



T.C.
KAHRAMANMARAŞ SÜTÇÜ İMAM ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**GÜNEŞ ENERJİ SANTRALİ KISA DÖNEM ENERJİ
ÜRETİM TAHMİNİ**

MELİKE KOCA

**YÜKSEK LİSANS TEZİ
ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI**

KAHRAMANMARAŞ 2023

T.C.
KAHRAMANMARAŞ SÜTÇÜ İMAM ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

GÜNEŞ ENERJİ SANTRALİ KISA DÖNEM ENERJİ
ÜRETİM TAHMİNİ

MELİKE KOCA

YÜKSEK LİSANS TEZİ
Elektrik Elektronik Mühendisliği Anabilim Dalı

KAHRAMANMARAŞ 2023

TEZ BİLDİRİMİ

Tez içindeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edilerek sunulduğunu, ayrıca tez yazım kurallarına uygun olarak hazırlanan bu çalışmada orijinal olmayan her türlü kaynağa eksiksiz atıf yapıldığını bildiririm.

MELİKE KOCA

Not: Bu tezde kullanılan özgün ve başka kaynaktan yapılan bilgilerin, çizelge, şekil ve fotoğrafların kaynak gösterilmeden kullanımı, 5846 sayılı Fikir ve Sanat Eserleri Kanunundaki hükümlere tabidir.

GÜNEŞ ENERJİ SANTRALİ KISA DÖNEM ENERJİ ÜRETİMİ TAHMİNİ (YÜKSEK LİSANS TEZİ)

MELİKE KOCA

ÖZET

Türkiye sahip olduğu fiziki özellikler nedeniyle oldukça yüksek bir güneş enerjisi potansiyeline sahiptir ve ülkedeki Güneş Enerjisi Santrali (GES) kurulu gücü her geçen gün artmaktadır. Fakat GES enerji üretimi değişken bir karaktere sahiptir ve üretilen değişken enerji elektrik şebekelerindeki arz-talep dengesini bozucu bir etki oluşturmaktadır. Bu konuda yapılan çalışmalar bozucu etkiyi yok etmek için GES üretim tahminlerinin gerekli olduğunu göstermektedir. Bu çalışmada GES üretimlerinin gün öncesinden tahmini için makine öğrenmesi algoritmaları temelli modeller geliştirilmiştir. Model girdileri Sayısal Hava Tahminleri (SHT) ve uygulama yapılan santralden alınan geçmiş güç değerleridir. Çalışmada kullanılan SHT verileri Meteoroloji Genel Müdürlüğünden (MGM) alınmıştır. Geçmiş güç değerleri ise şebekeye bağlı, 1 MW kurulu gücünde ve Eskişehir ilinde tesis edilmiş bir GES'ten temin edilmiştir. Model girdi verileri ve dört farklı makine öğrenmesi algoritması kullanılarak gün öncesi üretim tahminleri elde edilmiştir. Çalışmada kullanılan makine öğrenmesi algoritmaları; Doğrusal Regresyon (DR), Regresyon Ağacı (RA), Destek Vektör Makinesi (DVM) ve Gauss Süreç Regresyonu (GSR)'dur. Tahminlerin doğruluğu Kök Ortalama Kare Hata (RMSE), Ortalama Mutlak Hata (MAE) ve Determinasyon Katsayısı (R) performans değerlendirme kriterleri kullanılarak ölçülmüştür. Çalışma sonunda en iyi performans sergilediği tespit edilen GSR algoritması tahminleri için RMSE, MAE ve R değerleri sırasıyla 129.78 (kWh), 70.80 (kWh) ve 0.91 olarak hesaplanmıştır.

Anahtar sözcükler: Yenilebilir Enerji Kaynakları, Güneş Enerjisi Santrali, Gün Öncesi Güç Tahmini, Makine Öğrenmesi

Kahramanmaraş Sütçü İmam Üniversitesi

Fen Bilimler Enstitüsü

Elektrik Elektronik Mühendisliği Anabilim Dalı, Haziran /2023

Danışman: Doç. Dr. Ökkeş Fatih Keçecioglu

İkinci Danışman: Dr. Öğr. Üyesi Ceyhun Yıldız

Sayfa Sayısı: 66

SHORT-TERM ENERGY GENERATION FORECAST FOR SOLAR POWER PLANT

(MSc. THESIS)

MELİKE KOCA

ABSTRACT

Turkey has a very high solar energy potential due to its physical characteristics, and the installed capacity of Solar Power Plants (SPP) is increasing by the day. However, the energy generated by SPP is variable, and variable energy disrupts the supply-demand balance in power grids. The studies on this subject show that SPP generation estimates are necessary to eliminate the disruptive effect. In this study, models based on machine learning algorithms were developed for the day-ahead prediction of SPP generation. The model inputs were Numerical Weather Forecasts (NWP) and historical power values taken from the investigated power plant. NWP data used in the study were obtained from the General Directorate of Meteorology (GDM). The historical power values were obtained from a grid tied SPP that located in Eskisehir with 1 MW installed power capacity. The model input data and four different machine learning algorithms were utilized to obtain day-ahead generation forecasts. The machine learning algorithms used in the study were Linear Regression (DR), Regression Tree (RA), Support Vector Machine (DVM) and Gaussian Process Regression (GSR). The accuracy of the forecasts was measured using Root Mean Square Error (RMSE), Mean Absolute Error (MAE) and Determination Coefficient (R) performance evaluation criteria. At the end of the study, RMSE, MAE and R values were calculated as 129.78 (kWh), 70.80 (kWh) and 0.91, respectively, for the GSR algorithm which was found to have the best performance.

Key words: Renewable Energy Sources, Solar Power Plant, Day-Ahead Power Forecast, Machine Learning

Kahramanmaraş Sütçü Imam University

Graduate School of Natural and Applied Sciences

Department of Electrical and Electronics Engineering, June /2023

Supervisor: Assoc. Prof. Ökkeş Fatih Keçecioglu

Co- Supervisor: Asst. Prof. Dr. Ceyhun Yıldız

Page number: 66

TEŐEKKÜR

Bu uzun ve zorlu süreçte her türlü bilgi ve mesleki tecrübesiyle daima yoluma ışık tutan Kıymetli Hocam Dr. Öğr. Üyesi Ceyhun YILDIZ'a ve her fırsatta bana sunduđu destekleri için Kıymetli Hocam Doç. Dr. Ökkeş Fatih KEÇECİOĐLU'na sonsuz şükranlarımı sunarım. Tez çalışmamı yapmam için gerekli olan kaynak bilgileri benimle paylaşan BESA Enerji'ye teşekkür ederim.

Bu süreçte göstermiş olduđu fedakârlıktan ve anlayıştan dolayı eşim Uđur Serkan BALTACI' ya müteşekkirim. Son olarak tez çalışmam boyunca her daim yanımda olan anneme, babama, kardeşlerime ve eşimin değerli ailesine teşekkür ederim.

Melike KOCA

İÇİNDEKİLER

ÖZET.....	i
ABSTRACT.....	ii
TEŞEKKÜR.....	iii
İÇİNDEKİLER.....	iv
SİMGELER VE KISALTMALAR DİZİNİ.....	vi
ŞEKİLLER DİZİNİ.....	ix
ÇİZELGELER DİZİNİ.....	xi
1. GİRİŞ.....	1
1.1. Literatür Taraması.....	2
1.2. Tezin Kapsamı.....	9
1.3. Literatüre Katkı.....	9
1.4. Tezin Yapısı.....	10
2. ENERJİ KAYNAKLARI.....	11
2.1. Yenilenemez Enerji Kaynakları.....	12
2.2. Yenilenebilir Enerji Kaynakları.....	13
2.2.1. Hidrolik enerji.....	14
2.2.2. Jeotermal enerji.....	14
2.2.3. Biyokütle enerji.....	15
2.2.4. Rüzgâr enerjisi.....	15
2.2.5. Güneş enerjisi.....	16

3. GÜNEŞ ENERJİSİ ve ELEKTRİK ÜRETİMİ.....	19
3.1. Güneş Enerjisi.....	19
3.1.1. Dünya’da güneş enerjisi.....	19
3.1.2. Türkiye’de güneş enerjisi.....	21
3.1.3. Eskişehir’de güneş enerjisi.....	25
3.2. Güneş Enerjisi Elektrik Üretimi.....	29
3.2.1. Isıl güneş enerji teknolojisi.....	29
3.2.2. PV güneş enerji teknolojisi.....	31
4. MATERYAL ve METOT.....	34
4.1. Santral Özellikleri ve Üretim Değerleri.....	34
4.2. Meteoroloji Genel Müdürlüğü.....	35
4.3. Tahmin Modeli.....	38
4.3.1. DR modeli.....	39
4.3.2. RA modeli.....	41
4.3.3. DVM modeli.....	42
4.3.4. GSR modeli.....	44
4.4. Performans Değerlendirme Kriterleri.....	44
5. BULGULAR ve TARTIŞMA.....	47
6. SONUÇ ve ÖNERİLER.....	56
KAYNAKLAR.....	57
ÖZGEÇMİŞ.....	66

SİMGELER VE KISALTMALAR DİZİNİ

<i>GES</i>	: Güneş Enerji Santralleri
<i>SHT</i>	: Sayısal Hava Tahmini
<i>MGM</i>	: Meteoroloji Genel Müdürlüğü
<i>DR</i>	: Doğrusal Regresyon
<i>RA</i>	: Regresyon Ağacı
<i>DVM</i>	: Destek Vektör Makinesi
<i>GSR</i>	: Gauss Süreç Regresyonu
<i>RMSE</i>	: Kök Ortalama Kare Hata
<i>nRMSE</i>	: Normalize Kök Ortalama Kare Hata
<i>PRMSE</i>	: Kök Ortalama Kare Hata Yüzdesi
<i>MAE</i>	: Ortalama Mutlak Hata
<i>nMAE</i>	: Normalize Ortalama Mutlak Hata
<i>PMAE</i>	: Ortalama Mutlak Hataların Yüzdesi
<i>MBE</i>	: Ortalama Sapma Hatası
<i>nMBE</i>	: Normalize Ortalama Sapma Hatası
<i>MAPE</i>	: Ortalama Mutlak Hata Yüzdesi
<i>SMAPE</i>	: Simetrik Ortalama Hata Mutlak Yüzdesi
<i>R</i>	: Determinasyon Katsayısı
<i>SDE</i>	: Hata Standart Sapması

<i>PSDE</i>	: Hata Standart Sapma Yüzdesi
<i>MPE</i>	: Ortalama Yüzde Hatası
<i>MRE</i>	: Ortalama Bağlı Hatası
<i>MSE</i>	: Ortalama Hata Karesi
<i>HAT</i>	: Hava Araştırması ve Tahmini
<i>UKSB</i>	: Uzun Kısa Süreli Bellek
<i>YSA</i>	: Yapay Sinir Ağları
<i>ÜAHO</i>	: Üstel Ağırlıklı Hareketli Ortalama
<i>GD</i>	: Gauss Dağılım
<i>PV</i>	: Fotovoltaik
<i>GDOA</i>	: Girdiler ile Doğrusal Olmayan Ağ
<i>RES</i>	: Rüzgâr Enerjisi Santrali
<i>UEA</i>	: Uluslararası Enerji Ajansı
<i>VMD</i>	: Varyasyonel Mod Ayrıştırma
<i>KSA</i>	: Konvolüsyonel Sinir Ağı
<i>BGS</i>	: Benzer Gün Saptama
<i>OEHO</i>	: Otoresif Entegre Hareketli Ortalama
<i>İDA</i>	: İyileştirilmiş Derin Ağı
<i>ESA</i>	: Evrimsel Sinir Ağı
<i>MOEHO</i>	: Mevsimsel Otoresif Entegre Hareketli Ortalama
<i>ÇYT</i>	: Çekirdek Yoğunluğu Tahmini

SI	: Uluslararası Birim Sistemi
KTS	: Küresel Tahmin Sistemi
MM5	: Beşinci Orta Ölçekli Model
MTEP	: Milyon Ton Eşdeğer Petrol
AR-GE	: Araştırma ve Geliştirme
HES	: Hidroelektrik Santralleri
GEPA	: Güneş Enerjisi Potansiyeli Atlası
TÜBİTAK	: Türkiye Bilimsel ve Teknolojik Araştırma Kurumu
DA	: Doğru Akım
AA	: Alternatif Akım
WPD	: Web Plot Digitizer
C	: Karbon Atomu
S	: Kükürt Atomu
N	: Azot Atomu
μ	: Ortalama
m	: Medyan; Σ : Standart Sapma
σ	: Standart Sapma
σ^2	: Varyans

ŞEKİLLER DİZİNİ

Şekil 2.1 Enerji çeşitleri.....	11
Şekil 2.2 Dünya birincil enerji tüketim oranları (2018).....	12
Şekil 2.3 Küresel elektrik üretiminde yenilenebilir enerji oranı.....	17
Şekil 2.4 Türkiye elektrik üretiminde yenilenebilir enerji oranı.....	18
Şekil 3.1 Dünya güneş enerji potansiyeli.....	20
Şekil 3.2 Dünya yıllık güneş ilave kurulu gücü (GW).....	21
Şekil 3.3 Türkiye’de güneş enerjisi potansiyeli.....	22
Şekil 3.4 Türkiye aylık ortalama güneş radyasyon değeri (kWh/m ²).....	22
Şekil 3.5 Türkiye’de kurulu güce göre kaynak dağılımı.....	23
Şekil 3.6 Türkiye’de yıllara göre güneş enerjisi kurulu güç değişimi.....	24
Şekil 3.7 Türkiye’de yıllara göre güneş enerjisi kurulu güç içerisindeki oranı.....	25
Şekil 3.8 Eskişehir –Merkez toplam güneş radyasyonu.....	26
Şekil 3.9 Merkez güneş radyasyon değerleri (kWh/m ² -gün).....	26
Şekil 3.10 Merkez güneşlenme süreleri (saat).....	27
Şekil 3.11 Seyitgazi güneş radyasyon değerleri (kWh/m ² -gün).....	27
Şekil 3.12 Seyitgazi güneşlenme süreleri (saat).....	28
Şekil 3.13 Sivrihisar güneş radyasyon değerleri (kWh/m ² -gün).....	28
Şekil 3.14 Sivrihisar güneşlenme süreleri (saat).....	29
Şekil 3.15 a) Güneş bacası ve b) Güneş havuzları.....	30
Şekil 3.16 a) Parabolik çanak ve b) Merkezi alıcılı sistemler.....	30

Şekil 3.17 Örnek GES'ler: a) Çatı üstü GES, b) Yüzer GES, c) Güneş tarlası.....	31
Şekil 3.18 Güneş pillerinin yapısı.....	32
Şekil 3.19 Şebekeye bağlı GES'in enerji akış süreci.....	33
Şekil 4.1 KM güneş enerji santrali.....	34
Şekil 4.2 KM güneş enerji santrali saatlik güç değerleri.....	35
Şekil 4.3 Meteoroloji küresel ölçüm sistemi.....	36
Şekil 4.4 Meteoroloji otomatik ölçüm istasyonu.....	36
Şekil 4.5 Meteorolojik tahmin verisi alınan bölgeler ve GES.....	37
Şekil 4.6 SHT veri seti.....	38
Şekil 4.7 Tahmin modeli genel yapısı.....	39
Şekil 4.8 DR modelinde hata kavramı.....	40
Şekil 4.9 Örnek RA modeli.....	41
Şekil 4.10 DVM modeli.....	42
Şekil 4.11 Hard margin ve soft margin modeli.....	43
Şekil 4.12 C hiper parametre modeli.....	43
Şekil 5.1 24 Mayıs için Merkez bölgesi test sonuçları.....	49
Şekil 5.2 24 Mayıs için Seyitgazi bölgesi test sonuçları.....	50
Şekil 5.3 24 Mayıs için Sivrihisar bölgesi test sonuçları.....	51
Şekil 5.4 24 Mayıs için SHT verisiz test sonuçları.....	53
Şekil 5.5 Test sürecinde gerçekleşen üretimler ve GSR algoritması tahminleri.....	55

ÇİZELGELER DİZİNİ

Çizelge 4.1 Santral teknik bilgileri.....	34
Çizelge 4.2 Güç değerlerinin bazı istatistiksel özellikleri.....	35
Çizelge 4.3 Meteorolojik veri setinin bazı istatistiksel özellikleri.....	37
Çizelge 5.1 Performans testi sonuçları.....	47
Çizelge 5.2 24 Mayıs için 4 farklı makine öğrenmesi algoritmasının test sonuçları.....	52
Çizelge 5.3 24 Mayıs için 4 farklı makine öğrenmesi algoritmasının SHT verisiz test sonuçları.....	54

1. GİRİŞ

Günümüzde, dünyanın her yerinde enerji güncel bir sorundur. Enerji tüketim ihtiyacı; gelişen teknoloji ile beraber mevcut fosil yakıt rezervlerinin kullanılmasına, fosil yakıtların tüketilmesi ise çevrenin kirlenmesine ve ekolojik dengenin yok olmasına yol açacaktır. Bu durumun oluşması bilim adamlarını yenilenebilir ve temiz enerji kaynakları kullanımına teşvik etmiştir (Kök ve Yakıncı, 2017).

Diğer enerji kaynaklarına göre yenilenebilir enerji kaynakları daha ekonomik ve çevreye verdiği zarar daha azdır. Bu sebeple enerji tüketim ihtiyacının karşılanmasında kullanılan yöntemler içindeki payı her geçen yıl artmaktadır. Türkiye, yenilenebilir enerji kaynakları açısından yüksek potansiyele sahip olmak ile birlikte üretim açısından istenilen düzeyde değildir. Yenilenebilir enerji kaynaklarından elde edilen üretim payını arttırmak için ülkeler bu alana yönelik yatırımlarını geliştirmeli ve arttırmalıdır (Ataman, 2007) .

Günümüzde yenilenebilir enerji kaynakları içerisinde Güneş Enerji Santralleri (GES) önemli bir yere sahiptir. Fakat GES enerji üretimi değişkendir ve elektrik şebekelerindeki arz-talep dengesini etkilemektedir. Bu nedenle santralin üreteceği güç tahminlerine ihtiyaç duyulmaktadır (Taktak ve İlı, 2018). Bilindiği üzere elektriksel enerji gündelik hayatın olmazsa olmaz bir unsurudur. Bu nedenle çoğu ülkenin amaçlarından bir tanesi kullanıcılara kesintisiz, güvenilir ve kaliteli elektrik enerjisi tedarik etmek olacaktır. Bu durum elektrik arz sisteminin uygun şekilde planlanması ve yönetilmesi ile gerçekleşecektir. Elektrik arz sisteminin doğru planlanması ve yönetimi, etkili modelleme ve tahmin becerilerini kullanmayı gerektirmektedir. Daha iyi tahmin becerileri, daha verimli planlama, daha doğru zaman, maliyet ve performans yönünden daha doğru yatırımlar yapılması kullanıcıları memnun edecektir. GES enerji üretiminde ileriye dönük tahmin becerisi zor bir süreçtir ve çok karmaşık detayların göz ardı edilmemesi gerekmektedir.

GES üretim tahmini hem kısa dönem hem de uzun dönem yapılabilmektedir. Kısa dönem tahminler genellikle 24 saatten 1 haftaya kadar olan tahminlerden meydana gelmektedir. Bu kısa dönemli tahminler, üretim sistemlerinin işletilmesi, enerji piyasası, santral işletim planları, üretim ekonomisi ve serbest piyasada etkin fiyat teklifleri açısından önemli role sahiptir. GES sektörünün sahip olduğu birbirinden farklı alt sistemlere uyumlu olarak çalışabilecek tahmin modelleri geliştirmesi, GES sisteminin kendine has özelliklerinden dolayı zor olabilmektedir. Bugüne kadar GES üretim tahmini için birden çok tahmin yöntemi önerilmiştir. Ancak birçoğu belli bir alanda sınırlı kaldığı için dünyanın herhangi bir yerindeki GES üretim sisteminde kullanmak imkânsız hale gelmiştir. Her ülke

ve ortam şartları için uygun olan genel bir modelden söz etmek mümkün değildir. GES üretim tahminlerinin gerçekleştirilmesi için ülkelerin mevsimsel karakteristiği göz önüne alınmalıdır. Böylece, her ülkenin kendine ait özelliklerini içinde barındıracak yöntemlerin geliştirilmesi, GES üretim tahminlerinde daha doğru sonuçlar elde edilmesini sağlayacaktır. Bu tez çalışmasında konu ile ilgili bir literatür taraması yapılmıştır. Yapılan literatür taraması bir sonraki alt bölümde verilmiştir.

1.1. Literatür Taraması

Konuya dair yerli ve yabancı kaynaklarda yapılmış farklı çalışmalar yer almaktadır. Bazı önemli çalışmalar incelenerek özetlenmiştir.

Yumru çalışmasında, Orta Anadolu bölgesindeki binden fazla güneş enerjisi santralının kısa dönem güç üretim tahmini için Uzun Kısa Süreli Bellek (UKSB) ağı ile santral güç çıkışı ve SHT verilerinin kullanıldığı model geliştirilmiştir. Sonuçlar, derin öğrenme tekniklerinin klasik tahmin yöntemlerine göre daha iyi performansa sahip olduğu görülmüştür (Yumru, 2020).

Akbaba çalışmasında, son zamanlarda güneş enerjisi tahmin konusunda sıkça kullanılan Yapay Sinir Ağları (YSA) ile geleneksel yöntemler Ortalama Mutlak Hata (MAE), Kök Ortalama Kare Hata (RMSE), ve Determinasyon Katsayısı (R) performans değerlendirme kriterleri kullanılarak karşılaştırılmıştır. Birbirinden farklı girdiler, veri sayısı ve hesap hedefleri için yapılan değerlendirmede YSA'nın geleneksel metotlar ile benzer yönlerinin olduğu saptanmıştır. Sonuç olarak iki yöntem arasında çok az doğruluk farkının küçük limitler arasında kaldığı sonucuna varılmıştır (Akbaba, 2019).

Yavuz çalışmasında, Konya'da kısa dönem GES üretim tahmini için YSA ile geçmiş meteorolojik parametre veriler ve 24 adet GES santraline ait geçmiş üretim değerlerin kullanıldığı çeşitli yöntemler kıyaslanarak değerlendirilmiştir. YSA hava durumu şartlarına göre GES üretimlerinin yüksek hassasiyetle tahmin edilebileceği gösterilmiştir (Yavuz, 2018).

