

T.C.
MALATYA TURGUT ÖZAL ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

TÜRKİYE'DE BULUNAN GÜNEŞ ENERJİ SANTRALLERİNDEKİ
ELEKTRİK ÜRETİMİNİN ARAŞTIRILMASI VE YAPAY ZEKÂDA
MODELENMESİ

ÖMER OSMAN ORHAN

YÜKSEK LİSANS TEZİ
BİYOMEDİKAL MÜHENDİSLİĞİ DİSİPLİNLER ARASI ANA BİLİM DALI

OCAK 2025

ONUR SÖZÜ

Yüksek Lisans Tezi olarak sunduğum “Türkiye’de Bulunan Güneş Enerji Santrallerindeki Elektrik Üretiminin Araştırılması ve Yapay Zekâda Modellenmesi” başlıklı bu çalışmanın bilimsel ahlak ve geleneklere aykırı düşecek bir yardıma başvurmaksızın tarafımdan yazıldığını ve yararlandığım bütün kaynakların, hem metin içinde hem de kaynakçada yöntemine uygun biçimde gösterilenlerden oluştuğunu belirtir, bunu onurumla doğrularım.

Ömer Osman ORHAN

ÖZET

Yüksek Lisans Tezi

TÜRKİYE’DE BULUNAN GÜNEŞ ENERJİ SANTRALLERİNDEKİ ELEKTRİK ÜRETİMİNİN ARAŞTIRILMASI VE YAPAY ZEKÂDA MODELLENMESİ

Ömer Osman ORHAN

Malatya Turgut Özal Üniversitesi

Lisansüstü Eğitim Enstitüsü

Biyomedikal Mühendisliği Disiplinler Arası Ana Bilim Dalı

57+x sayfa

2025

Danışman: Doç. Dr. Ahmet Beyzade DEMİRPOLAT

Günümüzde nüfus artışı ve teknolojik gelişmelerin bir sonucu olarak enerjiye olan ihtiyaç her geçen gün artmaktadır. Artan enerji ihtiyacı insanları alternatif enerji kaynaklarına yöneltmiştir. Bu bağlamda çevre dostu güneş enerjisi günümüzde önem kazanmaktadır. Güneş enerjisi teknolojisinin gelişmesiyle birlikte; Güneş ışınları fotovoltaiik paneller tarafından toplanarak elektrik enerjisine dönüştürülür. Bu sayede enerji ihtiyacımızın büyük bir kısmını çevre dostu bir şekilde karşılayabiliyoruz. Çalışmamızda Türkiye’de belirli illerin farklı günlerde değişen iklim koşullarına bağlı olarak üretilen elektrik miktarları, güneş enerjisi santrallerinden saha çalışmaları sonucunda yapılan ölçümlerden elde edilmiştir. Geleceğe ışık tutacak bir model oluşturmak ve alınan ölçümlerin doğruluğunu belirlemek amacıyla fotovoltaiik panellerin üreteceği gücü sıcaklık, nem, rüzgâr ve ışıınım değeri gibi parametrelere bağlı olarak tahmin etmek üzere yapay zekâ algoritması eğitildi.

Bu araştırmalar sonucunda Türkiye’deki güneş enerjisi santralleri arasında sahadan alınan ölçümler ve oluşturulan modeller açısından en iyi sonuçlar Mardin ilinde elde edilmiştir. Model, Mardin ilindeki günlük verilerin %98’ine yaklaştı. Çalışmamızda iklim değişkenliğinin güneş enerjisinin faydalı ve verimli kullanımına etkisi, güneş enerjisi santrallerinde saha çalışmaları sonucunda yapılan ölçümlerin verimini etkileyen faktörler ve üretilen enerji verilerinin yapay zekâ ile modellenmesi konuları ele alınmıştır. Çalışmamızda bunların birleştirilmesi ve yorumlanması, bölgedeki güneş enerjisi santrallerinin kapasiteleri ile ilgili literatüre büyük katkı sağlayacaktır.

ANAHTAR KELİMELEER: Fotovoltaiik panel, Yapay zekâ, Makine öğrenmesi, Verim, Enerji

ABSTRACT

M.Sc.Thesis

INVESTIGATION OF ELECTRICITY PRODUCTION IN SOLAR POWER PLANTS IN TURKEY AND MODELING IT IN ARTIFICIAL INTELLIGENCE

Ömer Osman ORHAN

Malatya Turgut Özal University

Institute of Graduate Studies

Interdisciplinary Department of Biomedical Engineering

57+x pages

2025

Supervisor: Doç. Dr. Ahmet Beyzade DEMİRPOLAT

Today, as a result of population growth and technological developments, the need for energy is increasing day by day. The increasing need for energy has led people to alternative energy sources. In this context, environmentally friendly solar energy is gaining importance today. With the development of solar energy technology; Sun rays are collected by photovoltaic panels and converted into electrical energy. In this way, we can meet a large part of our energy needs in an environmentally friendly way. In our study, the amount of electricity produced depending on the changing climatic conditions of certain provinces in Turkey on different days was obtained from the measurements made as a result of field studies from solar power plants. In order to create a model that will shed light on the future and to determine the accuracy of the measurements taken, an artificial intelligence algorithm was trained to predict the power generated by photovoltaic panels depending on parameters such as temperature, humidity, wind and radiation value.

As a result of these studies, the best results were obtained in Mardin province in terms of measurements taken from the field and the models created among the solar power plants in Turkey. The model approached 98% of the daily data in Mardin province. In our study, the effect of climate variability on the beneficial and efficient use of solar energy, factors affecting the efficiency of measurements made as a result of field studies in solar power plants and modeling of energy data produced with artificial intelligence are discussed. Combining and interpreting these in our study will make a great contribution to the literature on the capacities of solar power plants in the region.

KEYWORDS: Photovoltaic panel, Artificial intelligence, Machine learning, Efficiency, Energy.

TEŞEKKÜR

Yüksek lisans öğrenimim boyunca, sabırla ve ilgiyle bana yol gösteren danışman hocam Doç. Dr. Ahmet Beyzade DEMİRPOLAT' a ve hayatım boyunca desteklerini benden hiçbir zaman esirgemeyen aileme teşekkür ederim.



İÇİNDEKİLER

ONUR SÖZÜ	i
ÖZET	ii
ABSTRACT	iii
TEŞEKKÜR	iv
İÇİNDEKİLER.....	v
KISALTMALAR.....	viii
ÇİZELGELER DİZİNİ.....	ix
ŞEKİLLER DİZİNİ.....	x
1. GİRİŞ.....	1
1.1. Türkiye’de Güneş Enerjisinin Durumu	3
1.2. Fotovoltaik Sistemler	6
1.2.1. Fotovoltaik sistemlerde hücre yapısı	6
1.2.2. Fotovoltaik sistemlerde hücre çeşitleri	7
1.2.2.1. Kristal yapıli silisyum hücreler	7
1.2.2.2. İnce filmden yapılan güneş pilleri.....	8
1.2.2.3. Grup III-V bileşik fotovoltaik hücreleri	8
1.2.2.4. Çok eklemli (tandem) fotovoltaik hücreler	8
1.2.2.5. Organik ve polimer fotovoltaik hücreler	9
1.2.3. Fotovoltaik sistem çeşitleri.....	9
1.2.3.1. Off Grid (şebekeden bağımsız) sistemler	9
1.2.3.2. On Grid (şebekeye bağıli) sistemler	10
1.2.3.3. Hibrid sistemler	11
1.3. Yapay Zekâ	12
1.3.1. Yapay sinir ağıları.....	14
1.3.2. Yapay sinir ağılarının özellikleri	15
1.3.3. Yapay sinir ağılarının sınıflandırılması.....	16
1.3.3.1. İleri beslemeli ağı.....	17
1.3.3.2. Geri beslemeli ağı	17
1.3.4. Tek katmanli sinir ağıları	18

1.3.5. Çok katmanlı sinir ağıları.....	19
1.3.6. Geriye yayılım algoritması.....	20
2. LİTERATÜR ARAŞTIRMASI.....	21
3. MATERYAL VE YÖNTEM.....	26
3.1. Veri Setleri.....	27
3.2. Modelin Seçilmesi ve Değerlendirme	28
3.2.1. Doğrusal regresyon algoritmaları	28
3.2.1.1. Çoklu doğrusal regresyon (Multiple Linear Regression - MLR).....	28
3.2.1.2. Temel bileşen regresyonu (Principal Component Regression - PCR)	29
3.2.1.3. Kısmi en küçük kareler regresyon (Partial Least Squares Regression - PLSR)	29
3.2.1.4. Ridge regresyon (RR)	29
3.2.1.5. Lasso regresyonu (LR).....	29
3.2.1.6. ElasticNet	30
3.2.2. Doğrusal olamayan regresyon algoritmaları	30
3.2.2.1. K-en yakın komşu (K Nearest Neighbors - KNN).....	30
3.2.2.2. Çok katmanlı algılayıcı (Multilayer Perceptron - MLP).....	30
3.2.2.3. Regresyon ağaçları (Regression Trees - RT).....	30
3.2.2.4. Rastsal orman (Random Forest - RF).....	31
3.2.2.5. LightGBM	31
3.2.2.6. CatBoost	31
3.3. Performans Metrikleri	31
3.3.1. RMSE (Kök ortalama kare hata)	32
3.3.2. NRMSE (Normalize edilmiş kök ortalama kare hata).....	32
3.3.3. MAE (Ortalama mutlak hata).....	32
3.3.4. MAPE (Ortalama mutlak yüzde hata)	33
3.3.5. Belirleme katsayısı (R^2)	33
4. DENEYSEL SONUÇLAR VE TARTIŞMA.....	34
4.1. Mardin İli Tahmin Sonuçları	34
4.2. Şırnak İli Tahmin Sonuçları.....	36

4.3. Malatya İli Tahmin Sonuçları	38
4.4. Elazığ İli Tahmin Sonuçları.....	39
4.5. Van İli Tahmin Sonuçları	40
4.6. Antalya İli Tahmin Sonuçları	42
4.7. Denizli İli Tahmin Sonuçları	43
4.8. Muğla İli Tahmin Sonuçları.....	44
5. SONUÇ.....	46
6. KAYNAKLAR.....	48



KISALTMALAR

ECMWF	: Avrupa orta vadeli hava durumu tahminleri merkezi
FV	: Fotovoltaik sistem
GEPA	: Güneş enerjisi potansiyel atlası
KNN	: K Nearest neighbors
LR	: Lasso regresyonu
LM	: Levenberg-Marquardt
NRMSE	: Normalize edilmiş kök ortalama kare hata
MAPE	: Ortalama mutlak yüzde hata
MAE	: Ortalama mutlak hata
MLP	: Multilayer perceptron
MLR	: Multiple linear regression
PLSR	: Partial least squares regression
PCR	: Principal component regression
RF	: Random forest
RT	: Regression trees
RR	: Ridge regresyon
RMSE	: Root mean square error
RR	: Ridge regresyon
YSA	: Yapay sinir ağları
YZ	: Yapay zekâ

ÇİZELGELER DİZİNİ

Çizelge 1.1. Bölgelere göre güneş enerjisi potansiyeli (YEGM)	5
Çizelge 4.1. Mardin iline ait makine öğrenmesi modellerinin karşılaştırması.....	35
Çizelge 4.2. Çoklu doğrusal regresyon grafiği (Mardin)	36
Çizelge 4.3. Şırnak iline ait CatBoost algoritması verileri.....	37
Çizelge 4.4. Çoklu doğrusal regresyon grafiği (Şırnak)	37
Çizelge 4.5. Malatya iline ait CatBoost algoritması verileri	38
Çizelge 4.6. Çoklu doğrusal regresyon grafiği (Malatya).....	39
Çizelge 4.7. Elazığ iline ait CatBoost algoritması verileri.....	39
Çizelge 4.8. Çoklu doğrusal regresyon grafiği (Elazığ)	40
Çizelge 4.9. Van iline ait CatBoost algoritması verileri	41
Çizelge 4.10. Çoklu doğrusal regresyon grafiği (Van)	41
Çizelge 4.11. Antalya iline ait CatBoost algoritması verileri	42
Çizelge 4.12. Çoklu doğrusal regresyon grafiği (Antalya)	43
Çizelge 4.13. Denizli iline ait CatBoost algoritması verileri	43
Çizelge 4.14. Çoklu doğrusal regresyon grafiği (Denizli)	44
Çizelge 4.15. Muğla iline ait CatBoost algoritması verileri.....	45
Çizelge 4.16. Çoklu doğrusal regresyon grafiği (Muğla)	45

ŞEKİLLER DİZİNİ

Şekil 1.1. Türkiye'nin güneş enerjisi potansiyel atlası (GEPA).....	3
Şekil 1.2. Yıllara göre güneş enerjisi kurulu gücü değişimi(GEPA).....	4
Şekil 1.3. Yıllara göre güneş enerjisinin toplam kurulu güç içindeki oranı(GEPA)	4
Şekil 1.4. Türkiye global radyasyon değerleri (kWh/m ² -gün)(GEPA).....	5
Şekil 1.5. Türkiye Güneşlenme Süreleri (Saat) (GEPA)	6
Şekil 1.6. Fotovoltaik hücre, modül, panel ve dizi	7
Şekil 1.7. Şebekeden bağımsız sistemler	10
Şekil 1.8. Şebekeye bağlı sistemler	11
Şekil 1.9. Hibrit sistemler.....	12
Şekil 1.10. Yapay sinir ağlarının sınıflandırılması	17
Şekil 1.11. İleri beslemeli sinir ağı blok gösterimi	17
Şekil 1.12. Geri beslemeli sinir ağı blok gösterimi	18
Şekil 1.13. Tek katmanlı yapay sinir ağı modeli	18
Şekil 1.14. Çok katmanlı yapay sinir ağı modeli.....	19
Şekil 2. Mardin Ra GES.....	34
Şekil 3. Şırnak Silopi GES	36
Şekil 4. Malatya İOTA Fırıncı GES	38
Şekil 5. Elazığ Solentegre GES	39
Şekil 6. Van Omicron Engil GES	40
Şekil 7. Antalya Serra GES	42
Şekil 8. Denizli Renoe GES	43
Şekil 9. Muğla Özmen-1 GES	44

1. GİRİŞ

Enerji, bir ülkenin gelişmişlik seviyesini belirleyen temel faktörlerden biridir. Enerji sadece sanayi kullanımı için değil, aynı zamanda insanların günlük ihtiyaçlarını karşılamak açısından da kritik bir öneme sahiptir. Enerji, fosil kökenli kaynaklar olan kömür, petrol, doğalgaz gibi unsurlardan veya güneş, rüzgâr, su gibi yenilenebilir enerji kaynaklarından elde edilebilir [1]. Ancak, fosil kaynakların azalması, bu kaynakların maliyetinin artması, çevresel etkileri ve gelecekte tükenme riski gibi faktörler, enerji talebinin artmasına rağmen ekonomik, temiz ve sürdürülebilir enerji kaynaklarına olan ilgiyi artırarak, enerji sektöründe dönüşümü teşvik etmektedir [2]. İthal edilen fosil yakıtlar, ülkemizde enerji yeterliliği konusunda önemli bir engel oluşturmaktadır. Ancak Türkiye, özellikle yenilenebilir enerji kaynaklarını daha etkin bir şekilde kullanarak kendi kendine yetebilirlik potansiyeline sahiptir. Yapılan araştırmalara göre, Türkiye'nin elektrik üretimindeki kendi kendine yetme oranı, 1980'de %77 iken 2014'te %37'ye düşmüştür. Bu değişimdeki ana faktörler arasında artan enerji talebi, ithal doğal gaz ve taş kömürüne olan bağımlılığın artmasıdır. Aynı zamanda yenilenebilir enerji kaynaklarının yeterince kullanılamaması da önemli bir rol oynamaktadır [3]. 2016 yılı "Yenilenebilir Enerji Kapasitesi İstatistikleri"ne göre, dünya genelinde kullanılan yenilenebilir enerji kapasitesi geçen yıllara kıyaslandığında %8.72 artmıştır. Bu artış oranına katkıda bulunan kaynaklar ve katkı oranları şu şekildedir: Biyoenerjide 8.6 GW, Hidroelektrik enerjisinde 35.1 GW, Rüzgâr enerjisinde 51.2 GW ve katkı payı en yüksek 70.8 GW ile güneş enerjisinde sağlanmıştır [4].

Ülkemiz, coğrafi konumunun avantajıyla önemli bir güneş enerjisi potansiyeline sahip bulunmaktadır. Türkiye Güneş Enerjisi Potansiyeli Atlası (GEPA) tarafından yapılan değerlendirmelere göre, ortalama yıllık toplam güneşlenme süresi 2741 saat olarak kaydedilmiş ve ortalama yıllık toplam ışıınım değeri ise 1527,46 kWh/m² olarak hesaplanmıştır (Url 1).

