



**T.C.
AMASYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**GÜNEŞ PANELİ ENERJİ ÜRETİM TAHMİNİNİN MAKİNE
ÖĞRENMESİ YÖNTEMLERİ İLE KARŞILAŞTIRILMASI**

YÜKSEK LİSANS TEZİ

HAVVA AYYILDIZ KOÇ

TEMMUZ

**GÜNEŞ PANELİ ENERJİ ÜRETİM TAHMİNİNİN MAKİNE ÖĞRENMESİ
YÖNTEMLERİ İLE KARŞILAŞTIRILMASI**

HAVVA AYYILDIZ KOÇ

**YÜKSEK LİSANS TEZİ
YENİLENEBİLİR ENERJİ VE UYGULAMALARI ANABİLİM DALI**

**Danışman
Dr. Öğr. Üyesi Yavuz ÜNAL**

**AMASYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

TEMMUZ 2022

Yüksek Lisans Tezi Kabul ve Onay Sayfası

Havva AYYILDIZ KOÇ tarafından hazırlanan “Güneş Paneli Enerji Üretim Tahmininin Makine Öğrenmesi Yöntemleri ile Karşılaştırılması” adlı tez çalışması aşağıdaki jüri tarafından OY BİRLİĞİ/OY ÇOKLUĞU ile Amasya Üniversitesi Fen Bilimleri Enstitüsü Yenilenebilir Enerji ve Uygulamaları Anabilim Dalında YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Danışman : Dr. Öğr. Üyesi Yavuz ÜNAL

Bilgisayar Yazılımı Anabilim Dalı, Amasya Üniversitesi

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum/onaylamıyorum

Başkan : Doç. Dr. Turgut ÖZSEVEN

Bilgisayar Bilimleri Anabilim Dalı, Tokat Gaziosmanpaşa Üniversitesi

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum/onaylamıyorum

Üye : Doç. Dr. Ünal KURT

Elektrik Makineleri Anabilim Dalı, Amasya Üniversitesi

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum/onaylamıyorum

Tez Savunma Tarihi: 22/07/2022

Jüri tarafından kabul edilen bu tezin Yüksek Lisans Tezi olması için gerekli şartları yerine getirdiğini onaylıyorum.

.....

Doç. Dr. Ümit YILDIRIM

Fen Bilimleri Enstitüsü Müdürü

ETİK BEYAN

Amasya Üniversitesi Fen Bilimleri Enstitüsü Tez Yazım Kurallarına uygun olarak hazırladığım bu tez çalışmada:

- 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 çalışmada 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.

(İmza)

Havva AYYILDIZ KOÇ

22/07/2022

GÜNEŞ PANELİ ENERJİ ÜRETİM TAHMİNİNİN MAKİNE ÖĞRENMESİ YÖNTEMLERİ İLE KARŞILAŞTIRILMASI

(Yüksek Lisans Tezi)

HAVVA AYYILDIZ KOÇ

AMASYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Temmuz 2022

ÖZET

Ülkeler elektrik enerjisi ihtiyacının yükselmesi nedeniyle ucuz ve güvenilir yenilenebilir enerji üretimine yönelmiştir. Son yıllara bakıldığında yenilebilir enerji kaynakları içerisinde fotovoltaik (FV) enerji sistemleri ön plana çıkmaktadır. Üretilen güneş enerjisinin makine öğrenmesi yöntemleri ile tahmininde güneş radyasyonu, basınç, sıcaklık gibi meteorolojik veriler etkili faktörlerdir. Bu faktörler de hava şartlarına göre değişkenlik gösterdiğinden, güneş enerjisi santrallerinde geleceğe dair üretilebilecek enerji miktarını tahmin etmek zordur. Güneş panellerinin kurulumu yapılmadan önce ışıyım şiddetine göre ortaya çıkacak elektrik enerji potansiyelinin hesaplanması için farklı yöntemler geliştirilmiştir. Bu yöntemlerden birisi de son zamanlarda yaygınlaşan makine öğrenme algoritmalarının kullanılarak model oluşturulması ve sonuçların değerlendirilmesidir. Bu tez çalışmasında; Amasya Üniversitesi İpekköy yerleşkesindeki güneş panellerinden saatlik üretilen enerjinin, makine öğrenmesi modelleri kullanılarak tahmin yapılmaya çalışılmıştır. Meteorolojik faktörlerin enerji üretimindeki etkileri analiz edilmiştir. Değerlendirmeler için Python programlama dilinin kütüphaneleri kullanılarak makine öğrenmesi gerçekleştirilmiştir. Yapılan çalışmada, veri seti olarak 2016 yılı Amasya bölgesine ait sıcaklık, güneş radyasyonu, azimut açısı ve üretilen enerji verileri kullanılmıştır. Çalışmadaki verilerin %80'i eğitim veri seti için, %20'si ise test verisi için kullanılmıştır. Veri eğitimi için makine öğrenmesi algoritmalarından Lojistik Regresyon, AdaBoost, Naive Bayes, K-En Yakın Komşu, Rastgele Orman, Destek Vektör Regresyonu ve Yapay sinir ağları algoritmaları kullanılmıştır. Sonuç olarak elde edilen veriler kullanılarak güneş enerjisi potansiyeli başarılı bir şekilde tahmin edilmiştir.

Sayfa Adedi : 75
Anahtar Kelimeler : Makine öğrenmesi, Güneş enerji tahmini, Yenilenebilir enerji
Danışman : Dr. Öğr. Üyesi Yavuz ÜNAL

COMPARISON OF SOLAR PANEL ENERGY PRODUCTION FORECAST WITH MACHINE LEARNING METHODS

(M. Sc. Thesis)

HAVVA AYYILDIZ KOÇ

AMASYA UNIVERSITY

GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCES

July 2022

ABSTRACT

Countries have turned to cheap and reliable renewable energy production due to the increase in electricity energy needs. Photovoltaic (PV) energy systems have been a prevalent one among these energy resources in recent years. In the estimation of generated solar energy using machine learning methods, meteorological data like solar radiation, pressure, and temperature are influential elements. The future generation of energy in solar power plants can be quite difficult to predict since these elements vary depending on weather conditions. Methods have been developed to calculate potential electricity generation from radiation energy before the installation of plants. One of these methods is to create a model and obtain simulation results by using machine learning algorithms that have become widespread recently. In this thesis study; It was aimed to predict the hourly electric power generation in the photovoltaic panels in Amasya University, Ipekkoy campus, using machine learning models. The effects of meteorological factors on energy production were analyzed. Machine learning was carried out using the libraries of the python programming language for the evaluations. In the study, temperature, solar radiation, azimuth angle and produced energy data of 2016 Amasya region were used as data set. 80% of the data in the study were used for the learning dataset, while 20% were used for testing data. For data learning, machine learning algorithms of Linear Regression models, Support Vector Regression, AdaBoost Regressor, K-Nearest Neighbors, Random Forest, Naive Bayes, and Artificial Neural Network were used. As a result, the solar energy potential was successfully estimated using the obtained data.

Page Number : 75
Keywords : Machine learning, Solar energy prediction, Renewable energy
Supervisor : Asst. Prof. Dr. Yavuz ÜNAL

ÖN SÖZ ve TEŞEKKÜR

Yüksek lisans eğitimimden itibaren desteğini esirgemeyen, akademik çalışmalar ve tez yazım sürecinde beni sürekli yönlendiren ve motive eden Dr. Öğr. Üyesi Yavuz ÜNAL'a teşekkür ederim.



İÇİNDEKİLER

	Sayfa
ÖZET	iv
ABSTRACT.....	v
ÖN SÖZ ve TEŞEKKÜR.....	vi
İÇİNDEKİLER	vii
ÇİZELGELER DİZİNİ	x
ŞEKİLLER DİZİNİ	xi
SİMGELER VE KISALTMALAR DİZİNİ	xiv
1. GİRİŞ.....	1
1.1. Literatür Taraması	2
2. YENİLENEBİLİR ENERJİ.....	5
2.1. Yenilenebilir Enerji Tanımı	5
2.2. Dünya da Yenilenebilir Enerji.....	5
2.3. Türkiye’de Yenilenebilir Enerji	7
2.4. Yenilenebilir Enerji Çeşitleri	10
2.4.1. Güneş enerjisi.....	10
2.4.2. Rüzgâr enerjisi	12
2.4.3. Jeotermal enerjisi	14
2.4.4. Biyokütle enerjisi	15
2.4.5. Hidroelektrik enerjisi	17
2.4.6. Hidrojen enerjisi.....	18
2.4.7. Dalga enerjisi	19
2.5. Güneş Enerjisi	20
2.5.1 Güneş hareketi	21

	Sayfa
2.5.2 Güneş açıları	22
2.5.3 Fotovoltaik sistem.....	22
2.5.4 Fotovoltaik sistem tipleri	24
2.5.5 Fotovoltaik hücre tipleri.....	27
2.5.6 Kristal silikon güneş hücreleri	28
3. MATERYAL VE YÖNTEM.....	32
3.1. Veri Toplama Süreci	32
3.2. Verilerin Normalizasyonu	33
3.3. Öznitelik Seçimi.....	34
3.4. Veri Analizi	36
3.5. Araştırma Modelinin Oluşturulması	38
3.6. Makine Öğrenmesi Nedir?	39
3.7. Makine Öğrenmesi Süreci.....	40
3.7.1. Veri seçimi	41
3.7.2. Veri temizleme.....	41
3.7.3. Veri dönüştürme.....	42
3.7.4. Model tahmini.....	43
3.7.5. Sonuç ve değerlendirme.....	43
3.8. Makine Öğrenmesi Algoritma Türleri.....	43
3.8.1. Denetimli makine öğrenmesi	43
3.8.2. Yarı denetimli makine öğrenmesi.....	44
3.8.3. Denetimsiz makine öğrenmesi.....	45
3.8.4. Takviyeli makine öğrenmesi.....	46
3.9. Makine Öğrenmesi Algoritmaları	46

	Sayfa
3.9.1. Destek vektör makinesi (DVM).....	46
3.9.2. Rastgele orman (RF)	47
3.9.3. Yapay sinir ağları (YSA)	48
3.9.4. Naive bayes (NB).....	49
3.9.5. K-en yakın komşu (KNN).....	50
3.9.6. Lojistik regresyon (LR).....	51
3.9.7. Adaboost (AB).....	52
3.10. Değerlendirme Ölçütleri.....	52
3.10.1. Kök ortalama kare hata (RMSE).....	53
3.10.2. Ortalama mutlak hata (MAE).....	53
3.10.3. Regresyon katsayısı (R^2)	53
4. BULGULAR	55
4.1. Lojistik Regresyon Algoritması ile Başarı Değerleri.....	55
4.2. Rastgele Orman Algoritması ile Başarı Değerleri.....	56
4.3. Destek Vektör Makineleri Algoritması ile Başarı Değerleri.....	58
4.4. K-en Yakın Komşu Algoritması ile Başarı Değerleri	59
4.5. Yapay Sinir Ağları Algoritması ile Başarı Değerleri	60
4.6. Naive Bayes Algoritması ile Başarı Değerleri	62
4.7. Adaboost Algoritması ile Başarı Değerleri	63
4.8. Oluşturulan Modellerin Karşılaştırılması.....	65
5. SONUÇ VE ÖNERİLER.....	67
KAYNAKLAR	69
ÖZGEÇMİŞ	74

ÇİZELGELER DİZİNİ

Çizelge	Sayfa
Çizelge 2.1. Dünya birincil enerji talebi (MTEP).....	6
Çizelge 2.2. Yenilenebilir enerji kurulu güç artış oranı (MW).....	9
Çizelge 3.1. Bir günlük radyasyon, sıcaklık ve enerji verileri.....	32
Çizelge 3.2. Veri setinde kullanılan öznitelikler.....	33
Çizelge 3.3. Min Max normalizasyon yöntemiyle normalize edilmiş örnek veri.....	34
Çizelge 3.4. Veri setindeki özniteliklerin üretilen enerjiye etkisi.....	34
Çizelge 4.1. Tüm öznitelikler için lojistik regresyon algoritması sonuçları	55
Çizelge 4.2. Öznitelik azaltıldığında lojistik regresyon algoritması sonuçları	55
Çizelge 4.3. Tüm öznitelikler için rastgele orman algoritması sonuçları	56
Çizelge 4.4. Öznitelik azaltıldığında rastgele orman algoritması sonuçları	57
Çizelge 4.5. Tüm öznitelikler için destek vektör makineleri algoritması sonuçları	58
Çizelge 4.6. Öznitelik azaltıldığında destek vektör makineleri algoritması sonuçları ...	58
Çizelge 4.7. Tüm öznitelikler için k-en yakın komşu algoritması sonuçları	59
Çizelge 4.8. Öznitelik azaltıldığında k-en yakın komşu algoritması sonuçları	60
Çizelge 4.9. Tüm öznitelikler için yapay sinir ağları algoritması sonuçları	61
Çizelge 4.10. Öznitelik azaltıldığında yapay sinir ağları algoritması sonuçları	61
Çizelge 4.11. Tüm öznitelikler için naive bayes algoritması sonuçları	62
Çizelge 4.12. Öznitelik azaltıldığında naive bayes algoritması sonuçları	63
Çizelge 4.13. Tüm öznitelikler için adaboost algoritması sonuçları.....	64
Çizelge 4.14. Öznitelik azaltıldığında adaboost algoritması sonuçları.....	64
Çizelge 4.15. Tüm öznitelikler kullanılarak oluşturulan modellerin karşılaştırılması....	65
Çizelge 4.16. Öznitelikler azaltılarak oluşturulan modellerin karşılaştırılması.....	66

ŞEKİLLER DİZİNİ

Şekil	Sayfa
Şekil 2.1. Yenilenebilir enerji ve fosil yakıtlardan 10 yıllık mali getiri	7
Şekil 2.2. Yıllar itibari ile birincil kaynak bazında brüt elektrik üretimi.....	8
Şekil 2.3. 2021 yılı birincil kaynak türünde brüt elektrik üretimi (GWh)	8
Şekil 2.4. Dünya güneş enerjisi 2010-2020 yılları güç kapasite gelişimi.....	11
Şekil 2.5. Türkiye güneş enerjisi 2010-2020 yılları güç kapasite gelişimi.....	11
Şekil 2.6. Türkiye güneş enerjisi potansiyeli atlası.....	12
Şekil 2.7. Dünya rüzgâr enerjisi santralleri 2010-2020 yılları kapasite gelişimi.....	13
Şekil 2.8. Türkiye rüzgâr enerjisi santralleri 2010-2020 yılları kapasite gelişimi.....	13
Şekil 2.9. Dünya jeotermal enerji santralleri 2010-2019 yılları elektrik üretimi.....	14
Şekil 2.10. Türkiye jeotermal enerji santralleri 2010-2019 yılları elektrik üretimi.....	15
Şekil 2.11. Dünya biyokütle enerji santralleri 2010-2019 yılları elektrik üretimi.....	16
Şekil 2.12. Türkiye biyokütle enerji santralleri 2010-2019 yılları elektrik üretimi.....	17
Şekil 2.13. Dünya hidroelektrik enerji santralleri 2010-2019 yılları elektrik üretimi	18
Şekil 2.14. Türkiye hidroelektrik enerji santralleri 2010-2019 yılları elektrik üretimi ..	18
Şekil 2.15. Dünya geneli hidrojen projeleri	19
Şekil 2.16. 2010-2017 yılları ülkelere göre toplam dalga enerjisi patent sayıları	20
Şekil 2.17. Güney yarım kürede güneşin izlediği yol.....	21
Şekil 2.18. Gün içerisindeki güneş açısının güneş panelinin verimine etkisi.....	22
Şekil 2.19. Güneş hücresinin eşdeğer devresi.....	23
Şekil 2.20. FV hücre, modül ve dizi	24
Şekil 2.21. Fotovoltaik sistem çeşitleri	24
Şekil 2.22. Şebekeden bağımsız güneş enerji sistemi.....	25
Şekil 2.23. Şebekeye bağlı güneş enerji sistemi	26

Şekil	Sayfa
Şekil 2.24. Hibrit bağlantılı enerji sistemi	27
Şekil 2.25. Güneş pilinin yapısı	28
Şekil 2.26 Monokristal ve polikristal güneş paneli.....	29
Şekil 2.27. Monokristal güneş paneli.....	29
Şekil 2.28. İnce film güneş hücreleri	31
Şekil 3.1. Veri setindeki özneliliklerin korelasyonu.....	36
Şekil 3.2. Radyasyon ile üretilen enerji arasındaki korelasyon	37
Şekil 3.3. Azimut açısı ile üretilen enerji arasındaki korelasyon.....	37
Şekil 3.4. Sıcaklık ile üretilen enerji arasındaki korelasyon.....	38
Şekil 3.5. Makine öğrenmesi ve disiplinler	39
Şekil 3.6. Makine öğrenmesi süreci	41
Şekil 3.7. Denetimli makine öğrenmesi süreci	44
Şekil 3.8. Yarı denetimli makine öğrenmesi süreci	45
Şekil 3.9. Denetimsiz makine öğrenmesi süreci	45
Şekil 3.10. Takviyeli makine öğrenmesi süreci	46
Şekil 3.11. Destek vektörü ve hiper düzlem	47
Şekil 3.12. Rastgele orman algoritması	48
Şekil 3.13. Yapay sinir ağı modeli.....	49
Şekil 3.14. KNN sınıflandırması.....	51
Şekil 3.15. Adaboost sınıflandırması	52
Şekil 4.1. Lojistik regresyon algoritması saatlik enerji tahmin dağılım grafiği.....	56
Şekil 4.2. Rastgele Orman algoritması saatlik enerji tahmin dağılım grafiği.....	57
Şekil 4.3. Destek vektör makinesi algoritması saatlik enerji tahmin dağılım grafiği	59
Şekil 4.4. K-en yakın komşu algoritması saatlik enerji tahmin dağılım grafiği	60

Şekil	Sayfa
Şekil 4.5. Yapay sinir ağları algoritması saatlik enerji tahmin dağılım grafiği	62
Şekil 4.6. Naive Bayes algoritması saatlik enerji tahmin dağılım grafiği	63
Şekil 4.7. Adaboost modeli algoritması saatlik enerji tahmin dağılım grafiği	65



SİMGELER VE KISALTMALAR DİZİNİ

Bu çalışmada kullanılmış bazı simgeler ve kısaltmalar, yanda açıklamaları verilmek üzere aşağıda listelenmiştir

Simgeler

Açıklama

kw	Kilowatt
mw	Megawatt
tw	Terawatt
gw	Gigawatt
h	Saat

Kısaltmalar

Açıklama

YES	Yenilenebilir enerji sistemleri
OECD	Ekonomik kalkınma ve iş birliği örgütü
MTEP	Milyon ton eşdeğer petrol
ETKB	Enerji ve tabii kaynaklar bakanlığı
TSKB	Türkiye sınai kalkınma bankası
HES	Hidroelektrik santrali
GES	Güneş enerjisi santrali
BES	Biyokütle enerji santrali
RES	Rüzgar enerji santrali
JES	Jeotermal enerji santrali
FV	Fotovoltaik
GEPA	Türkiye güneş enerjisi potansiyeli atlası
CSP	Konsantre güneş enerjisi

DVM	Destek vektör makinesi
KNN	K-en yakın komşu
RF	Rastgele orman
YSA	Yapay sinir ağı
NB	Naive bayes
LR	Lojistik regresyon
MLP	Çok katmanlı algılayıcı
ÖYS	Öğrenme yönetim sistemi
KA	Karar ağacı
ABD	Amerika Birleşik Devletleri
AKT	Artıkların kareler toplamı
TKT	Toplam kareler toplamı
RMSE	Kök ortalama kare hata
MAE	Ortalama mutlak hata

1. GİRİŞ

Enerji, ülkelerin ekonomik ve küresel alanda ilerlemeleri için, büyüme ve gelişme stratejilerinde göz önüne almaları gereken önemli bir etkidir. Dünya'daki enerji talebine mevcut fosil enerji kaynaklarının yetmemesi, ülkelerin enerjiye verdikleri önemi arttırmıştır. Günümüzde, birçok ülke ekonomik büyümeyi desteklemek amacıyla enerji politikalarını geliştirmekte ve ileriye dönük yatırımlar yaparak gelişmeleri yakından takip etmektedirler (Zamfir, Colesca ve Corbos, 2016).