Kılıç çalışmasında, Güneydoğu Anadolu Bölgesindeki 5 ilin MGM'den alınan geçmiş meteorolojik parametre verileri kullanılarak güneş ışınımı ve güneşlenme süreleri için matematiksel tahmin modelleri geliştirilmeye çalışılmıştır. Tahmin modellerinde, Üstel Ağırlıklı Hareketli Ortalama (ÜAHO) ve Gauss Dağılımı (GD) beraber uygulanmıştır (Kılıç, 2016).

Okur çalışmasında, Akdeniz Bölgesi'nden seçilmiş 14 yerleşim yerinin aylık ortalama toplam güneş ışınımını tahmin etmek için YSA ve 1993-2010 yılları arasındaki

geçmiş meteorolojik parametre verileri birlikte kullanılarak model geliştirilmiştir. Çalışma sonucunda toplam güneş ışınım tahmini ile ölçülen değerlerin oldukça benzer olduğu görülmüştür (Okur, 2016) .

Nkurlyngoma çalışmasında, Kayseri ilindeki Fotovoltaik (PV) santrallerdeki kısa ve orta dönem güç üretim tahmini için geçmiş meteorolojik parametre verileri kullanılarak YSA temelli model geliştirilmeye çalışılmıştır. Modelde Girdiler ile Doğrusal Olmayan Ağ (GDOA) kullanılmıştır. Geliştirilen modelin performansı Normalize Kök Ortalama Kare Hata (nRMSE), Ortalama Sapma Hatası (MBE), MAE, Ortalama Hata Mutlak Yüzdesi (MAPE) performans değerlendirme kriterleri kullanılarak karşılaştırılmıştır. Sonuçlar, önerilen modelin tahmin performansının iyi olduğu ve diğer iller içinde uygulanabilir olduğu görülmüştür (Nkurlyngoma , 2018).

Kara çalışmasında, Çorum ilinde günlük güneş ışınım tahmin problemi için Temmuz-1983 ve Aralık-2018 aralığındaki geçmiş meteorolojik parametre verileri ile UKSB ağı kullanılarak model geliştirilmiştir. Önerilen model ile Karar Ağaçları Regresyonu, Rastgele Orman Regresyonu, Gradyan Güçlendirme ve K-En Yakın Komşu gibi makine öğrenmesi algoritmaları; Ortalama Hata Karesi (MSE), MAE, RMSE, MAPE ve R performans değerlendirme kriterleri kullanılarak karşılaştırılmıştır. Hesaplama sonuçları ile UKSB metodunun makine öğrenmesi algoritmalarından daha iyi performansının olduğu saptanmıştır (Kara, 2019).

Yıldız ve arkadaşlarının çalışmasında, Türkiye’de şebekeye bağlı 1 MW kurulu gücünde Rüzgâr Enerjisi Santrali (RES) üretim tahmini için 1 Ocak – 31 Aralık 2018 tarihleri arasındaki meteorolojik rüzgâr hızı, rüzgâr yönü ve rüzgâr gücü verileri kullanılarak Varyasyonel Mod Ayrıştırma (VMD) ve Konvolüsyonel Sinir Ağı (KSA) yöntemleri ile model geliştirilmiştir. Önerilen model ile SqueezeNet, GoogLeNet, ResNet gibi derin öğrenme yöntemleri; R, RMSE, MAE, Simetrik Ortalama Hata Mutlak Yüzdesi (SMAPE) performans değerlendirme kriterleri kullanılarak karşılaştırılmıştır. Sonuçlar, önerilen modelin daha iyi tahmin performansına sahip olduğunu göstermiştir (Yıldız ve ark. 2021).

Yıldız ve arkadaşının çalışmasında, Türkiye’de faaliyet gösteren bir 1 MW’lık kurulu güce sahip GES tesisinin kısa dönem güç üretim tahmini için bazı geçmiş bazı meteorolojik parametre verileri ile santral geçmiş güç değerlerinin kullanıldığı YSA tabanlı model geliştirilmiştir. Geliştirilen model ile geleneksel tahmin yöntemleri R, RMSE ve MAE performans değerlendirme kriterleri kullanılarak karşılaştırılmıştır. Sonuçlar, önerilen modelin daha güçlü ve güvenilir bir tahmin performansına sahip olduğunu göstermiştir (Yıldız ve Açıkgöz, 2020).

Gök çalışmasında, Kahramanmaraş ilinde bulunan GES tesislerinin kısa dönem üretim tahmini için santral geçmiş güç değerleri ile geçmiş Küresel Tahmin Sistemi (KTS) modelinden bulutluluk verisi kullanılarak YSA temelli bir model geliştirilmiştir. Geliştirilen model ile sadece geçmiş güç değerlerinin kullanıldığı model R ve MSE performans değerlendirme kriterleri kullanılarak karşılaştırılmıştır. Sonuçlar, geçmiş güç değerleri ile geçmiş meteorolojik parametresi bulutluluk verisinin birlikte kullanıldığı önerilen modelin tahmin performansının daha iyi olduğunu göstermiştir (Gök, 2019)

Larson ve arkadaşlarının çalışmasında 2011-2014 arasında California'daki 1MW gücünde iki tane PV tesisin geçmiş güç değerleri ve geçmiş meteorolojik parametre verileri kullanılarak saatlik tahmin modeli kullanılmıştır. Kullanılan modelde, 2011-2014 yılları arasında, iki tesis için performans değişkenliği ölçümleri ve tesislerin karşılaştırılmasında meydana gelen mekânsal hatalar vb. oluşabilecek standart hata ölçümleri MAE, MBE, nRMSE ve RMSE performans değerlendirme kriterleri kullanılarak karşılaştırılmıştır. Elde edilen sonuçlar önceki çalışmalara göre önerilen yöntemin performansı olumlu sonuç vermiştir (Larson ve ark. 2016) .

Yang çalışmasında Tayvan Merkez Hava Bürosu'nda bulunan GES saatlik üretim tahmini için geçmiş meteorolojik parametrelerden sıcaklık ve yağış verileri ile santralin geçmiş güç değerleri kullanılarak hibrit bir model geliştirilmiştir. Önerilen model, geleneksel tahmin yöntemleri ve YSA modeli ile karşılaştırılmıştır. Sonuçlar, hibrit modelin diğer modellere göre tahmin performansının daha iyi olduğunu göstermiştir (Yang, 2014).

Zhang ve arkadaşlarının çalışmasında üç farklı noktada bulunan PV santral geçmiş güç değerleri ve geçmiş meteorolojik parametre verileri kullanılarak kısa dönem güç tahmini için model önerilmiştir. Önerilen modelde Benzer Gün Saptama (BGS) motoru ve tahmin motoru kullanılmıştır. Sonuçlar, Normalize Ortalama Mutlak Hata (nMAE) ve nRMSE performans değerlendirme kriterleri kullanılarak elde edilmiştir. Tahmin verilerinde meydana gelen hataların oluşma sebebinin meteorolojik parametre verilerinde oluşan hatalardan kaynaklandığını göstermiştir (Zhang ve ark. 2015).

Kim ve arkadaşlarının çalışmasında PV sistemlerdeki kısa dönem güç tahmini için geçmiş meteorolojik parametrelerden bulutluluk ve sıcaklık verileri kullanılarak tahmin modeli önerilmiştir. Elde edilen sonuçlar ile önerilen model kullanılarak bir sonraki gün için güneş enerjisi üretimi tahmin edilebilmiştir. Model, Kore'de kullanılan güneş PV gözlem sistemine yerleştirilmiştir ve hâlihazırda kullanılan tahmin modelleri karşılaştırıldığında daha iyi performans gösterdiği görülmüştür (Kim ve ark. 2017).

Işık ve arkadaşının çalışmasında 2005-2009 yılları arasında Tunceli ilinde bulunan GES aylık güç üretim tahmini için MGM'den alınan geçmiş meteorolojik parametre verileri YSA yöntemi ile kullanılarak tahmin modeli önerilmiştir. Modelin performansı YSA parametreleri değiştirilerek ayarlanmıştır ve R performans değerlendirme kriteri kullanılarak değerlendirilmiştir. Sonuçlar önerilen modelin tahmin performansının yüksek olduğunu göstermiştir (Işık ve İnallı, 2011).

Zhang ve arkadaşlarının çalışmasında kısa dönem PV güç üretim tahmini için VMD, Otoregresif Entegre Hareketli Ortalama (OEHO) ve İyileştirilmiş Derin Ağı (İDA) yöntemleri birlikte kullanılarak bir hibrit model önerilmiştir. Önerilen hibrit modelin çalışması RMSE, MAE ve MAPE parametreleri ile değerlendirilmiştir. Sonuçlar, önerilen modelin tahmin performansını diğer geleneksel tahmin yöntemlerine göre daha iyi olduğunu göstermiştir (Zhang ve ark. 2019).

Wang ve arkadaşlarının çalışmasında PV sistemlerinde güç tahmini için derin öğrenme modeli kullanılarak hibrit tahmin modeli önerilmiştir. Önerilen hibrit modeli ile UKSB ve Evrişimsel Sınır Ağı (ESA) modelleri MAE, MAPE, RMSE, Hata Standart Sapması (SDE), Ortalama Mutlak Hataların Yüzdesi (PMAE), Hata Kareleri Karekökünün Yüzdesi (PRMSE) ve Hata Standart Sapma Yüzdesi (PSDE) performans değerlendirme kriterleri kullanılarak karşılaştırılmıştır. Sonuçlar, önerilen hibrit modelin daha iyi olduğunu göstermektedir (Wang ve ark. 2019).

Jimenez ve arkadaşlarının çalışmasında PV sistemlerinde güç tahmini için santralin geçmiş güç değerleri ile KTS ve Beşinci Orta Ölçekli Model (MM5)'den elde edilen SHT verileri kullanılarak YSA tabanlı modelden oluşan tahmin modeli geliştirilmiştir. Önerilen modelin çalışması RMSE, nRMSE, MAE, nMAE performans değerlendirme kriterleri kullanılarak değerlendirilmiştir. Önerilen model, santralin bakım çalışmalarının belirlenmesi ve elektrik piyasa tekliflerinin hazırlanması için de önerilmektedir (Jimenez ve ark. 2021).

Wang ve arkadaşlarının çalışmasında güç sistemlerindeki PV güç kullanımının olumsuz etkisini azaltmak için, geçmiş meteorolojik parametre verileri ile santral geçmiş güç değerleri kullanılarak kısa süreli güç tahmin modeli önerilmiştir. Önerilen modelin çalışması nRMSE ve MAPE performans değerlendirme kriterleri kullanılarak değerlendirilmiştir. Sonuçlar, modelin yüksek doğruluk tahmini ve güç dağıtım sistemini birçok yönden olumlu katkıları olacağını göstermiştir (Wang ve ark. 2017).

Khatib çalışmasında, meteorolojik parametrelerden güneşlenme oranı, gün sayısı ve konum koordinatları kullanılarak güneş radyasyonu tahmin eden YSA tabanlı tahmin modeli önermiştir. Bununla birlikte, önerilen modelin çalışması RMSE, MAE ve R

performans değerlendirme parametreleri ile değerlendirilmiştir. Tahmin modeli ile elde edilen sonuçlara dayalı olarak, geliştirilen model yüksek doğruluk tahmin değerine sahip olduğu gözlemlenmiştir (Khatib, 2015).

Almonacid ve arkadaşlarının çalışmasında PV güç tahmini için geçmiş meteorolojik parametresinden sıcaklık verisi kullanılarak YSA tabanlı kısa süreli tahmin modeli önerilmiştir. Sonuçlar, önerilen modelin PV sistemlerin güç çıkışını kabul edilebilir bir doğruluk derecesi ile bir saat önceden tahmin etmek için kullanılabileceğini göstermektedir (Almonacid ve ark. 2014).

Bouzerdoum ve arkadaşlarının çalışmasında, PV sistemlerdeki kısa süreli güç tahmin modeli için Mevsimsel Ototegresif Entegre Hareketli Ortalama (MOEHO) ve DVR kullanılan bir hibrit model önerilmiştir. Çalışmada tahmin modeli için MOEHO ve DVR ayrı ayrı kullanılmış ve elde edilen sonuçlar ile hibrit model R, nRMSE, Normalleştirilmiş Ortalama Sapma Hatası (nMBE) ve Ortalama Yüzde Hatası (MPE) performans değerlendirme parametreleri ile karşılaştırılmıştır. Sonuçlar, geliştirilen hibrit modelin yüksek doğruluk tahmin değerine sahip olduğu göstermiştir. Ayrıca geliştirilen hibrit modelin hem MOEHO hem de DVR modelinden daha iyi performans gösterdiği görülmüştür (Bouzerdoum ve ark. 2013).

Liu ve arkadaşlarının çalışmasında, 15 kW güç kapasitesine sahip PV santrali için kısa süreli Çekirdek Yoğunluğu Tahmini (ÇYT) tabanlı model önerilmiştir. Elde edilen tahminlerin belirsizliğini ölçmek için modele farklı sinir ağları eklenmiş ve önerilmiştir. Sonuçlar, önerilen modelin kısa vadeli PV güç çıkışlarının ve ilgili belirsizliklerin tahmini açısından geleneksel tahmin yöntemlerinden daha iyi performans gösterdiğini göstermektedir (Liu ve ark. 2018)

Akarşan çalışmasında, saatlik güneş ışıma değerlerinin tahmini için üç yeni metot önerilmiştir. Bu metotlardan ilki, Afyonkarahisar iline ait saatlik güneş ışıma verileri için çok boyutlu doğrusal tahmin filtreleri kullanılmıştır ve iki boyutlu filtreler ile karşılaştırılmıştır. Önerilen model ile daha doğru sonuçlar gözlenirken, tahmin doğruluk değerleri %1'den %40'a kadar olan oranlarda gelişme göstermiştir. Diğer bir metotta Afyonkarahisar, Ankara ve Çanakkale illerine ait güneş ışıma değerleri bilinen modeller kullanılarak güneş ışıma tahmini yapılmıştır. Önerilen model Angstrom-PreScott eşitliklerinden oluşan tahmin değerleri ile karşılaştırılmıştır. Önerilen model daha başarılı sonuçlar elde edilmiştir. Üçüncü yöntemde benzerliğe dayanan, geçmiş meteorolojik parametre verileri ile tahmin yapılmak istenen güneş ışıma değerleri arasında benzerliğe dayalı ilişki kurularak belirlenmiştir. Farklı güneş ışıma özelliklerine sahip 5

farklı şehre ait güneş ışınım verileri ile uygulanan çalışmaların çalışması RMSE, MBE ve R performans değerlendirme kriterleri ile karşılaştırılmış ve önerilen modelin oldukça iyi tahmin becerilerine sahip olduğu görülmüştür (Akarslan, 2014).

Bekçioğulları çalışmasında, PV sistemlerdeki geçmiş güç değerleri ile geçmiş meteorolojik parametre verilerinden oluşturulan mevsimsel veri setleri , kısa süreli güneş enerjisi tahmini için kullanılarak derin öğrenme tabanlı UKSB tahmin modelini önerilmiştir.UKSB modeli ile diğer makine öğrenme tahmin yöntemleri R,RMSE ve MAE kullanılarak karşılaştırılmıştır. Sonuçlar, derin öğrenme tabanlı UKSB yöntemi daha üstün ve güvenilir tahmin performansı sergilediği performans ölçütlerindeki sonuçlar ile gösterilmiştir (Bekçioğulları, 2022).

Çetin çalışmasında, PV sistemlerdeki geçmiş güç değerleri ile geçmiş meteorolojik parametre verileri kullanılarak UKSB yöntemi YSA tabanlı aylık güç tahmin modeli önerilmiştir. Yapılan analizler sonucunda %1 ile %17 arasında hata oranı ile karşılaşılmıştır. Bu oranın diğer yapay zekâ algoritma tahminlerine karşın çok daha başarılı olduğu görülmüştür (Çetin, 2022).

Genç çalışmasında, Osmaniye'deki yatay yüzeye gelen güneş enerji potansiyeli tahmini için 21.06.2012-2013 tarihine kadar 5 er dakikalık zaman aralığındaki meteorolojik parametre verileri kullanılarak model geliştirilmiştir. Önerilen model farklı dokuz modelle karşılaştırılması yapılmıştır. Modellerin performans analizlerini göstermek için MBE, RMSE ve Ortalama Bağıl Hatası (MRE) performans değerlendirme kriterleri kullanılmıştır. Sonuçlar, önerilen modelin güneş ışınım verileri tahmininde oldukça kabul edilebilir düzeyde olduğu görülmüştür (Genç, 2015).

Kader çalışmasında, güneş radyasyonunun tahmini için 2012-2017 yılları arasında Şanlıurfa, Adıyaman, Diyarbakır, Gaziantep ve Hatay illerindeki ölçüm merkezlerinden alınan 10 dakikalık geçmiş güç değerleri ve meteorolojik parametre verileri kullanılarak 3 farklı yöntem ile tahmin modelleri önerilmiştir. Önerilen tahmin modellerinin birincisi, doğrusal sistem tanılama yöntemleri dışsal kaynaklı otoregresif ve Box-Jenkins'ten oluşmaktadır. Önerilen tahmin modellerinin ikincisi, DVM kullanılarak oluşturulan doğrusal olmayan güneş radyasyonu tahmin modelidir. Önerilen tahmin modellerinin üçüncüsü ise UKSB yöntemi kullanılarak oluşturulmuştur. Tahmin modelleri R, MAE, RMSE ve nRMSE kullanılarak karşılaştırılmıştır. Sonuçlarda en iyi performansa sahip model UKSB olduğu görülmüştür (Kader, 2022)

Kayri çalışmasında, Batman ilindeki PV sistemlerin geçmiş güç değerleri ve geçmiş meteorolojik parametre verileri kullanılarak YSA tabanlı tahmin modeli önerilmiştir.

Modelde DR kullanılmıştır. Elde edilen tahmin değerler ile ölçülmüş değerler R ve RMSE kullanılarak karşılaştırılmıştır. Sonuçlar, modelin yüksek bir doğrulukla güç üretim değerlerini tahmin edebildiğini göstermiştir (Kayri, 2017).

Kıymaz çalışmasında, Konya'da 1MW kapasiteli PV tesislerine ait günlük frekanslı 2 yıllık üç veri seti ve saatlik frekanslı 1 yıllık bir veri seti ile model geliştirilmiştir. Model de UKSB ve MOEHO kullanılmış ve MSE, RMSE, nMSE, MAE, MAPE hata performansları ile karşılaştırılmıştır. UKSB modelinin MOEHO modeline kıyasla doğru değerlere daha çok yaklaştığı görülmüştür (Kıymaz, 2020).

Maham çalışmasında, Mardin ilindeki PV sistemlerinin güç üretim tahmini için 2013-2014 yılları arasındaki meteorolojik parametre verileri kullanılarak hibrit bir tahmin modeli geliştirilmiştir. Geliştirilen model YSA, GDOA ve Ridge regresyon yöntemleri ile kullanılmıştır. Sonuçlarda, önerilen hibrit modelin her biri ile kullanılan modele göre daha iyi tahmin performansı gösterdiği saptanmıştır (Maham, 2022)

Oruç çalışmasında, Elâzığ'da bulunan PV santralleri için kısa-orta dönem tahmin modeli geçmiş meteorolojik parametre verileri kullanılarak YSA tabanlı model geliştirilmiştir. Model performansı 1-2-3 ve 4 saat sonrası tahmini için test edilmiştir. YSA tabanlı olmasının katkısını kıyaslamak için model DR tabanlı olarak kullanılmıştır ve R, MAE, MSE ve RMSE kullanılarak karşılaştırılmıştır. Tüm zamanlar için YSA mimarisinin daha iyi performans sergilediği tespit edilmiştir (Oruç, 2021).

Serttaş çalışmasında, Afyonkarahisar ve Antalya Bölgesinde güneş ışınımı tahmini için, 2 yıllık ve 4 yıllık geçmiş güneş ışınım verileri Mycielski öngörü yöntemi ile kullanılarak 2 boyutlu hibrit model geliştirilmiştir. Sonuçlar, önerilen hibrit tahmin modelinin gelenekler tahmin modellerine göre daha iyi performansa sahip olduğunu göstermiştir (Serttaş, 2015)

Ahmed ve arkadaşlarının çalışmasında, GES üretimlerinin kısa dönem tahmini için meteorolojik parametre bulutluluk verisi kullanılarak YSA tabanlı hibrit model önerilmiştir. Model performansı MAE, RMSE ve MAPE kullanılarak değerlendirilmiştir. Modelde ESA algoritması kullanılmıştır. Elde edilen sonuçlar, özellikle hibrit yapay sinir ağları ve evrimsel algoritmaların kullanımında, önerilen hibrit modelin tahmin performansının iyi olduğunu göstermiştir (Ahmed ve ark. 2020).

Gök ve arkadaşlarının çalışmasında gün öncesi GES üretim tahmini için KTS modelinden elde edilen bulutluluk verisi ve geçmiş güç değerleri kullanılarak YSA temelli bir model geliştirilmiştir. Önerilen model ile sadece geçmiş güç değerinin kullanıldığı YSA

modeli MSE ve R performans değerlendirme kriterleri kullanılarak karşılaştırılmıştır ve önerilen modelin performansının daha iyi olduğu görülmüştür (Gök ve ark. 2019).

Literatür değerlendirildiğinde, GES'lerin üretim tahmini konusunda yapılan çalışmaların çoğunda geçmiş meteorolojik parametre verileri kullanıldığı görülmüştür (Işık ve İnallı, 2011; Kılıç, 2013; Akarslan, 2014; Yang, 2014; Khatib, 2015; Gök, 2019; Larson ve ark. 2016; Okur, 2016; Kim ve ark. 2017; Nkurlyngoma, 2018; Yavuz, 2018; Kara, 2019; Ahmed ve ark. 2020; Yıldız ve Açıkgöz, 2020; Yumru, 2020; Oruç, 2021; Yıldız ve ark. 2021; Bekçioğulları, 2022; Maham, 2022).