Güneş enerjisi potansiyelinin bölgelere göre dağılımını incelediğimizde, Türkiye'deki farklı bölgelerin yıllık ortalama güneş ışıınım şiddetlerinin farklılık gösterdiği gözlemlenmektedir. Doğu Anadolu bölgesinde 1365 kWh/m², Güneydoğu Anadolu Bölgesinde 1460 kWh/m², İç Anadolu Bölgesinde 1314 kWh/m², Ege Bölgesinde 1304 kWh/m², Akdeniz Bölgesinde 1390 kWh/m², Marmara Bölgesinde 1168 kWh/m² olduğu gözlemlenmektedir. En düşük güneş ışıınım şiddeti ise

Karadeniz de olup güneş ışıının şiddeti 1120 kWh/ m²'dir. Bu süreleri dikkate aldığımızda Güneydoğu Anadolu Bölgesi yılda 3015 saat güneşlenme süresi ile en yüksek bölgemiz olduğu görülmektedir. Akdeniz Bölgesinde 2956 saat, Ege bölgesinde 2738 saat, İç Anadolu Bölgesinde 2628 saat güneşlenme süresi görülürken, Doğu Anadolu Bölgesinde 2664 saat, Marmara Bölgesinde 2409 saat Karadeniz Bölgesinde 1971 saat olarak saptanmıştır. Türkiye, coğrafi konumu sayesinde güneş enerji potansiyeli bakımından birçok ülkeye göre avantajlı bir konumda bulunmaktadır (Url 2).


Güneşlenme süreleri bölgesel farklılıklar gösterdiği gibi, fotovoltaik sistemlerin konumlarına göre de değişmektedir. Doğru konumlandırılmış bir fotovoltaik panelden, çevresel koşullar göz önüne alınarak en yüksek verim elde edilebilir. Ayrıca, fotovoltaik panellerin performansını etkileyen faktörler arasında iklim koşulları da bulunmaktadır. Sıcaklık, rüzgâr, nem gibi faktörlerin, panelin performansını güneş radyasyonu ile birlikte etkilediği bilinmektedir. Fotovoltaik sistemlerinden elde edilecek faydanın sağlanabilmesi için sistem en yüksek verime ulaşacak şekilde tasarlanmalıdır.

Fotovoltaik hücreler güneş radyasyonunu direkt elektrik enerjisine dönüştürmesinin sağladığı birçok avantajın olduğu görülmektedir. Ancak, bu avantajların yanı sıra iki önemli detay bulunmaktadır: İlk olarak, elektrik enerjisi üretimindeki dönüşümün verimliliğindeki düşüklük; ikinci olarak da panellerin ürettiği elektrik enerjisi miktarının hava koşullarıyla birlikte değişkenlik göstermesidir.

Bu çalışmada Türkiye’de belirli illerin farklı günlerde değişen iklim koşullarına bağlı olarak üretilen elektrik miktarları, güneş enerjisi santrallerinden saha çalışmaları sonucunda yapılan ölçümlerden elde edilmiştir. Model oluşturmak ve alınan ölçümlerin doğruluğunu belirlemek amacıyla fotovoltaik panellerin üreteceği gücü sıcaklık, nem, rüzgâr ve ışıının değeri gibi parametrelere bağlı olarak tahmin etmek üzere yapay zekâ algoritması eğitildi. İklim değişkenliğinin güneş enerjisinin faydalı ve verimli kullanımına etkisi, güneş enerjisi santrallerinde saha çalışmaları sonucunda yapılan ölçümlerin verimini etkileyen faktörler ve üretilen enerji verilerinin yapay zekâ ile modellenmesi konuları ele alınmıştır.


1.1. Türkiye’de Güneş Enerjisinin Durumu

Güneş, dünyamızın başlıca enerji kaynaklarından biridir. Bunun yanı sıra birçok enerji türünün kökenini oluşturur. Güneş enerjisi, ısıtma ve elektrik üretimi gibi çeşitli amaçlar için kullanılmaktadır. Güneş enerjisi, çevre dostu bir enerji kaynağı olarak değerlendirilir ve fosil yakıtların yerine geçebilecek önemli bir alternatif sunar [5]. Ülkemiz, jeopolitik konumu nedeniyle birçok ülkeye göre güneş enerjisi potansiyeli bakımından avantajlı bir konumda bulunmaktadır. Dünya genelinde güneşten saniyede yaklaşık 170 milyon MW enerji aldığımız bilinmektedir. Türkiye'nin yıllık enerji üretiminin 100 milyon MW olduğu düşünüldüğünde, bir saniyede dünyaya gelen güneş enerjisi miktarı, Türkiye'nin yıllık enerji üretiminin tam 1700 katına denk gelmektedir [13]. Türkiye Güneş Enerjisi Potansiyeli Atlası (GEPA)'na göre, ortalama yıllık toplam güneşlenme süresi 2741 saat olarak belirlenmiş, ayrıca ortalama yıllık toplam ışıınım değeri ise 1527,46 kWh/m² olarak hesaplanmıştır (Url 3).




Şekil 1.1. Türkiye’nin güneş enerjisi potansiyel atlası (GEPA, Url 4)

Türkiye’de 2024 yılı itibarı ile güneş enerjisinden elde edilen elektrik kurulu gücü 11.707 MW’dır. Bu gücün, kurulmuş olan toplam güç içindeki oranı %8.35’tir. Aşağıdaki grafiklerde, yıllara göre güneş enerjisi gücündeki değişim ile toplam elektrik kapasitesi içindeki oran gösterilmektedir (Url 5).



Şekil 1.2. Türkiye’de yıllara göre güneş enerjisi kurulu gücü değişimi (GEPA)




Şekil 1.3. Türkiye’de yıllara göre güneş enerjisinin toplam kurulu güç içindeki oranı (GEPA)

Türkiye'nin farklı bölgelerinde güneş enerjisi potansiyeli analizi yapıldığında, en yüksek potansiyele sahip bölgenin Güneydoğu Anadolu olduğu belirlenmiştir. Ege, Akdeniz, Doğu Anadolu ve İç Anadolu bölgeleri sırasıyla bu potansiyelde izlenmektedir. Karadeniz bölgesi ise güneş enerjisi bakımından daha düşük bir potansiyele sahiptir. Ülke genelinde güneş enerjisi ve güneşlenme süreleri üzerinden yapılan incelemede, toplam güneşlenme süresinin ortalama olarak 1527 kWh/m², toplam güneşlenme süresinin ise ortalama olarak 2741 saat olduğu tespit edilmiştir [6].

Çizelge 1.1. Bölgelere göre güneş enerjisi potansiyeli (YEGM)


Coğrafi bölge	Toplam yıllık güneş enerjisi (kWh/ m ²)	Güneşlenme süresi yıllık (saat)
Güney Doğu Anadolu	1460	2993
Akdeniz	1390	1959
Doğu Anadolu	1365	2664
İç Anadolu	1314	2628
Ege	1304	2738
Marmara	1168	2409
Karadeniz	1120	1971

GEPA verilerinin analizine göre, Türkiye genelinde güneş ışıınımı değerlerinin en yüksek olduğu dönemlerin genellikle Haziran ve Temmuz ayları olduğu gözlemlenmektedir. (Url 6).



Şekil 1.4. Türkiye'deki günlük global radyasyon değerleri (kWh/ m²)(GEPA)

GEPA verilerine baktığımızda Türkiye'deki güneşlenme sürelerine ait grafik incelendiğinde, Haziran ve Temmuz aylarında bütün bölgelerde gün içerisinde saatlik olarak daha yüksek potansiyele sahip olduğu açıkça görülmektedir. Bu aylar, güneşlenme süreleri açısından diğer aylara kıyasla belirgin bir artış göstermekte ve Türkiye genelinde güneş enerjisi potansiyelinin en yüksek olduğu dönemi oluşturmaktadır (Url 6).



Şekil 1.5. Türkiye Güneşlenme Süreleri (Saat) (GEPA)

1.2. Fotovoltaik Sistemler

Güneş enerjisinden yenilenebilir enerji kaynağı olarak yararlanmak için fotovoltaik sistemlerin kullanıldığı görülmektedir. Bu sistemler, güneş enerjisini elektrik enerjisine dönüştürme amacıyla tasarlanmış olup, dünya genelinde alternatif enerji kaynakları arasında hızla popülerlik kazanmaktadır. Güneşten gelen ışığı elektriğe dönüştüren fotovoltaik sistemler, yaygın olarak bilinen diğer adıyla güneş pilleri olarak anılmaktadır. Fotovoltaik terimi, kökenini Yunanca'dan alır; "photo" kelimesi ışık anlamına gelirken, "voltaic" kelimesi de elektrik akımını geliştiren makineyi tasarlayan Alessandra Volt'un isminden türetilerek voltajı ifade eder. Bu iki kelimenin birleşiminden oluşan "fotovoltaik" ifadesi genellikle FV olarak kısaltılarak da kullanılmaktadır [7].

1.2.1. Fotovoltaik sistemlerde hücre yapısı


Fotovoltaik (FV), fotovoltaik etki sergileyen yarı iletkenleri kullanarak güneş ışınımını doğru akım elektriğine dönüştürerek elektrik enerjisi üretme yöntemidir. FV enerji üretiminde kullanılan güneş panelleri çok sayıda hücrelerden oluşur. Bu hücreler mono kristalin silikon, silikon, polikristalin, amorf silikon, kadmiyum tellür ile bakır indiyum selenit/sülfür malzemelerden oluşur [8].

Güneş pilleri, yüzeyleri genellikle dikdörtgen, kare veya daire biçiminde olan, yaklaşık 100 cm² alanında ince tabakalardan oluşur. Bu tabakaların kalınlığı genel olarak 0.2 mm veya 0.4 mm seviyesindedir.

Güneşli bir günde deniz seviyesinde güneş ışınım şiddeti 1000W/m²'dir. Bu, güneş ışığının bir metrekaareye düşen enerji miktarını ifade eder. Bölgelere göre, yılda her bir metrekaareye düşen enerjinin miktarı 800 ile 2600 kilovatsaat (kWh)

seviyesinde deęişebilir. Bu deęer, güneş enerjisi potansiyelinin coęrafi konuma baęlı olarak farklılık gösterebileceęini gösterir.

FV sistemler, güneşten gelen enerjiyi pilin yapısına ve çeşidine göre %5 ile %30 arasındaki bir oranla enerjiye çevirebilirler. Çıkış gücünü artırmak için, bir dizi hücrenin paralel ve ya seri bağlanması ile "solar modül" oluşturulur; modüller bir araya getirilerek paneller ve paneller bir araya getirilerek "solar dizisi" elde edilir. Şekil 1.6'da gösterildięi gibi, çok sayıda panelin entegrasyonu ile daha büyük yüzeyli diziler elde edilebilir. Bu modüller sadece doğrudan güneşten deęil, aynı zamanda bulutlu hava koşullarında ve geniş ışıyım koşullarında da bir miktar daha az güçte elektrik üretebilirler [9].



Şekil 1.6. Fotovoltaik hücre, modül, panel ve dizi [9]

1.2.2. Fotovoltaik sistemlerde hücre çeşitleri

FV hücreler, farklı malzemeler ile üretimi yapılabilmektedir. FV güneş pillerinin üretim aşamasında en yaygın tercih edilen malzemenin silisyum olduğunu görüyoruz. Silisyum, doğada oldukça bol bulunan ve kumdan elde edilen yarı iletken bir maddedir. Kumun geniş bulunabilirliği, silisyumun güneş enerjisi teknolojilerinde yaygın ve ekonomik bir seçenek olmasını sağlar. Bu durum, hammadde temini konusunda herhangi bir sıkıntı yaşanmamasına katkıda bulunur. Çeşitli teknikler ve farklı ilave maddeler kullanılarak birbirinden farklı FV modüller üretilebilmektedir [10].

1.2.2.1. Kristal yapılı silisyum hücreler

Silisyum elektriksel, yapısal ve soęurma özelliklerini koruyan yarı iletken bir madde olup, aynı zamanda kullanım aşamasında kararlılığını sürdürebilen bir yapıya sahiptir. Bu özelliklere göre, silisyum materyali üzerinde detaylı çalışmalar yapıldıęı

ve üretim teknolojisinin yenilenip geliştirildiği görülmektedir. Farklı yöntemlerle üretimi yapılan bu hücrelerin, son zamanların popüler olan FV hücreleri arasında yer almaktadır [10-12].

1.2.2.2. İnce filmden yapılan güneş pilleri

İnce film teknolojisiyle üretilen güneş pilleri, kullanılan malzeme ve işçilik maliyetlerini düşürerek daha cazip bir enerji çözümü sunmaktadır. Ayrıca, teknolojinin daha basit hale getirilmesi ve geniş yüzeylerde yarı iletken malzemeyi kullanabilmek için ince bir film kaplama geliştirilmiştir. Bu sayede, daha büyük açıklıklı hücrelerin üretimi daha ucuz maliyetle gerçekleştirilebilmektedir. Ancak, ince film pillerin %18'lere kadar çıkabilen verimlilik oranlarına sahip olmasına rağmen, en büyük dezavantajı malzemenin kararlılığını koruyamamasından kaynaklanmaktadır. Bu sebeplerle, ince film pillerle ilgili yapılan yatırımlar sınırlı kalmıştır. Bu piller için kullanılan ince filmden yapılan bu malzemeler arasında kadmiyum tellür, amorf silisyum ve bakır indiyum-diselenid bulunmaktadır [13,14].

1.2.2.3. Grup III-V bileşik fotovoltaiik hücreleri

Grup III-V bileşik FV hücreleri, periyodik cetvelin üçüncü ve beşinci gruplarındaki elementlerin bir araya gelmesiyle meydana gelir. Elde edilen yeni bileşik, yüksek derecede soğurma yeteneğine sahiptir. Bu hücreler için en iyi örnek, genellikle galyum arsenitten (GaAs) üretilen güneş pilleridir. Bu pillerin verimliliğinin (%24) en yüksek olması ve maliyetlerinin yüksek olmasından dolayı genellikle uzay araştırmalarında kullanılmaktadır [14].

1.2.2.4. Çok eklemli (tandem) fotovoltaiik hücreler

Farklı malzeme türleri, güneşten gelen ışığı farklı şekillerde soğurduğu için, güneş ışınımından en yüksek verimi elde etmek amacıyla farklı malzemeleri içeren çok katmanlı hücreler olan "tandem" hücreleri üretilmiştir [15]. Bu hücrelerde en üstte yer alan tabakada bulunan malzeme, güneş ışığını en iyi şekilde soğurmakta olan kısımdır. Bu malzeme ışığı soğurmadığında, alt tabakada yer alan malzeme güneş ışınımını absorbe eder. Bu tür hücrelerde yapım aşamasında genellikle amorf silisyum, galyum arsenit, galyum indiyum fosfat ve bakır indiyum diselenid gibi malzemeler kullanılmaktadır [14].

1.2.2.5. Organik ve polimer fotovoltaik hücreler

İnorganik FV hücreler üretim teknolojisi açısından her ne kadar ilerlese de, maliyet bakımından hala yüksek seviyededir. Bu nedenle, bu tür hücreler için alternatif olması adına organik ve polimer hücre üretim teknikleri geliştirilmektedir. Ancak, organik ve polimer hücrelerde verim %2,5 gibi oldukça düşük seviyelerde kalgıdığından, henüz organik olamayan hücrelerle rekabet edebilecek seviyede değillerdir. Bu olumsuzluklara rağmen, üretim sırasında az miktar toksik madde açığa çıkarması ve maliyetlerin diğer malzemelere karşın düşük olması gibi nedenlerle, gelecekte kullanılması düşünülerek çalışmalar devam etmektedir [16].

1.2.3. Fotovoltaik sistem çeşitleri

FV modüller haricinde sistemde farklı bileşenler de vardır. Bu bileşenlerden;

Dönüştürücü olarak bilinen İnvertör, enerjiyi dönüştürmek için kullanılmaktadır. FV bir hücre doğru akım üretir ve enerjiyi kullanılabilir hale getirmesi için alternatif akıma dönüştürür. Bu dönüştürücüler şebekeye bağlı bir sistem ise 110V ve üstü yüksek gerilimli ve şebekeden bağımsız ise 12V-48V aralığında düşük gerilimli olarak kullanılır.

Aküler, enerjinin depolanması için kullanılır. Elektrik üretiminde kullanılan enerjinin artan kısmı, tüketilmediği durumlarda depolanarak muhafaza edilmelidir. Güneş ışığı bulunduğu sürece, bu enerjiler akülerde toplanarak depolanır. Herhangi bir sistem kurmadan önce, gerekli hesaplamalarla ihtiyaç duyulacak akü kapasitesi belirlenmelidir. Günümüzde FV sistemlerinde genellikle nikel kadmiyum ve kurşun-asit tipi aküler tercih edilmektedir [17].

Şarj Denetim Birimleri olarak bilinen bileşenler, hücrelerin ürettiği elektrik doğrudan aküye geldiğinde akünün zarar görmemesi için koruyucu görevi üstlenmektedir. Diğer bir ifadeyle akünün şarj ve deşarj olmasını engellemiş olur [17].

Diğer Sistem Bileşenleri ise devrede kullanılan kablolama, topraklama, sigorta, diyot gibi elemanlardır [17].

1.2.3.1. Off Grid (şebekeden bağımsız) sistemler

Şebeke ulaşımının kısıtlı olduğu durumlarda, bu tip sistemler özellikle enerjiye olan ihtiyacı karşılamak üzere tasarlanmıştır. Bağımsız çalışabilen bu sistemler, yeterli sayıda fotovoltaik modül kullanıldığında enerji ihtiyacını karşılayacak kapasitede

olabilirler. Güneş enerjisi, aküler gibi depolama birimlerinde saklanabilir ve ihtiyaç anında kullanılabilir. Ayrıca, gece saatlerinde şebeke olmadan depolanan enerji, kullanıma uygun hale getirilebilir. Depolanan DC elektrik, AC'ye dönüştürülüp şebeke bağlantısıyla uyumlu hale getirildiğinde kullanılabilir [17].