Ülkeler nüfus artışları doğrultusunda enerjiye olan ihtiyaçları sürekli artmaktadır. Enerjiye olan ihtiyacın fazlalaşması sebebiyle enerji arzıyla alakalı endişelerin artması ve iklimsel değişiklikler üzerine alınan kararlar; dünyadaki tüm ülkeler gibi ülkemizde de yenilenebilir enerji kaynaklarına ilginin artmasına neden olmuştur (Yurdadoğ ve Tosunoğlu, 2017).

Yenilenebilir enerjiye olan bu ilgi, güneş enerji sistemlerinin (GES) son yıllarda önemli ölçüde artmasını sağlamıştır (Shi, Lee, Liu, Yang ve Wang, 2012). Özellikle güneş enerjisi, fosil yakıtlara alternatif olarak yenilenebilir enerji kaynaklarından en talep görenlerden birisidir (Koca, Öztıp, Varol ve Koca, 2011). Fosil enerji kaynakları ile kıyaslandığında; çevreyi kirletmemesi, ekonomik olması ve tükenme ihtimalinin olmaması sebebi ile son yıllar içerisinde önemli hale gelmiştir (Özbay, Parmaksız, Karafil ve Kesler, 2016).

Türkiye'de elektrik piyasası serbestleşmiştir. Yatırımcılar tarafından güneş enerji santralleri kurularak enerji üretebilir hale gelmiştir. Serbest hale gelen elektrik piyasasının, verimli şekilde devam edebilmesi için üretim ve tüketim dengesinin sağlanması ve üretim yapılacak elektrik enerjisinin daha öncesinden bilinmesi gerekmektedir. Günümüz şartlarında ürettiği enerjiyi satmak isteyen güneş enerji santralleri ileriki zaman dilimi içinde ne kadar enerji üreteceğini hesaplaması önem arz etmektedir. Bu sayede üreteceği enerji miktarını ilgili kuruma bildirmesi, elektrik piyasasının devamlılığı bakımından önemlidir. Yenilenebilir enerji kaynakları ile elektrik üreten tesislerde üretim miktarının belirsizliği büyük riskler oluşturmaktadır (Jamil, Zhao, Zhang, Rafique ve Jamil, 2019).

Makine öğrenmesi, işlenmemiş verileri farklı algoritmalar aracılığıyla analiz ederek, anlamlı ve kullanılabilir bilgiler oluşturma süreci olarak ifade edilebilir. Makine öğrenmesi farklı

özniteliklere sahip verileri işleyerek, öğrenme sağladığı veriler neticesinde sınıflandırma veya tahminlerde bulunur. Makine öğrenmesi büyük verilerin bulunduğu her alanda yoğunlukla kullanılmaktadır.

Teknolojik gelişmeler neticesinde enerji sektöründe de makine öğrenmesi kullanılarak üretim değerlerinin artırılması, meteorolojik faktörlerin enerji üretimindeki etkisi üzerine analizler yapılmaktadır. Güneş enerji santrallerinin meteorolojik etkenlere göre enerji üretim değerleri çok değiştiği için hava tahmin raporlarındaki veriler ışığında üretebileceği enerji miktarını makine öğrenmesi sayesinde rahatlıkla tahmin edebilmektedir.

Bu tez kapsamında makine öğrenmesi algoritmaları kullanılarak güneş panellerinin enerji üretimi ve enerji üretimini etkileyen meteorolojik faktörler incelenmiştir. Çalışma kapsamında 2016 yılına ait Amasya Üniversitesi İpekköy yerleşkesi Fen Edebiyat fakültesi çatısında bulunan güneş panellerine ait veriler, makine öğrenmesi algoritmaları kullanılarak sınıflandırılacak ve enerji üretim değerlerinin doğruluk değerleri mukayese edilecektir.

Bu tezin amacı Amasya Üniversitesi İpekköy yerleşkesi Fen Edebiyat fakültesindeki güneş panellerinin enerji üretimini makine öğrenmesi algoritmalarını kullanarak önceden tahmin etmek ve güneş panellerinden üretilen enerjiye etki eden meteorolojik faktörlerin tespit edilmesidir. Bu sayede güneş panellerinden enerji üretimi yaparak satış yapan santrallerin ileriki zaman dilimlerinde üretebileceği enerji miktarını doğru tahmin ederek satış yapacakları kurumlara daha doğru üretim değerleri verebilmeleri amaçlanmaktadır. Bu amaçla Amasya Üniversitesi Fen Edebiyat fakültesinde bulunan güneş panellerinin enerji üretim değerleri ve meteorolojik faktörlere ait veriler, makine öğrenmesi yöntemlerinden Lojistik Regresyon, AdaBoost, Naive Bayes, Rastgele Orman, K-En Yakın Komşu, Destek Vektör Regresyonu ve Yapay sinir ağları algoritmaları kullanılarak üretilecek enerji tahmin edilmeye çalışılmış ve hava koşullarının üretime olan etkileri tespit edilmiştir.

1.1. Literatür Taraması

Güneş enerjisi tahmini için literatürde makine öğrenmesi tekniklerinin kullanımı son yıllarda yaygınlaşmıştır. Farklı amaçlar için farklı makine öğrenmesi teknikleri kullanılmakta ve başarılı sonuçlar elde edilmektedir. Bu bölümde, makine öğrenmesi teknikleri kullanarak güneş enerjisi tahmini yapan çalışmalardan bir kısmı sunulmuştur.

Sharma, Irwin, Shenoy & Sharma (2011) çalışmalarında, ilk olarak yenilenebilir enerji kaynaklarının ve geleceğe dair güneş enerji üretim tahmininin önemi belirtilmektedir. Çalışmalarında, Amerika Birleşik Devletleri Ulusal Meteoroloji Dairesinden alınan veriler kullanılıp, DVM ve doğrusal regresyon performansları kıyaslanmaktadır. Sonuç olarak yedi farklı öznitelik kullanılarak oluşturulan DVM modelinin tahmin değerleri, mevcut algoritmalara göre %27 daha isabetli sonuç verdiği gösterilmektedir.

Shi, Lee, Liu, Yang ve Wang (2012) çalışmasında, güneş enerji panellerinden üretilen gücün hava şartlarına bağlı olduğu belirtilip, güneş enerji santrallerinden üretilen enerjinin tahmininin başarılı olması durumunda sistemin güvenilirliğinin artacağı belirtilmiştir. Çalışmada güneş panellerinden üretilen enerjinin tahmini için DVM kullanılıp; havanın açıklığı, bulutlu olması, sis durumu ve yağmur oranı öznitelik olarak verilmektedir. Sonuç olarak bir sonraki gün için üretilecek gücün tahmini başarılı bir şekilde gerçekleştiği, Çin’de bulunan bir güneş enerji santralinin istasyonunda uygulanarak ispatlanmaktadır.

Yousif, Kazem ve Chaichan (2016) çalışmalarında, güneş panellerinden üretilen enerji tahmini için DVM ve MLP kullanılmaktadır. Veri setinde bulunan güneş ışık şiddeti ve ortam sıcaklığı değerleri kullanılarak, FV akım değeri tahmin edilmeye çalışılmıştır. Sonuç olarak DVM ile 0,9844, MLP ile 0,9701 R^2 doğruluk değerlerine sahip modelin yapılan diğer çalışmalara oranla başarılı olduğu belirtilmektedir.

Hossain, Oo ve Ali (2012) çalışmalarında, makine öğrenmesi algoritmaları kullanarak güneş panellerinden 6 saat sonra üretilecek enerji miktarının tahminini yapmaktadırlar. On katmanlı çaprazlama yapılarak oluşturulan çalışmada en başarılı tahmini çok katmanlı algılayıcı modeli yaparken, destek vektör makinesi ve ÖYS’nin birbirine yakın performans gösterdiği tespit edilmektedir.

Wang, Zhen, Wang ve Mi (2018) çalışmalarında, sonraki gün için FV panellerden üretilen enerjinin tahmin edilmesi amaçlanmaktadır. Makine öğrenmesi algoritmalarında DVM ve KNN kullanılıp, performans kıyaslaması gerçekleştirilmektedir. Sonuç olarak, küçük ölçekli verilerde DVM daha başarılı iken yüksek ölçekte KNN’in daha başarılı sonuç verdiği ifade edilmektedir.

Yang, Huang, Huang ve Pai (2014) çalışmalarında güneş enerji sisteminin üreteceği enerji miktarı, elde edilen yağış miktarı ve sıcaklık değerleri analiz edilerek bir gün öncesinden tahmin edecek bir modeli geliştirilmiş. Çalışmada kullanılan özneliklere ait veriler sayesinde meydana getirilen tahmin modelinin bulutlu olmayan günlerde başarılı olduğu görülmüştür.

Tao, Shanxu ve Changsong (2010) çalışmalarında herkese açık meteorolojik verileri paylaşan internet sitelerinden elde ettikleri bulutluluk durumuna ait hava tahmin bilgileri kullanılmıştır. Güneş enerji santrallerinde saatlik üretilen enerjinin tahmini için, NARX tahmin modeli kullanılmışlardır. Oluşturulan model çatı-üstü güneş enerji santrali üzerinde denenmiş ve enerji üretimine ait bulmuş oldukları tahmin sonuçlarının yüksek doğruluk ile eldeki verilere yakın tespitler yaptığı görülmüştür.

Kim, Kim, Yoo, Lee ve Kim (2017) çalışmalarında güneş enerji santrallerinin enerji üretimleri için hava durumuna dayalı bilgileri kullanarak günlük tahmin yapabilen bir model oluşturmuşlardır. Oluşturulan model Kore’de ticari olarak bu işi yapan bir güneş enerji santralinde denenmiş ve diğer tahmin modellerine göre daha iyi performans ortaya çıkardığı görülmüştür.

2. YENİLENEBİLİR ENERJİ

2.1. Yenilenebilir Enerji Tanımı

Yenilenebilir enerji, meteorolojik koşulların uygun olması durumunda sürekli enerji üretebilen kaynaklar için kullanılır. Rüzgâr enerjisi, güneş enerjisi, hidroelektrik enerji, jeotermal enerji, biyokütle enerjisi, hidrojen enerjisi ve dalga enerjisi yenilenebilir enerji kaynaklarıdır. Yenilenebilir enerji sistemleri (YES); günlük yaşamda sürekli kullandığımız fosil kaynakların azalması nedeniyle elektrik ihtiyacının karşılanması için yenilenebilir enerjiyi kullanan sistemlerin tamamıdır. Elektrik üretiminde sıkça kullandığımız fosil yakıtlar, çevreye zarar vermekle kalmayıp insan, hayvan ve bitki sağlığını da etkilemektedir. Bu yüzden yenilenebilir enerji kullanımının artması geleceğimiz açısından önem arz etmektedir (Kıymaz, 2020).

Artan nüfus artışları ve sanayileşme, fosil kaynakların etkin kullanımı ile enerji ihtiyacının karşılanmasında sorunlar çıkarmaktadır. Mevcut imkanlar ile enerji talebinin karşılanması ve devamlılığının sağlanarak ihtiyaca cevap verebilmesi çok önem kazanmıştır. Ülkelerin enerjideki dışa bağımlılıklarını en aza indirerek mevcut kaynaklarını daha verimli kullanma çabaları da özellikle yenilenebilir kaynaklarına olan ilgiyi daha da arttırmıştır (Kanat, 2019).

2.2. Dünya da Yenilenebilir Enerji


Dünyada ki enerjiye olan talep, ekonomik büyüme, teknolojik gelişme ve nüfus yoğunluğu ile doğru orantılı olarak devamlı bir artış söz konusudur (Yüksel ve Kaygusuz, 2011). Önümüzdeki yıllarda da enerjiye olan bu talep artış gösterecektir. Çizelge 2.1’de Dünya’da önümüzdeki yıllarda oluşabilecek birincil enerji ihtiyacının verileri yer almaktadır (Özbay, Parmaksız, Karafil ve Kesler, 2016). 2000’li yılların sonundan itibaren gelişmiş ülkelerin enerji ihtiyacında azalma olurken, gelişmekte olan ülkelerin enerji ihtiyaçları her geçen yıl artış göstermiştir. Bu sebep ile ilerideki 30 yıllık zaman içerisinde OECD ülkelerinin enerjiye olan ihtiyacı %17 civarında artış gösterirken, OECD haricindeki ülkelerin enerjiye olan ihtiyaçlarının %90 civarında artması beklenmektedir. Bu ülkelerden, Çin ve Hindistan gibi büyük nüfusa sahip ve sürekli ekonomik büyüme gösteren ülkelerin yer alması, Asya kıtasındaki enerji ihtiyacının artmasına sebep olacaktır (Yılmaz, 2012).

Çizelge 2.1. Dünya birincil enerji talebi (MTEP)

Yakıt Türü	2000	2018	2030	2040
Kömür	2 317	3 821	3 848	3 779
Petrol	3 665	4 501	4 872	4 921
Doğal Gaz	2 083	3 273	3 889	4 445
Nükleer	675	709	801	906
Hidrolik	225	361	452	524
Biyoenerji	374	737	1 058	1 282
Rüzgâr-Güneş-Jeotermal	60	293	777	1 320
Biyokütle	638	620	613	546
TOPLAM	10 037	14 314	16 311	17 723
Fosil Yakıt Oranı	%80	%81	%77	%74

2040 yılında bile enerji kaynaklarının kullanımında önemli değişikliklerin olmayacağı görülmektedir. Fosil yakıt tüketim miktarının %74 seviyesinde olacağı, fakat kömüre olan talep oranında azalma olurken doğal gaz kullanımının artış göstereceği tahmin edilmektedir.

İlerideki 30 yıllık süreç içerisinde birincil enerji kaynaklarının kullanımında, fosil enerji kaynaklarına olan talep biraz azalsa bile hala değerini koruyacağı tahmin edilmektedir (Yüksel ve Kaygusuz, 2011). Bu süreç içerisinde yenilenebilir enerji kaynaklarına olan ilginin daha da artması düşünülmektedir. Ayrıca fosil enerji kaynaklarından kaynaklanan küresel iklim değişikliği ve çevre sorunlarından dolayı özellikle gelişmiş ülkelerin karbon emisyon oranlarını Kyoto Protokolündeki taahhütlerine bağlı olarak azaltmaları gerekmektedir. Avrupa Birliği ülkelerinde kullanılan yenilenebilir enerji kaynaklarının 2020 yılında %20 civarında olması düşünülmektedir (Karadağ, Gülsaç, Ersöz ve Çalışkan, 2009).




Şekil 2.1. Yenilenebilir enerji ve fosil yakıtlardan 10 yıllık mali getiri

Şekil 2.1'deki (IEA, 2021) grafiğe göre küresel piyasalarda yenilenebilir enerjiden elde edilen getiri 2014 yılından itibaren giderek artmış ve Covid-19 salgınından itibaren fosil yakıtlara oranla daha fazla getiri sağlamıştır.


2.3. Türkiye'de Yenilenebilir Enerji

Enerji, Türkiye'nin yıl içerisinde meydana gelen toplam ithalatının dörtte birini oluşturmaktadır. Türkiye kendi imkanları ile toplam enerji ihtiyacının dörtte birini karşılayabilmektedir. Türkiye'deki yer altı kaynaklarında petrol ve doğalgaz kaynaklarının ihtiyaca cevap vermemesi, yenilenebilir enerji kaynaklarına olan ilginin geçmiş yıllarda yeterince olmaması ve enerjide verimlilik çalışmalarının tam anlamıyla yürütülememesi enerji ihtiyacında dışa bağımlılığa sebep olmaktadır. 2023 yılı ve sonrasında Türkiye'nin artış gösteren nüfusunun enerji olan ihtiyacını önemli derecede kendi içinde üretebilmesi ekonomik kalkınma yönünden önemlidir. Bu sebeple Türkiye'nin; önümüzdeki yıllarda enerjiye olan talebin tespit edilerek, bu ihtiyaca cevap verebilecek araştırmaların ve yatırımların yapılması zaruri hale gelmiştir (Yılankırkan ve Doğan, 2020).



Şekil 2.2. Yıllar itibari ile birincil kaynak bazında brüt elektrik üretimi

Türkiye’deki elektrik ihtiyacı şekil 2.2’de (Tskb, 2021a) gösterildiği gibi son 20 yıl içerisinde sadece 2001, 2009 ve 2019 yıllarında düşüş olmuştur. 2018 yılı içinde elektrik tüketimi 304,2 TWh olurken, 2019 yılı itibariyle 303,3 TWh elektrik kullanımı olmuştur. Pandeminin başlamasından itibaren 2020 yılı içerisinde elektriğe olan ihtiyaç 2019 yılına oranla %0,9’luk yükselme ile 306,1 TWh olmuştur (Tskb, 2021a).



Şekil 2.3. 2021 yılı birincil kaynak türünde brüt elektrik üretimi (GWh)

2021 yılında brüt elektrik üretimine; kömür santralleri %30,7 oranında, doğal gaz santralleri ise %33,1 oranında katkı sağlamıştır. 2020 yılındaki üretim değerleri ile kıyaslandığında, kömür santrallerinden üretilen elektrikte %3,6'lık azalma görülmüştür. Aynı şekilde, hidroelektrik santrallerinden elde edilen elektrikte de %10,3'lük azalma meydana gelmiştir. Kömür ve hidroelektrik santrallerinden üretilen elektriğin azalması nedeniyle oluşan açığın %89'u doğalgaz santrallerinden karşılanmıştır. 2021 yılında oluşan bu değişimin sebebi olarak ülke geneli yaşanan kuraklık ve ithal edilen kömür fiyatlarındaki pahalılaşma ana etken olmuştur. Şekil 2.3'de grafiği yer almaktadır (Tskb, 2021a).