Literatürdeki çalışmaların çok azında SHT verileri kullanılmıştır (Gök ve ark. 2019; Yumru, 2020; Jimenez ve ark. 2021).

(Jimenez ve ark. 2021) çalışmasında SHT verilerini KTS ve MM5 modellerinden, (Gök ve ark. 2019; Gök, 2019; Yumru, 2020) ise KTS modelinden elde etmiştir. KTS modelinin düşük çözünürlükte meteorolojik tahmin çıktısı verdiği bilinmektedir.

1.2. Tezin Kapsamı

Bu çalışmada Eskişehir ilinde bulunan, şebekeye 1 (MW) güç ile bağlı GES sisteminin 22.03.21-13.06.21 aralığındaki güç üretim değerleri ile aynı zaman dilimindeki SHT verileri, kullanılarak tahmin modelleri geliştirilmiştir. Çalışmada kullanılan SHT verileri Meteoroloji Genel Müdürlüğünden (MGM) alınmıştır. MGM'den resim formatında alınan SHT verisindeki sıcaklık, bulutluluk, yağış ve rüzgâr hızı değerleri sayısal verilere dönüştürülmüş ve önerilen tahmin modelinde kullanılmıştır. Tahmin modellerinde girdi olarak santralin geçmiş güç değerleri ve elde edilen sayısal değerler kullanılıp 24 saatlik zaman ufkunda santralin ne kadar güç üreteceği tahmin edilmiştir. Elde edilen tahmin değerlerinin değerlendirilmesinde, literatürde yaygın olarak kullanılan RMSE, MAE ve R performans değerlendirme kriterleri kullanılmıştır.

1.3. Literatüre Katkı

Çalışmanın literatüre katkısı üç yönlü olmuştur:

1. Makine öğrenmesi temelli tahmin modeli geliştirme çalışmalarında kullanılan veri setleri tahmin başarısını büyük oranda etkilemektedir. Bu tez çalışmasında, GES üretimlerinin kısa dönem (24 saat öncesinden) tahmini için geçmiş üretim ve yüksek kaliteli yerel (Eskişehir ili için) meteorolojik parametre tahmin verilerini içeren bir veri seti oluşturulmuştur.

2. Tez çalışmasında oluşturulan veri seti üzerinde dört farklı makine öğrenmesi algoritması; Doğrusal Regresyon (DR), Regresyon Ağacı (RA), Destek Vektör Makinesi (DVM) ve Gauss Süreç Regresyonu (GSR) kıyaslanarak değerlendirilmiştir.

3. GES üretim karakteristikleri ve tahmin edilebilirlikleri iklimsel koşullara bağlıdır. Bu sebeple farklı iklimsel koşullara sahip bölgelerde GES üretim tahmini modellerinin performansları değişmektedir. Bu çalışmada geliştirilen tahmin modellerinin performansları Eskişehir ilindeki koşullar altında değerlendirilmiştir.

1.4. Tezin Yapısı

Bu tez altı bölümden oluşmaktadır. Konuyla ilgili genel bilgilerden oluşan birinci bölümde, literatürün kısa bir özetine ve çalışmanın literatüre katkısına yer verilmiştir. İkinci kısımda enerji kaynakları ve güneş enerjisinin önemine değinilmiştir. Üçüncü bölümde güneş enerjisinin yapısı ve elektrik enerjisi elde edilmesinden bahsedilmiştir. Dördüncü bölümde çalışma kapsamında kullanılan veriler tanıtılmıştır. Beşinci bölümde çalışma sonunda elde edilen bulgular değerlendirilmiştir. Bulgular ışığında varılan sonuçlar son bölümde bulunmaktadır.

2. ENERJİ KAYNAKLARI

Enerji; Fizik bilim dalında doğrudan doğruya gözlenemeyen ancak dolaylı olarak gözlenebilen bir nicelik olarak kabul edilmektedir. Bir fiziksel sistemin başka bir fiziksel sisteme karşı çalışabilme yeteneği olarak tanımlanmıştır (Web 1).

1650'lerde Yunanca "energeia" olarak anılan enerji, daha sonra 1660'ların başında İngilizce 'de güç ifadesini de içeren bir nicelik olarak kullanılmıştır. Enerjinin birçok formu vardır. Bunlar; Kinetik, potansiyel, elektrik, ısı, ışık, yer çekimi, ses ve elektromanyetik enerji biçimleridir. Şekil 2.1'de enerji çeşitleri verilmiştir (Niele, 2005). (Kayri , 2017).




Şekil 2.1. Enerji çeşitleri

Termodinamiğin birinci yasası, izole bir ortamda enerji yok olmaz sadece enerji türleri arasında dönüşümler olduğunu söylemektedir. Doğal ve türetilmiş enerjiler arasında dönüşüm mümkündür. Enerji skaler bir niceliktir ve Uluslararası Birim Sistemi (SI)'ya göre birimi Joule (J)'dür (Kayri , 2017).

Dünya, hızlı nüfus artışı ve teknolojinin gelişmesi ile insanların enerjiye olan gereksinimi artmaktadır. 1970'lerde ortaya çıkan petrol krizi, dünyada ve ülkemizde enerjinin öneminin daha net anlaşılmasında rol almıştır. 1970'li yıllardan itibaren dünyada birçok ülke enerji kaynağı türlerini arttırmak ve bu kaynaklara ek olarak alternatif enerji kaynaklarının kullanılması yönünde önemli yatırımlar yapmışlardır. Geçmiş yıllara göre 2000'lerde alternatif enerji kaynaklarına erişim ve kullanılması amacıyla arama çalışmaları da hızlanmıştır (Gök ve ark. 2019).

Günümüzde işletmelerde kullanılan enerjinin büyük bir bölümü birincil enerji kaynaklarından oluşmaktadır. 2018 yılında elde edilen veriler ışığında, dünyada kullanılan toplam birincil enerji 14314,0 Mtep (milyon ton eşdeğer petrol) olduğu, kullanılan enerjinin kaynak dağılımı Şekil 2.2’de verilmiştir. Görüldüğü üzere, dünyada tüketilen birincil enerji dağılımında en çoktan en aza sırasıyla, petrol (%31), kömür (%27), doğal gaz (%23), hidroelektrik enerji (%3), nükleer enerji (%5) ve diğer yenilenebilir enerji kaynaklarının (%11) değerinde olduğu görülmektedir. Diğer yenilenebilir enerji kaynaklarını rüzgâr, güneş, biyokütle ve jeotermal enerji oluşturmaktadır (Yılmaz, 2016).



Şekil 2.2. Dünya birincil enerji tüketim oranları (2018)

Enerji kaynakları kullanımına göre 2 gruba ayrılmaktadır. Bunlar Yenilenebilir ve Yenilenemez enerji kaynaklarıdır.

2.1. Yenilenemez Enerji Kaynakları

Yenilenemez Enerji; tekrar dönüştürülemeyen, tüketim ihtiyaçlarını karşılamaya yetecek miktarda üretilmeyen veya yeniden kullanılamayan doğal kaynaklardan oluşan enerjiye denir. Yenilenemeyen enerji kaynaklarının enerji üretim hızı, tüketim talebini karşılayamamaktadır ve evrende kısıtlı sayıda bulunan kaynaklardır (Web 2).

Yenilenemez enerji kaynakları iki ana başlıkta söylemek mümkündür. Bunlar fosil yakıtlar ve nükleer enerjidir.

Fosil yakıtların temel yapısında karbon atomu (C) bulunmaktadır. Genelde canlı kalıntılarından oluşan bu enerji kaynakları arasında doğalgaz, petrol, kömür bulunmaktadır. Fosil yakıtlar kullanım alanı olarak akaryakıt, ısınma gibi ihtiyaçlar için kullanılmaktadır.

Aynı zamanda elektrik üretiminde de yoğun olarak kullanılsa da çevreye verdiği zarardan dolayı kullanımını tasvip edilmemektedir (Çetin, 2022).

Nükleer enerji ise maddenin en küçük yapı taşı olan atomun çekirdeğinden meydana gelmektedir. Nükleer enerji endüstri, sağlık, tarım, araştırma geliştirme gibi birçok farklı alanda kullanılmaktadır (Web 2) (Kılıç, 2016).

Yenilenemeyen enerji kaynakları sınırlı miktarda olmasının yanında yerkürenin belirli yerlerinde düzensiz şekilde bulunmaktadır. Bu kaynakların oluşabilmesi için toprağın bazı jeolojik özelliklere sahip olması gerekmektedir. Yapılarında bulunan kükürt (S), karbon (C) ve azot (N) atomlarından dolayı kullanıldıklarında çevreye zarar verirler. Miktar ve enerji potansiyeli açısından yenilenebilir enerji kaynaklarına oranla daha dengeli yapıya sahiplerdir (Web 2).

Artan nüfus ve devam eden sanayileşme ile birlikte enerjiye olan ihtiyaç her geçen zaman artmaktadır. Öte yandan, enerji talebinin büyük bir bölümünü oluşturan fosil kaynaklı yakıt rezervleri hızla azalmaktadır. Fosil kaynaklı enerji rezervlerinin bu şekilde azalması enerji ihtiyacını karşılayamayacak düzeye gelmesi beklenmektedir (Görez ve Alkan, 2005).

Fosil kökenli yakıtların kullanımı; atmosferde sera gazının oluşmasına, ortalama sıcaklık değerlerinin artmasına ve buna bağlı olarak doğal afetlerin oluşmasına sebep olmaktadır. Bu olumsuzluklar göz önüne alındığında; yenilenemez enerji kaynaklarının tüketiminden meydana gelen olumsuz sonuçların azaltılması yönünde çalışmalar devam etmektedir. Bununla beraber çevreye ve iklime duyarlı alternatif enerji kaynakları geliştirilmektedir (Kılıç , 2016; Kayri , 2017).

2.2. Yenilenebilir Enerji Kaynakları

Yenilenebilir enerji, doğal kaynaklardan oluşan ve kendini devamlı yenileyen enerji kaynağıdır. Yenilenebilir enerjinin diğer enerji kaynaklarından farkı kendini doğal yollarla yenileyebilmesi ve kullanımında tükenmemesidir. Yenilenebilir enerji; gelişmiş ve gelişmekte olan ülkelerin kendi enerji ihtiyaçlarını karşılaması, dışa bağımlılığını azaltması, enerji sektöründe söz sahibi olması, enerji kaynak türlerinin çeşitlenmesi ile devamlı enerji temin etmesi ve enerji tüketiminin beraberinde getirdiği çevresel kirliliğin en aza indirilmesinde çok önemli rol oynamaktadır (Kayri , 2017; Gök ve ark. 2019).

Yenilenebilir enerjinin üretim ve tüketim oranları; alanında yapılan yatırımlar, Araştırma ve Geliştirme (AR-GE) çalışmaları ve teknolojik gelişmeler sayesinde fosil yakıtlara göre enerji piyasasındaki yeri gün geçtikçe artmaktadır.

2016 yılının nisan ayında yapılan Paris Anlaşması ile birçok ülke fosil yakıt kullanımının azaltılması konusunda anlaşmaya varmıştır. Yapılan anlaşma sonucu kademeli olarak fosil yakıt kullanımının azaltılacağı kararı alınmıştır. Ülkelerin enerji ihtiyacı karşılamada yenilenebilir enerjiyi kullanmaya yönelik teşvikleri bu çerçevede artmaya başlamıştır (Antonanzas ve ark. 2016).

Fosil kökenli yakıtlara alternatifi olarak düşünülen ve dünya da en çok kullanılan yenilenebilir enerji kaynakları; hidrolik enerji, jeotermal enerji, biokütle enerjisi, rüzgâr enerjisi ve güneş enerjisidir.

2.1.1. Hidrolik enerji

Hidrolik enerji, suyun akışından ve düşme hızından kaynaklı oluşan bir enerji türüdür. Su enerjisinin elektrik enerjisine dönüştürülmesi ile elde edilmektedir.

Hidrolik enerjinin en çok kullanıldığı alanlardan birisi, akarsuların üzerine barajlar yapılarak suyun havuzda depolanması ve depolanan suyun sahip olduğu kinetik enerjiden faydalanılarak türbinler yardımı ile elektrik enerjisi üretilmesidir. Bu doğrultuda yapılan sistemlere Hidroelektrik Santral (HES) olarak adlandırılmaktadır (Süme ve Fırat, 2020).

Hidrolik enerji, diğer yenilenebilir enerji kaynaklarına göre daha ucuz olması nedeniyle dünyada en yaygın kullanılan yenilenebilir enerji kaynağıdır. Ancak hidrolik enerji üretiminde ülkelerin sahip olduğu fiziksel özellikler çok önemlidir. Bu enerji türünün potansiyeli açısından, engebeli arazilere ve sulak bölgelere sahip ülkeler avantajlıdır. Bu özellikleri sahip olan ülkemizde hidrolik enerji önemli bir kapasiteye sahiptir (Karadöl ve Kavaz, 2017).

2.1.2. Jeotermal enerji

Jeotermal enerji; yeryüzünün bazı ögelerinde yoğunlaşmış, kendiliğinden ısınan, yer kabuğunun derinliklerinde depolanmış basınç altındaki sıcak su, buhar, gaz ve sıcak kuru kayaların oluşturduğu termal enerji kaynağıdır.

Jeotermal enerji; maliyetinin düşük olması, çevresel sürdürülebilirliği ve enerji güvenliğine katkısı nedeniyle elektrik enerjisi üretimi ya da ısıtma amacıyla kullanılmaktadır. Jeotermal enerjinin, hava şartlarına bağlı olan rüzgâr ve güneş gibi

yenilenebilir enerji kaynakları söz konusu olduğunda en önemli avantajı iklim şartlarından etkilenmemesidir. Bunlardan dolayı jeotermal enerji ülkelerin ciddiye aldığı ve kullanılmasını teşvik ettiği bir yenilenebilir enerji türüdür.

Birçok ülke coğrafi yerküre özellikleri nedeniyle jeotermal enerjiden çok fazla faydalanmaktadır. Son zamanlarda Türkiye'deki jeotermal enerjinin kurulu güç içindeki payı hızlı bir şekilde artmaktadır (Koç ve Kaya, 2015; Karadöl ve Kavaz, 2017).

2.1.3. Biyokütle enerji

Biyokütle enerjisi, yapısında karbonhidrat bileşikleri bulunan bitki ve hayvan kaynaklı maddelerden elde edilen enerji kaynağıdır. Henüz fosilleşmemiş canlı kalıntılarından elde edilen enerjidir.

Günümüzde biyokütle enerji kaynakları birçok alanda kullanılmaktadır. Yakıt alanında; bioetanol, biyodizel ve biyogaz gibi yakıtlar biyokütle enerji kaynağından elde edilmektedir. Bioetanol ve biyodizel, çeşitli bitkisel veya hayvansal yağlardan elde edilmektedir. Biyogaz ise organik atıkların oksijenin olmadığı ortamda fermantasyonu sonucunda çok fazla metan ve karbondioksit gazından oluşmaktadır. Ayrıca ısınma, enerji ve ulaşım gibi birçok farklı alanda da biyokütle enerji kaynaklarından faydalanılmaktadır.

Son zamanlarda bazı ülkelerin enerji ihtiyaçları ve çevresel hedeflerine ulaşma isteği biyoenerji üretiminde artışa neden olmuştur. Fakat son dönemde biyoenerji sektörü, yaşanan piyasadaki düşen petrol fiyatları ve mevcut pazardaki siyasi belirsizlikler nedeniyle bazı zorluklar ile karşı karşıya kalmıştır.

Dünya genelindeki biyokütle enerjisi üretimine bakıldığında yenilenebilir enerji üretim payındaki yeri gittikçe artmaktadır. Türkiye de organik atık, biyokütle ve biyogazdan enerji üretimine yönelik kamu ve özel sektör yatırımları son dönemde artmasına rağmen ülkemizde büyük bir potansiyele sahip olan biokütle kaynakları yeterince kullanılmamaktadır (Koç ve Kaya, 2015).

2.1.4. Rüzgâr enerjisi

Rüzgâr enerjisi, güneş radyasyonunun yerküreyi birbirinden farklı derecelerde ısıtması ile oluşmaktadır. Okyanusların ve havanın farklı sıcaklık derecelerine sahip olmasından kaynaklanan basınç farkı, havanın hareket etmesine neden olmaktadır. Yüksek basınçtan alçak basınca doğru akan havanın bu hareketi rüzgâr olarak adlandırılmaktadır.

Rüzgâr enerjisi, mekanik enerji veya elektrik enerjisi üretmek için kullanılmaktadır. Sulama amacıyla mekanik enerjiden, elektrik enerjisi üretmek için de RES'lerden yararlanılmaktadır.

Rüzgâr enerjisinin elektrik üretimindeki kullanım payı her geçen gün yükselmektedir. Uluslararası Enerji Ajansı (UEA) 'na göre 2050 yılına kadar dünya elektriğinin yaklaşık yüzde 18'inin rüzgâr enerjisinden sağlanacağı ön görülmektedir. Mevcut toplam kapasitenin sekiz ila on kat artması için ve bu alandaki yatırımlara önem verilmelidir. Kısacası birçok ülke rüzgâr enerjisini uygun ve ekonomik bir enerji kaynağı haline getirmeye çalışmaktadır.

Dünya da ve Türkiye'de mevcut potansiyelin %10'unun bile faaliyete geçirilemediği göz önüne alınacak olursa rüzgâr enerjisi potansiyelinden yeterince yararlanılmadığı görülmektedir (Koç ve Kaya, 2015).

2.1.5. Güneş enerjisi

Güneş enerjisi, güneş sistemindeki gezegenler için ana enerji kaynağıdır. Dünyada en çok kullanılan yenilenebilir enerji kaynaklarından birisi olan güneş enerjisi, son zamanlarda yapılan yatırımların artması ve bu alanda teknolojik maliyetlerin azalması ile giderek yaygınlaşmaktadır. Ülkeler güneş enerjisini, önemli bir yenilenebilir enerji kaynağı olarak değerlendirmektedir.


Güneş enerjisi, elektrik ve ısı elde etmek için kullanılmaktadır. Güneş ışınları vasıtasıyla yerküreye ulaşan enerjiden faydalanmak için güneş kolektörleri, güneş enerjisi santralleri ve güneş hücreleri (PV piller) gibi teknolojiler geliştirilmiştir. Bu teknolojiler sayesinde güneş enerjisi doğrudan ısı enerjisi olarak veya dolaylı olarak elektrik enerjisine dönüştürülerek kullanılabilir.

Dünyada yoğunlaştırılmış güneş enerjisi toplam kapasitesi bakımından İspanya ilk sıradadır. Son on yıldaki Türkiye'nin güneş enerjisi kurulu güç kapasitesi, geçmiş yıllara göre artış göstermiştir. Türkiye'nin güneş enerji potansiyeli, sahip olduğu coğrafi konumdan dolayı İspanya dışındaki tüm Avrupa ülkelerinden daha fazladır. Ancak Türkiye' de elektrik üretim maliyetlerinin yüksek olması nedeniyle sıcak su ısıtma sistemlerinde (güneş kolektörleri) yaygın olarak kullanılmaktadır.

Güneş enerjisinden daha fazla faydalanmak için çeşitli çalışmalar yapılmaktadır. Güneş pili üretim maliyetindeki düşüş ve teşvikler nedeniyle yakın gelecekte güneş


enerjisinden elektrik üretiminin Dünya’da ve Türkiye’de artması beklenmektedir (Karadöl ve Kavaz, 2017).

Enerji talebini karşılayan en önemli kaynaklardan birisi, yenilenebilir enerji kaynaklarından elde edilen elektrik enerjisidir. Bundan dolayı yenilenebilir enerji kaynaklarının elektrik enerjisi üretimdeki toplam payı giderek büyümektedir. Toplam küresel elektrik üretiminin %23,7’si yenilenebilir kaynaklardan sağlanmaktadır. Şekil 2.3.’de gösterildiği gibi bu oranın %16,6’lık kısmı hidroelektrik santralleri, %3,7’si rüzgâr, %2’lik kısmı biyoenerji, %1’i PV güneş sistemleri ve %0,4’ü ise jeotermal ve diğer yenilenebilir enerji kaynaklarından elde edilmektedir (Gök ve ark. 2019).



Şekil 2.3. Küresel elektrik üretiminde yenilenebilir enerji oranı

Türkiye’de yenilenebilir enerji kaynakları alanındaki yatırımlar çeşitli teşvikler ile artırmıştır. Türkiye’de yapılan son çalışmalarda 2022 Eylül ile ülkemiz kurulu gücün kaynaklara göre dağılımı toplam kurulu gücün %53’ü yenilenebilir enerji kaynaklarından sağlanmaktadır. Bu gücün Şekil 2.4.’de gösterildiği gibi %32’lik kısmı hidroelektrik santralleri, %10,2’si rüzgâr, %1,8’lik kısmı biyoenerji, %7,5’i PV sistemleri ve %1,7’ü ise jeotermal ve diğer yenilenebilir enerji kaynaklarından elde edilmektedir.



Şekil 2.4. Türkiye elektrik üretiminde yenilenebilir enerji oranı

3. GÜNEŞ ENERJİSİ ve ELEKTRİK ÜRETİMİ

3.1. Güneş Enerjisi

Güneş enerjisi güneş radyasyondan elde edilen, yılın her saati son derece yüksek ve sabit miktarda radyasyon yayan enerji olarak tanımlanır (Nkurlyngoma , 2018). Güneş, Dünya’da ve güneş sistemindeki diğer gezegenlerde bulunan nükleer yakıtlar dışında, tüm enerji kaynaklarının kökenidir (Bekçioğulları, 2022).