Şekil 1.7. Şebekeden bağımsız sistemler (Url 7)

Ancak, bazen şebekeye bağlanmak için yapılan maliyet, fotovoltaik sistemin kurulum maliyetini aşabilmektedir. İlk yatırım maliyetinin ardından bakım ve gideri olmayacak olan bu sistemler, genelde kırsal bölgelerde tercih edilir. Şekil 1.7'de görüldüğü gibi, bu sistemlerde aküler kullanıldığı için depolama ihtiyacı bulunmaktadır, bu da sistemlerin maliyetini artırmaktadır [17].


Şebekeden bağımsız sistemler, fotovoltaik teknolojisinin en eski uygulamaları arasında yer almaktadır. Bu sistemler, şebekeden bağımsız oldukları için yalnızca belirli birimlerde elektrik ihtiyacını karşılayabilen tek kaynak olarak bilinirler. Genelde evlerin aydınlatılması, ısıtılma, kara yolu, demiryolu, botlar, yaya geçidi ışıkları ve güneşi sürekli gören küçük konut gibi yerlerde kullanılmaktadırlar. Akü desteği ile elektrik kesintisi durumunda uzak bölgelerde avantaj sağlar. Ayrıca, ekonomik ve çevreci olarak da tanımlanır [18].

1.2.3.2. On Grid (şebekeye bağlı) sistemler

Şebekeye bağlı olan sistemler, güneşten elde edilen enerjinin depolama birimine kaydedilmeden doğrudan şebekeye beslendiği ve anında kullanıldığı sistemlerdir. Bu sistemler, iki yönlü bir sayaç aracılığıyla şebekeye bağlanarak, o anda üretilen enerjinin şebekeye verildiği ve fazla elektriğin uygun tarifelerle satılabilmesi için gereken düzenlemelerin yapıldığı sistemlerdir. Bu tür sistemler, ilgili kanunlara uygun olduğu sürece fazla üretilen elektriğin satışına izin verilebilmektedir.

Şekil 1.8’de, sistemde akü kullanılmadığından depolama için ek maliyet gerekmez. Yalnızca üretilen DC akımının AC'ye dönüştürülüp şebekeye uyumlu bir hale getirilmesi yeterlidir. Dönüşüm kayıpları çok düşüktür. Şebekeye bağlı sistemde, enerji yetersiz olduğunda şebeke devreye girer ve kesintisiz elektrik sağlar [19].

Aynı zamanda, elektrik üreterek şebekeye satan büyük güç üretim merkezleri de mevcuttur. Bu tür güç üreten merkezlerin kapasitesi genellikle 600-700 kW’lardan başlayıp daha yüksek megavat seviyelerine kadar çıkabilmektedir [20].




Şekil 1.8. Şebekeye bağlı sistemler (Url 8)

1.2.3.3. Hibrit sistemler

Hibrit sistem, iki veya daha fazla yenilenebilir/yenilenemez enerji kaynağının birleşimi olarak tanımlanmaktadır. Hibrit sistemin temel bileşenleri, enerji kaynaklarını (AC/DC), AC/DC güç elektroniği dönüştürücülerini ve yükleri içerir. Farklı tipte DC-DC dönüştürücüler vardır, ancak en yaygın kullanılanlar düşürücü, yükseltici ve düşürücü-yükseltici dönüştürücülerdir. Hibrit sistemin olası konfigürasyonları DC kuplajlı, AC kuplajlı ve Hibrit kuplajlı sistemlerdir. Örneğin, DC bağlantılı sistemler, DC kaynaklarından ve DC yüklerinden oluşur; buradaki ana avantaj, DC mikro şebeke için kullanılabilecek sistemi senkronize etmeye gerek olmamasıdır. AC bağlantılı sistemler ayrıca AC mikro şebeke ve savunma uygulamaları için kullanılabilen güç frekanslı AC bağlı sistem ve yüksek frekanslı AC bağlı sistem olmak üzere iki türe ayrılır. Güç frekanslı AC kuplajlı sistemde hem kaynakların hem de yüklerin AC olması sistemin korunmasını kolaylaştırırken, yüksek frekanslı AC kuplajlı sistem farklı frekanslarda çalışan AC kaynaklardan ve yüksek frekanslı yüklerden oluşur ve bu da sistemin yüksek verimliliğini sağlar. Hibrit kuplajlı

sistemler hem AC hem de DC olabilen kaynak ve yüklerden oluşur, bu da en yüksek verimliliği sağlar [21].

Hibrid sistemler için dezavantajlardan en önemlisi, rüzgâr türbinleri veya güneş panellerinin maliyeti, tekil kullanıma göre biraz daha yüksektir. Ancak, bu fark oldukça minimaldir, çünkü kullanılmış olan bileşenler, Şekil 1.9'da yer aldığı gibi güneş ve rüzgâr enerjisi sistemleri ile aynı temel bileşenlere sahiptir (pil, inverter, kontrol ve güvenlik birimleri gibi).



Şekil 1.9. Hibrit sistemler (Url 9)

1.3. Yapay Zekâ

Yapay zekâ alanında çalışmalar, 1943 yılında McCulloch ve Pitts tarafından gerçekleştirilmiştir. Yapay zekâ, zekâ ve düşünme temelli işlemlerin bilgisayarlar yardımı ile daha etkili şekilde gerçekleştirilmesini ve bu başarılı sonuçların elde edilerek geliştirilmekte olan bir bilim dalıdır. Yapay zekâ, düşünerek, anlayarak, yorumlayarak ve öğrenerek insan zekâsına ait süreçleri, programlama yoluyla taklit ederek problemlerin çözümüne uygulaması olarak da ifade edilebilir [22].

Günümüz bilgisayarları, yapay zekâ ile yapılan çalışmaları kullanarak, olaylar arasında bağ kurabilme yeteneği sayesinde karar verme yeteneğine sahiptir. Matematiksel ilişkilerin kurulamadığı problemlerde, geleneksel bilgisayar sistemleri zorlanırken, yapay zekâ yöntemleri sezgisel yaklaşımları sayesinde çözümleme yapabilmektedir. Bir problem için geliştirilmiş formül veya algoritmalar genellikle geleneksel bilgisayar sistemleriyle başa çıkabilir, ancak önemli olan, çözümünün bulunamadığı durumlarda yapay zekâ yöntemlerini kullanarak problemlerin çözümü hızlandırılmaktadır [23].

Yapay zekâ, bilgisayar veya bilgisayar tarafından kontrol edilen bir makinenin, insan benzeri davranışları sergileyebilme yeteneğini içeren akıl yürütme, anlam çıkartma, genelleme ve geçmiş deneyimlerden öğrenme gibi zihinsel görevleri başarma yeteneğidir [22]. Yapay zekâ ile ilgili çalışmaların sayısı hızla artmakta ve çeşitli sektörlerde yaygın olarak kullanılmaktadır. Yapay zekâ uygulamalarında başlangıçta belirli tekniklere odaklanılmışken, kullanım alanları genişledikçe farklı yaklaşımlar da geliştirilmektedir. Yapay zekâ kavramı sadece tek bir teknolojiyi değil; makine öğrenme, doğal dil işleme, veri madenciliği, sinir ağları ve çeşitli algoritmalar gibi bir dizi teknoloji ve yöntemi ifade eden genel bir terimdir. Temel yapay zekâ teknikleri arasında uzman sistemler, bulanık mantık, genetik algoritmalar, yapay sinir ağları ve zeki etmenler ön plana çıkmaktadır [24].

Makine öğrenmesi, bilgisayarların gözlemledikleri ve gerçekte olan deneyimlerinden elde ettikleri verileri işleyerek zaman içinde öğrenmelerini, insanlar gibi davranış göstermeleri ve devamlı gelişmelerini sağlayan bir alandır [25].

Uzman sistemler, belirli bir alanda uzmanlaşmış bireylerin bilgi ve deneyimlerinin bilgisayar ortamına aktarılmasıyla oluşturulan, bu birikimi kullanarak sistem içinde ortaya çıkan sorunlara uzman bir kişiye başvurmadan çözümler sunabilen bilgi tabanlı sistemlerdir [26]. Uzman sistemler, insanlarla bilgisayarların birlikte kararlar aldığı durumlarda teşhis ve tavsiye niteliğinde bilgiler sunar. Oluşturulan kapsamlı bilgi tabanını kullanarak, uzman sistemler karar verme sürecinde oluşabilecek belirsizlikleri en aza indirmeye yardımcı olur [27].

Bulanık Mantık, tanımlamada ortaya çıkan belirsizlikleri telafi etmek maksadıyla matematiksel ifadeler yerine sözel ifadelerin kullanılmasına dayanan bir metodolojidir. Gerçek dünyadaki olaylar genellikle karmaşık bir yapıya sahiptir. Örneğin, hava sıcaklığından bahsederken soğuk, serin, ılık, sıcak, çok sıcak gibi çeşitli ifadeler kullanılabilir. Bu durumların yazılım geliştirme aşamasında matematiksel ifadelerle kesin bir şekilde tanımlanamaz. İnceleme yapılan bir konuda sayısal verilerle tam olarak ifade edilememesi ve belirsizlik içermesi, bulanıklık kavramını ortaya koymaktadır [28].

Genetik algoritmalar, evrimsel hesaplama tekniğini temel alarak çalışır. Bu algoritmaların mantığı, bir probleme ait mevcut çözümler arasından en iyisinin seçilmesi ve uygun olmayan verilerin elenmesi üzerine kuruludur [29].

Zeki etmenler, sürekli deęişen bir çevrede koşulların deęişimine eş zamanlı olarak tepki gösteren, durumu algılama, düşünme ve verdiği kararı eyleme dönüştürme görevlerini yerine getiren sistemlerdir. Zeki etmenler, mevcut davranış seçenekleri içinden amaç doğrultusunda en uygun olanını seçerek kullanıcıya tepki verme veya kullanıcıyla iletişim kurma yeteneğine sahiptir [30].

Yapay sinir aęları, insan sinir sisteminden esinlenerek tasarlanmıştır. Bu yapay sinir hücreleri, dış çevreden gelen verileri toplar, aktivasyon fonksiyonları kullanarak çıktılar üretir ve bu çıktıları dięer hücrelere ileterek aęda yayar. Yapay sinir aęları, veriler arasındaki gizli ve zor fark edilen ilişkileri keşfetme kapasitesine sahiptir [31]. Yapay sinir aęları, örnek olayları analiz edip genellemeler yaparak bilgi toplar. Karşılaşılan yeni bir örnekte, öğrenilen bilgileri kullanarak yeni sorunları çözme konusunda karar verebilme yeteneğine sahiptir [22].

Yapay Zekâ teknolojisi kullanarak yapılabilecek çalışmaların ortak hedefleri,

- İnsan beyni, zihinsel fonksiyonlarını öğrenme, analiz ve sentez yapma süreçlerinde izlemekte olduęu teknikleri araştırmak,
- Yöntemleri bilgisayarlarda uygulamak,
- Programlar için gerekli ara yüz geliştirmek,
- Gelişmiş sistemleri kullanarak genel bir bilgi sistemi oluşturmak,
- Yapay zekâ destekli teknolojileri uyarlayarak zeki sistemleri geliştirmek gibi sıralanabilir [32].

1.3.1. Yapay sinir aęları

Yapay sinir aęları konusunda bilim adamları tarafından çok sayıda tanımlamalar yapılmıştır. Bu tanımlamalar:

Yapay Sinir Aęları (YSA), biyolojik sinir aęlarının yapı ve işleyişinden ilham alınarak oluşturulmuş olan modeldir. YSA, yapay nöronların birbirine bağlanmasıyla oluşan bir grup içerir ve bilgiyi işlemek amacıyla bağlantılı yaklaşım kullanır. Genellikle, YSA, öğrenme sırasında aę üzerinden geçen dâhili veya harici bilgilere baęlı olarak yapılandırılabilen uyarlanabilir sistemdir [33].

YSA insan beyninin öğrenme yeteneğini taklit edebilen bilgisayar sistemleri olarak tasarlanmıştır. Öğrenme sürecini gerçekleştirebilmek için bu yapay sinir aęları,

örnek verilerle beslenmeye ihtiyaç duyarlar. Yapay sinir ağları, bağlantılı işlem birimlerinden oluşur ve her bir bağlantı belirli bir ağırlık değeri taşır. Ağdaki bilgi, bu ağırlıklar aracılığıyla ağına her yerine yayılır.

YSA, geleneksel hesaplama yöntemlerinden farklı yaklaşım sunan bir sistemdir. Eksik bilgiyle çalışabilme, bulunduğu yere uyum sağlama, belirsizlik durumlarında karar verebilme ve hatalara karşı tolerans gösterme gibi özellikleriyle birçok alanda başarılı sonuçlar elde edilmiştir. YSA ile çözülebilecek problemlerde, ağ yapısı veya parametrelerin seçimi için belirli bir standart yoktur ve çoğu zaman problemler sadece sayısal ifadelerle gösterilir. Eğitim sürecinin sonlandırılması veya ağına davranışlarının açıklanamaması gibi zorluklara rağmen, YSA'ya olan ilgi yüksektir. YSA'nın güçlü kullanıldığı alanlara örnek olarak veri sıkıştırma, örüntü tanıma, optimizasyon, sinyal filtreleme gibi alanlar gösterilebilir [34].

Yapay Sinir Ağları, mühendislik, matematik, tıp, meteoroloji, ekonomi, nöroloji, psikoloji ve birçok başka alanda uygulanmış ve hala uygulanmaktadır. Bu alanlardaki önemli uygulamalardan bazıları şunlardır: elektromiyografi ve diğer tıbbi işaretlerin analizi, askeri hedef belirleme, yolcu çantalarındaki patlayıcıları tanıma, desen, ses ve konuşmanın tanıma, mineral arama tahminleri, elektriksel ve termal yük tahminleri, robotik ve adaptif kontroller, hava tahminleri, ticari amaçlı pazar trendlerinin analizi gibi birçok alanda başarıyla kullanılmaktadır [35].

1.3.2. Yapay sinir ağlarının özellikleri

Yapay sinir ağları, bilimin birçok alanında yapılan çalışmalara önemli katkılarda bulunmaktadır. Literatüre kazandırılan çalışmalar incelendiğinde, Yapay sinir ağlarının pek çok alanda kullanılmakta olan bazı ortak özellikleri olduğu görülmektedir. Bu özellikler şu şekilde sıralanmıştır:

Doğrusal Olmama, Yapay sinir ağlarının doğrusal veya doğrusal olmayan problemleri ele alabilme yeteneğini belirleyen aktivasyon fonksiyonu tercihi sayesinde, etkili çözümlere ulaşabilme olanağını sağlar. Bu bağlamda, tercih edilen aktivasyon fonksiyonunun doğru seçilmesi önemlidir [36].

Öğrenme, Yapay sinir ağlarının insan beyninin öğrenme tarzından esinlenerek geliştirdiği bir süreçtir. YSA'lar, kendilerine sunulan örneklerle öğrenme işlemini gerçekleştirebilirler [31].

Genelleme, ağ yapısı eğitim esnasında sayısal verileri eşleştirip, gereksiz veya kullanılmayan özellikleri ayırt ederek anlamlı sonuçlar çıkarabilme yeteneğidir [37].

Uyarlanabilirlik, belirli bir problemi çözmek için eğitilen Yapay Sinir Ağlarının, problemdeki değişimlere göre tekrar eğitilebilme yeteneğini ifade eder. Bu, değişimler sürekli bir şekilde devam ediyorsa, YSA'nın gerçek zamanlı kontrol gibi alanlarda etkili bir şekilde kullanılabilmesini sağlar [38].

Paralellik, yapay sinir ağları bir aradayken çok sayıda hücre oluşturmaları ve bu hücrelerin birlikte çalışması anlamına gelir. Bilgisayar sistemleri, insan beynine kıyasla daha hızlı olmalarına rağmen, beyinin toplam hız kapasitesi bilgisayarların kapasitelerine oranla daha yüksektir. Yapay Sinir Ağları da tüm sistemini aynı anda ve hızlı bir şekilde çalıştırabilme özelliğine sahiptir. Bu özellik, doğrusal olmayan problemlerin etkili bir şekilde çözülmesine olanak tanır [39].


Eksik verilerle çalışabilme yeteneği, yapay sinir ağlarının geleneksel sistemlerden farklı olarak eksik bilgilerle de başa çıkabilme ve sonuç üretebilme kabiliyetine sahip olmasını ifade eder. Modelin performansı, eksik olan bilgilerin ne kadar etkili olduğu ile ilişkilidir [40].

Hata Toleransı, yapay sinir ağlarının çok sayıda hücrenin bağlanmasıyla oluşan ve paralel bir çalışma şekline sahip olan yapısından kaynaklanır. Ağa giren bilgiler, tüm bağlantılar üzerinde dağılarak işlenir. Bu nedenle, Yapay Sinir Ağının eğitimi sırasında bazı hücrelerdeki eksiklik veya etkisizliği, yine de ağın bilgi üretebilme yeteneğini önemli ölçüde etkilememektedir. Bu özellik, klasik yöntemlere kıyasla hataları daha yüksek oranda tolere ettiğini söyleyebiliriz [41].

