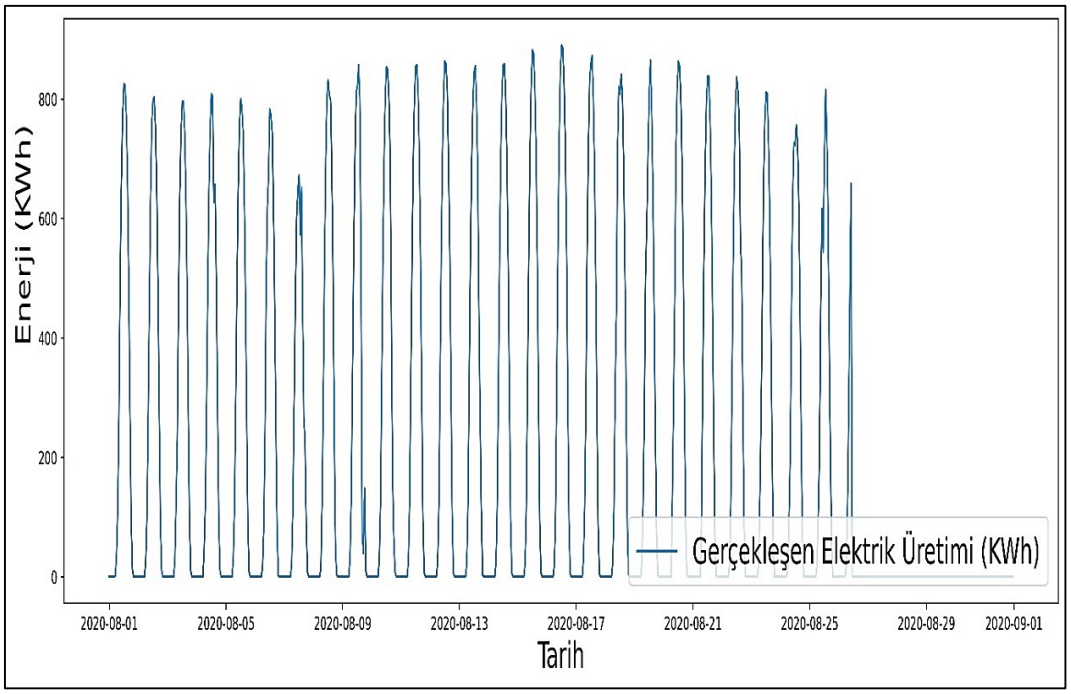


a) Aylık bazda 1 yıllık elektrik üretim değerleri

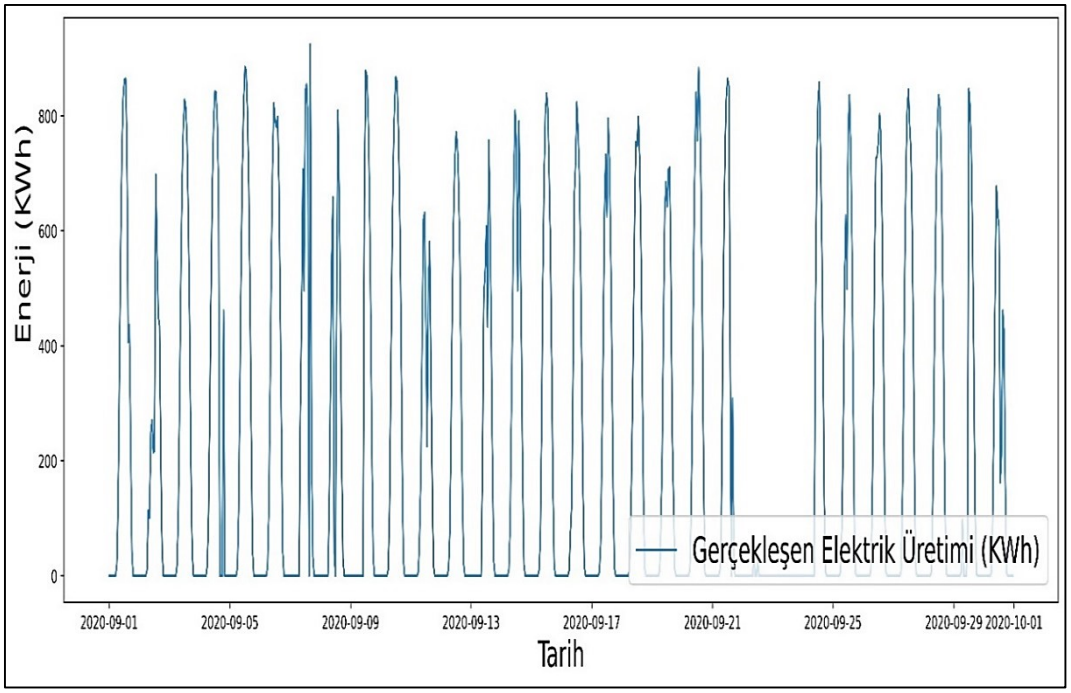


b) Saatlik bazda 1 yıllık elektrik üretim değerleri

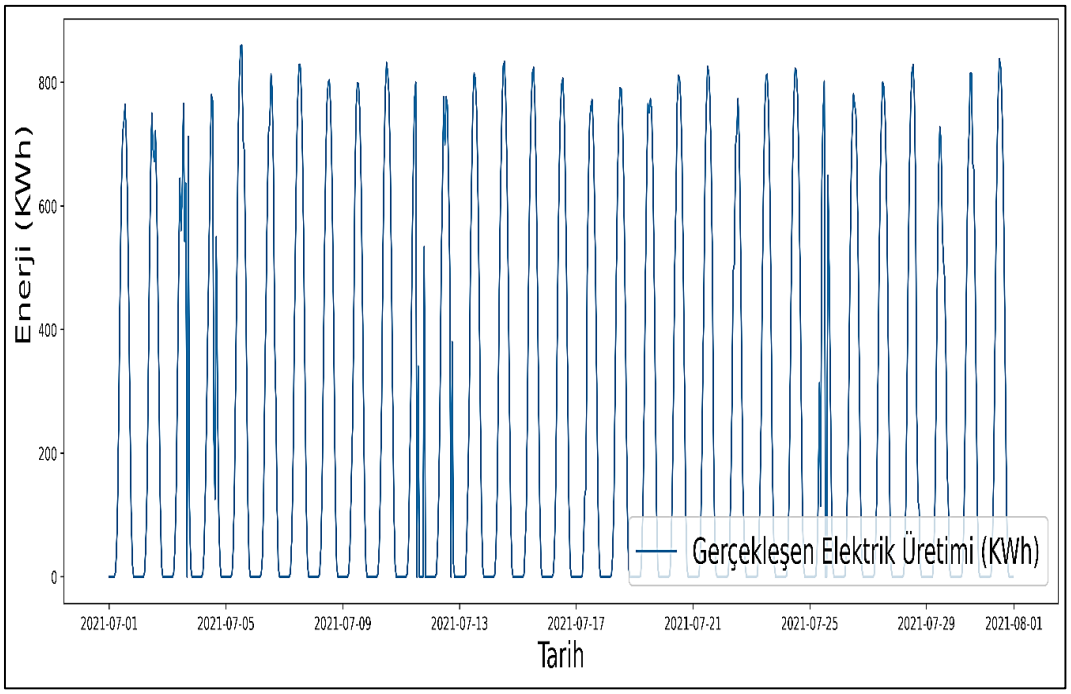
Şekil 4.6. 2020 Ağustos – 2021 ağustos arasındaki aylık GES üretim verileri



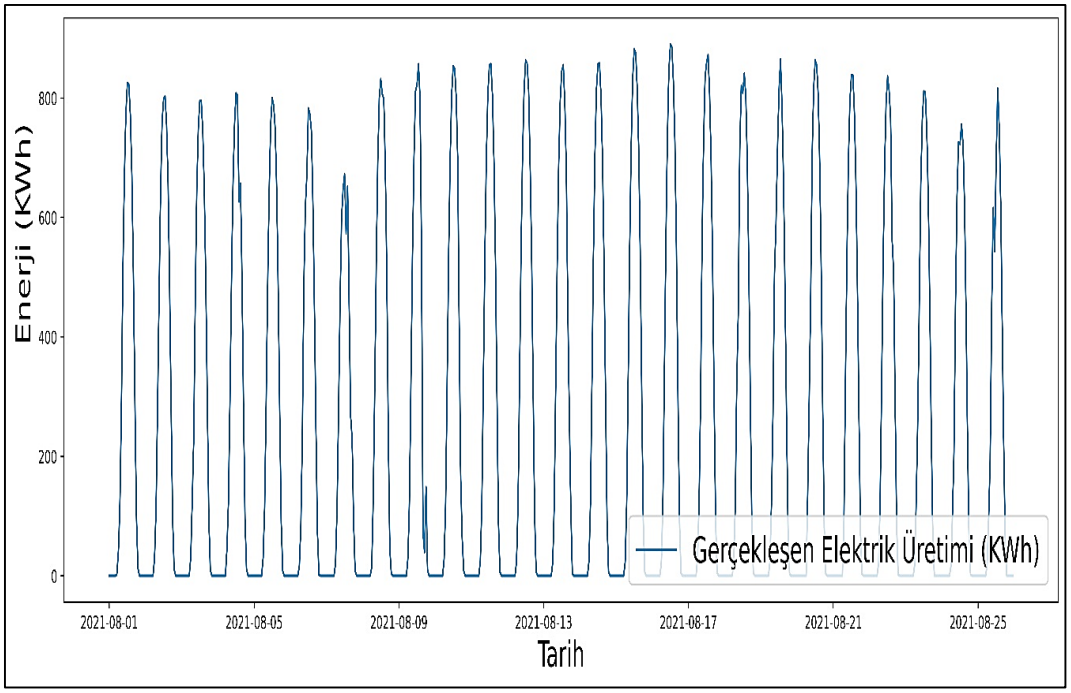
Şekil 4.7. 2020 Ağustos ayına ait günlerin saatlerine göre GES üretim verileri



Şekil 4.8. 2020 Eylül ayına ait günlerin saatlerine göre GES üretim verileri



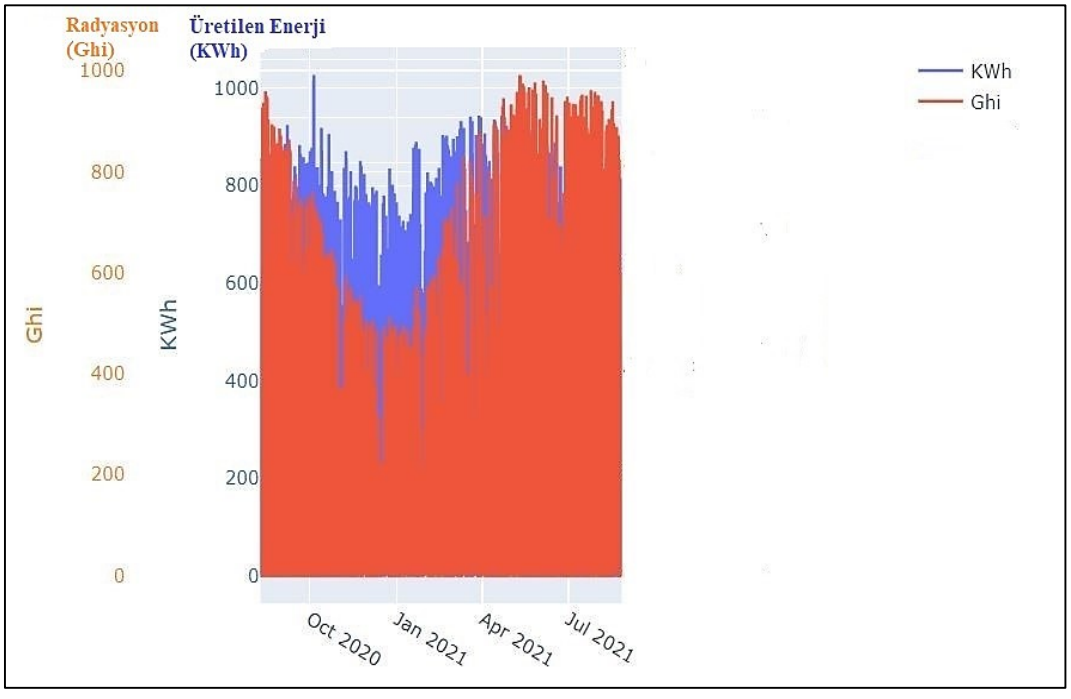
Şekil 4.9. 2021 Temmuz ayına ait günlerin saatlerine göre GES üretim verileri



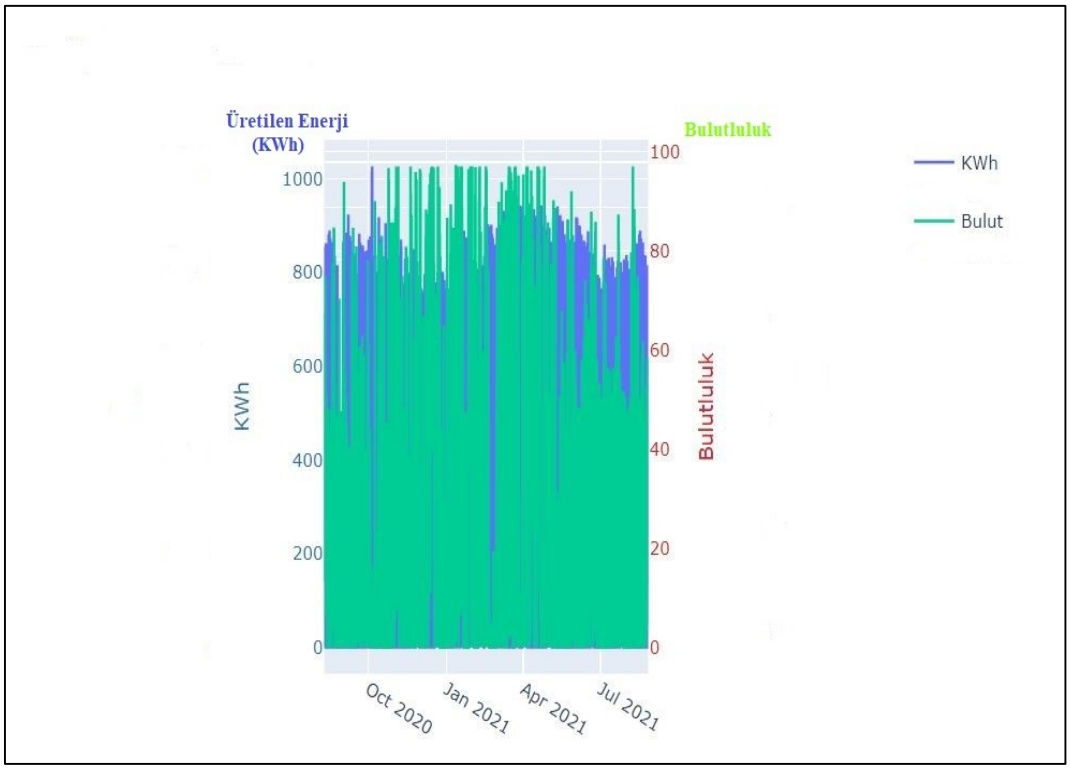
Şekil 4.10. 2021 Ağustos ayına ait günlerin saatlerine göre GES üretim verileri

Çizelge 4.1. Aylara göre 2020-2021 yılları arasındaki elektrik üretim değerleri

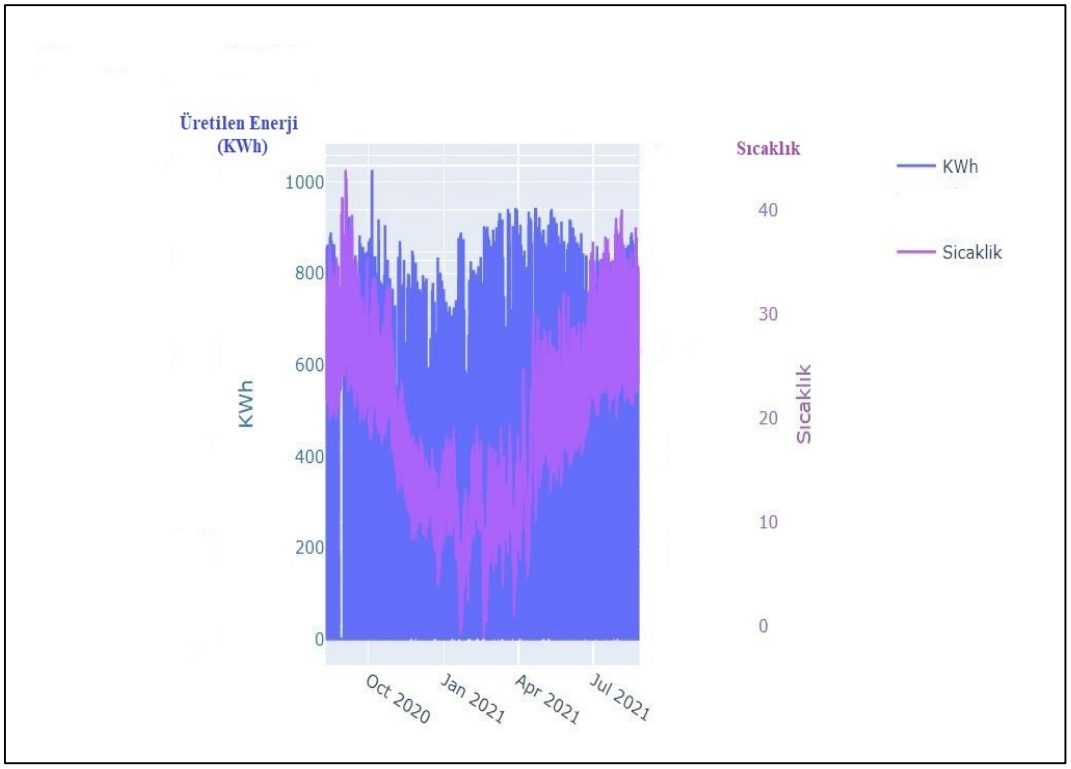
AYLAR	ÜRETİM DEĞERLERİ (KWh)
Ağustos 20	179.830,350
Eylül 20	149.154,075
Ekim 20	149.747,85
Kasım 20	111.555,675
Aralık 20	107.991,450
Ocak 21	101.880,45
Şubat 21	133.219,801
Mart 21	154.693,35
Nisan 21	165.488,4
Mayıs 21	199.149,3
Haziran 21	186.678,45
Temmuz 21	186.766,65
Ağustos 21	157.833,9



Şekil 4.11. Radyasyon (Ghi) ve üretilen enerji (KWh) arasındaki ilişki



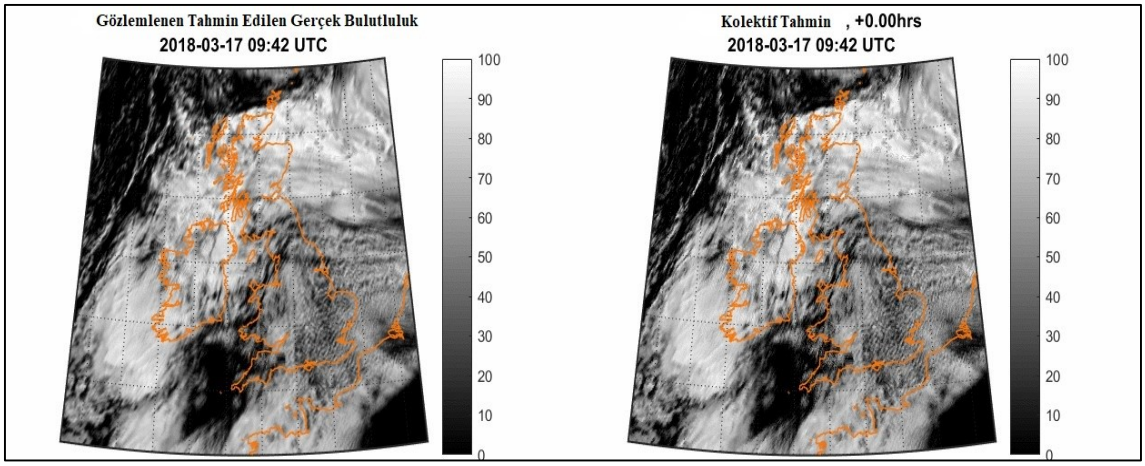
Şekil 4.12. Bulutluluk ve üretilen enerji (KWh) arasındaki ilişki



Şekil 4.13. Sıcaklık ve üretilen enerji (KWh) arasındaki ilişki

4.4. Meteorolojik Veriler

Meteorolojik veriler Solcast isimli internet sitesinden temin edilmiştir (Şekil 4.14.). Buradan elde edilen meteorolojik tahmin verileri 1'er saatlik alınmış olup bu veriler şu parametreleri ihtiva etmektedir: Küresel yatay parlaklık (GHI, W/m^2), direkt normal parlaklık (DNI, W/m^2), direkt yatay parlaklık (EBH, W/m^2), yayılmış yatay parlaklık (DHI, W/m^2), küresel eğik parlaklık (GTI, W/m^2), bulut kapatitesi (%), Albedo (Aklık derecesi, %), zenit açısı (°), azimut açısı (istikamet açısı, °), sıcaklık (°C), rüzgâr hızı (m/s), rüzgâr yönü (°), bağıl nem (%), yüzey basıncı (hPa), tortulaşabilen su (PWAT, kg/m^2), kar kalınlığı (SWDE, cm), çiylenme sıcaklığı (DWPT, °C). Solcast isimli siteden 60 dakikalık zaman aralıklarıyla alınmış olan veriler ".csv" formatında indirilmiş, içeriğinde bulunan ve yukarıda verilmiş olan parametreler Jupyter Notebook ortamında Python programlama diliyle işlenmiştir [33].