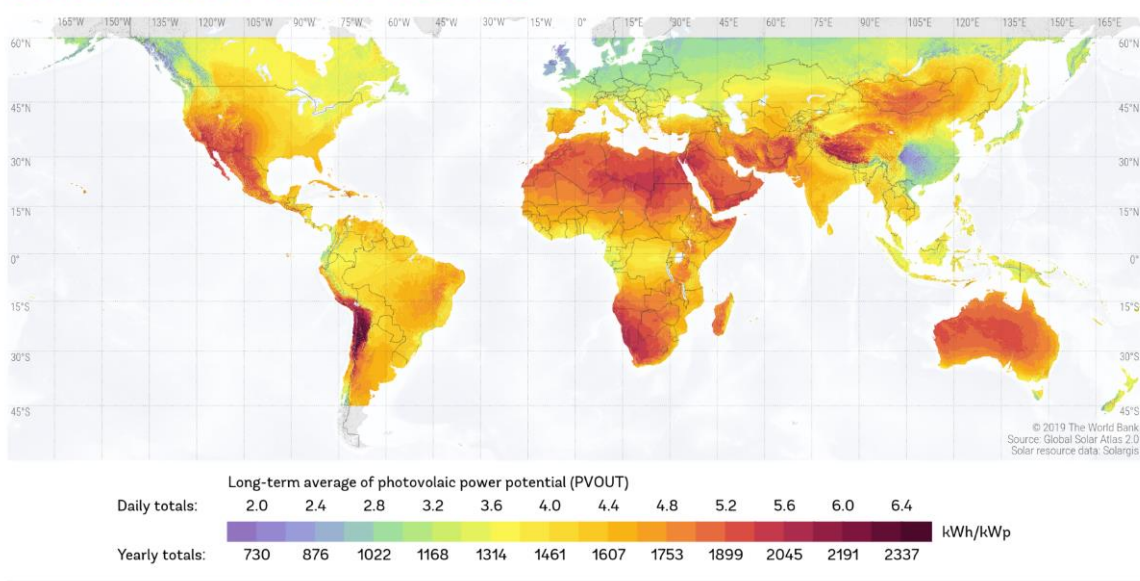
Güneş’in yaklaşık çapı 1,4 milyon km ve Dünya’dan uzaklığı yaklaşık 151,106 milyon kilometredir. Büyük hacmi nedeniyle içinde yoğun gazlar vardır. Güneşteki hidrojen elementinin helyum elementine dönüştürüldüğü nükleer füzyon reaksiyonları ile güneş enerjisi ortaya çıkmaktadır (Kayri, 2017). Füzyon süreci sonucunda ışımaya enerjisi olarak oluşan enerjinin şiddeti yaklaşık 1370 W/m^2 ’dir. Oluşan ışımaya enerjisinin önemli bir kısmı dünyaya ulaşmadan tekrar boşluğa yansır ve enerjinin sadece bir kısmı dünyaya ulaşabilmektedir. Fakat insanlığın ihtiyacı olan enerji miktarı yeryüzüne ulaşan enerjiden çok daha azdır. Mevcut teknolojilerle bu enerjinin küçük bir miktarı kullanılmaktadır. Gelişen teknoloji ve enerji talebine göre bu miktarın daha da artacağı ön görülmektedir (Kılıç, 2016).

Güneş enerjisinin diğer yenilenebilir enerji kaynaklarına göre kolay ulaşılabilir olması önümüzdeki yıllarda daha çok kullanım alanına sahip olacağını düşündürmektedir. Güneş enerjisi; güneş kaynaklı su ısıtıcıları, güneş enerjisine dayalı su pompalarının tarımsal sulaması, PV paneller aracılığıyla elektrik enerjisine dönüştürülmesi gibi uygulamalarda kullanılmaktadır.

3.1.1. Dünya’da güneş enerjisi

Enerji ihtiyacını karşılamak için sıklıkla kullanılan petrol, doğal gaz, kömür gibi birincil enerji kaynaklarına ait kaynaklar azalmaktadır. Bununla birlikte artan nüfus ve gelişen teknoloji ile elektrik enerjisine duyulan ihtiyaç artmaktadır (Demirbaş ve ark. 2008). Tüm dünya ülkeleri enerji ihtiyacını karşılayabilmek için binlerce yeni santral inşa etmiştir (Yu ve Qu, 2010). Araştırmalar gösteriyor ki 2050’den itibaren fosil yakıt rezervlerinde çok önemli bir azalma olacak ve 2300 yılından itibaren fosil yakıtların kullanımını mümkün olmayacaktır (Roper, 2016). Bu durum enerji ihtiyacının karşılanması için birçok ülkeyi farklı enerji kaynaklarından faydalanmaya yönlendirmiştir. Enerji ihtiyacının %85’i fosil yakıtlardan temin edilmektedir (Web 3). Dünya elektriğinin %10’u yenilenebilir kaynaklar kullanılarak üretilirken, bunun sadece %5’i güneş enerjisidir.

Güneş'ten gelen doğrudan ve dağılan ışınların toplamına küresel radyasyon denilmektedir. Güneş ışığından yeryüzüne her saat iletilen bu enerji, insanların bütün bir yılda tükettikleri enerjiden daha fazladır. Fakat Dünya şeklinin eliptik olması nedeniyle Güneş'ten aldığı ışınım miktarı değişmektedir. Bundan dolayı dünyadaki her yer güneş enerjisi potansiyelinden eşit yararlanamaz. Ekvatora daha yakın olan bölgeler; Güneş'in geliş açısı ve zamanlaması dikkate alındığında, kuzey veya güney bölgelerine göre daha fazla yıllık güneş enerjisi potansiyeline sahiptir (Nkurlyngoma , 2018). Dünya güneş enerji potansiyeli Şekil 3.1'de verilmiştir (Solar Avm, 2022).




Şekil 3.1. Dünya güneş enerji potansiyeli

Dünyadaki sıcak suya olan ihtiyaçtan dolayı sıcak su elde etmek için ısı güneş enerjisi kullanılmaktadır. Isı depolama sistemlerinde oluşan teknik ve ekonomik zorluklar nedeniyle yaşam alanlarının ısıtılması yaygınlık kazanmamıştır. Güneşlenme saatlerinin ve potansiyelinin çok fazla olduğu alanlarda soğutma amacıyla kullanım mümkün olmaktadır.

Güneş enerjisi ile enerjinin diğer formlarının elde edildiği, güneşten gelen ışınımı doğrudan elektrik enerjisine dönüştüğü bir yöntem olan PV uygulamaları; Dünya'nın büyük güneş enerjisi potansiyeli nedeniyle yaygın olarak kullanılmaktadır. Güneş pillerinin üretimi oldukça zor ve sınırlı olmasına rağmen teknolojik gelişmelere bağlı olarak hücre verimliliği artmış ve fiyatları düşmüştür. Böylece kullanım alanı genişlemiştir.

Dünya da 2020'ye kadar inşa edilen PV sistemler ile birlikte, küresel kurulu güç 710 GW'a yükselmiştir (Çolakoğlu ve ark. 2021). Öte yandan, kurulu güneş enerjisi

kapasitesindeki büyümenin önümüzdeki beş yılda önceki beş yılın neredeyse iki katına çıkması tahmin edilmektedir. Dünya yıllık güneş ilave kurulu gücü Şekil 3.2’de verilmiştir.



Şekil 3.2. Dünya yıllık güneş ilave kurulu gücü (GW)

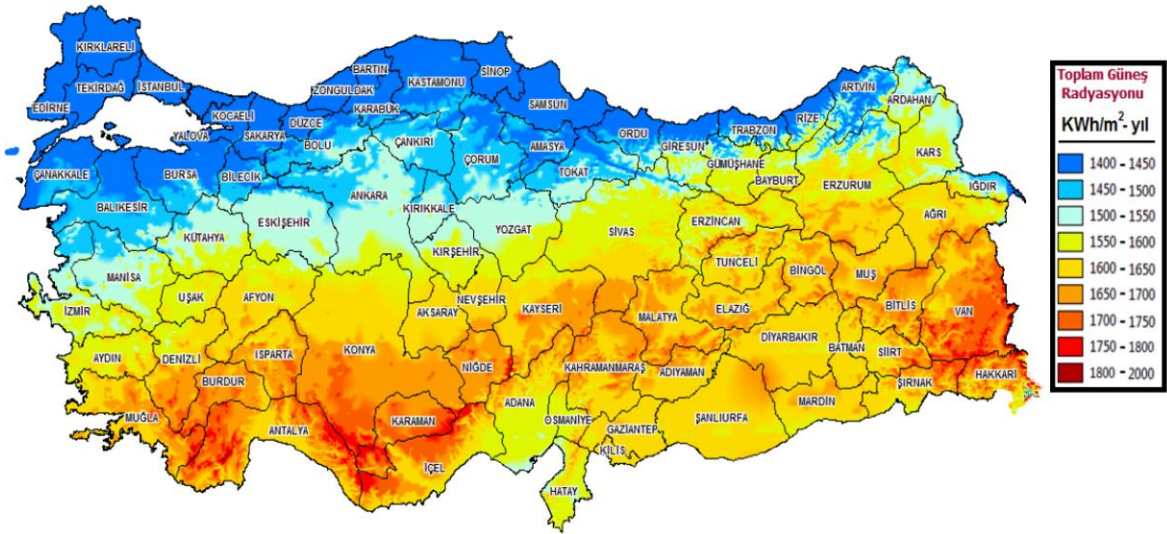
3.1.2. Türkiye’de güneş enerjisi

Türkiye’de temel enerji ihtiyaçlarına olan bağımlılık giderek artmaktadır. Bununla beraber yerli ve alternatif enerji kaynaklarının geliştirilip kullanıma hazır hale getirilemeyişi enerji ihtiyacını karşılamada dışa bağımlılığa neden olmuştur. Bu durum ekonomik ve siyasi belirsizlik gibi olumsuz etkenlere yol açmıştır (Kılıç, 2016). Türkiye’nin birincil enerji talebinin %70’e varan oranlarda dışa bağımlı olması, petrol ve doğal gaz gibi enerji kaynaklarının elde edilmesinde yeterli ilerleme ve gelişmenin olmamasından kaynaklanmaktadır. Sürekli artış ivmesine sahip olan temel enerji ihtiyacı göz önüne alınırsa bu oranın sürekli artması öngörülmektedir (Durmuş ve Kumbaroğlu, 2021). Tüm bu olumsuzluklar yatırımcıları, Türkiye’nin sahip olduğu yüksek potansiyel yenilenebilir enerji alanında başta güneş enerjisi olmak üzere diğer yerli ve temiz kaynakların kullanımına teşvik etmiştir.


Dünyanın küresel şekli nedeniyle, Güneş’ten yayılan enerji yeryüzündeki ana karaya eşit olarak dağılmamaktadır. Güneş Kuşağı olarak bilinen 40° Kuzey ve 40° Güney enlemleri arasındaki alan en fazla güneş enerjisi potansiyeline sahiptir.

Türkiye, kuzey yarımkürede 36°-42° Kuzey enlemleri ve 26°-45° Doğu boylamları arasında kalan bölgede yer aldığından güneş enerjisi potansiyeli yüksek ülkelerden biridir (Kayri, 2017).

Enerji ve Tabii Kaynaklar Bakanlığınca tarafından formüle edilen Türkiye Güneş Enerjisi Potansiyeli Atlasına (GEPA) göre, ortalama toplam güneşlenme süresi 2.741 saat olup yıllık ortalama toplam radyasyon miktarı 1.527,46 kWh/m² olarak hesaplanmıştır. GEPA’da bulunan genel potansiyel görünümü Şekil 3.3’te ve aylık ortalama radyasyon dağılımı Şekil 3.4’te verilmiştir (Web 4)



Şekil 3.3. Türkiye’de güneş enerjisi potansiyeli



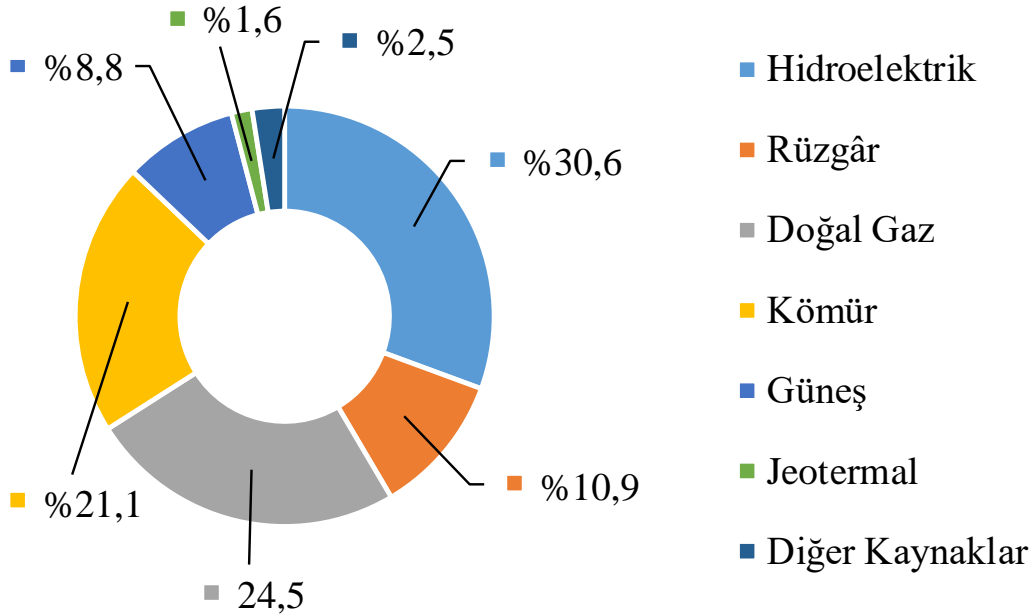
Şekil 3.4. Türkiye aylık ortalama güneş radyasyon değeri (kWh/m²)

Şekil 3.3'e bakıldığında Türkiye'de güneş enerjisi potansiyelinin Güneydoğu Anadolu ve Akdeniz bölgelerinde yüksek, Karadeniz Bölgesi'nde ise düşük değerde olduğu görülmektedir.

Şekil 3.4'e bakıldığında Türkiye'de güneş enerjisini kullanmak için en verimli ayların Haziran, Temmuz ve Ağustos, en az verimli ayların ise Kasım, Aralık ve Ocak ayları olduğu görülmektedir. Tüm bu değerler gösteriyor ki, Türkiye'de yerli enerjinin yaygınlaşması ile güneş enerjisi önemli bir alternatif enerji kaynağı haline gelecektir.

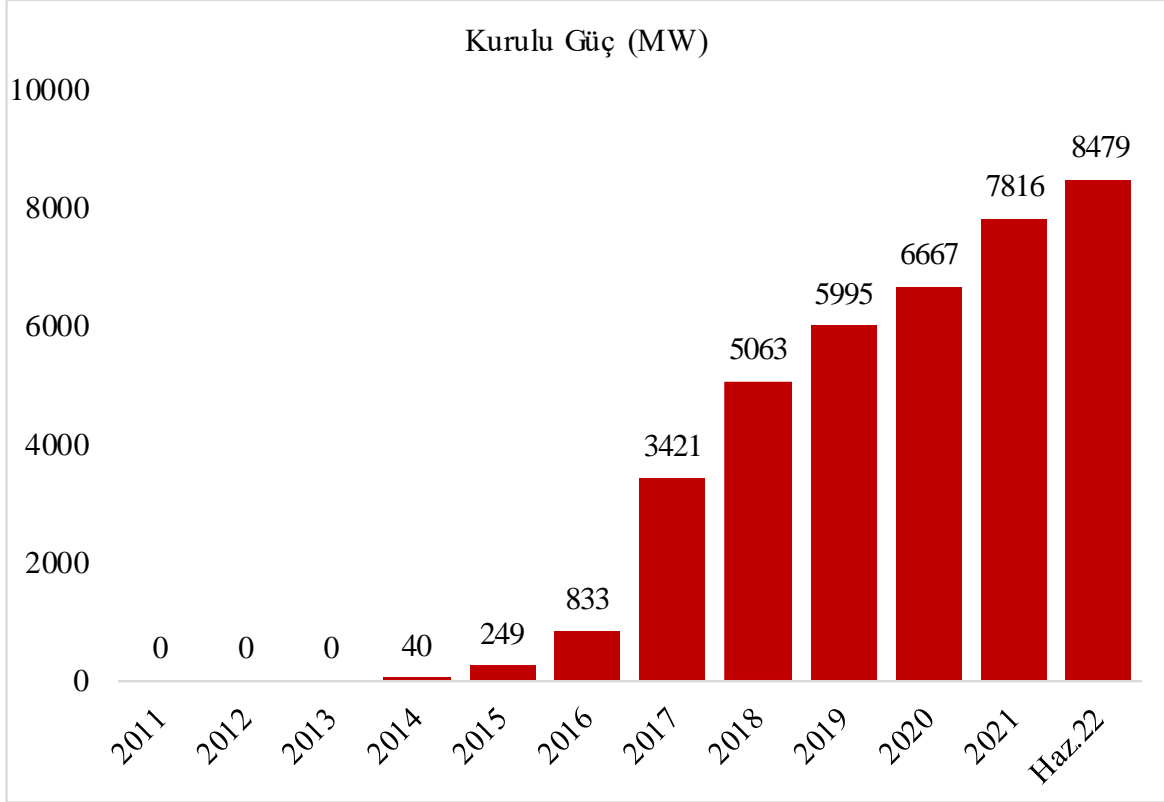
Türkiye'de güneş enerjisi potansiyeli elektrik enerjisi üretimi ve evsel sıcak su elde etmek için güneş kolektörü alanlarında kullanılmaktadır.

Türkiye'de yıllık güneş kolektörü üretimi 750.000 ile 1.000.000 m² arasındadır. Yerli üretim enerji talebinin tamamını karşılayamadığı için bir kısmı ihraç edilmektedir (Web 5). Elektrik üretimi alanında ise 2022 Ekim ayı sonu itibarıyla Türkiye'deki Kurulu güç 103.276 MW'a ulaşmıştır. Elde edilen kurulu gücün kaynaklara göre dağılımı Şekil 3.5'te gösterildiği gibi; %30,6'sı hidroelektrik enerji, %10,9'u rüzgâr, %24,5'i doğal gaz, %21,1'i kömür, %8,8'i güneş, %1,6'sı jeotermal ve %2,5'i ise diğer kaynaklardır. Ayrıca elektrik enerjisi üretim santrali sayısı, 11.276'ya ulaşmıştır. Mevcut santraller arasında 750 adet hidroelektrik, 68 adet kömür, 358 adet rüzgâr, 63 adet jeotermal, 344 adet doğal gaz, 9.203 adet güneş, 490 adet diğer kaynaklı santraller bulunmaktadır.




Şekil 3.5. Türkiye'de kurulu güce göre kaynak dağılımı

Türkiye'nin mevcut kurulu gücü ve elektrik üretimi incelendiğinde, fosil yakıtların oranının çok yüksek olduğu görülmektedir. Fakat yenilebilir enerji kaynaklarından güneş enerjisi kullanılarak üretilen elektrik kurulu gücü Haziran 2022 yılı itibariyle 8479 MW olduğu ve toplam kurulu güç içerisindeki oranı %8,35 olup yıllara göre kurulu güç değişimi Şekil 3.6'da ve toplam kurulu güç içerisindeki oranı Şekil 3.7'de verilmiştir.



Şekil 3.6. Türkiye’de yıllara göre güneş enerjisi kurulu güç değişimi

Toplam Kurulu Güce Oran



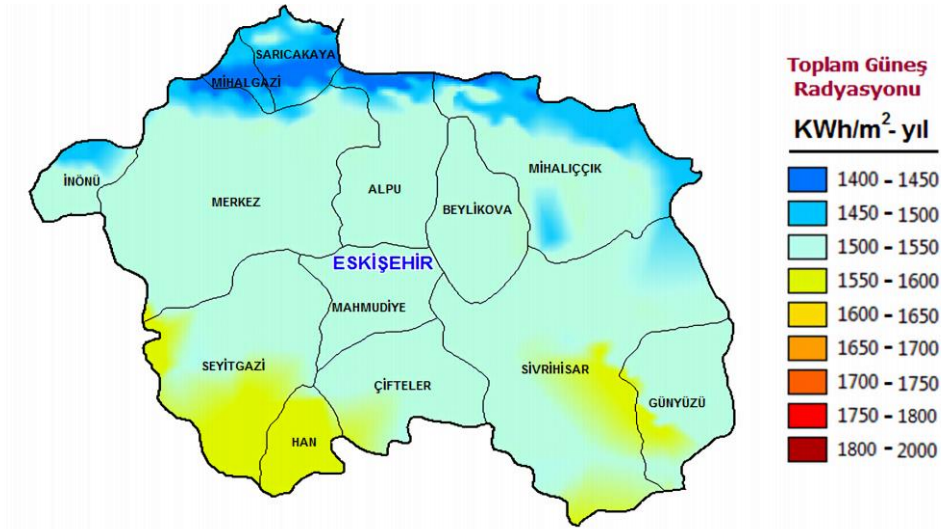
Şekil 3.7. Türkiye’de yıllara göre güneş enerjisi kurulu güç içerisindeki oranı

Türkiye’de güneş enerjisinden elektrik üretimi oranını arttırmak için bu alanda çalışmaların sürdürülmesi, özel sektörün teşvik edilmesi, toplumu güneş enerjisi hakkında bilinçlendirilmesi gibi adımların atılması gerekmektedir. Türkiye Bilimsel ve Teknolojik Araştırma Kurumu (TÜBİTAK), Marmara Araştırma Merkezi ve üniversiteler güneş enerjisi ile ilgili AR-GE çalışmalarına devam etmekle birlikte bazı üniversiteler ve enstitüler ise güneş enerjisi ile çalışan otomobiller tasarlamaktadır.


3.1.3. Eskişehir’de güneş enerjisi

Eskişehir’de bulunan santrallerin kurulu gücü 752 MWh’dir. Eskişehir’de bulunan 19 elektrik santralının yıllık elektrik üretimi yaklaşık 1.772 GWh’dır. Bu üretim miktarı ile Eskişehir’in elektrik ihtiyacının yüzde 41’i mevcut santraller ile karşılanmaktadır. Güneş Enerji Santrali olarak 9 adet GES’e sahip olan Eskişehir ilinin toplam kurulu gücü de 163 MW’dır. Bu oranla kurulu gücün yüzde %21,7’si güneş enerjisine aittir.

Bu çalışmada Eskişehir iline ait 3 bölge incelenmiştir ve Şekil 3.8’de verilmiştir. Her bölgeye ait güneş radyasyon değerleri ve güneşlenme süreleri Şekil 3.9, 3.10, 3.11, 3.12, 3.13 ve 3.14’te verilmiştir (Web 6).