Uyum, yapay sinir ağları, değişken parametreler ve problemlere uygun çözümler üretebilmek için her seferinde eğitilebilir; bu eğitimleri gerçek zamanlı olarak yapılabilir [22].

1.3.3. Yapay sinir ağlarının sınıflandırılması


Yapay sinir ağları, çeşitli ölçütler dikkate alınarak sınıflandırılabilir. Yapay Sinir Ağları genellikle öğrenme yöntemleri, katman sayıları, tipleri ve yapılarına göre farklı sınıflandırmalara tabi tutulabilir [31]. YSA'nın sınıflandırılması Şekil 1.10'da gösterilmiştir.



Şekil 1.10. Yapay sinir ağlarının sınıflandırılması [31]

1.3.3.1. İleri beslemeli ağ


İleri beslemeli bir ağ yapısında, yapay sinir hücreleri genellikle katmanlara ayrılmıştır. Giriş katmanındaki nöronlar, yapay sinir hücreleri tarafından çıkış katmanına doğru tek yönlü bağlantılarla iletilir. Genel olarak bir katmandaki yapay sinir hücreleri, bir önceki katmandaki yapay sinir hücreleri tarafından beslenmektedir ve Şekil 1.11’de gösterilmiştir. Yapay sinir hücreleri, bir katmandan diğerine bağlantı kurabilir, ancak aynı katman içinde birbirleriyle bağlantı yapamazlar. İleri besleme yapabilen ağlarda, Çok Katmanlı Algılayıcı (MLP) ve Doğrusal Vektör Parçalama (LVQ) ağları bu kısıtlamaya örnek olarak gösterilebilir [22].



Şekil 1.11. İleri beslemeli sinir ağı blok gösterimi [29]

1.3.3.2. Geri beslemeli ağ


Geri beslemeli ağlarda, ara ve çıkış katmanlarındaki çıktının, giriş birimlerine ya da önceki katmanlara geri döndüğü bir ağ yapısı olarak tanımlanır. Bu sayede, Şekil 1.12’de görüldüğü üzere; girişlerin hem ileriye doğru hem de geriye doğru aktarılabilir. Geri beslemeli ağlar, dinamik hafızalarıyla bilinir; bir katmandan diğerine yapılan çıkışlar, o anki girişleri ve önceki girişleri yansıtma yeteneğine sahiptir. Bu nedenle, genellikle geri beslemeli sinir ağları, tahmin odaklı uygulamalarda tercih edilir ve bu ağlar, çeşitli türdeki zaman serilerini başarılı bir şekilde tahmin etmek için kullanılır. Hopfield, Elman, Jordan, Narmax gibi çeşitli ağ tipleri, geri beslemeli ağlara örnek olarak gösterilebilir [22].



Şekil 1.12. Geri beslemeli sinir ağı blok gösterimi [29]

1.3.4. Tek katmanlı sinir ağları

Bu ağlar sadece girdi ve çıktı katmanlarından oluşur. Ağda bir ya da daha fazla girdi ve çıktı bulunabilir. Şekil 1.13'te tek katmanlı yapay sinir ağlarına ait model gösterilmektedir. Girdiler, herhangi bir işlem yapılmadan çıktı katmanına iletilir [42].



Şekil 1.13. Tek katmanlı yapa sinir ağı modeli [23]

X:Giriş değeri

W:Ağırlık

ϕ :Eşik girdisi

ϕ : Çıkış değerini ifade eder.

Çıkış değerleri,

$$\phi = x_1 \cdot w_1 + x_2 \cdot w_2 + x_3 \cdot w_3 + \dots + x_n \cdot w_n + \phi$$


ile hesaplanır.

Tek katmanlı yapay sinir ağı yapısında, çıktılar, girdilerin ağırlıklarla çarpılıp eşik değeri ile toplandıktan sonra, aktivasyon fonksiyonuna tabi tutularak hesaplanır. Ancak, tek katmanlı yapay sinir ağları, doğrusal olmayan problemlerin çözümünde yeterli olmayabilir [42].

1.3.5. Çok katmanlı sinir ağları

Tek katmanlı Yapay sinir ağlarının çözemediği problemlere karşı geliştirilen çok katmanlı YSA, 1986'da Rumelhart ve arkadaşları tarafından ortaya konmuştur. Bu model, yaygın olarak "hatayı geri yayma" veya "backpropagation" olarak bilinir. Çok katmanlı ağlar, öğrenme sürecinde Delta Öğrenme Kural'ını kullanır. Bu öğrenme yöntemi, ağın üretmiş olduğu sonuç ile beklenen değer arasındaki hatayı en düşük seviyeye indirmeyi amaçlar ve bu işlemler hata geri yayılarak gerçekleştirilir. Çok katmanlı ağlar, öğretmenli öğrenme prensibine dayandığı için başlangıç aşamasında girdiler ve bu girdilere bağlı olarak üretilen çıktılar sisteme verilir. Çalışan bu ağlar Delta Kuralı'na göre, ileri ve geri hesaplama olmak üzere iki aşamadan oluşur. İleri hesaplama, ağın çıktısını belirleme sürecini kapsarken, geri hesaplama ise ağırlıkları ayarlama sürecini ifade eder. Geriye hata hesaplama süreci, ileri doğru hesaplamaların ardından gerçekleştirilir. Bu nedenle bu ağlara aynı zamanda ileri beslemeli ağlar da denir. Bu sistem çeşitli teknik ve mühendislik problemlerin çözümünde etkili bir yöntem olarak kabul edilir. Şekil 1.14'de görüldüğü gibi, çok katmanlı yapay sinir ağı yapısında, girdi katmanları ile çıktı katmanları arasında bulunan ara katmanlar yer almaktadır. Bu ara katmanların görevi, girdi katmanlarından aldıkları bilgileri işleyerek çıktı katmanlarına iletmektir. Aynı zamanda bu ara katmanlar, gizli katmanlar olarak da adlandırılır ve bu katmanların sayısı değişebilir [23].

Çok Katmanlı Ağ Modelinin Yapısı



8

Şekil 1.14. Çok katmanlı yapay sinir ağı modeli [30]

1.3.6. Geriye yayılım algoritması

Bu model yapay sinir ağılarında yaygın olarak kullanılmakta olan bir öğrenme algoritmasıdır ve değişkenlerin güncellenmesi için sıkça tercih edilir. Bu algoritmanın başarılı bir şekilde kullanıldığı birçok uygulama arasında ses tanıma problemleri ve doğrusal olmayan sistem problemleri bulunmaktadır. Algoritmanın ağ içinde oluşan hatayı geri yönde azaltma yeteneği nedeniyle, bu algoritmaya geriye yayılım adı verilmiştir [43].



2. LİTERATÜR ARAŞTIRMASI

Günümüzde yapılan araştırmalar, Yapay Sinir Ağları'nın (YSA) birçok alanda tahmin yapma amacıyla kullanıldığını göstermektedir. YSA'nın gelecekteki potansiyel kullanım alanlarından biri de enerji sektörüdür. Son birkaç yılda yapılan çalışmalara baktığımızda, YSA'nın enerji üretimi, tüketimi ve bu faktörleri direkt etkileyen unsurların tahmin edilmesinde etkili bir şekilde kullanılabileceğini ortaya koymuştur. Bu alanda yapılan bazı çalışmalardan örnekler aşağıda verilmiştir.

Farklı bir ülkede, özellikle Adrar Çölü'nde gerçekleştirilen bir araştırmada, şebekeye bağlı bir fotovoltaik istasyonun performansının meteorolojik değişkenler tarafından önemli ölçüde etkilendiği belirtilmiştir. Bu meteorolojik değişkenlerin kullanılmasıyla, güç üretimini tahmin etmek için bileşenlerin analizi geliştirilmiştir. Tahmin modelleri, hesaplama süresi, doğruluk ve çeşitli istatistiksel göstergeler açısından değerlendirilmiştir. Özellikle ışıınım ve hava sıcaklığının, performans değerlendirmesi ve üretim tahmini açısından belirgin bir etkisi olduğu ifade edilmiştir [44].

Fotovoltaik enerji santralleri için güç tahmini, FV gücünün değişken özellikleri nedeniyle geleneksel doğrusal veya zaman serisi modellerine dayalı yöntemlerden farklı olarak, dalgacık ayrıştırma (WD) ve Yapay sinir ağlarının avantajlarını birleştiren bir yöntem geliştirilmiştir. YSA'nın doğrusal olmayan ilişkileri modelleme yeteneği sayesinde, teorik güneş ışıınımı ve meteorolojik değişkenler, WD ve YSA tabanlı hibrit modelin girdileri olarak seçilmiştir. Çalışmada, WD ve YSA kullanarak FV enerji santrallerinin güç çıkışını tahmin etmek için bir yöntem önerilmiştir. FV çıkış serisinin periyodik ve durağan olmayan özellikleri nedeniyle, santral çıkışının çok ölçekli ayrıştırılması amacıyla dalgacık analizi tekniği kullanılmıştır. YSA aracılığıyla farklı sinyal katmanlarında tahmin modelleri oluşturulmuş ve FV santralinin güç çıkışı tahmin edilmiştir [45].

Bir diğer araştırmada, FV panellerin altı farklı açıyla yerleştirildiği bir kurulumdan elde edilen güç değerlerini tahmin etmek için parçacık sürü optimizasyonu (PSO), geri yayımlı yapay sinir ağı (GY) ve klonal seçim algoritması (KSA) gibi yöntemler geliştirilmiştir. Üç modelin doğrulama sonuçları incelendiğinde, PSO algoritmasının diğer yöntemlere göre daha başarılı sonuçlar verdiği belirlenmiştir [46]. Harran Üniversitesi Gapyenev merkezindeki meteorolojik veriler kullanılarak, kayıp güneş ışıınımı değerlerinin çeşitli veri madenciliği teknikleriyle tahmin edilmesi

amaçlanmıştır. Yapay sinir ağı modelleri ve diğer veri madenciliği yaklaşımlarıyla elde edilen tahmin sonuçları karşılaştırıldığında, eksik verilerin en doğru şekilde tahmin edilmesinde 'En Yakın Komşu Yöntemi'nin en yüksek başarıyı sağladığı görülmüştür [47].

Yapay sinir ağları dışında, çeşitli yapay zekâ tekniklerinin de tahminleme problemlerini çözmek için kullanmış olduğu çalışmalar da vardır. Bu tekniklerden biri için yapılan araştırmada, Li ile arkadaşları, kısa süreli güneş ışıının tahmin algoritmalarını, Avustralya Meteoroloji Bürosu'ndan elde ettikleri verileri kullanarak, Makine Öğrenme metodolojileri, Gizli Markov Modeli ve SVM regresyonunu temel alan bir tahmin platformu geliştirmişlerdir. Deney sonuçlarına göre, makine öğrenme temelli tahmin algoritmalarının, farklı hava koşullarında gelecek 5-30 dakika içinde güneş ışıının başarılı bir şekilde tahmin edebildiğini ortaya koymuşlardır [48].

Gerçek bir santral üzerinde yapılan bir çalışmada, FV santralde üretilen enerjinin tahmin edilmesi için bir yapay sinir ağı önerilmiştir. Bu öneri, giriş veri setlerine dayalı hassasiyet, yöntemin doğruluğu, eğitim veri setlerinin ve hata tanımlarının fonksiyonlarını kapsayan ayrıntılı bir inceleme içermektedir. Santralde gerçekleştirilen deneysel çalışmalar doğrultusunda yapılan analiz, 48 saatlik hava tahminlerine dayanarak ertesi günün tüm gün ışı saatleri için saatlik enerji tahminini ele almaktadır. Bu yaklaşım, akıllı şebeke uygulamalarının talep ettiği öngörülse özellikler dikkate alındığında, yenilenebilir enerji kaynaklarının planlanmasında, özellikle depolama sistemlerinin boyutlandırılması ve FV çıkış gücünün 24 saat öncesinden Yapay Sinir Ağı tahminlerinin analizi açısından önemli bir rol oynamaktadır [49].

Coşkun ve arkadaşları çalışmalarında, yapay sinir ağları yöntemi kullanılarak bir FV panelin yüzey sıcaklığının tahmin edilmesini amaçlamışlardır. Deneysel olarak elde edilen FV verileri kullanılarak YSA'nın modelleme doğruluğu değerlendirmişlerdir. Yapay sinir ağlarını eğitmek için dış sıcaklık, güneş radyasyonu ve rüzgâr hızı değerleri girdi olarak kullanılmışlar ve çıkış olarak FV panel yüzey sıcaklığı belirlemişlerdir. Yapay sinir ağları, FV panel yüzey sıcaklığının tahmininde kullanmışlardır. Levenberg-Marquardt (LM) algoritmaları kullanılarak ileri besleme tipi yapay sinir ağları eğitmişlerdir. Ayrıca, iki farklı geri yayılım (backpropagation) ağ tipi YSA algoritması da kullanmışlar ve bu algoritmaların performansları LM algoritmasının tahmini ile karşılaştırmışlardır. En iyi tahmini LM algoritması verdiğini

görmüşler ve yüzey sıcaklığı tespitinde yapay sinir ağının etkili olduğunu göstermişlerdir [50].

Bu çalışmada, FV güç üretimini tahmin etmek amacıyla, FV sahasının kümelenme işlemi, temsili FV sahalarının seçimi ve geleneksel bulanık modelin geliştirilmesi sürecini içeren bulanık model önerilmektedir. İlk adımda, eksik verilerin tamamlanmasında K-en yakın komşu (KNN) algoritması kullanılmaktadır. Ardından, FV sahalar, iki farklı kümeleme algoritmasıyla gruplanmaktadır. Her küme için, tek bir FV sahasının güç üretimi ile aynı kümedeki diğer tüm sahaların toplam üretimi arasındaki ilişki incelenir ve temsili FV sahaları belirlenir. Son olarak, FV güç üretimini tahmin etmek için geliştirilmiş bulanık bir model uygulanır. Bu çalışmada, tahmin doğrulama ve karşılaştırma amacıyla Tayvan'daki gerçek FV sahalarından alınan veriler kullanılmıştır. Sayısal sonuçlar, önerilen modelin, FV sahalarından elde edilen sınırlı verilerle yaklaşık %7'lik bir tahmin hatası sağladığını ve yüksek verimlilik ile uygulanabilirlik gösterdiğini ortaya koymaktadır [51].

Bu makalede, FV güç üretimini tahmin etmek amacıyla YSA ve ANFIS tabanlı bir tahmin modeli önerilmiştir. Geliştirilen model, geçmiş verilere dayalı olarak eğitilmiş ve FV güç üretim istasyonunun veri seti kullanılarak sonuçlar doğrulanıp karşılaştırılmıştır. Sistem performansını değerlendirmek için, MATLAB ortamında önerilen modelin simülasyonuna yönelik bir model geliştirilmiştir [52].

Bu araştırmada, FV güç üretimini tahmin etmek amacıyla çok katmanlı algılayıcı (MLP) ve uyarlanabilir ağ tabanlı bulanık çıkarım sistemi (ANFIS) modelleri kullanılmıştır. Geliştirilen tahmin modeli, Ekim 2011 ile Şubat 2022 arasındaki geçmiş verilere dayanarak eğitilmiştir. Önerilen modelin çıktıları, doğruluk açısından kontrol edilip, FV güç üretim istasyonundan alınan veri kümesi ile karşılaştırılmıştır. Modelin güvenilirliğini değerlendirmek için üç farklı hata ölçümü (ortalama kare hatası, kök-ortalama-kare hatası ve Pearson korelasyon katsayısı) kullanılmıştır. Sonuçlar, önerilen yöntemlerin, en yeni ve gelişmiş modellerden daha iyi performans sergilediğini göstermektedir. MLP ve ANFIS modelleri, daha az tahmin hatası ($MSE = 1,1116 \times 10^{-8}$ ve $MSE = 1,3521 \times 10^{-8}$) ile en yüksek performansı ($R = \%100$) elde etmiştir. Ayrıca, bu çalışma, önceki toplanılan FV gücü üretimine ait veriler kullanılarak gelecekte FV güç üretimi değerlerini tahminde bulunmaktadır [53].

Bu makale, Vietnam'ın Thua Thien Hue Eyaleti'nde yer alan Phong Dien güneş enerjisi santralının (48 MWp - 35 MWAC) kısa süreli üretilen kapasitesinin

meteorolojik parametrelerle tahmin etmek için tekrarlayan sinir ağı modellerinden Uzun Kısa Süreli Bellek (LSTM) ağı kullanılmaktadır. Yazarlar, santralin koşullarına uygun ve veri toplama süreçlerine dayalı olarak modelin en verimli yapısını belirlemek amacıyla çeşitli deneyler gerçekleştirmiştir. Bu model, ticari tedarikçilerden alınan meteorolojik tahmin verilerini kullanarak, santralin çıkış gücünü tahmin etmek için geliştirilmiştir. Elde edilen sonuçlar doğrultusunda, yorumlar yapılmış ve ileriye dönük araştırmalar için önerilerde bulunulmuştur [54].