Şekil 4.14. Meteorolojik verilerin temin edilmesi [33]

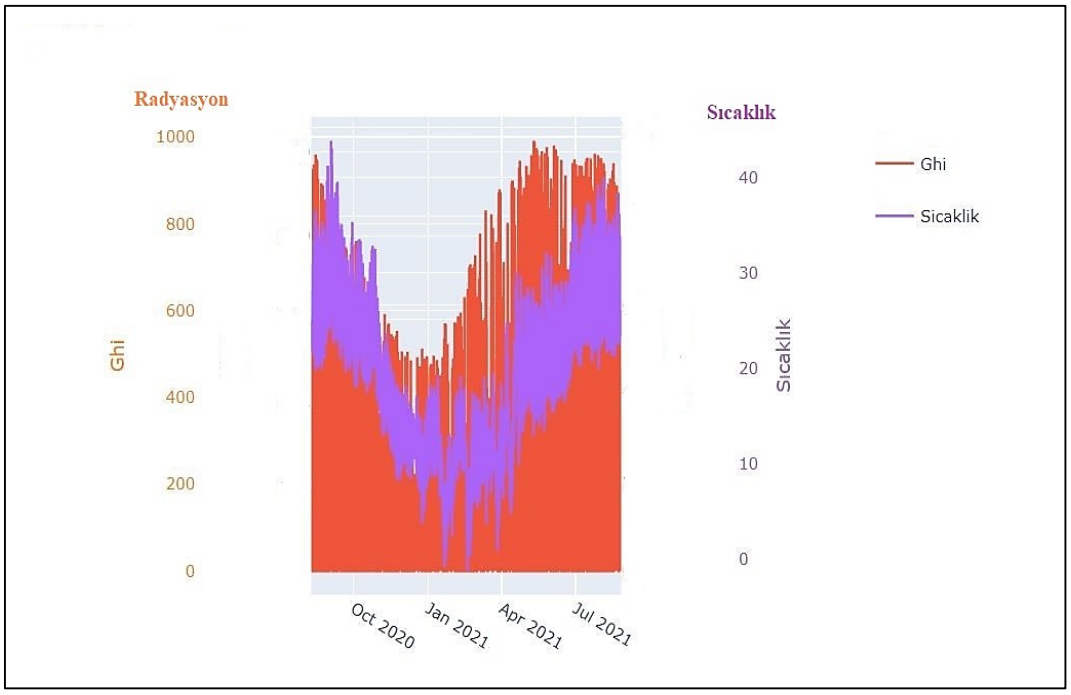
Alınan bu meteorolojik tahmin verileri excel formatında bilgisayara kaydedilmiştir. Daha sonra Jupyter Notebook ortamında bu veriler excel'den okuma komutu ile okunmuştur. Daha sonra elde edilen güneş enerjisi üretim verileri ile 'concat' komutu yardımıyla birleştirilmiştir. Jupyter Notebook ortamında elde edilen tablo Çizelge 4.2.'de verilen öznitelikleri ihtiva etmektedir. Yani Çizelge 4.2. Jupyter Notebook ortamında elde edilen tablonun özeti olarak excel ortamında elde edilmiştir. Çizelge 4.2.'de oluşturulan tabloda hava durumu verileri öznitelik ('Feature'), güneş enerjisi üretim verileri olan 'kWh' ise hedef değer ('Target Value') olarak belirlenmiştir. Çizelge 4.2.'deki tablo aynı zamanda bir zaman serisidir. Zamana bağlı olarak değişen hava durumu tahmin değerleri ve güneş enerjisi üretim değerleri arasındaki korelasyon bu zaman serisi tablosundan makine

öğrenmesi algoritmalarından Destek Vektör Regresyonu ve Polinom Regresyonu yardımıyla analiz edilmeye çalışılmıştır. Hava durumu değerleri 10.08.2020 – 04:00:00 tarihinden 25.08.2021 – 23:00:00 tarihine kadar elde edilmiştir. Elde edilen veriler Greenwich saatine göre elde edildiği için Türkiye saatine göre 2 saat geridedir. Bu nedenle Çizelge 4.2.'de elde edilen tablodaki meteorolojik tahmin verileri 2 saat ileriye alınarak (Time Shifting) tablo güncellenmiştir. Yani hava durumu tahmin verileri internet sitesinden ilk alındığı itibariyle değerler 10.08.2020 – 02:00:00'den başlamaktaydı. Türkiye saatine uygun hale getirilmesi için bu ilk değeri 10.08.2020 – 04:00:00 olarak değiştirildi.

Şekil 4.15.'te sıcaklık ve radyasyon arasındaki ilişki gösterilmiştir, burada sıcaklık ve radyasyonun değişiminin paralellik gösterdiği yani sıcaklık arttığında radyasyonun da arttığı sıcaklık azaldığında radyasyonun da azaldığı görülmektedir.

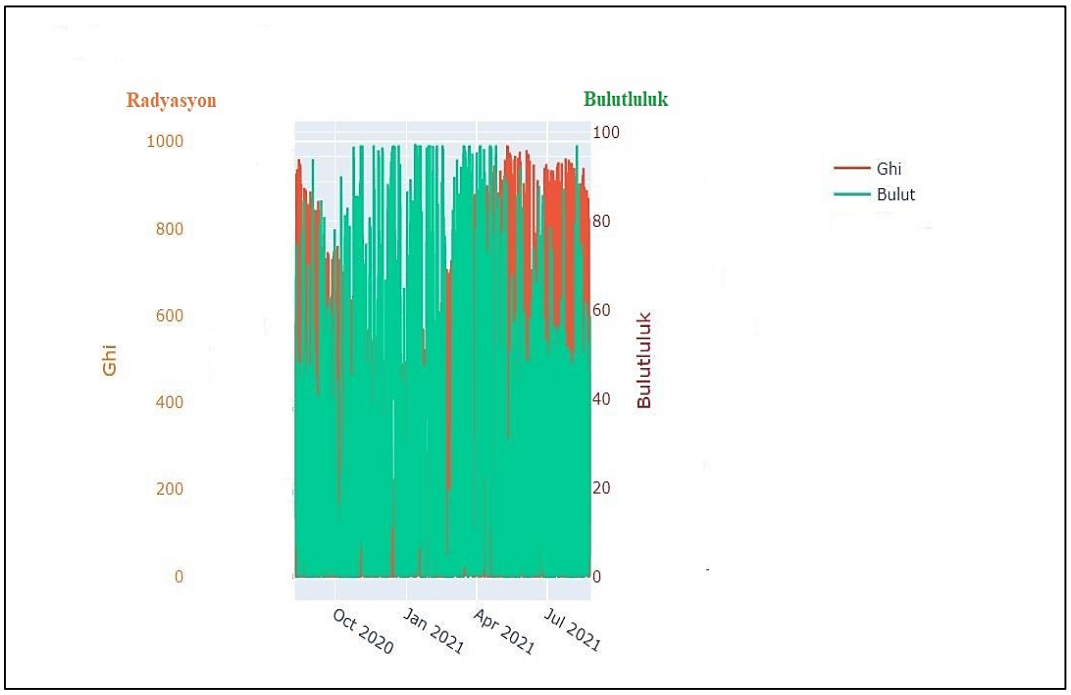
Çizelge 4.2. Hava durumu tahmin değerleri ve elektrik üretim verilerini birlikte ihtiva eden zaman serisi tablosu

Tarih	Üretilen Enerji (KWh)	Hava Sıcaklığı (°C)	Bulutluluk Kapasitesi	Yayılmış Yatay Parlaklık	Direk Normal Parlaklık	Direk Yatay Parlaklk	Küresel Yatay Parlaklık	Küresel Eğik Parlaklık	Rüzgar Yönü
2020-08-10 04:00:00	0	22.6	52.4	0	0	0	0	0	228
2020-08-10 05:00:00	0	22.5	58.9	1	0	0	1	1	221
2020-08-10 06:00:00	28,35	22,8	38,7	42	0	0	42	42	217
2020-08-10 07:00:00	121,275	23,5	46,1	120	0	0	120	120	220
2020-08-10 08:00:00	324,45	24,7	63,5	151	0	0	151	151	225
...	...	...	...	...	...	...	...	...	...
2021-08-25 19:00:00	0	25,7	49,9	1	0	0	1	1	199
2021-08-25 20:00:00	0	24,4	52,2	0	0	0	0	0	181
2021-08-25 21:00:00	0	24	25,3	0	0	0	0	0	157
2021-08-25 22:00:00	0	23,7	12,2	0	0	0	0	0	120
2021-08-25 23:00:00	0	23,4	19,5	0	0	0	0	0	105



Şekil 4.15. Sıcaklık ve radyasyon (Ghi) arasındaki ilişki

Şekil 4.16.'da ise bulutluluk ve radyasyon (Ghi) arasındaki ilişki gösterilmiştir, bulutluluğun sıcaklık ile ters orantılı olarak değiştiği bu grafikten anlaşılabilmektedir.



Şekil 4.16. Bulutluluk ve radyasyon (Ghi) arasındaki ilişki

5. MATERYAL VE METOT

5.1. Makine Öğrenmesi

Bilgisayar ortamında herhangi bir problemi el almak için bir algoritmaya kullanmak gerekmektedir. Algoritma, girilen verinin herhangi bir çıktıya çevrilmesi için gerçekleştirilmesi gereken bir dizi talimattan oluşmaktadır. Örneğin, sıralama için bir algoritma geliştirildiğinde girdi bir dizi sayıdır ve çıktı bu girilen sayıların sıralı bir listesidir. Aynı görevi gerçekleştirmek için farklı algoritmalar kullanılabilir ve bu algoritmaların içerisinden en başarılı olanı tespit edilebilir. En başarılı algoritma aynı görevi en az sayıda talimat ya da bellek ile gerçekleştirebilen algoritmadır [22].

Örneğin, spam e-postaları yasal e-postalardan ayırmak gibi işlemler için belirli bir algoritma elimizde bulunmamaktadır. Böyle bir durumda girdi bir karakter dosyası olan e-posta belgesidir. Çıktı ise mesajın spam olup olmadığını denetleyen bir evet/hayır çıktısıdır. Fakat girdinin çıktıya nasıl dönüştürüleceği burada bilinmemektedir. Hangi durumda gelen iletinin spam olarak değerlendirileceği de bir diğer problem olarak karşımıza çıkmaktadır [22].

Bilgi konusundaki eksiklikler verilerle telafi edilebilir. Bazıları spam olarak bilinen binlerce örnek mesaj kolayca derlenebilir ve bu iletilerden hangilerinin spam olduğu konusunda makine (Bilgisayar) üzerinde bir "Öğrenme" işlemi gerçekleştirilebilir. Diğer bir ifadeyle, bilgisayarın (makinenin) bu işlemi gerçekleştirmesi için algoritmayı otomatik olarak çıkarması istenmektedir. Sıralama probleminde söz konusu olan sayıları sıralamayı öğrenmeye gerek yoktur, bunun için zaten bir algoritma bulunmaktadır. Gerçek hayatta belirli bir algoritmanın olmadığı fakat örnek verilerin olduğu pek çok durum vardır. Bu veriler için bilişsel hesaplama yapmak ve bu yolla verinin algoritmasını çıkarmak uygun olacaktır [22].

Bilgisayar teknolojisindeki gelişmelerle birlikte günümüzde büyük miktardaki verileri depolamak, işlemek ve bir bilgisayar ağı üzerinden fiziksel bağlantılar vasıtasıyla uzak noktalardan söz konusu verilere erişmek mümkündür. Çoğu veri toplama cihazları dijital olup ve güvenilir bir şekilde verileri muhafaza etmektedirler. Örneğin, bir ülkenin her yerinde milyonlarca müşteriye binlerce mal satan yüzlerce mağazası olan bir süpermarket zincirini düşünüldüğünde, Satış noktalarında, her alış-veriş işlemi detaylarıyla kaydedilir.

Bu günlük olarak gigabaytlarca veri anlamına gelmektedir. Bu süpermarket zinciri bir ürün için olası müşterilerin kim olduğunu tahmin etmek istediğinde bu ürünün satışı zamana ve coğrafi konuma göre değiştiğini tespit edebilmektedir. Bu işlemin yapılabilmesi için depolanan çok büyük miktardaki verilerin analiz edilmesi ve tahmin işlemine uygun (Kullanılabilir) bilgilere dönüştürülmesi gerekmektedir. Depolama teknolojilerindeki ilerlemeler bu tahmin çalışmasının başarılı bir şekilde yapılamasının önünü açmıştır [22].

Makine öğrenmesi yöntemlerinin büyük veri tabanları üzerinde tatbik edilmesiyle veri madenciliği ortay çıkarılmıştır. Veri madenciliği ile bilinen günlük hayattaki madencilik arasında bir analoji söz konusudur. Madencilik büyük miktarda toprak ve hammaddenin bir maden ocağından çıkarılmasıdır. Çıkarılan maden işlendiğinde miktarı az fakat değeri fazla olan bir malzeme ortaya çıkar. Veri madenciliğinde ise yüksek doğrulukta tahmin yapabilen kıymetli ve basit bir model oluşturmak için büyük miktarda verinin işlenmesi ve bu verinin tahmin haline getirilmesi gerekmektedir. Veri madenciliğinin pek çok uygulama alanı bulunmaktadır. Bunlar; perakende, finans bankalarının kredi uygulamaları, dolandırıcılık tespiti, borsa işlemeleri, tıbbi teşhis öğrenmeleri, telekomünikasyon, ağ optimizasyonu, fizik, astronomi ve biyolojidir. Bu alanlarda kullanılan büyük miktardaki veriler ancak bilgisayarlar tarafından yeterince hızlı ve etkin bir şekilde analiz edilebilirler. İnternet ortamı ("www" - World Wide Web) çok büyük ve sürekli olarak büyümektedir. Bu nedenle ilgili bilgileri manuel olarak aramak çok zordur. Burada makine öğrenimi el ile manuel yapılamayacak kadar zor aramaları çok etkin bir şekilde yapabilmektedir [22].

Makine öğrenmesi sadece bir veri tabanı problemi değildir, aynı zamanda yapay zekânın bir parçasıdır. Değişken (Dinamik) bir ortamda bulunan sistemin zeki olabilmesi için öğrenme yeteneğine sahip olması gerekir. Sistem bu tür değişiklikleri öğrenip bu değişimlere uyum sağlayabiliyorsa, sistem tasarımcısının olası tüm durumları öngörmesi ve bu durumlar için çözüm bulması gerekmez, çünkü bu zeki sistem tüm değişiklikleri ve olası durumları öğrenme yeteneği sayesinde ortaya çıkarabilmektedir [22].

Makine öğrenmesi görüntü işleme, tıbbi görüntüleme, doğal dil işleme ve robotik alanındaki birçok probleme çözüm getirmektedir. Örneğin yüz tanımada; poz, ışık, saç stili vb. farklılıklara rağmen her gün aile üyelerini ve arkadaşlarımızı yüzlerine veya fotoğraflarına bakarak tanımaktayız. Ama bunu bilinçsizce yapmakta ve nasıl yaptığımızı açıklayamamaktayız. Bu tanıma işleminin nasıl yapıldığı bilinemediği ve izah edilemediği

zaman bu işlem bilgisayar programına aktarılamamakta, yani bu işlemin algoritması çıkarılamamaktadır. Aynı zamanda, bir yüz görüntüsünün yalnızca rastgele bir piksel koleksiyonu olmadığını bilinmektedir. Bir yüzün kendine has bir yapısı vardır ve her bir yüz belirli bir simetriye sahiptir. Yüzün belli yerlerinde gözler, burun, ağız vardır. Her insanın yüzü, bunların belirli bir kombinasyonundan meydana gelir. Bir kişinin örnek yüz görüntülerini analiz eden bir öğrenme programı, o kişiye özgü kalıbı (Pattern) yakalar ve ardından verilen bir görüntüde bu kalıbı kontrol ederek tanıma işlemi yapar. Bu aslında örüntü tanımanın bir çeşidi olarak karşımıza çıkmaktadır [22].

Makine öğreniminde örnek veriler veya geçmiş deneyimler kullanılmaktadır. Makine öğrenimi aynı zamanda bir performans kriterinin optimize edilmesi için bilgisayar ortamında belirli bir algoritmanın kodlanmasıdır. Makine öğrenmesi bazı parametreleri (Girdileri) olan bir modelin eğitim verileri veya geçmiş deneyimler kullanılarak söz konusu modelin parametrelerinin optimize edilmesi için kodlanmış bir bilgisayar programının yürütülmesidir. Modelde geleceğe yönelik tahminler yapmak için deneyimlerden veya verilerden faydalanılır [22].

Makine öğrenimi bilgisayar ortamında işletilirken geri planda aslında matematiksel modeller oluşturulur. Bu matematiksel modellerin makine öğrenmesi tarafından oluşturulması için istatistik teorisi kullanılır, çünkü temel görev bir örnekten ya da bir veri setinden çıkarım yapmaktır. Bilgisayar biliminin bir uygulaması olan makine öğrenmesinde optimizasyon problemini çözmek, sahip olduğumuz büyük miktardaki veriyi depolamak ve işlemek için verimli algoritmalara ihtiyaç duyulmaktadır. Bir makine öğrenme modeli bir kez eğitildiğinde, modelin öğreniminin temsili ve çıkarımı için algoritma çözümünün de başarılı olması gerekir. Bazı uygulamalarda, öğrenme veya çıkarım algoritmasının etkinliği, yani uzay ve zaman karmaşıklığı, tahmin doğruluğu kadar önemli hale gelmektedir [22].

Makine öğrenmesi ilk olarak 1956 yılında Dartmouth Konferansında bilgisayar bilimcileri tarafından kullanılmış ve günümüze kadar birçok araştırmaya konu olmuştur [34]. Makine öğrenimi, veriler üzerinde eğitilebilen yapı algoritmaları tasarlanarak yapılır. Bu algoritmaların seçiminde kullanılacak veri seti büyük önem taşımaktadır [35].

Makine öğrenimi, istatistik, yapay zekâ, bilişsel hesaplama, tahmine dayalı analiz ve istatistiksel öğrenmenin kesiştiği ortak bir alandır. Daha önce öğrenilmemiş girdilerin

çıktıları, makine öğrenmesi tarafından verilen girdi ve çıktı setleri yardımıyla tahmin edilebilir. Python, birçok veri bilimi uygulaması için bugün ortak dil haline gelmiştir. Python, veri işleme, istatistik, görüntü işleme ve daha birçok konuda kütüphaneler ihtiva etmektedir [36].

Makine öğrenmesini etkileyen dört faktörden söz edilebilir: Bu faktörlerden ilki makineye deneyim olarak girilen veri setidir. Deneyim olarak verilen veri kümesi, daha fazla ve farklı olası durumları içeriyorsa, öğrenmeye katkısı daha fazla olacaktır. İkinci faktör, sonuca etkisi olmayan veya veri setinde aynı etkiye sahip birden fazla verinin kullanılmasıdır. Birbiriyle yüksek düzeyde ilişkili olduğu veya çözüme katkısı çok az olduğu tespit edilen nitelikler ve nicelikler elenmelidir. Üçüncü faktör, seçilen öğrenme stratejisidir. Öğrenme stratejisi hem makinenin öğrenmesi istenen görevle hem de gerekli veri kümesiyle ilgilidir. Makine öğrenmesi, bazı problemleri çözmek için veri setinde bir çıktı değerine (Hedef Öznitelik) ihtiyaç duyar, ancak bazı problemler için bu değere ihtiyaç duymaz. Tahmin ve sınıflandırma problemleri, hedef öznitelik gerektiren problemlerdir. Bu nedenle makine öğrenmesinde ele alınacak probleme göre öğrenme stratejisinin belirlenmesi önemlidir. Dördüncü ve son faktör ise öğrenme için kullanılan algoritmadır. Makinenin kendi veri setinden öğrenebilmesi için adım adım izlemesi gereken yol, algoritmalar tarafından sağlanmaktadır [35].

Makine öğrenmesi üç ana araştırma alanı etrafında incelenebilir. Bu ana araştırma alanları: Görev odaklı yürütülen çalışmalar, bilişsel benzetim çalışmaları ve teorik analizlerdir [37].

- Göreve Odaklı Yürütülen Çalışmalar: Daha önce yapılmış ve tamamlanmış çalışmaların ya da görevlerin performansı zamanla azalabilir. Yapılacak yeni çalışmalarda performansı artırmak için öğrenme sistemlerinin geliştirilmesine görev odaklı çalışmalar denir.
- Bilişsel Benzetim Çalışmaları: Bilişsel modelleme yaklaşımı olarak da bilinen Bilişsel Benzetim Çalışmaları, insan öğrenme aşamalarının incelenmesi ve bilgisayar üzerinde yapılan simülasyon çalışmalarını ihtiva etmektedir.
- Teorik Analizler: Teorik Analiz, pratik alanlardan bağımsız bir şekilde mevcut öğrenme yöntemlerinin ve algoritmalarının teorik olarak ele alınmasını ihtiva etmektedir.

Makine öğrenmesi için modeli veya modelleri veri seti ve algoritma temelinde oluşturulur ve performansı en yüksek olan model tercih edilir. Bu amaca yönelik olarak birçok makine öğrenmesi yöntemi geliştirilmiştir, bunlardan bazıları; k-en yakın komşuluk (KNN) algoritması, Naïve Bayes Sınıflandırma Algoritması, karar ağaçları, lojistik regresyon analizi, k-ortalamalar algoritması, destek vektör makineleri ve yapay sinir ağları. Bu algoritmaların bazıları tahmin, bazıları kümeleme, bazıları ise sınıflandırma yapabilmektedir [35].

Makine öğrenmesi algoritmaları öğrenme yöntemleri açısından iki ana başlık altında incelenebilir; denetimli öğrenme ve denetimsiz öğrenme. Ancak teknolojinin ve algoritmaların ilerlemesi ile bu iki ana yöntemin yanı sıra ek yöntemler de geliştirilmiştir. Bu yöntemler yarı denetimli, pekiştirmeli, Transdüktif çıkarım, çevrimiçi, aktif öğrenme olarak sıralanabilir [38].

Polinom regresyonu istatistik bir yöntemdir, aynı zamanda makine öğrenmesi yöntemi olarak kabul edilmektedir [39] . Bu tahmin çalışmasında polinom regresyon ve destek vektör regresyon olmak üzere iki farklı makine öğrenme yöntemi önerilmiştir.

5.2. Polinom Regresyonu

Çalışmada iki yöntem kullanılmıştır: Polinom regresyon ve destek vektör regresyonu. Çalışmada Python'un geliştirme ortamı olan Anaconda Navigator'da geliştirilmiştir. Çalışmada "matplotlib", "pandas", "numpy", "scikit-learn", "seaborn", "datetime" kütüphaneleri kullanılmıştır. Anaconda Navigator ortamında geliştirilen program sayesinde tahmin çalışması gerçekleştirilmiştir.

Çalışmada kullanılan yöntemlerden regresyon analizi, bağımlı değişken ile bir veya çok fazla sayıda bağımsız değişken arasında yapılan modellemenin parametrelerinin tahmin edilmesi ve bağımsız değişkenin gözlemlenen yani alabileceği büyüklüklere karşılık bağımlı değişkenin alacağı değerlerin tespit edilmesi işlemidir [40-41]. Bir bağımsız değişken kullanılan regresyon analizine tek değişkenli regresyon analizi denilmektedir. Tek değişkene sahip polinom regresyonuna ait eğri denklemi şu şekilde belirlenebilir (Eş. 5.1.) [42-43]

$$y_i = \beta_0 + \beta_1 x_i + \beta_2 x_i^2 + \beta_3 x_i^3 + \cdots + \beta_k {x_i}^k + \varepsilon_i \mid i = 1,2,3,\ldots,N \tag{5.1}$$

Bu ifadede;

y_i: Bağımlı değişkenin i. gözlemlenen değeri,

x_i: Bağımsız değişkenin i. gözlemlenen değeri,

N: Birim sayısı,

β_0: Regresyon sabiti,

$\beta_1, \beta_2, \beta_3, \dots, \beta_k$: Regresyon katsayıları

k: Bağımsız değişken derecesi,

ε_i: Modelin hata terimi

olarak tanımlanmıştır.

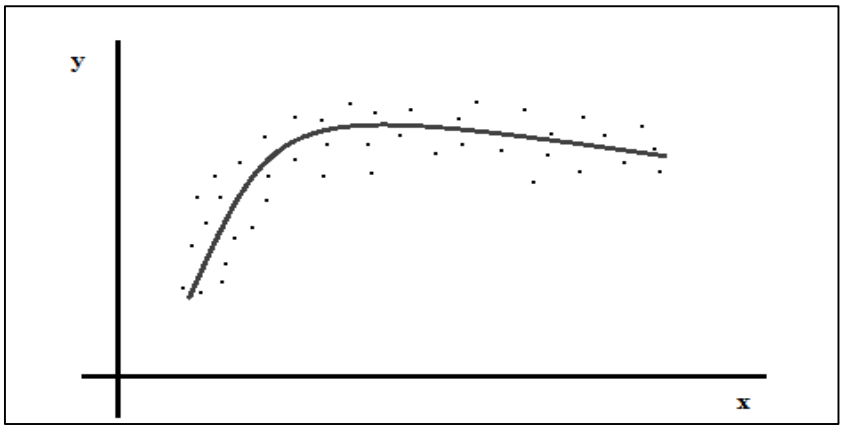
Çalışmada kullanılan diğer yöntem olan polinom regresyonu, regresyon modellemesindeki bağımsız değişken parametresinin, bağımlı değişken parametresi üzerindeki etkisinin toplanabilir olmadığı (eğrisel, üstel, çarpımsal vs.) varsayımının yapıldığı regresyon analiz metotlarını ihtiva eder [43-44].