Şekil 3.8. Eskişehir –Merkez toplam güneş radyasyonu




Şekil 3.9. Merkez güneş radyasyon değerleri (kWh/m²-gün)

Şekil 3.9 incelendiğinde, Eskişehir Merkez ilçesinin en fazla ve en az güneş radyasyon değerine sahip olduğu aylar haziran ve aralık olduğu görülmektedir.




Şekil 3.10. Merkez güneşlenme süreleri (saat)




Şekil 3.11. Seyitgazi güneş radyasyon değerleri (kWh/m²-gün)

Şekil 3.11 incelendiğinde, Eskişehir Seyitgazi ilçesinin en fazla ve en az güneş radyasyon değerine sahip olduğu aylar haziran ve aralık olduğu görülmektedir.




Şekil 3.12. Seyitgazi güneşlenme süreleri (saat)



Şekil 3.13. Sivrihisar güneş radyasyon değerleri (kWh/m²-gün)

Şekil 3.13 incelendiğinde, Eskişehir Sivrihisar ilçesinin en fazla ve en az güneş radyasyon değerine sahip olduğu aylar haziran ve aralık olduğu görülmektedir.



Şekil 3.14. Sivrihisar güneşlenme süreleri (saat)

3.2. Güneş Enerjisi Elektrik Üretimi

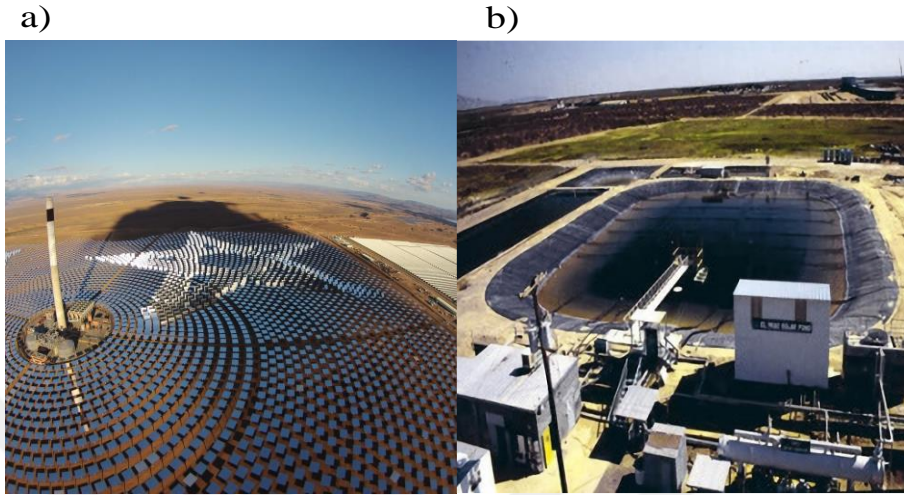
Günümüzde endüstri, konut ya da kişisel kullanımdaki enerji ihtiyacının doğrudan güneşten karşılanması olanaksızdır. Bundan dolayı güneş enerjisinin birbirinden farklı şekillere dönüştürüldüğü teknolojik yöntem ve malzeme kullanılmaktadır. Güneş enerjisi teknolojisi çok çeşitlilik göstermekle birlikte güneş enerjisinden elektrik üretmek için Isıl Güneş Enerji Teknolojileri ve PV Güneş Enerji Teknolojileri kullanılmaktadır.

3.2.1. Isıl güneş enerji teknolojisi

Güneş enerjisinden ısı elde edilmesi teknolojisine dayanan uygulamada, elde edilen ısı doğrudan kullanılabilirdiği gibi elektrik üretiminde de kullanılabilir. Isıl Güneş Enerji Teknolojisi elde edilen sıcaklık değerlerine göre düşük sıcaklık uygulamaları ve yoğun ısı sistemleri olarak ikiye ayrılır.


Düşük sıcaklık uygulamaları; düz ve vakumlu güneş kolektörleri, güneş havuzları, güneş bacaları, su arıtma sistemleri, güneş mimarisi, ürün kurutma ve sera ısıtma sistemleri

ve güneş enerjisi ile pişirme gibi sistemlerde kullanılmaktadır. Bu sistemler en çok evsel sıcak su temini, yüzme havuzları ve endüstriyel tesisler için sıcak su temininde kullanılmaktadır (Web 4). Güneş bacası (Balık, 2020) ve güneş havuzları (Web 7) Şekil 3.15'te verilmiştir.



Şekil 3.15. a) Güneş bacası ve b) Güneş havuzları

Yoğuşmalı ısı sistemleri yüksek sıcaklıklar kullanılarak elektrik enerjisi üretilmektedir. Bu uygulama ile çalışan tesislerin kurulu güç kapasiteleri 10 MW üzerinde olmak zorundadır. Yoğuşmalı ısı sistemlerini kullanan enerji üretim teknolojileri; parabolik oluklu kolektörler, parabolik çanak sistemler ve merkez alıcılı sistemlerdir. Parabolik çanak (Uyar, 2016) ve merkezi alıcılı sistemleri (Yalçın ve İlhan, 2012) Şekil 3.16'da verilmiştir.



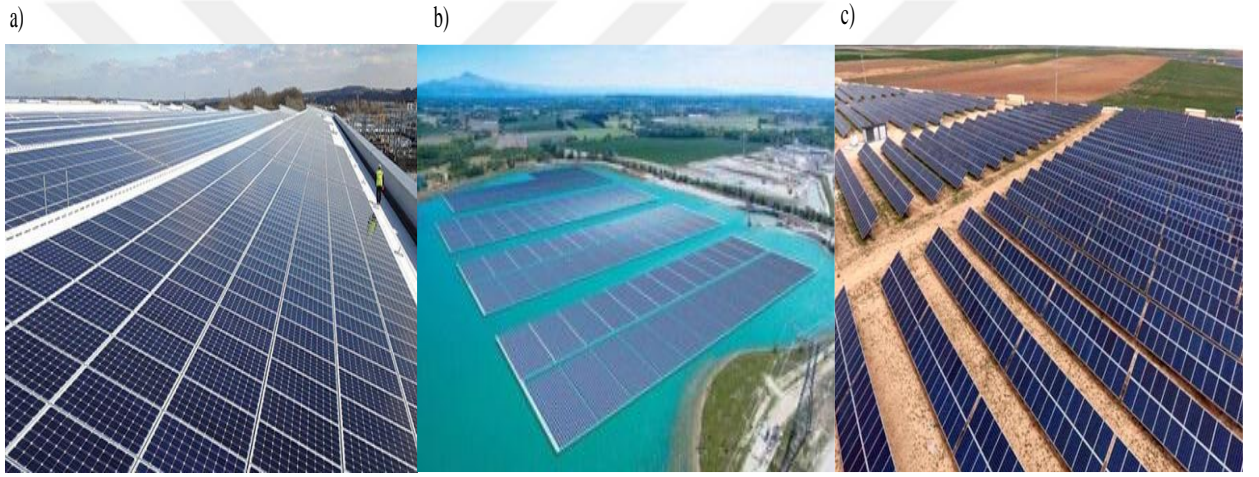
Şekil 3.16. a) Parabolik çanak ve b) Merkez alıcılı sistemler

3.2.2. PV güneş enerji teknolojisi

PV güneş teknolojilerinde kullanılan güneş modülleri; güneş enerjisini doğrudan elektrik enerjisine dönüştürmektedir. Bu sistem, üretilen elektrik enerjisini pillerde depolamak ve gerektiğinde kullanılması esasına dayanır (Kaplukan, 2014)

Doğru akım (DA) formunda üretilen elektrik enerjisi DA ile çalışan sistemleri besleyebildiği gibi evirici ile alternatif akıma (AA) çevrilerek de kullanılabilir.

Güneş enerjisinden elektrik üretiminde güneş pili temelli GES'ler yaygın olarak kullanılmaktadır. Karada ve su üzerinde birçok kullanım alanı bulunan GES uygulamalarına çatı üstü GES (Web 8), yüzer GES (Web 9) ve güneş tarlası (Web 10) örnekleri verilebilmektedir. Şekil 3.17'de farklı sahalarda uygulanan GES proje örnekleri verilmiştir.




Şekil 3.17. Örnek GES'ler: a) Çatı üstü GES, b) Yüzer GES, c) Güneş tarlası

PV sistem yapısında bulunan güneş pilleri yüzeylerine düşen güneş ışığını PV hücreler tarafından tutularak, PV hücrenin yapısına göre %5 ile %20 aralığındaki bir verimle elektrik enerjisine dönüştürmektedir. Alanları genellikle 100 cm², kalınlıkları ise 0,2- 0,4 mm arasında olan güneş pillerinin yüzey şekilleri kare, dikdörtgen veya daire şeklinde olmalıdır.

Güneş pilinin üst tabakası; çatlamayı, kırılmayı ve enerji kaybını önlemek için yansıma önleyici kaplama ve ekranlamadan yapılmıştır. Bu katmanların alt kısmında ise az elektrona sahip N tipi ve çok elektrona sahip P tipi yarıiletken malzemeler bulunmaktadır. Yarı-iletken özelliğine sahip maddeler arasında en kullanışlı olan silisyumdur (Web 11)

PV güneş teknolojilerindeki temel ilke PV dönüşümdür. Bir araya gelmeden önce P ve N tipi yarıiletkenler elektriksel bakımdan nötrdür. PN katmanı yan yana geldiğinde


elektriksel alan oluşturmaktadır. N tipi yarıiletken maddeye, P tipi yarıiletken maddeden koparılan elektronlar yol almaktadır. Tek yönlü elektron hareketi ile DA elde edilmektedir. Üretilen DA ihtiyaç olduğunda bir akü grubunda depolanabilmekte veya DA/AA eviriciler aracılığıyla dönüştürülerek şebeke sistemine aktarılabilir (Web 4). Şekil 3.18’de güneş pillerinin yapısı verilmiştir (Web 11).



Şekil 3.18. Güneş pillerinin yapısı

Üretilen elektrik enerjisinin çıkış gücünü artırmak için çok fazla güneş hücresinin bağlantısı paralel ya da seri olmak koşulu ile düzleme yerleşilmektedir. Bu yapı PV modülü olarak adlandırılır. Yüzey alanları $2,1 \text{ m}^2$ ve güçleri ise 675 Wp olan PV modülleri güç talebine göre güneş panellerini ve GES tesislerini oluşturmaktadır. Günümüz teknolojileri ve kurulumun şekline göre 13-25 dönüm bir alana 1 MW gücünde GES inşa edilebilmektedir. Özellikle, binaların çatı ve cephelerine inşa edilen GES’ler ile ihtiyaç duyulan elektrik enerjisi tüketim yerinde üretilebilmektedir (Web 4).

Şekil 3.19’da şebekeye bağlı olarak çalışan güneş pili GES’ten üretilen elektriğin tüketiciye ulaştırılma süreci verilmiştir. Şekilde görüldüğü gibi güneş pillerine gelen fotonlar ile DA sahip enerji üretilmektedir. Evirici ile AA forma çevrilen DA gerilim yükseltici trafo ile enerji iletim hattı gerilimine yükseltilmektedir. Enerji dağıtım hattına kadar bu şekilde iletilen elektrik enerjisi daha sonra alçaltıcı trafo ile tüketicinin kullanabileceği 230V ve 50 Hz değerine azaltılarak tüketiciye ulaştırılmaktadır (Bekçioğulları, 2022).



Şekil 3.19. Şebekeye bağlı GES'in enerji akış süreci

4. MATERYAL ve METOT

Çalışmada kullanılan veriler, ilgili santralden üretilen geçmiş güç değerleri ile MGM'den alınan meteorolojik tahmin verileridir. Matlab uygulamasındaki tahmin yöntemleri kullanılarak elde edilen veriler performans değerlendirme kriterleri ile karşılaştırılmıştır. Veriler ve çalışmanın gerçekleştirildiği santral ile ilgili detaylı bilgiler bir sonraki alt bölümde verilmiştir. Çalışma Eskişehir'de bulunan KM GES santralinde gerçekleştirilmiştir.

4.1. Santral Özellikleri ve Üretim Değerleri

Santral ile ilgili teknik bilgiler Çizelge 4.1'de verilmiştir. Santralin genel görünümü Şekil 4.1'de olduğu gibidir.

Çizelge 4.1. Santral teknik bilgileri

Santral Özelliği	Değer
Panel Gücü	265(W)
Kurulu Güç	1(MW)
Üretim Başlangıç Yılı	2014
Konum	Eskişehir, Odunpazarı, Harlak Üstü
Bağlı Olduğu Dağıtım Şirketi	Zorlu Enerji Dağıtım Şirketi




Şekil 4.1. KM güneş enerji santrali

Çalışmada tahmin modelinin girdisi olarak kullanılan geçmiş güç değerlerinin örnekleme zamanı bir saattir. Her değer bir saat boyunca üretilen toplam kWh biriminde enerji miktarıdır. Çalışmadaki veriler 22.03.21-13.06.21 tarihleri arasını kapsamaktadır. Bu verilerden seçilen 1 haftalık üretim Şekil 4.2’de verildiği gibidir. Ayrıca güç verilerine ilişkin bazı istatistiksel özellikler Çizelge 4.2’de verilmiştir.

Çizelge 4.2. Güç değerlerinin bazı istatistiksel özellikleri

İstatistiksel Özellik	Elektriksel Güç (kWh)
μ	222.016
M	25.875
σ	303.106
σ^2	91873


μ : Ortalama; M: Medyan ; σ : Standart Sapma; σ^2 : Varyans.



Şekil 4.2. KM güneş enerji santrali saatlik güç değerleri

4.2. Meteoroloji Genel Müdürlüğü

Bu çalışmada geliştirilen güç tahmin modellerinin diğer girdisi meteorolojik tahminlerdir. Meteorolojik tahmin; belirli bir ülke, bölge veya merkezde, bir zaman dilimi içinde oluşacak meteorolojik değerlerin gözlem ve analizler ile elde edilmesidir. Meteorolojik tahmin süreci genel olarak gözlem, analiz ve tahmin aşamalarından oluşmaktadır. Günümüzde manuel sistem yerine tamamı otomatik sisteme dönüştürülen meteoroloji gözlem istasyonları, son 15 yıldaki kullanım sayısı Türkiye için 31'den 1856'ya yükselmiştir (Web 12). Meteoroloji küresel ölçüm sistemi Şekil 4.3'te ve ölçüm istasyonu yapısı Şekil 4.4'te verilmiştir.



Şekil 4.3. Meteoroloji küresel ölçüm sistemi



Şekil 4.4. Meteoroloji otomatik ölçüm istasyonu (Web 13)

Dünya çapında meteorolojik veriler; ölçüm istasyonlarının karmaşıklığı, yüksek maliyeti ve ticari olarak yüksek kar oranlarının olmaması nedeniyle kamu kuruluşları ve üniversiteler tarafından elde edilmektedir. Ülkemizde meteorolojik ölçümler MGM tarafından yapılmaktadır. Çalışmada kullanılan meteorolojik tahmin değerleri MGM'den alınmıştır. MGM'de birçok tahmin metodu kullanılmaktadır. Bu çalışmada HAT-Meteogram modeli ile elde edilen meteorolojik tahmin verileri kullanılmıştır. Bu veriler kullanıma açık olup MGM tarafından günlük olarak resim formatında açıklanmaktadır.

Resim formatında alınan veriler Web Plot Digitizer (WPD) programı ile sayısal verilere dönüştürülmüştür.

MGM, santralin bulunduğu Eskişehir ilinin 3 ayrı bölgesi için tahmin hesaplamaktadır. Bu bölgeler; Eskişehir-Merkez, Seyitgazi ve Sivrihisar'dır. Şekil 4.5'te bu bölgelerin ve incelenen GES'in Google Earth görünümü verilmiştir.




Şekil 4.5. Meteorolojik tahmin verisi alınan bölgeler ve GES

Her bir bölgenin 24 saatlik meteorolojik tahmin verileri günlük olarak erişime açılmaktadır. Bu çalışmada; bulutluluk, sıcaklık, yağış, rüzgâr parametrelerinin gün öncesi tahminleri kullanılmıştır. Tahmin modeli için kullanılan meteorolojik veri seti parametrelerine ilişkin bazı istatistiksel bilgiler Çizelge 4.3'te verilmiştir. 22.03.21-13.06.21 tarihleri arasında kapsayan SHT veri seti Şekil 4.6'da verilmiştir.

Çizelge 4.3. Meteorolojik veri setinin bazı istatistiksel özellikleri

İstatistiksel Özellik	Sıcaklık (°C)	Bulutluluk (%)	Rüzgâr Hızı (km/s)	Yağış (mm)
μ	12.569	36.809	14.557	0.049
M	13.2	23.4	12.6	0
σ	7.177	36.688	9.208	0.311
σ^2	51.517	13460	84.790	0.097

μ : Ortalama; M: Medyan ; σ : Standart Sapma; σ^2 : Varyans

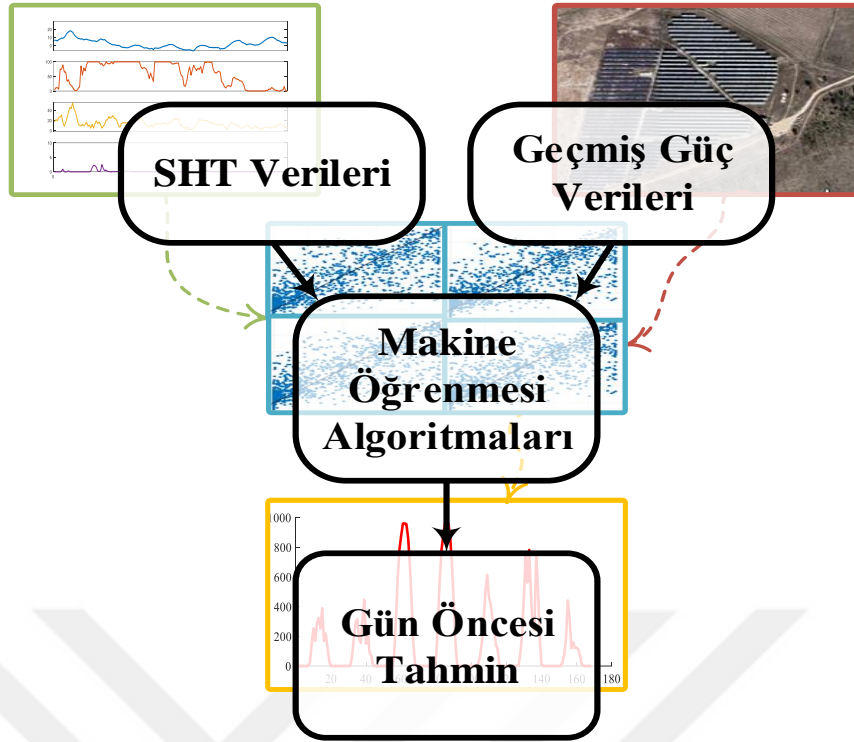


Şekil 4.6. SHT veri seti

4.3. Tahmin Modeli

Bu çalışmada GES üretimlerinin gün öncesi tahmini için modeller geliştirilmiştir. Modelleme çalışmaları Matlab yazılım dilinde gerçekleştirilmiştir. Makine öğrenmesi algoritmaları Matlab kütüphaneleri kullanılarak modele dâhil edilmiştir. Makine öğrenmesi algoritmalarının bazıları tahmin çalışmasında kullanılmıştır. Kullanılan makine öğrenmesi algoritmaları ilerleyen alt bölümlerde anlatılmıştır.

Çalışmada geliştirilen tahmin modelinin genel yapısı Şekil 4.7’de verilmiştir. Ayrıca, elde edilen kısa dönemlik güç tahminleri ve santralin ürettiği gerçek güç değerleri bazı performans değerlendirme kriterleri kullanılarak karşılaştırılmıştır.



Şekil 4.7. Tahmin modeli genel yapısı

Model gün öncesi GES üretim tahmini çıktısı vermektedir. Tahmin ufku 24 saattir. Model girdisi olarak kullanılan SHT verileri 24 saat öncesinden tahmin edilmiş meteorolojik parametrelerdir. Diğer girdi olan geçmiş güç verileri, GES tesisinin tahmin edilecek günden 24 saat önce ürettiği güç değerleridir. Bu iki tip model girdisine ilaveten tahmin edilecek saat bilgisi (1-24)'de model girdisi olarak kullanılmıştır. Toplam 2016 örnek bulunan veri seti eğitim ve test süreçlerini gerçekleştirmek amacıyla iki parçaya bölünmüştür. Bu parçalar eğitim ve test için sırasıyla veri setinin %75 ve %25'lik kısımlarından oluşmaktadır. Ayrıca eğitim sürecinde tahmin modelinin güvenilirliğini irdelemek amacıyla 10 katlamalı çapraz doğrulama kullanılmıştır.

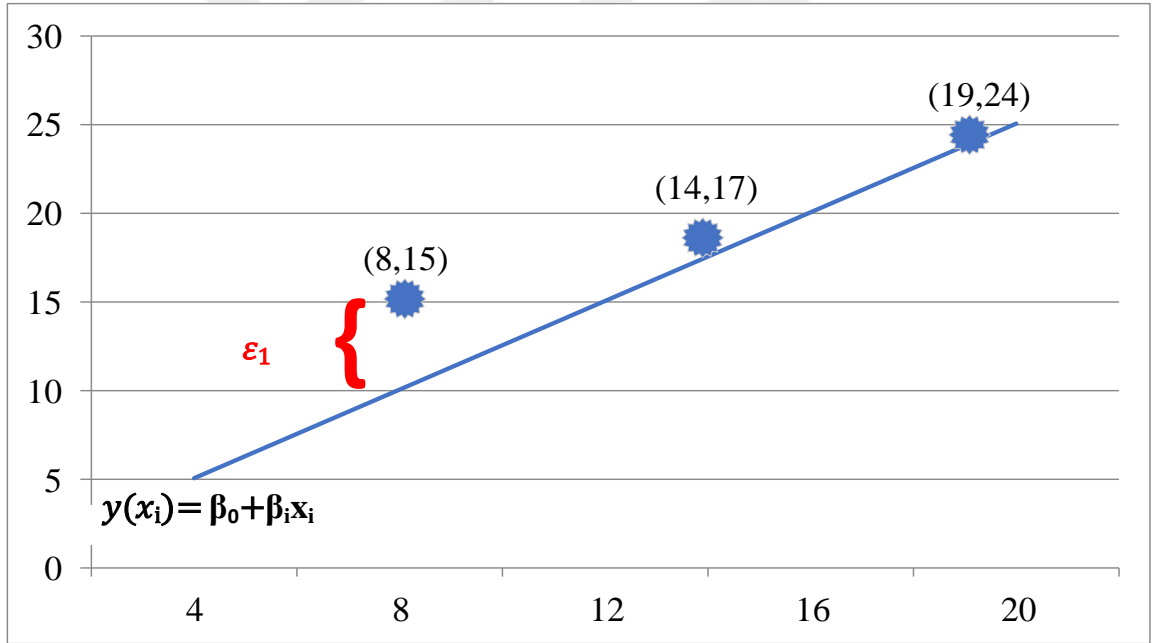
Çalışmada önerilen, kısa dönem GES üretim tahmini modelinde DR, DVM, GSR ve RA olmak üzere dört farklı makine öğrenmesi algoritması kıyaslanarak değerlendirilmiştir. İrdelenen makine öğrenmesi algoritmalarının teorik alt yapısı ilerleyen alt bölümlerde detaylı bir şekilde açıklanmıştır.

