



T. C.

SİVAS CUMHURİYET ÜNİVERSİTESİ

FEN BİLİMLERİ ENSTİTÜSÜ

**YAPAY SİNİR AĞLARIYLA TÜRKİYE'DEKİ YENİLENEBİLİR
ENERJİ POTANSİYELİNE BAĞLI OLARAK UZUN SÜRELİ
ELEKTRİK ÜRETİM TAHMİNİ**

YÜKSEK LİSANS TEZİ

**Merve GÜLER
(20199240005)**

**Enerji Bilimi ve Teknolojisi Mühendisliği Ana Bilim Dalı
Tez Danışmanı: Dr. Öğr. Üyesi Derya Betül ÜNSAL ÇELİMLİ**

**SİVAS
OCAK 2023**

Merve GÜLER'in hazırladığı ve “**YAPAY SİNİR AĞLARIYLA TÜRKİYE’DEKİ YENİLENEBİLİR ENERJİ POTANSİYELİNE BAĞLI OLARAK UZUN SÜRELİ ELEKTRİK ÜRETİM TAHMİNİ**” adlı bu çalışma aşağıdaki jüri tarafından **ENERJİ BİLİMİ VE TEKNOLOJİSİ MÜHENDİSLİĞİ ANA BİLİM DALI**’nda **YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

Tez Danışmanı	Dr. Öğr. Üyesi Derya Betül ÜNSAL ÇELİMLİ Sivas Cumhuriyet Üniversitesi	
Jüri Üyesi	Dr. Öğr. Üyesi Zeynep HASIRCI TUĞCU Karadeniz Teknik Üniversitesi	
Jüri Üyesi	Dr. Öğr. Üyesi Yağmur ARIKAN YILDIZ Sivas Cumhuriyet Üniversitesi	

Bu tez, Sivas Cumhuriyet Üniversitesi Fen Bilimleri Enstitüsü tarafından **YÜKSEK LİSANS TEZİ** olarak onaylanmıştır.

Prof. Dr. Nevcihan GÜRSOY
FEN BİLİMLERİ ENSTİTÜSÜ MÜDÜRÜ

Bu tez, Sivas Cumhuriyet Üniversitesi Senatosu'nun 20.08.2014 tarihli ve 7 sayılı kararı ile kabul edilen Fen Bilimleri Enstitüsü Lisansüstü Tez Yazım Kılavuzu (Yönerge)'nda belirtilen kurallara uygun olarak hazırlanmıştır.





Bütün hakları saklıdır.
Kaynak göstermek koşuluyla alıntı ve gönderme yapılabilir.

© Merve GÜLER, 2023

Çalışma sırasında bana destek olan aileme ve tüm arkadaşlarıma...

ETİK

Sivas Cumhuriyet Üniversitesi Fen Bilimleri Enstitüsü, Tez Yazım Kılavuzu

(Yönerge)'nda belirtilen kurallara uygun olarak hazırladığım bu tez çalışmada;

- ✓ Bütün bilgi ve belgeleri akademik kurallar çerçevesinde elde ettiğimi,
- ✓ Görsel, işitsel ve yazılı tüm bilgi ve sonuçları bilimsel ahlak kurallarına uygun olarak sunduğumu,
- ✓ Başkalarının eserlerinden yararlanılması durumunda ilgili eserlere, bilimsel normlara uygun olarak atıfta bulunduğumu ve atıfta bulunduğum eserlerin tümünü kaynak olarak gösterdiğimi,
- ✓ Bütün bilgilerin doğru ve tam olduğunu, kullanılan verilerde herhangi bir değişiklik yapmadığımı,
- ✓ Tezin herhangi bir bölümünü, Sivas Cumhuriyet Üniversitesi veya bir başka üniversitede, bir başka tez çalışması olarak sunmadığımı; beyan ederim.

13.04.2023

Merve GÜLER

KATKI BELİRTME VE TEŞEKKÜR

Bilgi ve deneyimlerinden sürekli yararlandığım, tezin her aşamasında yardımlarını esirgemeyen danışman hocam Dr. Öğr. Üyesi Derya Betül ÜNSAL ÇELİMLİ 'ye, her türlü desteğiyle yanımda olan hocam Dr. Öğr. Üyesi Mustafa ŞEKER'e, tezime olan katkılarından ötürü Dr. Öğr. Üyesi Zinnur YILMAZ hocama ve en büyük şansım olan aileme çok teşekkür ederim.



ÖZET

YAPAY SİNİR AĞLARIYLA TÜRKİYE’DEKİ YENİLENEBİLİR ENERJİ POTANSİYELİNE BAĞLI OLARAK UZUN SÜRELİ ELEKTRİK ÜRETİM TAHMİNİ

Merve GÜLER

Yüksek Lisans Tezi

**Enerji Bilimi ve Teknolojisi Mühendisliği Anabilim Dalı
Danışman: Dr. Öğr. Üyesi Derya Betül ÜNSAL ÇELİMLİ**

2023, 65 + xvii sayfa

Günümüze kadar, Dünya üzerinde enerji üretiminde en çok kullanılan kaynak fosil yakıtlar olmuştur. Son yıllarda ise fosil yakıtların tükenmesi ve çevre kirliliği etkilerinden ötürü yenilenebilir enerji kaynakları gündeme alınmış ve yeni enerji kaynakları arama yoluna gidilmiştir. Bu süreçte çeşitli yenilenebilir enerji kaynakları geliştirilerek iyi sonuçlar alınmış olup hala da geliştirilmeye devam edilmektedir. Türkiye’de ise kömür ve doğalgaz kaynaklı enerji üretiminde son yıllarda düşüş gözlenirken, yenilenebilir enerji kaynaklarından enerji üretimi oldukça artmıştır. Ancak üretilen enerjinin depolanamamasında dolayı arz ve talep miktarı dengesizliklere sebep olmaktadır, bu durumun aşılabilmesi için ise enerji üretim ve tüketim tahmininin yapılması hem ülke ekonomisi hem de rezerv sıkıntılarının önüne geçilmesi için çok büyük önem arz etmektedir. Bu problemlerin önüne geçilebilmesi için ise tahmin modellerine dayanan birçok yöntem geliştirilmeye devam edilmektedir.

Bu çalışmada yapay sinir ağlarıyla Türkiye’nin enerji potansiyeli temel alınmış, hava durumu verileri ile birlikte güneş enerji sistemlerinin enerji üretim potansiyeli hesaplanarak gerçek zamanlı sonuçlarına ANN (Yapay Sinir Ağları) ve LSTM (Uzun Kısa Vadeli Bellek), CNN (Evrişimli Sinir Ağları) ve Hibrit CNN+LSTM mimarilerinden faydalanılarak ulaşılmıştır. Sonuçların farklı modeller ile kıyaslanarak performans iyileştirmeleri için çözüm önerileri oluşturulması hedeflenmiştir. Türkiye geneli için ulaşılan resmi verilerin ortalama değerlerden oluşması sebebiyle bölgesel yaklaşım ele alınmış ve mevsim normallerine bağlı hava durumu verilerinin yakın değerlerde olduğu bölgeler için genel sonuçlara ulaşılmıştır. Alınan sonuçlar neticesinde ulaşılan hata

oranını azaltabilmek için etkili sonuçları bulunan makine öğrenmesi tekniklerinden de faydalanılmıştır. Derin öğrenme modelleri ile birlikte makine öğrenme modelleri olan LightGBM, GBR ve RF yöntemleri ile kıyaslamalar yapılmıştır. Karşılaştırma modelleri sonuçlarına göre tahmin doğruluğunu iyileştirmede makine öğrenme modeli olan LightGBM'in en iyi sonuç verdiği gözlenmiş olup en yüksek hata oranı ise hibrit model olan CNN+LSTM modelinde gözlemlenmiştir.

Anahtar kelimeler: Yapay sinir ağları (ANN), Uzun kısa vadeli bellek (LSTM), Convolutional Neural Network(CNN), Light Gradient Boosting Machine(LightGBM), Gradient Boosting Regressor (GBR), Random Forest Regressor (RF)



ABSTRACT

ESTIMATION ON LONG-TERM ELECTRICITY GENERATION DEPENDING ON RENEWABLE ENERGY POTENTIAL IN TURKEY WITH ARTIFICIAL NEURAL NETWORKS

Merve GÜLER

Master of Science Thesis

Department of Energy Science and Technology Engineering

Supervisor: Assist. Prof. Derya Betül ÜNSAL ÇELİMLİ

2023, 65 + xvii pages

To date, fossil fuels have been the most widely used source of energy in the world. In recent years, due to the depletion of fossil fuels and the effects of environmental pollution, renewable energy sources have been put on the agenda and new energy sources have been sought. In this process, various renewable energy sources have been developed and good results have been obtained and they are still being developed. In Turkey, on the other hand, while a decrease has been observed in energy production from coal and natural gas in recent years, energy production from renewable energy sources has increased considerably. However, due to the inability to store the produced energy, the amount of supply and demand causes imbalances, and in order to overcome this situation, estimating energy production and consumption has great importance both for the country's economy and for preventing reserve problems. In order to prevent these problems, many methods based on prediction models continue to be developed.

In this study, Turkey's energy potential is based on artificial neural networks, the energy production potential of solar energy systems is calculated together with weather data, and the real-time results are obtained by ANN (Artificial Neural Networks) and LSTM (Long Short Term Memory), CNN (Convolutional Neural Network) and it was achieved by using hybrid CNN+LSTM architectures. It is aimed to create solutions for performance improvements by comparing the results with different models. Due to the fact that the official data obtained for the whole of Turkey consists of average values, the regional approach has been handled and general results have been reached for the regions where the weather data depending on the seasonal normals are close to the values. In order to

reduce the error rate achieved as a result of the outcomes obtained, machine learning techniques with effective results were also used. Comparisons were made with deep learning models, as well as machine learning models LightGBM, GBR and RF methods. According to the results of the comparison models, it was observed that the machine learning model LightGBM gave the best results in improving the prediction accuracy, and the highest error rate was observed in the hybrid model, the CNN+LSTM model.

Key Words: Artificial neural networks (ANN), Long short-term memory (LSTM), Convolutional Neural Network(CNN), Light Gradient Boosting Machinen(LighGBM), Gradient Boosting Regressor (GBR), Random Forest Regressor (RF)



İÇİNDEKİLER

Sayfa

ETİK	vi
KATKI BELİRTME VE TEŞEKKÜR.....	vii
ÖZET	viii
ABSTRACT.....	x
ŞEKİLLER DİZİNİ.....	xiv
ÇİZELGELER LİSTESİ	xv
SİMGELER DİZİNİ.....	xvi
KISALTMALAR DİZİNİ	xvii
1. GİRİŞ	1
1.1 Literatür Araştırması	1
2. GÜNEŞ ENERJİSİ	7
2.1 Güneş ve Enerji	7
2.2 Güneş Enerjisinin Tarihsel Gelişimi	9
2.3 Güneş Enerji Potansiyeli	11
2.3.1 Dünyada Güneş enerjisinin potansiyeli.....	11
2.3.2 Türkiye’de Güneş Enerjisinin Potansiyeli	14
2.4 Güneş Enerjisi ve Çalışma Prensibi	16
2.4.1 PV hücrelerin çalışma ilkesi	17
2.4.2 PV Hücrelerin Güç Sistemleri Analizi ve Matematiksel Modellemesi	20
2.4.3 PV Panellerin Bağlantı Türleri.....	23
2.4.3.1 Panellerin Seri Bağlanması.....	23
2.4.3.2 Panellerin Paralel Bağlanması	23
2.4.3.3 Panellerin Seri ve Paralel Bağlanması	24
2.4.4 PV Panel Çeşitleri ve Özellikleri	24
2.4.4.1 Kristal Silikon Hücreler	25
2.4.4.2 İnce film hücreler	26
2.5 Güneş Enerji Sistemlerinin Şebekeye Bağlanması.....	28
2.5.1 Şebekeden Bağımsız (Off-Grid) Sistemler.....	28
2.5.2 Şebekeye Bağlı (On Grid) Sistemler.....	28
2.6 Sivas İli Güneş Enerjisi Potansiyeli	30
3. MATERYAL VE METOT	32
3.1 Makine öğrenmesi	32
3.1.1 Makine Öğrenmesi Nedir?	32
3.1.2 Makine Öğrenim Teknikleri.....	32
3.1.3 Sınıflandırma ve Regresyon.....	33
3.2 Derin Öğrenme	34
3.2.1 Derin Öğrenme Türleri.....	35
3.2.1.1 LSTM (Uzun Kısa Süreli Bellek)	35
3.2.1.2 ANN (Yapay Sinir Ağları).....	37
3.3 MAPE (Ortalama Mutlak Yüzde Hata)	42
3.4 RMSE (Kök Ortalama Kare Hata)	42
3.5 Derin Öğrenme ile Güneş Enerji Tahmini.....	43
4. VERİ ANALİZİ VE YÖNTEMLERİN UYGULANMASI.....	45
4.2 Tahmin Modelinin Oluşturulması ve Kıyaslanması.....	47