Bu makalede, yenilenebilir enerjinin ekonomik olarak uygulanabilirlik derecesini artırmak için, güç sistemlerindeki kesintileri (özellikle rüzgâr ve güneş enerjisi kesintilerini - WSPC'ler) doğru bir şekilde tahmin etmek amacıyla yapay zekâ tabanlı modeller önerilmektedir. Güç sistemindeki kesintiler, yenilenebilir enerjinin etkin kullanımını engellediği için, bu kesintilerin tahmin edilmesi büyük önem taşımaktadır. Çalışmada, farklı makine öğrenimi (ML) yöntemleri kullanılarak bir tahmin metodolojisi geliştirilmiş ve bu metodoloji hem tutma (HO) hem de çapraz doğrulama (CV) yaklaşımlarına dayalı olarak değerlendirilmiştir. Ele alınan makine öğrenimi yöntemleri arasında regresyon ağaçları (RT), gradyan artırma ağaçları (GBT), rastgele orman (RF), ileri beslemeli yapay sinir ağları (ANN), uzun kısa süreli bellek (LSTM) ve destek vektör makineleri (SVR) bulunmaktadır. Tahmin modelleri, yük talepleri, termik santrallerin çıkış gücü, nükleer üniteler, güneş çiftlikleri, rüzgâr türbinleri, biyokütle/jeotermal üniteler, büyük hidro üniteler, enerji ithalatı ve WSPC olmak üzere sekiz farklı girdi özelliğine dayalı olarak eğitilmiştir. Modeller, Kaliforniya Bağımsız Sistem Operatörü'nün (ISO) saatlik verilerine dayanarak doğrulanmış ve her model için Bayesian optimizasyonu kullanılarak optimum hiperparametreler seçilmiştir. Sonuçlar, rastgele orman (RF) modelinin, önerilen çapraz doğrulama yaklaşımıyla en düşük tahmin hatalarıyla ve dolayısıyla en yüksek performansla sonuçlandığını göstermektedir. Elde edilen bulgular, WSPC'lerin tahmininde önerilen yapay zekâ tabanlı modellerin etkinliğini ortaya koymaktadır [55].

Bu çalışma, İran'ın Meşhed kentinde yer alan elektrik tüketim miktarının makine öğrenme yöntemleri kullanarak analiz etmeyi ve vatandaşların yenilenebilir enerji üretimine yönelik istekliliğini artırmak için dinamik stratejileri geliştirmeyi amaçlamaktadır. Araştırmanın temel yeniliği, bir Karar Destek Sistemi (KDS) oluşturmak amacıyla Yapay Sinir Ağı ve istatistiksel analizlerin eşzamanlı olarak

uygulanmasıdır. Ayrıca, güneş enerjisi potansiyeli, Meşhed'deki vaka çalışmasında bir yıl boyunca FV sistem simülasyon aracıyla değerlendirilmiştir. Motivasyon stratejileri ve daha ileri TP uygulamaları için Klasik Delphi (CD) yöntemi de uygulanmıştır. Bu yöntemle, 45 uzman tarafından önerilen motivasyon stratejileri, sıralı uzman toplantılarında önceliklendirilmiştir. Araştırmanın sonuçları, YSA modelinin yaz ve kış aylarında elektrik enerjisi tüketimini %99 doğrulukla başarılı bir şekilde tahmin edebildiğini ortaya koymaktadır. Ayrıca, FV sistemindeki güneş enerjisi hesaplamalarına dayanarak, en sıcak ve soğuk aylarda elektrik enerjisi tüketimindeki zirveler kontrol edilebilir. Son olarak, uzmanlar ve vatandaşlar arasındaki görüşlerin birleşimi, kısa, orta ve uzun vadeli planlama ufuklarında güneş enerjisi üretimi için ana motivasyon stratejilerini belirlemiştir. Bu stratejiler arasında A4 (güneş enerjisi üretiminin optimizasyonu ile maliyet faydalarının vatandaşlarla paylaşılması), B2 (özellikle yoğun dönemlerde güneş enerjisi üretimi için elektrik maliyetlerinin düşürülmesi) ve C1 (güneş enerjisi üretimine uygun kentsel faaliyetlerde para harcamak yerine kredilerle enerji parası yaratılması) ön plana çıkmaktadır [56].

Değişken enerji kaynakları (VER) arasında güneş enerjisinin yaygınlaşmasıyla birlikte, güneş FV enerji üretimi büyük ölçekli enerji endüstrilerinde hızla artmaktadır. Ancak, FV sistemlerinin güç çıkışı, hava durumu koşullarına büyük ölçüde bağlıdır ve bu nedenle güç çıkışındaki ani değişimler, güç sisteminin işletme maliyetlerini artırabilir. Ayrıca, bu tür enerji kaynaklarının şebekeye entegrasyonu, sabit bir çıktı garanti edilememesi nedeniyle öngörülemezlik nedeniyle önemli bir engel teşkil etmektedir. Bu durum, şebeke planlamasını ve genel dengelenmeyi son derece zor hale getirdiği için enerji kuruluşları, FV gücünün kullanımına karşı temkinli yaklaşmaktadır. Güneş enerjisinin şebekeye verimli bir şekilde entegrasyonu için, yakın gelecekteki FV enerji üretimini daha doğru bir şekilde tahmin edebilecek güvenilir bir algoritmanın geliştirilmesi büyük önem taşımaktadır. Bu makale, güneş radyasyonu ve sıcaklık verilerini içeren FV sistemlerinin bir saatlik güç çıkış tahminini, dalgacık dönüşümü (WT) ve yapay zeka (AI) tekniklerinin bir kombinasyonunu kullanarak sunmaktadır. Önerilen yöntemde, WT, FV güç zaman serisi verilerindeki düzensizlikleri daha etkili bir şekilde ele almak için uygulanırken, AI teknikleri, doğrusal olmayan FV dalgalanmalarını daha iyi bir şekilde yakalamaktadır [57].

3. MATERYAL VE YÖNTEM

Çalışma, yapay zekâ algoritmaları kullanılarak bilgisayar üzerinden gerçekleştirilmiştir. Derin öğrenme ve istatistiksel analiz için gerekli olan materyaller, kullanılan uygulamalar ve yazılım kütüphanelerinde mevcuttur. Bu materyaller, yaygın kullanımları, çeşitli örnek uygulamaları ve kolay erişim imkânları nedeniyle tercih edilmiştir.

Python, 1990 yılında Guido van Rossum tarafından tasarlanarak geliştirilen, nesne yönelimli, modüler yapıda ve etkileşimli bir yüksek seviyeli programlama dilidir. Geliştirilmesi Python Yazılım Vakfı tarafından sürdürülmektedir.

Bu dilin modüler yapısı, çeşitli veri alanlarına rahat bir şekilde entegre olmasını sağlar. Donat'ın ifadesine göre, Python'un esnekliği sayesinde hemen her türlü platformda sorunsuz bir şekilde çalışabilir [58].

Numpy (Numerical Python), bilimsel hesaplamaların yapılmasına ve yüksek seviyeli matematiksel fonksiyonların daha az kod yazımı ile oluşturulmasına yardımcı olmak amacıyla Python tarafından desteklenen bir açık kaynak kütüphanedir. Bu kütüphane, araştırmacılar ve bilim insanları tarafından sıklıkla tercih edilen, çok boyutlu dizilerin ve matrislerin hızlı bir şekilde oluşturulmasını sağlayan bir araçtır.

Bu Python Kütüphanesi, veri görselleştirmesi (Data visualization) amacıyla kullanılmakta olan açık bir kaynak araçtır. İki ya da üç boyutlu grafik çizimlerinde kullanışlı olmakla beraber ve Numpy Kütüphanesi ile de uyumlu çalışabilmektedir. Aynı zamanda çeşitli grafik türlerini destekler, bu grafik türleri arasında çizgi grafikleri, sütun grafikleri, daire grafikleri, görüntü işleme ve daha birçok seçenek bulunmaktadır.

Bu kütüphane, Python dilinde yazılmış ve veri analizi ile manipülasyon için kullanılan bir açık kaynak araçtır. Proje içerisine veri aktarımını kolaylaştırmak üzere tasarlanmış olup, csv, txt, xls gibi çeşitli formatları destekler. "Dataframe" ve "Series" türleriyle çalışır. Özellikle makine öğrenimi uygulamalarında sıkça kullanılan "Dataframe" yapıları, ilişkisel veri tabanı sistemlerindeki tabloları andırır. Pandas, "Dataframe" yapıları üzerinde çeşitli veri işlemleri gerçekleştirmek için kullanılır; örneğin, sütun veya satır ekleme/silme, tabloları birleştirme, ayırma gibi işlemler bu kütüphane aracılığıyla kolaylıkla gerçekleştirilebilir.

3.1. Veri Setleri

Bu çalışmada Türkiye’de belirlenen illerin son 10 yıllık meteoroloji verileri ile saha çalışmaları sonucu elde edilen günlük üretilen elektrik miktarları veri setleri kullanılmıştır. Bu veri setlerinde günlük meteorolojik veriler ile günlük üretilen elektrik miktarları eşleştirilmiştir. Eşleşen değerler model eğitmek için kullanılmıştır. Eşleşen veriler aşağıda belirtilmiştir.

Malatya ilinin son 10 yılına ait 3941 meteorolojik veri ile 14.08.2020 tarihinden itibaren üretime başlamış İOTA M. Fırıncı GES e ait elde edilen veriler eşleştirilmiş ve 3487 adet veri elde edilmiştir.

Elazığ ilinin son 10 yılına ait 3951 meteorolojik verileri ile 20.10.2016 tarihinden itibaren üretime başlamış Solentegre GES’e ait elde edilen veriler eşleştirilmiş ve 3571 adet veri elde edilmiştir.

Van ilinin son 10 yılına ait 3943 meteorolojik verileri ile 30.10.2020 tarihinden itibaren üretime başlamış Gün Güneş Van Arısu GES’e ait, 21.09.2018 tarihinden itibaren üretime başlamış Omicron Engil GES ile Omicron Erciş GES ait elde edilen veriler ve 27.07.2019 tarihinden itibaren üretime başlamış PSİ Engil 207 GES’e ait elde edilen veriler eşleştirilmiş ve 3559 adet veri elde edilmiştir.

Mardin ilinin son 10 yılına ait 3946 meteorolojik verileri ile 07.11.2019 tarihinden itibaren üretime başlamış Ra Güneş Mardin GES e ait elde edilen veriler eşleştirilmiş ve 3573 adet veri elde edilmiştir.

Şırnak ilinin son 10 yılına ait 3706 meteorolojik verileri ile 01.01.2020 tarihinden itibaren üretime başlamış Silopi GES e ait elde edilen veriler eşleştirilmiş ve 3301 adet veri elde edilmiştir.

Antalya ilinin son 10 yılına ait 3929 meteorolojik verileri ile 02.10.2020 tarihinden itibaren üretime başlamış Serra GES e ait elde edilen veriler eşleştirilmiş ve 3215 adet veri elde edilmiştir.

Muğla ilinin son 10 yılına ait 3956 meteorolojik verileri ile 24.03.2017 tarihinden itibaren üretime başlamış Özmen-1 GES e ait elde edilen veriler eşleştirilmiş ve 3110 adet veri elde edilmiştir.

Denizli ilinin son 10 yılına ait 3956 meteorolojik verileri 21.04.2016 tarihinden itibaren üretime başlamış Renoe GES e ait elde edilen veriler eşleştirilmiş ve 3254 adet veri elde edilmiştir.

3.2. Modelin Seçilmesi ve Değerlendirme

Makine öğrenimi prosedürleri, verilerden öğrenme sağlayarak modeller oluşturur (fit) ve bu modellerle tahminler yapar. Ancak, her veri için tek bir evrensel model bulunmamakta ve veri özelliklerine bağlı olarak farklı makine öğrenmesi teknikleri birbirlerine üstünlük sağlayabilmektedir. Bu nedenle, tipik bir veri analizinde kritik bir adım, bir dizi aday modeli değerlendirmek ve ardından en uygun olanını seçmektir [59]. Kısacası, model seçimi, bir eğitim veri kümesi için çeşitli aday makine öğrenimi modelleri arasından en uygun olanını belirleme sürecidir. Bu aşamada, farklı modellerin performansı değerlendirilir ve en etkili sonuçları sağlayan model seçilir. Ardından, seçilen model test edilir ve uygulanır [60].

Bu çalışmada üretilecek olan gücün tahmin edilmesi için regresyon analizinden faydalanılmıştır. Bu tahmin için gerekli olan iklimsel veriler (sıcaklık, rüzgâr, nem, radyasyon değeri, güneşlenme şiddeti) Meteoroloji Genel Müdürlüğü'nden alınmıştır. Üretilen elektrik miktarı ise Enerji Piyasaları İşletme Anonim Şirketi'nden alınmıştır. İklimsel verilerin üretilen güce olan etkisini incelemek için regresyon algoritmaları kullanılmıştır. Makine öğrenmesi algoritmaları, haritalama fonksiyonunun formuyla ilgili güçlü varsayımlarına bağlı olarak doğrusal ve doğrusal olmayan olmak üzere iki ana kategoriye ayrılabilir. Doğrusal yöntemler, özelliklerin nihai sonucu yalnızca doğrusal bir model aracılığıyla etkilediğini varsayar. Diğer taraftan, doğrusal olmayan yöntemler daha genel bir perspektife sahiptir ve performansları model varsayımına daha az bağımlıdır [61]. Bu kısımda, çalışma sırasında kullanılan makine öğrenimi regresyon algoritmaları (6 adet doğrusal ve 6 adet doğrusal olmayan) ile performans metrikleri kısaca açıklanmıştır.

3.2.1. Doğrusal regresyon algoritmaları

3.2.1.1. Çoklu doğrusal regresyon (Multiple Linear Regression - MLR)

Çoklu doğrusal regresyon modeli, n gözlem birimine sahip birden fazla öngörücü değişkeni ve tek çıktı değişkenini içeren veriler için basit doğrusal regresyon modelinin genişletilmiş bir versiyonu olarak açıklanır. Bu model, $x_{i1}, x_{i2}, \dots, x_{i,p-1}$ öngörücü değişkenleri ile birlikte çıktı değişkeni y_i 'yi ($i=1,2,\dots,n$) içerir [62].

3.2.1.2. Temel bileşen regresyonu (Principal Component Regression - PCR)

Temel Bileşen Regresyonu, yaygın bir boyut azaltma tekniği olup çoklu bağlantı problemlerini çözmek amacıyla kullanılmaktadır. Bu teknik, bağımsız değişkenler arasındaki doğrusal ilişkileri azaltmak için bağımsız değişkenlerin doğrusal kombinasyonlarını oluşturarak değişken sayısını azaltır. Temel bileşen regresyonu, yanlı bir regresyon tekniği olup, bağımlı değişkeni doğrudan bağımsız değişkenlere regresyonlamak yerine, bağımsız değişkenleri temel bileşenlere indirgeyerek regresyon modeli oluşturma fikrine dayanır [63].

3.2.1.3. Kısmi en küçük kareler regresyon (Partial Least Squares Regression - PLSR)

1960'larda Herman Wold tarafından bir ekonometri tekniği olarak geliştirilmiştir [64]. Kısmi en küçük kareler regresyonu, çok sayıda faktörün ve yüksek düzeyde çoklu bağlantının bulunduğu durumlarda, yanıtları tahmin etmeye odaklanan bir yöntemdir. Bu yöntem, değişkenler arasındaki temel ilişkiyi anlamak yerine, yanıtların tahmin edilmesine odaklanarak model oluşturur. Amaç, regresyon problemindeki çoklu bağlantı sorununu azaltırken, tahmin için yararlı olan bağımsız değişkenlerdeki bilgileri yakalayan bileşenler oluşturmaktır [65].

3.2.1.4. Ridge regresyon (RR)

Ridge regresyon yöntemi, çoklu bağlantı problemlerini ele almak için en yaygın yöntemlerden biridir ve özellikle örneklem boyutu küçük olduğunda diğer yaklaşımlardan daha iyi performans gösterir [66-67]. Önceki iki teknik olan PCR ve PLCR, çoklu bağlantı problemini aşmak için var olan bağımsız değişkenlerin kombinasyonlarından oluşan daha az sayıda değişken seti ile tahmin modeli oluşturmayı amaçlayan bir prensibe dayanıyordu. Ancak ridge, lasso regresyonu ve elasticNet, cezalandırma prensibine dayanmaktadır. Bu modeller, genellikle küçültme veya daraltma modelleri olarak adlandırılır [68].

3.2.1.5. Lasso regresyonu (LR)

Yüksek boyutlu verilerin regresyonu için uygun bir yöntem olan Ridge Regresyonu (RR), nihai modeldeki tüm bağımsız değişkenleri içermektedir. Buna karşın, Lasso regresyonu en az önemli özelliklerin ağırlıklarını tamamen ortadan kaldırma eğilimindedir, yani onları sıfıra ayarlama. Başka bir deyişle, Lasso

regresyonu aynı zamanda özellik seçimi yapmaktadır. Bu nedenle Lasso, aşırı öğrenmeyi önleyen yorumlanabilir modeller vermektedir [69].

3.2.1.6. ElasticNet

Ridge ve Lasso regresyonu arasında bir köprü sağlayan bir yaklaşım olan ElasticNet, katsayıların ve her iki algoritmanın düzenleme normu ile eğitilmesine dayanır [70]. Büyük balıkları kaçırmayan bir ağ gibi davranarak bu adı almıştır [71].