4.3.1. DR modeli

DR modeli iki veya daha fazla değişken arasındaki ilişkinin bir doğru ile gösterilmesidir. DR modelinde, girdi olan bir değişkenin değeri ile doğrusal bir fonksiyon oluşturularak çıkış değerinin tahmin edilmesini sağlayan bir makine öğrenmesi modelidir. İki değişken arasındaki ilişkiyi göstermeye çalışan bir tür istatistiksel analizdir (Kılıç, 2013).

$$y = \beta_0 + \sum_{i=1}^i \beta_i x_i = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3 + \dots + \beta_i x_i + \varepsilon \quad (4.1)$$

DR modeli matematiksel olarak Eşitlik 4.1’de verilmiştir (Şenel ve ark. 2009). Burada i tane olmak üzere, x_i bağımsız değişkenler olan girdi değerlerini ifade etmektedir. y değişkeni x ’e bağlı olarak değişen çıkış değeridir. y değişkeni ile gerçek değer arasındaki fark ne kadar az ise tahmin değişkeni olan y o kadar gerçeğe yakındır. β_i ise hesaplanacak doğrusal parametre tahminini her bir girdi değerine atanan ağırlık değerleridir. β_0 değeri bias değeri ve ε hata değeri olarak ifade edilmektedir. Bu yöntemde bias ve ağırlık değerlerini sürekli değiştirerek veri setine en uygun olan doğru denklemi elde edilmektedir. Belirlenecek olan bu değerlerin ε hata değerini olabildiğince en küçük yapan değerler olması gerekmektedir (Taş, 2020; Kader, 2022). DR modelinde hata kavramı Şekil 4.8’de verilmiştir.



Şekil 4.8. DR modelinde hata kavramı

DR modelinde elde edilen veri noktaları kullanılarak, bu noktaları en iyi modelleyen bir eğilim çizgisi oluşmaktadır ve tahmin değerleri elde edilmektedir.


4.3.2. RA modeli

RA modeli ölçüt ve değerlendirme olmayan kural tabanlı bir yaklaşımdır. Hesaplama maliyetinin düşük olması ve kolay yorumlanabilir olması sebebiyle sıkça kullanılmaktadır.

Çok sayıda veri içeren kümelerin yapısından yola çıkarak ağaç yapısı şeklinde regresyon modelleri elde edilmektedir. Bir karar ağacı, kök, dallar, yapraklar ve düğümlerden oluşmaktadır (Vega ve ark. 2009).

RA modeli çok aşamalıdır ve karmaşık verileri adım adım verilere çevirerek basit karar verme süreçlerini gerçekleştirmektedir (Kavzoğlu ve ark. 2021). Karar sürecinde, bir parametre kök veya birinci düğüm olarak seçilir ve ardından birinci düğüm, bir dizi özelliğe dayalı olarak birden çok düğüme bölünmektedir. Kök, dal ve düğümden oluşan bir zincirin ucu yapaktır (Tiryaki, 2008).

Bölme işleminde girdi parametrelerinden herhangi biri işlemi uygular ve bölme aralığı MSE değerinin en aza indirilmesine göre seçilmektedir. RA modelinde çıkış değeri gerçek bir değerler kümesidir. Elde edilen tahminler girdi parametrelerine uygulanan eğer-ise kurallarına göre yapılmaktadır. Şekil 4.9’da örnek bir RA modeli verilmiştir (Yıldırım, 2018).




Şekil 4.9. Örnek RA modeli

Şekil 4.9’da verildiği üzere veriler bir düzlem de dağılmıştır ve sınıflandırmanın en iyi olacağı şekilde bazı kısımlara bölünmüştür. Bu sınırlar bir ağaç yapısına dönüştürülerek örnek bir veriyi işlemek için bu ağaç yapısında eğitilerek veri hakkında bilgi elde edilmektedir. RA modeli ile tahmin edilecek değerler sürekli değişkenlerden oluşmaktadır (Kayri ve Boysan, 2012).

4.3.3. DVM modeli

DVM makine öğrenme metodu genellikle sınıflandırma ve regresyon problemlerinin çözümünde kullanılan gözetimli öğrenme yöntemidir (Uğuz, 2019). DVM metodu ilk olarak 1995 Vladimir Vabnik ve Alexey Shervonenikis tarafından sınıflandırma ve regresyon tipi problemleri çözümleri için ortaya atılmıştır (Daş ve ark. 2019). DVM, eski veriler yardımı ile girdilere karşılık gelen çıktıyı tahmin etmeye yarayan metottur (Güner ve Çomak, 2011).

Bu yöntem genelde yüksek boyutlu verilerde kullanılan bir ayırım metodudur. Metoda veri üzerinde eğitim uygulanmaktadır. DVM , temelde düşük boyutta doğrusal olarak ayıramayacak bir veri kümesini daha yüksek boyuta taşıyarak bir düzlem yardımıyla ayırmaktadır (Uğuz, 2019).



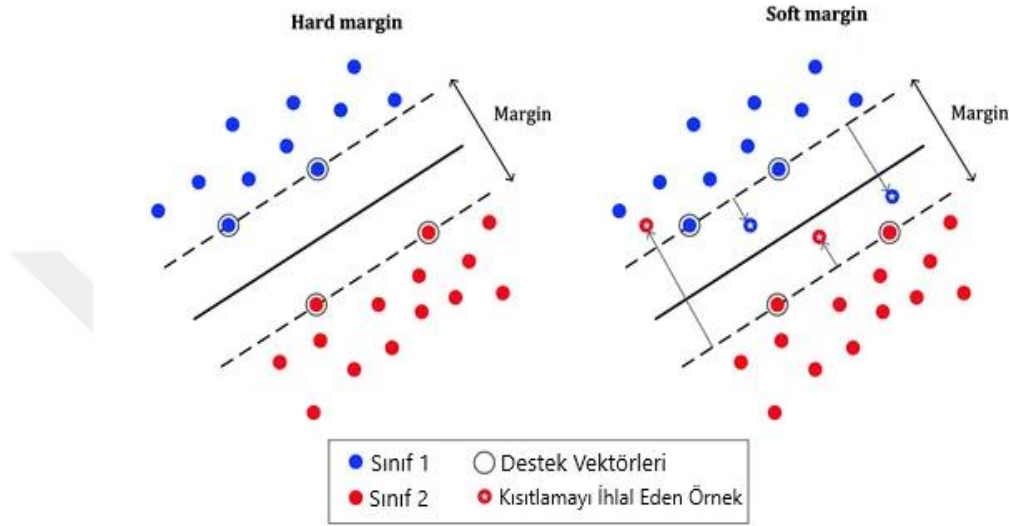
Şekil 4.10. DVM modeli

Şekil 4.10'da verilen DVM modelinde bir düzlemde bulunan veriler doğru yardımı ile ayrılmıştır. Bu doğru iki sınıfın noktaları için de maksimum uzaklıkta çizilmektedir. Şekilde siyahlar ve beyazlar olmak üzere iki farklı sınıf mevcuttur. Sınıflandırmadaki amaç yeni oluşacak verinin hangi sınıfa ait olduğuna karar vermektir. Bu sınıflandırmayı yapabilmek için çizilen doğrunun ± 1 'i arasında kalan yeşil bölgeye Margin denilmektedir. Marginin geniş olması iki veya daha fazla sınıfın dahaiyi ayrılması demektir (Akça, 2020).

$$y = \begin{cases} 0 & ; w^T \cdot x + b < 0 \\ 1 & ; w^T \cdot x + b \geq 0 \end{cases} \quad (4.2)$$

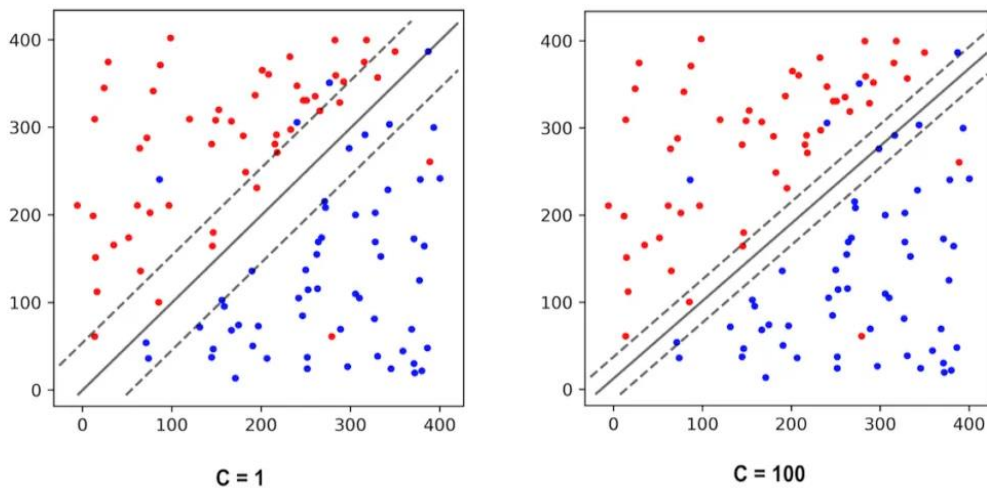
DVM modeli matematiksel olarak Eşitlik 4.2’de verilmiştir (Akça, 2020). W ağırlık vektörü, x girdi vektörü ve b sapmadır. Yeni bir değer için ; sonuç 0’dan küçükse beyaz noktalara, 0’a eşit veya büyükse siyah noktalara daha yakın olacaktır.

Margin bölgesi her zaman bu şekilde olmayarak verilerin bazılarını içinde barındırmaktadır. Bu durum Soft Margin’dır. Hard Margin ise verilerin doğrusal olarak ayrılabilirdiği durumlardır ve Şekil 4.11’de verilmiştir (Akça, 2020).



Şekil 4.11. Hard margin ve soft margin modeli

Hard Margin ile Soft Margin arasındaki denge DVM içerisindeki C hiper parametresi ile kontrol edilmektedir. Şekil 4.12’de C ne kadar büyük olursa margin bölgesi o kadar dar olacağı verilmiştir (Akça, 2020).



Şekil 4.12. C hiper parametre modeli

4.3.4. GSR model

GSR, analitik yollar ile hesaplanamayacak fonksiyonların tahmin yöntemine dayanan bir metottur. GSR sürecinde fonksiyonlar üzerinde bir dağılım tanımlanmaktadır. Bu durumda fonksiyonlar kombinasyonunda sürekli nicel değerler oluşmaktadır. Doğrusal olmayan verilerin tahmininde DR yöntemine göre daha geniş esnekliğe sahip olan DR yöntemine kıyasla oldukça avantajlı bir regresyon tekniğidir. GSR işlevi tahmin edilemeyen veriler üzerinde olasılık dağılımları oluşturularak bazı çıkarımlarda bulunur ve böylece fonksiyonel olarak oluşturulmuş tahminler belirlenmektedir.

$$\begin{bmatrix} y \\ g \star \end{bmatrix} \sim N\left(\begin{bmatrix} \mu \\ \mu \star \end{bmatrix}, \begin{bmatrix} Ky & K \star \\ K^T \star & K \star \star \end{bmatrix}\right) \quad (4.3)$$

GSR modelinde oluşan fonksiyon Eşitlik 4.3'te verilmiştir (Bekçioğulları, 2022). y vektörü bir kısmı bilinen verileri, $g \star = g(x \star)$ ise tahmin çıkış verileridir. $\mu \star = \mu(x \star)$ test ve $\mu = \mu(x)$ eğitim verileri ortalama fonksiyonların vektörleridir. Ky matrisi tahmin edilen değerlerin birbirine benzerliğini göstermektedir ve $Ky = k(x, x) + \beta^2 I$ 'nin girdi değişkenleri olan $X - X \star$ tüm permütasyonları için hesaplanan kovaryans fonksiyonudur. Gürültü göz önüne alınarak eşitliğe $\beta^2 I$ değeri eklenmiştir.

4.4. Performans Değerlendirme Kriterleri

Bu çalışmada, tahmin sistemlerinin etkinliğini değerlendirmek için performans değerlendirme kriterleri kullanılmıştır. Kullanılan tahmin yöntemlerinin veriye uygunluğu ve algoritmaların verimliliğini ölçmek için farklı yöntemler kullanılmaktadır (Kader, 2022).

Performans değerlendirme kriterleri, farklı modellerden elde edilen gerçek ve tahmin edilen çıktı veri setleri arasındaki farkı test ederek en düşük tahmin hatasına sahip modeli seçen istatistiksel araçtır (Wang ve ark. 2019; Jimenez ve ark. 2021; Maham, 2022).

Literatürde yoğunlukla kullanılan performans metrikleri bu tez kapsamında kullanılmıştır. Çalışmada kullanılan yöntemlerin performansı 3 temel performans metriği kullanılarak değerlendirilmiştir. Bunlar R, Ortalama RMSE ve MAE'dir. Bu ölçütler matematiksel olarak sırasıyla şu şekilde ifade edilmektedir.

R, tahmin yönteminin girdi ile çıkışın birbirlerine ne kadar bağımlı olduğunu göstermektedir (Bekçioğulları, 2022). Ölçülen gerçek değer ile tahmin yöntemi ile elde edilen değerler arasında doğrusal ilişki olup olmadığını belirlemek amacıyla

kullanılmaktadır. R değeri -1 ile 1 arasında değişir; 1'e yakınsa model tahmini ile ölçülen değer arasındaki bağımlılık güçlüdür, -1'e yakınsa model tahmini ile ölçülen değer arasındaki bağımlılık zayıftır, 0 değerini alması ise modelin tahmin ettiği değer ile ölçülen değerler arasında ilişki olmadığını göstermektedir. R değerinin matematiksel denklemi Eşitlik 4.4'te verilmiştir (Chugh, 2020).

$$R = \frac{\sum_{i=1}^n [(P^t_i - \bar{P}^t)(P_i - \bar{P})]}{\sqrt{\sum_{i=1}^n (P^t_i - \bar{P}^t)^2 \sum_{i=1}^n (P_i - \bar{P})^2}} \quad (4.4)$$

RMSE, tahmin hatasının standart sapması olarak tanımlanmaktadır. Ölçüm değerleri ile model tahminleri arasındaki hata oranını belirlemek için kullanılmaktadır. Gerçek ölçülen değer ile tahmin modeli kullanılarak hesaplanan değer arasındaki farkın kareleri toplamının ortalamasının kareköküdür

Yani hatalar regresyon çizgisinin veri noktalarından ne kadar uzakta olduğunu ölçerken, RMSE bu hataların nasıl yayıldığını göstermektedir. Kısa dönem ölçülen ve tahmin edilen model performans değerlendirmesinde önemli olan RMSE değerinin sıfıra yaklaşması, tahmin modeli performansının iyi olduğu anlamına gelmektedir (Okur, 2016; Kader, 2022; Maham, 2022). Ancak gerçekte hiçbir zaman 0 değerine sahip olmamaktadır. Genelde daha düşük değere sahip bir RMSE, yüksek değere sahip RMSE değerinden daha iyidir (Kıymaz, 2020). RMSE değerinin matematiksel denklemi Eşitlik 4.5'te verilmiştir (Chugh, 2020).

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (P_i - P^t_i)^2} \quad (4.5)$$

MAE, gerçek değer ile tahmin edilen değer arasındaki her bir farkın yani hatanın mutlak değerinin ortalama büyüklüğünü ifade etmektedir (Kıymaz, 2020). MAE değeri bu farkların pozitif veya negatif oluşunu göz ardı ederek ölçüm değerleri ile model tahminleri arasındaki mutlak hatanın öğrenilmesi için kullanılmaktadır. MAE'nin sıfır değerine yaklaşması modelin tahmin performansının iyi olduğu anlamına gelmektedir (Okur, 2016;

Kader, 2022). MAE deęerinin matematiksel denklemini Eşitlik 4.6'da verilmiştir (Chugh, 2020).

$$MAE = \frac{1}{n} \sum_{i=1}^n |P^t_i - P_i| \quad (4.6)$$

P^t ve P sırasıyla tahmin edilen ve gerçek güç deęerini belirtmektedir. \bar{P}^f tahmin edilen n adet güç deęerinin ortalamasıdır. \bar{P} ise gerçek güç deęerinin ortalama deęeridir.

Bu denklemlerde; R deęerinin 1'e olabildięi kadar yaklaşması, RMSE ve MAE hata deęerlerinin ise olabildięince 0'a yaklaşması hedeflenmektedir. Böylece daha doęru tahmin sonucu elde edilebilmektedir.

5. BULGULAR ve TARTIŞMA

Çalışmada, üç farklı bölgeden elde edilen gün öncesi SHT verileri kullanılarak oluşturulan tahmin modellerinin performansları 24 Mayıs-13 Haziran tarihleri arasındaki test verisi üzerinde değerlendirilmiştir. Meteorolojik tahmin verilerinin yanı sıra uygulama yapılan santralden alınmış gün öncesi gerçek güç değerleri ve tahmin edilecek saatin zaman bilgisi de model girdisi olarak kullanılmıştır. Geliştirilen güç tahmin modellerinde 4 farklı makine öğrenmesi algoritması kullanılmıştır. Böylece çalışma kapsamında toplam 12 adet tahmin modeli geliştirilmiş ve performansları değerlendirilmiştir. Değerlendirmeler sonucunda elde edilen RMSE, MAE ve R performans kriterleri Çizelge 5.1 'de verilmiştir.

Çizelge 5.1. Performans testi sonuçlar

Meteorolojik Tahmin Bölgesi	Değerlendirme Kriterleri	Makine Öğrenmesi Algoritması			
		DR	RA	DVM	GSR
Eskişehir Merkez	RMSE (kWh)	173.49	147.47	152.07	142.52
	MAE (kWh)	117.67	77.15	95.24	77.47
	R	0.841	0.887	0.869	0.895
Eskişehir Seyitgazi	RMSE (kWh)	161.79	136.01	149.44	129.78
	MAE (kWh)	109.35	71.74	94.17	70.80
	R	0.862	0.902	0.875	0.91
Eskişehir Sivrihisar	RMSE (kWh)	218.93	140.75	159.76	149.20
	MAE (kWh)	123.5	70.45	95.16	76.84
	R	0.750	0.893	0.861	0.881

RMSE ve MAE değerlerinin 0'a yakın olması iyi bir performansa sahip olduğunu 0'dan uzaklaşması ise kötü bir performansa sahip olduğunu göstermektedir.

Bu durum göz önüne alındığında Eskişehir Merkez ve Eskişehir Seyitgazi bölgelerinden alınan veriler ile GSR algoritmasının en düşük RMSE değerlerine sahip olduğu görülmüştür. Eskişehir Sivrihisar bölgesinden alınan veriler için ise RA algoritması en düşük RMSE değerini yakalamıştır. Eskişehir Merkez, Eskişehir Seyitgazi ve Eskişehir Merkez için en yüksek RMSE değeri DR uygulamasına ait olduğu görülmüştür.


MAE kriteri incelendiğinde en düşük değerlerin Eskişehir Merkez ve Sivrihisar bölgeleri için RA algoritması tarafından yakalandığı görülmüştür. Eskişehir Seyitgazi bölgesinden alınan veriler için ise GSR algoritması en düşük MAE değerini yakalamıştır. Eskişehir Merkez, Eskişehir Seyitgazi ve Eskişehir Merkez için en yüksek MAE değeri DR uygulamasına ait olduğu görülmüştür.

Çalışmada kullanılan R kriterinin 1'e yakın olması iyi bir performansa sahip olduğunu göstermektedir. Elde edilen R kriteri değerleri irdelendiğinde, Eskişehir Merkez ve Seyitgazi verileri için GSR, Eskişehir Sivrihisar verileri için RA algoritmasının 1'e en yakın R değerlerine sahip olduğu görülmüştür. Eskişehir Merkez, Eskişehir Seyitgazi ve Eskişehir Merkez için en düşük R değeri DR uygulamasına ait olduğu görülmüştür.

Üç farklı veri seti için genel bir değerlendirme yapıldığında DR algoritmasının Eskişehir Merkez, Seyitgazi ve Sivrihisar bölgeleri için en başarısız değerlere sahip olduğu görülmektedir. Önerilen tahmin modeli için kullanılan makine öğrenmesi algoritmalarından DR algoritmasının diğer üç algoritmaya göre daha kötü performansa sahip olduğu görülmektedir.


GSR algoritmasının ise Merkez ve Seyitgazi veri setlerinde daha başarılı olduğu görülmektedir. Sivrihisar bölgesi veri seti için ise RA algoritması en iyi performansı yakalamıştır. Bu durum GSR algoritmasının farklı veri setlerinde iyi bir performansa sahip olduğunu göstermektedir. 3 farklı veri seti ve 4 farklı makine öğrenmesi algoritması ile elde edilen 12 sonuç genel olarak değerlendirildiğinden ise GSR algoritmasının 0'a en yakın RMSE ve MAE değerlerine ve 1'e en yakın R değerine sahip olduğu görülmüştür.