4.2.1 Makine Öğrenmesi Modelleri Kullanarak Tahmin Modelinin Oluşturulması.....	48
4.2.2 Derin öğrenme modelleri kullanarak üretilen tahminlerin değerlendirilmesi.....	49
4.2.2.1 ANN Modelinin İncelenmesi.....	49
4.2.2.2 LSTM Modelinin İncelenmesi.....	50
4.2.2.3 CNN Modelinin İncelenmesi.....	51
4.2.2.4 CNN +LSTM Hibrit Modelin İncelenmesi.....	51
5. SONUÇ.....	53
KAYNAKLAR.....	58



ŞEKİLLER DİZİNİ

Sayfa

Şekil 2.1	Güneşin katmanları	7
Şekil 2.2	Lavoisier'ın tasarladığı güneş ışığını toplayan bir cihaz	10
Şekil 2.3	Mouchot'un parabolik güneş kolektörü	10
Şekil 2.4	Dünya ısı radyasyon haritası	12
Şekil 2.5	2019'dan 2020'ye güneş enerjisi kapasite ilavesi değişiklikleri	13
Şekil 2.6	Net PV kapasite ilaveleri, 2019-2022	14
Şekil 2.7	Yıllık güneş PV kapasiteleri	14
Şekil 2.8	Türkiye güneş enerjisi potansiyel atlası	15
Şekil 2.9	Bazı güneş enerji sistemleri	17
Şekil 2.10	PV Sistemini oluşturan elemanlar	18
Şekil 2.11	Güneş pilinin çalışması	18
Şekil 2.12	P-N birleşimli iyot	19
Şekil 2.13	PV eşdeğer devresi	20
Şekil 2.14	PV Modül ve bağlanma şekilleri	24
Şekil 2.15	Hücre tipleri	25
Şekil 2.16	Monokristal hücre	26
Şekil 2.17	Polikristal hücreler	26
Şekil 2.18	İnce film güneş panel örnekleri	27
Şekil 2.19	Şebekeden bağımsız sistem	28
Şekil 2.20	Şebekeye bağımlı sistem	29
Şekil 2.21	Sivas ili güneş enerji potansiyel atlası	30
Şekil 2.22	Sivas ili güneşlenme süresi	31
Şekil 2.23	Işıma süreleri Sivas ili ısıma miktarı	31
Şekil 3.1	Makine öğrenim teknikleri	33
Şekil 3.2	Regresyon ve Sınıflandırma	34
Şekil 3.3	a) Tek katmanlı bir ağ b) Çok katmanlı bir ağ	35
Şekil 3.4	LSTM Mimarisi	35
Şekil 3.5	Örnek nöron ve ANN hücresi	38
Şekil 3.6	RMSE ve MAPE değerleri	44
Şekil 3.7	Tahmin sapma miktarı	44
Şekil 4.1	Ön işlem öncesi veriler	46
Şekil 4.2	Ön işlem sonrası veriler	46
Şekil 4.3	Korallasyon test sonuçları	47
Şekil 4.4	Makine öğrenme modeli için oluşturulan kod görüntüsü	49
Şekil 4.5	ANN modeli için kullanılan kodlar	50
Şekil 4.6	LSTM modeli için kullanılan kodlar	50
Şekil 4.7	CNN modeli için kullanılan kodlar	51
Şekil 4.8	LSTM- CNN modeli için kullanılan kodlar	52
Şekil 5.1	MAE ve RMSE analizine göre eğitim-doğrulama grafiği	54
Şekil 5.2	MAE ve RMSE eğitim- doğrulama grafikleri	55
Şekil 5.3	MAE ve RMSE eğitim-doğrulama grafikleri	55
Şekil 5.4	MAE ve RMSE eğitim-doğrulama grafikleri	55
Şekil 5.5	Modellerin grafiksel olarak karşılaştırılması	56
Şekil 5.6	Modellerin grafiksel olarak karşılaştırılması	56

ÇİZELGELER LİSTESİ

	<u>Sayfa</u>
Çizelge 2.1 Güneş radyasyon miktarı	11
Çizelge 2.2 Türkiye'nin aylık ortalama güneş enerjisi potansiyeli.....	15
Çizelge 2.3 Türkiye'nin yıllık toplam güneş enerjisi potansiyelinin bölgelere göre dağılımı	16
Çizelge 2.4 Güneş pilleri hücre verimlilikleri.....	27
Çizelge 5.1 Modellerin hata oranları.....	54
Çizelge 5.2 Modellerin kıyaslanması	55



SİMGELER DİZİNİ

$^{\circ}\text{C}$	Celcius sıcaklık birimi
I_0	Diyotun ters doyma akımı
k	Boltzmann sabiti
q	Elektron yükü
k	Boltzmann sabiti
q	Elektron yükü
I_0	Diyotun ters doyma akımını göstermektedir
T_{nom}	hücre sıcaklığı
N_s	panelde kullanılan seri hücre sayısını
N_p	panelde kullanılan paralel hücre sayısını ifade eder.
r_T	iç direnci,
r_1	birinci panelin iç direncini,

KISALTMALAR DİZİNİ

ANN	: Artificial Neural Network- Yapay Sinir Ağları
LightGBM	: Light Gradient Boosting Machine
CIS	: Bakır İndiyum-Diselenid
CNN	: Convolutional Neural Network -Evrişimli Sinir Ağları
CSP	: Konsantre Güneş Enerji Sistemleri
EPİAŞ	: Enerji Piyasaları İşletme A.Ş.
GBR	: Gradient Boosting Regressor)
IEA	: Uluslararası Enerji Ajansı
KNN – K	: Nearest Neighbors - K (Komşuluk Sayısı)
LSTM	: Long Short Term Memory- Uzun Kısa Süreli Bellek
MAE	: Mean Absolute Error- Ortalama mutlak hata
MAPE	: Ortalama Mutlak Yüzde Hata
PV	: Fotovoltaik Hücreler
RE	: Enerji Politikası Ağı
RF	: Random Forest Regressor
RMSE	: Kök Ortalama Kare Hata
RNN	: Reccurent Neural Network- Yinelemeli Sinir Ağı
YEK	: Yenilenebilir Enerji Kaynakları

1. GİRİŞ

Günümüzde elektrik üretiminde en çok fosil yakıt kaynaklarından enerji üretilmektedir. Sıkça kullanılan fosil yakıtlar; petrol, kömür, doğalgaz olup çevreye ciddi anlamda zarar veren ve tükenmesi beklenen kaynaklardır. Gerek salınan karbon sorunu gerek rezerv sıkıntısı yenilenebilir enerji kaynaklarının kullanımını artırmıştır. Birçok devlet elektrik üretiminin yenilenebilir enerji kaynaklarından destek alarak fosil yakıtlardan ürettikleri enerji miktarını en az seviyeye ulaştırmak için uğraşmaktadır. Türkiye, yenilenebilir enerji kaynaklarının potansiyeli bakımından oldukça zengin bir ülke olmakla birlikte, ülkemizde de yenilenebilir enerji kaynakları (YEK) için birçok destek verilmektedir. Bu yüzden bilhassa yenilebilir enerji kaynaklarından biri olan, güneş enerjisi de fosil yakıt tüketimini azaltmakta büyük rol oynayan ve rüzgâr enerjisinden sonra en çok kullanılan enerji kaynaklarından birisidir.

Ülkemizde kurulmuş olan birçok güneş enerji santrali; lisanslı, lisanssız olmasına bakılmaksızın, kamu kuruluşu ve özel firmaların desteği ile şebekeye enerji satmaları mümkün kılınmış olup, aynı zamanda kendi elektriklerini üretmelerine de izin verilmiştir. Saat saat değişen elektrik piyasasında yüzlerce güneş santrali piyasada sapmalara sebep olmakla beraber kullanıcının da değişen güç üretimi doğrultusunda zarar etmesine sebep olabilmektedir. Elektrik piyasasındaki bu sapmalar ciddi anlamda kar/zarar miktarını etkilemektedir. Dolayısıyla elektrik piyasa işlemlerinin ileri tarihli üretim tahminlerinin gerçeğe en yakın olması çok büyük önem taşımaktadır.

1.1 Literatür Araştırması

Ilianna Kolia ve arkadaşları Yunanistan'ın kısa vadeli yük tahminlerini değerlendirmek ve tahmin sonucunda oluşan sapmaların tahmini için bir yöntem geliştirmişlerdir. Bu yaklaşım gelecek yükü tahmin edip mevcut ve geçmiş tahminleri, gerçek yük değerleri ile kıyaslayıp yeterli tahmin edip etmediğini değerlendirmiş ve bu değerlendirmenin de tahminini yapmayı hedeflemişlerdir. Bu yöntem için ilk olarak Long Short

Term Memory (LSTM) ile zaman serilerini analiz etmiş ve günlük ve saatlik tahmin üretebilen Convolutional Neural Network (CNN) ve Recurrent Neural Network (RNN) den faydalanmışlardır [1].

Pengpeng Yang ve arkadaşları, mevcut tahmin teknolojisinin, rüzgar gücünün tahmin sonuçları doğrudan uygulandığında büyük hatalar ortaya çıkabileceğini, bundan dolayı,

rüzgar enerjisi tahmin hatası istatistiklerine dayanarak olasılık dağılım modeli geliştirmeyi önermişlerdir. Önerilen yöntemde, farklı kuşakların olasılıksal dağılımları ile Gauss fonksiyonu kullanılmıştır. Çalışmada ekonomik gönderim (ED) ve Birim taahhüdü(UC)' deki Lagrangian çarpanlarının fonksiyonları analiz edilip basitleştirilip yeni bir yöntem sunmuşlardır. Deney sonucunda geliştirdikleri modelin rüzgar enerjisi dahil büyük ölçekli sistemlere uyarlanabilirliği de dikkate değer bir şekilde artırılabilirliğini savunmuşlardır [2].

Runhai Jiao ve arkadaşları, yoğun otomatik kodlayıcılarla (SAE) geri yayılım algoritmasını (BP) birleştirilerek, rüzgâr enerjisi tahmini için çok katmanlı bir derin sinir ağı oluşturulmuşlardır. Tahmin modeli olarak kısa vadeli, basit ve doğrusal olduğu için otoregressif yöntem kullanılmış olup güçlü bir makine öğrenme aracı olan destek vektör makineleri (SVM) tatmin edecek seviyede kullanılmıştır. Önerilen yöntem, eğitim öncesi süreç ve ince ayar süreci olmak üzere iki aşamadan oluşmuştur. Ön eğitimde görünür katman, gizli katman ve çıktı katmanını içeren üç istiflenmiş otomatik kodlayıcı (AE)' den oluşur. Ayar sürecinde ise eğitilmiş ağı sonuna bir katman daha eklenir ve daha sonra geri yayılım algoritması (BP) tüm ağı ağırlıklarını ayarlamak için kullanılmıştır. Tahmin sonuçlarını iyileştirmek için ise parçacık sürü optimizasyonu (PSO)' dan faydalanılmış ve kısa vadeli rüzgar enerjisi tahmini için önerilen yöntemin, mevcut yöntemlerden daha iyi sonuçlar aldığı gösterilmiş olup daha da iyileştirilmesi gerektiği savunulmuşlardır [3].