3.2.2. Doğrusal olmayan regresyon algoritmaları

3.2.2.1. K-en yakın komşu (K Nearest Neighbors - KNN)

Eğitim setindeki en yakın k örneği kullanarak tahminlerde bulunur [72]. KNN algoritması, sınıflandırma ve regresyon için parametrik olmayan bir yaklaşımı temsil eder [73]. KNN algoritması, tek bir hiperparametreye, yani k değerine bağlıdır. Bu değer çok düşükse aşırı uyarlanma (overfitting) riski oluşturabilirken, çok yüksekse yetersiz uyum (underfitting) durumu meydana gelebilir. Ayrıca, KNN algoritmasının dezavantajlarından biri, veri miktarı arttıkça mesafe hesaplama işlemlerinden kaynaklanan işlem yükünün artma eğilimindedir [74].

3.2.2.2. Çok katmanlı algılayıcı (Multilayer Perceptron - MLP)

MLP'ler, evrensel tahminçiler olarak işlev gören sinir ağı modelleridir; yani, herhangi bir sürekli fonksiyona yaklaşabilirler [75]. İleri beslemeli algoritmalara ait olan çok katmanlı algılayıcılar, giriş ve çıkış katmanlarına ek olarak bir veya birden fazla gizli katman içeren yapıları temsil ederler. Bu gizli katmanlar, bilgileri girişten başlayarak çıkışa doğru aktaran bir akışa sahiptir [76].

3.2.2.3. Regresyon ağaçları (Regression Trees - RT)

RT (Random Forest), basit (if/then/else) karar kurallarıyla çalışan ve genellikle denetimli öğrenme bağlamında tercih edilen bir algoritmadır [77]. RT, sınıflandırma veya regresyon modelleri oluşturmak için ağaç yapısı biçiminde kullanılan bir algoritmadır. Temel amacı, veri setindeki karmaşık yapıları basit karar yapılarına dönüştürmektir. Veri seti, belirli bir hedef değişkene göre homojen alt gruplara ayrılarak ağaçlar oluşturulur [78]. Algoritmanın sonucu, karar düğümleri içeren bir ağaç yapısıdır. RT'ler, kategorik ve sayısal verileri işleyebilme yeteneğine sahiptirler [79].

3.2.2.4. Rastsal orman (Random Forest - RF)

Rastgele Orman (Random Forest), torbalı (bagged) regresyon ağaçlarının özel bir durumudur. Korelasyonu azaltmak amacıyla ağaç oluşturma sürecinde yalnızca rastgele seçilen tahmin edicilerin kullanıldığı bir yöntemdir [80]. RF, birçok Rastgele Ağaç'tan oluşan bir orman şeklinde tasarlanmıştır. Topluluk yöntemleri grubundan olan RF, (ensemble methods) genellikle yorumlanması kolaydır ve değişkenler arasında doğrusal olmayan korelasyonları yakalama yeteneğine sahiptir [81]. Ancak eğitim verilerine aşırı uyum sağlama eğilimindedir [82].

3.2.2.5. LightGBM

Ağaç tabanlı öğrenme algoritmalarını kullanan bir gradyan artırma yöntemidir [83]. Microsoft tarafından geliştirilen bu algoritma, bellek tüketimini azaltmak ve eğitim sürecini hızlandırmak amacıyla histogram tabanlı bir yaklaşımı benimser [84]. Hesaplama maliyetini azaltmak amacıyla, bu algoritma sürekli değere sahip olan değişkenleri kesikli hale getirir [85]. Ke ve arkadaşları yaptığı bir çalışmada bu modelin diğer modellere göre 20 kat daha hızlı olduğu sonucuna varılmıştır [86].

3.2.2.6. CatBoost

Yandex mühendis ve araştırmacıları tarafından geliştirilen yeni bir gradyan artırma algoritması olan bu algoritma, açık kaynaklı olarak sunulmuştur. Bu algoritma, kategorik özellikleri düşük bilgi kaybıyla işleyebilme yeteneğine sahiptir [87]. CatBoost, eğitim için tüm veri setini kullanma olanağı tanıyan daha etkin bir strateji kullanır [88]. Ayrıca, CatBoost, geleneksel gradyan artırma algoritmalarının neden olduğu aşırı öğrenmeyi ele almak için ağaç yapısı ve yaprak değerlerini tahmin etmek için rastgele permütasyonlar gerçekleştirir [89]. CatBoost'un sunduğu bir diğer avantaj, varsayılan parametrelerle bile mükemmel sonuçlar elde edebilmesi nedeniyle parametre ayarlama süresini minimize etmesidir [90].

3.3. Performans Metrikleri

Tahmin yöntemlerinin performansını değerlendirmek için kullanılan metrikler genellikle tahmin hataları üzerinden ölçülür. Yüksek hata değerleri, genellikle düşük tahmin doğruluğuyla ilişkilidir. Bu bölümde, genellikle kullanılan bazı performans ölçümleri ele alınacaktır. Önemli bir not, "x" ile gösterilen değer $\bar{x}$ gözlemlenen değeri, "y" ile gösterilen değer tahmin edilen değeri ve "n" ise toplam örnek sayısını temsil eder [91].

3.3.1. RMSE (Kök ortalama kare hata)

Kök Ortalama Kare Hata (RMSE - Root Mean Square Error), MSE değerinin karekökü ile elde edilir (Denklem 3.1). Bu ölçüt, makine öğrenimi modelinin tahminde bulunma mekanizmasının gerçek değerlerle arasındaki uzaklığı ölçen bir kuadratik ölçüdür. RMSE, yapılan tahminlerdeki hataların standart sapmasını açıklar, yani regresyon çizgisinin gerçek veri noktalarından uzaklaşma seviyesini gösterir. Bu ölçüm, kalıntıların (residuals) regresyon çizgisinden ne kadar sapma gösterdiğini ifade eder. RMSE, matematiksel hesaplamalarda istenmeyen mutlak değerlerin kullanılmasını engeller [92]. RMSE, sıfıra yaklaştıkça, verilerle o kadar mükemmel bir uyum gösterdi denir. Ancak, pratikte asla tam olarak 0 değerini almaz. Genelde, RMSE değerinin düşük olması, yüksek olan bir değerden daha iyidir. RMSE'nin kullanımı, ölçüm olarak kullanılan sayıların ölçeğine bağlı olduğu için (biz günlük kWh cinsinden kullanacağız, bu bağlamda şekillenecek), farklı veri türleri arasında karşılaştırmaların genel geçerliliği olmayabilir. Yine de, model karşılaştırmalarında sıkça kullanılır.

$$RMSE = \sqrt{\frac{1}{n} (\sum_{i=1}^n (\tilde{x}_i - x_i)^2)} \quad (3.1)$$

3.3.2. NRMSE (Normalize edilmiş kök ortalama kare hata)

Normalize edilmiş kök ortalama kare hata (NRMSE – Normalized root mean square error), RMSE değerinin normalize edilmiş versiyonudur [92]. (Denklem 3.2).

$$NRMSE = \frac{\sqrt{\frac{1}{n} (\sum_{i=1}^n (\tilde{x}_i - x_i)^2)}}{\frac{1}{n} (\sum_{i=1}^n x_i)} \quad (3.2)$$

3.3.3. MAE (Ortalama mutlak hata)

Ortalama Mutlak Hata (MAE - Mean Absolute Error), sürekli olan iki değişken arasındaki farkı ölçen bir değerlendirme ölçütüdür (Denklem 3.3). MAE, her bir gerçek değer ile veriye en uygun olan çizgi arasındaki ortalama dikey ve yatay mesafeyi ifade eder. Bu değer ne kadar düşükse, modelin başarısı o kadar yüksek demektir.

MAE, anlaşılması kolay bir sonuç sunar ve genellikle regresyon ve zaman serisi analizlerinde yaygın olarak kullanılır [92].

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

3.3.4. MAPE (Ortalama mutlak yüzde hata)

Ortalama mutlak yüzde hata (MAPE – Mean absolute percentage error), denklem 3.4’de gösterilmiştir.

$$MAPE = \frac{1}{n} \left(\sum_{i=1}^n \left| \frac{\hat{x}_i - x_i}{x_i} \right| \right) \times 100\% \quad (3.4)$$

MAPE (Mean Absolute Percentage Error), regresyon ve zaman serileri modellerinde tahmin doğruluğunu değerlendirmek için sıklıkla kullanılan bir ölçüdür. $MAPE < \%10$ olduğunda yüksek doğruluk oranına, $\%10 < MAPE < \%20$ olduğunda doğru tahmin ve $\%50 < MAPE$ olduğunda yanlış hatalı model olduğu anlamına gelmektedir. Ancak, gerçek değerler içinde sıfır (0) bulunuyorsa, MAPE hesaplanamaz çünkü sıfıra bölünme durumu söz konusu olup yanlış sonuçlar ortaya çıkar. Ayrıca, çok düşük tahmin değerleri için yüzde hata $\%100$ ’ü aşamaz. Ancak, tahmin değerleri çok yüksek olduğunda, yüzde hata için üst limit bulunmamaktadır. Bu durum, MAPE’nin özellikle tahminleri düşük olan bir modeli sistematik olarak seçme eğiliminde olduğu ve bu nedenle önyargılı bir ölçü olduğu anlamına gelir. Bu durumu göz önünde bulundurarak MAPE’nin kullanılması, model karşılaştırmalarında dikkatli bir şekilde yapılmalıdır [92].

3.3.5. Belirleme katsayısı (R^2)

R^2 metriği modelimizin yaptığı tahminlerinin ne kadar iyi olduğunun bir göstergesidir. En fazla 1 değerini alabilir, en düşük olarak eksi değerlere düşebilir. Çıkan değer 1’e ne kadar yakın olursa modelimizin veriler üzerindeki başarısı da bir o derece yüksek olur [92].

4. DENEYSEL SONUÇLAR VE TARTIŞMA

Bu kısımda Türkiye’de belirlenen illerin verileri ile eğitilen modellerin incelenmesi için metrik değerler ve tablo üzerinden karşılaştırma yapılacaktır. Mardin ili için üretilen elektrik miktarının tahmin edilmesi için 12 çeşit makine öğrenmesi algoritması ile test yapılmıştır. Mardin ili iklimsel olarak Akdeniz ile Karasal iklimin ortak özelliklerine sahip olması ve mevsimsel geçişlerin diğer illere göre daha az değişkenlik göstermesinden dolayı seçilmiştir. Mardin ili için bu tüm algoritmalar içerisinde en iyi sonuç veren CatBoost algoritması ile diğer iller test edilmiş ve tüm iller için 5 adet farklı metrik ile karşılaştırma yapılmıştır. Bu tahminde scikit-learn kütüphanesi ve Google Colaboratory (Colab) notebookdan faydalanılmıştır.

4.1. Mardin İli Tahmin Sonuçları

Mardin ilinde yapılan saha analizleri sonucunda güneş enerjisi santrallerinde elde edilen veriler, 07.11.2019 tarihinden itibaren üretime başlamış Ra Güneş Mardin GES e ait elde edilen veriler eşleştirilmiş ve 3573 adet veri elde edilmiştir.



Şekil 2. Mardin Ra GES

Elde edilen verilerin işlenmesi sonucunda Mardin ili verilerinin makine öğrenmeye göre karşılaştırılması aşağıdaki tabloda gösterilmektedir.

Çizelge 4.1. Mardin iline ait makine öğrenmesi modellerinin karşılaştırması

Doğrusal Regresyon Algoritmaları												
	MLR		PCR		PLSR		Ridge		Lasso		ElasticNet	
	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test
NRMSE	%6,38	%6,47	%6,38	%6,47	%6,89	%6,91	%6,56	%6,77	%6,94	%7,08	%6,96	%7,02
RMSE	6,33	6,52	6,33	6,52	6,83	6,93	6,32	6,34	6,89	7,14	6,90	7,07
MAE	3,72	3,80	3,72	4,14	4,35	4,38	3,76	3,80	4,05	4,11	4,05	4,08
MAPE	13,22	13,44	13,11	13,44	15,26	15,36	13,59	13,68	14,36	14,56	14,35	14,78
R²	0,98	0,98	0,98	0,98	0,97	0,97	0,98	0,98	0,98	0,98	0,98	0,98


Doğrusal Olmayan Regresyon Algoritmaları												
	KNN		RT		MLP		Random Forest		LightGBM		CatBoost	
	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test	Train	Test
NRMSE	%7,63	%7,67	%7,55	%7,77	%7,21	%7,40	%6,88	%7,11	%6,78	%6,91	%6,45	%6,71
RMSE	7,57	7,66	7,49	6,80	7,15	7,39	6,83	6,86	6,73	6,96	6,40	6,76
MAE	4,82	4,87	4,26	4,68	4,38	4,67	4,04	4,26	4,22	4,59	3,91	4,45
MAPE	16,00	16,12	14,27	15,56	17,35	17,40	14,33	15,96	15,32	15,46	14,54	15,41
R²	0,96	0,96	0,97	0,97	0,97	0,97	0,98	0,98	0,98	0,98	0,99	0,99

Çalışmada kullanılan bütün algoritmalar, eğitim seti ve test seti üzerinden değerlendirilmiş ve bu değerlendirmeler Çizelge 4.1'de karşılaştırmalı bir biçimde sunulmuştur. Bu yaklaşım, makine öğrenmesinin en temel sorunlarından biri olan aşırı öğrenme durumunun var olup olmadığını gözlemlenmeye çalışmaktadır. Bir algoritmanın eğitim setinde yüksek, ancak test setinde düşük performans sergilemesi, aşırı öğrenme durumuna işaret eder. Bu durum, oluşturulan modelin genelleme yeteneğinin düşük olduğunu ve yeni veriler için başarılı sonuçlar vermeyeceğini gösterir. Çizelge 4.1'de sunulan sonuçlar arasında, MLP algoritması ile elde edilen sonuçlardaki küçük farklılık dışında, tüm algoritmaların eğitim ve test setleri için benzer bir performans sergilediği gözlemlenmiştir. MAPE değerinin %20'nin altında olması, modelin tahminle ilgili yüksek bir doğruluk oranına sahip olduğunu gösterir. Bu bağlamda, analiz edilen tüm yöntemlerin doğru sonuçlar elde etme yeteneği olduğu ve her birinin gerçek dünya koşullarında uygulanabilir olduğu gözlemlenmektedir. Tüm performans ölçütleri açısından diğerlerine sürekli olarak üstün olan tek bir model bulunmamakla birlikte, genel olarak doğrusal olmayan makine öğrenmesi algoritmalarının tüm metriklerde daha iyi sonuçlar verdiği görülmüştür. Özellikle boosting machine algoritmaları, etkileyici sonuçlar göstermiştir. CatBoost ve LightGBM yöntemleri, RMSE ve NRMSE değerleri açısından hemen hemen eşit performans sergilemiştir. Ancak, MAPE ve MAE açısından değerlendirildiğinde LightGBM üstünlük sağlamıştır. MLP algoritması, MAPE haricinde tüm metriklerde

en düşük performansı sergilemiştir. En düşük NRMSE değeri ise KNN algoritması ile elde edilmiştir.

Mardin iline ait Çoklu Doğrusal Regresyon (Multiple linear regression - MLR) grafiği incelendiğinde tahmin ve gerçek değerlerin birbirine yakın olduğu görülmektedir. Bu da modelimizin tahmin gücünün ve doğruluğunun gerçek dünya koşullarında uygulanabilir olduğunu göstermektedir.

Çizelge 4.2. Çoklu doğrusal regresyon grafiği



4.2. Şırnak İli Tahmin Sonuçları

Şırnak ilinde yapılan saha analizleri sonucunda güneş enerjisi santrallerinde elde edilen veriler, 01.01.2020 tarihinden itibaren üretime başlayan Silopi GES e ait elde edilen veriler eşleştirilmiş ve 3301 adet veri elde edilmiştir.



Şekil 3. Şırnak Silopi GES


Elde edilen verilerin işlenmesi sonucunda Şırnak ili verilerinin makine öğrenmeye göre karşılaştırılması aşağıdaki tabloda gösterilmektedir.

Çizelge 4.3. Şırnak iline ait CatBoost algoritması verileri

CatBoost		
Metrikler	Train	Test
NRMSE	%8,84	%14,23
RMSE	7,50	9,09
MAE	5,22	6,62
MAPE	129,92	248,86
R ²	0,82	0,82

Çizelge 4.3'te sunulan sonuçlar incelendiğinde, MAPE değerinin test değeri %100'ün çok üzerinde olduğu görülmektedir. Bu da modelin doğruluk oranına sahip olmadığını gösterir. Bu nedenle önyargılı bir ölçü olduğu anlamına gelir. NRMSE, RMSE ve MAE değerlerinin düşük olması verilerle ilgili bir uyum içinde olduğunu gösterir. Ancak bu durum bir çelişki olduğunu göstermektedir. Ayrıca Çoklu Doğrusal Regresyon grafiği incelendiğinde gerçek ve tahmin değerlerinin birbiri ile uyumsuz olduğu görülmektedir. Bunun birçok sebebi olabilir. Sapmaların olduğu yerlerde veri setindeki eşleşen verilerin beklenen oranda olmamasından yani yetersiz olmasından kaynaklandığı ya da iklim koşullarının sert olmasından kaynaklanmış olabileceği düşünülebilir.

Çizelge 4.4. Çoklu doğrusal regresyon grafiği



4.3. Malatya İli Tahmin Sonuçları

Malatya ilinde yapılan saha analizleri sonucunda güneş enerjisi santrallerinde elde edilen veriler, 14.08.2020 tarihinden itibaren üretime başlamış İOTA M. Fırıncı GES e ait elde edilen veriler eşleştirilmiş ve 3487 adet veri elde edilmiştir.