Bu başlıkta karesel ve kübik polinom regresyon modellemeleri incelenecektir**.** Bu modelleri tek tek aşağıdaki gibi ele alabiliriz:

Karesel Regresyon Modeli: İki değişken arasında olan neden sonuç bağıntısını ele alan ikinci dereceden regresyon modeline karesel regresyon modeli adı verilir [44]. β_0, β_1 ve β_2 değişkenlerinin ele alınan örnekten alınan tahmini değerleri "b_0, b_1 ve b_2", hata terimi olan ε'nun örnekten alınan kestirim büyüklüğü "e" olarak kabul edildiğinde, n örneklem birim sayısını ifade etmek üzere tek değişkene sahip regresyon modeline ait eğri denklemi şu şekilde ifade edilebilir (Eş. 5.2) [43,45,46]

$$y_i = b_0 + b_1 x_i + b_2 x_i^2 + e_i \mid i = 1,2,3, \dots, N \tag{5.2}$$

Karesel regresyon modele ait noktasal dağılım grafiği Şekil 5.1.'de gösterilmiştir:

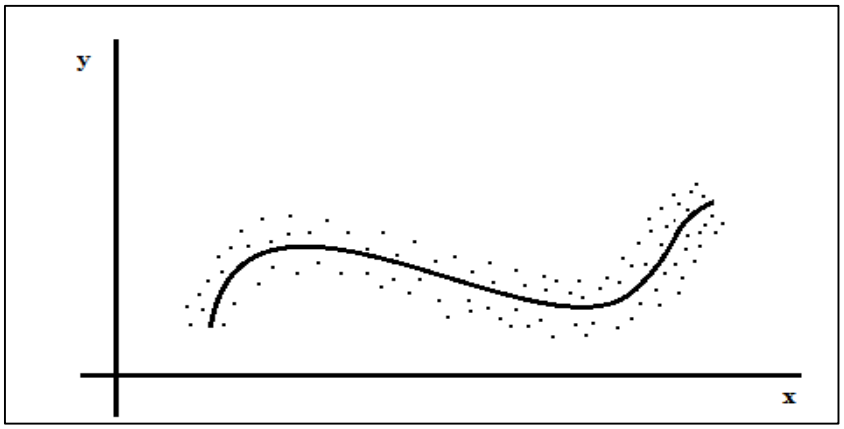


Şekil 5.1. Karesel regresyon modelinin noktasal dağılımı [47]

Kübik Regresyon Modeli: İki değişken arasında olan neden sonuç bağıntısını ele alan üçüncü dereceden regresyon modeline kübik regresyon modeli adı verilir (Rawlins ve ark, 1998; Seber ve Wild, 2003). Tek değişkene sahip kübik regresyon modeline ait eğri denklemi Eş. 5.3 ile ifade edilebilir [43,45,46]

$$y_i = b_0 + b_1 x_i + b_2 x_i^2 + b_3 x_i^3 + e_i \mid i = 1,2,3, \dots, N \tag{5.3}$$

Kübik regresyon modele ait noktasal dağılım grafiği Şekil 5.2.'de gösterilmiştir [47]:



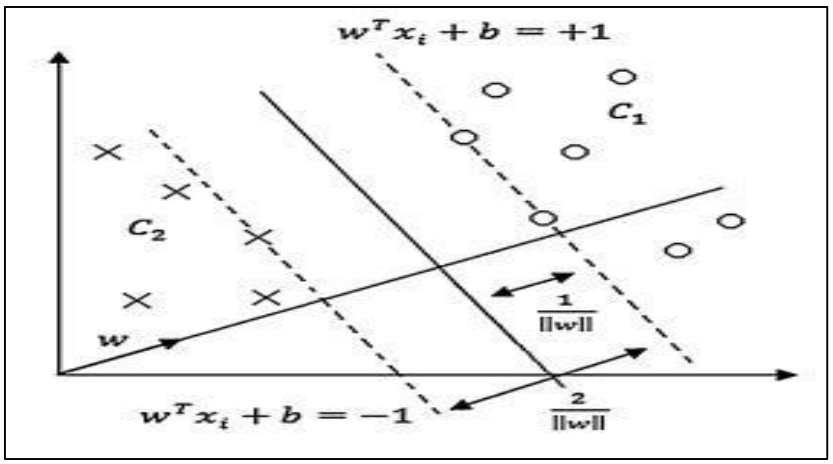
Şekil 5.2. Kübik regresyon modelinin noktasal dağılımı [47]

Güneş enerjisi ile elektrik enerjisi tahmininde polinom regresyon da önerilen yöntemlerden bir tanesidir. Eğer sınırlı sayıda satır ve sütun (Özellik) varsa bu sütunların yani özelliklerin

polinom kombinasyonları seçilen polinom derecesine göre alınarak modelin kötü öğrenme (Underfitting) yapması engellenebilir [25].

5.3. Destek Vektör Regresyonu

Destek vektör makineleri yönteminden, regresyon ve sınıflandırma operasyonlarında yararlanılabilmektedir. Genellikle iki sınıf üyelerinin birbirinden ayırt edilebilmesi amacıyla faydalanılabilecek en iyi sınıflandırma fonksiyonunu tespit etmek üzere kullanılmaktadır. Yani destek vektör makineleri, sınırını en yüksek doğruyu seçerek sınıflandırma hatasını asgariye çeker; ayrıca iki sınıfı birbirinden ayırt etmek için öznitelikleri kullanarak sınıfları en iyi şekilde birbirinden ayırabilecek bir düzlem ya da hiper düzlem tespit etmeyi hedeflemektedir. Şekil 5.3.'ten de görülebildiği üzere iki sınıfa da destek vektör makineleri algoritmasının uygulanması için evvela hatayı asgariye indirgeyen paralel iki tane vektör seçilip aralarında bulunan aralık azami yapılır, daha sonra bu iki vektörün orta notasından optimum hiper düzlem tespit edilmektedir. Rastgele alınan bir x verisinin sınıflandırılması içinse y=w*x+b denkleminden faydalanılmaktadır [24].



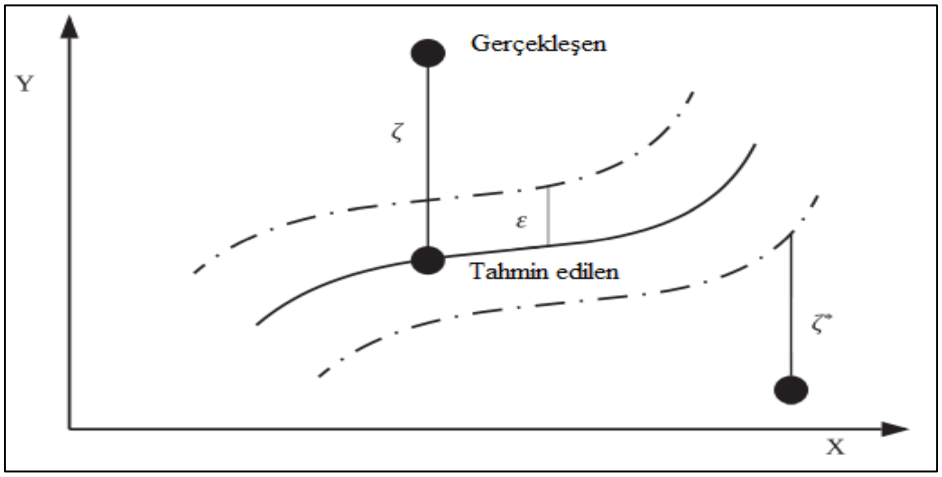
Şekil 5.3. SVM Algoritmasında hiper düzlemin belirlenmesi [22]

Destek vektör makinesi hesabında temel hedef eğitim kümesi x_i değeri ile önceden tespit edilen hata toleransından (ε) daha küçük bir uzaklıktaki y_i tahmin değerini hesap edebilen f(x) fonksiyonunu yazabilmektir Bu durumda destek vektör regresyon fonksiyonu aşağıdaki denklemin minimizasyonu ile hesap edilir (Eş. 5.4 ve Eş. 5.5) [48]:

$$Minimum = \frac{1}{2} * |W|^2 + C * \frac{1}{N} \sum_{i=1}^{N} L_{\epsilon}\big(y_i, f(x_i)\big) \tag{5.4}$$

$$L_{\epsilon}(y_i, f(x_i)) = \begin{cases} 0, |y_i - f(x_i) \leq \varepsilon| \\ |y_i - f(x_i)| \; diğer \end{cases} \tag{5.5}$$

Eş. 5.4.'ün ikinci terimi deneysel hata olup Eş. 5.5'teki ε duyarsız kayıp fonksiyonu ile tespit edilir. Şekil 5.4.'te lineer olmayan bir destek vektör regresyon fonksiyonu için ε tüpü verilmiştir. Tahmin edilen değer ε tüpü içerisinde bulunuyorsa kayıp fonksiyonu sıfıra eşit olacaktır. Aksi halde kayıp ε ile tahmin edilen değer arasındaki farka eşit olacaktır [48].



Şekil 5.4. Doğrusal olmayan regresyon fonksiyonu için **ϵ** tüpü [49]

Tüm veri kümesindeki x_i 'ler için ε'dan küçük mesafede yer alan y_i tahmin değerini hesaplayan f(x) fonksiyonunu bulmak imkansız olduğu için regresyon fonksiyonuna ve kısıtlara her noktada Eş. 5.6.-5.7.-5.8.-5.9.'daki gibi yapay değişkenler eklenir [50].

$$Minimum\ \zeta_1\zeta_1^*\ W\ b: \frac{1}{2} * |W|^2 + C * \frac{1}{N}\sum_{i=1}^{N}(\zeta_1 + \zeta_1^*) \tag{5.6}$$

$$y_i - W * \phi * x_i - b \leq \varepsilon + \zeta_1 \tag{5.7}$$

$$W * \phi * x_i + b \leq \varepsilon + \zeta_1^*;\ i = 1,2,3,\ldots,N \tag{5.8}$$

$$\zeta_1 \geq 0;\ \zeta_1^* \geq 0 \tag{5.9}$$

Burada ζ_1 ve ζ_1^* yapay değişkenleri göstermektedir. Diğer kısıtlara ilaveten hata fonksiyonunu asgariye çekmek için Lagrange çarpanları ilave edilmektedir. Eş. 5.10'daki ve Eş. 5.11'deki a_i ve a_i^* Lagrange çarpanlarını, *i* ve *j* ise farklı örnekleri göstermektedir. Diğer

taraftan lineer olmayan modellerin lineer yapılması için kullanılan çekirdek fonksiyonu $K(x_i, x_j)$ regresyon fonksiyonuna ilave edilir (Eş. 5.10) [50].

$$Minimum\ \{a_i\}\{\ a_i^*\} = \frac{1}{2} * \sum_{i=1}^{N}\sum_{j=1}^{N}(\ a_i - \ a_i^*) * \left(\ a_j - \ a_j^*\right) * \mathrm{K}\left(x_i, x_j\right)$$

$$- \varepsilon * \sum_{i=1}^{N}(\ a_i - \ a_i^*) + \sum_{i=1}^{N} y_i(\ a_i - \ a_i^*) \tag{5.10}$$

$$\sum_{i=1}^{N}(\ a_i - \ a_i^*) = 0 \tag{5.11}$$

$$(a_i - \ a_i^*) \in [0, C] \tag{5.12}$$

Bu halde sonuçta yazılabilecek tahmin fonksiyonu Eş. 5.13. ile ifade edilmiştir [50].

$$y = f(x) = \sum_{i=1}^{N}(\ a_i - \ a_i^*) * \mathrm{K}\left(x_i, x_j\right) + b \tag{5.13}$$

Güçlü ve iyi bir SVR modeli için hiper parametreler titizlikle seçilmelidir, tersi durumda aşırı öğrenme ya da eksik öğrenme meydana gelebilir. Eş. 5.4. ve Eş. 5.6 'daki kutu kısıtlaması diye ifade edilen düzenleme sabitesi (C), SVR modelinin karmaşıklığını (Yani fonksiyonun düzlüğünü) hesaplamak üzere kullanılır. Epsilon (ε) ise regresyon fonksiyonlarının karmaşıklığını kontrol altına alır. Yapay değişkenler olan $\zeta 1$ ve ζ_1^* ise sırasıyla epsilonun üzerinde ve altında meydana gelen mutlak sapmaları ifade eder. Düşük C büyüklükleri düz fonksiyonlara sebep olabilirken, yüksek C büyüklükleriyse aşırı öğrenmeye sebep olabilmektedir. Öte taraftan, yüksek ε değeri regresyon modelini çok daha basit bir hale getirebilir, bu durum düşük tahmin doğruluğuna sebep olurken, düşük ε değeri ise SVR modelini çok daha karmaşık bir duruma getirir ve tahmin başarısını azaltır. Neticede, uygun C ve ε değerlerinin tespit edilmesi, tahmin çalışmalarında büyük önem arz etmektedir [51].

MAPE (Mean Absolute Percentage Error - Ortalama Mutlak Yüzde Hata) tahmin yöntemlerinde doğruluğu tespit edebilmek için yaygın bir şekilde kullanılan ölçüttür. MAPE aşağıda yer alan formül ile hesaplanır [52].

$$\mathrm{MAPE} = \frac{1}{\mathrm{n}} * \sum_{\mathrm{i}=1}^{\mathrm{n}} \left|\frac{\mathrm{A_i} - \mathrm{F_i}}{\mathrm{A_i}}\right| \tag{5.14}$$

A_i: $Gerçek\ veriler$

F_i: $Tahmin\ edilen\ veriler$

n: $Veri\ sayısı$

Aslay ve Özen tarafından Lewis'in Talep Tahminleri kitabına göre; MAPE değeri %10'un altındaki modeller "çok iyi", %10 ile %20 arasındaki modeller "iyi", %20 ile %50 arasındaki modeller "kabul edilebilir" olarak tespit edilmiştir [52].

R-kare (R^2) puanı, herhangi bir regresyon modelinin performansını hesaplamak içindir [53-54]. Regresyon modelini eğittikten (Fit ettikten) sonra, eğitilmiş (Fit edilmiş) herhangi bir modelin uygunluğunun (Fit edilmesinin) mükemmelliği R^2-skor kullanılarak tespit edilebilir. R^2-skor, regresyon çizgisini çevreleyen veri noktalarının dağılımını ifade eder. Ancak bu performans metriği, bir belirleme katsayısı olarak tanımlanabilir. R^2-skor herhangi bir veri setinin eğitilmesinde %0 - %100 arasında bir değer alır. %0 puanı, bağımlı değişkenin tahmin değerleri etrafında herhangi bir değişkenliğinin olmadığını, %100 oranı ise bağımlı değişkenin mevcut regresyon modeli tarafından tahmin edilen değerler etrafında tamamıyla değişkenliğe sahip olduğunu ifade eder. Yüksek R^2-skor, eğitilen modelin başarısını ifade ederken ancak düşük R^2-skoru, modelin başarısızlığını ya da eksikliğini ifade eder [55].

5.4. Jupyter Notebook

Jupyter Notebook, Anaconda Navigator platformu içerisinde yer alan bir program yazma editörüdür. Bu editör içerisinde Pandas, Seaborn, Numpy, Matplotlib, Scikit - Learn ve DateTime kütüphaneleri kullanılmıştır.

Pandas kütüphanesi verilerin ilgili dosyalardan okunması, bu verilerin tahminde kullanılmak üzere zaman serisine formatına dönüştürülmesi için kullanılmıştır. Numpy kütüphanesi Step By Step Prediction dediğimiz adım adım olarak yapılan tahminde tahmin edilen elektrik üretim verilerinin dizi şeklinde ifade edilmesi için kullanılmıştır. Seaborn üretim verisinin hava durumu parametreleriyle doğrusal bir değişim gösterip göstermediğini tetkik etmek için

kullanılmıştır. Matplotlib tahmin edilen ve gerçekleşen elektrik üretim verileri arasındaki ilişkiyi grafik üzerinde göstermek üzere kullanılmıştır.

Scikit-Learn makine öğrenmesini gerçekleştiren ana kısım olup bu kütüphane sayesinde destek vektör ve polinom regresyonu ile veri seti hem fit edilmiş (Destek vektör regresyonu veya polinom regresyonu ile eğitime uygun hale getirilmiş) hem de eğitilmek suretiyle tahminler ürettirilmiştir. Ayrıca yine aynı kütüphanede yer alan başarı metrikleri (Ortalama Mutlak Yüzdesel Hata ve R2-Skor) ile yapılan tahminin gerçekleşen üretime nazaran ne kadar başarılı olduğu tespit edilmiştir.

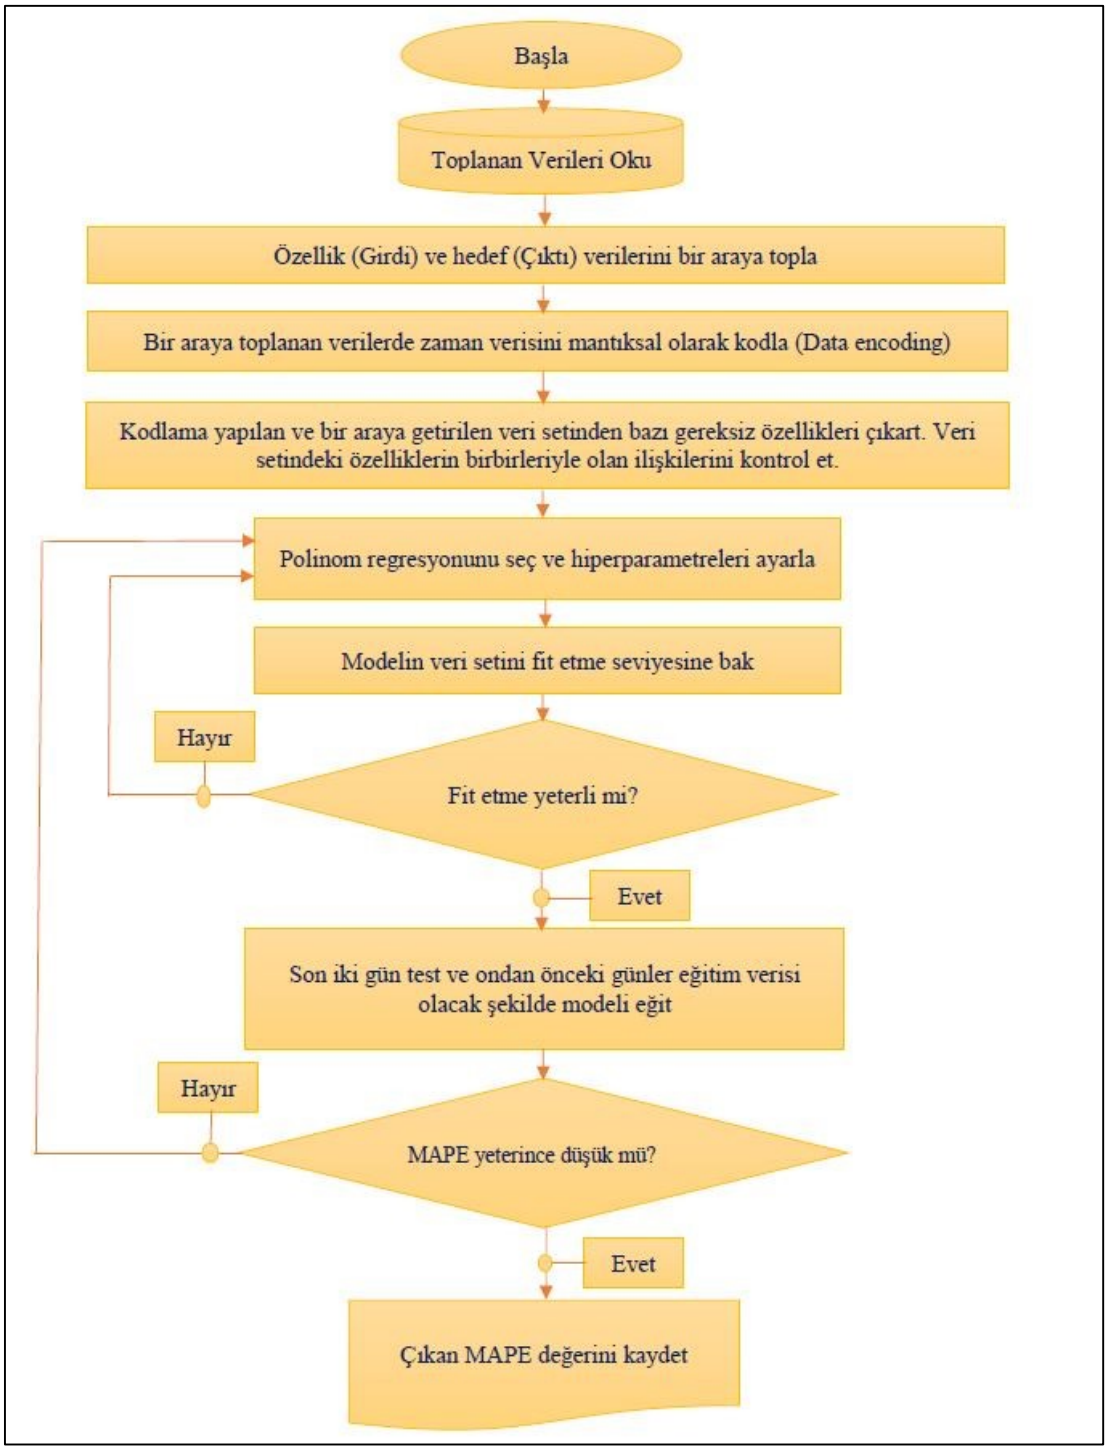
6. ÖNERİLEN ELEKTRİK ÜRETİM TAHMİNİ

Radyal Temelli Çekirdek Fonksiyonu (‘rbf’), SVR modeline eklenen çekirdek (Kernel) özelliğinin model tarafından kullanılmasıyla hesaplamanın model tarafından daha isabetli sonuçları daha az bir sürede yapılmasını sağlar. SVR’de radyal temelli çekirdek fonksiyonu ve Polinom Çekirdeği (‘poly’) olmak üzere iki tür çekirdek hilesi (Kernel Trick) kullanılmıştır.