Wenjie Zhang ve arkadaşları, Geleneksel bir yük tahmini olan, Quantum Recurrent Neural Network (QRNN)'nin çok fazla bellek tükettiği, aşırı ısındığı ve eğitimi zor bir sistem olduğunu savunarak, yeni İQRNN tasarlamışlardır. Çalışma verileri GEFcom2014 den alınmıştır. Veri setindeki alakasız özellikleri ortadan kaldırması için rastgele orman (RFE), setin olası tahminlerinin mutlak hatası için ise Mean Absolute Error (MAE) kullanılmıştır. QRNN'nin eksikliklerini giderme adına, olay uyarlanabilme, hızlı öğrenme gibi yenilikler eklenmiş ve yeni geliştirilen bu sistemin, son teknolojiye sahip yöntemlerden daha üstün tahminler üretebileceği gibi doğru ve kararlı olduğunu savunmuşlardır [4].

Zhiwei ve arkadaşları kısa vadeli yük tahminlerinin eksikliklerinden bahsederek, derin öğrenme yöntemleri ile geliştirdikleri dalgacık dönüşümü yöntemini birleştirip yeni bir tahmin yöntemi sunmuşlardır. EWDL adını verdikleri bu tahmin sisteminde yük serisine uyumlu olması için topluluk derin öğrenme (EDL), derin inanç ağı(DBN), LSTM ve çok

katmanlı algılayıcı (MLP)' den faydalanmışlardır. Yüksek tahmin çıktısı için orijinal yük verilerini farklı bileşenlere ayırmış ve bu bileşenleri sırasıyla tahmin etmişlerdir. Yani DBN, LSTM ve MLP sırasıyla eğitim veri seti ile eğitilmiş, çıktıların ortalaması ile üç eğitilmiş derin öğrenme yük tahmini yapılmıştır. Oluşan tahmin sistemi ile Çin'deki bir şehrin vaka çalışmaları yapıp yöntemin üstünlüğünün doğrulandığını savunmuşlardır [5].

Roosbeh Rajabi ve arkadaşları konut içi-Hane halkı yük tahmininde, konvolüsyonel sinir ağından (CNN) daha etkili bir sistem geliştirerek 2D CNN tahmin modeli geliştirmiş ve kullanmışlardır. 2D CNN'de giriş katmanı, bir boyutlu zaman serisini kabul eden 1D CNN'den farklı olarak iki boyutlu verileri kabul ettirmişlerdir. Önerilen yöntemin performansını değerlendirmek için ise Destek Vektör Makinesi (SVM), Yapay Sinir Ağı (ANN) ve Konvolüsyonel Sinir Ağı(CNN) kullanmışlar ve sonuçlara göre geliştirilen yöntemin daha iyi sonuç verdiğini sunmuşlardır [6].

Cristina ve arkadaşları ise büyük ticari binaların enerji tüketim tahmini problemine uygun, derin öğrenme tekniği sunmuşlardır. Çalışmalarında uzun kısa süreli bellek (LSTM) ve tekrarlayan sinir ağları (RNN) kullanılmıştır. Yazarlar, kullanılan sinir ağlarından LSTM'yi ise gradyan sorununu giderdiği için tercih ettiklerini savunmuşlardır ve eğitim süresince uyarlamalı moment tahmini (ADAM) algoritması kullanmışlardır. Deney için verileri ise Singapur Üniversitesi Veri Bilimi Grubundan edinmişlerdir. Deney sonucunda LSTM sinir ağları için yapılandırma önermişlerdir [7].

Kasun ve arkadaşları bina düzeyinde enerji yükü tahmininde bulunmuşlardır. Enerji yükü tahmininde konvensiyonel sinir ağının (CNN) etkinliğini araştırmış ve CNN' den elde edilen sonuçlar LSTM, Faktörlü Kısıtlı Boltzmann Makinesi (FCRBM), Sığ Yapay Sinir Ağları (ANN) ve Destek Vektör Makineleri (SVM) ile kıyaslayıp karşılaştırılabilir sonuçlar elde edip, performansı doğrulamak için daha fazla sinir ağı ile kıyas yapılması gerektiğini savunmuşlardır. Modelin eğitimi için standart sırt yayılımı, optimizasyonu gerçekleştirmek için ise Stochastic Gradient Descent (SGD) gradyan iniş modeli kullanmışlardır. Deney sonucunda CNN mimarilerinin SVM'den daha iyi performans gösterdiği ancak ANN ile benzer sonuçlar verdiğini, CNN'nin FCRBM' den daha iyi tahmin yaptığını ancak LSTM'nin daha iyi performans gösterdiğini ANN'nin ise en kötü performansı gösterdiğini savunmuştur [8].

Mitchell ve arkadaşları yük tahmininde ortalama mutlak yüzde hatasını (MAPE) azaltmak ve en iyi sonuç veren tahmini geliştirmek için en iyi yöntemlerin kombinasyonunu araştırmışlardır. Tahmin yöntemi olarak Nöral Ağ (NN) kullanan yazarlar tahmin kodunu MATLAB'da geliştirmişlerdir. NN eğitimi için Bayesian Regularization (BR), Scaled Conjugant Gradient (SCG) ve Levenberg- Marquardt (LM) gibi algoritmalarından faydalanmışlardır. Verileri Teksas Elektrik Güvenilirlik Konseyi'nden almış olup verilere ek olarak hava durumunun yanı sıra tatil günleri gibi hafta sonları da hesaba katılmıştır. Daha sonra veri seti eğitilmek için NN'yi yapılandırmışlardır. NN eğitildikten sonra, yükü tahmin etmek için ağ ve sınav için veri kümesi kullanılarak simülasyon yapıp çalıştırmışlardır. Sonuç olarak BR ve LM'nin benzer hatalar ürettiğini, fakat BR'nin daha üstün olduğunu NN'nin ise Eğitimde çok hızlı olmasına rağmen hata payının yüksek olduğunu savunmuşlardır [9].

Weicong ve arkadaşları kısa vadeli yük tahmini üzerine birçok çalışmaya nazaran kısa vadeli yük tahminindeki parametre problemini ele almak istemişlerdir ve bunun neticesinde yüksek uçucu mesken yükü için otomatik hiperparametre ayarlamalı, derin uzun kısa süreli hafıza (LSTM) tabanlı yük tahmini geliştirmişlerdir. Hiperparametre seçiminde düğüm sayısı, optimizasyon seçimi, etkinleştirme işlevinin seçimi gibi birçok parametre seçimi kullanmışlardır. Parametre seçimi kötü seçilirse genellikle yetersiz sonuç elde edileceğini ve çalışma sonucunda LSTM tabanlı modelin birçok tahmin yaklaşım modelini geride bırakıp, konut tahmin problemleri için doğruluğunu daha da iyileştirme potansiyeline sahip olduğunu savunmuşlardır [10].

Qiang Jiang ve arkadaşları, büyük ölçekli elektrik yük tahminine odaklanmışlardır. Estonya'nın elektrik yükünü tahmin etmek için geliştirilen bu çalışma, LSTM öğrenme teknolojisi ile gerçekleştirilmiş olup verileri Min-Max yöntemi ile normalleştirmişlerdir. Deney sonucunda ulusal şebeke planlanmasında yardımcı olabileceğini savunmuşlardır [11].

Sumit Kumar ve arkadaşları, sinir ağlarının verilerde doğrusal olmayan davranışı öğrenmek ve tahmin etmek için en iyisi olduğunu savunmuşlardır. Yük tahminini, LSTM ve tekrarlı ünite (GRU) ile yapmışlardır. Tahmin yönteminde bir Spark kümesinde derin öğrenme yaklaşımı kullanmışlardır. İlk olarak Tekrarlayan Sinir Ağı (RNN) kullanarak temel bir sonuç elde etmişler ardından LSTM ağını kullanıp düşük hata oranlı veriler elde etmişlerdir. Bu konfigürasyonları GRU, modelinin ileriye yönelik birkaç adımı öngörmek

için uygulamışlardır. Deney sonucunda GRU, modelinin LSTM'den daha iyi sonuçlar verdiğini savunmuşlardır [12].

Baifu Huang ve arkadaşları maliyet ilişkili derin ve kısa süreli belleğe dayalı yük tahmin modeli geliştirmişlerdir. Bu modelde LSTM ve maliyet ilişki faktörü (CCF) dikkate alarak yük tahmin modelini başlatmışlardır. Ağ eğitimi için uyarlanabilir moment tahmin algoritması ve doğrusal birim (ReLU) kullanmışlardır. Çalışmanın maliyet kısmı, programdaki güç için ödenen ücret ve programın eşitsizliği için ödenen veya alınan ücret olmak üzere iki kısımdan oluşmuştur. Bu sistemin yüksek hassasiyetli olup yüksek maliyetli olabileceğini de savunmuşlardır [13].

Stefan Hosein ve Patrick Hosein geleneksel yük tahmin yöntemlerinden ziyade çok az kullanılan derin sinir ağı kullanarak yük tahmin modeli geliştirmişlerdir. Derin Sinir Ağları (DNN)'nin yanı sıra elektrik şebekesinde kısa süreli yük tahminine yönelik makine öğrenme tekniklerinden de faydalanmışlardır. Bu çalışmada aynı zamanda DNN'nin geleneksel yük tahminleri ile kıyasını da yaparak, DNN hesaplama süresi uzun olduğu için bu yönüyle gelenekselden uzak olsa da ayrıntılı karşılaştırmalar neticesinde DNN'nin de yük tahmini konusunda başarılı olduğunu savunmuşlardır [14].

Yuan ma ve arkadaşları dağıtım ağında verilerin ürettiği gürültünün yük tahminini olumsuz etkilediğini savunmuşlardır ve İzolasyon ormanı (IForest) ve Long Short Term Memory (LSTM) sinir ağlarını temel alan kısa vadeli bir yük tahmini modeli geliştirmişlerdir. Çalışmada geçmiş yük verilerinin Iforrest-LSTM algoritmasıyla tahmin yöntemi karşılaştırılmıştır. Deney sonucunda ise yöntemin geleneksel LSTM ve İforest-BP yöntemlerinden daha kötü olduğunu savunmuşlardır [15].

Xue Hui ve arkadaşları derin sinir ağına(DNN) dayalı kısa vadeli yük tahmin modeli sunmuşlardır ve derin sinir ağını optimize etmek için genetik algoritma kullanılmıştır. Optimizasyon sırasında başlatma işlemi yapılmıştır ardından bir sonraki nesil uygunluk fonksiyonu tarafından seçilmiştir ve çaprazlama ile mutasyon işlemine geçilmiştir. Test için elektrik sisteminin gerçek yük verilerinden faydalanılmıştır. Deney sonucunda DNN' nin iyi bir tahmin gerçekleştirdiğini savunmuşlardır [16].

Jiawei ve arkadaşları, Tensor Flow derin öğrenme ve kümelene-regresyon modelini temel alarak belirli bir bölgenin güç yükü tahminini incelemişlerdir. Veriler Adamix, Adagrad ve RMSProp ile eğitilmiş ve normalize edilmiştir. Normalize ettikleri verileri SSE kümeleme yöntemi ile kümelemiş ve regresyon tahminini K-means LSTM metodu

ile geleneksel LSTM arasında yapmışlardır. Tahmin hatasını değerlendirmek için ise mutlak yüzde hatası (MAPE) ve ortalama kare hatası (RMSE) den faydalanmışlardır. Deney sonucunda geleneksel LSTM modelinin verimsiz bellek hatalarının olduğunu ve K-mean LSTM modelinin ortama daha iyi adapte edilebildiğini savunmuşlardır [17].