2021 yılındaki enerji talebi ve üretimi en üst seviyeye çıkmıştır. 2021 yılında yenilenebilir enerji kaynaklarından üretilen elektriğin oranı %36,1 olmuştur. Hidroelektrik santrallerden üretilen elektrik miktarındaki azalma nedeniyle doğalgaz santrallerinden üretilen elektrik oranının yükseldiği düşünülmektedir. 2021 yılı içerisinde rüzgâr ve güneş enerji kaynaklarından elde edilen elektrik miktarında artış olmasına rağmen kurak bir sene olması nedeniyle yenilenebilir enerji kaynaklarından elde edilen elektriğin oranında azalma gerçekleşmiştir (Tskb, 2021a).

Çizelge 2.2. Yenilenebilir enerji kurulu güç artış oranı (MW)

Kaynak	2013	2014	2015	2016	2017	2018	2019	2020	2021/9
Hidroelektrik	22 289	23 643	25 868	26 682	27 273	28 291	28 503	30 984	31 447
Rüzgâr	2 760	3 630	4 498	5 751	6 516	7 005	7 591	8 832	10 168
Güneş	0	40	310	833	3 421	5 063	5 995	6 667	7 534
Biyokütle	224	288	345	467	575	739	1 163	1 485	1 782
Jeotermal	311	405	624	821	1 064	1 283	1 515	1 613	1 650
Toplam	25 583	28 006	31 645	34 554	38 849	42 381	44 768	49 581	52 581

Çizelge 2.2'de (Tskb, 2021a) yenilenebilir enerji kaynaklarından elde edilen gücün yıllar içerisindeki gelişimi görülmektedir. 2013 yılı verilerine göre HES'lerden üretilen enerjinin toplam üretime oranı %87'dir. RES ve GES'lere olan talebin çoğalmasıyla beraber HES'lerin toplam enerji üretimindeki payı düşmüştür. Buna rağmen 2021 yılı Eylül ayına kadar olan zaman içerisinde HES'ler %60'lık oran ile en fazla enerji üretimi yapan yenilenebilir enerji kaynağı olmuştur. Son yıllarda lisanssız santrallere olan yatırımların

büyük bir ivme ile artması RES'lerin %19, GES'lerin %14 oranında paya sahip olmasını sağlamıştır. Yenilenebilir enerji kaynakları kurulu gücü içerisinde BES'lerin oranı %3,4, JES'lerin ise %3,1'dir (Tskb, 2021a).


2.4. Yenilenebilir Enerji Çeşitleri

2.4.1. Güneş enerjisi


Havanın bulutlu olduğu zamanlarda bile güneşten enerji elde edilebilir. Dünya genelinde güneş enerjisinden faydalanılmaktadır. Güneş enerjisine olan talep gittikçe artmaktadır.

Güneş pilleri diye bilinen FV, güneş ışığını direkt enerjiye çeviren elektronik cihazlardır. 1954 yılında ABD'deki Bell telefon laboratuvarlarında buluşu gerçekleşmiştir. Günümüzde FV, en hızlı artış gösteren yenilenebilir enerji teknolojilerinden biri haline gelmiştir. Gelecek yıllardaki küresel elektrik üretimde önemli bir paya sahip olacaktır. FV paneller ortalama 30 yıllık bir ömre sahiptir. İmalat esnasında kullanılan malzemeye göre çeşitli renklerde olur (ETKB Güneş, 2021).

Şekil 2.4'de (IRENA Solar Energy, 2022) görüldüğü gibi dünya genelinde güneş enerjisinden elektrik üretimi son 10 yıl içerisinde hız kazanarak gelişmiştir. Ülkemizde ise 2015 yılından itibaren güneş enerjisine olan ilgi artmaya başlamıştır. Dünya geneline bakıldığında üretilen enerji miktarını oranının düşük olduğu gözükmemektedir. Şekil 2.5'de detaylı şekilde yer almaktadır (IRENA Solar Energy, 2022).




Şekil 2.4. Dünya güneş enerjisi 2010-2020 yılları güç kapasite gelişimi



Şekil 2.5. Türkiye güneş enerjisi 2010-2020 yılları güç kapasite gelişimi

Ülkemizin coğrafi yapısı sebebiyle güneş enerjisi potansiyeline yüksektir. GEPA'ya göre, ortalama yıllık toplam güneşlenme süresi 2741,07 saat ve yıllık ortalama toplam ısınım miktarı 1527,46 kWh/m² tespit edilmiştir. Şekil 2.6'da Türkiye güneş enerjisi potansiyeli atlasında ülkemizdeki güneş enerji potansiyeli ve aylık ortalama global radyasyon değerleri gözükmemektedir. Türkiye'nin Güney Bölgeleri ve Güney Doğu Anadolu Bölgesi güneş enerjisi ve güneşlenme süreleri açısından büyük potansiyeli vardır (ETKB Güneş, 2021).




Şekil 2.6. Türkiye güneş enerjisi potansiyeli atlası


2.4.2. Rüzgâr enerjisi

Rüzgâr enerjisi yenilenebilir enerji teknolojileri arasında hızlı bir ivme ile büyümektedir. Maliyetler eskiye nazaran azaldığı için dünya çapında kullanımı artmaktadır. Rüzgârdan enerji üretim kapasitesi, 1997'de 7,5 GW seviyesinden 2018'e kadar yaklaşık 564 GW'a kadar artarak 20 yıl içerisinde yaklaşık olarak 75 kat büyüme olmuştur. Rüzgârdan elektrik üretimi 2009 ve 2013 yılları içerisinde iki katına çıkmıştır. 2016 yılında yenilenebilir enerji kaynakları içerisinde rüzgâr enerjisinden üretilen elektrik %16'lık bir paya sahiptir. Dünyanın birçok yerinde güçlü rüzgâr hızları vardır. Açık deniz rüzgâr enerjisi muazzam bir potansiyel sunmaktadır (IRENA Wind Energy, 2022).

Rüzgâr enerjisinden elde edilen gücün son 10 yıllık gelişimine bakıldığında dünya verileri Şekil 2.7'de verilmiştir. Ülkemiz verilerinin Şekil 2.8'deki gibi artış yönünde benzerlik gösterdiği görülmektedir (IRENA Wind Energy, 2022). Ülkemizin rüzgâr enerjisinden elde ettiği gücün düşük seviyelerde olduğu söylenebilir.



Şekil 2.7. Dünya rüzgâr enerjisi santralleri 2010-2020 yılları kapasite gelişimi




Şekil 2.8. Türkiye rüzgâr enerjisi santralleri 2010-2020 yılları kapasite gelişimi

Rüzgâr enerjisinin devamlılığı mevsimsel ve coğrafi farklılıklar haricinde yenilenebilir bir enerji kaynağı olarak yararlanmaya olanak sağlar. Yatırım yapılacak alanlar iyi tespit edildiği takdirde, güvenilir ve sürekli bir enerji üretim kaynağı olabilmektedir.


2.4.3. Jeotermal enerjisi

Jeotermal enerji, dünyanın yer kabuğunun çeşitli derinliklerinde bulunan ısıdan elde edilir. Özelliklerine göre ısıtma ve soğutma olarak kullanılabilir. Fakat elektrik üretimi olabilmesi için genellikle tektonik olarak aktif kısımlara yakın olan yüksek veya orta sıcaklıktaki kaynaklara ihtiyaç vardır.

Bu önemli enerji kaynağı İzlanda, El Salvador, Yeni Zelanda, Kenya ve Filipinler gibi ülkelerin elektrik ihtiyacının büyük çoğunluğu karşılamakta ve İzlanda'daki ısıtma ihtiyacının %90 oranda karşılamaktadır. En önemli avantajları hava şartlarına göre değişkenlik göstermemesi ve kapasitesinin çok büyük olmasıdır (IRENA Geothermal, 2022).



Şekil 2.9. Dünya jeotermal enerji santralleri 2010-2019 yılları elektrik üretimi



Şekil 2.10. Türkiye jeotermal enerji santralleri 2010-2019 yılları elektrik üretimi

Jeotermal enerjinin dünya genelindeki kurulu gücü diğer enerji kaynaklarına göre daha düşük seviyelerdedir. Şekil 2.10'da gösterildiği gibi ülkemiz 2010 yılından itibaren büyük bir ivme ile jeotermal enerjiden elektrik üretimini arttırmıştır. Şekil 2.9'daki dünya geneli jeotermal enerjiden elektrik üretimine bakıldığında 2010-2019 yılları arasında %30'luk bir artış gerçekleşmiştir (IRENA Geothermal, 2022). Ülkemizin ise Avrupa'daki ülkeler arasında jeotermal enerji potansiyeline sahip 1. ülke olması elektrik üretim seviyesinin 2010 ile 2019 yılları arasında yaklaşık 10 kat arttırmasının sebebidir (ETKB Jeotermal, 2021). Şekil 2.9. ve şekil 2.10'daki verileri kıyasladığımızda dünya geneline göre enerji üretiminde daha yüksek artış gösteren ülkemizin bu alandaki avantajını göstermektedir.


2.4.4. Biyokütle enerjisi

Biyokütle, yakın zamanda yaşamış veya yaşamakta olan organizmalardan üretilen fosil olmayan biyolojik ürünlerin genel ismidir. Endüstriyel anlamda biyolojik maddelerden yakıt üretilmesi ile alakalıdır. Biyokütle yakılabilecek organik atıklar içerir. Diğer taraftan, coğrafi koşullar ile fosilleşmiş ve değiştirilmiş kömür ve petrol benzeri organik maddeleri kapsamaz (Saz, 2015).


Dünya'da yenilenebilir enerjiden elde edilen enerjinin yaklaşık dörtte üçünü biyoenerji oluşturmaktadır. Bunun yarısından fazlası geleneksel biyokütle kullanımından oluşur.

Biyoenerji, 2015 yılındaki verilere göre toplam enerji tüketiminin %10'unu karşılamış ve küresel elektrik üretiminin de %1,9'unu oluşturmuştur (IRENA Bioenergy, 2022).

Şekil 2.11'deki verilere bakıldığında Dünya genelinde biyokütle enerji alanında sıvı biyoyakıtlar, yenilenebilir belediye atıkları, biyogaz ve katı biyoyakıtlar enerji üretiminde belli seviyelere gelmiştir. Şekil 2.12'deki verilere göre Türkiye son yıllara kadar sadece biyogaz ile enerji üretimi yapmıştır (IRENA Bioenergy, 2022). 2016 yılından itibaren de katı biyoyakıtlardan enerji üretimine başlanmıştır. Dünya geneline kıyasladığımızda ülkemizde bu alanda pekte yeterli yatırımlar yapılmamıştır.



Şekil 2.11. Dünya biyokütle enerji santralleri 2010-2019 yılları elektrik üretimi



Şekil 2.12. Türkiye biyokütle enerji santralleri 2010-2019 yılları elektrik üretimi


2.4.5. Hidroelektrik enerjisi

HES'ler akan suyun gücünden faydalanarak elektriğe dönüştüren sistemlerdir. Enerji büyüklüğünü suyun akış veya düşüş hızı belli eder. Toplanmış haldeki suyun yüksek bir yerden bırakılması ile büyük miktarda enerji elde edilebilir. Su akış yönünde bir kanal içine yönlendirilir. Su, Türbinlere doğru büyük bir ivmeyle yol alır. Elektrik üretmek için pervane şeklinde yapıları olan türbinlerin hızla hareketini sağlar. Türbinler de jeneratörler aracılığı ile bu esnada mekanik enerjiyi elektrik enerjisine dönüştürürler (Kanat, 2019).


2.000 yıldan daha uzun bir süre önce, antik Yunanlılar tahıl öğütmek için çarkları döndürebilmek için su gücünden yararlandılar. Günümüzde elektrik üretmenin maliyet yönünden en uygun yollarından biridir. Örneğin Norveç'te elektrik ihtiyacının %99'u hidroelektrikten üretiliyor. Dünyanın en büyük hidroelektrik santrali, Çin'deki 22,5 GW'lık Three Gorges Barajı'dır. 70 ila 80 milyon haneye yetecek kadar elektrik üretir (IRENA Hydropower, 2022).

Hidroelektrik santrallerinden üretilen enerji ülkemizin yenilenebilir enerji potansiyeli açısından önemlidir. Ülkemizin hidroelektrik potansiyeli 433 milyar kWh'tir. Halihazırda ekonomimize kazandırılan enerji potansiyeli ise 160 milyar kWh/yıl'dır. 2019 yılı itibariyle hidroelektrik santrallerinden üretilen elektrik 90.000 GWh seviyesine ulaşmıştır (ETKB

Hidrolik, 2020). Şekil 2.14'deki (IRENA Hydropower, 2022) verilere bakıldığında yağış miktarına göre üretilen enerjinin yıllara göre artıp, azaldığı görülmektedir.



Şekil 2.13. Dünya hidroelektrik enerji santralleri 2010-2019 yılları elektrik üretimi




Şekil 2.14. Türkiye hidroelektrik enerji santralleri 2010-2019 yılları elektrik üretimi

2.4.6. Hidrojen enerjisi

Hidrojen, rengi ve kokusu olmayan, herhangi bir sıcaklığa sahip olmayan, Dünya yüzeyinde en çok bulunan basit ve zehirsiz bir elementtir. Elementler arasında en hafif olmasına rağmen diğer elementler ile kıyaslandığında enerjisi en yükseğidir. Bu enerjinin yeryüzünde en fazla

olan hali sudur. Her ortamda fazlasıyla olmasına rağmen, hidrojenin suyun içerisinde bileşik halinde olması sebebiyle doğal enerji kaynağı değildir. Hidrojen, petrol yakıtları ile kıyaslandığında yaklaşık 1,33 kat daha performanslıdır. Ayrıca, hidrojen enerjisi sonrasında doğada hiçbir kirlilik oluşmamaktadır. Hidrojen üretimi pahalı olduğu için üretimi çok kolay yapılamamaktadır. Günümüzde bu alanda yapılan çalışmalar sayesinde enerji maliyeti azaltılmaya çalışılmaktadır (Çelik, 2012).

2021 yılında dünya genelinde 30 ülke hidrojen enerjisi alanında yapılacak yatırımlarını açıkladı. Bu açıklanan yatırımlar içerisinde büyük ölçekli toplam 228 hidrojen projesi bulunmaktadır. Şekil 2.15'deki görselde detaylı şekilde gösterilmiştir. Yatırım yapılacak projelerin %85'i Asya, Avrupa ve Avustralya kıtalarında yer almaktadır (Tskb, 2021b).



Şekil 2.15. Dünya geneli hidrojen projeleri


2.4.7. Dalga enerjisi

Gelgitler, dalgalar ve akıntılar elektrik üretmek için kullanılabilir. Dalga enerjisi, yüksek güç avantajları nedeniyle diğer yenilenebilir enerjiler arasından öne çıkıyor. Toplam küresel dalga gücü, 2,11 TW civarında olarak tahmin edilmekte olup, günümüzde sadece %4,6'sı enerjiye dönüştürülmektedir (Gunn ve Stock-Williams, 2012). Dalgadan enerji dönüştürürken deniz ve okyanuslardaki fırtınalara, tuzlu sudan oluşan korozyon gibi doğal

etkenlere dayanıklı olması gerekmektedir. Geçmiş yıllardaki bu etkenler günümüzde aşılmış görünmektedir. Dünyadaki birçok ülke şu an dalga enerjisini ticari olarak üretmektedir (Önöz ve diğerleri, 2011).

Dalganın yüksekliği ve sıklığı elde edilecek dalga enerjisini belirlemektedir. Dalga enerjisinin en önemli üstünlüğü de oluşan her dalga yüksekliğinden enerjinin elde edilebilmesidir. Bu sebeple dünya genelinde dalga enerjisi için yapılan yatırımlar ve çalışmalar artmıştır (Kapluhan, 2014).

Şekil 2.16.'daki (IRENA Inspire, 2020) dalga enerjisi alanında alınan lisans sayılarına bakıldığında 2003 yılından itibaren ülkelerin bu sektöre yatırım yaptıkları görülmektedir. 2009 yılına kadar Çin, Amerika ve Güney Kore ülkelerinin yoğun bir şekilde dalga enerjisi için lisans aldığı, ama 2009 yılından sonra sadece Çin'in büyük bir hız ile lisans almaya devam ettiği gözükmemektedir. Diğer ülkelerin bu alana olan yatırım isteklerinin azaldığı gözükmemektedir (IRENA Inspire, 2020).




Şekil 2.16. 2010-2017 yılları ülkelere göre toplam dalga enerjisi patent sayıları

2.5. Güneş Enerjisi

Bu bölümde fotovoltaik sistemlerde elektrik üretiminin nasıl olduğunu anlamak için gerekli bilgiler verilecektir. Fotovoltaik sistemlerin çalışma mantığını anlayabilmek için tüm bileşenler anlatılacaktır.

2.5.1 Güneş hareketi

Şekil 2.17’de ki Güneş’in hareketi Dünya’nın kendi etrafında dönmesinin sonucu olarak ortaya çıkar. Dünya yüzeyine gelen ışığın doğrudan açısını değiştirmektedir. Güneşin konumu, yıl ve günün zamanına ve yüzeyde bulunan nesnenin yerine göre farklılık göstermektedir. Güneşin hareketi şekil 2.17’de yer almaktadır (Durak, 2016).




Şekil 2.17. Güney yarım kürede güneşin izlediği yol

Güneşin gün içerisinde yapmış olduğu bu hareket güneş panellerine gelen ışığın şiddetini doğrudan etkileyen bir faktördür. Güneş ışınları yüzeye ne kadar dik gelirse yüzeyde oluşan güç de bir o kadar artmaktadır. Bu sebeple güneş ve yüzey arasındaki açı farklılıklarında yoğunluk azalmaktadır. Güneş panellerine gelen ışık paralel konuma geldiğinde ışık yoğunluğu sıfıra düşer. Ayrıca, güneşin sabah doğuşu ve akşam batışı da yerin boylamına bağlıdır. Bu nedenlerden ötürü yer yüzeyinde bulunan sabit konumdaki bir güneş panelinin enlem, boylam, yıl ve günün zamanının bilinmesi ile güneş açısının tam olarak modellenmesi mümkün olabilmektedir (Durak, 2016).

2.5.2 Güneş açıları

Dünya kendi etrafında dönerek ilerlediği için yüzeye gelen güneş ışığının açısı sürekli değişkenlik gösterir. Sabit konumdaki güneş panellerine güneş ışınları sürekli olarak dik gelmez. Bu nedenle güneş panellerinden en fazla verim alınan öğlen saatlerindeki güneş açısına göre konumlandırılır. Buna göre ayarlanan güneş paneli gün içerisinde sadece 3-4 saatlik tam verim ile çalışma imkânı bulur. Güneş açısının, panellerin verimine etkisi şekil 2.18’de gösterilmiştir (Çıracı, 2005).