Şekil 4. Malatya İOTA Fırıncı GES


Elde edilen verilerin işlenmesi sonucunda Malatya ili verilerinin makine öğrenmeye göre karşılaştırılması aşağıdaki tabloda gösterilmektedir.

Çizelge 4.5. Malatya iline ait CatBoost algoritması verileri

CatBoost		
Metrikler	Train	Test
NRMSE	%8,74	%9,55
RMSE	7,95	8,42
MAE	5,08	5,35
MAPE	19,28	19,86
R ²	0,96	0,96

Çizelge 4.5'te Malatya ili için sonuçlar incelendiğinde, MAPE değerinin test değeri %20'nin altında olması modelin tahminle ilgili yüksek bir doğruluk oranına sahip olduğunu gösterir. NRMSE, RMSE ve MAE değerlerinin düşük olması verilerle ilgili bir uyum içinde olduğunu gösterir. Bu durumda çoklu doğrusal regresyon grafiği incelendiğinde gerçek ve tahmin değerlerinin birbiri ile uyumlu olduğu görülmektedir. Bu bağlamda, analiz edilen yöntem Malatya ili için doğru sonuçlar vermiştir.

Çizelge 4.6. Çoklu doğrusal regresyon grafiği



4.4. Elazığ İli Tahmin Sonuçları

Elazığ ilinde yapılan saha analizleri sonucunda güneş enerjisi santrallerinde elde edilen veriler, 20.10.2016 tarihinden itibaren üretime başlamış Solentegre GES e ait elde edilen veriler eşleştirilmiş ve 3571 adet veri elde edilmiştir.



Şekil 5. Elazığ Solentegre GES


Elde edilen verilerin işlenmesi sonucunda Elazığ ili verilerinin makine öğrenmeye göre karşılaştırılması aşağıdaki tabloda gösterilmektedir.

Çizelge 4.7. Elazığ iline ait CatBoost algoritması verileri

CatBoost		
Metrikler	Train	Test
NRMSE	%9,45	%10,73
RMSE	6,25	6,77
MAE	4,47	4,92
MAPE	31,52	49,89
R ²	0,90	0,90

Çizelge 4.7'de Elazığ ili için sonuçlar incelendiğinde, MAPE değerinin test değeri $\%20 < \text{MAPE} < \%50$ aralığında olması modelin tahminle ilgili doğruluk oranına sahip olduğunu gösterir. NRMSE, RMSE ve MAE değerlerinin düşük olması verilerle ilgili bir uyum içinde olduğunu gösterir. Ancak çoklu doğrusal regresyon grafiği incelendiğinde gerçek ve tahmin değerlerinin bazı yerlerde uyumsuz olduğu görülmektedir. Sapmaların olduğu yerlerde veri setindeki eşleşen verilerin beklenen oranda olmamasından yani yetersiz olmasından kaynaklandığı söylenebilir.

Çizelge 4.8. Çoklu doğrusal regresyon grafiği



4.5. Van İli Tahmin Sonuçları

Van ilinde yapılan saha analizleri sonucunda güneş enerjisi santrallerinde elde edilen veriler, 30.10.2020 tarihinden itibaren üretime başlamış Gün Güneş Van Arısu GES'e ait, 21.09.2018 tarihinden itibaren üretime başlamış Omicron Engil GES ile Omicron Erciş GES ait elde edilen veriler ve 27.07.2019 tarihinden itibaren üretime başlamış PSİ Engil 207 GES'e ait elde edilen veriler eşleştirilmiş ve 3559 adet veri elde edilmiştir.



Şekil 6. Van Omicron Engil GES


Elde edilen verilerin işlenmesi sonucunda Van ili verilerinin makine öğrenmeye göre karşılaştırılması aşağıdaki tabloda gösterilmektedir.

Çizelge 4.9. Van iline ait CatBoost algoritması verileri

CatBoost		
Metrikler	Train	Test
NRMSE	%12,47	%14,64
RMSE	101,32	117,56
MAE	80,84	96,72
MAPE	137,24	104,63
R ²	0,81	0,81

Çizelge 4.9’da sunulan sonuçlar incelendiğinde, MAPE değerinin test değeri %100’ün çok üzerinde olduğu görülmektedir. Bu da modelin doğruluk oranına sahip olmadığını gösterir. Bu nedenle önyargılı bir ölçü olduğu anlamına gelir. RMSE değeri düşük olması verilerle ilgili bir uyum içinde olduğunu gösterir Ancak bu durum bir çelişki olduğunu göstermektedir. Ayrıca Çoklu Doğrusal Regresyon grafiği incelendiğinde gerçek ve tahmin değerlerinin birbiri ile uyumsuz olduğu görülmektedir. Bunun birçok sebebi olabilir. Sapmaların olduğu yerlerde veri setindeki eşleşen verilerin beklenen oranda olmamasından yani yetersiz olmasından kaynaklandığı ya da iklim koşullarının sert olmasından kaynaklanmış olabileceği düşünülebilir.

Çizelge 4.10. Çoklu doğrusal regresyon grafiği



4.6. Antalya İli Tahmin Sonuçları

Antalya ilinde yapılan saha analizleri sonucunda güneş enerjisi santrallerinde elde edilen veriler, 02.10.2020 tarihinden itibaren üretime başlamış Serra GES e ait elde edilen veriler eşleştirilmiş ve 3215 adet veri elde edilmiştir.



Şekil 7. Antalya Serra GES


Elde edilen verilerin işlenmesi sonucunda Antalya ili verilerinin makine öğrenmeye göre karşılaştırılması aşağıdaki tabloda gösterilmektedir.

Çizelge 4.11. Antalya iline ait CatBoost algoritması verileri

CatBoost		
Metrikler	Train	Test
NRMSE	%9,76	%11,14
RMSE	9,73	10,04
MAE	4,07	4,19
MAPE	17,52	18,24
R ²	0,88	0,88

Çizelge 4.11'de Antalya ili için sonuçlar incelendiğinde, MAPE değerinin test değeri %20'nin altında olması modelin tahminle ilgili yüksek bir doğruluk oranına sahip olduğunu gösterir. NRMSE, RMSE ve MAE değerlerinin düşük olması verilerle ilgili bir uyum içinde olduğunu gösterir. Bu durumda çoklu doğrusal regresyon grafiği incelendiğinde gerçek ve tahmin değerlerinin birbiri ile uyumlu olduğu görülmektedir. Bu bağlamda, analiz edilen yöntem Antalya ili için doğru sonuçlar vermiştir.

Çizelge 4.12. Çoklu doğrusal regresyon grafiği



4.7. Denizli İli Tahmin Sonuçları

Denizli ilinde yapılan saha analizleri sonucunda güneş enerjisi santrallerinde elde edilen veriler, 21.04.2016 tarihinden itibaren üretime başlamış Renoe GES e ait elde edilen veriler eşleştirilmiş ve 3254 adet veri elde edilmiştir.



Şekil 8. Denizli Renoe GES


Elde edilen verilerin işlenmesi sonucunda Denizli ili verilerinin makine öğrenmeye göre karşılaştırılması aşağıdaki tabloda gösterilmektedir.

Çizelge 4.13. Denizli iline ait CatBoost algoritması verileri

CatBoost		
Metrikler	Train	Test
NRMSE	%9,04	%10,32
RMSE	9,01	9,30
MAE	4,12	4,24
MAPE	17,73	18,45
R ²	0,96	0,96

Çizelge 4.13'te Denizli ili için sonuçlar incelendiğinde, MAPE değerinin test değeri %20'nin altında olması modelin tahminle ilgili yüksek bir doğruluk oranına sahip olduğunu gösterir. NRMSE, RMSE ve MAE değerlerinin düşük olması verilerle ilgili bir uyum içinde olduğunu gösterir. Bu durumda çoklu doğrusal regresyon grafiği incelendiğinde gerçek ve tahmin değerlerinin birbiri ile uyumlu olduğu görülmektedir. Bu bağlamda, analiz edilen yöntem Denizli ili için doğru sonuçlar vermiştir.

Çizelge 4.14. Çoklu doğrusal regresyon grafiği



4.8. Muğla İli Tahmin Sonuçları

Muğla ilinde yapılan saha analizleri sonucunda güneş enerjisi santrallerinde elde edilen veriler, 24.03.2017 tarihinden itibaren üretime başlamış Özmen-1 GES e ait elde edilen veriler eşleştirilmiş ve 3110 adet veri elde edilmiştir.



Şekil 9. Muğla Özmen-1 GES


Elde edilen verilerin işlenmesi sonucunda Muğla ili verilerinin makine öğrenmeye göre karşılaştırılması aşağıdaki tabloda gösterilmektedir.

Çizelge 4.15. Muğla iline ait CatBoost algoritması verileri

CatBoost		
Metrikler	Train	Test
NRMSE	%9,73	%11,12
RMSE	9,71	10,02
MAE	4,47	4,60
MAPE	19,26	19,99
R ²	0,90	0,90

Çizelge 4.15'te Muğla ili için sonuçlar incelendiğinde, MAPE değerinin test değeri %20'nin altında olması modelin tahminle ilgili yüksek bir doğruluk oranına sahip olduğunu gösterir. NRMSE, RMSE ve MAE değerlerinin düşük olması verilerle ilgili bir uyum içinde olduğunu gösterir. Bu durumda çoklu doğrusal regresyon grafiği incelendiğinde gerçek ve tahmin değerlerinin birbiri ile uyumlu olduğu görülmektedir. Bu bağlamda, analiz edilen yöntem Muğla ili için doğru sonuçlar vermiştir.

Çizelge 4.16. Çoklu doğrusal regresyon grafiği



5. SONUÇ

Bu çalışmada güneş enerjisinden elektrik üretiminde iklim koşullarının üretim sürecine etkisine odaklanılmıştır. Güneş enerjisinde üretilen elektrik miktarı birçok parametreye bağlı olarak değişmektedir. Çalışma, illerde kurulu olan GES'ler üzerinden yapıldığı için panel özellikleri, arazi şartları, panelin konumu, montaj açısı gibi parametreler ihmal edilmiştir. Bu yüzden sadece iklimsel veriler baz alınarak sahada elde edilen verilerle elektrik üretim miktarının tahminin yapılması için 12 adet makine öğrenmesi algoritması ile test edilmiştir. Bu algoritmalar 6 adet doğrusal olan ve 6 adet doğrusal olmayan algoritmalar. Deneysel çalışmada Mardin ili 12 adet algoritma üzerinden test edilmiştir. Mardin ili için en doğru sonuçlar CatBoost algoritmasından elde edildiği görülmüştür. Bu yüzden diğer iller için CatBoost algoritmasıyla modelleme yapılmış ve bu modeller üzerinden sonuçlar yorumlanmıştır. Mardin ili için modelimizin yüksek oranda doğruluğa sahip olduğu görülmektedir. Antalya, Muğla, Denizli, Malatya ve Elazığ illeri için de modelimiz doğruluk oranına sahiptir ancak Şırnak ve Van illeri için metrik değerleri arasında sapmalar olduğu görülmektedir. Bu sapmalar eşleşen verilerin beklenen oranda yetersiz olmasından kaynaklandığı ya da iklimsel şartların sert olmasından kaynaklandığı düşünülebilir. Güneydoğu Anadolu Bölgesinde Mardin ili güneş enerji santrallerinin kurulumuna daha uygun olduğu, Ege ilinde Denizli ilinin, Akdeniz'de Antalya ilinin ve Doğu Anadolu Bölgesi için de Malatya ilinin uygun olduğu görülmüştür. Elazığ ili de Malatya iline göre yaklaşık değerler göstermiş olup bu iller de güneş enerjisi santrali kurulumuna uygun olduğu görülmektedir. Bu çalışmanın sonucunda elde edilen veriler doğrultusunda tüm iller içerisinde Mardin ilinin %99 tahmin değeri ile en doğru sonucu vermesinde Akdeniz ikliminin etkisi altında olması, güneşlenme süresi ve radyasyon değerinin diğer bölgelere göre daha fazla olması ile güneş ışınlarının daha dik gelmesinin etkili olduğu görülmektedir.

Bu çalışma ile elde edilen sonuçlar ışığında, gelecekte güneş santrallerinin elektrik üretiminde verimliliğin düşüşünü azaltmak amacıyla, düzenli olarak genişletilip güncellenerek modellerin iyileştirilmesine olanak tanındığı takdirde, gelecekteki üretim değerlerini tahmin ederek güneş santrallerinin bakımını zamanında ve düşük maliyetle gerçekleştirmek için bir fırsat sunabilir. İlerleyen yıllarda, tahminleme altyapısı aylık periyodlara kadar indirgenerek, geçmiş yıllarda aynı aylarda karşılaşılan sorunların hızlı bir şekilde tespit edilmesinde kullanılabilir. Bu

alıřma aynı zamanda, gneř enerji santrallerinden elde edilen elektrik verilerinin temel alındığı aylık retim, elektrik dağıtım řirketlerince hedeflenen aylık retimle karřılařtırılması sonucu ortaya ıkabilecek hataları minimize etmek amacıyla aylık retim tahminleriyle nlem alınmasına ynelik bir sistem sunabilir. Gneř enerji santrallerinin standart mrlerinin genellikle 30 yıl civarında olduėu ve gemiře dnk 5 yıllık verilerin en iyi alıřma iin yeterli olduėu dřnldėnde, bu tr alıřmaların GES'ler iin nemli bir rol oynadıėı aıka grlmektedir.



6. KAYNAKLAR

- [1] Sahin, A. D., A Review of Research and Development of Wind Energy in Turkey, Clean-Soil, Air, Water 36, 734-742, 2008.
- [2] Bilgili, M., Sahin, B. ve Yasar, A. Application of Artificial Neural Networks for the Wind Speed Prediction of Target Station Using Reference Stations Data, Renewable Energy, 32, 2350-2360, 2007.
- [3] Ozcan, M. The role of renewables in increasing Turkey's self-sufficiency in electrical energy. Renewable and Sustainable Energy Reviews, 82-3, 2018.
- [4] Mühürücü A. ve Toylan H. (2018). Fotovoltaik Sistemlerde PSO ile Optimize Edilmiş Mirac Algoritması Kullanarak Maksimum Güç Noktası Takibi, IV. Uluslararası Katılımlı Anadolu Enerji Sempozyumu, 18-20 Nisan 2018, Trakya Üniversitesi, Edirne.
- [5] Yılmaz, M. (2012). Türkiye'nin Enerji Potansiyeli ve Yenilenebilir Enerji Kaynaklarının Elektrik Enerjisi Üretimi Açısından Önemi, Ankara Üniversitesi Çevre Bilimleri Dergisi 4(2), 33-54.
- [6] Varınca, K. B., & Gönüllü, M. T. (2006). Türkiye'de güneş enerjisi potansiyeli ve bu potansiyelin kullanım derecesi, yöntemi ve yaygınlığı üzerine bir araştırma. Ulusal güneş ve hidrojen enerjisi kongresi, 21, 23.
- [7] Turhan, S. ve Çetiner, I. (2012). Fotovoltaik Sistemlerde Performans Değerlendirmesi. 6. Ulusal Çatı & Cephe Sempozyumu 12-13 Nisan 2012 Uludağ Üniversitesi Mühendislik Ve Mimarlık Fakültesi - Görükle Kampüsü - Bursa.
- [8] Ramakumar, R., & Bigger, J. E. (1993). Photovoltaic systems. Proceedings of the IEEE, 81(3), 365-377.
- [9] Çelebi, G. (2002). Bina Dışarı Kabuğunda Fotovoltaik Panellerin Kullanım İlkeleri. Gazi Üniversitesi, Mühendislik-Mimarlık Fakültesi Dergisi, 17(3) 17-33.
- [10] Sayın, S. ve Koc, İ. (2011). Güneş Enerjisinden Aktif Olarak Yararlanmada Kullanılan Fotovoltaik (FV) Sistemler Ve Yapılarda Kullanım Biçimleri./ . hac. Eng. Arch. Selçuk Univ , 26(3).
- [11] Sarıtaş, M. (1988). Review paper on Solar Cell Technology, Proceedings of ECA Electronics Technology Workshop, TÜBİTAK, Gebze.