Sen Wan Younghui Sun ve arkadaşları mevcut rüzgar enerjisi tahmin yöntemlerinden farklı olarak LSTM' ye dayanan yeni kısa vadeli bir yük tahmini geliştirmişlerdir. Tahmin sistemi derin inanç ağı (DBN)'nin katman eğitimini, sınırlı boltzman makinası olan (RBM) ile sağlamışlardır. DBN rüzgâr enerji tahmin sistemini MATLAB kullanarak oluşturmuşlardır ve yöntemin geçerliliğini gerçek güç değeri ile doğrulamışlardır. Analiz ve karşılaştırmayı kolaylaştırmak için ise geri yayılım (BP) ve DBN modelleri sırasıyla tahmin edip sonuçları kıyaslanmıştır ve tahmin hatalarının karşılaştırılması için ise MAPE kullanmışlardır. Deney sonucunda DBN bazlı tahmin yönteminin iyi sonuçlar elde ettiğini savunmuşlardır [18].

Aparna S ve arkadaşları, bir üniversitenin enerji tüketimini tahmin etmek için uzun kısa süreli bellek (LSTM) modelini yuvarlanan pencere metoduna göre tasarlamışlardır. Yöntemde kullanılan yuvarlama tekniğini veri kümesindeki önemli desenleri alıp geçmiş verileri istatistiksel modelle kıyasladığı gerekçesi ile kullanmışlardır. Derin öğrenme çerçevesi olarak TensorFlow ve Keras LSTM ağlarına uygulamak için kullanılmıştır. Deney sonucunda nesnelerin interneti (IoT) ile beraber süreci otomatikleştirip akıllı şebekelere de farklı bir çözüm olabileceğini ve modelin veri kümesinin boyutuyla daha iyi performans göstereceğini savunmuşlardır [19].


Tae-Young ve arkadaşları enerji tüketimi için parçacık sürüsü optimizasyonunu (PSO) CNN+LSTM ağı ile birleştirerek tahmin yeteneği yüksek bir model oluşturmak istemişlerdir. Yapılan çalışmada veriler arasında hiper parametreyi ayıklamak için parçacık sürü optimizasyonu kullanılmışlardır. Bu sistemin aynı zamanda partiküllerin nesiller üzerindeki hareketini güncellemek için de faydalı bir optimizasyon olduğunu savunmuşlardır. Çalışmanın sonucunda kullanılan yöntem diğer yöntemlerle kıyaslandığında önerilen yöntemin daha iyi sonuçlara ulaştığını gözlemlemişlerdir [20].

2. GÜNEŞ ENERJİSİ

2.1 Güneş ve Enerji

Güneş, hidrojen, helyum gazlarından oluşur ve canlı hayatının ana kaynağıdır [21]. Elektromanyetik ışımlar yaparak enerji yayar ve dünyadan 150 milyon kilometre uzaklıkta olup, çapı 1.39×10^9 m olan bir gaz küresidir. Kütlesi dünyanın yaklaşık 330.000 katıdır. Güneş enerjisinin büyük bir çoğunluğu güneşin merkezinde oluşan nükleer füzyon olan termonükleer füzyondan olduğu düşünülmektedir. Füzyon sonrası bölgede oluşan sıcaklık 15×10^6 K civarında ve açığa çıkan enerji yaklaşık 3.83×10^{26} W'tır. Bu bir saniyede 600 milyon ton proton tükettiği manasına gelir. Bu durumda güneş kütlesinin yaklaşık olarak %90'ı protonlardan oluştuğu düşünülürse, güneşteki hidrojenin tükenmesinin ortalama 5 milyar yıllık bir süreci kapsayacağı tahmin edilir. Bu durum güneş enerjisinin; yenilenebilir, temiz bir enerji kaynağı olduğunun ispatıdır [22].

Şekil 2.1'de gösterildiği gibi güneş, toplamda 7 katmandan oluşan güneşin, 3 iç katmanı ve 4 dış katmanı bulunmaktadır. En dışta yer alan fotosfer sıcaklığı, 6050K olup, $6,33 \times 10^7$ W/m²'lik enerji miktarına sahiptir. Fotosferin ötesinde kromosfer olarak bilinen yaklaşık olarak boyutu 10.000 km olan bir gaz tabakası bulunur. Bu tabakanın sıcaklığı yüksek ve yoğunluğu düşük bir yapıdadır. Kromosferden sonra yoğunluğu daha da küçük olan korona yer almaktadır [22]. Güneş tacı ise en düşük ve en yüksek sıcaklığa sahip olmakla birlikte bu bölgelerin en sonunda yer almaktadır [23].



Şekil 2.1 Güneşin katmanları [24]

Güneşin yüzey enerji miktarı çok yüksek olup $6,33 \times 10^7$ W/m²'dir. Güneşe uzaklığı 1.5×10^{11} m olan bir yüzeye ulaşan enerji miktarı 1367 W/m²'dir. Bu sayı güneş sabiti olarak isimlendirilmektedir. Bu sabit güneş ile dünyanın arasındaki mevsimsel farklardan dolayı oluşan uzaklık neticesinde değişebilmektedir.

Güneş'ten gelen ve atmosferik yayılıma uğramayan ışınlara güneş ışınları denilmektedir. Güneş ışınlamalarının %51'i yeryüzüne ulaşmakla beraber kalan %49'luk ışınlamının %26'sı atmosfer tarafından geriye yansıtılır ve yeryüzüne ulaşamaz. Geriye kalan %23' ün bir kısmı atmosferik gazlar ve bulutlar tarafından absorbe edilmektedir bu olay ışınlam olarak adlandırılmaktadır [21].

Güneşten dünyaya ulaşabilen %51'lik ışınlam üç şekilde enerjiye dönüşmektedir. Bunlardan ilki; bitkiler tarafından güneş enerjisinin kimyasal enerjiye dönüşmesi, ikincisi güneş kolektörleri tarafından ısıya dönüşmesi olup üçüncüsü ve son olanı ise güneş enerjisinden elektrik enerjisine dönüşmesidir [25]. Güneş enerjisinden elektrik üretmenin birçok yolu olmakla birlikte Konsantre güneş enerji sistemleri(CSP) ve güneş pilleri olmak üzere ikiye ayrılabilir.

Konsantre güneş enerji sistemleri(CSP): CSP'ler enerji üretiminde büyük bir paya sahip olup işletme maliyeti açısından oldukça uygun fiyatlıdır. Bu sistemlerin çalışma prensibi doğrudan güneş ışınlamını yansıtıcı aynalar vasıtasıyla yüksek ısı elde ederek elektrik üretimine dayanmaktadır.

- Güneş pilleri yani fotovoltaik (PV) piller ise kısaca yarı iletken maddelerin güneş ışınlamının panele yansmasıyla birlikte elektron alışverişi sonucu elektrik üretimine dayanmaktadır [26].

PV sistemlerin en temel yapısı, PV hücrelerdir. PV hücreler, üzerlerine düşen ışınlamı direkt gerilime dönüştürerek elektrik üretiminde yardımcı olur. PV hücreler, ürettiği voltaj ve akım miktarlarını ayarlayabilmek için seri ve paralel olmak üzere iki farklı şekilde bağlanabilmektedir. Bu sayede istenilen güç W'tan MW büyüklüğüne kadar ulaşabilmektedir. Oluşan bu yapılar PV modül olarak nitelendirilmiştir [27].

Güneş enerjisi kullanımının bazı avantajlarıyla beraber dezavantajları da bulunmaktadır.

Avantajlarından bahsedilecek olursa;

- Temiz, çevre dostu ve küresel ısınmayı etkilemez

- Fosil yakıt veya herhangi bir yanıcı kullanımına gerek kalmadan elektrik üretilmektedir.
- Ülkenin enerji bakımından dışa bağımlılığının azalmasını sağlar
- Yatırım maliyetleri haricinde ucuz ve güvenilir bir kaynak olması
- Enerji krizinden etkilenmeyecek olması
- Enerji ihtiyacını kolayca karşılayabilir olması
- Karmaşık teknolojilere ihtiyaç duymaması
- İşletme maliyetinin ekonomik olması
- Hareketli parçaların az olması ya da hiç olmaması
- Doğal afetlere karşı dayanıklı olması

Dezavantajları;

- İlk yatırım maliyetlerinin yüksek olması
- Düşük verimle çalışıyor olmaları
- Mevsimsel nedenlerden ısıtım ve enerji ihtiyacının değişmesi
- Üretilen enerji miktarının sabit olmaması
- Batarya ihtiyacının olması


Olarak sıralanabilir [28].

2.2 Güneş Enerjisinin Tarihsel Gelişimi

Güneş, kullanılan eski enerji kaynaklardan biri olup canlılığın devamı için çok önemlidir. Güneşten çıkan enerjinin tamamı dünya yüzeyine gelmemesine rağmen 84 dakikalık bir ısıtımın dünyanın bir senelik enerji gereksinimini karşılayabileceği düşünülmektedir. Bu değer fosil yakıtlarla karşılanacak olsaydı 13 milyar taş kömürüne tekabül edeceği düşünülmektedir. Ancak ısı radyasyonunun yoğunluğunun az olması, mevsimsel koşullar gibi nedenler güneş enerjisinden yeteri kadar faydalanılamamasına sebep olmaktadır [29].

Tarihte kullanılan ilk enerji yönteminin güneş enerjisi olduğu bilinmektedir. Buna örnek olarak Yunan Filozof Arşimed' in (M.Ö. 287-212) güneş ışınlarının parabolik bir aynadan yansımaları kullanarak Roma gemilerini yakması verilebilir[30]. O tarihten bu yana güneş enerjisinden elektrik üretebilmek için çeşitli yöntemler geliştirilmiş ve geliştirilmeye devam etmektedir. Şekil 2.2'de gösterilen Fransız kimyacı Lavoisier'in 1774 yılında geliştirdiği büyük lenslerle güneş ışığını belirli bir alana toplayan cihaz

bunlara ek bir örnek olarak gösterilebilir. Bu cihazın absorbe ettiği ısının 1750°C olduğu kaydedilmiştir.



Şekil 2.2 Lavoisier'in tasarladığı güneş ışığını toplayan bir cihaz [31]

19. Yüzyıl boyunca güneş enerjisini farklı enerji türlerine dönüştürmek için birçok çalışma yapılmıştır. 1839 yılında platin tabakalar üzerinde çalışmalar yapan Alexander Edmond Becquerel, platin tabaka üzerinde ilk fotovoltaiik etkiyi saptamıştır [32].

1878 yılında ise ilk parabolik kolektör olan ve şimdi Paris Sergisinde yer alan Mouchout'un parabolik kolektörü Şekil 2.3'te gösterilmiştir.



Şekil 2.3 Mouchot'un parabolik güneş kolektörü [33]

1912 yılında, Frank Shuman, C.V. Boys iş birliği ile parabolik aynalardan faydalanılarak Nil nehrinden 5 saatlik periyotlarla su çeken 37-45 kW'lık bir pompayı güneş enerji

sistemiyle çalıştırmışlardır [30]. Günümüzde, dünya genelinde birçok büyük ölçekli güneş enerjisi santrali elektrik ve ısı enerjisi üretmektedir. Ticari amaçlı olarak tarihte bilinen ilk güneş enerji santrali, 1979 yılında ABD'nin New Mexico eyaletinin Albuquerque şehrinde kurulmuştur. İlk selenyum kullanılarak %1 verimle çalışan PV hücre ise 1883 yılında, Charles Fristts tarafından geliştirilmiştir. Dünya'nın ikinci en eski güneş paneli tarlası ise Barstow, California'da 1985 yılında inşa edilmiştir. Bu tesisin güneş ışığı olmadığı zamanlarda bile 7 MW enerji ürettiği bilinmektedir [12]. PV hücrenin patenti, Amerikalı mühendis olan Russel Ohl'a ait olup, 1946 yılında alınmıştır. İlerleyen yıllarda Hoffman Elektronik hücre verimliliği üzerine çalışmalar yapmış ve %14 verimliliğe kadar çıkan hücreler geliştirmiştir. Verimlilik üzerine çalışmalar sürerken, 1970'li yılların sonlarına doğru petrol krizi ile beraber Amerika, Avrupa ve Japonya'da, PV teknolojilerine ilgi artmış olup, AR-GE çalışmaları ve üretim hızlandırılmıştır. 2000'li yıllara kadar iki eklemli ve verimliliği yüksek PV hücreleri üretime geçerken, 2000'li yıllardan sonra ise üç eklemli PV hücreleri geliştirilmiş ve 2009 yılında Spectrolab %41.6 verimli üç eklemli PV hücre geliştirerek dünya rekoru kırmıştır [32]. Günümüzde ise ucuza üretilebilecek, ince film panellerin üretimine ve çalışmalarına hız verilmiş olup çeşitli panel türleri geliştirilmeye devam etmektedir.