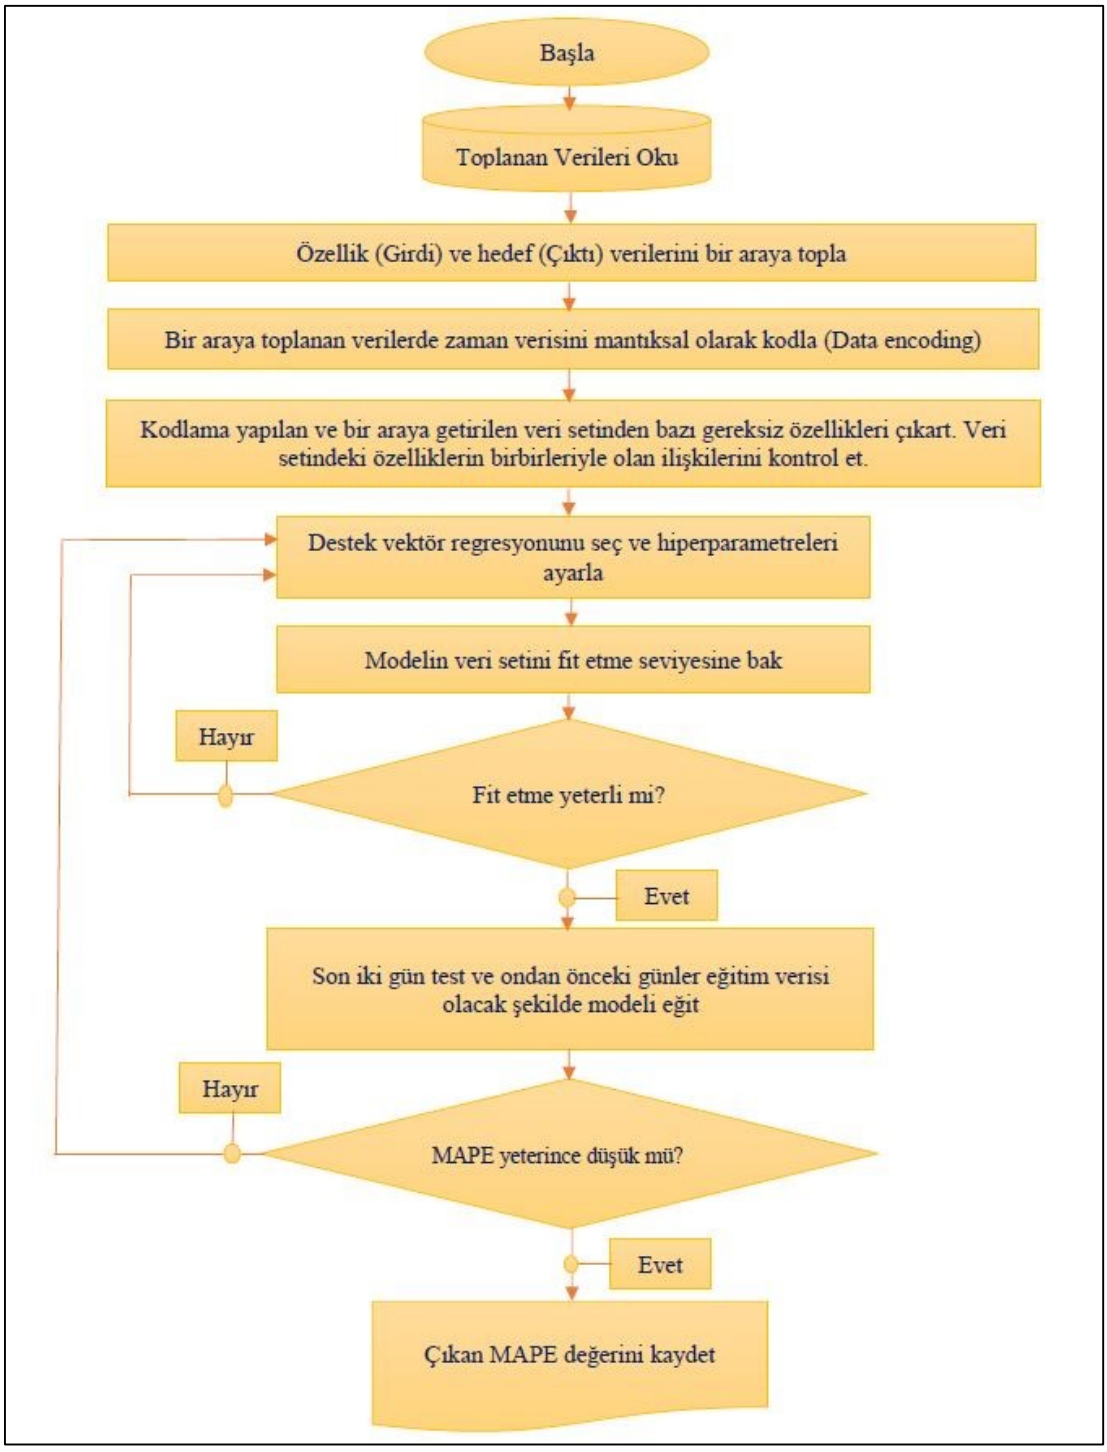
6.1. Tek Adımda Yapılan Tahmin Çalışması

Tek adımda yapılan tahmin çalışması tek seferde 24.08.2021 ve 25.08.2021 günlerine ait toplam 48 saatin elektrik üretim tahminlerinin tek seferde ve bütün halinde elde edildiği çalışmadır. Tek adımlı tahmin çalışmasından elde edilen bulgular bu bölümde ele alınacaktır.

Şekil 6.1. ve Şekil 6.2.’de sırasıyla polinom regresyonu ve destek vektör regresyonu için yazılan programın akış şeması gösterilmiştir. Her iki akış şeması da yapı ve basamak sırası bakımından birbirinin aynısıdır. “MAPE yeterince düşük mü” sorusuna her bir yöntem için Lewis’in Talep Tahminleri kitabında %10 ile %20 arasındaki MAPE değerleri “iyi” olarak değerlendirildiği için %10’a yakın MAPE değerleri elde edilmeye çalışılmıştır. Veri seti bir yılla sınırlıdır. Veri seti eğer daha büyük olsaydı %10’un altında MAPE elde edilebilirdi. Çünkü daha büyük veri setiyle bu daha iyi fit etme seviyesi yakalanıp bu veri seti daha iyi eğitilebilir. Eldeki veri setiyle %10’un altında MAPE elde edilemese dahi %10’a yakın MAPE değerleri elde edilmeye çalışılmıştır. Bu nedenle “MAPE yeterince düşük mü?” sorusu yazılan bu program için aslında “%10’a yakın bir MAPE değeri elde edilebilmiş midir?” sorusunun cevabıdır. Akış diyagramında ayrıca “Fit etme (Uygun Olma) yeterli midir?” sorusunun cevabı da yine %10’a yakın MAPE elde edilmesine bağlı bir durumdur. Fit etme ne kadar yüksek olursa MAPE değeri de o kadar düşük olacaktır.



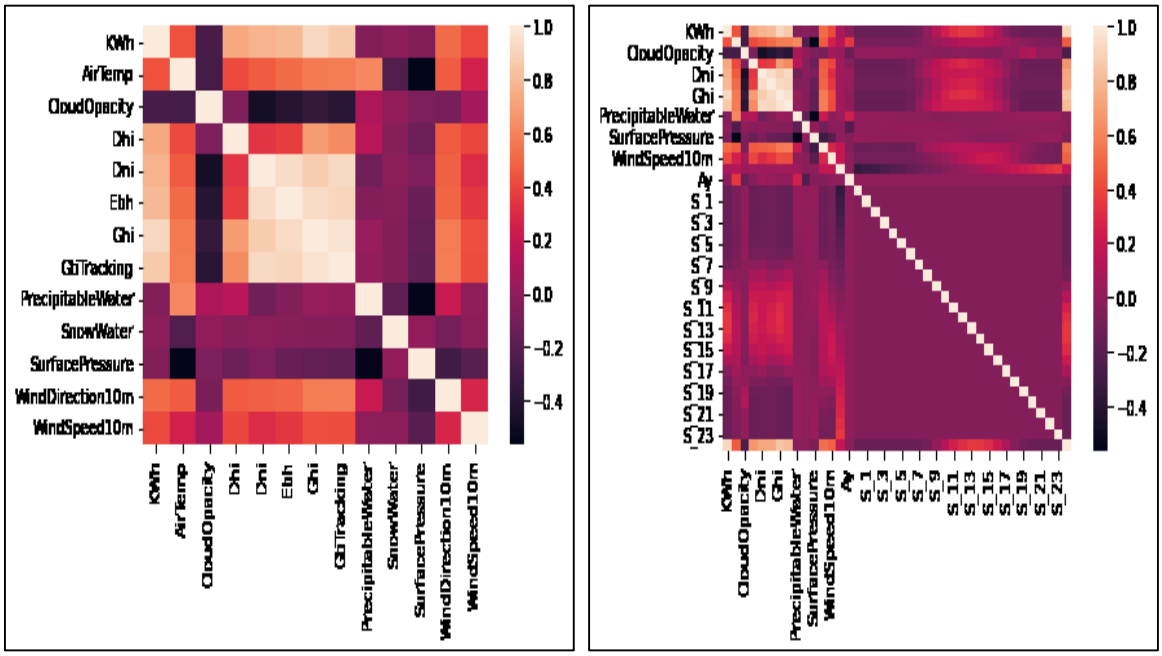
Şekil 6.1. Polinom regresyonu için akış şeması



Şekil 6.2. Destek vektör regresyonu için akış şeması

Şekil 6.3. incelendiğinde 'KWh', 'AirTemp (Hava Sıcaklığı)', 'CloudOpacity (Bulutluluk Kapasitesi)', 'Dhi (Yayılmış Yatay Işınım)', 'Dni (Direk Normal Işınım)', 'Ebh (Direk Yatay Işınım)', 'Ghi (Küresel Yatay Işınım)', 'GtiTracking (Bakış Yörünge İndeksi İzleme)', 'PrecipitableWater (Çökelebilen Su)', 'SnowWater (Kar Suyu)', 'SurfacePressure (Yüzey Basıncı)', 'WindDirection10m (Rüzgar Yönü)', 'WindSpeed10m (Rüzgar Hızı)' ve ayrıca

saat bilgilerinin ('S_0', 'S_1', 'S_2', 'S_3', 'S_4', 'S_5', 'S_6', 'S_7', 'S_8', 'S_9', 'S_10', 'S_11', 'S_12', 'S_13', 'S_14', 'S_15', 'S_16', 'S_17', 'S_18', 'S_19', 'S_20', 'S_21', 'S_22', 'S_23'); KWh yani enerji üretim verisiyle ne kadar doğrusal olarak değiştiği ifade edilmiştir. Skalada 1,0'a (Açık renkli kısımda) en yakın parametrelerin üretim verisiyle doğrusal bir ilişkide olduğu, skala üzerinde rengi 0,4 ile 0 arasında (Siyah renkli kısımda) olan verilerin ise üretim verisiyle doğrusal olmayan bir ilişkide olduğu söylenebilir. Veri seti kısıtlı olduğu için karmaşıklığı artırmak ve ezberlemeyi önlemek için bu parametrelerin hepsi veri setinde kullanılmıştır.

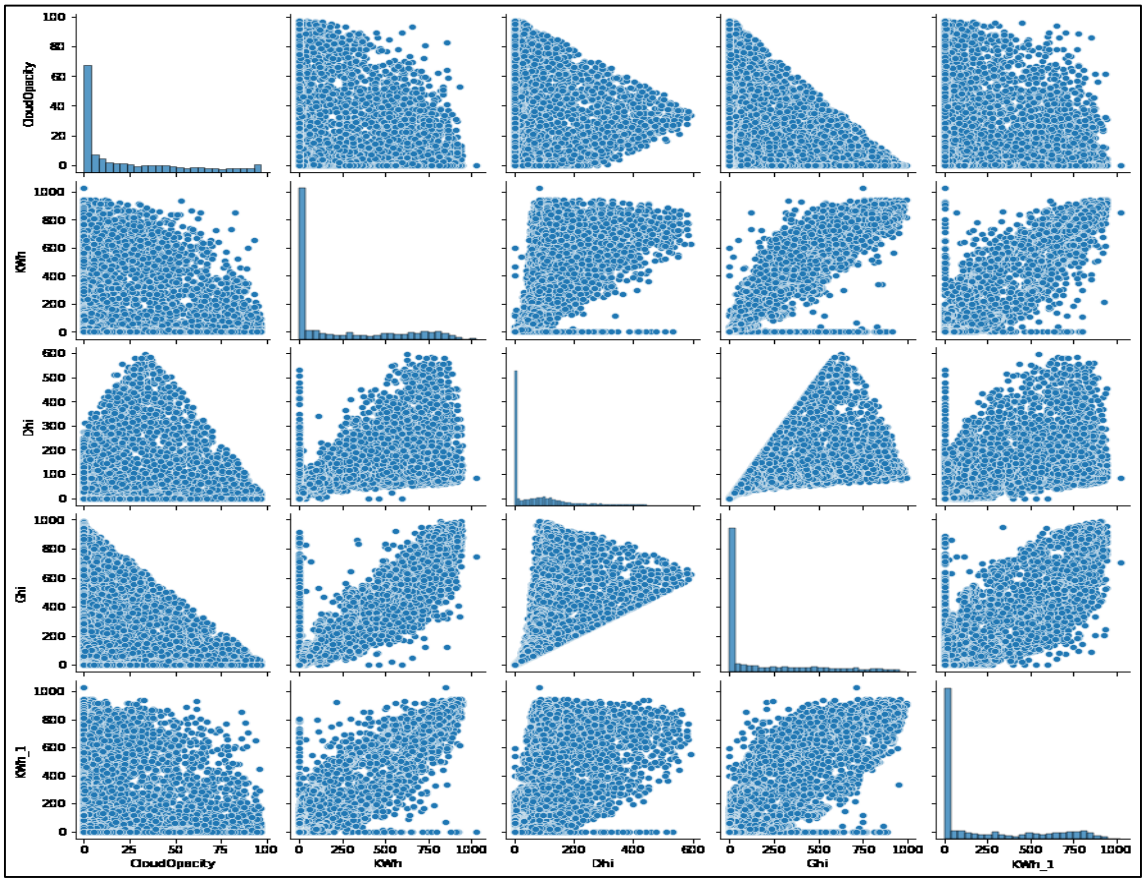


Şekil 6.3. Üretim tahmini (Target Value) için öznitelik (Feature) seçim haritaları (Heat Map)

'S_0', 'S_1', 'S_2', 'S_3', 'S_4', 'S_5', 'S_6', 'S_7', 'S_8', 'S_9', 'S_10', 'S_11', 'S_12', 'S_13', 'S_14', 'S_15', 'S_16', 'S_17', 'S_18', 'S_19', 'S_20', 'S_21', 'S_22', 'S_23' ile 24 saatlik elektrik enerjisi verileri aslında kodlanmıştır (Data Encoding). Bu veri kodlamasında baştaki , 'S' saat anlamında olup 'S_0' günün birinci saat aralığını (00.00 ile 01.00 saat aralığını), 'S_23' ise günün son saat dilimini (23.00 ile 00.00 aralığını) ifade etmektedir. Burada amaç saatlik elektrik üretim verilerini sütunlara girdi olarak 'var-yok' yani '0-1' şeklinde yansıtabilmektir. Saatlik veriler satırlarda yer almaktadır. Fakat saatlik verilerin girdi değişkeni olarak kullanabilmesi yani sütunlara dönüştürülmesi için 0'dan 23'e kadar numaralandırılarak modelin sütunlarına yerleştirilir. Fakat her bir saat için mevcut saat '1'

geriye kalan 23 saat ‘0’ olacak şekilde saatlik veriler dijital verilere dönüştürülür. Aslında burada saatlik veriler ikili matris formuna dönüştürülerek modelin girdisi olarak ele alınır.

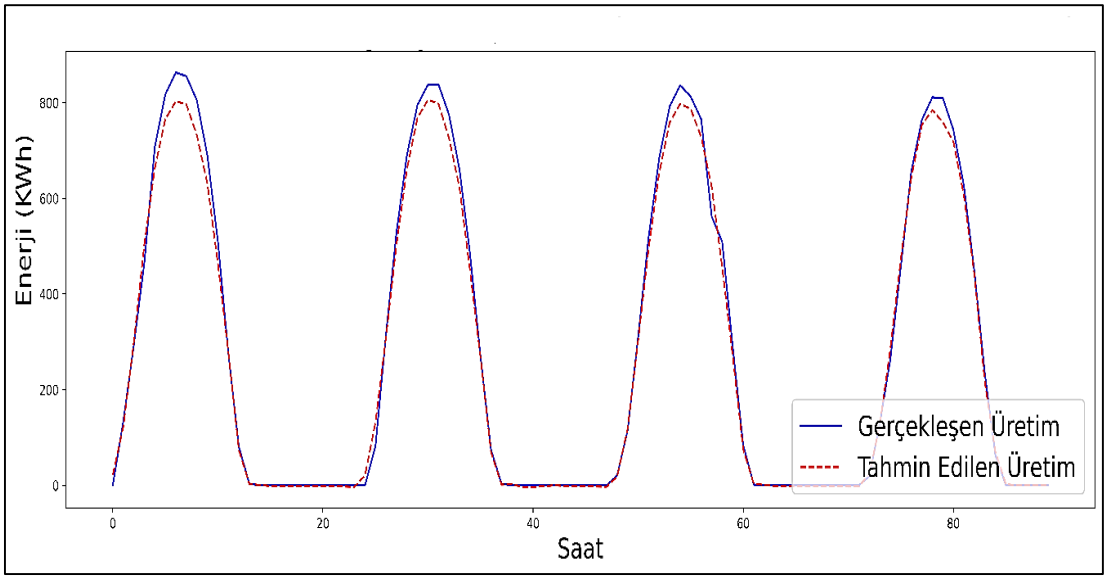
Şekil 6.4.te ise 'CloudOpacity', 'KWh' (Enerji üretimi), 'Dhi', 'Ghi' verilerinin doğrusal olup olmadığı yine araştırılmıştır. Buna göre enerji üretimiyle en fazla doğrusal ilişkisi olan parametreler Ghi (Küresel Yatay Işınım) ve Dhi (Dağınık Yatay Işınım) olduğu görülebilir. Ancak bir önceki paragrafta da belirtildiği üzere buradaki tüm parametreler modelin eğitiminde kullanılmıştır.



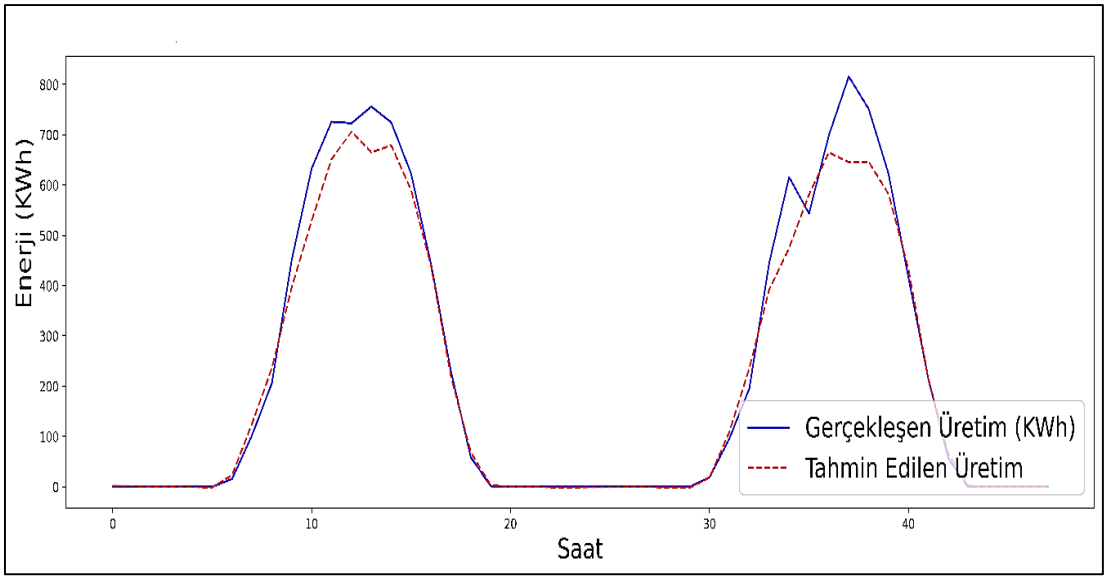
Şekil 6.4. Üretim tahmini (Target Value) için öznitelik (Feature) seçim skalası (Pair Plot)

Polinom ve destek vektör regresyonu yöntemleri kullanılarak yukarıda verilen parametrelerin tamamı regresyon yöntemlerinde kullanılmıştır. Veri setimiz eğer büyük boyutlu olsaydı bu özellik ya da girdilerin belirli bir kısmı elenebilirdi. Fakat modelin ezberleme ya da kötü öğrenme ihtimali de göz önüne alındığında modelin karmaşıklığını artırmak için yukarıda etüt edilen girdilerin tamamı modelde kullanılmıştır.

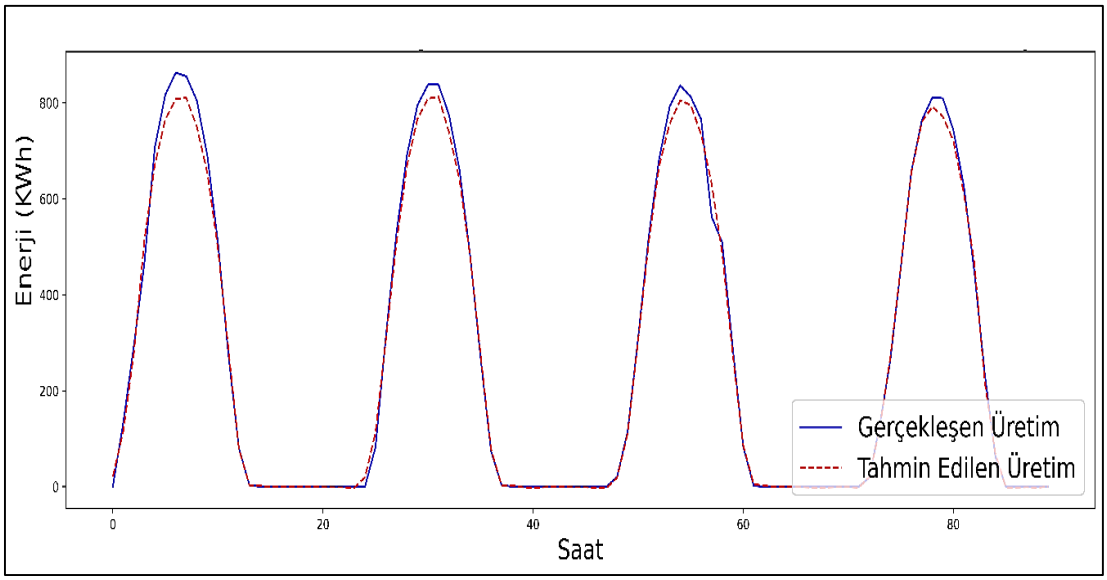
Regresyon analizi iki şekilde gerçekleştirilmiştir. Bu analiz yöntemleri, Destek Vektör Regresyonu ve Polinom regresyondur. Bu iki yöntemden polinom regresyonun uygulanması sonucu Şekil 6.5.- 6.10. elde edilmiştir. Bu yöntemle elde edilen tahminler Çizelge 6.1.'de verilmiştir. Elde edilen MAPE değerleri ise Çizelge 6.2.'de verilmiştir. Polinom Regresyonundan MAPE değerleri Çizelge 6.2.'den de görüleceği üzere polinom derecelerine göre sırasıyla %18,23-%16,78-%14,58 olarak elde edilmiştir.