Şekil 2.18. Gün içerisindeki güneş açısının güneş panelinin verimine etkisi

Ülkemizin konumu itibarıyla ortalama güneş panelinin eğim açısı 25-27 derecedir arasında olmalıdır. Güneş panellerinin açılarını değiştirme olanağı varsa yaz aylarında eğim açısını 12-15 dereceye kadar yatırıp, kış aylarında ise panelleri 40-45 dereceye kadar eğimini arttırmak gerekir. Bu sayede kış aylarında kar yağışı sonrası güneş panellerin yüzeyinde kar duramayacağı için gölgeleme yapmayacak, hem de güneşten en fazla verim elde edilecektir (Solaravm, 2021).

2.5.3 Fotovoltaik sistem

2.5.3.1. Güneş hücrelerinin elektriksel özellikleri

Şekil 2.19’da güneş hücresinin eşdeğer devresi yer almaktadır. Güneş hücresi, doğrultucu bir diyota paralel bağlanmış bir akım kaynağı olarak düşünülebilir (Gunn ve Stock-Williams, 2012).




Şekil 2.19. Güneş hücresinin eşdeğer devresi

Burada güneş hücresinin verimine etki eden R_s seri direnci ile R_{sh} paralel direncin etkilerini göstermektedirler. Paralel direnç, güneş pilinin açık devre gerilimini ve dolumu düşüren bir faktördür. Seri direnç, güneş hücresinin dolumunu ve kısa devre akımını azaltan bir faktördür (Gunn ve Stock-Williams, 2012).

2.5.3.2. Fotovoltaik hücre, modül ve dizi

Fotovoltaik (FV), güneşten gelen ışığı doğrudan elektriğe dönüştüren bir teknolojidir. Fotovoltaik hücrenin yapısı, klasik p-n diyotuna çok benzemektedir. Işık hücre üzerine geldiğinde, absorbe edilen fotonlar elektron sistemine aktarılır. Birleşme noktalarında yük taşıyıcılarının oluşmasını sağlar. Yük taşıyıcıları, bir sıvı elektrolit içindeki elektron-iyon çiftleri veya katı bir yarı iletken malzemedeki elektron deliği çiftleri olabilir. Mevcut devrenin direncinin karesi, elektriğe dönüştürülen güçtür. Fotonun kalan gücü hücrenin sıcaklığını yükseltir (Patel, 1999).


Tek bir FV hücresi küçük olduğu için ürettiği enerjide azdır. Daha fazla enerji üretmek için hücreler birbirine bağlanır. FV modülleri, çeşitli boyut ve güç çıkışında FV dizileri oluşturmak için birleştirilebilir ve bağlanabilir. Şekil 2.20’de FV hücre, modül ve dizi görüntüleri yer almaktadır (Li, 2011).



Şekil 2.20. FV hücre, modül ve dizi

2.5.4 Fotovoltaik sistem tipleri

Fotovoltaik sistemler şebeke sistemine bağlı olan ve şebekeden bağımsız olmak üzere ikiye ayrılır. Şebekeye bağlı FV sistemler, doğrudan bağlı ve çift modlu şeklinde ayrılır. Şebekeden bağımsız FV sistemler ise bataryalı, bataryasız ve hibrit diye ayrılır. Şekil 2.21’de fotovoltaik sistem çeşitleri yer almaktadır (Özyiğit, 2019).



Şekil 2.21. Fotovoltaik sistem çeşitleri

2.5.4.1. Şebekeden bağımsız fotovoltaik sistem

Şebeke hattının olmadığı, hattın çekilmesinin zor veya pahalı olduğu, elektriğin sık sık kesintiye uğradığı yerlerde kullanılır. Şekil 2.22’de şebekeden bağımsız fotovoltaik sistemin yapısı yer almaktadır (Kutluca, 2020).

Telekomünikasyon alıcı verici istasyonları, yerleşim yerlerinden uzak mekanlar, yollardaki bazı trafik işaretleri, acil durum aydınlatma sistemleri, sulama sistemleri gibi başlıca kullanım alanları bulunmaktadır (Azmak, 2016).

Güneş paneli, inverter, batarya, şarj regülatörü gibi cihazlar kullanılmaktadır. Güneş panellerinden gün ışığında üretilen elektrik enerjisini, şarj kontrol cihazlarıyla aküye depo ederek kullanıma hazırlamaktadır. Aküler güneş panellerinin ürettiği elektrik enerjisini kimyasal yolla depolar. Güneş panellerinden üretilen enerji ihtiyaçtan azsa bu talebi aküler sağlamaktadır. Akülere depolanan bu enerji dönüştürülerek kullanılmaktadır. Akülerdeki doğrusal akım inverterler sayesinde alternatif akıma dönüştürülür. Sistem kurulurken günlük ihtiyaç olacak enerji miktarı, güneş ışınım miktarı, kullanım yapılacak ay gibi çevre koşulları değerlendirilmelidir (Kutluca, 2020).




Şekil 2.22. Şebekeden bağımsız güneş enerji sistemi

2.5.4.2. Şebekeye bağlı fotovoltaik sistem

Bu tür sistemlerde üretilen enerji kullanımdan çoksa depolama yapılmadan direkt şebekeye iletilir. Eğer ihtiyaç duyulandan daha düşük enerji üretildiği zamanlarda ise şebekeden enerji alınır (Önöz ve diğerleri, 2011). Bu sistemde elde edilen doğru akım, inverterler aracılığıyla alternatif akıma dönüştürülerek şebekeye aktarılır. Çift yönlü sayaçlar sayesinde ihtiyaç duyulduğunda şebekeden enerji alınabilir veya fazla enerji şebekeye verilebilir. Akü kullanımına ihtiyaç yoktur (Kutluca, 2020).

Bu tür sistemler iki bölüme ayrılmaktadır. Birinci sistemde, kurulan güneş panelleri ile üretilen elektrik enerjisi doğrudan şebekeye verilerek gelir elde etmek amacıyla kurulmaktadır. Üretilen enerjinin direkt şebekeye iletilmesi ve ilgili kuruluşa satışı nedeniyle farklı büyüklüklerde oluşabilir. Ayrıca üretilen enerji en yakındaki dağıtım şebekesine aktarıldığı için dağıtım ve iletim kayıpları minimum seviyeye inmektedir. İkinci sistemler, kullanıcı aynı zamanda elektrik ihtiyacını karşılamakta ve ihtiyaç fazlası elektriği şebekeye satarak ek gelir elde edebilmektedir (Arıcı ve İskender, 2020). Şekil 2.23’de şebekeye bağlı fotovoltaik sistemin yapısı yer almaktadır (Kutluca, 2020).



Şekil 2.23. Şebekeye bağlı güneş enerji sistemi

2.5.4.3. Hibrit fotovoltaik sistemler

Hibrit FV sistemler, iki farklı sistemin kullanımıyla oluşturulmaktadır. Kurulan sistemde güneş panelleri, jeneratör, rüzgâr enerji sistemi gibi farklı enerji üreten bileşenler

bulunmaktadır. Güneşin bol olduğu zamanlarda güneş panellerinden elektrik üretimi yapılır ve fazla enerji bataryalara depolanır. İhtiyacın fazla olduğu anlarda ise diğer bağlı enerji kaynaklarından enerji üretimi sağlanır. Bu sayede, mevsimsel değişkenlikler fark etmeksizin enerji üretilmesi hedeflemektedir. Böylece enerji üretiminde çevresel şartlara ve zamana göre dalgalanmalar meydana gelmeyecektir (Cöcen, 2022; Kutluca, 2020). Şekil 2.24’de çalışma şekli gösterilmiştir (Çelik, 2012).




Şekil 2.24. Hibrit bağlantılı enerji sistemi

2.5.5 Fotovoltaik hücre tipleri

Fotovoltaik hücreler, yüzeylerine düşen güneş ışınlarını doğrudan elektrik enerjisine çeviren yarı iletken maddelerdir. Yüzeyleri genellikle kare ve dikdörtgen şeklindedir. Fotovoltaik hücreler; diyotlar, transistörler ve tristörlerlerden üretilmektedir. FV hücrenin üretimi için anorganik yarı iletken malzemeler kullanılmaktadır (Antalya Enerji, 2021). Güneş hücreleri, katot ve anot yerine n tipi ve p tipi yarı iletken malzemeler ile yapılır. N ve P tipi yarı iletken maddelerin arasındaki irtibat neticesinde meydana gelen voltaj beslemesi ile PN eklemi oluşmaktadır. P bölgesinde negatif, N bölgesinde ise pozitif yük toplanmaktadır. PN eklemi oluştuğunda; çoğunluk taşıyıcısı olan N tipindeki elektronlar P tipi elektronlara doğru akım meydana getirirler. Bu durum, her iki tarafta da yükler dengeleninceye kadar sürer. Bu şekilde bir kısım elektron, diğer kısımda da boşluk bir yapı oluşur. Güneş ışınlarının

gelmesiyle elektronların enerjisi artarak hareket etmeye başlar. Bu sayede sistem elektrik üretmeye başlar. Şekil 2.25’de güneş pilinin yapısı gösterilmiştir (Antalya Enerji, 2021).



Şekil 2.25. Güneş pilinin yapısı

2.5.6 Kristal silikon güneş hücreleri

Kristal yapıdaki güneş hücreleri yaklaşık %94'lük pazar payına sahiptir. Bu oranın %70'i polikristallerden oluşmakta, %6'sı ise ince film güneş hücreleridir. Endüstriyel alanda da %14 ile %24 arasında verim sağlamaktadır Silisyum doğada en fazla bulunan element olması, ekonomik ve yüksek verimli olması nedeniyle ticari olarak fazla tercih edilmektedir. Silisyum yapı özelliklerini uzun zamanlar muhafaza edebildiğinden dolayı güneş panel üreticileri 25 yıl dayanıklılık ve %80'in üzerinde performans ile çalışabileceği garantisini verebilmektedir (Karabul, 2019).


Kristal yapılu güneş hücreleri monokristal ve polikristal olmak üzere iki kategoride incelenebilir. Şekil 2.26'da görselleri verilmiştir (Skaaland, Ricke, Wallevik ve Strandberg, 2011).



Şekil 2.26 Monokristal ve polikristal güneş paneli.

2.5.6.1. Monokristal silikon güneş hücreleri

Monokristal silikon güneş hücreleri yüksek verime sahiptir. Monokristal güneş hücrelerinin yapısal ve elektriksel yönden homojen olduğu bilinmektedir. Özelliklerini uzun süre muhafaza edebildiği için verimli çalışır. Fakat maliyet açısından polikristale göre pahalıdır. Renkleri lacivert ve siyah arasındadır. Piyasada bulunan monokristal silikon güneş hücrelerinin verimi %15 ile %18 arasında değişmektedir. Monokristal güneş paneli Şekil 2.27’de gösterilmektedir (Domurcuk, 2021).



Şekil 2.27. Monokristal güneş paneli

2.5.6.2. Polikristal silikon güneş hücreleri

Polikristal silikon hücreler, erimiş durumdaki yarı iletken silisyum maddesinin farklı ebatlardaki kalıplarda soğutulmasıyla oluşur (Oğuz, Karakan ve Uslu, 2015). Bir veya daha

fazla taneden oluşur. Genellikle birkaç santimetre genişliğindedir. Her kristalin içindeki atomlar düzenli olarak konumlandırılmıştır. Ancak farklı kristaller bir araya geldiği için malzemenin kalitesini düşürmektedir. Günümüzde en yaygın kullanılan güneş pili malzemesidir (Skaaland, Ricke, Wallevik ve Strandberg, 2011).

Avantajları

- Üretim aşamasının basit olması nedeniyle fiyat/performans olarak tercih edilir.
- Monokristal yapıdaki güneş hücrelerine göre panel sıcaklık artışında performansı daha iyidir.
- Üretim esnasında az silisyum kullanılır.

Dezavantajları


- Yapısındaki silisyum oranı az olduğu için verimi monokristale göre daha azdır. Verimi %13 ile %17 arasındadır.
- Daha fazla alan kapladığı için montaj esnasında fazla sayıda komponent kullanılmasına sebep olur.

2.5.6.3. İnce film güneş hücreleri

Güneş ışınlarını emme kapasiteleri, kristal silisyum hücrelere göre az malzeme kullanılarak üretilebilirler. Soğurucu tabaka kalınlığı 1 μm seviyesinde hazırlanabilir. Ayrıca kristal silikon güneş hücrelerinin üretimi sırasında silisyumu saflaştırma esnasında 1400-1900 $^{\circ}\text{C}$ gibi sıcaklığa ihtiyaç olması yüksek enerji tüketimine neden olmaktadır. İnce film güneş hücreleri genellikle 500 $^{\circ}\text{C}$ altındaki sıcaklıklarda üretilebilmektedir (Kuzdere, 2019).

İnce film güneş hücreleri, geniş yüzeylere yarı iletken malzemelerin yerleştirilmesiyle meydana gelmektedir. Güneş pillerinin birçok farklı yarı iletken malzemenin kullanılmasıyla düşük üretim masraflarıyla cam, paslanmaz çelik gibi değişik yüzeylere yapılabildiği görülmüştür. Üretim sırasında kullanılan malzemelerin boyutu çok düşük olduğu için ince

film güneş hücreleri şekil 2.28’de görüldüğü gibi esnek bir özelliğe sahiptir (Oğuz, Karakan ve Uslu, 2015).



Şekil 2.28. İnce film güneş hücreleri

3. MATERYAL VE YÖNTEM

3.1. Veri Toplama Süreci

Bu çalışmada kullanılan veriler Amasya Üniversitesi İpekköy yerleşkesindeki Fen Edebiyat Fakültesinin çatısında bulunan 800 adet güneş panellerinden elde edilmiştir. 2016 yılına ait saatlik enerji üretimi, güneş radyasyonu, panel sıcaklığını içeren veriler alınmıştır. Amasya Meteoroloji Genel Müdürlüğü'nden sıcaklık, bağıl nem, basınç, bulutluluk oranı, rüzgâr yönü, rüzgâr hızı, yağış miktarı, ışık yansıtıcılığı, çiğ ve azimut açısı verileri saatlik olarak temin edilmiştir. Veri setimizde toplam 6328 veri bulunmaktadır. Çizelge 3.1'de bir günlük enerji üretim ve güneş radyasyon verileri gösterilmiştir. Güneşlenme saatlerine göre enerji üretimi başlayıp, güneş ışınlarının panellere en dik geldiği zaman dilimlerinde maksimuma ulaşmaktadır. Güneş battıktan itibaren enerji üretimi de durmaktadır. Güneşlenme saatleri mevsimlere göre değişkenlik göstermektedir. Kış aylarında 08:00 ile 16:00 saat aralığında enerji üretimi sağlanabilirken, yaz aylarında 07:00 ile 19:00 saat aralığında enerji üretimi sağlanabilmektedir. Bu yüzden veri setinden enerji üretimi olmayan veriler temizlenmiştir. Bunun sonucunda veri setimizde toplam 2584 veri ve 16 öznitelik bulunmaktadır.

Çizelge 3.1. Bir günlük radyasyon, sıcaklık ve enerji verileri

Tarih ve Saat	Radyasyon (W/m ²)	Sıcaklık (°C)	Üretilen Enerji (kw/h)
01.01.2016 00:00	1,00	-6,46	
01.01.2016 01:00	1,00	-6,73	
01.01.2016 02:00	1,00	-7,28	
01.01.2016 03:00	1,00	-7,95	
01.01.2016 04:00	1,00	-8,70	
01.01.2016 05:00	1,00	-9,46	
01.01.2016 06:00	1,08	-9,38	0
01.01.2016 07:00	15,75	-9,23	1,3
01.01.2016 08:00	166,00	-6,72	26,1
01.01.2016 09:00	295,67	-3,23	57,4
01.01.2016 10:00	396,67	-1,07	81,7
01.01.2016 11:00	409,50	0,17	80,2
01.01.2016 12:00	158,17	1,26	57,1
01.01.2016 13:00	321,42	1,80	55,7
01.01.2016 14:00	133,00	1,53	20,5
01.01.2016 15:00	52,25	1,38	6,5

Çizelge 3.1. (Devamı)

Tarih ve Saat	Radyasyon (W/m ²)	Sıcaklık (°C)	Üretilen Enerji (kw/h)
01.01.2016 16:00	3,08	0,85	0
01.01.2016 17:00	1,00	-0,49	
01.01.2016 18:00	1,00	-1,46	
01.01.2016 19:00	1,00	-1,33	
01.01.2016 20:00	1,00	-1,40	
01.01.2016 21:00	1,00	-1,50	
01.01.2016 22:00	1,00	-1,57	
01.01.2016 23:00	1,00	-1,83	

Çizelge 3.2’de veri setinde kullanılan özniteliklerin ortalama, standart sapma, minimum ve maksimum değerleri gösterilmiştir.

Çizelge 3.2. Veri setinde kullanılan öznitelikler

Özellikler	Ortalama	Standart Sapma	Minimum	Maksimum
Rüzgâr Yönü	156,43	72,80	6,17	349
Rüzgâr Hızı	1,28	1,16	0	9,71
Güneş Radyasyonu	317,72	219,15	1	847,67
Basınç	965,27	4,92	951	983
Sıcaklık	22,40	8,69	-9,40	39,73
Nem	52,92	19,66	10,08	100
Çiğ	11,10	5,97	-12,38	20,70
Işık Yansıtıcılığı	0,16	0,05	0,13	0,49
Azimut Açısı	25,42	111,83	-180	180
Bulutluluk	25,74	30,52	0	99,80
Yağış Miktarı	18,25	6,77	2,80	36,40
Güneş Açısı	60,72	28,20	18	121
Fırtına Hızı	3,085	2,101	0	16,58
Panel Sıcaklığı	7,81	6,86	-10,29	26,92
Batarya	4,087	0,201	3,84	4,59
Enerji	71,79	53,15	1	180,10

3.2.Verilerin Normalizasyonu

Normalleştirme işlemi nümerik olarak çok değişkenlik gösteren değerlerin 0 ile 1 değerleri arasına sıkıştırılmasına denir. Normalizasyon aykırı değerlerin olmasının önüne geçer. Normalizasyon işlemi ile veri seti içindeki değerler 0 ile 1 değerleri arasında yeniden ölçeklendirilir. Bu hesaplama işlemi Denklem 3.1’de gösterildiği gibidir.

$$x^l = \frac{x - x_{min}}{x_{mak} - x_{min}} \quad (3.1)$$

Bu formülde x^l normalize edilmiş veriyi, x girdi değerini, x_{min} girdi verilerindeki en küçük değeri, x_{mak} girdi verilerindeki en büyük değeri ifade etmektedir. Min Max Normalizasyon yöntemi ile normalize edilmiş örnek veriler çizelge 3.4.'de gösterilmiştir.