2.3 Güneş Enerji Potansiyeli

2.3.1 Dünyada Güneş enerjisinin potansiyeli

Güneş enerjisinden faydalanabilecek en iyi alan Dünya Güneş Kuşağı denilen ekvatorun 35° kuzey ve güney enlemleri arasında yer alan bölgedir Bu bölge 1 yılda 2000-3500 kWh/m² saat güneş ışığı almakta ve güneş potansiyeli 3,5-7 kWh/m²/gün arasında bulunmaktadır. Dünyanın kurak bölgelerinde radyasyon miktarı 2000-2500 kWh/m² arasında değişirken üst enlemlerde radyasyon miktarı düşmektedir. Çizelge 2.1'de bölgelere göre Güneş radyasyon miktarları verilmiştir [34]. Çizelgeye göre en fazla radyasyon miktarı ekvator, en az radyasyon miktarı ise Kuzey Avrupa bölgesindedir.


Çizelge 2.1 Güneş radyasyon miktarı[34]

Bölge	kWh/m ²
Ekvator	2200
Akdeniz Bölgesi	1700
Kuzey Avrupa	800
Orta Avrupa	1000

1970’li yıllar ve öncesinde gelişmiş ülkelerin birçoğu petrole bağımlılık göstermiş ve enerjiyi petrolden sağlamıştır. Arap-İsrail Savaşında ABD’nin İsrail’e desteğini sebebiyet gösterilerek petrol ambargosu gelişmiş ülkelerde petrol krizine neden olmuştur. Gerek petrol ambargosu gerekse çevre duyarlılığının oluşması ile gelişimi durağan olan yenilenebilir enerji kaynakları tekrar gündeme gelerek çalışmalara başlanılmıştır [35].

Geçmişten bugüne gelişen teknolojilerle yenilenebilir enerji gelişmiş ülkelerin yanı sıra gelişmekte olan ülkeleri de gerek çevresel, gerek politik nedenlerden ötürü yenilenebilir enerji kaynaklarından elektrik üretmeye teşvik etmiştir [36]. Yenilenebilir enerji kaynaklarından biri olan Güneş, hem çevresel avantajı hem de ekonomik getirisi sebebiyle en çok tercih edilen enerji kaynaklarından biridir [35]. Günümüzde dünyanın birçok yerinde güneş enerjisinden elektrik üretimi yapılmaktadır. Güneş enerjisinin enerji üretim miktarı ise ülkeden ülkeye değişiklik göstermektedir.

Dünya yüzeyine ulaşan güneş ışınlarından elde edilen enerjinin çok küçük bir kısmı dahi günümüz insanın günlük enerji ihtiyacından oldukça fazladır. Şekil 2.4’te dünyaya ulaşan ısı radyasyon haritası gösterilmiştir. Güneş enerjisinden; güneş pilleri, güneş santralleri ve güneş kolektörleri (Fotovoltaikler) vasıtasıyla bütün dünya faydalanmaktadır.




Şekil 2.4 Dünya ısı radyasyon haritası [37]

PV Pazar hacminde Almanya %6.60 ile en fazla paya sahip olan ülke olup, Almanya’yı %1.30’la İtalya takip etmektedir. Güneş enerjisi ülkeler arasında bir yarış içinde hızla

büyümektedir. Güneş enerjisi, üretim yönünden ise Çin 77.42 GW enerji üretim kapasitesi ile lider üretici konumundadır [35].


21. Yüzyıl Yenilenebilir Enerji Politikası Ağı (RE) Raporuna göre, 2020'nin sonunda en az 15 ülke, elektrik talebinin %5'ini, PV panellerle karşılayacak kapasiteye sahip olduğunu göstermektedir. Bu verilere göre Honduras, elektrik üretiminin, %11,2'sini, Yunanistan %10,4'ünü, Avustralya %9,9'unu, Şili %9,8'ini, İtalya %9,4'ünü ve Japonya %8,5'i PV panellerle karşılamıştır [38]

Uluslararası Enerji Ajansı (IEA) 2020-2021 Raporuna göre 2020'de yenilenebilir enerji kapasiteleri, 2019'a göre %45'ten fazla artış göstermiştir ve bu büyümenin %23 oranında kurumların kapsadığını belirtilmiştir. Şekil 2.5'te bazı ülkelerin 2019-2020 yılları arasındaki güneş enerji kapasite artışı gösterilmiştir [39].




Şekil 2.5 2019'dan 2020'ye güneş enerjisi kapasite ilavesi değişiklikleri[39]

Yıllık solar PV büyümesinin 2021 yılında %8 artarak 145GW'a ulaşması, 2022 yılında ise 162GW'a ulaşarak büyümesi beklenmektedir. Şekil 2.6'da 2019-2022 yılları arasında PV teknolojilerin kapasite artışı gösterilmiştir.



Şekil 2.6 Net PV kapasite ilaveleri, 2019-2022 [39]

IEA raporuna göre, Şekil 2.7’de de gösterildiği gibi, Çin temiz enerji alanında liderliğini korurken, Avrupa ülkelerinde 2021 ve 2022 yıllarında büyük bir artış olacağı, ABD’de 2020 yılında pandemi kaynaklı durağan dönemin son bulduğunu, büyüme oranının %30’unu oluşturduğu ve büyümeye devam edeceğini, Hindistan’ın ise PV büyümelerinin durağan olduğu belirtilmiştir [39].



Şekil 2.7 Yıllık güneş PV kapasiteleri [39]


2.3.2 Türkiye’de Güneş Enerjisinin Potansiyeli

Türkiye, 36-42° kuzey enlemleri ile 26-45° doğu boylamları arasında Kuzey Yarımküre’de yer almaktadır. Coğrafi konumu itibari ile güneş enerji potansiyeli bakımından çoğu ülkeye göre avantajlı olmakla birlikte, 1985-2019 yılları arasında yapılan araştırmaya göre Türkiye’nin günlük ortalama güneşlenme süresi 6,8 saat, 2011-2019 yılları arasında ortalama güneş radyasyonu ise 1558,7 kWh/m²’dir [40]. Çizelge 2.2’de

görüldüğü üzere, Türkiye’de aylık ortalama güneş enerjisi potansiyelinin en yüksek olduğu ay Temmuz, en düşük olduğu ay ise Ocak ve Aralık aylarıdır.

Çizelge 2.2 Türkiye’nin aylık ortalama güneş enerjisi potansiyeli [41]

Aylar	Aylık Toplam Güneş Enerjisi		Güneşlenme Süresi (Saat/Ay)
	(Kcal/Cm ² -Ay)	(Kwh/M ² -Ay)	
Ocak	4,45	51,75	103,0
Şubat	5,44	63,27	115,0
Mart	8,31	96,65	165,0
Nisan	10,51	122,23	197,0
Mayıs	13,23	153,86	273,0
Haziran	14,51	168,75	325,0
Temmuz	15,08	175,38	365,0
Ağustos	13,62	158,40	343,0
Eylül	10,60	123,28	280,0
Ekim	7,73	89,90	214,0
Kasım	5,23	60,82	157,0
Aralık	4,03	46,87	103,0
Toplam	112,74	1311	2640
Ortalama	308.0 cal/cm ² -gün	3.6 kWh/m ² -gün	7,2 saat/gün



Şekil 2.8 Türkiye güneş enerjisi potansiyel atlası [42]

Şekil 2.8’ e göre güneşlenme süresi en iyi bölge, Güneydoğu Anadolu Bölgesi iken, en az güneşlenme süresi ise Karadeniz Bölgesine aittir. Ancak, Karadeniz bölgesi Güneş enerjisinde önde gelen Almanya’nın en iyi bölgesinden daha iyi değerlere sahiptir [41].

Çizelge 2.3 Türkiye'nin yıllık toplam güneş enerjisi potansiyelinin bölgelere göre dağılımı [41]

Bölge	Toplam Güneş Enerjisi (kWh/m ² -yıl)	Güneşlenme Süresi (h/yıl)
Güneydoğu Anadolu	1460	2993
Akdeniz	1390	2956
Doğu Anadolu	1365	2664
İç Anadolu	1314	2628
Ege	1304	2738
Marmara	1168	2409
Karadeniz	1120	1971

Çizelge 2.3'te gösterildiği üzere ülkemizde yıllık ortalama toplam güneş ışınımının en büyük ve en küçük değerleri sırası ile 1460 kWh/m²-yıl ile Karadeniz Bölgesi'nde ve 1120 kWh/m²-yıl ile Güneydoğu Anadolu Bölgesi'nde gerçekleşmektedir.

Türkiye elektrik kurulu gücü 2019 yılı sonunda verilen teşviklerin de artması ile 91,3 GW seviyesine gelmiştir ve bu artışın 2,1GW'ı güneş ve rüzgâr enerjilerine aittir. Yenilenebilir enerji kaynaklarının 2005 yılında kurulu güçteki oranı %33 seviyelerinde iken 2019 yılında bu oran %41,1'e yükselmiştir ve 2005-2019 yılları arasında %13,4'lük bir artış olmuştur [43].


Türkiye'de yenilenebilir enerji kaynaklarının hemen hemen hepsi ile ilgilenilmekte ve çalışmalar sürdürmektedir. Güneş enerji sistemlerine ilk yatırım 20.yy sonlarına doğru başlamış olup, çeşitli Ar-Ge çalışmalarına devam edilmektedir [35].

Türkiye jeopolitik açıdan yenilenebilir enerji potansiyeli yüksek bir konumda olmasına rağmen yasal düzenlemeler ve maliyet yetersizliğinden dolayı mevcut potansiyel hala istenilen durumda değildir. Son yıllarda yapılan yasal düzenlemeler ve devlet teşvikleri ile güneş enerji sistemlerine ivme kazandırılmıştır.

2.4 Güneş Enerjisi ve Çalışma Prensipleri

Güneş enerjisi, güneşin çekirdeğinde oluşan füzyon tepkimesi yani hidrojen gazının helyuma dönüşmesiyle oluşan enerjidir. Bu enerjinin en küçük miktarı bile dünyada ki enerji tüketiminden çok büyüktür [44]. Günümüzde gelişen teknoloji ile güneş enerjisinin kullanım alanları da artmıştır. Bu alanlara örnek verilecek olursa; Soğutma, kurutma, damıtma işlemleri, Binalarda sıcak su ve elektrik ihtiyacının karşılanması, sokak aydınlatması, trafik lambası gibi birçok alanda kullanılmaktadır [45].


Güneş enerji teknolojileri; yöntem, kullanılan malzeme gibi birçok faktörle ayrılrsa da güneş enerjisinden elektrik üretimi doğrudan ve dolaylı olmak üzere iki ayrı yolla gerçekleştirilir. Doğrudan elektrik üretimi kapsamında ısı hem doğrudan hem de elektrik üretimi için kullanılmakta ve bunların içerisinde fotovoltaik, termoelektrik ve iyonik çeviriciler bulunmaktadır. Dolaylı yöntemde ise güneş enerjisi kullanarak elde edilen buhar gücü ile yine güneş enerjisi kullanılarak elde edilen hidrojenin kullanıldığı termik elektrik üreticilerle yakıt pilleri yer almaktadır [46]. Şekil 2.9’da bazı güneş enerji sistemlerine yer verilmiştir.