Çalışmada, üç farklı bölgeden alınan SHT verileri kullanılarak tahmin modelleri geliştirilmiştir. Bu 3 bölge verisinde makine öğrenmesi algoritmalarının performanslarını değerlendirmek için test verisinden seçilen bir günde 4 farklı makine öğrenmesi algoritmasının tahmin sonuçları grafiklere aktarılmıştır. Seçilen gün 24 Mayıs'tır. Oluşturulan grafikler Şekil 5.1-5.2-5.3'te verilmiştir. Bir GES tesisinin günlük üretimi simetrik bir gauss eğrisi oluşturmakta ve hesaplanan tahmin değerlerinin bu eğriyi takip etmesi beklenmektedir. Bu bilgi göz önüne alınarak grafikler incelenmiştir.




Şekil 5.1. 24 Mayıs için Merkez bölgesi test sonuçları

Şekil 5.1’de Merkez bölgesi için GES üretimi ve makine öğrenmesi algoritmaları ile elde edilen test sonuçlarının oluşturduğu grafikler verilmiştir. Şekilde verilen grafikler incelendiğinde DR algoritması, GES üretiminin oluşturduğu gauss eğrisinin yükselen ve alçalan kısmında gauss eğrisinden uzaklaştığı görülmektedir. DR algoritması, GES üretiminin oluşturduğu gauss eğrisinin tepe değerlerinden daha düşük sonuçlar verdiği görülmektedir. RA algoritması, GES üretiminin oluşturduğu gauss eğrisinin yükselen kısmında gauss eğrisini kısmen yakaladığı, alçalan kısımda ise gauss eğrisinden uzaklaştığı görülmektedir. RA algoritması, GES üretiminin oluşturduğu gauss eğrisinin tepe değerlerinden daha düşük sonuçlar verdiği görülmektedir. DVM algoritması, GES üretiminin oluşturduğu gauss eğrisinin yükselen ve alçalan kısmında gauss eğrisinden uzaklaştığı görülmektedir. DVM algoritması, GES üretiminin oluşturduğu gauss eğrisinin tepe değerlerinden daha düşük ve değişken sonuçlar verdiği görülmektedir. GSR algoritması, GES üretiminin oluşturduğu gauss eğrisinin yükselen kısmında iyi performans gösterdiği, alçalan kısmında gauss eğrisinden kabul edilebilir değerde eğriden uzaklaştığı görülmektedir. GSR algoritması, GES üretiminin oluşturduğu gauss eğrisinin tepe değerlerinden daha düşük sonuçlar verdiği, GES üretiminin oluşturduğu gauss eğrisinde meydana gelen azalma ve artışlara olumlu yönde tepki vererek eğriyi iyi bir şekilde yakaladığı görülmektedir.



Şekil 5.2. 24 Mayıs için Seyitgazi bölgesi test sonuçları

Şekil 5.2’de Seyitgazi bölgesi için GES üretimi ve makine öğrenmesi algoritmaları ile elde edilen test sonuçlarının oluşturduğu grafikler verilmiştir. Şekilde verilen grafikler incelendiğinde DR algoritması, GES üretiminin oluşturduğu gauss eğrisinin yükselen ve alçalan kısmında gauss eğrisinden uzaklaştığı görülmektedir. DR algoritması, GES üretiminin oluşturduğu gauss eğrisinin tepe değerlerinden daha yüksek sonuçlar verdiği görülmektedir. RA algoritması, GES üretiminin oluşturduğu gauss eğrisinin yükselen kısmında gauss eğrisini kısmen yakaladığı, alçalan kısımda ise gauss eğrisinden uzaklaştığı görülmektedir. RA algoritması, GES üretiminin oluşturduğu gauss eğrisinin tepe değerlerinden daha düşük sonuçlar verdiği görülmektedir. DVM algoritması, GES üretiminin oluşturduğu gauss eğrisinin yükselen ve alçalan kısmında gauss eğrisine kısmen yaklaştığı görülmektedir. DVM algoritması, GES üretiminin oluşturduğu gauss eğrisinin tepe değerlerinden daha düşük sonuçlar ve değişken sonuçlar verdiği görülmektedir. GSR algoritması, GES üretiminin oluşturduğu gauss eğrisinin yükselen kısmında kabul edilebilir şekilde uzaklaştığı, alçalan kısmında gauss eğrisine yaklaşarak iyi performans gösterdiği görülmektedir. GSR algoritması, GES üretiminin oluşturduğu gauss eğrisinin tepe değerlerinden daha düşük sonuçlar verdiği, GES üretiminin oluşturduğu gauss eğrisinde meydana gelen azalma ve artışlara olumlu yönde tepki vererek eğriyi iyi bir şekilde yakaladığı görülmektedir.



Şekil 5.3. 24 Mayıs için Sivrihisar bölgesi test sonuçları

Şekil 5.3’de Sivrihisar bölgesi için GES üretimi ve makine öğrenmesi algoritmaları ile elde edilen test sonuçlarının oluşturduğu grafikler verilmiştir. Şekilde verilen grafikler incelendiğinde DR algoritması, GES üretiminin oluşturduğu gauss eğrisinin yükselen ve alçalan kısmında gauss eğrisinden uzaklaştığı görülmektedir. DR algoritması, GES üretiminin oluşturduğu gauss eğrisinin tepe değerlerinden daha fazla sonuçlar verdiği görülmektedir. RA algoritması, GES üretiminin oluşturduğu gauss eğrisinin yükselen kısmında eğriyi kısmen yakaladığı, alçalan kısımda ise gauss eğrisinden kısmen uzaklaştığı görülmektedir. RA algoritması, GES üretiminin oluşturduğu gauss eğrisinin tepe değerlerinden daha düşük sonuçlar verdiği görülmektedir. DVM algoritması, GES üretiminin oluşturduğu gauss eğrisinin yükselen ve alçalan kısmında gauss eğrisine kısmen yaklaştığı görülmektedir. DVM algoritması, GES üretiminin oluşturduğu gauss eğrisinin tepe değerlerinden daha düşük ve değişken sonuçlar verdiği görülmektedir. GSR algoritması, GES üretiminin oluşturduğu gauss eğrisinin yükselen ve alçalan kısmında gauss eğrisine yaklaşarak iyi performans gösterdiği görülmektedir. GSR algoritması, GES üretiminin oluşturduğu gauss eğrisinin tepe değerlerinden daha düşük sonuçlar verdiği, GES üretiminin oluşturduğu gauss eğrisinde meydana gelen azalma ve artışlara olumlu yönde tepki vererek eğriyi iyi bir şekilde yakaladığı görülmektedir.

Üç farklı grafik için genel bir değerlendirme yapıldığında DR algoritmasının Eskişehir Merkez, Seyitgazi ve Sivrihisar bölgeleri için en başarısız değerlere sahip olduğu

görülmektedir. Önerilen tahmin modeli için kullanılan makine öğrenmesi algoritmalarından DR algoritmasının diğer üç algoritmaya göre daha kötü performansa, GSR algoritmasının ise iyi bir performansa sahip olduğunu görülmektedir.

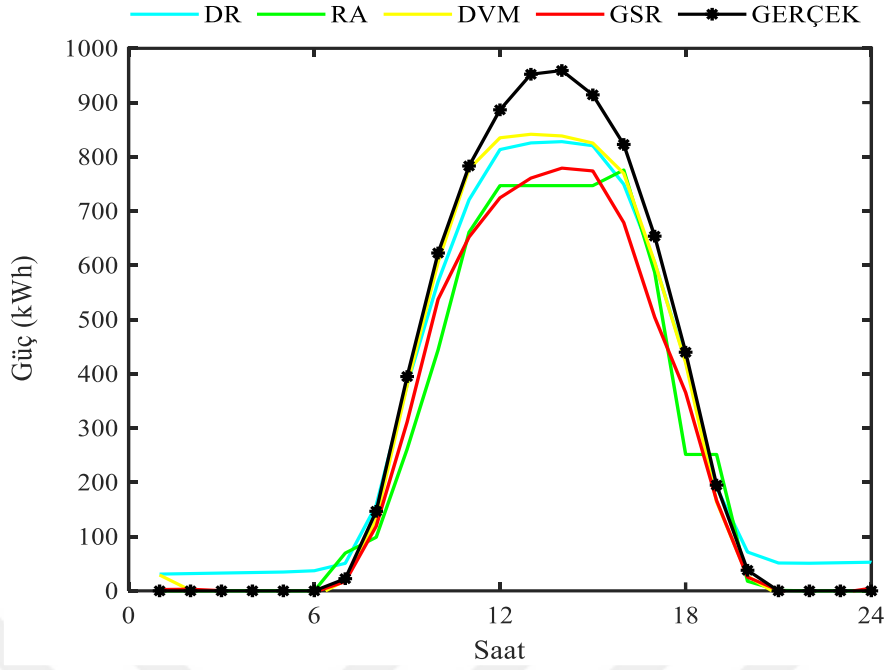
Çalışmada, 24 Mayıs günü için üç farklı bölgede uygulanan 4 farklı makine öğrenmesi algoritmasının test sonuçları Çizelge 5.2’de verilmiştir.

Çizelge 5.2. 24 Mayıs için 4 farklı makine öğrenmesi algoritmasının test sonuçları

Saat	Meteorolojik Tahmin Bölgesi												Gerçek Güç (kWh)
	Eskişehir Merkez				Eskişehir Seyitgazi				Eskişehir Sivrihisar				
	DR	RA	DVM	GSR	DR	RA	DVM	GSR	DR	RA	DVM	GSR	
0	46,7	0,0	28,4	0,3	16,6	0,0	26,4	0,4	25,6	0,0	13,3	-0,1	0
1	56,4	0,0	14,2	0,0	18,6	0,0	9,7	0,8	29,8	0,0	3,6	0,1	0
2	47,2	0,0	8,9	0,0	21,7	0,0	-9,1	-0,2	35,7	0,0	-4,1	1,8	0
3	37,3	0,0	-7,7	0,1	27,3	0,0	-1,2	-1,5	10,0	0,0	5,9	-0,4	0
4	31,8	31,1	40,8	8,6	32,8	0,0	28,3	2,3	26,2	0,0	-16,9	0,2	0
5	38,9	31,1	78,8	30,7	37,2	2,2	52,9	13,2	31,1	3,6	-11,7	5,1	0
6	67,2	14,6	82,2	44,2	69,3	11,4	8,9	31,0	61,6	20,2	15,3	31,9	22,4
7	212,7	134,2	161,5	164,8	219,9	105,9	264,3	240,4	213,5	134,4	178,4	156,1	146,6
8	484,3	348,0	394,3	389,1	477,8	330,4	434,7	483,0	459,5	365,3	423,3	419,4	395,0
9	706,1	589,3	721,7	712,5	698,0	589,4	596,3	684,8	682,1	593,0	649,5	644,4	622,7
10	863,2	830,0	753,0	861,3	866,3	820,4	800,7	855,2	849,7	804,8	787,9	837,6	783,1
11	958,4	932,6	804,7	905,9	978,4	897,7	747,0	910,3	952,6	907,9	774,2	879,8	886,6
12	969,4	932,6	907,9	927,7	990,9	897,7	804,5	913,0	972,4	907,9	767,9	898,7	952,2
13	974,5	932,6	870,0	913,2	988,0	897,7	887,5	933,5	975,4	907,9	839,3	930,6	959,1
14	960,3	932,6	817,9	856,0	971,8	897,7	858,8	898,0	962,1	907,9	882,7	950,0	914,2
15	883,1	911,3	813,0	841,5	895,7	897,7	843,8	843,9	888,4	928,1	796,4	835,6	822,8
16	727,8	830,0	596,6	626,0	737,7	788,2	695,2	685,0	736,9	804,8	641,9	649,7	653,8
17	543,6	293,0	463,9	570,2	507,4	447,1	430,0	417,9	541,1	409,8	432,6	450,2	439,9
18	312,0	172,2	479,4	453,7	246,8	213,8	161,2	146,8	280,3	163,1	149,0	138,9	194,9
19	182,9	21,7	203,7	192,2	116,9	26,5	48,7	45,1	96,4	22,6	46,5	32,6	37,9
20	144,1	2,7	76,7	44,9	83,6	2,2	51,9	12,2	33,0	3,6	38,9	13,9	0
21	120,5	0,0	10,1	-16,3	77,8	30,9	32,6	-4,6	41,9	0,0	14,8	-0,3	0
22	111,7	0,0	14,5	-15,9	81,1	30,9	39,1	-11,3	71,6	0,0	-2,4	2,3	0
23	90,8	0,0	34,5	-3,2	93,9	0,0	54,1	-12,4	66,4	0,0	27,1	0,0	0

Çizelge 5.2 4 farklı makine öğrenmesi algoritmasının Eskişehir Merkez, Seyitgazi, Sivrihisar bölgeleri ile 24 Mayıs günü için verdiği sonuçları içermektedir. Tabloda bir gün için alınan toplam 24 tahmin değeri bulunmaktadır. Değerler incelendiğinde Eskişehir Merkez ve Seyitgazi bölgelerinde GSR algoritmasının, Sivrihisar bölgesi için RA algoritmasının diğer algoritmalara göre daha iyi performansa sahip olduğu görülmektedir.

Çalışmada, üç farklı bölgeden alınan SHT verileri kullanılarak tahmin modelleri geliştirilmiştir. SHT verilerinin gerekliliğini göstermek amacıyla 24 Mayıs günü için 4 farklı makine öğrenmesi algoritması SHT verileri kullanılmadan test sonuçları alınmıştır ve görsel olarak değerlendirmek için Şekil 5.4’de verilmiştir.



Şekil 5.4. 24 Mayıs için SHT verisiz test sonuçları

Şekil 5.4’de GES üretimi ve makine öğrenmesi algoritmaları ile SHT verileri kullanılmadan elde edilen test sonuçlarının oluşturduğu grafikler verilmiştir. Tahmin modelinin girdileri saat ve santral geçmiş güç değerlerinden oluşmaktadır. Şekilde verilen grafikler incelendiğinde DR algoritmasının, GES üretiminin oluşturduğu gauss eğrisinin yükselen kısımda kısmen yakaladığı, alçalan kısmında ise gauss eğrisinden uzaklaştığı görülmektedir. DR algoritması, GES üretiminin oluşturduğu gauss eğrisinin tepe değerlerinden çok daha düşük sonuçlar verdiği görülmektedir. RA algoritması, GES üretiminin oluşturduğu gauss eğrisinin yükselen ve alçalan kısımda gauss eğrisinden uzaklaştığı görülmektedir. RA algoritması, GES üretiminin oluşturduğu gauss eğrisinin tepe değerlerinden daha düşük ve değişken sonuçlar verdiği görülmektedir. DVM algoritması, GES üretiminin oluşturduğu gauss eğrisinin yükselen kısımda eğriye kısmen yaklaştığı, alçalan kısmında ise gauss eğrisinden uzaklaştığı görülmektedir. DVM algoritması, GES üretiminin oluşturduğu gauss eğrisinin tepe değerlerinden daha düşük sonuçlar verdiği görülmektedir. GSR algoritması, GES üretiminin oluşturduğu gauss eğrisinin yükselen ve alçalan kısmında eğriden uzaklaştığı görülmektedir. GSR algoritması, GES üretiminin oluşturduğu gauss eğrisinin tepe değerlerinden daha düşük sonuçlar verdiği, tahmin modelinin gauss eğrisinde meydana gelen azalma ve artışlara daha az tepki vererek eğriyi yakalayamadığı görülmektedir.

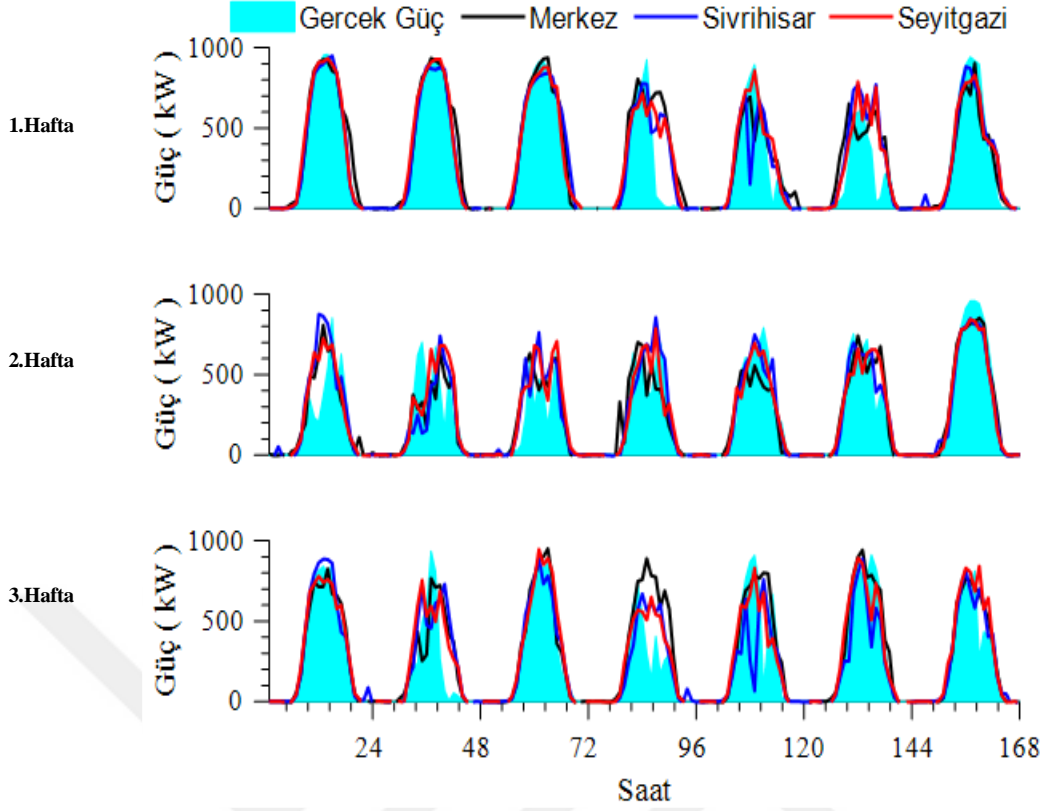
Çalışmada, 24 Mayıs günü için 4 farklı makine öğrenmesi algoritmasının SHT verisiz test sonuçları Çizelge 5.3'te verilmiştir.

Çizelge 5.3. 24 Mayıs için 4 farklı makine öğrenmesi algoritmasının SHT verisiz test sonuçları

Saat	DR	RA	DVM	GSR	GSR+SHT	Gerçek Güç (kWh)
0	46,7	0,0	28,4	0,3	2,4	0
1	56,4	0,0	14,2	0,0	3,0	0
2	47,2	0,0	8,9	0,0	0,4	0
3	37,3	0,0	-7,7	0,1	-4,6	0
4	31,8	31,1	40,8	8,6	-7,4	0
5	38,9	31,1	78,8	30,7	-2,5	0
6	67,2	14,6	82,2	44,2	17,0	22,4
7	212,7	134,2	161,5	164,8	119,2	146,6
8	484,3	348,0	394,3	389,1	311,2	395,0
9	706,1	589,3	721,7	712,5	537,5	622,7
10	863,2	830,0	753,0	861,3	652,1	783,1
11	958,4	932,6	804,7	905,9	724,5	886,6
12	969,4	932,6	907,9	927,7	760,8	952,2
13	974,5	932,6	870,0	913,2	779,2	959,1
14	960,3	932,6	817,9	856,0	774,0	914,2
15	883,1	911,3	813,0	841,5	678,8	822,8
16	727,8	830,0	596,6	626,0	504,4	653,8
17	543,6	293,0	463,9	570,2	365,5	439,9
18	312,0	172,2	479,4	453,7	166,5	194,9
19	182,9	21,7	203,7	192,2	25,2	37,9
20	144,1	2,7	76,7	44,9	1,2	0
21	120,5	0,0	10,1	-16,3	-5,3	0
22	111,7	0,0	14,5	-15,9	-3,6	0
23	90,8	0,0	34,5	-3,2	5,0	0

Çizelge 5.3 4 farklı makine öğrenmesi algoritmasının SHT verileri kullanmadan 24 Mayıs günü için verdiği sonuçları ve en iyi performansa sahip olan GSR algoritmasının SHT verileri kullanılarak elde edilen test sonuçlarını içermektedir. Tabloda bir gün için alınan toplam 24 tahmin değeri bulunmaktadır. Değerler incelendiğinde GSR+SHT modelinin gerçek güç değerlerine en yakın değerleri verdiği görülmektedir. Bu durum SHT verilerinin tahmin performansını arttırdığını ve tahmin modeli için gerekli olduğunu göstermektedir.

GSR algoritmasının performansını farklı bölgelerden alınan veriler üzerinden görsel olarak değerlendirmek için Şekil 5.5'te verilen grafikler oluşturulmuştur. Grafikler, test sürecinde gerçekleşen üretimleri ve yapılan tahminleri göstermektedir. Test süreci toplam üç haftalık zaman aralığındaki veriler kullanılarak gerçekleştirilmiştir. Şekildeki üst, orta ve alt grafikler sırasıyla test sürecinin birinci, ikinci ve üçüncü haftalarında oluşturulmuştur.



Şekil 5.5. Test sürecinde gerçekleşen üretimler ve GSR algoritması tahminleri

Şekilde verilen grafikler incelendiğinde GES tesisinin test sürecindeki bazı günlerde kararlı üretim gerçekleştirdiği görülmektedir. 1. Haftanın 1-3. günlerinde, 2. haftanın 7. gününde ve 3. haftanın 1. ve 3. gününde gerçekleşen bu kararlı üretimlerde her üç veri seti ile geliştirilen modeller iyi performans sergilemiş ve tahmin değerleri üretim değerlerine oldukça yaklaşmıştır. GES tesisi test sürecindeki bazı günlerde ise beklenenden düşük ve değişken üretim gerçekleştirmiştir. 1. haftanın 4-5 ve 6. günlerinde, 2. haftanın 1-6. günlerinde ve 3. Haftanın 2-4-5 ve 7. günlerinde gerçekleşen bu düşük ve değişken üretimlerde tahmin modeli performansları üretim karasızlığının artması sebebiyle kabul edilebilir seviyede düşmüştür. Ani üretim düşüşü yaşanan günlerde tahmin modelleri iyi bir performans yakalayamamıştır. Bu durumun santralin bazı tahmin edilemeyen meteorolojik olaylara verdiği tepkiden kaynaklandığı düşünülmektedir.