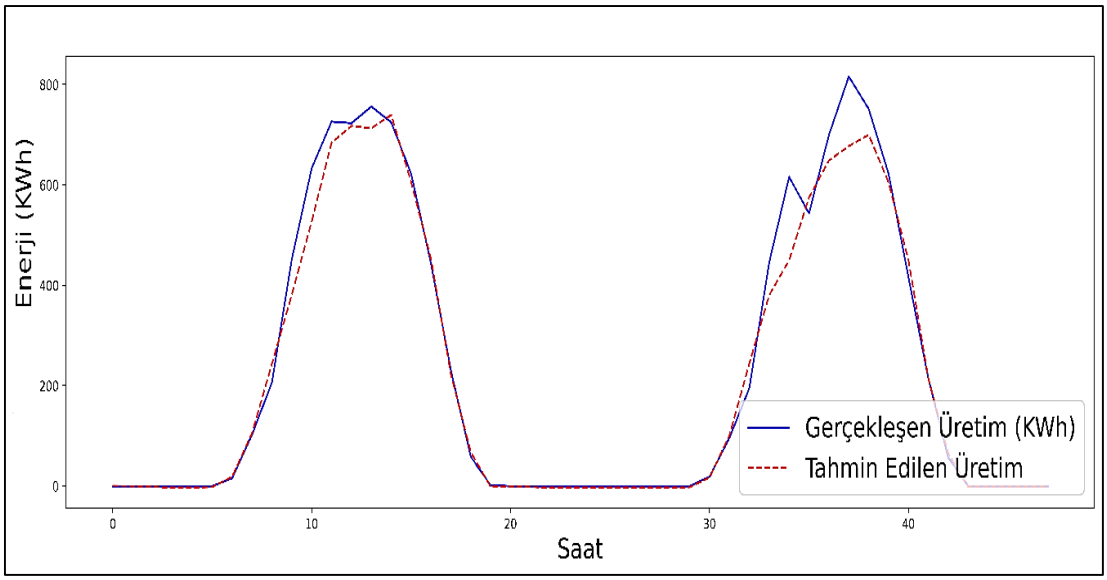
Şekil 6.5. 2. Derece Polinom regresyonu ile eğitim verisinin fit etme seviyesi (R^2 skoru = %96,87)



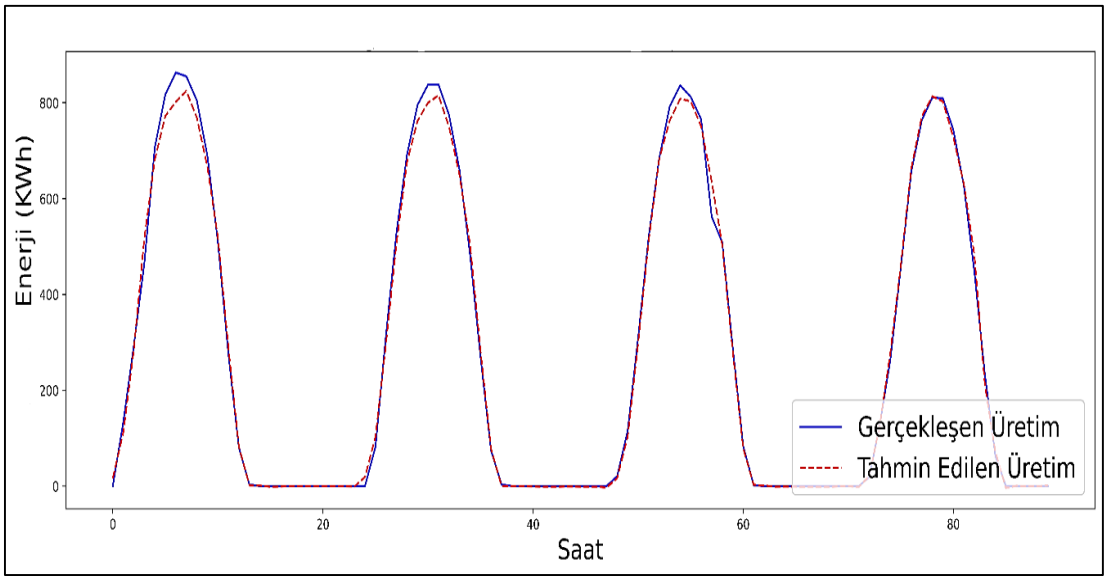
Şekil 6.6. 2. Derece Polinom regresyon sonucu yapılan tahmin ile gerçekleşen üretim karşılaştırması (MAPE= %14,58)



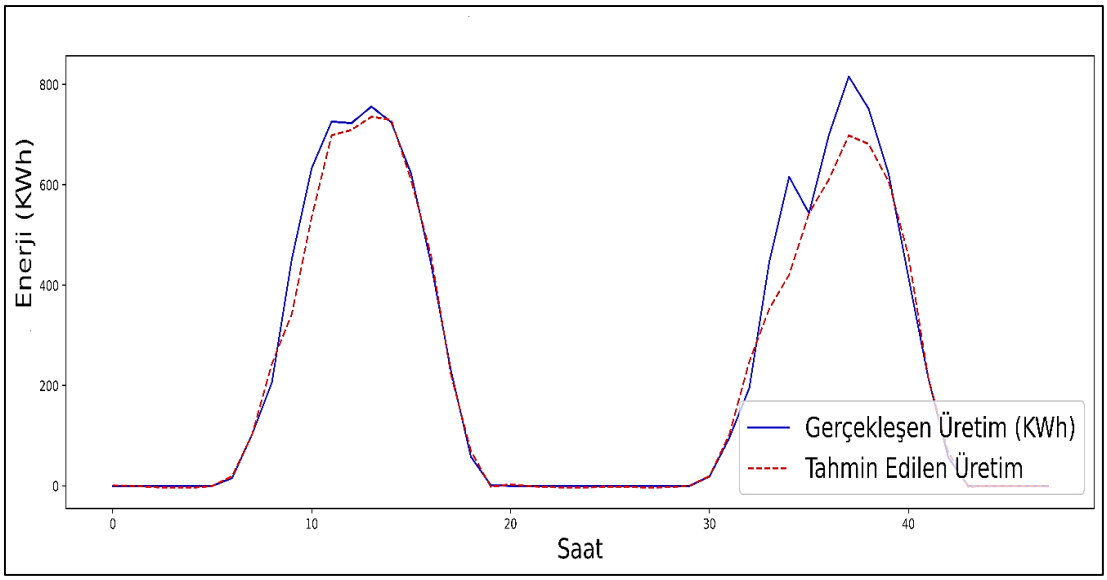
Şekil 6.7. 3. Derece Polinom regresyonu ile eğitim verisinin fit etme seviyesi (R^2 skoru = %97,22)



Şekil 6.8. 3. Derece Polinom regresyon sonucu yapılan tahmin ile gerçekleşen üretim karşılaştırması (MAPE=%16,78)



Şekil 6.9. 4. Derece Polinom regresyonu ile eğitim verisinin fit etme seviyesi (R^2 skoru =%97,63)



Şekil 6.10. 4. Derece Polinom regresyon sonucu yapılan tahmin ile gerçekleşen üretim karşılaştırması (MAPE =%18,23)

Çizelge 6.1. Polinom regresyonu derecelerine göre yapılan tahminler ve gerçekleşen değerler

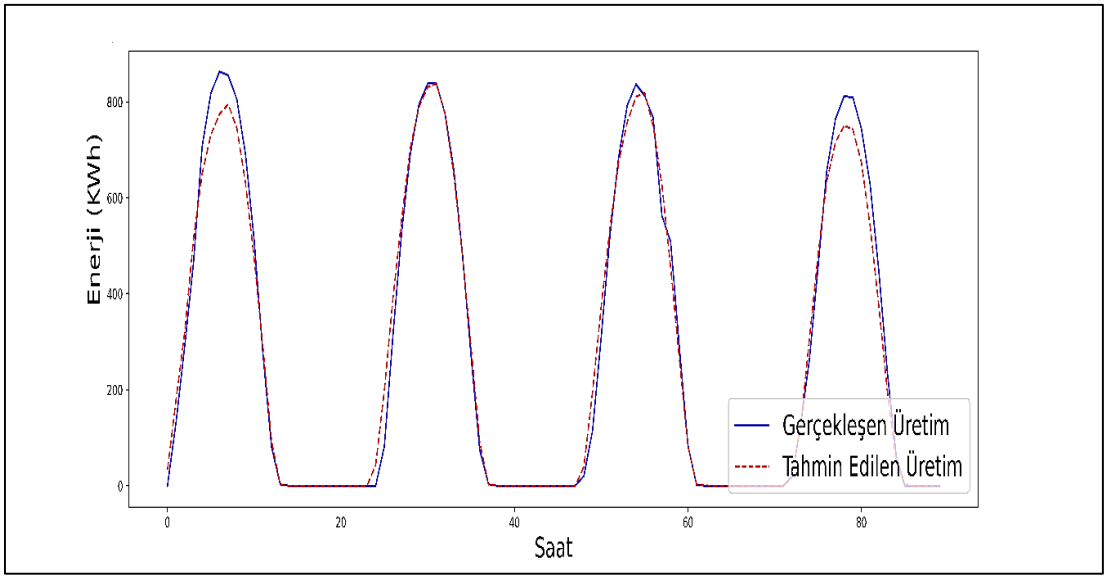
Tarih	4. Dereceden Polinom Regresyon elde edilen Tahminler	3. Dereceden Polinom Regresyon elde edilen Tahminler	2. Dereceden Polinom Regresyon elde edilen Tahminler	Gerçekleşen (KWh)
2021-08-24 06:00:00	19,31742	18,72353	23,43884973	15,75
2021-08-24 07:00:00	101,9878	105,5136	125,5189617	102,375
2021-08-24 08:00:00	243,3769	243,537	235,9862681	206,325
2021-08-24 09:00:00	342,6648	381,16	397,2466138	452,025
2021-08-24 10:00:00	535,7927	527,2697	529,4794396	633,15
2021-08-24 11:00:00	698,4738	684,1009	651,7983449	726,075
2021-08-24 12:00:00	709,5371	717,3397	706,1987597	722,925
2021-08-24 13:00:00	735,6228	712,9393	665,1173939	756
2021-08-24 14:00:00	729,5866	739,1406	678,8793214	724,5
2021-08-24 15:00:00	608,587	605,2016	589,8321152	622,125
2021-08-24 16:00:00	459,3358	452,1904	439,2489714	442,575
2021-08-24 17:00:00	221,6508	222,0656	219,3022707	229,95
2021-08-24 18:00:00	70,12632	67,34992	68,48540295	58,275
2021-08-24 19:00:00	-1,78615	-1,54438	2,749641109	1,575
2021-08-25 06:00:00	19,51666	17,04642	18,47992114	18,9
2021-08-25 07:00:00	103,1024	101,1767	109,5479919	96,075
2021-08-25 08:00:00	247,8359	244,3056	235,8476671	195,3
2021-08-25 09:00:00	352,6551	380,4014	392,2144418	445,725
2021-08-25 10:00:00	420,7302	449,8164	474,6459907	615,825
2021-08-25 11:00:00	543,0222	574,8928	581,0942389	543,375
2021-08-25 12:00:00	611,0407	648,5073	664,9358493	699,3
2021-08-25 13:00:00	698,3483	677,2099	645,3599195	815,85
2021-08-25 14:00:00	681,1626	699,7653	646,3184008	751,275
2021-08-25 15:00:00	606,7025	604,6988	581,872807	622,125
2021-08-25 16:00:00	458,8839	449,9445	433,086613	415,8
2021-08-25 17:00:00	214,4803	214,6715	214,6117946	214,2
2021-08-25 18:00:00	68,01085	65,02374	65,98894995	56,7

Polinom regresyonunda 10.08.2020 ile 19.08.2021 arasındaki veriler eğitim verisi olarak girilir. 20.08.2021 ile 23.08.2021 arasındaki günler saatlik olarak tahmin edilir, yani son 3 gün test olarak ayrılmıştır. Sonuçta eğitim verisiyle test verisinin uyumluluğu R^2 skoruna göre %97,22 olarak elde edilir.

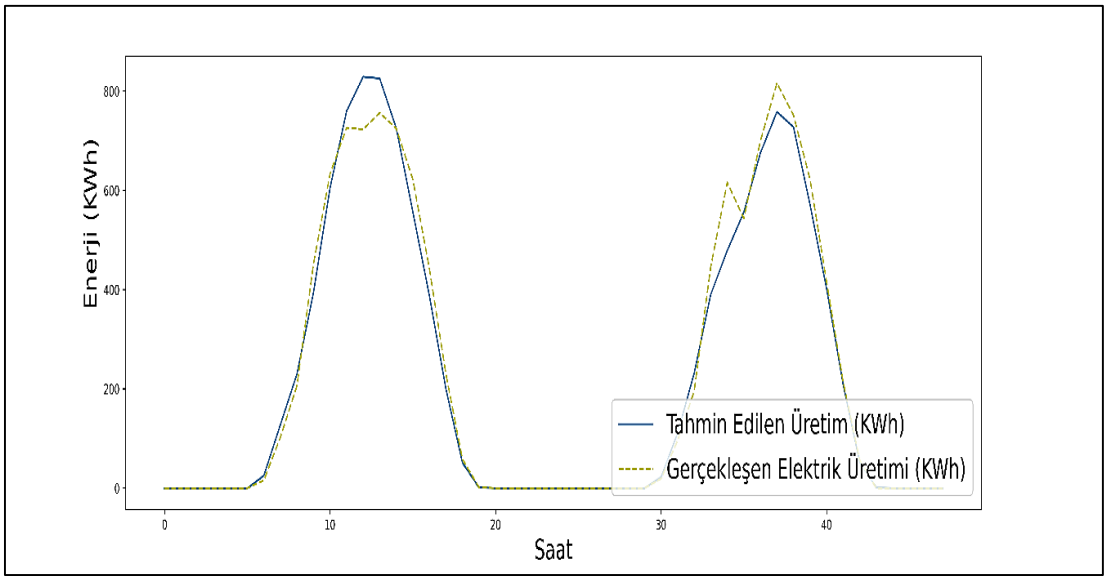
Çizelge 6.2. Polinom regresyonu derecelerine göre yapılan tahminlerin MAPE değerleri

Polinom Derecesi	4.	3.	2.
MAPE (%)	18,23	16,78	14,58

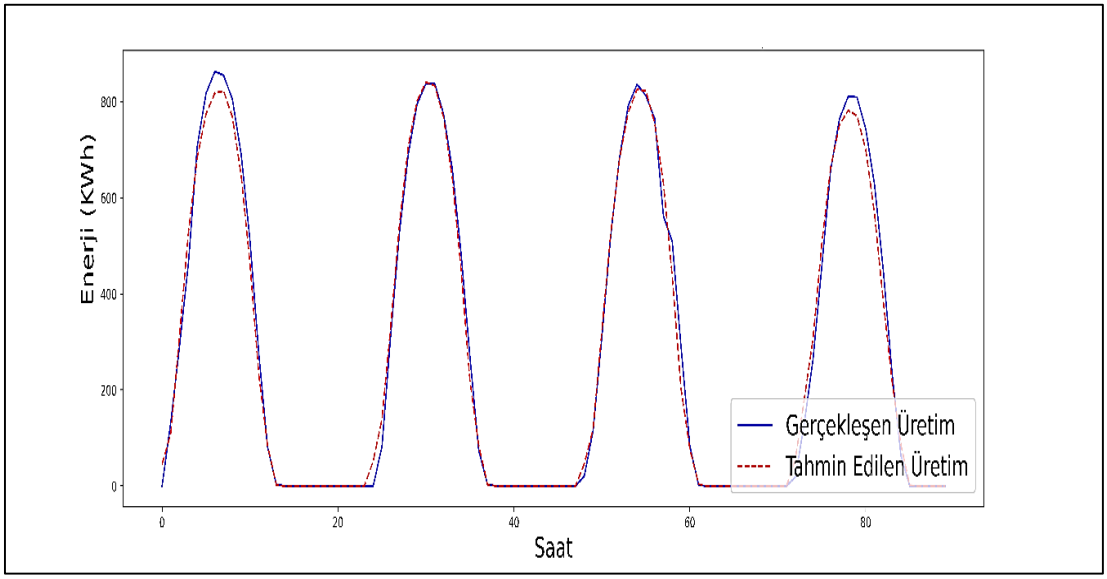
Destek vektör regresyonunda tahmin edilen ve gerçekleşen değerler arasındaki ilişki Şekil 6.11.-6.18.'de gösterilmiştir. Destek vektör regresyonu (SVR) sonucu elde edilen sonuçlar ise Çizelge 6.3.'te verilmiştir. SVR sonucu elde edilen MAPE değerleri ise Çizelge 6.4.'te verilmiştir. MAPE (Mean Absolute Percentage Error) değerleri 'rbf' çekirdeği için Çizelge 6.4.'ten de görüleceği üzere sırasıyla %25,54-%26,69-%26,74 olarak elde edilmiştir. 'poly' çekirdeği içinse %12.68 MAPE elde edilmiştir (Şekil 6.12.).



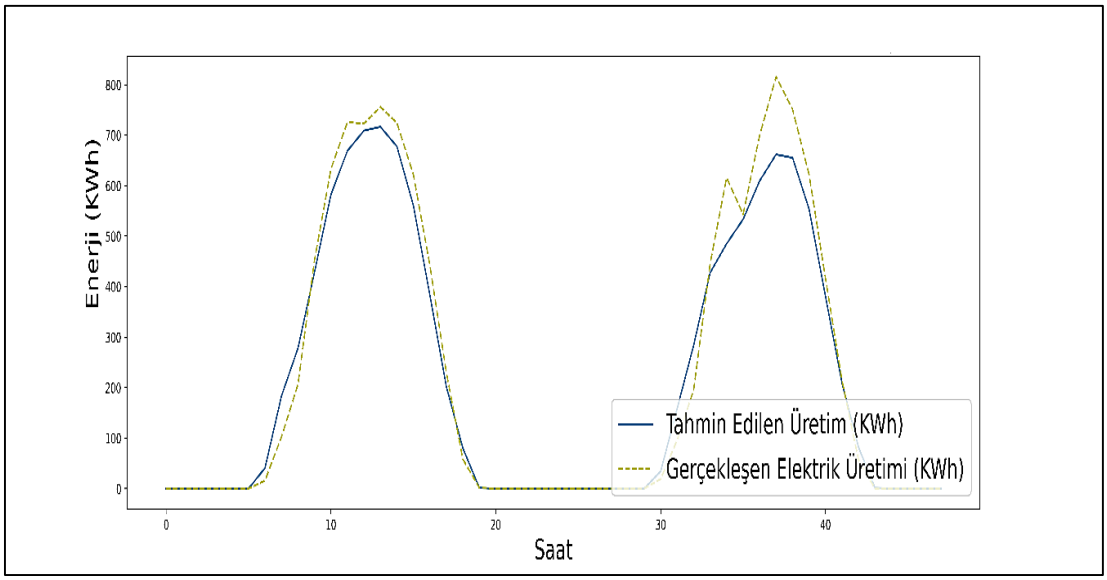
Şekil 6.11. C=500, cache_size=3000, epsilon=0,1; kernel='poly' iken destek vektör regresyonu ile eğitim verisinin fit etme seviyesi (R^2 skoru = %85,72)



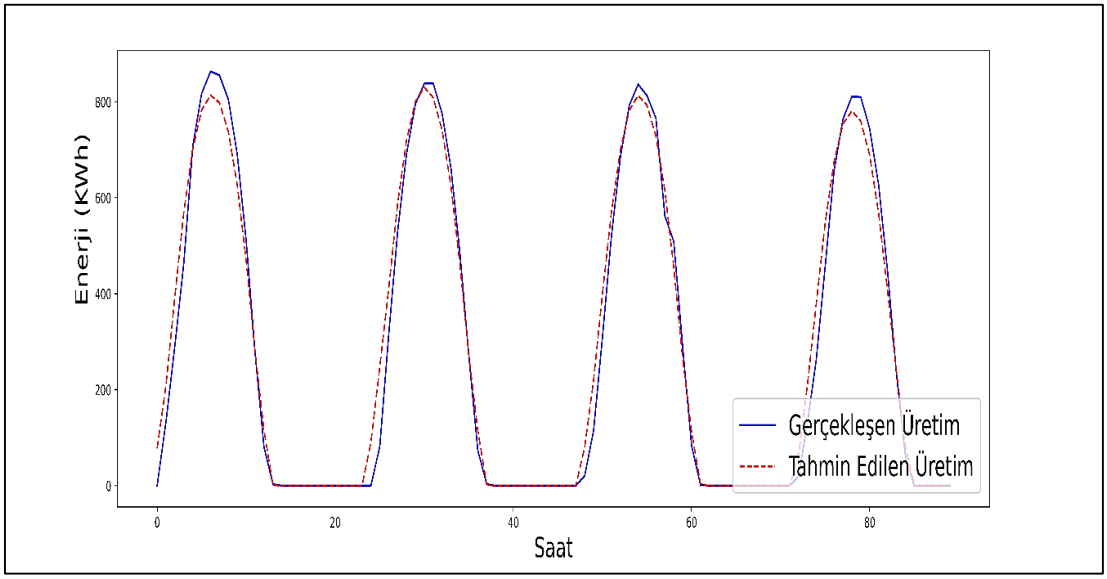
Şekil 6.12. C=500, cache_size=3000, epsilon=0,1; kernel='poly'iken yapılan tahmin ve gerçekleşen üretim karşılaştırması (MAPE=%12,68)



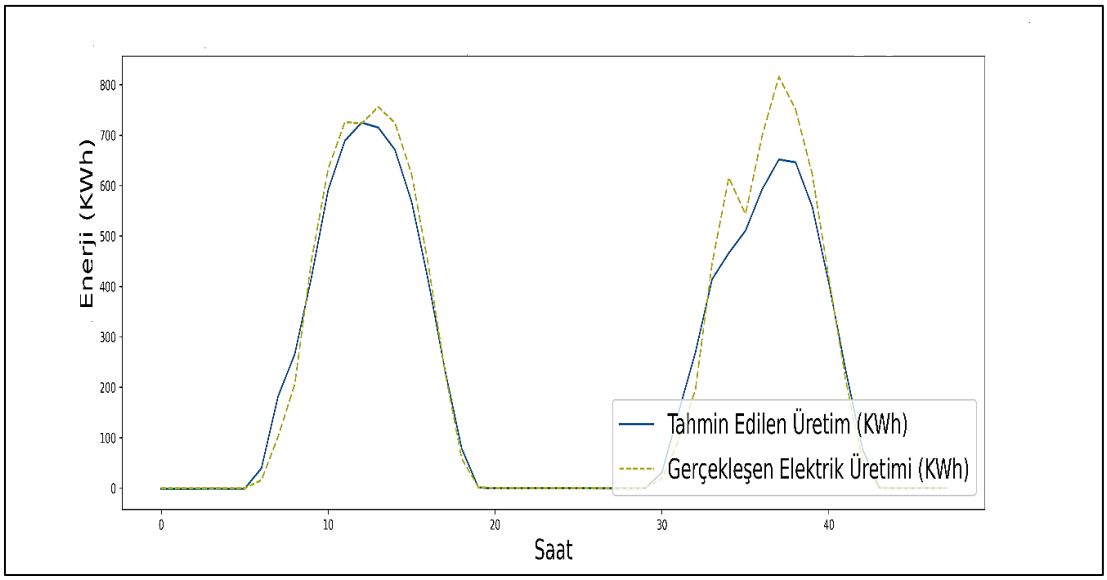
Şekil 6.13. C=500, cache_size=3000, epsilon=0,1; kernel='rbf'iken destek vektör regresyonu ile eğitim verisinin fit etme seviyesi (R^2 skoru = %90,45)



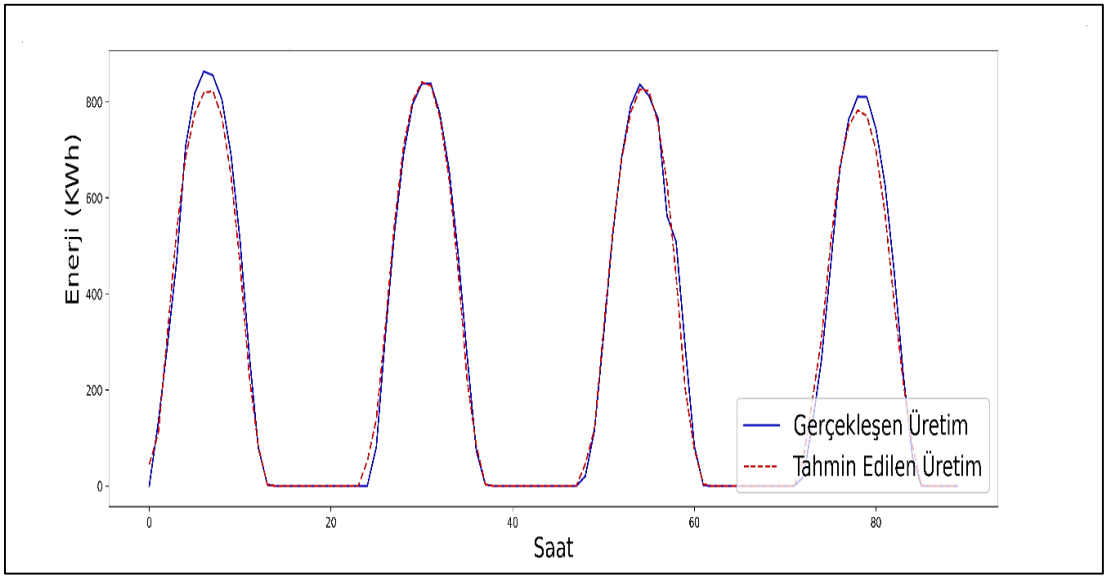
Şekil 6.14. C=500, cache_size=3000, epsilon=0,1 ve kernel='rbf' iken yapılan tahmin ve gerçekleşen üretim karşılaştırması (MAPE=%26,69)



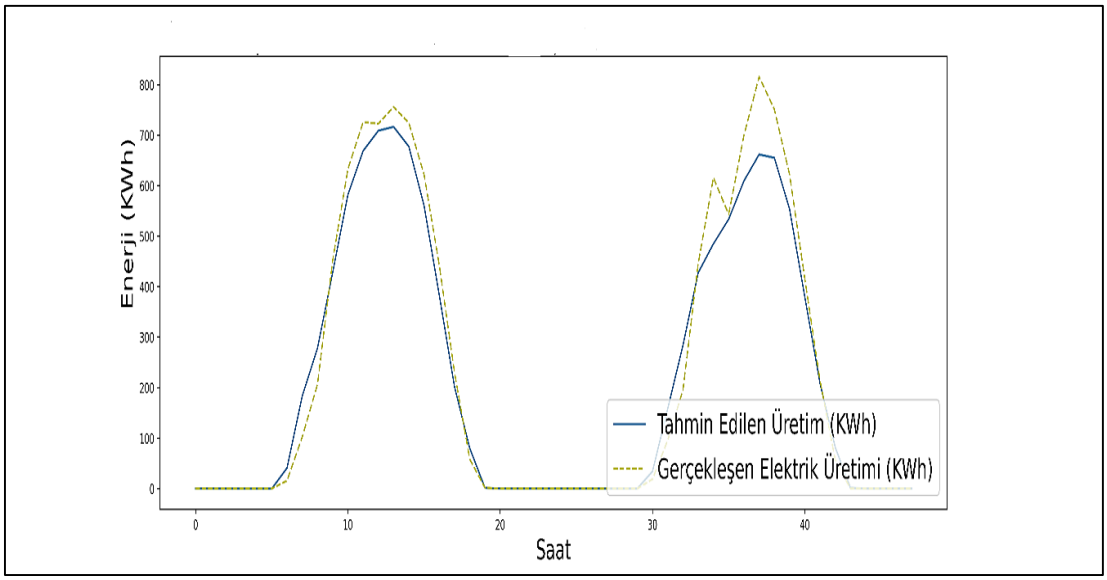
Şekil 6.15. C=50, cache_size=3000, epsilon=0,1; kernel='rbf' iken destek vektör regresyonu ile eğitim verisinin fit etme seviyesi (R^2 skoru = %89,25)



Şekil 6.16. C=50, cache_size=3000, epsilon=0,1 ve kernel='rbf' iken yapılan tahmin ve gerçekleşen üretim karşılaştırması (MAPE=%25,54)



Şekil 6.17. C=500, cache_size=3000, epsilon=0,01; kernel='rbf' iken destek vektör regresyonu ile eğitim verisinin fit etme seviyesi (R^2 skoru = %90,45)



Şekil 6.18. C=500 cache_size=3000 epsilon=0,01; kernel='rbf'iken yapılan tahmin ve gerçekleşen üretim karşılaştırması (MAPE=%26,74)

Bu çalışmada en iyi sonuç (%12,68) MAPE oranında ve %10 MAPE değerine en yakın değerdeki 'poly' yani Polinom Çekirdek Hilesine sahip Destek Vektör Regresyonundan elde edilmiştir.