Şekil 2.9 Bazı güneş enerji sistemleri


2.4.1 PV hücrelerin çalışma ilkesi

Fotovoltaik sistemlerde (PV) güneş ışığını elektrik enerjisine çevirme işlemi, fotoelektrik olay prensibiyle çalışan güneş pilleri vasıtasıyla gerçekleştirilir. Fotovoltaik ilke gereği bu sistemlerin üzerine ışık düştüğünde elektrik gerilimi oluşmaktadır. Fotovoltaik güneş hücrelerinin yüzeyleri kare, dikdörtgen veya daire şeklinde olabilir. Boyutları genellikle 125×125 mm veya 156×156 mm olabilirken kalınlıkları 0,15-0,20 mm arasında değişmektedir. Şekil 2.10’de gösterildiği gibi Fotovoltaik sistemler (PV) soğurulan güneş ışığının doğrudan elektrik enerjisine çevrilmesi prensibine dayanmaktadır. Bu sistemler; elektrik üretiminin gerçekleştiği güneş panelleri, elektrik enerjisini depolayan solar aküler, sistemdeki voltaj değişimini dengeleyen şarj kontrol cihazları ve çeviricilerden meydana gelmektedir [30].




Şekil 2.10 PV Sistemini oluşturan elemanlar [47]

Şekil 2.11’de gösterildiği gibi güneş ışığı yani fotonlardan bir kısmı güneş pilini oluşturan yarı iletken malzemeye çarparak, atomlarını serbest bırakır. Kalan kısım ise güneş pili tarafından yansıtılır. Enerji üretimi, pil tarafından soğurulan fotonlarla yarı iletken malzemedeki elektronlar arasında gerçekleşir [48].



Şekil 2.11 Güneş pilinin çalışması[49]

Yarı iletken bileşimli diyotun bir görüntüsü Şekil 2.12’ye eklenmiştir.




Şekil 2.12 P-N birleşimli diyot[50]

Yarı-iletken diyot, P ve N tipi iki yarı-iletkenin birleştirilmesiyle oluşmaktadır. Yarı iletkenin hangi tip (P ya da N) olacağı saf yarı-iletken eriyik içine kontrollü olarak eklenen katkı maddesine bağlıdır. Örnek olarak, güneş panellerinde en sık kullanılan yarı-iletken olan silisyumdan bir P tipi taşıyıcı elde etmek için silisyum erişine belirli miktarda Boron eklenir. Aynı şekilde N tipi bir yarı iletken elde etmek için saf silikon erişine bir miktar Fosfor eklenir. Bu işlemler tamamlandıktan sonra Fosfor eklenen silikon parçasında serbest elektronlar oluşurken, Boron eklenen parça da ise boşluklar (delikler) oluşur. Bu iki tabaka bir araya getirilmeden önce her parça kendi doğal atom ve elektron sayılarına sahiptir ancak birleştirildikten sonra N tipindeki elektronlar P tipine doğru akar ve P tipindeki boşluklar N tipi parçaya akar. Bu akışın meydana getirdiği dengesizlik N tipi malzemede valans elektron kaybına ve dolayısıyla da net bir pozitif yük oluşmasına neden olur. P tipi malzemede de elektron sayısı arttığı için negatif yüklenme olmaktadır. Böylece birleşme noktalarında sınır potansiyeli denilen fazla elektronun N'den P'ye geçişini engelleyen küçük bir gerilim oluşmaktadır. Bu tabaka sayesinde bu bölgedeki tüm serbest elektron ve delikler bu bölgenin dışına itilir [15,51].

Bir P-N diyotundan enerji üretilmesi için bir miktar foton ya da ışının Silikon güneş pili üzerine düşmesi gerekir. Bu durum pilin valans bandında bir elektron oluşturacak ve bu elektronun termik enerji harcayarak yukarı doğru hareket etmesini sağlayacaktır. Dış devre metal bağlantılarla kapatıldığında, eğer bir elektrik tüketici sisteme bağlandıysa doğru akım (DC) meydana gelmektedir.

2.4.2 PV Hücrelerin Güç Sistemleri Analizi ve Matematiksel Modellemesi



Şekil 2.13 PV eşdeğer devresi [52]

Şekil 2.13'te I_{ph} , foton akımını, R_s , seri direnci, R_{sh} , paralel direnci, I , hücre çıkış akımını, V , hücre çıkış gerilimini göstermektedir.

Fotovoltaik hücrenin çıkış akımı,

$$I = I_{ph} - I_0 \left(e^{\frac{-q(V+IR_s)}{nkT_c}} - 1 \right) - \left(\frac{V+IR_s}{R_{sh}} \right) \quad [2.1]$$

Formülü ile bulunmaktadır. Formülde

k , Boltzmann sabitini ($1,380622 \times 10^{-23} \text{J/K}$),

q , elektron yükünü ($1.6021917 \times 10^{-19} \text{C}$) ve

I_0 , Diyotun ters doyma akımını göstermektedir.

PV hücreye gelen ışının enerjiye dönüşmeyen kısmı ısı olarak çıkar T_c olarak ifade edilir.

T_c Hücre sıcaklığı,

$$T_c = T_{ortam} + \frac{T_{nom}-20}{0,8} \times G \quad [2.2]$$

Formülü ile bulunur. Burada,

T_{nom} , hücre sıcaklığı

20, ortam sıcaklığını

G, güneşten gelen ışıma miktarını(w/m^2) göstermektedir.

Seri direnç açık devreye alındığında, PV hücre akımı

$$I = I_{ph} - I_0 \left(e^{\frac{-q(V+IR_s)}{nkT_c}} - 1 \right) \quad [2.3]$$

Olarak bulunur.

PV hücrelerin gerilimi,

$$V = \frac{nkT_c}{q} \ln \left(\frac{I_{ph} + I_0 - I}{I_0} \right) - IR_s \quad [2.4]$$

Olarak bulunur. PV hücrede hücre yüzeyine gelen ışık şiddeti ile indüklenen gerilim, ışık şiddeti ile orantılıdır. PV hücre çıkış uçlarına yük bağlanması durumunda yük üzerinden bir akım akar. Bu akım değeri,

$$I = N_p I_{ph} - N_p I_0 \left(e^{\frac{q \left(\frac{V}{N_s} + \frac{IR_s}{N_p} \right)}{nkT_c}} - 1 \right) - \frac{1}{N_p} \left(\frac{V + IR_s}{R_{sh}} \right) \quad [2.5]$$

Şeklinde bulunur.

N_s , panelde kullanılan seri hücre sayısını

N_p , panelde kullanılan paralel hücre sayısını ifade eder.

Paralel bağlı R_{sh} , direncinin değeri, seri bağlı R_s , değerinden büyük olduğundan R_{sh} açık devreye alındığında, PV panel akımı,

$$I = N_p I_{ph} - N_p I_0 \left(e^{\frac{q \left(\frac{V}{N_s} + \frac{I R_s}{N_p} \right)}{n k T_c}} - 1 \right) \quad [2.6]$$

Formülü ile bulunur.

PV panelin çıkış geriliminin değeri,

$$V = \frac{n k T_c}{q} L_n \left(\frac{I_{ph} + I_0 - I + N_p}{I_0} \right) - R_s I \quad [2.7]$$

Formülü ile hesaplanır.

PV panelin çıkış gücünün değeri ise,

$$P = I \times V \quad [2.8]$$

Formülü ile bulunur. Bu da 6. ve 7. denklemlere göre,

$$P = \left[\frac{n k T_c}{q} L_n \left(\frac{I_{ph} + I_0 - I + N_p}{I_0} \right) - R_s I \right] \times \left[N_p I_{ph} - N_p I_0 \left(e^{\frac{q \left(\frac{V}{N_s} + \frac{I R_s}{N_p} \right)}{n k T_c}} - 1 \right) \right] \quad [2.9]$$

Olarak bulunur [53].

Güneş panelinde elektrik üretilmesinde, Güneş panellerinin en etkili şekilde soğurma işlemi yapabilmesi için konumlandırılacağı bölgenin toprak özellikleri, yüzeyin eğimi, güneş ışınlarından faydalanma süresi gibi parametreler oldukça önemlidir [16,54].

2.4.3 PV Panellerin Bağlantı Türleri

Paneller akım ve gerilim artırılma ihtiyacına göre seri ve paralel bağlanırlar. Bu bağlanmalar sonucu dizinler elde edilir [53].

2.4.3.1 Panellerin Seri Bağlanması

Panellerin çıkış gerilimini artırmak istenirse seri bağlanmaları gerekir. Panellerin seri bağlanmasında çıkış gerilimi,

$$U = U_1 + U_2 + U_3 + \dots + U_n \quad [2.10]$$

Formülü ile bulunur. PV hücrelerin iç direncini bulmak için ise,

$$r_T = r_1 + r_2 + r_3 + \dots + r_n \quad [2.11]$$

Güç Sisteminin R yükünü beslemesi durumunda akım değeri,

$$I = \frac{U}{R + r_T} \quad [2.12]$$

Şeklinde hesaplanır.

2.4.3.2 Panellerin Paralel Bağlanması

Paralel bağlama, panellerin çıkış akımını artırmak için kullanılır. Seri bağlanmanın aksine çıkış gerilimi sabittir. Panellerin paralel bağlanmasında çıkış gerilimi,

$$U = U_1 = U_2 = U_3 = \dots = U_n \quad [2.13]$$

Sabittir ve PV panelin iç direnci,

$$r_T = \frac{r_1}{n} \quad [2.14]$$

Formülü ile hesaplanır. Burada

r_T , iç direnci,

r_1 , birinci panelin iç direncini,

n ise dizinde bulunan panel sayısını temsil etmektedir.

PV güç sistemi R direnç değerinde bir yüke bağlı ise yük akımı,


$$I = \frac{U}{R + \frac{r_1}{n}} \quad [2.15]$$

Formülü ile bulunur.

2.4.3.3 Panellerin Seri ve Paralel Bağlanması

Karmaşık bağlama denilen bu bağlama türünde hem gerilim hem de akım çıkışı artırılır.

Şekil 2.14'te seri ve paralel bağlı modüller gösterilmiştir.




Şekil 2.14 PV Modül ve bağlanma şekilleri [21]

2.4.4 PV Panel Çeşitleri ve Özellikleri

PV paneller, kristal silikon hücreler (C-Si) ve ince film hücreler olmak üzere ikiye ayrılır.

En sık tercih edilen hücre tipi kristal silikon hücreler olsa da ince film hücreler de

geliştirilmiş ve maliyeti düşük olduğundan az da olsa tercih edilmeye başlanmıştır. Şekil 2.15'te hücre tipleri gösterilmiştir.



Şekil 2.15 Hücre tipleri [46]

2.4.4.1 Kristal Silikon Hücreler

Ham maddesi silisyum olan bu hücreler, silisyum atom yapısının geç değişmesi ve teknolojik yönden sürekli gelişmesi ile en çok tercih edilen hücre tipidir. Ancak Silisyum yeryüzünde en çok bulunan elementlerden biri olmasında rağmen saf bir halde bulunamadığı için güneş teknolojilerinde kullanılabilmesi için uzun ve zahmetli işlemlerden geçmesi gerekmektedir. Silikon ilk etapta çok yüksek sıcaklıklara maruz bırakılarak silikon dioksit' ten ayrıştırılır, ardından metalürjik silikonun saflığı artırılır bunun sonucunda yüksek kalite ve saflıkta silikon elde edilerek kullanıma hazır hale getirilmektedir [46]. Şekil 2.15'da gösterildiği üzere kristal silikon hücreler, monokristal ve polikristal olarak ikiye ayrılmaktadır.

a) Monokristal güneş hücreleri: Monokristal hücreler, hücreler arasında ilk ticari hücre olmasıyla en eski ve verimi en yüksek hücrelerdir. Verimlilik yüzdeleri %15-%18 arasında gösterilmektedir. Ancak gelişen teknoloji ile bu yüzdeler daha da artmıştır.


Monokristal hücreler homojen ve renkleri lacivertten siyaha doğrudur. Çeşitli şekil ve boylarda olabilmektedirler [46].

Şekil 2.16'da bir monokristal hücrenin örneği verilmiştir. Pilin ön yüzeyinde akımı toplaması için bakır kontaklar, altında ise p-n eklemi bulunmaktadır [48],[55].