6. SONUÇ ve ÖNERİLER

Temiz ve sınırsız olan yenilenebilir enerji kaynakları günden güne artan bir hızla elektrik şebeke sistemlerinde kullanılmaktadır. Ancak yenilenebilir enerji üretim tesisleri, değişken ve kararsız üretim özelliklerine sahiptir ve şebeke işletmesinde ek maliyetler oluşturmaktadır. Bu maliyetleri ortadan kaldırmak için özellikle gün öncesi planlama sürecinde hesaplamalara dâhil edilecek kaliteli üretim tahminlerine ihtiyaç duyulmaktadır. Bu çalışmada, MGM'den alınan meteorolojik tahminler ve geçmiş GES üretim verileri kullanılarak, makine öğrenmesi algoritmaları ile gün öncesi tahmin modelleri geliştirilmiştir. Eskişehir ilindeki bir GES tesisinde yapılan uygulamalar sonucunda, aşağıdaki sonuçlara varılmıştır.

1) Yapılan test çalışmalarında en iyi performansın Seyitgazi verileri ile elde edildiği görülmüştür.

2) DR, RA, DVM ve GSR algoritmaları kullanılarak geliştirilen tahmin modellerinden, elde edilen bulgular GSR algoritmasının diğer üç algoritmaya göre daha başarılı olduğunu göstermiştir.

3) Önerilen model sonuçları SHT verileri kullanılmadan elde edilen sonuçlar ile karşılaştırıldığında, SHT verilerinin tahmin performansını arttırdığı ve tahmin modeli için gerekli olduğu görülmüştür.

4) Test sürecindeki model performansları incelendiğinde en yüksek tahmin hatalarının ani üretim düşüşlerinin yaşandığı günlerde gerçekleştiği görülmüştür.

Bu çalışmada bazı meteorolojik tahmin verileri ve makine öğrenmesi algoritmalarının GES üretim tahminindeki performansları gösterilmiştir. İleride yapılacak çalışmalarda, gelişmiş makine öğrenmesi algoritmaları (YSA, Derin Öğrenme) kullanılarak tahmin performansı iyileştirilebilir ve farklı bölgelerde, farklı makine öğrenmesi algoritmaları değerlendirilebilir.

KAYNAKÇA

- Ahmed, R., Sreeram, V., Mishra, Y., & Arif, M. (2020). A Review And Evaluation Of The State-Of-The-Art In PV Solar Power Forecasting: Techniques And Optimization. *Renewable And Sustainable Energy Reviews*, 124, 109792.
- Akarslan, E. (2014). Güneş Enerjisinin Tahmininde Sinyal İşleme Tabanlı Yeni Yaklaşımlar. Eskişehir Osmangazi Üniversitesi, Fen Bilimleri Enstitüsü, Elektrik-Elektronik Mühendisliği Anabilim Dalı, Doktora Tezi.
- Akbaba, E. C. (2019). Using Artificial Neural Network (Ann) Techniques For Solar Irradiation Predictions. Ankara: Orta Doğu Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Fizik Ana Bilim Dalı, Yüksek Lisans Tezi.
- Akça, M. F. (2020, Ağustos 25). Nedir Bu Destek Vektör Makineleri? (Makine Öğrenmesi Serisi-2). Medium: <https://124.im/zAYv1> adresinden alındı
- Almonacid, F., Higuera, P., Fernandez, E., & Hontoria, L. (2014). A Methodology Based On Dynamic Artificial Neural Network For Short-Term Forecasting Of The Power Output Of A PV Generator. Centre of Advanced Studies in Energy and Environment, University of Jaen, Spain.
- Antonanzas, J., Osorio, N., Escobar, R., Martinez, P., & Antonanzas, T. (2016). Review of Photovoltaic Power Forecasting. 78-111. *Solar Energy*.
- Ataman, A. R. (2007). Türkiye’de Yenilenebilir Enerji Kaynakları. Ankara: Ankara Üniversitesi, Kamu Yönetimi ve Siyaset Bilimi (Yönetim Bilimleri) Anabilim Dalı, Yüksek Lisans Tezi.
- Balık, D. (2020, Mart 22). MGT: <https://124.im/Y3J> adresinden alındı
- Bekçioğulları, M. F. (2022). Güneş Enerjisinin Kısa Dönem Tahmini İçin Derin Öğrenme Tabanlı Bir Metodun Geliştirilmesi. Kahramanmaraş: Kahramanmaraş Sütçü İmam Üniversitesi, Fen Bilimleri Enstitüsü, Elektrik-Elektronik Anabilim Dalı, Yüksek Lisans Tezi.

- Bouzerdoum, M., Mellit, A., & Pavan, M. (2013). A Hybrid Model (SARIMA–SVM) For Short-Term Power Forecasting Of A Small-Scale Grid-Connected Photovoltaic Plant. Science Direct,Solar Energy.
- Chugh, A. (2020, Aralık 8). MAE, MSE, RMSE, Coefficient of Determination, Adjusted R Squared — Which Metric is Better? Medium: <https://124.im/12zyX> adresinden alındı
- Çetin, Ö. (2022). Güneş Enerji Santrallerinde Derin Öğrenme İle Aylık Elektrik Üretim Tahmini. Burdur: Burdur Mehmet Akif Ersoy Üniversitesi, Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği Anabilim Dalı, Yüksek Lisans Tezi.
- Çolakoğlu, M., Aslan, S., İyikul, E., & Özenbaş, M. (2021). Türkiye ve Dünyada Güneş Enerjisi Sektörü. PWC, 16.
- Daş, M., Balpetek, N., Kavak, E., & Akpınar, S. (2019). Investigation Of Wind Energy Potential Of Different Provinces Found İn Turkey And Establishment Of Predictive Model Using Support Vector Machine Regression With The Obtained Results. Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi, 34(4),2203-2213.
- Demirbaş, Ş., Demirbaş, M., Sefa, İ., & Çolak, İ. (2008). Building of W&S Energy System. İtaly: International Symposium on Power Electronics, Electrical Drives, Automation and Motion,1466-1469.
- Durmuş, A., & Kumbaroğlu, G. (2021, Nisan 12). Türkiye Enerjide Dışa Bağımlılığını Azaltma Yönünde İlerliyor. Boğaziçi Üniversitesi Haberler: <https://124.im/3YqMN> adresinden alındı
- Genç, Y. A. (2015). Osmaniye İli İçin Yatay Düzleme Gelen Güneş Radyasyon Tahminininde Yeni Model Geliştirilmesi. Osmaniye: Osmaniye Korkut Ata Üniversitesi , Fen Bilimleri Enstitüsü , Makine Mühendisliği Anabilim Dalı, Yüksek Lisans Tezi.
- Gök, A. O. (2019). Güneş Enerjisi Santralleri İçin Bir Kısa Süreli Üretim Tahmin Sistemi Geliştirilmesi. Kahramanmaraş: Kahramanmaraş Sütçü İmam Üniversitesi, Fen Bilimleri Enstitüsü, Elektrik Elektronik Mühendisliği Anabilim Dalı, Yüksek Lisans Tezi,1-3s.

- Gök, A. O., Yıldız, C., & Şekkeli, M. (2019). Yapay Sinir Ağları Kullanarak Kısa Dönem Güneş Enerjisi Santrali Üretim Tahmini: Kahramanmaraş Örnek Çalışması. Uluslararası Doğu Anadolu Fen Mühendislik ve Tasarım Dergisi, 1(2),186-195.
- Görez, T., & Alkan, A. (2005). Türkiye' Nin Yenilenebilir Enerji Kaynakları Ve Hidroelektrik Enerji Potansiyeli. III. Yenilenebilir Enerji Kaynakları Sempozyumu, (s. 21-22). Antalya.
- Güner , N., & Çomak, E. (2011). Mühendislik Öğrencilerinin Matematik I Derslerindeki Başarısının Destek Vektör Makineleri Kullanılarak Tahmin Edilmesi. Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi, 87-96.
- Işık, E., & İnallı, M. (2011). Tunceli İli İçin Güneş Işınımının Yapay Sinir Ağları İle Tahmini. Elazığ: Fırat Üniversitesi,Engineering Sciences, 190-194.
- Jimenez, F. A., Jimenez, A. M., Falces, A., Villena, M. M., Garrido, E. G., Santillan, P. L., ... Santamaria, P. Z. (2021). Short-Term Power Forecasting System For Photovoltaic Plants. Universidad de La Rioja,Department of Electrical Engineering,Renewable Energ.
- Kader, G. (2022, Şubat). Sistem Tanılama Makine Öğrenmesi Ve Derin Öğrenme Modelleri İle Güneş Radyasyonu Tahmini. İstanbul: İstanbul Teknik Üniversitesi, Enerji Bilim Ve Teknoloji Anabilim Dalı ,Enerji Bilim Ve Teknoloji Programı,Yüksek Lisans Tezi.
- Kapluhan, E. (2014). Enerji Coğrafyası Açısından Bir İnceleme: Güneş Enerjisinin Dünya'daki Ve Türkiye'deki Kullanım Durumu. İstanbul Üniversitesi Edebiyat Fakültesi Coğrafya Bölümü Coğrafya Dergisi, 70-98.
- Kara, A. (2019). Uzun-Kısa Süreli Bellek Ağı Kullanarak Global Güneş Işınımı Zaman Serileri Tahmini. Ankara: Gazi Üniversitesi,Dergipark Akademik ,Fen Bilimleri Dergisi,Cilt 7, Sayı 4, 882 - 892.
- Karadöl, E. T., & Kavaz, İ. (2017). Dünya'da ve Türkiye'de Yenilenebilir Enerji . SETA, 197.

- Kavzođlu, T., řahin, E. K., & řölkesen, İ. (2021). Heyelan Duyarlılıđının İncelenmesinde Regresyon Ađaçlarının Kullanımı: Trabzon Örneđi. Harita Dergisi, 21-33.
- Kayri, İ. (2017). Güneş Panelleri İle Üretilen Enerjinin Ortam Bilgileri Kullanılarak Yapay Sinir Ađlarıyla Tahmini. Elazıđ: Fırat Üniversitesi, Fen Bilimleri Enstitüsü, Elektrik Elektronik Mühendisliđi Anabilim Dalı, Doktora Tezi.
- Kayri, M., & Boysan, M. (2012). Bilişsel Yetkinlik ile Depresyon Düzeyleri İlişkinin Sınıflandırma ve Regresyon Ađacı Analizi ile İncelenmesi. Ankara: Hacettepe Üniversitesi Eğitim Fakültesi Dergisi, 34(34), 168-177.
- Khatib, T. (2015). A Novel Approach for Solar Radiation Prediction Using Artificial Neural Network. Nanyang Technological University, Department of Energy Engineering and Environment, Energy Sources.
- Kılıç, H. (2016). Güneş Enerjisi İle İlgili Meteorolojik Verilerin Tahmini İçin Yöntem Geliştirilmesi. Diyarbakır: Dicle Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi.
- Kılıç, S. (2013, řubat 1). Doğrusal Regresyon Analizi. Ankara: Gülhane Askeri Tıp Fakültesi, Cilt 3, Sayı 2, 90 - 92.
- Kim, J.-G., Kim, D.-H., Yoo, W.-S., Lee, J.-Y., & Kim, Y. (2017). Daily Prediction Of Solar Power Generation Based On Weather Forecast Information İn Korea. IET Renewable Power Generation, 11(10), 1268-1273s.
- Kıymaz, Y. E. (2020, Aralık). Güneş Enerjisi Santrallerinde Derin Öğrenme Kullanılarak Elektrik Üretimi Tahmininin Yapılması. Konya: Necmettin Erbakan Üniversitesi ,Fen Bilimleri Enstitüsü, Enerji Sistemleri Mühendisliđi Anabilim Dalı, Yüksek Lisans Tezi.
- Koç, E., & Kaya, K. (2015). Enerji Kaynakları–Yenilenebilir Enerji Durumu. Mühendis ve Makina, Cilt 56, sayı 668, s. 36-47.
- Kök, M., & Yakıncı, Z. D. (2017). Yenilenebilir Enerji Ve Toplum Sađlıđı. Malatya: İnönü Üniversitesi. Sađlık Hizmetleri Meslek Yüksekokulu Dergisi, Cilt 5 , Sayı 1.

- Larson, D., Nonnenmacher, L., & Coimbra, C. (2016). Day-Ahead Forecasting Of Solar Power Output From Photovoltaic Plants In The American Southwest. *Renewable Energy*,91,11-20s.
- Liu, L., Zhaoa, Y., Chang, D., Xie, J., Ma, Z., Sun, Q., . . . Wennersten, R. (2018). Prediction Of Short-Term PV Power Output And Uncertainty Analysis. *Applied Energy*,Science Direct.
- Maham, F. H. (2022, Ocak). Güneş Işınım Tahmini İçin Farklı Güneşlenme Durumlarını Dikkate Alan Hibrit Bir Yöntem Tasarımı. Afyon: Afyon Kocatepe Üniversitesi ,Fen Bilimleri Enstitüsü, Elektrik Mühendisliği – Yenilenebilir Enerji Sistemleri Anabilim Dalı, Yüksek Lisans Tezi.
- Niele, F. (2005). *Energy Engine and Evolution*. içinde
- Nkurlyngoma , O. (2018, Eylül). Kayseri İli İçin Güneş Santrali Elektrik Enerjisi Üretim Tahmin Planlaması. Kayseri: Erciyes Üniversitesi, Fen Bilimleri Enstitüsü ,Enerji Sistemleri Anabilim Dalı,Yüksek Lisans Tezi.
- Okur, Y. (2016). Akdeniz Bölgesine Ait Meteorolojik Veriler Kullanılarak Yapay Sinir Ağları Yardımıyla Güneş Enerjisinin Tahmini. Osmaniye: Osmaniye Korkut Ata Üniversitesi ,Fen Bilimleri Enstitüsü Fizik Ana Bilim Dalı ,Yüksek Lisans Tezi.
- Oruç, E. N. (2021, Kasım). Yapay Sinir Ağları Kullanılarak Kısa Süreli Güneş Enerjisi Tahmini. İstanbul: İstanbul Teknik Üniversitesi, Meteoroloji Mühendisliği Anabilim Dalı ,Atmosfer Bilimleri Programı, Yüksek Lisans Tezi.
- Roper, D. (2016). *Future World Energy*. Professor Emeritus of Physics, College of Arts and Sciences.
- Serttaş, F. (2015, Temmuz). Güneş Işınım Şiddeti Tahminine Örüntü Tarama Tabanlı Yeni Bir Yaklaşım. Afyon Kocatepe Üniversitesi ,Fen Bilimleri Enstitüsü, Yenilenebilir Enerji Sistemleri Anabilim Dalı, Yüksek Lisans Tezi.
- Solar Avm. (2022, Haziran 23). Enerji Kaynağı Olarak Güneş ve Potansiyeli. Solar Avm: <https://124.im/HqaeFwj> adresinden alındı

- Süme, V., & Fırat, S. S. (2020). Hidroelektrik Santraller ve Trabzon İlinde Bulunan Hidroelektrik Santrallerin Şehir ve Doğu Karadeniz Havzası İçin Önemi. Rize: Recep Tayyip Erdoğan Üniversitesi, Mühendislik Fakültesi, İnşaat Mühendisliği Bölümü, Türk Hid. Der. (Tur. J. Hyd.), Sayfa 11-24.
- Şenel, T., Cengiz, M. A., Savaş, N., & Terzi, Y. (2009). Çoklu Doğrusal Regresyonda Model Seçiminde Genelleştirilmiş Toplamsal Modellerin Kullanımı. Dergipark.
- Taktak, F., & Ilı, M. (2018). Güneş Enerji Santrali (GES) Geliştirme: Uşak Örneği. Uşak: Dergipark Akademik, Cilt 3, Sayı 1, 1 - 21.
- Taş, B. (2020, Mayıs 15). Doğrusal Regresyon (Linear Regression). Stay Curious: <https://124.im/uWJh2> adresinden alındı
- Tiryaki, B. (2008). Predicting İntact Rock Strength for Mechanical Excavation Using Multivariate Statistics, Artificial Neural Networks, and Regression Trees. Engineering Geology (s. 51-60). içinde
- Uğuz, S. (2019). Makine Öğrenmesi Teorik Yönleri ve Python Uygulamaları ile Bir Yapay Zeka Ekolü. Ankara: Isparta Üniversitesi, Nobel Akademik Yayıncılık, 312s.
- Uyar, F. (2016, Aralık 1). Güneş Enerjisinden Elektrik Üretimi Yöntemleri Nelerdir ? Enerji Beş Temiz Enerji Portalı: <https://124.im/fugw4t> adresinden alındı
- Vega, F., Matías, J., Andrade, M., Reigosa, M., & Covelo, E. (2009). Classification and Regression Trees (Carts) for Modelling The Sorption and Retention of Heavy Metals by Soil. Journal of Hazardous Materials. Journal of Hazardous Materials (s. 615-624). içinde
- Wang, J., Ran , R., & Zhou, Y. (2017). A Short-Term Photovoltaic Power Prediction Model Based On An FOS-ELM Algorithm. Tianjin University, Applied Science, Key Laboratory of Smart Grid of Ministry of Education.
- Wang, K., Qi, X., & Liu, H. (2019). Photovoltaic Power Forecasting Based LSTM-Convolutional Network. College of Automation, Harbin Engineering University, Harbin, 150001, China, Science Direct.
- Web 1. (tarih yok). Web 1: <https://tr.wikipedia.org/wiki/Enerji> adresinden alındı

- Web 2. (tarih yok). Web 2. Allianz: <https://124.im/sjyHO> adresinden alındı
- Web 3. (tarih yok). Wikipedia. Web 3: <https://124.im/9UTvW> adresinden alındı
- Web 4. (2022). T.c Enerji ve Tabii Kaynaklar Bakanlığı. <https://124.im/msjO> adresinden alındı
- Web 5. (tarih yok). Ayek Uluslararası Danışmanlık Ve Savunma Sanayi: <https://124.im/c7A6Ga> adresinden alındı
- Web 6. (tarih yok). Enerji İşleri Genel Müdürlüğü. GEPA Enerji: <https://124.im/FARCZH> adresinden alındı
- Web 7. (2011, Şubat 16). Solar Bazaar: <https://shorturl.at/diGX2> adresinden alındı
- Web 8. (tarih yok). Güneş Enerji Sistemleri. Solar Plaza: <https://solarplaza.com.tr/endustriyel-cati-ges-> adresinden alındı
- Web 9. (2021, Mayıs 24). Yüzer Güneş Enerjisi Santralleri ve Beklentiler. Dünya Enerji Konseyi Türk Milli Komitesi: <https://124.im/Ltea> adresinden alındı
- Web 10. (2021, Ekim 31). Tarlanıza Kaç Kw Güneş Enerjisi Santrali Kurulabilir? Gezegen Solar: <https://124.im/X6Ix7> adresinden alındı
- Web 11. (tarih yok). Güneş Pilleri. Robotik Sistem. adresinden alındı
- Web 12. (tarih yok). Meteoroloji Gözlem İstasyonları. Anadolu Ajansı: <https://124.im/6LE4a> adresinden alındı
- Web 13. (tarih yok). Meteorolojide Kullanılan Alet ve Cihazlar. Meteoroloji Genel Müdürlüğü: <https://124.im/ajgSs> adresinden alındı
- Yalçın, E., & İlhan, M. (2012). Muğla Güneş Enerjisi Sektör Yatırım Raporu. Geka-Muğla Yatırım Destek Ofisi: https://geka.gov.tr/uploads/pages_v/mugla-gunes-enerjisi-sektor-yatirim-raporu.pdf adresinden alındı
- Yang, H. T. (2014). A Weather-Based Hybrid Method For 1-Day Ahead Hourly Forecasting Of PV Power Output. IEEE transactions on sustainable energy, 5(3), 917-926s.

- Yavuz, C. (2018). Konya Da Kısa Dönemli Güneş Enerjisi Üretim Tahmini. Konya: Necmettin Erbakan Üniversitesi ,Fen Bilimleri Enstitüsü,Endüstri Mühendisliği Anabilim Dalı,Yüksek Lisans Tezi.
- Yıldırım, H. B. (2016). Introducing Novel Models To Estimate Global Solar Radiation Based On Meteorological Parameters In Eastern Mediterranean Region. Adana: Çukurova University Institute Of Natural And Applied Sciences, Department Of Electrical And Electronics Engineering,Master Of Science.
- Yıldırım, Y. (2018, Eylül 12). Karar Ağaçları (Decision Tree). İstanbul, Türkiye.
- Yıldız, C., & Açıkgöz, H. (2020, Ağustos). A Kernel Extreme Learning Machine-Based Neural Network To Forecast Very Short-Term Power Output Of An On-Grid Photovoltaic Power Plant. *Energy Sources, Part A: Recovery, Utilization, and Environmental Effects. Energy Sources, Part A: Recovery, Utilization, and Environmental Effects*, 43(4), 395-412.
- Yıldız, C., Açıkgöz, H., Korkmaz, D., & Budak, Ü. (2021). An Improved Residual-Based Convolutional Neural Network For Very Short-Term Wind Power Forecasting. *International Journal of Green Energy*, 18(5), 525-539.
- Yılmaz, Ş. (2016). Dünyada Ve Türkiye’de Birincil Enerji Arzı. Türkiye’nin Enerji Görünümü, 5-17.
- Yu, X., & Qu, H. (2010). Wind Power In China—Opportunity Goes With Challenge. *Renewable and Sustainable Energy Reviews*,s. 2232-2237.
- Yumru, İ. T. (2020). Spatiotemporal Forecasting Of Solar Power Generation With Deep Learning. İstanbul: Boğaziçi Üniversitesi, Fen Bilimleri Enstitüsü Endüstri Mühendisliği Ana Bilim Dalı ,Yüksek Lisans Tezi.
- Zhang, J., Tan, Z., & Wei, Y. (2019). An Adaptive Hybrid Model For Day-Ahead Photovoltaic Output Power Prediction. *Science Direct*.
- Zhang, Y., Beaudin, M., Taheri, R., Zareipour, H., & Wood, D. (2015). Day-Ahead Power Output Forecasting For Small-Scale Solar Photovoltaic Electricity Generators. *IEEE Transactions On Smart Grid*, 6(5), 2253-2262s.