Çizelge 6.3. Destek vektör regresyonu hiperparametrelerine göre tek adımda yapılan tahminler ve gerçekleşen değerler

Tarih	C=50 cache_size=3000 epsilon=0,1 kernel='rbf'	C=500 cache_size=3000 epsilon=0,01 kernel='rbf'	C=500 cache_size=3000 epsilon=0,1 kernel='rbf'	C=500 cache_size=3000 epsilon=0,1 kernel='poly'	Gerçekleşen (KWh)
2021-08-24 06:00:00	39,31499	40,875436	40,75564	25,23101	15,75
2021-08-24 07:00:00	182,2576	183,3718	183,3591	127,7533	102,3
2021-08-24 08:00:00	265,8159	28,0765357	278,0748	229,953	206,3
2021-08-24 09:00:00	418,548	428,232348	428,2512	394,1812	452,0
2021-08-24 10:00:00	591,505	582,260428	582,310	604,8143	633,1
2021-08-24 11:00:00	688,8882	669,04519	669,0885	759,535	726,0
2021-08-24 12:00:00	724,8451	709,010872	709,0569	828,7933	722,9
2021-08-24 13:00:00	715,109	716,639143	716,6773	825,3381	756

Çizelge 6.3. (devam) Destek vektör regresyonu hiperparametrelerine göre tek adımda yapılan tahminler ve gerçekleşen değerler

Tarih	C=50 cache_size=3000 epsilon=0,1 kernel='rbf'	C=500 cache_size=3000 epsilon=0,01 kernel='rbf'	C=500 cache_size=3000 epsilon=0,1 kernel='rbf'	C=500 cache_size=3000 epsilon=0,1 kernel='poly'	Gerçekleşen (KWh)
2021-08-24 14:00:00	670,9387	677,618855	677,7371	725,0563	724,5
2021-08-24 15:00:00	567,6339	560,567432	560,8337	556,8708	622,1
2021-08-24 16:00:00	411,0404	382,932485	383,3383	387,9172	442,5
2021-08-24 17:00:00	233,4925	201,686671	202,0161	199,9989	229,9
2021-08-24 18:00:00	78,35702	79,9983708	80,12088	50,96831	58,27
2021-08-24 19:00:00	0,975624	1,40609400	1,406109	1,150411	1,575
2021-08-25 06:00:00	31,81494	34,3502924	34,26741	22,26569	18,9
2021-08-25 07:00:00	151,6552	158,546048	158,5135	110,9198	96,07
2021-08-25 08:00:00	269,1822	283,868422	283,8756	231,5233	195,3
2021-08-25 09:00:00	414,2408	427,619606	427,6523	389,9337	445,7
2021-08-25 10:00:00	466,2425	485,037169	485,0672	478,6481	615,8
2021-08-25 11:00:00	510,5712	533,408518	533,4307	555,8705	543,3
2021-08-25 12:00:00	592,704	609,315256	609,3103	675,0943	699,3
2021-08-25 13:00:00	651,7695	661,899384	661,8839	758,0343	815,8
2021-08-25 14:00:00	646,1188	655,287891	655,3364	727,4257	751,2
2021-08-25 15:00:00	557,9098	553,6006853	553,8982	570,9894	622,1
2021-08-25 16:00:00	405,4769	379,7436212	380,1965	401,7291	415,8
2021-08-25 17:00:00	233,9322	208,2695515	208,6097	208,9679	214,2
2021-08-25 18:00:00	78,41204	81,68138382	81,79672	52,03244	56,7

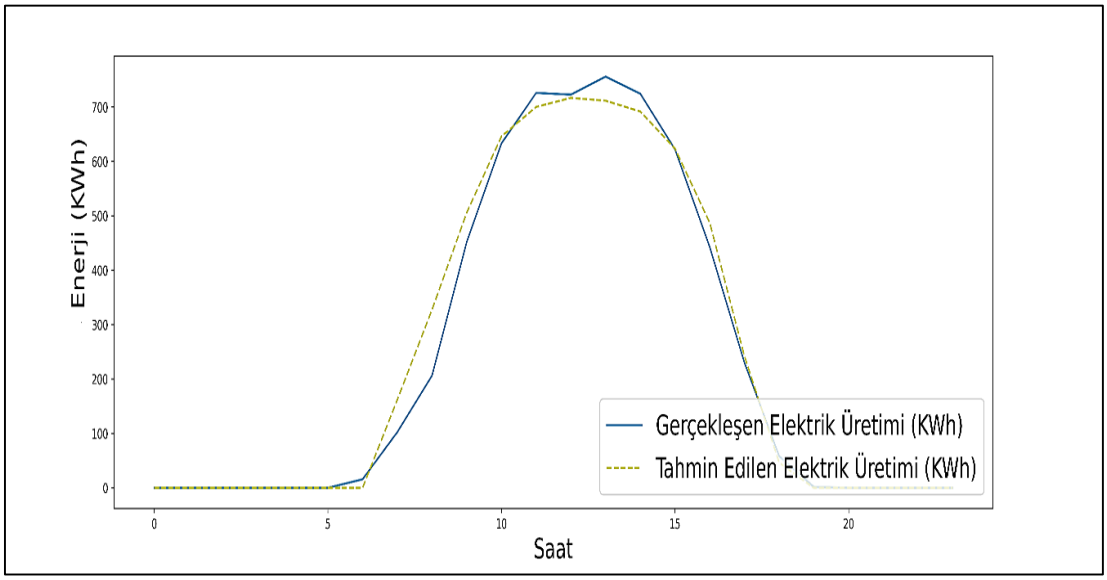
Destek vektör regresyonunda 10.08.2020 ile 23.08.2021 arasındaki veriler eğitim verisi olarak girilir. 24.08.2021 ile 25.08.2021 arasındaki günler saatlik olarak tahmin edilir yani son 2 gün test olarak ayrılmıştır. Sonuçta eğitim verisiyle test verisinin uyumluluğu R^2 skoruna göre %90,45 olarak elde edilir.

Çizelge 6.4. Destek vektör regresyonu hiperparametrelerine göre tek adımda yapılan tahminlerin MAPE değerleri

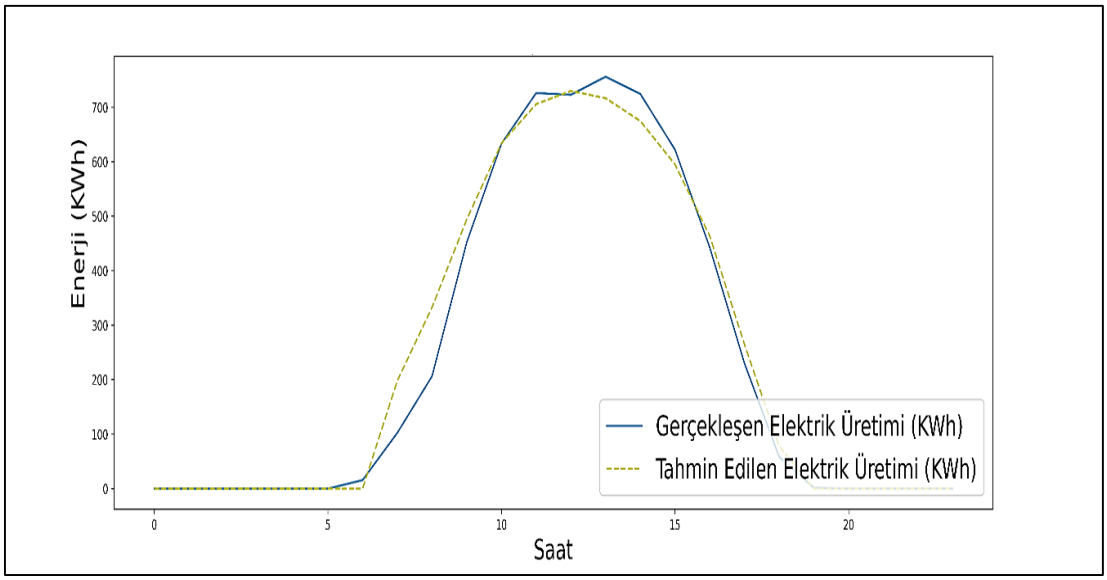
Hiperparametre Değerleri	C=50 cache_size=3000 epsilon=0,1 kernel='rbf'	C=500 cache_size=3000 epsilon=0,1 kernel='rbf'	C=500 cache_size=3000 epsilon=0,01 kernel='rbf'	C=500 cache_size=3000 epsilon=0,1 kernel='poly'
MAPE (%)	25,54	26,69	26,74	12,68

6.2. Adım Adım Olarak Yapılan Tahmin Çalışması (Step By Step Prediction)

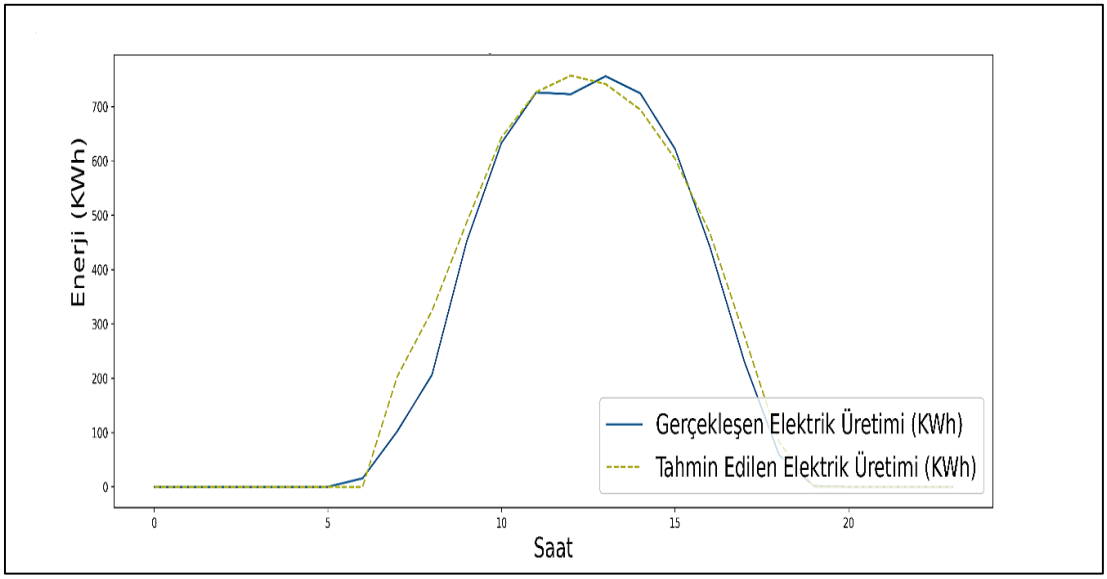
24.08.2021 ve 25.08.2021 günü için polinom regresyonuyla yapılan tahmin ve gerçekleşen değerler arasındaki ilişki Şekil 6.19.- 6.24.'te verilmiştir. Tahmin edilen ve gerçekleşen değerler arasındaki ilişki Çizelge 6.5.'te verilmiş olup 24.08.2021 ve 25.08.2021 günleri için yapılan tahminden elde edilen MAPE değerleri Çizelge 6.6. ve Çizelge 6.7.'de verilmiştir.



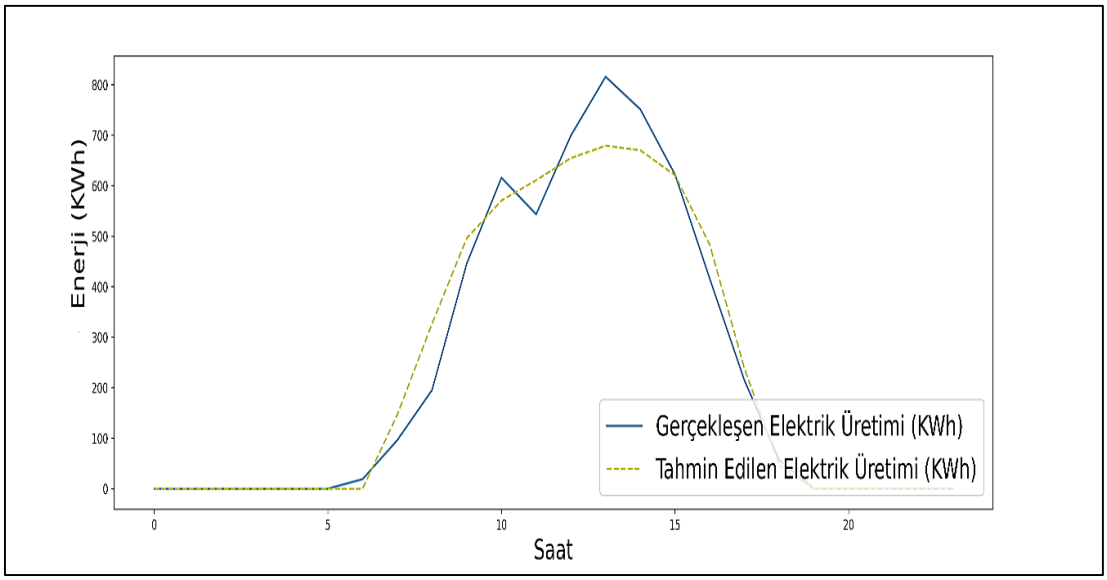
Şekil 6.19. Step By Step Prediction 24.08.2021 Günü 4. dereceden polinom regresyonu tahmin edilen ve gerçekleşen üretim karşılaştırması (MAPE=%15,89)



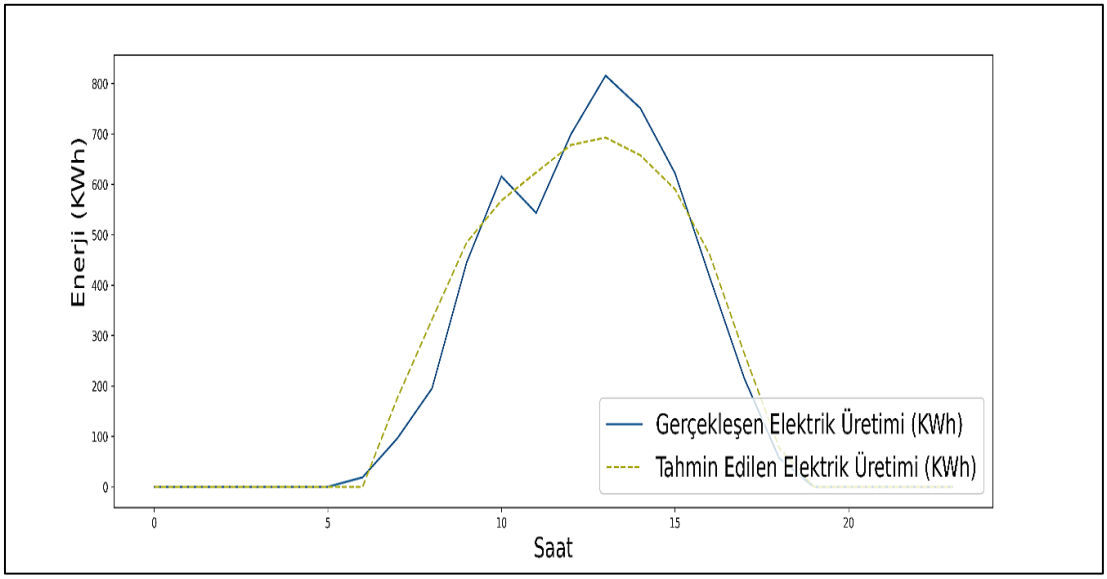
Şekil 6.20. Step By Step Prediction 24.08.2021 Günü 3. dereceden polinom regresyonu tahmin edilen ve gerçekleşen üretim karşılaştırması (MAPE=%18,27)



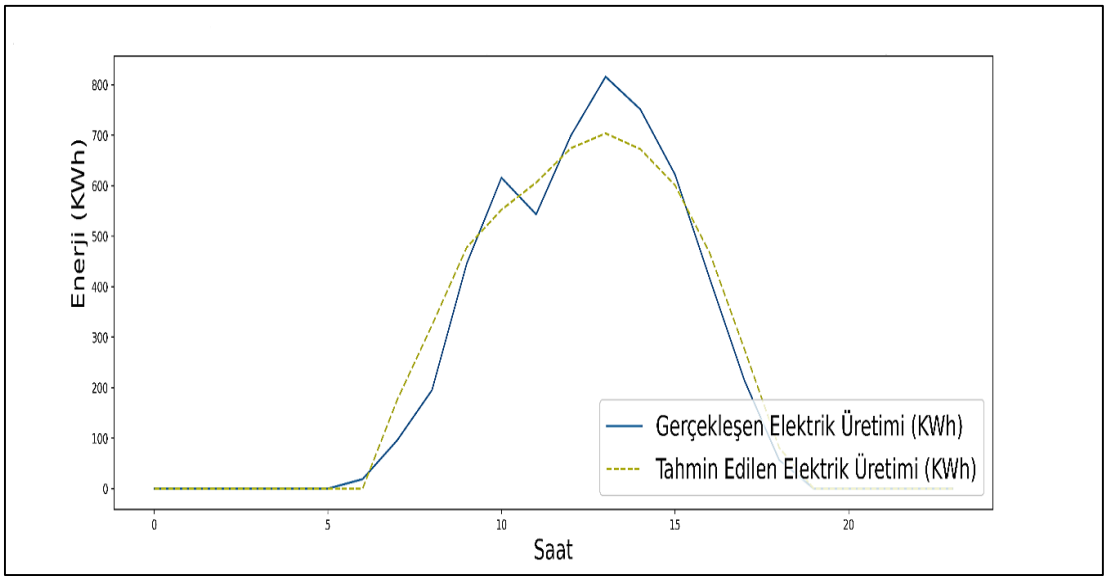
Şekil 6.21. Step By Step Prediction 24.08.2021 Günü 2. dereceden polinom regresyonu tahmin edilen ve gerçekleşen üretim karşılaştırması (MAPE=%18,58)



Şekil 6.22. Step By Step Prediction 25.08.2021 Günü 4. dereceden polinom regresyonu tahmin edilen ve gerçekleşen üretim karşılaştırması (MAPE=%13,76)



Şekil 6.23. Step By Step Prediction 25.08.2021 Günü 3. dereceden polinom regresyonu tahmin edilen ve gerçekleşen üretim karşılaştırması (MAPE=%16,27)



Şekil 6.24. Step By Step Prediction 25.08.2021 Günü 2. dereceden polinom regresyonu tahmin edilen ve gerçekleşen üretim karşılaştırması Üretimi (MAPE=%16,40)

Çizelge 6.5. Adım adım olarak yapılan tahmin sonucunda polinom regresyonuyla tahmin edilen ve gerçekleşen üretim değerleri

Tarih	4. Dereceden Polinom Regresyon elde edilen Tahminler	3. Dereceden Polinom Regresyon elde edilen Tahminler	2. Dereceden Polinom Regresyon elde edilen Tahminler	Gerçekleşen (KWh)
2021-08-24 06:00:00	0	0	0	15,75
2021-08-24 07:00:00	161,9484994	198,0130005	203,394156	102,375
2021-08-24 08:00:00	327,5021338	332,7273813	324,2291813	206,325
2021-08-24 09:00:00	505,8407778	494,0692091	487,2188502	452,025
2021-08-24 10:00:00	646,0782735	633,8847008	643,201031	633,15
2021-08-24 11:00:00	700,3496798	705,8118399	726,8563681	726,075
2021-08-24 12:00:00	716,8867116	729,9988846	757,1033406	722,925
2021-08-24 13:00:00	711,6975284	716,6390235	741,6310199	756
2021-08-24 14:00:00	691,8143716	674,7570483	694,4099492	724,5
2021-08-24 15:00:00	623,543241	594,9744808	603,9454465	622,125
2021-08-24 16:00:00	487,2653922	463,6820803	467,8509936	442,575
2021-08-24 17:00:00	241,8293187	264,9659279	277,7150601	229.95
2021-08-24 18:00:00	46,38991597	78,2632657	81,91473221	58,275
2021-08-25 06:00:00	0	0	0	18,9
2021-08-25 07:00:00	146,506323	175,7931707	176,3107655	96,075
2021-08-25 08:00:00	326,5481653	332,0310267	323,8731813	195,3
2021-08-25 09:00:00	496,1394604	484,9482302	477,9343128	445,725
2021-08-25 10:00:00	570,6137293	568,0075583	552,4660296	615,825
2021-08-25 11:00:00	610,9525039	623,7447415	606,2265779	543,375
2021-08-25 12:00:00	654,6624356	678,280606	674,4019668	699,3
2021-08-25 13:00:00	679,2669723	692,9527467	703,5935136	815,85
2021-08-25 14:00:00	670,2503113	657,8363982	672,6258026	751,275
2021-08-25 15:00:00	620,5847183	590,2580223	600,9701327	622.125
2021-08-25 16:00:00	483,0713609	460,2524375	466,619846	415,8
2021-08-25 17:00:00	237,9571017	263,4054045	275,9549666	214,2
2021-08-25 18:00:00	46,39721672	77,68665087	81,09019547	56,7