Şekil 2.16 Monokristal hücre [55]

b) Polikristal güneş hücreleri: Yapısal, elektriksel özellikleri ile monokristal pillerle aynı olan polikristal çok kristalli hücrelerin atomik yapısı homojen değildir [56]. Üretim teknolojileri daha kolay olan polikristal silisyumlu hücreler, başlangıçta aynı monokristal hücreler gibi hazırlanmaktadır. Hazırlanma aşaması erimiş yarı iletken kalitesindeki silisyum elementinin kalıplara dökülerek soğumaya bırakılması ile başlar, soğuyan kalıplarda elde edilen bloklar kare şeklinde kesilerek hazır hale getirilmektedir. Hücrenin üretilmesinde en çok kullanılan bu yöneme ise “dökme” adı verilmektedir. Bu hücrelerin verimlilik oranları monokristal hücrelere göre daha az olup %15-%17 civarındadır. Üretim maliyetleri ise daha düşük olduğu için sıklıkla tercih edilen bir hücre tipidir [46]. Rengi monokristalden farklı olarak daha açık mavidir. Şekil 2.17’de polikristal güneş hücrelerine bir örnek gösterilmiştir.



Şekil 2.17 Polikristal hücreler[57]

2.4.4.2 İnce film hücreler

İnce film hücrelerde çok az malzeme kullanılır ve genellikle çok kristalli malzemelerden üretilmektedir. Yarı iletken malzemelerden oluşan hücreler üst üste yerleştirilmiş çok

ince katmanlardan meydana gelmektedir. Yarı iletken malzemenin elektriksel ve yapısal özellikleri PV uygulamalar için uygun olsa da, hücre yüzeyindeki damarlar arasında mikro düzeydeki kusurlar, ince film hücrelerde en sık karşılaşılan problemlerden biridir. İnce film hücrelerin üretiminde en çok kullanılan yöntemler, katot saçınımı, buhar çözünümü ve elektrolit banyo yöntemleridir. Kullanılan malzemelere göre çeşitlere ayrılan ince film hücreler, bakır indiyum-diselenid (CIS), amorf silikon ve kadmiyum tellür (CdTe) olarak üçe ayrılır. Kullanılan malzemelerin 1 mikronluk kalınlığı enerji üretimi için yeterli olduğundan, kristal panellere nazaran çok daha az malzeme ile daha çabuk üretildiği düşünülmektedir [58,46]. Verimi çok düşük olan bu hücreler aynı zamanda fazla da yer kapladığı için pazarda çok tercih edilmemektedir [56]. Şekil 2.18’de kadmiyum tellür, amorf silikon ve mikromorf ince film güneş panellerinin örnekleri gösterilmiştir.



Şekil 2.18 İnce film güneş panel örnekleri [48]

Çizelge 2.4’te Kristal ve silikon panellerin verimlilik yönünden karşılaştırılması verilmiştir. Bu şekle göre kristal silikon güneş pillerinin polikristal silikon pillere göre daha verimli olduğu, ince film güneş pillerinden ise en verimlisinin Bakır İndiyum Diselenid olduğu görülmektedir [59].

Çizelge 2.4 Güneş pilleri hücre verimlilikleri

Teknoloji	Kristal Silikon		İnce Film		
	Mono	Poli	Amorf Silisyum	Kadmiyum Tellür	Bakır İndiyum Diselenid
Hücre Verimi	%15-24	%14-19	%6-13	%10-16	%13-20


2.5 Güneş Enerji Sistemlerinin Şebekeye Bağlanması

2.5.1 Şebekeden Bağımsız (Off-Grid) Sistemler

Elektrik şebekesinden ayrı kurulan bu sistemde, güneş panelinden üretilen elektrik, enerjisi akülerde depolanarak inverter vasıtası ile kullanıcının elektrik ihtiyacını karşılamasına dayanmaktadır. Sistem tasarımında öncelikle ihtiyaç duyulan enerji miktarının belirlenmesi ve yeterli sayıda PV modül sayısı enerji kaynağı olarak kullanılmalıdır. İhtiyaç sahibi güneşin olmadığı saatlerde ise gerekli olan enerjiyi akülerden karşılamaktadır [48].

Bu teknoloji park, bahçe tabela aydınlatması, güvenlik sistemleri, bağ evleri gibi birçok alanda karşımıza çıkmaktadır [60].

Şebekeden bağımsız sistemler, Şekil 2.19’da da gösterildiği gibi güneş paneli, akü, denetim birimi ve inverter olmak üzere 4 ana parçadan oluşmaktadır [44]. Denetim birimi, sistemdeki akülerin aşırı şarj veya deşarj olarak zarar görmesini engellemektedir. Bu birime, şarj kontrolörü de denilmektedir. Kontrolör sayesinde aküler şarjı tamamladığında modülden geçen şarj akışı durur. Aynı zamanda çok fazla aküden fazla akım çekilirse akımı da durdurmaya yaramaktadır [48]. Bu sistemlerde her ne kadar kontrolör kullanılsa da akü kalitesi çok önemli olup, verimi yüksek, sıcaklığa dayanıklı, uzun ömürlü aküler tercih edilmelidir [44].



Şekil 2.19 Şebekeden bağımsız sistem


2.5.2 Şebekeye Bağlı (On Grid) Sistemler

Şebekeye bağlı sistemlerde, kullanıcıların enerjisi PV sistemden karşılanarak üretilen enerjinin fazlası tek faz ya da üç faz inverter ile şebekeye verilmektedir. Tüketime fazla

olduğu zamanlarda ise kullanıcı enerji ihtiyacını şebekeden almaktadır. Böylece bu sistemlerde, şebekeden bağımsız sistemlerde olduğu gibi aküye ihtiyaç duyulmamaktadır [48].

Evler, oteller, güneş santralleri, fabrika, atölye gibi birçok alanda bu sistemlerden faydalanılabilmektedir [60].

Şebekeye bağlı sistemler, Şekil 2.20’de gösterildiği gibi dört ana elemandan oluşmaktadır. Bunlar, güneş paneli, inverter, çift yönlü sayaçlar ve datalogger’dir. Birçok farklı elemanı bünyesinde bulunduran fotovoltaik sistemlerin tasarımında temel bileşenlerin hesabı ve kaliteleri son derece önem kazanmaktadır [44].



Şekil 2.20 Şebekeye bağlı sistem [61]

Fotovoltaik sistemlerin kullanımı birçok ülke tarafından desteklenerek uygulamaya geçilmiştir. Ülkemizde de 1MW gücünün altında ki PV sistemlerin lisansız şebekeye bağlanması desteği verilmiş olsa da bu sistemlerin şebeke kalitesini gerilim bakımından olumsuz etkilediği ve bazı güvenlik problemlerine yol açabildiği görülmektedir [60].

Bu tip sistemlerin şebekeye bağlanması faydası ile birlikte sorunlar da meydana getirmektedir. Karşılaşılabilecek tüm sorunların önüne geçilmesi için sistemin çıkış gerilim karakteristiği şebeke gerilimine oldukça yakın olmalıdır. Elektrik şebekesine bağlanması düşünülen sistemde güvenlik açısından alınabilecek dört ana önlem bulunmaktadır [62].

1. PV sistem çıkış gerilim frekansı ile şebeke frekansı eş olmalıdır.
2. Sistemin çıkış terminal gerilimi şebeke gerilimi ile aynı seviyede olmalıdır.

Kurulu gücü en çok 11kW olan sistemler alçak gerilim seviyesinde 11 kW’tan

büyük olanlar ise çeşitli koşullara göre alçak gerilim veya yüksek gerilim seviyesinde şebekeye bağlanırlar [60].

3. PV sistemin çıkış fazları ile şebeke üç faz sırası aynı olmalıdır.
4. Faz açısı sistem ve şebeke ile eşzamanlı olmalıdır.

Bu dört ana madde ile beraber Elektrik Piyasasında Lisanssız Elektrik Üretimine İlişkin Yönetmeliğin vermiş olduğu kurallar dâhilinde sistem şebekeye alınabilmektedir [62].

2.6 Sivas İli Güneş Enerjisi Potansiyeli


Sivas, İç Anadolu Bölgesinin, $28.619km^2$ yüz ölçüm alanı ile Konya'dan sonraki en büyük ikinci ilimizdir. Ortalama yüksekliği 1.000 metrenin üzerinde olup, dağlık ve platolar üzerine kurulmuştur. Yaz aylarında sıcak ve kurak, kış aylarında ise yoğun kar yağışlı iklime sahiptir. Meteorolojik parametrelere göre, yıllık ortalama sıcaklık;

9 °C, ortalama güneşlenme süresi; 6,8 saat ve ortalama yağışlı gün sayısı 112 olduğu belirtilmiştir[63]. Şekil 2.21'de Sivas ili için enerji potansiyel haritası gösterilmektedir.




Şekil 2.21 Sivas ili güneş enerji potansiyel atlası [64]

Bununla birlikte, Türkiye ortalaması civarında olan, Sivas merkez ilçenin, güneşlenme süresi günlük toplam 7,2 saat, ısınım değeri ise toplam $4,1 kW/m^2$ olarak hesaplanmıştır [65].



Şekil 2.22 Sivas ili güneşlenme süresi



Şekil 2.23 Işıma süreleri Sivas ili ışıma miktarı[64]

Şekil 2.22 ve 2.23'te Sivas ili için aylara göre güneşlenme süreleri ve ışıınım miktarı verilmiştir. Güneşlenme süresinde en düşük 3.29 ile Aralık ayına, en yüksek 11.05 ile Temmuz ayına aittir. Işıınım miktarında ise yine en düşük miktar, 1.58 ile Aralık ayına, en yüksek ise 6.56 ile Haziran ayına aittir.

3. MATERYAL VE METOT

3.1 Makine öğrenmesi

Yapay zeka, makine öğrenimi ve derin öğrenme birbiriyle bağlantılıdır; Derin öğrenme bir tür makine öğrenimidir. Makine öğrenimi ise bir tür yapay zeka ürünüdür. Yani belirli bir yapay teknoloji grubunu belirtmek için makine öğreniminden faydalanılır. Makine öğrenimi ise birçok teknolojiye bağlı belirli bir alanı ifade etmektedir. Bu alanın içinde yapay zekadan çok üstün olan derin öğrenme teknolojisi de bulunmaktadır. Bu teknoloji her ne kadar yapay zekadan üstün olsa da makine öğreniminin bazı sorunlarını beraberinde getirmektedir. Bundan dolayı derin öğrenme kavramından önce makine öğrenimi ele alınacaktır [66].


Yapay zeka $\Rightarrow$ Makine Öğrenmesi $\Rightarrow$ Derin Öğrenme

3.1.1 Makine Öğrenmesi Nedir?

Makine öğrenimini geleneksel yöntemlerden ayıran en büyük özellik insan beynini model olarak almasıdır. İnsan beyninin herhangi bir nesneyi kavraması için örnekler gösterilir ve öğrenme gerçekleşir makine öğreniminde ise fiziksel yasaların, matematiksel problemlerin model üretmediği anlarda konuşma, tanıma, görselleştirme gibi eğitim verisi denilen veriler kullanılarak makine öğrenmesi gerçekleştirilir. Bununla beraber makine öğrenimi analitik modellerin sorunlarını çözmekte istatistiksel geçmişe sahip olan verilerden bir model oluşturulmasını sağlar. Ancak eğitim verileri ve girdi verilerinin farklılığı makine öğrenimini zorlaştırmıştır. Örneğin tek bir kişinin yazısından oluşan notların eğitim verisi için kullanılması halinde makine öğrenmesi başka bir yazarın yazısını tanımakta eksik kalmıştır. Bu ve bunun gibi çeşitli alanlardaki sorunların çözümü için makine öğrenimi teknik olarak geliştirilmiştir [66].

3.1.2 Makine Öğrenim Teknikleri

Makine öğrenim teknikleri eğitim sürecinde eksik kaldığı için, eğitim yöntemine dayalı olarak 2 ana grupta incelenmiştir. Bunlar, Şekil 3.1’de de gösterildiği gibi denetimli öğrenme, denetimsiz öğrenmedir.



Şekil 3.1 Makine öğrenim teknikleri [67]

Denetimli öğrenme, sınıflandırılmış bir veri kaynağından veriyi eğitmeye dayanır. Eğitim verilerinden gelen girdiye karşılık bir sonuç üretilir. Bu bir problemi çözmek için mevcut bilgilerin taranıp cevap çözümünden farklı ANN bilgiyi yeniden taramaya benzer.