Çizelge 3.3. Min Max normalizasyon yöntemiyle normalize edilmiş örnek veri

Radyasyon (W/m ²)	Sıcaklık (°C)	Azimut Açısı (°)	Üretilen Enerji (kw/h)
0,48	0,57	0,06	0,29
0,61	0,63	0,00	0,56
0,69	0,69	0,94	0,67
0,47	0,74	0,88	0,81
0,63	0,78	0,84	0,84
0,62	0,79	0,80	0,83
0,50	0,80	0,77	0,75
0,34	0,80	0,75	0,56
0,16	0,79	0,72	0,40

3.3. Öznitelik Seçimi

Veri setindeki meteorolojik değerlerden hangilerinin enerji üretimine doğrudan etkili olduğunu tespit etmek için Weka programının öznitelik seçimi bölümünden korelasyon özellik değerlendirme (Correlation Attribute Evaluation) sınıfı kullanılarak analiz yapıldı. Ranker metodu kullanılmıştır. Öznitelik seçimi için kullanmış olduğum sınıf, her bir değeri bir gösterge olarak ele alarak nominal nitelikleri değer bazında değerlendirir. Nominal bir nitelik için genel bir korelasyona, ağırlıklı bir ortalama yoluyla ulaşılır. Yapılan analiz sonucunda çizelge 3.4'de yer aldığı gibi enerji üretimine en fazla etkisi olan meteorolojik öznitelikler; radyasyon, sıcaklık, azimut açısı, fırtına hızı olmuştur.


Çizelge 3.4. Veri setindeki özniteliklerin üretilen enerjiye etkisi

Öznitelikler	Üretilen Enerjiye Etkisi
Radyasyon	0.8252
Sıcaklık	0.5237
Azimut Açısı	0.4031
Fırtına Hızı	0.2653

Çizelge 3.4. (Devamı)

Öznitelikler	Üretilen Enerjiye Etkisi
Rüzgâr Hızı	0.2123
Çiğ	0.0758
Yağış Miktarı	0.0575
Rüzgâr Yönü	-0.0144
Panel Sıcaklığı	-0.1257
Basınç	-0.1777
Işık Yansıtıcılığı	-0.188
Bulutluluk	-0.2312
Batarya	-0.2515
Güneş Açısı	-0.3508
Nem	-0.6623


Veri setini aynı zamanda Python ile hazırlamış olduğum model ile de analiz yaptığımda şekil 3.1’de görüldüğü gibi radyasyon, sıcaklık ve azimut açısının güneş panellerinin enerji üretiminde en başarılı meteorolojik veriler olarak ortaya çıkmıştır. Hem Weka programının öznitelik azaltma algoritması hem de Python programlama dili ile yaptığım analizlerde aynı meteorolojik değerlerin güneş panelinin enerji üretimine doğrudan etki ettiği tespit edilmiştir. Çiğ, rüzgâr hızı ve yağış miktarı özniteliklerinin enerji üretimine etkisinin çok az olduğu için analiz için bu değerler kullanılmayacaktır. Veri setinde yer alan diğer meteorolojik özniteliklerin enerji üretimine negatif olarak etki ettikleri gözükmemektedir. Nem ve bulutluluk özniteliklerinin güneş panellerinin enerji üretimine olumsuz anlamda en fazla etki eden değerlerdir.



Şekil 3.1. Veri setindeki özniteliklerin korelasyonu


3.4. Veri Analizi

Weka programı ile kullanacağım özniteliklerin enerji üretimi ile olan bağlantısı görselleştirildi. Şekil 3.2’de güneş radyasyonu ile üretilen enerjinin doğru orantılı olduğu görülmektedir. Güneş radyasyonu arttıkça üretilen enerji miktarı da artmaktadır. Güneş battıktan sonra güneş radyasyonu sıfıra yakın bir değere kadar düşmektedir. Güneş panellerinin enerji üretimini en fazla etkileyen meteorolojik faktör gün içerisinde oluşan güneş radyasyonudur.




Şekil 3.2. Radyasyon ile üretilen enerji arasındaki korelasyon

Şekil 3.3’de azimut açısının, güneş panellerinden üretilen enerji ile olan bağlantısı gösterilmektedir. Güneşin gün içerisindeki hareketine göre değişiklik gösterdiği için güneş panellerinin en performanslı çalıştığı azimuta açısı 90° olarak tespit edilmiştir.



Şekil 3.3. Azimut açısı ile üretilen enerji arasındaki korelasyon

Şekil 3.4’de sıcaklığın, güneş panellerinden üretilen enerji ile olan bağlantısı gösterilmektedir. Sıcaklık arttıkça enerji üretiminin de arttığı görülmektedir. Güneş panellerinden enerji üretimi doğrudan sıcaklığa bağlı olmadığı için şekil 3.4’de belli olduğu gibi sıcaklığın yüksek olduğu bazı aralıklarda enerji üretiminin düşük olduğu, sıcaklığın az olduğu aralıklarda da enerji üretiminin yüksek olduğu görülmektedir.



Şekil 3.4. Sıcaklık ile üretilen enerji arasındaki korelasyon

3.5. Araştırma Modelinin Oluşturulması

Amasya Üniversitesi İpekköy yerleşkesindeki Fen Edebiyat Fakültesinin çatısında bulunan güneş enerji panellerinin 2016 yılı içerisinde saatlik üretmiş olduğu enerji miktarı ile elde edilen meteorolojik veriler arasından öznitelik azaltımı yapılarak sıcaklık, güneş radyasyonu ve azimut açısının meteorolojik verileri düzenlenmiştir.

Veri seti Excel formatında Google firmasının bulut tabanlı depolama hizmeti olan Drive'a yüklenmiştir. Yine Google firmasına ait Colaboratory uygulaması üzerinden veri seti ile bağlantı kurulmuştur. Tüm analizler Python programlama dili ve makine öğrenmesinde kullanılan kütüphaneler ile yapılmıştır. Modelleme makine öğrenmesi algoritmalarından lojistik regresyon, rastgele orman, yapay sinir ağları, destek vektör makineleri, k-en yakın komşu, naive bayes ve adaboost kullanılarak yapılmıştır. 2016 yılına ait veriler makine öğrenmesi algoritmaları ile eğitilerek güneş enerji potansiyel tahmini için model oluşturulmuştur. Daha sonra veriler Python programlama dilinde bulunan kütüphaneler kullanılarak %80'i eğitim verisi ve %20'si de test verisi olmak üzere bölümlendirilmiştir. Eğitim verileri ile makine öğrenmesi yapıldıktan sonra tahmin için diğer test verilerinin analizi yapılmıştır. Son olarak oluşturulan modeller ile veri tahmini gerçekleştirilip elde edilen sonuçlar R^2 , RMSE ve MAE metrikleriyle değerlendirilmiştir.

3.6. Makine Öğrenmesi Nedir?

Makine öğrenmesi, geleneksel programlama mantığı ile çalışmayan, işlenmesini istediğimiz verilerden öğrenebilen ve bunun sonucunda tahmin veya sınıflandırma yapmaya çalışan veri analiz tekniğidir. Makine öğrenmesi yapay zekanın bir dalı olduğundan asıl amacı insanlar gibi düşünerek, sorunlar karşısında farklı çözüm yolları bulabilmeyi sağlamak ve çözebilmektir. Makine öğrenmesinin en önemli özelliği öğrenerek kendini geliştirmesidir. Önceki öğrendiği verilerden çıkarım yaparak sonraki işlemlerde öğrendiklerini arttırmaktadır (Saygın, 2021).

Günümüzdeki teknolojinin artmasıyla birçok kullandığımız bilgi dijital ortama taşınmıştır. Bununla birlikte işlenecek veri miktarı da çok artmıştır. Makine öğrenmesinin, veri işleme, ses ve görüntü tanıma gibi özellikleri birçok sektörde kullanılmaktadır.

Günlük yaşantımızda kullandığımız teknolojilerin temelinde makine öğrenmesi bulunmaktadır. Akıllı telefonlarda kullanılan sesli komut, ses ile yazı yazma, yüz tanımlama ile telefon kilidinin açılması veya internette arattığımız kelimelerden arama motorunun çıkarımlar yaparak bize önerilerde bulunması gibi örnekler verilebilir.




Şekil 3.5. Makine öğrenmesi ve disiplinler

Şekil 3.5’de yer aldığı gibi makine öğrenmesi birçok disiplini içine alan geniş bir tekniktir. Günümüzdeki ekonomik koşullar ve teknolojinin hızlı gelişmesiyle oluşan değişime adapte olabilmek için bilgiye dayalı yönetimde makine öğrenmesi tekniklerini kullanmak zorunlu hale gelmiştir (Savaş, Topaloğlu ve Yılmaz, 2012).

Makine öğrenmesi sürecinin ilk adımı algoritmaya eğitim verilerin girilmesiyle başlar. Algoritma girilen verilerle öğrenim sağlar. Algoritmanın doğru çalışıp çalışmadığı ise test verilerinin girilmesi ile kontrol edilir. Tahmin istenilen düzeyde değilse algorithmadan istenilen çıktı elde edilemeye kadar yeni verilerin girişi sağlanır ve algoritma birçok kez yeniden eğitilir. Makine öğrenmesi algoritmaları verilerin artmasıyla daha iyi eğitilip doğruluk oranı artar ve en uygun sonucu üretir. Ancak dikkat edilmesi gereken husus algoritmanın aşırı öğrenmesinden kaçınmaktır.

3.7. Makine Öğrenmesi Süreci

Makine öğrenmesi ile sınıflandırma veya tahmin yapabilmek için ilk önce veri kümesinin belli bir yüzdesi eğitim kümesi olarak belirlenmelidir. Bu sayede makine öğrenmesi algoritması verileri işleyerek eğitildikten sonra test için kullanılacak giriş kümesi işleme girer. Elde edilecek model sayesinde sonuçlara bakılarak modelin başarılı olup olmadığı değerlendirilir. Değerlendirme neticesinde ortaya çıkan model yüksek performans göstermesi halinde modeli kullanabilmek için yeterli olacaktır. Şekil 3.6’da makine öğrenme süreci yer almaktadır (Sel, 2020).



Şekil 3.6. Makine öğrenmesi süreci

3.7.1. Veri seçimi

Veri seçimi esnasında, işlenmemiş veri içerisinde daha önce belirlemiş olduğumuz, problemi etkileyen değişkenleri içeren bir veri seti oluşturulmalıdır. Bu veri seti, istatistiksel hesaplama veya model oluşturmada yeterli olabilecek kadar büyük olmalıdır. Veri setinin büyük olması aynı zamanda işlem esnasında algoritmaların hesaplama karmaşıklığına sebep olabileceği için doğrudan problemimizi etkileyen değişkenlerin kullanılması önceliklidir. Elimizde bulunan işlenmemiş veri setinde problemimiz ile ilgisi olmayan değişken türleri yer alabilir. İlk olarak bu değişkenler veri setinden çıkartılmalıdır. Daha sonra, elde edilen sonuçlara göre dolaylı etkisi olan değişkenler belirlenerek, veri setine tekrar eklenebilir (Kılınç ve Başgömez, 2019).

3.7.2. Veri temizleme

Veri setindeki, eksik değerlerin tamamlanması, sonucu etkileyebilecek büyük veya küçük değerler tespit edilerek gürültü azaltılmalıdır. Bu sayede veriler arasındaki uyumsuzlukların düzeltilmesi mümkün olacaktır. Gürültülü veriler, değişkende ölçülen istatistiksel bir hatadır. Gürültülü verileri belirlemek amacıyla kümeleme, regresyon gibi yöntemler

kullanılabilir. Analizlerin doğru çıktılar verebilmesi için gürültülü verilerin, veri setinden temizlenmesi gerekir (Oğuzlar, 2003).

Kullanacağımız veri setinde bazı değişkenler için eksik değerler bulunabilir. Bu eksik değerler doldurulmadan veya bu değişkenler veri setinden çıkarılmadan yapılan makine öğrenmesi hatalı sonuçlar çıkartacaktır. Eksik verilerin meydana getireceği sıkıntıları minimuma indirmek için kullanılan teknikler aşağıda verilmiştir (Silahtaroglu, 2013).

- Eksik verinin yer aldığı satırı veri setinden çıkarmak veya bu kaydı iptal etmek.
- Eksik verileri elle tek tek doldurmak.
- Eksik olan tüm verilere aynı bilgileri girmek.
- Eksik olan verilere tüm verilerin ortalama değerini vermek.
- Diğer değişkenler yardımıyla eksik verileri tahmin etmek.

3.7.3. Veri dönüştürme

Makine öğrenmesinde kullanılan model, teknik ve algoritmalar belirli türdeki veriler ile çalışır, bazı veri türlerinde de çalışmazlar. Bazı algoritmalar sadece sayısal değerler ile çalışırken bazıları da kategorik değerleri kullanırlar. Bazıları da 0 ve 1'lerden oluşan değerler ile işlem yaparlar. Bu yüzden elimizdeki verileri çalışacağımız algoritmaya uygun hale getirmelidir (Silahtaroglu, 2013).

Normalizasyon işlemi, veriyi makine öğrenmesinde kullanabilmek için kullanılan bir tekniktir. Amacı, veri setindeki değişkene ait sayısal değerleri, değerler arasındaki farklılıkları değiştirmeden ortak bir aralığa uygun şekilde düzenlemektir. Her veri setini normalleştirme gerekmez. Normalleştirme işlemi, verilerin kapladıkları alanı düşürmek, anlamlı ve kolay yorumlanabilecek çıktılar alabilmek için kullanılabilir (Gültepe, 2019).

Veri bütünleştirme, farklı veri kaynaklarından elde edilmiş değerleri bir arada değerlendirebilmek için yapılan işlemdir. Değişik veri kaynaklarında aynı veri için farklı

değerlerin kullanılması analiz yapılmasını zorlaştırır. Bundan dolayı farklı tiplerdeki verilerin analizden önce aynı türe dönüştürülmesi gerekmektedir (Aydemir, 2017).

Veri indirgeme, kullanılacak verilerin miktarının azaltılması işlemidir. Gereksiz yere tutulan bir değişken varsa bunun veri setinden kaldırılması gerekir. Ancak indirgeme işlemi daha çok birden fazla değişkenin birleştirilerek tek bir değişken ile ifade edilmesi ile değer kazanır. Algoritmanın yapısı ve çıkacak sonuçların hassasiyeti açısından, belirli değişkenler birleştirilerek tek bir değişken olarak işleme katılabilir (Silahtaroglu, 2013).

3.7.4. Model tahmini

Bu adımda probleme uygun makine öğrenme algoritmaları yardımıyla test verilerinin istenilen çıktılara dönüştürülmesi aşamasıdır. Modeller çıkan sonuçlara göre değerlendirilerek en iyisini seçmek önemlidir. Farklı model değerlendirme yöntemi ve aşamalarıyla en iyi model tespit edilir.

3.7.5. Sonuç ve değerlendirme


Makine öğrenmesi algoritmalarıyla yapılan işlem sonucunda elde edilen çıktılar değerlendirilerek oluşturulan modelin verimli olup olmadığına karar verilir. Sonuç istenilen düzeyde değilse veri seti tekrardan gözden geçirilir (Fakı, 2015).

3.8. Makine Öğrenmesi Algoritma Türleri

3.8.1. Denetimli makine öğrenmesi

Bu öğrenme türünde öğrenilmiş verilerden faydalanarak yeni veriler için tahmin veya sınıflandırma gerçekleştirilmektedir. Veri setindeki test verilerinin sonucuna göre hangi çıktılar elde edildiği gerekmektedir. Oluşturulan model sayesinde verileri analiz ederek girdi verileri ile sonuç verileri arasındaki ilişkiyi ortaya çıkarmaktadır. Bu şekilde veriye dayalı bir model oluşturur. Yeni girilen veriler modelin öğrenmiş olduğu veriler ile kıyaslanarak en iyi sonuç elde edilir. Yeni veriler girildiğinde sonucu tahmin edilir. Veriler, eğitim, test ve doğrulama olmak üzere üç farklı veri setine ayrılmaktadır. Eğitim veri seti ile model eğitilir. Test veri seti, modelin başarı seviyesini ölçmek için kullanılır. Doğrulama veri seti sonuç


bölümünde genel performansı analiz etmek için kullanılır (Yiğit, 2021). Denetimli makine öğrenme süreci şekil 3.7’de yer almaktadır (Turhost, 2021).



Şekil 3.7. Denetimli makine öğrenmesi süreci

3.8.2. Yarı denetimli makine öğrenmesi


Yarı denetimli makine öğrenmesi, denetimli öğrenme ve denetimsiz öğrenmenin birleştirildiği öğrenme türüdür. Az sayıda eğitilmiş veri ile çok sayıda veri sınıflandırılmak istendiğinde, denetimli öğrenme ile denetimsiz öğrenme verimli analiz yapmayabilir. Denetimli öğrenmeden farklı olarak eğitilmemiş verilerin fazla olmasıdır. Denetimli öğrenmede eğitilmiş veri sayısı fazla iken tahmin edilecek veri sayısı azdır. Yarı denetimli öğrenmede bunun tam tersidir. Ham veriler öğrenilmiş bilgilere göre sınıflandırılabilir (Kızılkaya ve Oğuzlar, 2018; Saygın, 2021). Yarı denetimli öğrenme süreci şekil 3.8’de gösterilmiştir (Turhost, 2021).



Şekil 3.8. Yarı denetimli makine öğrenmesi süreci

3.8.3. Denetimsiz makine öğrenmesi


Denetimsiz Makine Öğrenmesi modelinde sistemin önceden eğitilmemiş verileri kullanarak öğrenmesi amaçlanır. Algoritma sadece verilen değerlere göre öğrenerek, çıktı sonuçları bilinmediği ham veriler arasındaki yapıyı ve dağılımı modellemektedir. Amacı tanıma veya sınıflandırma değildir. Genellikle kümeleme, boyut indirgeme gibi amaçlarla kullanılmaktadır (Bilgin, 2017). Denetimsiz öğrenme süreci şekil 3.9’da yer almaktadır (Turhost, 2021).



Şekil 3.9. Denetimsiz makine öğrenmesi süreci

3.8.4. Takviyeli makine öğrenmesi

Takviyeli öğrenme modelinde sistem, kendisine verilen amaca ulaşmak için karar verir ve çeşitli yöntemler deneyerek durumunu değiştirir. Sistemin almış olduğu kararlar arasından, doğru olanı nasıl tespit edeceğini bulan bir öğrenme yöntemidir. Sistem, doğru kararlar için ödüllendirilir, yanlış kararlar vermesi durumunda da cezalandırılır. Asıl amaç en fazla ödülü alabilmek için kararlar ve denemelerin sırasını öğrenmektir. Bunun içinde yeterli düzeyde karar alması ve denemeler yapması gerekmektedir (Kılınç ve Başeğmez, 2019). Takviyeli öğrenme süreci şekil 3.10'da görselleştirilmiştir (Turhost, 2021).