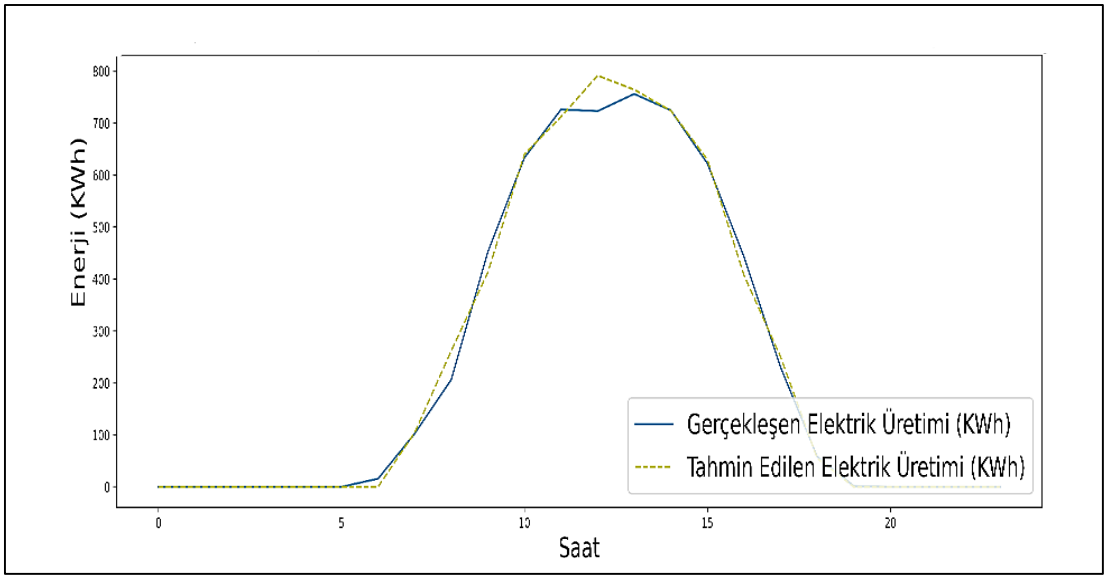
Çizelge 6.6. Adım adım olarak yapılan tahmin sonucunda polinom regresyonuyla 24.08.2021 gününde tahmin edilen ve gerçekleşen üretim değerleri için hesaplanan MAPE değerleri

Polinom Derecesi	4.	3.	2.
MAPE (%)	15,89	18,27	18,58

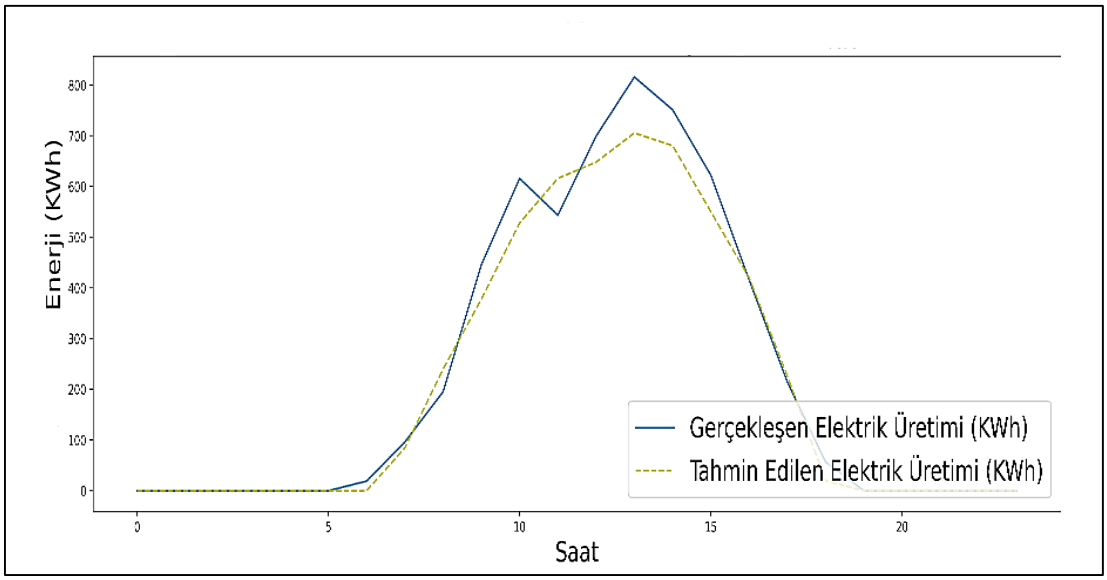
Çizelge 6.7. Adım adım olarak yapılan tahmin sonucunda polinom regresyonuyla 25.08.2021 gününde tahmin edilen ve gerçekleşen üretim değerleri için hesaplanan MAPE değerleri

Polinom Derecesi	4.	3.	2.
MAPE (%)	13,76	16,27	16,40

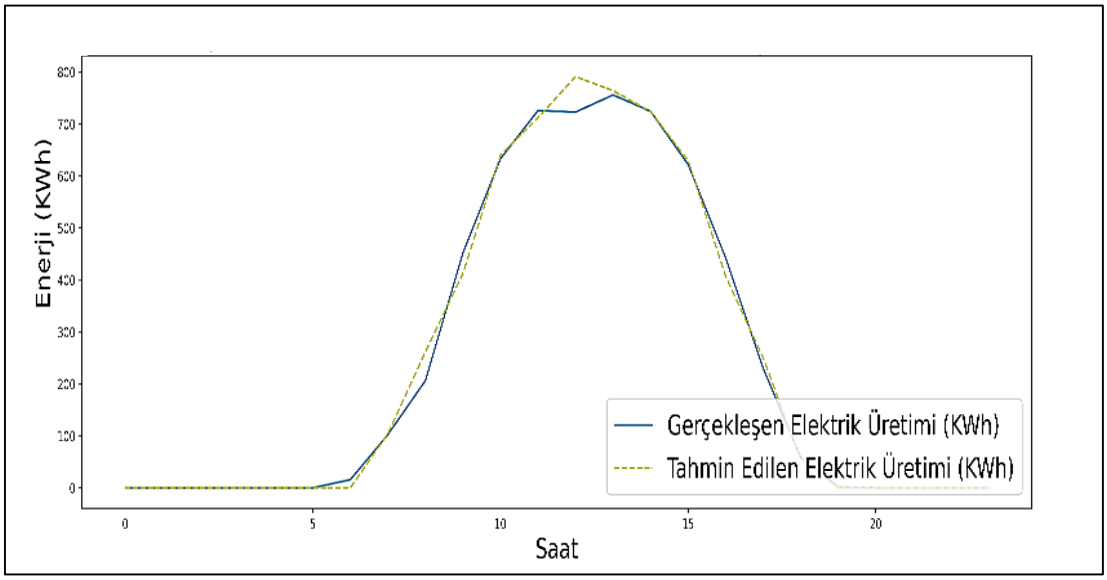
24.08.2021 ve 25.08.2021 günü için destek vektör regresyonuyla yapılan tahmin ve gerçekleşen değerler arasındaki ilişki Şekil 6.25.-6.26-6.27.-6.28.-6.29.-6.30.-6.31.-6.32.'de gösterilmiştir. Çizelge 6.8.'de tahmin edilen ve gerçekleşen değerler arasındaki ilişki tablo halinde verilmiştir. 24.08.2021 ve 25.08.2021 günleri için yapılan tahminden elde edilen MAPE değerleri Çizelge 6.9. ve Çizelge 6.10'da verilmiştir.



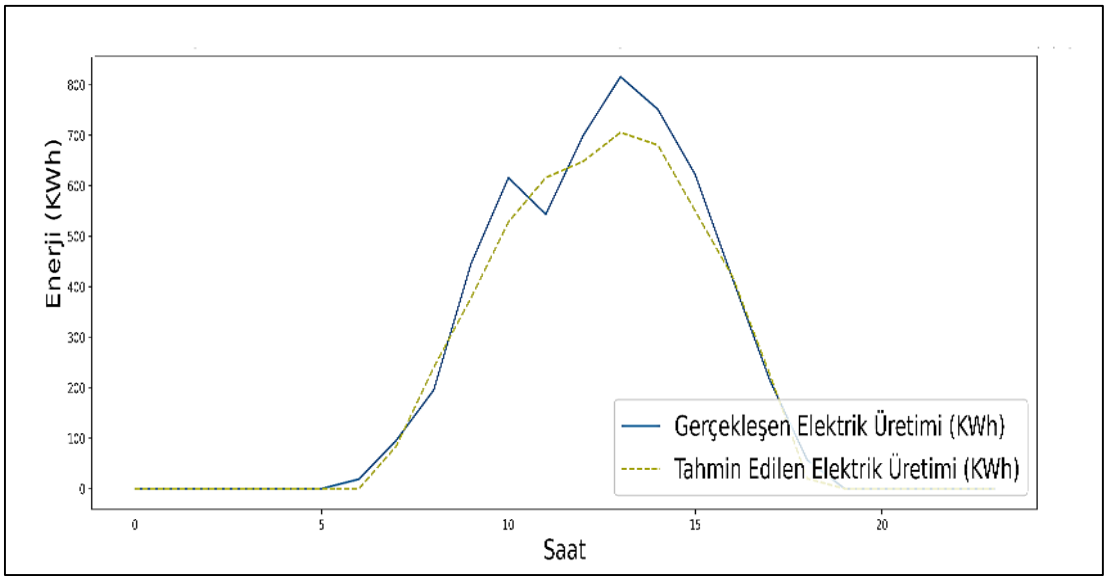
Şekil 6.25. 24.08.2021 Günü C=3, cache_size=9000, kernel='rbf', epsilon=0,1 destek vektör regresyonu tahmin edilen ve gerçekleşen elektrik üretimi (MAPE=%11,44)



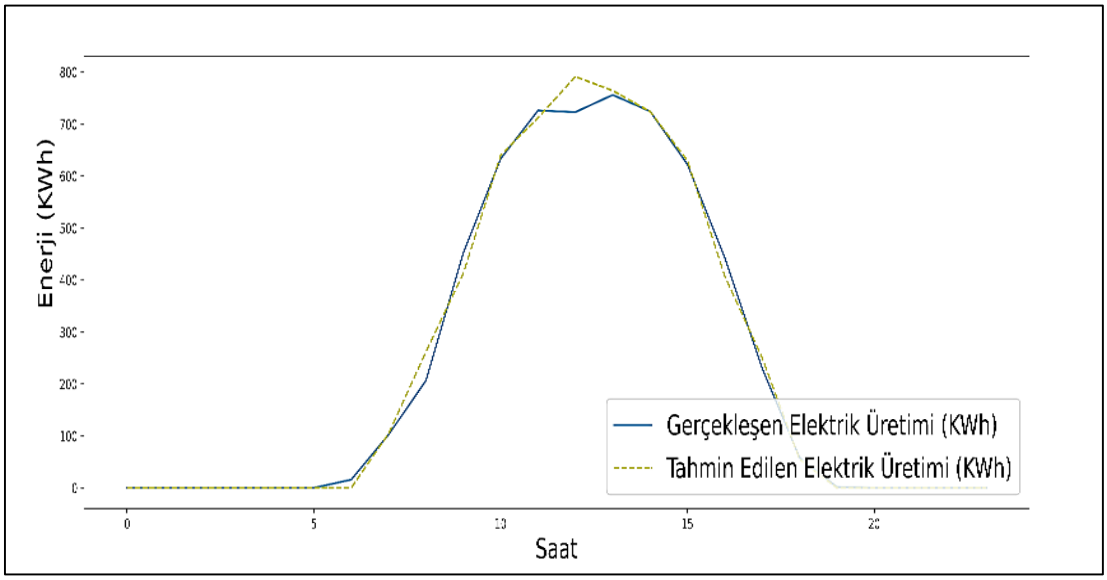
Şekil 6.26. 25.08.2021 Günü C=3, cache_size=9000, kernel='rbf', epsilon=0,1 destek vektör regresyonu tahmin edilen ve gerçekleşen elektrik üretimi (MAPE=%12,11)



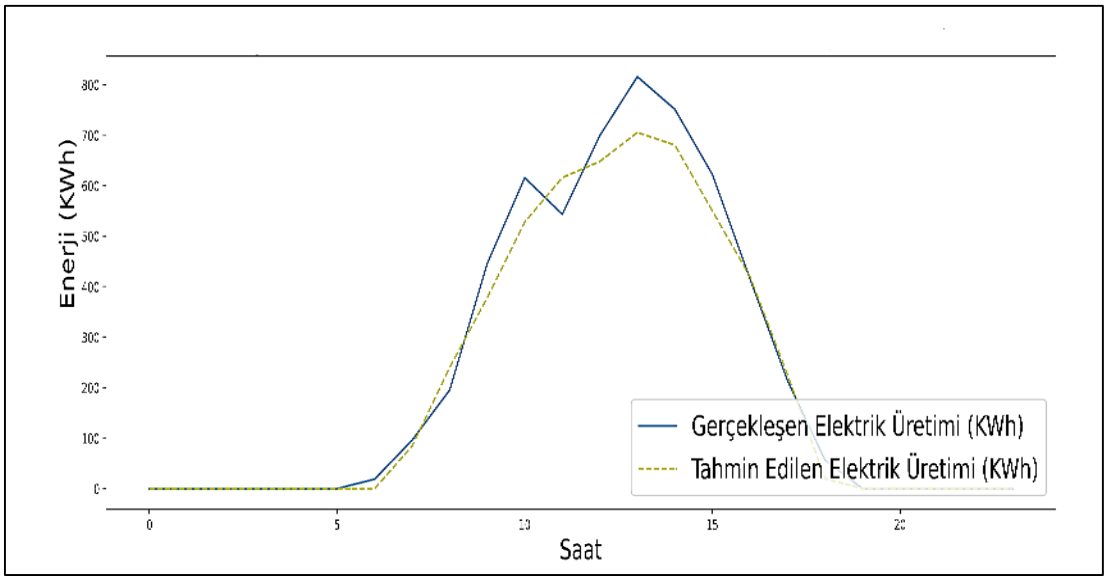
Şekil 6.27. 24.08.2021 Günü C=30, cache_size=9000, kernel='rbf', epsilon=0,01 destek vektör regresyonu tahmin edilen ve gerçekleşen elektrik üretimi (MAPE=%11,44)



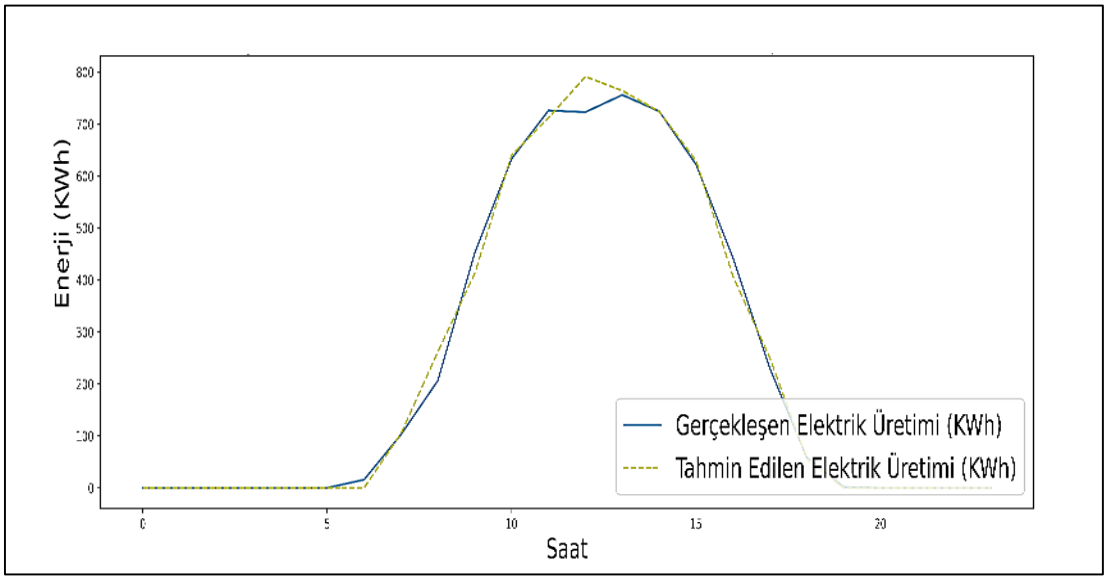
Şekil 6.28. 25.08.2021 Günü C=30, cache_size=9000, kernel='rbf', epsilon=0,01 destek vektör regresyonu tahmin edilen ve gerçekleşen elektrik üretimi (MAPE=%12,11)



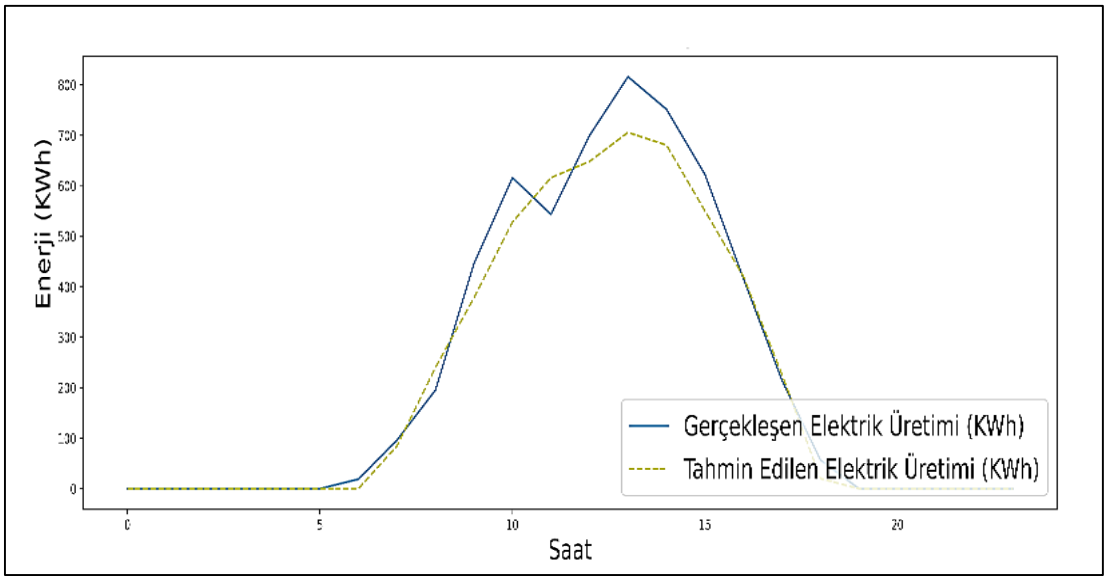
Şekil 6.29. 24.08.2021 Günü C=3, cache_size=9000, kernel='poly', epsilon=0,1 destek vektör regresyonu tahmin edilen ve gerçekleşen elektrik üretimi (MAPE=%11,44)



Şekil 6.30. 25.08.2021 Günü C=3, cache_size=9000, kernel='poly', epsilon=0,1 destek vektör regresyonu tahmin edilen ve gerçekleşen elektrik üretimi (MAPE=%12,11)



Şekil 6.31. 24.08.2021 Günü C=30, cache_size=9000, kernel="poly", epsilon=0,01 destek vektör regresyonu tahmin edilen ve gerçekleşen elektrik üretimi (MAPE=%11,44)



Şekil 6.32. 25.08.2021 Günü C=30, cache_size=9000, kernel="poly", epsilon=0,01 destek vektör regresyonu tahmin edilen ve gerçekleşen elektrik üretimi (MAPE=%12,11)

Çizelge 6.8. Adım adım olarak yapılan tahmin sonucunda destek vektör regresyonuyla tahmin edilen ve gerçekleşen üretim değerleri

Tarih	C=3 cache_size=9000 epsilon=0,1 kernel='rbf'	C=30 cache_size= 9000 epsilon=0,01 kernel='rbf'	C=3 cache_size= 9000 epsilon=0,1 kernel='poly'	C=3 cache_size= 9000 epsilon=0,1 kernel='poly'	Gerçekleşen (KWh)
2021-08-24 06:00:00	0	0	0	0	15,75
2021-08-24 07:00:00	104,25	104,25	104,2	104,25	102,3
2021-08-24 08:00:00	261,75	261,75	261,7	261,75	206,3
2021-08-24 09:00:00	412,5	412,5	412,5	412,5	452,0
2021-08-24 10:00:00	640	640	640	640	633,1
2021-08-24 11:00:00	712	712	712	712	726,0
2021-08-24 12:00:00	791,25	791,25	791,2	791,25	722,9
2021-08-24 13:00:00	764,25	764,25	764,2	764,25	756
2021-08-24 14:00:00	724	724	724	724	724,5
2021-08-24 15:00:00	629,625	629,62	629	629,625	622
2021-08-24 16:00:00	407	407	407	407	442,5
2021-08-24 17:00:00	250	250	250	250	229,9

Çizelge 6.8. (devam) Adım adım olarak yapılan tahmin sonucunda destek vektör regresyonuyla tahmin edilen ve gerçekleşen üretim değerleri

Tarih	C=3 cache_size=9000 epsilon=0,1 kernel='rbf'	C=30 cache_size= 9000 epsilon=0,01 kernel='rbf'	C=3 cache_size= 9000 epsilon=0,1 kernel='poly'	C=3 cache_size= 9000 epsilon=0,1 kernel='poly'	Gerçekleşen (KWh)
2021-08-24 18:00:00	55,0156	55,0156	55,01	55,0156	58,2
2021-08-25 06:00:00	0	0	0	0	18,9
2021-08-25 07:00:00	84,5	84,5	84,5	84,5	96,07
2021-08-25 08:00:00	240	240	240	240	195,3
2021-08-25 09:00:00	378	378	378	378	445,7
2021-08-25 10:00:00	528	528	528	528	615,8
2021-08-25 11:00:00	616	616	616	616	543,3
2021-08-25 12:00:00	648	648	648	648	699,3
2021-08-25 13:00:00	705,5	705,5	705,5	705,5	815,8
2021-08-25 14:00:00	680,5	680,5	680,5	680,5	751,2
2021-08-25 15:00:00	550	550	550	550	622,1
2021-08-25 16:00:00	420	420	420	420	415,8
2021-08-25 17:00:00	226	226	226	226	214,2
2021-08-25 18:00:00	20	20	20	20	56,7

Çizelge 6.9. Adım adım olarak yapılan tahmin sonucunda destek vektör regresyonuyla 24.08.2021 gününde tahmin edilen ve gerçekleşen üretim değerleri için hesaplanan MAPE değerleri

Hiperparametre Değerleri	C=3 cache_size=9000 epsilon=0,1 kernel='rbf'	C=30 cache_size=9000 epsilon=0,01 kernel='rbf'	C=3 cache_size=9000 epsilon=0,1 kernel='poly'	C=30 cache_size=9000 epsilon=0,01 kernel='poly'
MAPE (%)	10,93	10,93	11,44	11,44

Çizelge 6.10. Adım adım olarak yapılan tahmin sonucunda destek vektör regresyonuyla 25.08.2021 gününde tahmin edilen ve gerçekleşen üretim değerleri için hesaplanan MAPE değerleri

Hiperparametre Değerleri	C=3 cache_size=9000 epsilon=0,1 kernel='rbf'	C=30 cache_size=9000 epsilon=0,01 kernel='rbf'	C=3 cache_size=9000 epsilon=0,1 kernel='poly'	C=30 cache_size=9000 epsilon=0,01 kernel='poly'
MAPE (%)	9,75	12,11	12,11	12,11

7. SONUÇ VE ÖNERİLER

Osmaniye İl Özel İdaresine ait 990 kW kurulu gücündeki Güneş Enerjisi Santralinin elektrik üretim tahmin çalışması polinom regresyon ve destek vektör regresyon yöntemleriyle gerçekleştirilmiş olup en iyi tahmin başarısı adım adım olarak yapılan destek vektör regresyonundan elde edilmiştir. Destek vektör regresyonun bu çalışma için polinom regresyonuna göre daha uygun bir yöntem olduğunu söylemek mümkündür.