- [12] Goetzberger, A., Luther, J. ve Willeke, G. (2002). “Solar cells: past, present, future”, Solar Energy Materials & Solar Cells, 74, 1-11.
- [13] Goksal, T. (1998). Mimaride Güneş Enerjisi, Anadolu Üniversitesi Yayınları, Eskişehir.
- [14] Oktik, Ş. (2001). Güneş-Elektrik Dönüşümleri Fotovoltaik Güneş Gözeleri ve Güç Sistemleri, Temiz Enerji Vakfı Yayınları, Ankara.
- [15] Kazem, H. A., Chaichan, M. T., Al-Shezawi, I. M., Al-Saidi, H. S., Al-Rubkhi, H. S., Al sinani, K. ve Al-Waeli, A. H. (2012). Effect of Humidity on the FV Performance in Oman. Asian Transactions on Engineering (ATE ISSN: 2221 - 4267) Volume 02 Issue 04.
- [16] Pearsall, N.M. ve Hill, R. (2001). “Photovoltaics modules, System and applications”, Clean Electricity From Photovoltaics, Sydney.
- [17] Sayın, S. ve Koc, İ. (2011). Güneş Enerjisinden Aktif Olarak Yararlanmada Kullanılan Fotovoltaik (FV) Sistemler Ve Yapılarda Kullanım Bicimleri../. h ac. Eng. Arch. Selçuk Univ , 26(3).
- [18] Kantaroğlu, F. (2010). Fotovoltaik Sistemler. Türk Tesisat Mühendisleri derneği. TTMD, Temmuz-Ağustos.
- [19] Aktacir, M. A., Yeşilata, B., ve Işiker, Y. (2008). Fotovoltaik-Rüzgar Hibrid Güç Sistemi Uygulaması, Yeni Enerji. Yenilenebilir Enerji Teknolojileri, 3, 56-62.
- [20] Oluklulu, C. (2001). Güneş Enerjisinden Etkin Olarak Yararlanmada Kullanılan Fotovoltaik Modüller, Boyutlandırılmaları ve Mimaride Kullanım Olanakları Üzerine Bir Araştırma, Yüksek Lisans Tezi, Gazi Üniversitesi, Fen Bilimleri Enstitüsü, Ankara.
- [21] Krishna, K. S., & Kumar, K. S. (2015). A review on hybrid renewable energy systems. Renewable and Sustainable Energy Reviews, 52, 907-916.
- [22] Sağiroğlu, Ş., Yolacan, E. N. ve Yavanoğlu, U. (2011). “Zeki saldırı tespit sistemi tasarımı ve gerçekleştirilmesi”, Gazi Üniv. Müh. Mim. Fak. Dergisi, Ankara, Cilt:26 No:2, 325-340.
- [23] Oztemel, E. (2012). Yapay Sinir Ağları, 3. Baskı, Papatya Yayıncılık, İstanbul.
- [24] Öngöz, S. (2020). Yapay zeka teknolojinin kullanıldığı yeni nesil öğretim

materyalleri. Nabiyev, V. & Erümit, A.K. (Ed.). Eğitimde Yapay Zeka Kuramdan Uygulamaya içinde. Ankara: Pegem Yayıncılık

[25] Pala, F.K. (2020). Makine öğrenmesi ve eğitim sistemine getirdikleri. Nabiyev, V. & Erümit, A.K. (Ed.). Eğitimde Yapay Zeka Kuramdan Uygulamaya içinde. Ankara: Pegem Yayıncılık

[26] Şahin, İ. (2008). Uzman sistem kullanarak 2B’lu izdüşümlerden katı model oluşturma, Doktora Tezi, Fen Bilimleri Enstitüsü, Gazi Üniversitesi, Ankara.

[27] Erçetin, Ö. Z. ve Baykoç, Ö. F. (2004). Tedarikçi seçimi problemine karar teorisi destekli uzman sistem yaklaşımı. Gazi Üniversitesi Mühendislik-Mimarlık Fakültesi Dergisi, 19(3), 276-286.

[28] Ünal, O. ve Uygunoğlu, T. (2005). Seyitömer uçucu külünün betonun basınç dayanımına etkisi üzerine bulanık mantık yaklaşımı. Yapı Teknolojileri Elektronik Dergisi, 1(1), 13-20.

[29] Bolat, B., Erol, K. O., & İmrak, C. E. (2004). Genetic algorithms in engineering applications and the Function of operators. Sigma, 4, 264-271.

[30] Bekleriç, G. (2003). Yapay zekâda zeki etmenler ve uygulamaları. Doktora tezi, Fen Bilimleri Enstitüsü, İstanbul Teknik Üniversitesi, İstanbul.

[31] Yıldırım, M. Z. (2017). Makine Öğrenmesi Yöntemleri ile Network Üzerinde Saldırı Tespiti. Yüksek Lisans Tezi, Karabük Üniversitesi Fen Bilimleri Enstitüsü, Karabük.

[32] Sarac, T. (2004). Yapay Sinir Ağları, Basılmamış Seminer Projesi, Gazi Üniversitesi Endüstri Mühendisliği Bölümü Anabilim Dalı, Ankara.

[33] Quaiyum, S. (2011). Application of Artificial Neural Network in Forecasting Solar Irradiance and Sizing of Photovoltaic Celi for Standalone Systems in Bangladeşli. International Journal Of Computer Applications, Volume 32—No. /d,(0975 - 8887).

[34] Oztemel, E. (2012). Yapay Sinir Ağları, 3. Baskı, Papatya Yayıncılık, İstanbul.

[35] Kalogirou, S.A. (2001). Artificial Neural Networks In Renewable Energy Systems Applications: A Review, Renewable and Sustainable Energy Reviews,5,373-390.

- [36] Haykin, S. (1994). Neural Network, A Comprehensive Foundation, Macmillan College Publishing Company, New York.
- [37] Efe, O. ve Kaynak, O. (2006). Yapay Sinir Ağları ve Uygulamaları, İstanbul Boğazici Üniversitesi Yayınları, Ankara.
- [38] Ergezer, H., Dikmen, M. ve Özdemir, E. (2003). Yapay Sinir Ağları ve Tanıma Sistemleri, Pivotka, 2, 6, 14-17.
- [39] Temür, G. (2013). Yapay sinir ağlarının Otomatik Olarak FPGA Çipine Uygulanması İçin Denetleyici Tasarım Aracı, Yüksek Lisans Tezi, Düzce Üniversitesi, Fen Bilimleri Enstitüsü, Düzce.
- [40] Yiğit, P. (2011). Yapay Sinir Ağları ve Kredi Taleplerinin Değerlendirilmesi Üzerine Bir Uygulama, Yüksek Lisans Tezi, İstanbul Üniversitesi, Sosyal Bilimleri Enstitüsü, İstanbul.
- [41] Bahadır, İ. (2008). Bayes Teoremi ve Yapay Sinir Ağları Modelleriyle Borsa Gelecek Değer Tahmini Uygulaması, Yüksek Lisans Tezi, TOBB Ekonomi Ve Teknoloji Üniversitesi, Fen Bilimleri Enstitüsü, Ankara.
- [42] Güç, R. (2016). Bilecik İli İçin Güneş Enerjisi Analizi ve Yapay Sinir Ağları İle Hava Sıcaklığı Tahmini, Yüksek Lisans Tezi, Bilecik Şeyh Edebali Üniversitesi, Fen Bilimleri Enstitüsü, Bilecik.
- [43] Ozveren, U. (2006). Pem Yakıt Hücrelerin in Yapay Sinir Ağları İle Modellenmesi, Yüksek Lisans Tezi, Yıldız Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- [44] Ziane, A., Necaibia, A., Sahouane, N., Dabou, R., Mostefaoui, M., Bouraiou, A., Khelifi, S., Rouabhia, A., Blal, M. (2021). Photovoltaic output power performance assessment and forecasting: Impact of meteorological variables. Solar Energy, 220, 745-757. doi:10.1016/j.solener.2021.04.004
- [45] Zhu, H. L., Li, X., Sun, Q., Nie, L., Yao, J. X., Zhao, G. (2016). A Power Prediction Method for Photovoltaic Power Plant Based on Wavelet Decomposition and Artificial Neural Networks. Energies, 9(1). doi:10.3390/en9010011
- [46] Dandıl, E., Gürgen, E. (2019). Yapay Sinir Ağları Kullanılarak Fotovoltaik Panel Güç Çıktılarının Tahmini ve Sezgisel Algoritmalar ile Karşılaştırılması. Avrupa Bilim ve Teknoloji Dergisi, 16, 146-158.

- [47] Sağaltıcı, D., Alay, F., D., Efil, C., İlhan, N. (2018). Veri Madenciliği Yöntemleri İle Meteorolojik Verilerden Kayıp Güneş Işınım Değerlerinin Tahmini. Harran Üniversitesi Mühendislik Dergisi, 2, 49-53.
- [48] Li, J., Ward, J., Tong, J., Collins, L., ve Platt, G. (2016). Machine learning for solar irradiance forecasting of photovoltaic system. Renewable Energy, 90, 542-553.
- [49] Leva, S., Dolara, A., Grimaccia, F., Mussetta, M., Ogliari, E. (2017). Analysis and validation of 24 hours ahead neural network forecasting of photovoltaic output power. Mathematics and Computers in Simulation, 131, 88-100. doi:10.1016/j.matcom.2015.05.010
- [50] Coşkun, A. (2007). Yapay zeka optimizasyon teknikleri: literatür değerlendirmesi. Doğu Anadolu Bölgesi Araştırmaları, 27, 142-146.
- [51] Wu, Y. K., Lai, Y. H., Huang, C. L., Phuong, N. T. B., & Tan, W. S. (2022). Artificial Intelligence Applications in estimating invisible solar power generation. Energies, 15(4), 1312.
- [52] Kumar, K. R., & Kalavathi, M. S. (2018). Artificial intelligence based forecast models for predicting solar power generation. Materials today: proceedings, 5(1), 796-802.
- [53] Alzain, E., Al-Otaibi, S., Aldhyani, T. H., Alshebami, A. S., Almaiah, M. A., & Jadhav, M. E. (2023). Revolutionizing solar power production with artificial intelligence: a sustainable predictive model. Sustainability, 15(10), 7999.
- [54] Quang, N., Duy, L., Van, B., & Dinh, Q. (2021). Applying Artificial Intelligence in Forecasting the Output of Industrial Solar Power Plant in Vietnam. EAI Endorsed Transactions on Energy Web, 8(36).
- [55] Shams, M. H., Niaz, H., Hashemi, B., Liu, J. J., Siano, P., & Anvari- oghaddam, A. (2021). Artificial intelligence-based prediction and analysis of the oversupply of wind and solar energy in power systems. Energy conversion and Management, 250, 114892.
- [56] Ghadami, N., Gheibi, M., Kian, Z., Faramarz, M. G., Naghedi, R., Eftekhari, M., ... & Tian, G. (2021). Implementation of solar energy in smart cities using an integration of artificial neural network, photovoltaic system and classical Delphi methods. Sustainable Cities and Society, 74, 103149.

- [57] Mandal, P., Madhira, S. T. S., Meng, J., & Pineda, R. L. (2012). Forecasting power output of solar photovoltaic system using wavelet transform and artificial intelligence techniques. *Procedia Computer Science*, 12, 332-337.
- [58] Donat, W., 2015, What is Python: An Intro to a Cross-Platform Programming Language, <https://www.atlantic.net/vps-hosting/what-is-python-intro-crossplatform-programming-language/>: [16.05.2020].
- [59] Ding, J., Tarokh, V., & Yang, Y. (2018). Model selection techniques: An overview. *IEEE Signal Processing Magazine*, 35(6), 16-34.
- [60] Brownlee J., 2019, <https://machinelearningmastery.com/a-gentle-introduction-to-model-selection-for-machine-learning/>
- [61] Ouyang, F. S., Guo, B. L., Ouyang, L. Z., Liu, Z. W., Lin, S. J., Meng, W., ... & Yang, S. M. (2019). Comparison between linear and nonlinear machine-learning algorithms for the classification of thyroid nodules. *European journal of radiology*, 113, 251-257.
- [62] Eberly, L. E. (2007). Multiple linear regression. *Topics in Biostatistics*, 165-187.
- [63] Kurnaz, F. S., 2020. Temel Bileşenlere Dayalı Bazı Regresyon Yöntemleri. *Gümüşhane Üniversitesi Fen Bilimleri Dergisi*, 10(3), 581-591.
- [64] Wold, H. (1966). Estimation of principal components and related models by iterative least squares. In P.R. Krishnaiah (Ed.). *Multivariate Analysis*. (pp.391-420) New York: Academic Press.
- [65] Garthwaite, P. H. (1994). An interpretation of partial least squares. *Journal of the American Statistical Association*, 89(425), 122-127.
- [66] El-Dereny, M., N. Rashwan, Solving multicollinearity problem using ridge regression models, *Int. J. Contemp. Math. Sci.* 6 (2011) 585–600.
- [67] Fitrianto, A., L.C. Yik, Performance of Ridge Regression Estimator Methods on small sample size by varying correlation coefficients: a simulation study, *J. Math. Stat.* 10 (2014) 25, <https://doi.org/10.3844/jmssp.2014.25.29>.
- [68] Fidanoğlu, I., & Akdeniz, F. İstatistiksel Daraltıcı (Shrinkage) Model Ve Uygulamaları.
- [69] Tibshirani, R. J. (1996). Regression shrinkage and selection via the LASSO. *Journal of the Royal Statistical Society B*, 58, 267-288.

- [70] Hans, C. (2011). Elastic net regression modeling with the orthant normal prior. *Journal of the American Statistical Association*, 106(496), 1383-1393.
- [71] Zou, H., & Hastie, T. (2003). Regression shrinkage and selection via the elastic net, with applications to microarrays. *JR Stat Soc Ser B*, 67, 301-20.
- [72] Kuhn, M., & Johnson, K. (2013). *Applied predictive modeling* (Vol. 26, p. 13). New York: Springer.
- [73] Altman NS. An introduction to Kernel and nearest-neighbor nonparametric regression. *Am Stat* 1992; 46: 175–185.
- [74] Seçkin, M., Seçkin, A. Ç., & Coşkun, A. (2019). Production fault simulation and forecasting from time series data with machine learning in glove textile industry. *Journal of Engineered Fibers and Fabrics*, 14, 1558925019883462.
- [75] Hornik, K. (1991). Approximation capabilities of multilayer feedforward networks. *Neural networks*, 4(2), 251-257.
- [76] Bento, C., 2021. <https://towardsdatascience.com/multilayer-perceptron-explained-with-a-real-life-example-and-python-code-sentiment-analysis-cb408ee93141>
- [77] Quinlan JR. Induction of decision trees. *Mach Learn* 1986; 1: 81–106.
- [78] Breiman, L., Friedman, J. H., Olshen, R. A., & Stone, C. J. (2017). *Classification and regression trees*. Routledge.
- [79] Quinlan JR. Simplifying decision trees. *Int J Man Mach Stud* 1987; 27: 221–234.
- [80] Lingitz, L., Gallina, V., Ansari, F., Gyulai, D., Pfeiffer, A., Sihn, W., & Monostori, L. (2018). Lead time prediction using machine learning algorithms: A case study by a semiconductor manufacturer. *Procedia Cirp*, 72, 1051-1056.
- [81] James, G., Witten, D., Hastie, T., and Tibshirani, R. (2013). *An introduction to statistical learning*, volume 112. Springer
- [82] Bishop, C. M., *Pattern Recognition and Machine Learning* (Information Science and Statistics). Berlin, Heidelberg: Springer-Verlag, 2006
- [83] LightGBM documentation, 2022, (<https://lightgbm.readthedocs.io/en/v3.3.2/>).
- [84] Machado, M. R., Karray, S., & de Sousa, I. T. (2019, August). LightGBM: An effective decision tree gradient boosting method to predict customer loyalty in the finance industry. In *2019 14th International Conference on Computer Science &*

Education (ICCSE) (pp. 1111-1116). IEEE.

[85] Muratlar, E.R., 2020, <https://www.veribilimiokulu.com/lightgbm/>

[86] Ke, G., Meng, Q., Finley, T., Wang, T., Chen, W., Ma, W., ... & Liu, T. Y. (2017). Lightgbm: A highly efficient gradient boosting decision tree. Advances in neural information processing systems, 30.

[87] Jabeur, S. B., Gharib, C., Mefteh-Wali, S., & Arfi, W. B. (2021). CatBoost model and artificial intelligence techniques for corporate failure prediction. Technological Forecasting and Social Change, 166, 120658.

[88] Dorogush, A.V., A. Gulin, G. Gusev, L. Ostroumova Prokhorenkova, and A. Vorobev. Catboost: unbiased boosting with categorical features. arXiv preprint arXiv:1706.09516, 2017.

[89] Dorogush, A.V., Ershov, V., Gulin, A., 2018. CatBoost: gradient boosting with categorical features. 1–7.

[90] CatBoost documantation, 2022 <https://catboost.ai/>

[91] Ghofrani, M. ve Alolayan, M., 2018, Time series and renewable energy forecasting, Time series analysis and applications, 77-92.

[92] anonymous, 2017, MSE, RMSE, MAE, MAPE ve Diğer Metrikler, <https://veribilimcisi.com/2017/07/14/mse-rmse-mae-mape-metrikleri-nedir/>:

[07.03.2020].

Url1. <https://enerji.gov.tr/bilgi-merkezi-enerji-gunes#:~:text=%C3%9C%20co%C4%9Fraf%C4%B1%C5%9Ft%C4%B1r.>

Url2. <https://www.sunmax.com.tr/index.php?t=s&i=14#:~:text=Akdeniz%20B%C3%B6lgesinde%202956%20saat%2CEge,B%C3%B6lgesinde%201971%20saat%20olarak%20saptanm%C4%B1%C5%9Ft%C4%B1r.>

Url 3. <https://enerji.gov.tr/bilgi-merkezi-enerji-gunes>

Url 4. <https://gepa.enerji.gov.tr/MyCalculator/>

Url 5. <https://enerji.gov.tr/eigm-yenilenebilir-enerji-kaynaklar-gunes>

Url 6. <https://gepa.enerji.gov.tr/MyCalculator/>

Url 7. <https://www.bagimsizenerji.com/%C5%9Febekedenbagimsiz.html>

Url 8. <https://enerjiye.com/sebeke-baglantili-on-grid-gunes-enerji-sistemleri/>

Url 9. <https://www.powerenerji.com/hibrid-enerji-sistemleri-maliyeti-kurulumu-ruzgar-gunes-enerjisi-fiyaatlari.html>