Şekil 3.10. Takviyeli makine öğrenmesi süreci

3.9. Makine Öğrenmesi Algoritmaları


Bu çalışmada makine öğrenmesi algoritmaları içerisinde karar ağaçları, yapay sinir ağları, naive bayes, rastgele orman, k-en yakın komşu, lojistik regresyon ve adaboost ile modeller kurularak veri setinde analizler gerçekleştirilmiştir. Bu algoritmalar aşağıda açıklanmıştır.

3.9.1. Destek vektör makinesi (DVM)

Klasik öğrenme yaklaşımları, eğitim veri setindeki hatayı en aza indirecek şekilde tasarlanmıştır. Diğer taraftan DVM, istatistiksel öğrenme teorisine dayanan yapısal risk minimizasyonu ilkesine dayanmaktadır. Daha iyi genelleme yapma yeteneğine sahiptir. DVM'nin çok fazla özneliliğe sahip verileri işleme potansiyeli vardır. Bu nedenle özellikle

büyük sınıflandırma problemlerinde verimli olduğu görülmektedir. Bu aynı zamanda hata sınıflandırmasında da fayda sağlamaktadır. Çünkü hata tespiti için öznelilik sayısının sınırlı olmasına gerek yoktur (Widodo ve Yang, 2007).

DVM, Vladimir Vapnik ve arkadaşları tarafından geliştirilmiş bir öğrenme yöntemidir. Genellikle verileri iki sınıfa ayırmak için kullanılan bir yöntemdir. DVM modeli, sistemdeki hataları ayırarak bir sonuç çıkarmak amacıyla kullanılabilir. DVM modelinin ana özelliği, verileri ayrıştırarak farklı sınıflara ait destek vektörleri arasındaki mesafeyi en üst seviyeye çıkartmaktır (Venkatasubramanian, Rengaswamy, Yin ve Kavuri, 2003). Şekil 3.11’de hiper düzlem yapısı yer almaktadır.



Şekil 3.11. Destek vektörü ve hiper düzlem


Hiper düzleme en yakın nokta destek vektörüdür. DVM modelinde veri boyutu arttıkça eğitim süresinin artması, anlaşılması ve yorumlanmasının karmaşık olması bu modelin dezavantajlarıdır (Cawley ve Talbot, 2010).

3.9.2. Rastgele orman (RF)

RF modeli, her biri rastgele bir eğitim kümesinin alt kümesini kullanan birden çok karar ağacının eğitilerek sonuçların bir oy hakkı olacak şekilde sınıflandırma işlemini gerçekleştirmesidir. Karar ağaçları modelinin birleşiminden oluşmaktadır. RF

algoritmasının hata oranı, ormandaki her bir ağaç ve bu ağaçlar arasındaki ilişkiye bağlıdır (Breiman, 2001).

Karar ağaçlarına ait değerlendirmeler bir araya toplandığında genel doğruluk oranı önemli derecede artırılabilir. Her bir KA ait veri seti de azaldığı için öğrenme süresi kısalmır (Alpaydın, 2014). Rastgele orman modeli sınıflandırma ve regresyon ağacı yapılarından oluşmaktadır. Şekil 3.12’de RF algoritmasının çalışma mantığı yer almaktadır.




Şekil 3.12. Rastgele orman algoritması

RF modelindeki yapıda bulunan her ağaç eğitim setindeki bir alt küme tarafından eğitilerek sınıflandırma yapılır. Tüm ağaçlar içerisinde en fazla oyu olan çıktıya göre sınıflandırma yapılmaktadır. Rastgele orman modeli, tek bir karar ağacının sınıflandırmasına göre daha doğru sonuçlar elde etmektedir (Alpaydın, 2014).

3.9.3. Yapay sinir ağları (YSA)

Yapay Sinir Ağları insan yapısındaki sinir sistemine benzer şekilde öğrenme yapmayı amaçlayan denetimli bir makine öğrenme algoritmasıdır. YSA modeli, bir katmanda bulunan nöronların diğer katmandaki nöronlara ilişkilendirilmesiyle meydana gelir. En fazla kullanılan YSA modeli olan MLP sinir ağı modeli; girdi, gizli ve çıktı katmanlarından meydana gelmektedir. Girdi katmanında veriler ağına içerisine dahil edilir. Veri setindeki her

özelliği bir nöron simgeleri. Veri setindeki öznelilik değeri kadar nöron bulunmaktadır (Güler, 2021).



Şekil 3.13. Yapay sinir ağı modeli

Şekil 3.13’de örnek bir YSA modeli gösterilmektedir (Ocak, 2020). Sınıfların tespit edildiği yer çıktı katmanıdır. Bu katman sınıf türü kadar nöron içermektedir. Gizli katman ise girdi katmanı ile çıktı katmanları arasında bulunan verilerin işlendiği katmandır. Gizli katman sayısı ve her katmandaki nöron sayısı eğitimin doğruluk oranını etkileyen önemli iki faktördür. MLP modelindeki algoritma hatanın karesini minimuma düşürecek şekilde ağırlıkları güncellemeyi amaçlar (Güler, 2021).

3.9.4. Naive bayes (NB)

NB, olasılık teorimi içinde yer almaktadır. Bu kuram, bir rassal değişkenin olasılık dağılımıyla koşullu olasılıklar ile önsel olasılıklar arasındaki yapıyı ifade eder. Naive Bayes, değişken bir süreç esnasında oluşan rastgele olay A ile rastgele olay B’nin koşullu ve uç olasılıkları arasındaki yapı denklem 3.1’de gösterilmiştir (Uzun, 2020).


$$P(A|B) = \frac{P(B|A)P(A)}{P(B)} \quad (3.1)$$

$P(A|B)$: A olayının meydana geldiği esnada B olayının gerçekleşme olasılığıdır. $P(B|A)$: B olayının meydana geldiği esnada A olayının gerçekleşme olasılığıdır. $P(A)$ ve $P(B)$: A ve B olaylarının önsel olasılıklarıdır.

Burada önsel olasılık NB'e subjektiflik katar. $P(A)$ henüz veri yokken A olayı ile alakalı edinilen bilgidir. $P(B|A)$ ise elde edilen veriler neticesinde, A olayının meydana geldiği durumlarda B olayının olma ihtimalini gösterir.

3.9.5. K-en yakın komşu (KNN)

KNN algoritması, regresyon ve sınıflandırma amacıyla kullanılabilen bir tekniktir. Kolay yorumlanması ve düşük hesaplama süresi nedeniyle yaygın olarak kullanılır. Bu algortmada k parametresinin seçimi çok önemlidir. Eğitim hata oranı ve doğrulama hata oranı, farklı k değerlerinde erişilmesi gereken iki parametredir. Sınıfı olmayan veri, eğitim setindeki verilerle mukayese edilir ve bir uzaklık hesaplaması yapılır. Hesaplanan uzaklığa göre sınıfı olmayan veriye en uygun sınıflandırma yapılır. Sınıflandırma modellerinin genelinde kendi içinde bir artık sınıflayıcı bulunur. Modele gelen yeni veriler bu sınıflayıcıyı kullanılır. KNN algoritmasında ise gelen yeni veriler için en yakın komşu kümesi tekrardan bakılır. KNN sınıflandırma yönteminde, önceden hiçbir sınıflandırıcı model olmadığı ve her yeni verinin sınıflandırılmasında ham eğitim verilerine geri dönüldüğünden, eğitim kümesi tamamı sınıflandırıcı olarak değerlendirilir (Dilki ve Başar, 2020). Bu özelliği yüzünden tek tek tarama yaptığı için sınıflandırma aşaması uzun olan bir algortmadır. KNN algoritması, yeni verilerin hemen geldiği ve eğitim kümesinin çok fazla değiştiği durumlarda diğer modellere göre daha iyi bir sınıflandırıcı olarak değerlendirilebilir. Şekil 3.14'de KNN sınıflandırmasına bir örnek verilmiştir.



Şekil 3.14. KNN sınıflandırması

3.9.6. Lojistik regresyon (LR)

Lojistik regresyon, sonuç değişkenler üzerindeki bağımsız değişkenlerin oluşturduğu farklılığı olasılık ile hesaplayarak, riskli etmenlerin ortaya çıkmasını sağlamaktadır. LR amacı, bir veya daha fazla bağımsız değişken ile sonuç değişkeni arasında bir model kurulmasıdır. LR analizini diğer regresyon yöntemlerinden ayıran ise sonuç değişkeninin kesikli değerler almasıdır. Diğer yöntemlere göre daha esnek varsayımlar içerdiği ve önkoşul gerektirmediği için çok tercih edilen bir yöntemdir (Öztürk ve Horzum, 2011).

LR analizi, genelde regresyon analizinde kullanılmakla birlikte sınıflandırma yapmak içinde kullanılmaktadır. Bu nedenle LR analizini diğer regresyon analizlerinden ayıran üç önemli farklılığı vardır (Atakurt, 1999).


- Regresyon analizinde bağımlı değişken metrik ölçekli iken, LR analizinde nominal ölçekli bir değişkendir.
- Regresyon analizinde bağımlı değişkenin birim değeri, LR analizinde ise bağımlı değişkenin alabileceği değerlerden birinin gerçekleşme olasılığı tahmin edilir.
- Regresyon analizinde bağımsız değişkenlerin çoklu normal dağılım göstermesi şartı aranırken, LR analizinin uygulanabilmesi için bağımsız değişkenlerin bir kuramsal dağılıma uygunluk varsayımı yapılmaz.

3.9.7. Adaboost (AB)

AdaBoost en çok kullanılan artırma algoritmaları içerisinde yer almaktadır. En başta Freund ve Schapire tarafından kullanılmıştır. Tahmin oranının diğer algoritmalara göre fazla olması, hafızayı diğer algoritmalara oranla daha düşük seviye kullanması, uygulanabilir olması gibi özellikleri sayesinde diğer modellere göre daha çok tercih edilmektedir (Moldagulova ve Sulaiman, 2017).

Torbalama yönteminde her bir tekrarlama tüm verilerin eğitim kümesine seçilme ihtimali eşittir. Fakat artırmada her tekrarlama esnasında verilere ait seçilme ihtimalleri güncellenmektedir. Bunun neticesinde doğru kararlar yerine, yanlış alınan kararlar üzerine konsantre olmasını sağlayan bir yöntemdir (Bulut, 2016). Bu şekilde modelin daha isabetli tahminler oluşturması sağlanmaktadır.

AB algoritması, her öznitelik içerisinde zayıf bir sınıflandırıcı belirleyerek bir topluluk oluşturur. Her öznitelikteki negatif ve pozitif örneklerin ortalaması alınarak zayıf sınıflandırıcı tespit edilir. Güçlü sınıflandırıcılar hata oranı az olan zayıf sınıflandırıcılardan seçilir. Güçlü sınıflandırıcı içerisinde olmayan zayıf sınıflandırıcılara ait öznitelikler silinir (Bulut, 2016). Şekil 3.15’de Adaboost sınıflandırma mantığı yer almaktadır.



Şekil 3.15. Adaboost sınıflandırması

3.10. Değerlendirme Ölçütleri

Tahmin işlemlerinin performansı, farklı metriklerle ölçülür. Hata değerlerinin yüksek çıkması, tahmin doğruluğunun düşük olduğu anlamına gelir. Bu bölümde, tahmin hata oranı ve doğruluğunu hesaplamak için kullanılan bazı değerlendirme ölçütleri açıklanacaktır. Formüllerdeki x ifadesi gerçek değeri ifade etmekte, ise tahmin yapılan değeri ve n toplam veri sayısına göstermektedir.

3.10.1. Kök ortalama kare hata (RMSE)

RMSE makine öğrenmesi ile oluşturulan modelin, tahmin sonucu ile gerçek değer arasındaki mesafenin bulunmasında kullanılan bir ölçüttür. RMSE, tahmin edilen sonucun hatalarını standart sapma ile açıklar. RMSE 0 değerine ne kadar yakın olursa hata oranı o derece az demektir. Model karşılaştırmalarında çoğunlukla kullanılır. Denklem 3.2'deki x_i tahmin değerini, y_i gözlem değerini ve n ise gözlem sayısını ifade etmektedir (Er, 2020).

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n \frac{(x_i - y_i)^2}{n}} \quad (3.2)$$

3.10.2. Ortalama mutlak hata (MAE)

MAE, iki değişken arasındaki farkın ölçülmesi ile çıkar. MAE, veri setindeki her gerçek veri ile bu veriye en uygun çizgi arasındaki ortalama dikey ve yatay uzaklığı ifade eder. MAE, tahmindeki hataların büyüklüğünü gösterir. MAE sonucu, kolay yorumlandığı gibi regresyon ve zamansal problemlerde çoğunlukla kullanılmaktadır. Denklem 3.3'deki x_i tahmin değerini, y_i gözlem değerini ve n ise gözlem sayısını ifade etmektedir (Er, 2020).

$$MAE = \frac{1}{n} \sum_{i=1}^n |x_i - y_i| \quad (3.3)$$

3.10.3. Regresyon katsayısı (R^2)

R^2 , verilerin yerleştirilmiş regresyon hattına ne kadar yakın olduğunun istatistiksel bir değeridir. R^2 , giriş ve çıkış verilerinin ne kadar bağlantılı olduğunu tespit eder. Regresyon katsayısının iki temel özelliği vardır. Bunlardan ilki R^2 eksi değer alamaz. Diğeri ise R^2 , 0 ile 1 arasında bir değer almak zorundadır (Er, 2020).

$$R^2 = 1 - \frac{AKT}{TKT} \quad (3.4)$$

Denklem 3.4'deki AKT, artıkların kareler toplamını, TKT ise toplam kareler toplamını ifade eder.



4. BULGULAR

4.1. Lojistik Regresyon Algoritması ile Başarı Değerleri

Lojistik regresyon algoritması ile yapılan analiz için kullanılan parametreler şu şekildedir. Modelin analiz esnasında belirlemiş olduğu en iyi parametre değerleri verilmiştir. Ağırlık optimizasyonunu (solver) parametresi lbfgs olarak kullanılmıştır. Sınıflar ile ilgili ağırlık (class_weight), balanced olarak belirlenmiştir. Tekrarlama değeri (max_iter) 400 olarak ayarlanmıştır.

Tüm öznitelikler kullanılarak analiz yapıldığında, enerji üretim tahmini ile ilgili lojistik regresyon algoritmasından elde edilen değerler çizelge 4.1’de gösterilmiştir.

Çizelge 4.1. Tüm öznitelikler için lojistik regresyon algoritması sonuçları

Değerlendirme Metrikleri	RMSE	R ²	MAE
Lojistik Regresyon	0,1413	0,7523	0,1127


Öznitelik azaltıldığında veri setinin analiz sonucu, enerji üretim tahmini ile ilgili lojistik regresyon algoritmasından elde edilen değerler çizelge 4.2’de gösterilmiştir.

Çizelge 4.2. Öznitelik azaltıldığında lojistik regresyon algoritması sonuçları

Değerlendirme Metrikleri	RMSE	R ²	MAE
Lojistik Regresyon	0,1176	0,8430	0,0902

Tüm öznitelikler kullanılarak model ile tahminleme yapıldığında başarı oranının %10 oranında azaldığı gözükmemektedir. Bundan dolayı öznitelik azaltılmış veri setine göre değerlendirmeler yapılmıştır. Elde edilen sonuçlara göre doğrusal regresyon algoritmasının sıcaklık, güneş radyasyonu ve azimut açısı özniteliklerini kullanarak güneş panellerinin ürettiği enerjiyi tahmin başarı oranı %84 olarak tespit edilmiştir.

Lojistik regresyon modeli kullanarak eğitim verileri ile test verilerinin analizi sonucunda oluşan tahmin grafiği şekil 4.1’de gösterilmiştir. Saatlik üretilen enerji miktarı ile tahmin edilen enerji miktarı arasındaki korelasyon yer almaktadır.



Şekil 4.1. Lojistik regresyon algoritması saatlik enerji tahmin dağılım grafiği

4.2. Rastgele Orman Algoritması ile Başarı Değerleri

Rastgele Orman algoritması ile yapılan analiz için kullanılan parametreler şu şekildedir. Modelin analiz esnasında belirlemiş olduğu en iyi parametre değerleri verilmiştir. Oluşturulmak istenilen ağaç sayısı ($n_estimators$) için 400 değeri kullanılmıştır. Ağacın maksimum derinliği (max_depth), 25 olarak belirlenmiştir. Düğümü bölmek için gereken minimum örnek sayısı (min_sample_split), 4 olarak kullanılmıştır. Düğümü ayırırken dikkate alınacak maksimum özellik sayısı ($max_features$) için $\sqrt{}$ kullanılmıştır. Çapraz doğrulama kullanılarak modelin kaç kez eğitileceğini belirleyen cv parametresi 5 olarak belirlenmiştir.

Tüm öznitelikler kullanılarak analiz yapıldığında, enerji üretim tahmini ile ilgili Rastgele Orman algoritmasından elde edilen değerler çizelge 4.3’ de gösterilmiştir.

Çizelge 4.3. Tüm öznitelikler için rastgele orman algoritması sonuçları

Değerlendirme Metrikleri	RMSE	R^2	MAE
Rastgele Orman	0,0634	0,9266	0,0479


Öznitelik azaltıldığında veri setinin analiz sonucu, enerji üretim tahmini ile ilgili Rastgele Orman algoritmasından elde edilen değerler çizelge 4.4’ de gösterilmiştir.

Çizelge 4.4. Öznitelik azaltıldığında rastgele orman algoritması sonuçları

Değerlendirme Metrikleri	RMSE	R ²	MAE
Rastgele Orman	0,0342	0,9867	0,0207

Tüm öznitelikler kullanılarak model ile tahminleme yapıldığında başarı oranının %7 oranında azaldığı gözükmemektedir. Bundan dolayı öznitelik azaltılmış veri setine göre değerlendirmeler yapılmıştır. Elde edilen sonuçlara göre Rastgele Orman algoritmasının sıcaklık, güneş radyasyonu ve azimut açısı özniteliklerini kullanarak güneş panellerinin ürettiği enerjiyi tahmin başarı oranı %98 olarak tespit edilmiştir.

Rastgele Orman modeli kullanarak eğitim verileri ile test verilerinin analizi sonucunda oluşan tahmin grafiği şekil 4.2’de gösterilmiştir. Saatlik üretilen enerji miktarı ile tahmin edilen enerji miktarı arasındaki korelasyon yer almaktadır.



Şekil 4.2. Rastgele Orman algoritması saatlik enerji tahmin dağılım grafiği

4.3. Destek Vektör Makineleri Algoritması ile Başarı Değerleri

Destek vektör makineleri algoritması ile yapılan analiz için kullanılan parametreler şu şekildedir. Modelin analiz esnasında belirlemiş olduğu en iyi parametre değerleri verilmiştir. Çekirdek fonksiyonu (kernel) olarak lineer seçilmiştir. Çekirdek değeri (c) varsayılan olarak belirlenmiştir.