Polinom regresyon ile elde edilen sonuçlar Çizelge 6.2.'de sırasıyla %18,23-%16,78 ve %14,58 olarak elde edilmiş olup bu sonuçlar da %10-%20 aralığında olduğu için polinom regresyonu ile iyi bir tahmin yapıldığı söylenebilir. Polinom regresyonu uygulandığında elde edilen Çizelge 6.2.'de 24.08.2021 ve 25.08.2021 günlerine ait sıfır değerinin dışındaki elektrik üretim değerleri bir seferde tahmin edilmiş olup çizelgedeki MAPE oranları sırasıyla %18,23- %16,78 ve %14,58 olarak hesap edilmiştir. Bu sıralamada en büyük başarı en küçük MAPE oranıyla 2. dereceden polinom regresyonunda gerçekleştirilmiştir.

Destek vektör regresyon uygulandığında elde edilen Çizelge 6.4.'te 24.08.2021 ve 25.08.2021 günlerine ait sıfır değerinin dışındaki elektrik üretim değerleri bir seferde tahmin edilmiş olup çizelgedeki MAPE oranları sırasıyla %25,54-%26.69-%26,74 ve 12.68 olarak hesap edilmiştir. Bu sıralamada en büyük başarı; yani en küçük MAPE C=500, cache_size=3000, epsilon=0,1 ve kernel="poly" hiperparametrelerine sahip destek vektör regresyonudur. Bu regresyonun MAPE'si %12,68 olarak elde edilmiştir. Çizelge 6.4.'te Destek vektör regresyonundan 'rbf' çekirdek hilesiyle elde edilen MAPE değerleri sırasıyla %25,54-%26,69 ve %26.74 olarak elde edilmiş olup bu değerler %20-%50 arasında gerçekleştiği için kabul edilebilir olarak değerlendirilir. Destek vektör regresyonunda 'poly' çekirdek hilesiyle elde edilen %12.68 MAPE ise yine %10-%20 aralığında gerçekleşmiş olup iyi bir tahmin olarak değerlendirilir. Bu sonuç Polinom Regresyonuyla elde edilen MAPE değerlerine göre daha düşüktür. Yani çekirdek hilesi 'poly' olarak değiştirildiğinde elde edilen tahmin başarısı Polinom Regresyondan bile daha yüksek çıkmıştır. Bu da, Hiperparametre seçiminin ne kadar özenle yapılması gerektiğini göstermektedir. %12,68 MAPE; %10-%20 aralığında olduğu için iyi bir tahmindir.

Destek vektör regresyon uygulandığında elde edilen Çizelge 6.4.'ten görüleceği üzere destek vektör regresyonunda kullanılan 'rbf' çekirdek hilesiyle elde edilen MAPE değerleri genel

olarak, Çizelge 6.2.‘de verilen Polinom Regresyonundan elde edilen MAPE değerlerine göre daha yüksek çıkmıştır. Yani ‘rbf’ çekirdek hilesine sahip Destek Vektör Regresyonu, Polinom Regresyonundan elde edilen tahmine göre daha başarılı bir performans sergilemiştir. Tek aşamada yapılan polinom regresyondaki başarı oranı Radial Basis Function (‘rbf’) çekirdeği kullanılan destek vektör regresyonlarına göre yaklaşık %12 daha fazladır. Fakat destek vektör regresyonuna Polinom (‘poly’) çekirdeği uygulandığı zaman MAPE %12.68 olarak gerçekleşmiş olup bu sonuç polinom regresyonunda elde edilen en küçük MAPE değeri olan %14,58’e göre %2 daha iyi bir sonuç olarak elde edilmiştir.

Destek vektör regresyonu ile yapılan tahminde eğer veri seti 1 yıldan daha fazla veri ihtiva etseydi Polinom Çekirdek Hileli SVR yöntemiyle elde edilen MAPE %10’un altında elde edilebilirdi. Veri setinin düşük boyutlu olması ele alınan problemin çözümünün doğruluğunu etkileyen en önemli kısıt olarak burada karşımıza çıkmaktadır. Küçük ve orta ölçekli veriler için destek vektör regresyonu ideal bir yöntemdir ancak dikkat edilmesi gereken nokta doğru çekirdeği ve doğru hiperparametreleri seçebilmektir. Destek vektöründeki tahmin hataları ‘rbf’ (Radial Basis Function) çekirdeği kullanıldığında %26 civarında iken ‘poly’ (Polinom) çekirdeği kullanıldığında bu oran %12,68 olarak yani hata oranı yarısı kadar azalmış haliyle elde edilmiştir.

Destek vektör regresyonu ile yapılan tahminde radyal temelli çekirdek fonksiyonu ve polinom çekirdek fonksiyonu temelde, sonsuz boyutlu özellik vektörleriyle yapılamayacak kadar karmaşık işlemlerin sanki model üzerinde özellik vektörleriyle işlem yapıyormuş davranır; ancak bu özellik vektörleri, aslında modellemenin içerisine yer almaz.

Destek vektör regresyonunda tek adımda yapılan tahminde destek vektör regresyonu modelinde RBF (Radyal Temelli Çekirdek Fonksiyonu – Radial Basis Function) yerine Polinom Çekirdek Fonksiyonu kullanılması 48 saatlik (24.08.2021 – 25.08.2021) tahmindeki MAPE oranını %26’lardan %12,68’e düşürmüştür. Bu da ele alınan modelde Hiperparametre ayarının ne kadar önemli olduğunu bir kez daha gözler önüne sermektedir.

Tahmin çalışmasının geneline bakıldığında en az 5 yıllık veri seti olsaydı MAPE oranı %10’un altında elde edilebilirdi. Çünkü daha fazla örnek ve veri seti modelin daha başarılı tahmin yapması anlamına gelmektedir. Daha fazla veri olsaydı bu veri seti için derin öğrenme yöntemleri de kullanılabilirdi. Yalnızca 1 yıllık elektrik üretim verileri için makine

öğrenmesi yöntemlerinden sadece polinom ve destek vektör regresyonları tatbik edilmiştir. Kullanılan makine öğrenme algoritmalarından destek vektör regresyonundan %12,68 oranında MAPE elde edilmiştir. Böylelikle tahmin çalışmasında en başarılı yöntem SVR olarak tespit edilmiştir. Bu sonuç %10-%20 aralığında olduğu için Polinom Çekirdek Hilesi yardımıyla yapılan tahminin başarısı 'İyi' olarak değerlendirilir.

Adım adım tahmin çalışmasında 24.08.2021 günü için 2., 3. ve 4. dereceden polinom regresyonu için elde edilen MAPE değerleri sırasıyla %18,58-%18,27-%15,89 olarak Çizelge 6.6'da verilmiştir. 25.08.2021 günü için 2., 3. ve 4. Dereceden polinom regresyonu için elde edilen MAPE değerleri ise sırasıyla %16,40-%16,27-%13,76 olarak Çizelge 6.7'da gösterilmiştir. Her iki gün için MAPE değerlerinin aritmetik ortalaması sırasıyla %17,49-%17,27-%14,825 olarak elde edilir. Polinom regresyonu ile tek seferde yapılan tahminde elde edilen MAPE değerleri (2., 3. ve 4. derece sıralamasına göre) %14,58-%16,78-%18,23 olarak verilmişti (Çizelge 6.2.). Hem aritmetik ortalaması alınan MAPE değerleri hem de Çizelge 6.2.'de gösterilen MAPE değerleri her birindeki en küçük MAPE değerleri bakımından kıyaslandığında %14,58 ile tek seferde yapılan polinom regresyonunun %14,58 MAPE değeri ile daha iyi sonuç verdiği tespit edilmiştir.

Adım adım yapılan SVR çalışmasında 24.08.2021 günü için %10,93 ve 25.08.2021 günü içinse %9,75 oranında en iyi MAPE değerleri elde edilmiştir. Bu iki gün için ortalama MAPE %10,34 olarak tespit edilmiştir. Bu çalışma özelinde elde edilen en başarılı sonuç ortalama %10,34 MAPE değeriyle adım adım yapılan SVR tahmini olmuştur. Hem adım adım (Ortalama %10,34) yapılan hem de tek adımda (%12,68) yapılan tahmin çalışmasında en başarılı tahmin destek vektör regresyonundan elde edilmiştir.

Veri setinin büyüklüğüne bağlı olarak Çizelge 6.2.-6.4.-6.6.-6.7.-6.9.-6.10'daki ortalama mutlak hata (MAPE) değerleri tahmin çalışmasından elde edilmiştir. Sonuç olarak bu tahmin çalışmasında adım adım yapılan destek vektör regresyonu ile ortalama %10,34 MAPE oranıyla en iyi yöntem olarak güneş enerjisinden elde edilecek elektrik enerjisinin tahmin edilmesi çalışması için önerilmektedir. Daha geniş veri setiyle daha küçük MAPE elde edilebilirdi. Eldeki verinin 1 yılla sınırlı olması nedeniyle bu veri seti üzerine polinom regresyon ve destek vektör regresyon tatbik edilmiştir. Örneğin 5 yıl kadar geniş bir veri seti olsaydı derin öğrenme algoritmaları (Örneğin yapay sinir ağları) bu veri seti üzerine uygulanırdı. Bu durumda elde edilecek MAPE değeri %10,34'ün altında olabilirdi. Daha

fazla satırdaki veri seti ve kullanılan derin öğrenme yöntemleri elbette elde edilen hatayı (MAPE) asgariye çekecektir.

Yapılan çalışmada ölçme ya da test sadece gerçekleşen verilerle ve MAPE yoluyla yapılmıştır. Buna göre elde edilen MAPE değerleri Çizelge 6.1.- Çizelge 6.10.'da verilmiştir. Ayrıca fit etme (Uygun olma) ise R2 yöntemiyle test edilmiştir.

Gerçekleştirilmiş olan bu çalışma kök çalışma olarak başka güneş enerjisi santrallerinde yapılacak durum çalışmaları (Case study) için de kullanılabilecektir. Veri seti daha geniş olan güneş enerjisi santralleri için daha az hata ile daha fazla günün tahmin edilmesi imkânı ortaya çıkacaktır. İlerleyen yıllarda bu santrale ait veri seti genişledikçe MAPE azalacak bununla birlikte tahmin edilen gün sayısı artacaktır.

KAYNAKLAR

1. Sobri, S., Koohi-Kamali, S. , Abd.Rahim, N. (2018). Solar photovoltaic generation forecasting methods: A Review. *Energy Conversion and Management*, 156, 459–497.

2. Raza, M. K., Nadarajah, , M., Ekanayake, C. (2016). On recent advances in PV output power forecast. *Solar Energy*,136, 125-144.

3. Şahan, M. ve Okur, Y. (2016). Akdeniz bölgesine ait meteorolojik veriler kullanılarak yapay sinir ağları yardımıyla güneş enerjisinin tahmini. *Süleyman Demirel University Faculty of Arts and Sciences Journal of Science*, 11(1), 61-71.

4. İnternet: Osmaniye GES 1,18 MWp arazi tipi güneş enerjisi santrali. (2020). Web: https://arcenerji.com.tr/referanslarimiz Son Erişim Tarihi: 16.01.2022

5. İnternet: Enerji Piyasalar İşletme A.Ş.. Şeffaflık Platformu. (2022). Web: https://seffaflik.epias.com.tr/transparency/uretim/gerceklesen-uretim/gercek-zamanli-uretim.xhtml, Son Erişim Tarihi: 16.01.2022

6. Voyant, C., Notton, G., Kalogirou, S., Nivet, M. L., Paoli, C. (2017). Machine learning methods for solar radiation forecasting: a review, *Renewable Energy*, 105, 569-582.

7. Li, J.,Ward, J. K., Tong, J., Collins, L., Platt, G. (2016). Machine learning for solar irradiance forecasting of photovoltaic system. *Renewable Energy*, 90, 542–553.

8. Das, U. K., Tey, K. S., Seyedmahmoudian, M., Idris, M. Y. I., Mekhilef, S., Horan, B., Stojcevski, A. (2017). SVR-based model to forecast pv power generation under different weather conditions. *Energies*, 10(7), 876, 1-17.

9. Theocharides, S., Makrides, G., Georghiou, G. E., Kyprianou, A. (2018). *Machine learning algorithms for photovoltaic system power output prediction*. IEEE International Energy Conference (ENERGYCON), Limassol, 1-6.

10. Gala, Y., Fernandez, A., Díaz, J., Dorronsoro, J. R. (2016). Hybrid machine learning forecasting of solar radiation values. *Neurocomputing*, 176, 48-59.

11. Assouline, D., Mohajeri, N., Scartezzini, J. L. (2017). Quantifying rooftop photovoltaic solar energy potential: a machine learning approach. *Solar energy*, 141, 278-296.

12. Teo, T. T., Logenthiran, T., Woo, W. L. (2015). Forecasting of photovoltaic power using extreme learning machine. *IEEE Innovative Smart Grid Technologies - Asia (ISGT ASIA)*, 1-6.

13. Ahmed, R., Sreeram, V., Mishra, Y., Arif, M. D. (2020). A review and evaluation of the state-of-the-art in pv solar power forecasting: techniques and optimization. *Renewable and Sustainable Energy Reviews*, 124, 1-2.

14. Akhter, M. N., Saad, M., Hazlie, M., Noraisyah, M. S. (2019). Review on forecasting of photovoltaic power generation based on machine learning and metaheuristic techniques. *IET Renewable Power Generation*, 13(7), 1009-1023.

15. Kim, S., Jung, J., Sim, M. A. (2019). A swo-step approach to solar power generation prediction based on weather data using machine learning. *Sustainability*, 11(5), 1-16.

16. Demolli, H., Dokuz, A. Ş., Gökçek, M., Ecemiş, A. (2019). *Makine öğrenmesi algoritmalarıyla güneş enerjisi tahmini: Niğde ili örneği*. International Turkic World Congress on Science and Engineering Konferansı, Niğde, 775- 783.

17. Gök, A., O., Yıldız, C., Şekkeli, M. (2019). Yapay sinir ağları kullanarak kısa dönem güneş enerjisi santrali üretim tahmini: Kahramanmaraş örnek çalışması. *Uluslararası Doğu Anadolu Fen Mühendislik ve Tasarım Dergisi*, 1(2), 186-195.

18. Wolff, B., Kühnert, J., Lorenz, E., Kramer, O., Heinemann, D. (2016). Comparing support vector regression for PV power forecasting to a physical modeling approach using measurement, numerical weather prediction, and cloud motion data, *Solar Energy*, 135, 197-208.

19. Yıldız, C. ve Açıkgöz, H. (2021). A kernel extreme learning machine-based neural network to forecast very shortterm power output of an on-grid photovoltaic power plant. *Energy Sources Part A: Recovery, Utilization and Environmental Effects*, 43(4), 395–412.

20. Goodale, C. D., Aber, J. D., Ollinger, S. V. (1998). Mapping monthly precipitation, temperature, and solar radiation for Ireland with polynomial regression and a digital elevation model. *Climate Research*, 10, 35-49.

21. George, J., Janaki, L., Gomathy, J. P. (2016). Statistical downscaling using local polynomial regression for rainfall predictions – a case study. *Water Resour Management: An International Journal, Published for the European Water Resources Association (EWRA)*, 30(1), 183-193.

22. Alpaydin, E. (2014). *Introduction to machine learning*. (3.rd Edition). London: The MIT Press, 1-4.

23. Filiz, E. (2019). *Makine öğrenmesi yöntemleri ve eğitim verisi üzerine bir uygulama: uluslararası matematik ve fen eğilimleri araştırması 2015 Türkiye örneği*. Yayımlanmış Doktora Tezi, Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul.

24. Görmez, B. (2021). *Adli bilişimde makine öğrenmesi: makine öğrenmesi algoritmaları ile terör olaylarının tahmin edilmesi çalışması.* Yayımlanmış Yüksek Lisans Tezi, Ankara Üniversitesi Sağlık Bilimleri Enstitüsü, Ankara, 24-26.

25. Geron, A. (2019). *Hands on Machine Learning with Scikit-Learnn, Keras & Tensorflow*. (2.nd Edition). Sebastopol: O'Reilly Media Inc, 132-161.

26. Wu, Y. C., Chen, M. J., Huang, S. H., Tsai, M. T., Li, C. H. (2013). Maximum power point tracking on stand-alone solar power system: three-point-weighting method ıncorporating mid-point tracking. *Electrical Power and Energy System*, 52, 14-24.

27. İnternet: The Ohio State University. photovoltaic systems for solar electricity production. (2011). Web: https://ohioline.osu.edu/factsheet/AEX-652-11, Son Erişim Tarihi: 26.01.2022.

28. İnternet: Kırcıoğlu, O., Yıldız, A. B. (Eylül 2011). Fotovoltaik panelin tek diyotlu eşdeğer devresine ait büyük sinyal analizi, Kocaeli Üniversitesi, Web: https://www.emo.org.tr/ekler/4a7cb508ff0809f_ek.pdf, Son Erişim Tarihi:26.01.2022

29. İnternet: Tek, C. S. ve Yıldırım, D. (Haziran 2008). Güneş paneli simülatörü, elektrik mühendisleri odası İstanbul şubesi IV. Proje Yarışması, Web: https://www.emo.org.tr/ekler/613ca9ece1fec54_ek.pdf, Son Erişim Tarihi: 27.01.2022

30. İnternet: Güneş enerji santrali yapımı. (2019). Web: http://www.osmaniyeozelidare.gov.tr/gunes-enerji-santrali-yapimi, Son Erişim Tarihi: 02.02.2022

31. İnternet: Osmaniye İl Özel İdaresi güneş enerjisi santrali ihale dokümanı (KİK No: 2019/505775). (2020). Web: https://ekap.kik.gov.tr/EKAP/Ortak/IhaleArama/index.html, Son Erişim Tarihi: 02.01.2022

32. İnternet: Osmaniye İl Özel idaresi güneş enerjisi santrali uydu görüntüsü. (2020). Web:https://earth.google.com/web/search/37.129621,+36.213784/@37.129621,36.213784,114.46698414a,821.87932287d,35y,0h,45t,0r/data=ClgaLhIoGfrvwWuXkEJAITs0LEZdG0JAKhQzNy4xMjk2MjEsIDM2LjIxMzc4NBgCIAEiJgokCV4ICg07_zNAEV0ICg07_zPAGVxBkRXW5T9AIXeRVelBX1HAKAI, Son Erişim Tarihi: 23.03.2022.

33. İnternet: Meteorolojik verilerin alınması. (2010). Web: https://solcast.com/solar-data-api/ , Son Erişim Tarihi: 23.03.2022

34. Karamanlı, E. (2019). *Makine öğrenmesi algoritmaları kullanarak, metin madenciliği ve duygu analizi ile müşteri deneyiminin geliştirilmesi*. Yayımlanmış Yüksek Lisans Tezi, İstanbul Üniversitesi Sosyal Bilimler Enstitüsü, İstanbul, 6-7.

35. Bastem, N. H. (2021). *Student academic performance prediction via artificial ıntelligence using machine learning algorithms*. Yayımlanmış Yüksek Lisans Tezi, Çankaya Üniversitesi, Fen Bilimleri Enstitüsü, 9-13.

36. Müller, A. and Guido, S. (2016). *Introduction to machine learning with python: a guide for data scientists*. (1.st ed.). Sebastopol: O'Reilly Media, 1-6.

37. Camastra, F. and Vinciarelli, A. (2015*). Machine learning for audio, image and video analysis: theory and applications*. (2.nd ed.). London: Springer, 4.

38. Mohri, M., Rostamizadehi, A., Talwalkar, A. (2018). *Foundations of machine learning*. (2.nd ed.). United States: MIT Press, 7-8.

39. Serbest, K. ve Kılıç, S., K. (2021). *Diz eklemi momentinin tahmini için makine öğrenmesi yöntemlerinin incelenmesi*. 9.th International Symposium on Innovative Technologies in Engineering and Science, Sakarya, 344-345.

40. Freedman, D. A. (2009). *Statistical Models: Theory and Practice, University of California* . (2. nd ed.). Newyork: Cambridge University Press, 424.

41. Alpar, R. (2017). *Uygulamalı Çok Değişkenli İstatistiksel Yöntemler*. (5.th Edition). Ankara: Detay Press, 840.

42. Fan, J., Gijbels, I. (1996). *Local Polynomial Modelling and Its Applications,* Newyork: CRC Press, 336.

43. Rawlings, J. O., Pantula, S. G., Dickey, D. A. (1998). *Applied Regression Analysis: A Research Tool.* (2.nd ed.), Newyork: Springer Science & Business Media, 657.

44. Aggrey, S. (2002). Comparison of three nonlinear and spline regression models for describing chicken growth curves, *Poultry Science Association*, 81(12), 1782-1788.

45. Lee, B. C. and Brooks, D.M. (2006). Regression modeling strategies for microarchitectural performance and power prediction, *Harvard Computer Science Group Technical Report*. Massachusetts 6-7.

46. Draper, N. R., and Smith, H. (2014). *Applied Regression Analysis.* (3.rd ed.). New York: John Wiley&Sons, 20-29.

47. Varol, B. (2017). *Parçalı regresyon ile polinom regresyon analizlerinin karşılaştırılması.* Yayımlanmış Yüksek Lisans Tezi, Adnan Menderes Üniversitesi, Sağlık Bilimleri Enstitüsü, Aydın.

48. Li, Q., Meng, Q., Cai, J., Yoshino, H., Mochida, A. (2009). Applying support vector machine to predict hourly cooling load in the building. *Applied. Energy*, 86(10), 2249-2256.

49. Dong, B., Cao, C., Lee, S. E. (2005). Applying support vector machines to predict building energy consumption in tropical region. *Energy and Buildings*, 37(5), 545-553.

50. Yazıcı, K. (2021). *Makine Öğrenmesi Yöntemleri Kullanılarak Kısa Dönem Rüzgâr Gücü Tahmini*. Yayımlanmış Yüksek Lisans Tezi, Sakarya Üniversitesi, Fen Bilimleri Enstitüsü, Sakarya.

51. Ito K. ve Nakano R. (2003). *Optimizing support vector regression hyperparameters based on cross-validation*. Proceedings of the International Joint Conference on Neural Networks, Newyork, 5-7.

52. Aslay, F. ve Özen, U. (2013). Estimating soil temperature with artificial neural networks using meteorological parameters. *Journal of Polytechnic*, 16(4) 139-145.

53. Lupón, J., Gaggin, H. K., Antonio, M., Domingo, M., Galán, A., Zamora, E., Vila, J., Peñafiel, J., Urrutia, A., Ferrer, E., Vallejo, N., Januzzi, J. L., Bayes-Genis, A. (2015). Biomarker-assist score for reverse remodeling prediction in heart failure: The ST2-R2 score. *Int. J. Cardiol.*, 184, 337–343.

54. Han, J.-H. and Chi, S.-Y. (2016). *Consideration of manufacturing data to apply machine learning methods for predictive manufacturing*. The 8.th Internatioanl Conference Ubiquitous and Future Networks (ICUFN 2016), Vienna, 1-5.

55. Rustam, F. Reshi, A. A., Mehmood, A. Ullah, S., On, B-W., Aslam, W., Chio, A. G. S. (2020) COVID-19 Future forecasting using supervised machine learning models, *IEEE Access*, 8, 101489 – 101499.



GAZİ GELECEKTİR…