Tüm öznitelikler kullanılarak analiz yapıldığında, enerji üretim tahmini ile ilgili Destek Vektör Makineleri algoritmasından elde edilen değerler çizelge 4.5’ de gösterilmiştir.

Çizelge 4.5. Tüm öznitelikler için destek vektör makineleri algoritması sonuçları

Değerlendirme Metrikleri	RMSE	R ²	MAE
Destek Vektör Makineleri	0,1157	0,8340	0,0849


Öznitelik azaltıldığında veri setinin analiz sonucu, enerji üretim tahmini ile ilgili destek vektör makineleri algoritmasından elde edilen değerler çizelge 4.6’de gösterilmiştir.

Çizelge 4.6. Öznitelik azaltıldığında destek vektör makineleri algoritması sonuçları

Değerlendirme Metrikleri	RMSE	R ²	MAE
Destek Vektör Makineleri	0,0894	0,9093	0,0652

Elde edilen sonuçlara göre destek vektör makineleri algoritmasının sıcaklık, güneş radyasyonu ve azimut açısı özniteliklerini kullanarak güneş panellerinin ürettiği enerjiyi tahmin başarı oranı %90 olarak tespit edilmiştir.

Destek vektör makineleri modeli kullanarak eğitim verileri ile test verilerinin analizi sonucunda oluşan tahmin grafiği şekil 4.3’de gösterilmiştir. Saatlik üretilen enerji miktarı ile tahmin edilen enerji miktarı arasındaki korelasyon yer almaktadır.



Şekil 4.3. Destek vektör makinesi algoritması saatlik enerji tahmin dağılım grafiği

4.4. K-en Yakın Komşu Algoritması ile Başarı Değerleri

K-en Yakın Komşu algoritması ile yapılan analiz için kullanılan parametreler şu şekildedir. Modelin analiz esnasında belirlemiş olduğu en iyi parametre değerleri verilmiştir. Uzaklık metrik algoritması minkowski olarak belirlenmiştir. Algoritma olarak auto seçilmiştir. Komşu sayısı (n_neighbors) 14 olarak belirlenmiştir. Tahminde kullanılacak ağırlık fonksiyonu distance olarak seçilmiştir

Tüm öznitelikler kullanılarak analiz yapıldığında, enerji üretim tahmini ile ilgili K-en yakın komşu algoritmasından elde edilen değerler çizelge 4.7’de gösterilmiştir.

Çizelge 4.7. Tüm öznitelikler için k-en yakın komşu algoritması sonuçları

Değerlendirme Metrikleri	RMSE	R ²	MAE
K-En Yakın Komşu	0,0952	0,8875	0,0621


Öznitelik azaltıldığında veri setinin analiz sonucu, enerji üretim tahmini ile ilgili k-en yakın komşu algoritmasından elde edilen değerler çizelge 4.8’de gösterilmiştir.

Çizelge 4.8. Öznitelik azaltıldığında k-en yakın komşu algoritması sonuçları

Değerlendirme Metrikleri	RMSE	R ²	MAE
K-En Yakın Komşu	0,0835	0,9177	0,0571

Tüm öznitelikler kullanılarak model ile tahminleme yapıldığında başarı oranının %3 civarında azaldığı gözükmemektedir Bundan dolayı öznitelik azaltılmış veri setine göre değerlendirmeler yapılmıştır. Elde edilen sonuçlara göre k-en yakın komşu algoritmasının sıcaklık, güneş radyasyonu ve azimut açısı özniteliklerini kullanarak güneş panellerinin ürettiği enerjiyi tahmin başarı oranı %91 olarak tespit edilmiştir.

K-en yakın komşu modeli kullanarak eğitim verileri ile test verilerinin analizi sonucunda oluşan tahmin grafiği şekil 4.4’de gösterilmiştir. Saatlik üretilen enerji miktarı ile tahmin edilen enerji miktarı arasındaki korelasyon yer almaktadır.



Şekil 4.4. K-en yakın komşu algoritması saatlik enerji tahmin dağılım grafiği

4.5. Yapay Sinir Ağları Algoritması ile Başarı Değerleri

Yapay sinir ağları algoritması ile yapılan analiz için kullanılan parametreler şu şekildedir. Modelin analiz esnasında belirlemiş olduğu en iyi parametre değerleri verilmiştir. Gizli

katman sayısı (hidden_layer_sizes) (40,30) olarak belirlenmiştir. Relu, aktivasyon fonksiyonu kullanılmıştır. Ağırlık optimizasyonunu (solver) parametresi lbfgs olarak kullanılmıştır. Tekrarlama değeri (max_iter) 500 olarak belirlenmiştir. Öğrenme hızı (learning_rate) için adaptive fonksiyonu kullanılmıştır.

Tüm öznitelikler kullanılarak analiz yapıldığında, enerji üretim tahmini ile ilgili yapay sinir ağları algoritmasından elde edilen değerler çizelge 4.9’da gösterilmiştir.

Çizelge 4.9. Tüm öznitelikler için yapay sinir ağları algoritması sonuçları

Değerlendirme Metrikleri	RMSE	R ²	MAE
Yapay Sinir Ağları	0,1281	0,7963	0,0967


Öznitelik azaltıldığında veri setinin analiz sonucu, enerji üretim tahmini ile ilgili yapay sinir ağları algoritmasından elde edilen değerler çizelge 4.10’da gösterilmiştir.

Çizelge 4.10. Öznitelik azaltıldığında yapay sinir ağları algoritması sonuçları

Değerlendirme Metrikleri	RMSE	R ²	MAE
Yapay Sinir Ağları	0,1002	0,9013	0,0715

Tüm öznitelikler kullanılarak model ile tahminleme yapıldığında başarı oranının %12 oranında azaldığı gözükmemektedir. Bundan dolayı öznitelik azaltılmış veri setine göre değerlendirmeler yapılmıştır. Elde edilen sonuçlara göre yapay sinir ağları algoritmasının sıcaklık, güneş radyasyonu ve azimut açısı özniteliklerini kullanarak güneş panellerinin ürettiği enerjiyi tahmin başarı oranı %90 olarak tespit edilmiştir.

Yapay sinir ağları modeli kullanarak eğitim verileri ile test verilerinin analizi sonucunda oluşan tahmin grafiği şekil 4.5’de gösterilmiştir. Saatlik üretilen enerji miktarı ile tahmin edilen enerji miktarı arasındaki korelasyon yer almaktadır.



Şekil 4.5. Yapay sinir ağları algoritması saatlik enerji tahmin dağılım grafiği

4.6. Naive Bayes Algoritması ile Başarı Değerleri

Naive Bayes algoritması ile yapılan analiz için kullanılan parametreler şu şekildedir. Modelin analiz esnasında belirlemiş olduğu en iyi parametre değerleri verilmiştir. GaussianNB sınıfı ile analiz yapılmıştır. Hesaplama kararlılığı için kullanılan var_smoothing özelliği, varsayılan değer (1e-09) olarak ayarlanmıştır.

Tüm öznitelikler kullanılarak analiz yapıldığında, enerji üretim tahmini ile ilgili Naive Bayes algoritmasından elde edilen değerler çizelge 4.11’de gösterilmiştir.

Çizelge 4.11. Tüm öznitelikler için naive bayes algoritması sonuçları

Değerlendirme Metrikleri	RMSE	R ²	MAE
Naive Bayes	0,1413	0,7523	0,1127


Öznitelik azaltıldığında veri setinin analiz sonucu, enerji üretim tahmini ile ilgili Naive Bayes algoritmasından elde edilen değerler çizelge 4.12’de gösterilmiştir.

Çizelge 4.12. Öznitelik azaltıldığında naive bayes algoritması sonuçları

Değerlendirme Metrikleri	RMSE	R ²	MAE
Naive Bayes	0,1176	0,8430	0,0903

Tüm öznitelikler kullanılarak model ile tahminleme yapıldığında başarı oranının %8 oranında azaldığı gözükmemektedir. Bundan dolayı öznitelik azaltılmış veri setine göre değerlendirmeler yapılmıştır. Elde edilen sonuçlara göre Naive Bayes algoritmasının sıcaklık, güneş radyasyonu ve azimut açısı özniteliklerini kullanarak güneş panellerinin ürettiği enerjiyi tahmin başarı oranı %84 olarak tespit edilmiştir.

Naive Bayes modeli kullanarak eğitim verileri ile test verilerinin analizi sonucunda oluşan tahmin grafiği şekil 4.6'da gösterilmiştir. Saatlik üretilen enerji miktarı ile tahmin edilen enerji miktarı arasındaki korelasyon yer almaktadır.



Şekil 4.6. Naive Bayes algoritması saatlik enerji tahmin dağılım grafiği

4.7. Adaboost Algoritması ile Başarı Değerleri

Adaboost algoritması ile yapılan analiz için kullanılan parametreler şu şekildedir. Modelin analiz esnasında belirlemiş olduğu en iyi parametre değerleri verilmiştir. Oluşturulmak

istenilen ağaç sayısı ($n_estimators$) için 400 değeri kullanılmıştır. Öğrenme hızı ($learning_rate$), default seçilmiştir. Kayıp fonksiyonu lineer olarak belirlenmiştir.

Tüm öznitelikler kullanılarak analiz yapıldığında, enerji üretim tahmini ile ilgili Adaboost algoritmasından elde edilen değerler çizelge 4.13’de gösterilmiştir.

Çizelge 4.13. Tüm öznitelikler için adaboost algoritması sonuçları

Değerlendirme Metrikleri	RMSE	R^2	MAE
Adaboost	0,1351	0,7737	0,1124


Öznitelik azaltıldığında veri setinin analiz sonucu, enerji üretim tahmini ile ilgili Adaboost algoritmasından elde edilen değerler çizelge 4.14’de gösterilmiştir.

Çizelge 4.14. Öznitelik azaltıldığında adaboost algoritması sonuçları

Değerlendirme Metrikleri	RMSE	R^2	MAE
Adaboost	0,1186	0,8492	0,1000

Elde edilen sonuçlara göre Adaboost algoritmasının sıcaklık, güneş radyasyonu ve azimut açısı özniteliklerini kullanarak güneş panellerinin ürettiği enerjiyi tahmin başarı oranı %84 olarak tespit edilmiştir.

Adaboost modeli kullanarak eğitim verileri ile test verilerinin analizi sonucunda oluşan tahmin grafiği şekil 4.7’de gösterilmiştir. Saatlik üretilen enerji miktarı ile tahmin edilen enerji miktarı arasındaki korelasyon yer almaktadır.



Şekil 4.7. Adaboost modeli algoritması saatlik enerji tahmin dağılım grafiği

4.8. Oluşturulan Modellerin Karşılaştırılması

Amasya Üniversitesi Fen Edebiyat fakültesi çatısında bulunan güneş panellerine ait 2584 verinin kullanıldığı çalışmada çizelge 4.15 ve çizelge 4.16'daki sonuçlar ortaya çıkmıştır. Tüm öznitelikler kullanılarak yapılan analiz sonucu çizelge 4.15'de görülmektedir. Öznitelikler azaltıldıktan sonra yapılan analiz sonuçlarının daha başarılı olduğu tespit edilmiştir. Tüm öznitelikler kullanılarak yapılan analiz neticesinde, rastgele orman algoritması %92 oranı ile en başarılı tahmini gerçekleştirmiştir. Algoritmaların genel başarı oranları çok düşük olduğu için öznitelik azaltılmış verilerin sonuçları detaylı olarak değerlendirilmiştir.

Çizelge 4.15. Tüm öznitelikler kullanılarak oluşturulan modellerin karşılaştırılması

Algoritmalar	RMSE	R ²	MAE
Lojistik Regresyon	0,1413	0,7523	0,1127
Rastgele Orman	0,0634	0,9266	0,0479
Destek Vektör Makineleri	0,1157	0,8340	0,0849
K-En Yakın Komşu	0,0952	0,8875	0,0621
Yapay Sinir Ağları	0,1281	0,7963	0,0967
Naive Bayes	0,1413	0,7523	0,1127
Adaboost	0,1351	0,7737	0,1124

Sıcaklık, güneş radyasyonu, azimut açısı ve üretilen enerji öznitelikleri; lojistik regresyon, rastgele orman, destek vektör makineleri, k-en yakın komşu, yapay sinir ağları, naive bayes ve adaboost algoritmaları kullanılarak modeller oluşturulmuştur. Algoritmalar arasında karşılaştırma yapabilmek için modellerin başarı ve hata oranları çizelge 4.16’da verilmiştir.

Çizelge 4.16. Öznitelikler azaltılarak oluşturulan modellerin karşılaştırılması

Algoritmalar	RMSE	R ²	MAE
Lojistik Regresyon	0,1176	0,8430	0,0902
Rastgele Orman	0,0342	0,9867	0,0207
Destek Vektör Makineleri	0,0894	0,9093	0,0652
K-En Yakın Komşu	0,0835	0,9177	0,0571
Yapay Sinir Ağları	0,1002	0,9013	0,0715
Naive Bayes	0,1176	0,8430	0,0903
Adaboost	0,1186	0,8492	0,1000

RMSE ve MAE değerlendirme kriterleri hata oranlarını göstermektedir. RMSE değerlerine bakıldığında en iyi performansı rastgele orman algoritması sergilemiştir. Lojistik regresyon, Naive Bayes ve Adaboost algoritmalarının RMSE oranları birbirine çok yakın çıkmıştır.

MAE değerlerine bakıldığında en iyi performans gösteren modelin rastgele orman algoritması olduğu belli olmaktadır. En yüksek hata oranı adaboost algoritmasında olmuştur.

R² doğruluk oranları kıyaslandığında en başarılı algoritma rastgele orman olmuştur. Doğruluk oranlarına göre diğer algoritmalar sırasıyla k-en yakın komşu, destek vektör makineleri, yapay sinir ağları, adaboost, lojistik regresyon ve naive bayes olmuştur. En düşük doğruluk oranına sahip algoritmalar adaboost, naive bayes ve lojistik regresyon olmuştur.

5. SONUÇ VE ÖNERİLER

Bu tez çalışmasında, Amasya Üniversitesi İpekköy yerleşkesindeki Fen Edebiyat Fakültesinde bulunan güneş panellerinin 2016 yılına ait ürettiği enerjinin tahmini için Amasya meteoroloji müdürlüğü ve güneş panellerinin kurulu olduğu yerde bulunan meteoroloji istasyonundan veriler alınarak, makine öğrenmesi algoritmaları ile analiz yapılmıştır.

Makine öğrenmesi algoritmalarından lojistik regresyon, k-en yakın komşu, rastgele orman, destek vektör makineleri, adaboost, naive bayes ve yapay sinir ağları algoritmaları kullanılmıştır. Veri setindeki meteorolojik özniteliklerin güneş panellerinden üretilen enerjiye olan etkileri belirlenerek, öznitelik azaltımı yapılmıştır. Öznitelik azaltımı yapılmadan analiz yapıldığında başarı oranının çok azaldığı görülmüştür. Güneş panellerinden saatlik üretilen enerji tahmini için güneş radyasyonu, sıcaklık, azimut açısı ve üretilen enerji öznitelikleri kullanılmıştır.

Bu çalışmada 2584 veri ve 4 öznitelik makine öğrenmesi algoritmaları kullanılarak analizleri yapıldı. Oluşturulan modellerin için verinin %80'i eğitim, %20'si test amaçlı kullanıldı. Tahmin sonucu oluşan sonuçlar MAE, RMSE ve R^2 değerlendirme metrikleriyle başarı oranları tespit edildi.

Elde edilen analizlere göre kök ortalama kare hata (RMSE) oranına göre en az hata yapan algoritmalar sırasıyla rastgele orman, k-en yakın komşu ve destek vektör makineleri oldu. Ortalama mutlak hata (MAE) oranına göre en az hata yapan algoritmalar rastgele orman, k-en yakın komşu ve destek vektör makineleri oldu. R^2 değerlerine bakıldığında en iyi tahmin rastgele orman algoritmasıyla yapıldı.

Analizler neticesinde, makine öğrenmesi algoritmaları ile güneş panellerinin geçmiş tarihlerdeki verileri kullanılarak ileriki zaman dilimleri için üretilecek enerjinin başarılı bir şekilde tahmin edilebileceği görüldü. Meteorolojik öznitelikler arasından güneş panellerinin enerji üretimini en fazla etkileyen faktörler sıcaklık, güneş radyasyonu ve azimut açısı olduğu tespit edilmiştir.

Bu alanda yapılacak çalışmalarda güneş panellerinin bulunduğu konumda meteorolojik verileri kayıt altına alan istasyonun olması elde edilecek verilerin daha tutarlı olmasını sağlayacaktır. Güneş radyasyonu, sıcaklık ve azimut açısı gibi güneş panellerinin enerji üretimini doğrudan etkileyen meteorolojik verilerin, güneş panelinin bulunduğu yerden farklı uzaklıktaki bir meteoroloji istasyonundan alınması veriler arasında tutarsızlıklara neden olacaktır. Bu da analiz sonuçlarından yeterli başarının elde edilememesini ortaya çıkaracaktır.



KAYNAKLAR

- Alpaydın, E. (2014). *Introduction to Machine Learning* (Third b.). London, England: The MIT Press.
- Arıcı, N., & İskender, A. (2020). Fotovoltaik Güneş Santrallerinde Şebeke Bağlantı Sorunları ve Çözümleri. *Politeknik Dergisi*, 23(1), 215-222.
- Atakurt, Y. (1999). Lojistik Regresyon Analizi ve Tıp Alanında Kullanımına İlişkin Bir Uygulama. *Ankara Üniversitesi, Tıp Fakültesi Mecmuası*, 52(4), 191-199.
- Aydemir, B. (2017). *Veri Madenciliği Yöntemleri Kullanarak Meslek Yüksek Okulu Öğrencilerinin Akademik Başarı Tahmini*. Yayımlanmamış Yüksek Lisans Tezi, Pamukkale Üniversitesi, Fen Bilimleri Enstitüsü, Denizli.
- Azmak, E. (2016). *Off-Grid Sistemler*. Güneş Enerji Sistemleri Tesisatı Eğitimi Ders Notları, 298.
- Bilgin, M. (2017). Gerçek veri setlerinde klasik makine öğrenmesi yöntemlerinin performans analizi. *Breast*, 2(9), 683.
- Breiman, L. (2001). Random Forests. *Machine Learning*, 45(1), 5-32.
- Bulut, F. (2016). AdaBoost ile Kalp Krizi Risk Tespiti. *Celal Bayar Üniversitesi, Fen Bilimleri Dergisi*, 12(3), 459-472.
- Cawley, G., & Talbot, N. (2010). On Over-fitting in Model Selection and Subsequent Selection Bias in Performance Evaluation. *11*, 2079–2107.
- Cöcen, C. (2022). *Farklı Azimut Açılarındaki Teras Çatı Fotovoltaik Sistemlerinin Karşılaştırmalı Optimizasyonu*. İstanbul: Yayımlanmamış Yüksek lisans tezi, İstanbul Teknik Üniversitesi, Lisansüstü eğitim enstitüsü.
- Çelik, S. (2012). *Türkiye’Nin Enerjide Dışa Bağımlılığının Azaltılmasında Yenilenebilir Enerji Kaynaklarının Önemi*. Eskişehir: Yayımlanmamış Yüksek Lisans Tezi, Eskişehir Anadolu Üniversitesi, Sosyal Bilimler Enstitüsü.
- Çıracı, E. (2005). *Güneş panellerinin verimini arttırmak için sistem tasarımı*. Eskişehir: Yayımlanmamış Yüksek lisans tezi, Osmangazi Üniversitesi, Fen bilimleri enstitüsü.
- Dilki, G., & Başar, Ö. D. (2020). İşletmelerin İflas Tahmininde K- En Yakın Komşu Algoritması Üzerinden Uzaklık Ölçütlerinin Karşılaştırılması. *İstanbul Ticaret Üniversitesi, Fen Bilimleri Dergisi*, 19(38), 224-233.
- Domurcuk, R. (2021). *The Experimental Investigation of Photovoltaic System*. Aydın: Master's Thesis, Aydın Adnan Menderes University, Graduate School Of Natural And Applied Sciences, Aydın, 9.
- Durak, M. (2016). *Güneş Enerjisi: Teori ve Uygulama*.

- Er, F. (2020). *Gayrimenkul Değerlemesinde Makine Öğrenmesi Tekniklerinin Kıyaslanması*. Yayınlanmamış Yüksek lisans tezi, Yıldız Teknik Üniversitesi, Fen bilimleri enstitüsü, İstanbul.
- Fakı, B. M. (2015). *Veri Madenciliği Yöntemlerini Kullanarak Anemi Sınıflandırılmasına Yönelik Bir Uygulama*. Yayınlanmamış yüksek lisans tezi, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- Gunn, K., & Stock-Williams, C. (2012). Quantifying the Global Wave Power Resource. *Renewable Energy*, 44, s. 296-304. doi:10.1016/j.renene.2012.01.101
- Güler, H. (2021). *Denetimli Öğrenme Yöntemleri Kullanılarak Bir Ses Olay Tespit Sisteminin Gerçekleştirilmesi*. Yayınlanmamış Yüksek lisans tezi, Fırat Üniversitesi, Fen bilimleri enstitüsü, Elazığ.
- Gültepe, Y. (2019). Makine öğrenmesi algoritmaları ile hava kirliliği tahmini üzerine karşılaştırmalı bir değerlendirme. *Avrupa Bilim ve Teknoloji Dergisi*(16), 8-15.
- Hagerman, G., & Bedard, R. (2003). E2I EPRI specification guidelines for preliminary estimation of power production by offshore wave energy conversion devices. *Electric Power Research Institute*.
- Hossain, M. R., Oo, A. M., & Ali, A. S. (2012). Hybrid prediction method of solar power using different computational intelligence algorithms. In *2012 22nd Australasian Universities Power Engineering Conference (AUPEC)*, (s. 76-87). doi:10.4236/sgre.2013.41011
- İnternet: Antalya Enerji. (Mayıs, 2021). *Güneş pili nedir ve nasıl çalışır?*. URL: <https://www.antalyaenerji.com/gunes-fotovoltaik-pili-nedir-ve-nasil-calisir>. Son Erişim Tarihi: 10.04.2022.
- İnternet: ETKB. (Ağustos, 2021). *Güneş*. URL: <https://enerji.gov.tr/eigm-yenilenebilir-enerji-kaynaklar-gunes>. Son Erişim Tarihi: 14.05.2022.
- İnternet: ETKB. (Nisan, 2021). *Hidrolik*. URL: <https://enerji.gov.tr/bilgi-merkezi-enerji-hidrolik>. Son Erişim Tarihi: 14.05.2022.
- İnternet: ETKB. (Nisan, 2021). *Jeotermal*. URL: <https://enerji.gov.tr/eigm-yenilenebilir-enerji-kaynaklar-jeotermal>. Son Erişim Tarihi: 21.04.2022.
- İnternet: IEA. (Ekim, 2021). *World Energy Outlook 2021*. URL: <https://www.iea.org/reports/world-energy-outlook-2021>. Son Erişim Tarihi: 18.04.2022.
- İnternet: IRENA. (Nisan, 2022). *Bioenergy*. URL: <https://www.irena.org/bioenergy>. Son Erişim Tarihi: 18.04.2022.
- İnternet: IRENA. (Nisan, 2022). *Geothermal Energy*. URL: <https://www.irena.org/geothermal>. Son Erişim Tarihi: 21.04.2022.

İnternet: IRENA. (Nisan, 2022). *Hydropower*. URL: <https://www.irena.org/hydropower>. Son Erişim Tarihi: 12.04.2022.

İnternet: IRENA. (Kasım, 2020). *Inspire*. URL: <http://inspire.irena.org/Pages/patents/Patents-Search.aspx>. Son Erişim Tarihi: 18.04.2022.

İnternet: IRENA. (Mart, 2022). *Solar Energy*. URL: <https://www.irena.org/solar>. Son Erişim Tarihi: 23.03.2022.

İnternet: IRENA. (Mart, 2022). *Wind Energy*. URL: <https://www.irena.org/wind>. Son Erişim Tarihi: 22.03.2022.

İnternet: Li, Y. (Nisan, 2011). *Photovoltaic Systems for Solar Electricity Production*. URL: <https://ohioline.osu.edu/factsheet/AEX-652-11>. Son Erişim Tarihi: 24.04.2022.

İnternet: Ocak, M. E. (Aralık, 2020). *Yapay Sinir Ağları Nedir?*. URL: <https://bilimgenc.tubitak.gov.tr/yapay-sinir-aglari-nedir>. Son Erişim Tarihi: 18.05.2022.

İnternet: Solaravm. (Aralık, 2021). *Kış mevsiminde güneş paneli eğim açısı kaç olmalıdır*. URL: <https://solaravm.com/kisin-gunes-paneli-egim-acisi-ne-olmalidir>. Son Erişim Tarihi: 22.04.2022.

İnternet: Tskb. (Kasım, 2021). *Enerji Görünümü 2021*. URL: <https://www.tskb.com.tr/i/assets/document/pdf/enerji-sektor-gorunumu-2021.pdf>. Son Erişim Tarihi: 12.05.2022.

İnternet: Tskb. (Mayıs, 2021). *Hidrojen Enerjisi Bilgilendirme Notu*. URL: <https://www.tskb.com.tr/uploads/file/hidrojen-enerjisi-bilgilendirme-notu-120721.pdf>. Son Erişim Tarihi: 10.05.2022.

İnternet: Turhost. (Kasım, 2021). *Makine Öğrenmesi (Machine Learning) Nedir?*. URL: <https://blog.turhost.com/makine-ogrenmesi-machine-learning-nedir>. Son Erişim Tarihi: 20.05.2022.

İnternet: Uzun, E. (Ağustos, 2020). *Naive Bayes Classifier*. URL: https://erdincuzun.com/makine_ogrenmesi/naive-bayes-classifier. Son Erişim Tarihi: 23.05.2022.

Jamil, I., Zhao, J., Zhang, L., Rafique, S. F., & Jamil, R. (2019). Uncertainty analysis of energy production for a 3×50 MW AC photovoltaic project based on solar resources. *International Journal of Photoenergy*, 2019. doi:10.1155/2019/1056735

Kanat, H. (2019). *Yenilenebilir Enerji Kaynaklarından Güneş Enerjisi Yatırımlarını Etkileyen Faktörler: Konya Güneş Enerjisi Yatırımları Analizi*. Yayımlanmamış yüksek lisans tezi, Selçuk Üniversitesi, Sosyal Bilimler Enstitüsü, Konya.

Kapluhan, E. (2014). Enerji coğrafyası açısından bir inceleme: güneş enerjisinin dünya'daki ve Türkiye'deki kullanım durumu. *Coğrafya dergisi*(29), 70-98.

- Karabul, M. (2019). *Türkiye’de Fotovoltaik ve Rüzgâr Uygulamalarının Ülke Verileri ve Mevcut Teknolojiler Kapsamında İstatistiksel Olarak Analizi*. Yayımlanmamış yüksek lisans tezi, Gebze Teknik Üniversitesi, Fen bilimleri enstitüsü, Gebze.
- Karadağ, Ç., Gülsaç, I. I., Ersöz, A., & Çalışkan, M. (2009). Çevre Dostu ve Temiz: Yenilenebilir Enerji Kaynakları. *Bilim ve Teknik*, 42(498), 24-27.
- Kılınç, D., & Başeğmez, N. (2019). *Uygulamalarla Veri Bilimi* (3. b.). İstanbul: Abaküs Yayınları.
- Kim, J.-G., Kim, D.-H., Yoo, W.-S., Lee, J.-Y., & Kim, Y. B. (2017). Daily prediction of solar power generation based on weather forecast information in Korea. *IET Renewable Power Generation*, 11(10), 1268-1273. doi:10.1049/iet-rpg.2016.0698
- Kıymaz, Y. E. (2020). *Güneş Enerjisi Santrallerinde Derin Öğrenme Kullanılarak Elektrik Üretimi Tahmininin Yapılması*. Yayımlanmamış yüksek lisans tezi, Necmettin Erbakan Üniversitesi, Fen Bilimleri Enstitüsü, Konya.
- Kızılkaya, Y. M., & Oğuzlar, A. (2018). Bazı Denetimli Öğrenme Algoritmalarının R Programlama Dili İle Kıyaslanması. *Karadeniz Uluslararası Bilimsel Dergi*, 37(37), 90-98.
- Koca, A., Öztıp, H. F., Varol, Y., & Koca, G. Ö. (2011). Estimation of solar radiation using artificial neural networks with different input parameters for Mediterranean region of Anatolia in Turkey. *Expert Systems with Applications*, 38(7), 8756-8762. doi:10.1016/j.eswa.2011.01.085
- Kutluca, M. (2020). *Şebekeden Bağımsız Mikro Güneş Enerji Santralının Tasarımı ve Analizi*. Yayımlanmamış Yüksek lisans tezi, Kırklareli Üniversitesi, Fen Bilimleri Enstitüsü, Kırklareli.
- Kuzdere, H. E. (2019). *Farklı Katman Kalınlıklarına Sahip İnce Film Cdte/Cds Güneş Hücrelerinin İncelenmesi*. Yayımlanmamış Yüksek lisans tezi, Isparta Uygulamalı Bilimler Üniversitesi, Lisansüstü Eğitim Enstitüsü, Isparta.
- Moldagulova, A., & Sulaiman, R. B. (2017). Using KNN algorithm for classification of textual documents. *8th International Conference on Information Technology (ICIT)*, (s. 665-671). doi:10.1109/ICITECH.2017.8079924
- Oğuz, Y., Karakan, A., & Uslu, B. (2015). Afyonkarahisar'da Kurulu Olan Monokristal, Polikristal ve İnce Film Güneş Panellerinin Verimliliğinin İncelenmesi. *Makine Mühendisleri Odası, Tesisat Mühendisliği Dergisi*(149), s. 47.
- Oğuzlar, A. (2003). Veri Ön İşleme. *Erciyes Üniversitesi, İktisadi ve İdari Bilimler Fakültesi Dergisi, Kayseri*, 21.
- Önöz, B., Kabdaşlı, S., Yeğen, B., Yılmaz, A., Babaç, G., Albostan, A., & Varol, E. (2011). Türkiye Kıyılarında Dalga Enerji Potansiyelinin Belirlenmesi. *İstanbul Teknik Üniversitesi, Mühendislik Dergisi, İstanbul*, 10(5), 181-192.

- Özbay, H., Parmaksız, H., Karafil, A., & Kesler, M. (2016). Farklı Eğitim Açılarındaki Fotovoltaik Panellerin Elektriksel Ölçümlerinin Raspberry Pi ile İzlenmesi. *Düzce Üniversitesi, Bilim ve Teknoloji Dergisi, Düzce, 4*(2), 711-718.
- Öztürk, E., & Horzum, M. B. (2011). Teknolojik pedagojik içerik bilgisi ölçeği'nin Türkçe'ye uyarlaması. *Ahi Evran Üniversitesi, Kırşehir Eğitim Fakültesi Dergisi, Kırşehir, 12*(3), 255-278.
- Özyiğit, F. Y. (2019). *Sivas il merkezi ve ilçelerinde güneş enerjisinden elektrik enerjisi üretiminin ekonomik fizibilitesi*. Yayımlanmamış yüksek lisans tezi, Sivas Cumhuriyet Üniversitesi, Fen Bilimleri Enstitüsü, Sivas.
- Patel, M. R. (1999). *Wind and Solar Power Systems*. ABD: CRC Press LLC.
- Savaş, S., Topaloğlu, N., & Yılmaz, M. (2012). Veri madenciliği ve Türkiye'deki uygulama örnekleri. *İstanbul Ticaret Üniversitesi, Fen Bilimleri Dergisi, İstanbul, 11*(21), 1-23.
- Saygın, E. (2021). *Karaciğer Hastalığı Teşhisinde Makine Öğrenmesi Yöntemlerinin Başarılarının Ölçülmesi*. Yayımlanmamış yüksek lisans tezi, Fırat Üniversitesi, Fen Bilimleri Enstitüsü, Elazığ.
- Saz, S. (2015). *T.C. Biyokütle Enerjisi ve Yararlanma Yöntemleri*. Bitirme Tezi, Ondokuz Mayıs Üniversitesi, Mühendislik Fakültesi, Çevre Mühendisliği Anabilim Dalı, Samsun.
- Sel, A. (2020). Pandemi Sürecinde Altın Fiyatları ile Kripto Para İlişkisinin Makine Öğrenme Metotları ile İncelenmesi. *Journal of Statistics and Applied Sciences, 1*(2), 85-98.
- Sharma, N., Sharma, P., Irwin, D., & Shenoy, P. (2011). Predicting solar generation from weather forecasts using machine learning. *IEEE International Conference on Smart Grid Communications (SmartGridComm)*, (s. 528-533). Belgium. doi:10.1109/SmartGridComm.2011.6102379
- Shi, J., Lee, W.-J., Liu, Y., Yang, Y., & Wang, P. (2012). Forecasting Power Output of Photovoltaic Systems Based on Weather Classification and Support Vector Machines. *IEEE Transactions on Industry Applications, 48*(3), 1064-1069. doi:10.1109/TIA.2012.2190816
- Silahtaroglu, G. (2013). *Veri Madenciliği Kavram ve Algoritmaları* (2. b.). İstanbul: Papatya Yayınları.
- Skaaland, A., Rieke, M., Wallevik, K., & Strandberg, R. (2011). *Potential and Challenges for Building Integrated Photovoltaics in the Agder Region*. Kristiansand: Agderforskning.
- Tao, C., Shanxu, D., & Changsong, C. (2010). Forecasting power output for grid-connected photovoltaic power system without using solar radiation measurement. *In The 2nd*

International Symposium on Power Electronics for Distributed Generation Systems, (s. 773-777). China. doi:10.1109/PEDG.2010.5545754

- Venkatasubramanian, V., Rengaswamy, R., Yin, K., & Kavuri, S. N. (2003). A review of process fault detection and diagnosis: Part I: Quantitative model-based methods. *Computers & Chemical Engineering*, 27(3), 293-311. doi:10.1016/S0098-1354(02)00160-6
- Wang, F., Zhen, Z., Wang, B., & Mi, Z. (2018). Comparative Study on KNN and SVM Based Weather Classification Models for Day Ahead Short Term Solar PV Power Forecasting. *Applied Sciences*, 8(1), 28. doi:10.3390/app8010028
- Widodo, A., & Yang, B.-S. (2007). Support vector machine in machine condition monitoring and fault diagnosis. *Mechanical systems and signal processing*, 21(6), 2560-2574. doi:10.1016/j.ymssp.2006.12.007
- Yang, H.-T., Huang, C.-M., Huang, Y.-C., & Pai, Y.-S. (2014). A Weather-Based Hybrid Method for 1-Day Ahead Hourly Forecasting of PV Power Output. *IEEE Transactions on Sustainable Energy*, 5(3), 917 - 926. doi:10.1109/TSTE.2014.2313600
- Yiğit, E. (2021). *Makine Öğrenmesi Kullanılarak Endüstriyel Pres Makinesi İçin Kestirimci Bakım Uygulaması*. Yayımlanmamış yüksek lisans tezi, Kocaeli Üniversitesi, Fen Bilimleri Enstitüsü, Kocaeli.
- Yılankırkan, N., & Doğan, H. (2020). Türkiye'nin enerji görünümü ve 2023 yılı birincil enerji arz projeksiyonu. *Batman Üniversitesi, Yaşam Bilimleri Dergisi, Batman*, 10(2), 77-92.
- Yılmaz, M. (2012). Türkiye'nin enerji potansiyeli ve yenilenebilir enerji kaynaklarının elektrik enerjisi üretimi açısından önemi. *Ankara Üniversitesi, Çevre Bilimleri Dergisi, Ankara*, 4(2), 33-54. doi:10.1501/Csaum_0000000064
- Yousif, J. H., Kazem, H. A., & Chaichan, M. T. (2016). Modeling of daily solar energy system prediction using soft computing methods for Oman. *International Journal of Applied Engineering Research*, 13(3), 10166-10172.
- Yurdadoğ, V., & Tosunoğlu, Ş. (2017). Renewable Energy Support Policies In Turkey. *Eurasian Academy of Sciences Eurasian Business & Economics Journal*, 9, 1-21.
- Yüksel, İ., & Kaygusuz, K. (2011). Renewable energy sources for clean and sustainable energy policies in Turkey. *Renewable and Sustainable Energy Reviews*, 15(8), 4132-4144. doi:10.1016/j.rser.2011.07.007
- Zamfir, A., Colesca, S. E., & Corbos, R. A. (2016). Public policies to support the development of renewable energy in Romania: A review. *Renewable and Sustainable Energy Reviews*, 58, 87-106. doi:10.1016/j.rser.2015.12.235

ÖZGEÇMİŞ

Adı-Soyadı : Havva AYYILDIZ KOÇ

Eğitim Derecesi	Okul/Program	Mezuniyet Yılı
Lisans	Pamukkale Üni., Bilgisayar Öğrt.	2004 - 2008
Önlisans	Anadolu Üni., İlahiyat	2019 - 2021

İş Deneyimi/Yıl	Çalıştığı Yer
Aralık 2009 - Halen	Toruntay Mesleki ve Teknik Anadolu Lisesi

Yabancı Dil

İngilizce

Bilimsel Faaliyetler (Yayınlar, Bildiriler, Katıldığı Projeler)

Koç, H. A., Ünal, Y. (2021). Prediction of Energy Generated From Solar Panels Using Machine Learning, International Conference on Engineering Technologies, ICENTE'21 Konya, Turkey, November 18-20, 2021, 43-45. E-ISBN: 978-625-44427-7-3