Denetimsiz öğrenmede ise eğitim verileri yalnızca girdiler içerir. Genellikle en elverişli etkileşim gerektiğinde kullanılmaktadır [68].

3.1.3 Sınıflandırma ve Regresyon

Sınıflandırma işlemi makine öğrenimi için son derece yaygın bir işlem olup, verileri sınıf sınıf ayırmaya onları kategorize etmeye yarar ve makine öğreniminde rolü oldukça büyüktür. Sınıflandırma sırasında girdinin hangi sınıfta olduğu öğretilir böylece çıktı girdiye karşılık gelen sınıfa sahip olmaktadır [66]. Sınıflandırma modellerine örnek olarak Karar Destek Vektör Makinesi(SVM), Yapay Sinir Ağları (ANN), gibi modeller örnek verilebilir.

Regresyon problemleri ise sınıflandırma problemlerinin aksine değişkenler arasındaki ilişkiyi çözmeye yardımcı olur. Yani girdiler ve çıktılar arasında bağ oluşturarak başarılı bir sonuç elde edilmeye çalışılmaktadır. Şekil 3.2’de regresyon ve sınıflandırma için bir örnek gösterilmiştir.




Şekil 3.2 Regresyon ve Sınıflandırma [66]

3.2 Derin Öğrenme

Derin öğrenme, yapay zeka ve istatistiklerin bir alt kümesi olan makine öğreniminin bir alt kümesidir ve insan beyninden ilham alınarak oluşturulmuştur [69,70]. Derin öğrenme modelleri tüm uygulamalarda kullanılabilecek şekilde esnek bir yapıdan oluşmaktadır.

İlk çalışmalar, beynin yapısı, önermeler mantığı ve Turing'in hesaplama teorisi hakkındaki bilgilere dayanmaktadır. Warren McCulloch ve Walter Pitts, sinir ağları için eşik mantığına dayalı matematiksel bir formül oluşturmuştur. Oluşturulan bu formül, sinir ağı araştırmasının iki ayrı yaklaşıma neden olmuştur: biri beyindeki biyolojik süreçlere, diğeri sinir ağlarının yapay zekaya uygulanmasına odaklanmıştır. Bu yaklaşımların ışığında, Marvin Minsky ve Dean Edmonds, 1950'de Harvard'da ilk nöral bilgisayar yapmıştır [69].

İlk bilgisayar programları ve günümüzdeki bilgisayarların büyük bir kısmı, programcı tarafından kodun içine yerleştirilmiş bilgiye sahiptir. Programcı geniş veri tabanlarından yararlanabilir. Örneğin, bir uçak modeli, aerodinamik katsayıların çok boyutlu tablolarını kullanabilir. Bu sebeple ortaya çıkan yazılım, uçaklar hakkında birçok bilgi vermekte ve modellerin çalışan simülasyonları, simülasyonu tam olarak anlayamayabilecekleri veya hatalı girdiler girebilecekleri için programcı ve kullanıcılar için sürprizlere neden olabilmektedir. Ayrıca, veriler ve algoritmalar arasındaki pragmatik ilişkiler kod tarafından önceden belirlenir [69]. Derin öğrenme kavramı, birden fazla nöron katmanına sahip sinir ağlarını ifade eder. "Derin öğrenme" popüler literatürde öğrenme sisteminin "derin düşünen" olduğu anlamına gelmektedir. Şekil 3.3'te, tek katmanlı ve çok katmanlı bir ağ gösterilmiştir. Çok katmanlı ağların, tek katmanlı ağlara göre daha iyi öğrenme yapabildiği ortaya çıkmıştır. Bir ağın elemanları, ağırlıklı sinyallerin birleştirildiği ve önyargıların eklendiği düğümlerdir. Tek bir katmanda girdiler ağırlıklarla çarpılıp bir eşik fonksiyonundan geçerek toplanır. Çok katmanlı veya "derin öğrenme" ağında, girdiler, çıktı alınmadan önce ikinci katmanda birleştirilir. Eklenen bağlantılar, ağın daha karmaşık sorunları öğrenmesini ve çözmesini sağlamaktadır[69].




Şekil 3.3 a) Tek katmanlı bir ağ [69] b)Çok katmanlı bir ağ [69]

Birçok makine öğrenimi türü mevcuttur, çevreden gelen girdilere dayalı olarak uyum sağlayabilen herhangi bir bilgisayar algoritması, bir öğrenme sistemidir. Bunlardan Uzun kısa süreli bellek(LSTM) ,yapay sinir ağları(ANN) ve evrimsel sinir ağları(CNN) ele alınmıştır.

3.2.1 Derin Öğrenme Türleri

3.2.1.1 LSTM (Uzun Kısa Süreli Bellek)

LSTM, uzun süreli zaman serilerini, kaybolan veya patlayan gradyanlar problemine maruz kalmadan analiz edebilmek için tasarlanmış özel bir tür Özyinelemeli Sinir Ağları (RNN)metodudur [71]. Mimarisi basit RNN'ye benzetmekle birlikte, gradyan akışını daha iyi kontrol edebilmek için daha fazla geçit bulundurmaktadır. Bu sebeple kısmen karışık bir mimariye sahiptir. LSTM mimarisi aşağıdaki Şekil 3.4'te gösterilmektedir.



Şekil 3.4 LSTM Mimarisi [72]

LSTM mimarisinin en önemli bileşeni hafıza hücresidir (memory cell). Zamanla durumunu koruyabilen bu hücre sayesinde geçmişten gelen bilgiler sonraki katmanlara aktarılabilir. LSTM, unutma ve giriş geçitleri (forget/input gates) kullanarak,

hafıza hücresi içindeki bilgileri değiştirme kapasitesine sahiptir. Unutma geçidi, bu hücrede bulunan verilerin saklanıp saklanmayacağına veya unutulup unutulmayacağına karar vermektedir. Geçmişe ait veriler önemli ise saklanmalı, aksi halde unutulmalıdır. Unutma geçidinin çıktısı 0 ise veriler unutulur, 1 ise saklanır. Bu karar bir sigmoid aktivasyon fonksiyonu yardımıyla verilir ve aşağıdaki gibi formülize edilir:

$$f_t = \sigma(W_f[h_{t-1}, x_t] + b_f) \quad [3.1]$$

Giriş geçidi, hücrenin yeni girişlerden elde edilen faydalı bilgiler ile güncellenmesini sağlayacak olan verileri üretir. Hangi değerlerin güncelleneceğini ise bir sigmoid aktivasyon fonksiyonu ile belirler. Hiperbolik tanjant aktivasyon fonksiyonu yardımıyla da yeni aday değerler belirlenir. Giriş geçidi ve yeni aday değerler aşağıdaki gibi hesaplanmaktadır:

$$i_t = \sigma(W_i[h_{t-1}, x_t] + b_i) \quad [3.2]$$

$$\check{C}_t = \tanh(W_c[h_{t-1}, x_t] + b_c) \quad [3.3]$$

Yukarıda gösterilen unutma geçidi, giriş geçidi ve yeni aday değerler kullanılarak, önceki katmandan gelen veriler güncellenmektedir. Bu güncelleme aşağıdaki formül ile yapılmaktadır:

$$C_t = f_t \cdot C_{t-1} + i_t \cdot \check{C}_t \quad [3.4]$$

Son aşamada ise hangi verilerin çıktı olarak alınması gerektiği kararlaştırılır. Bu işlem çıkış geçidi olarak adlandırılan geçitte yer alan bir sigmoid aktivasyon fonksiyonu yardımıyla belirlenir ve aşağıdaki gibi hesaplanır:

$$o_t = \sigma (W_o [h_{t-L}, x_t] + b_o) \quad [3.5]$$

Hafıza hücresindeki güncellenen veriler, değerleri -1 ile 1 arasında tutabilmek için hiperbolik tanjant aktivasyon fonksiyonuna tabi tutulur. Sonrasında ise yeni çıktı, aşağıdaki formül yardımıyla elde edilir:

$$h_t = o_t \cdot \tanh(C_t) \quad [3.6]$$

LSTM mimarisi, konuşma, tanıma, doğal dil işleme ve duygu analizi gibi pek çok alanda başarı ile kullanılmaktadır [72].

3.2.1.2 ANN (Yapay Sinir Ağları)

Sinir ağları ya da diğer bir deyişle yapay sinir ağları, makine öğreniminden farklı olarak insan beyninin bilgi işleyiş sürecinin temel düzeyde dijital bilgisayarın bilgi işleyiş sürecinden farklı olduğu varsayımıyla geliştirilmiştir. Nöronlar beyin temel yapıtaşı ve bilgi işleme modülüdür. Tipik bir beyinde muazzam miktarda (yaklaşık 10 milyon nöron korteks ve bunlar arasında 60 trilyon bağlantı yani sinaps içerir) doğrusal olmayan ve paralel yapıda nöron bulunmaktadır. Sonuç olarak, insan beyni bilgiyi işleme, öğrenme ve muhakeme etme için çok verimli bir yapıya sahiptir [73].


Yapay sinir ağı, araştırmacıların altta yatan fonksiyonları bilmediği karmaşık yapılar için uygun bir tür parametrik olmayan modelleme tekniğidir. Başka bir deyişle ANN, belirli işlev varsayımları olmaksızın verilerden öğrenebilir [74]. Sinir ağı, bir sisteme yerleştirilmiş algoritmadır ve beyin bir işlevi yerine getirme şeklini modeller. Ağ, giriş parametrelerini simüle etmek ve en iyi çıktı çözümlerini üretmek için elektronik mekanizmalar kullanılarak veya yazılımda simüle edilen bir dijital bilgisayarda uygulanır. Bir sinir ağı, deneysel bilgileri depolamak ve bunlara çözüm sağlamak için doğal bir eğilime sahip olan basit işlem birimlerinden oluşan büyük ölçüde paralel dağıtılmış bir işlemcidir. Yapay sinir ağı, doğal beyne iki şekilde benzer:

- 1) İlk gözlem ve benzerlik, bilginin edinilmesi ve depolanmasıyla ilgilidir. Ağ, çevresinden bir öğrenme süreci yoluyla bilgi edinebilir.
- 2) Sinir ağının doğal beyne benzemesinin ikinci yolu, nöronların birbirine bağlanmasıyla ilgilidir. Nöronlar, çok yönlü bir modelde takviye edilir, güçlendirilir ve iç içe geçer. Bir sinir ağında öğrenme sürecini yürütmek için kullanılan teknik, istenen bir hedefe ulaşmak için ağın sinaptik ağırlıklarını düzenli bir şekilde değiştirme görevi olan bir öğrenme algoritması olarak adlandırılır [75].

ANN'ler kullanıma uygun deneysel bilgiyi depolamak için yerleşik bir yeteneğe sahiptir.

- Yüksek hızlı bilgi işleme
- Yönlendirme yetenekleri
- Hata toleransı
- Uyarlanabilirlik
- Genelleme
- Sağlamlık

ANN'lerin en iyi özellikleri arasındandır. Bu özellikleri ile ANN'ler çeşitli mühendislik sistemlerinin performansını modelleme, en iyi şekilde kullanmak ve tahmin etmek için yararlı araçlar haline getirilmesini sağlar [76].



Şekil 3.5 Örnek nöron ve ANN hücresi [77]

Birçok ANN modelinde kullanılan nöron modeli bir seriden oluşmaktadır. Şekil 3.5'te gösterildiği gibi her bir sinaps x girişi ile çarpılır. Bundan sonra tüm ağırlıklı girdiler

toplanarak toplamın çıktı değerini değiştirmek için harici olarak uygulanan b_k uygulanır. Bu diziler aşağıdaki gibi formülize edilir. Burada y_k çıktı sinyali, ϕ , genlik aktivasyonunu, k nöronu temsil ederken j ise sinaps sayısını temsil etmektedir [76].

$$y_k = \varphi \left(\sum_{j=1}^m (w_{kj}) + b_k \right) \quad [3.7]$$

ANN'nin terminolojisine aşağıda değinilmiştir.

İşlem Birimi; Yapay sinir ağları (ANN), biyolojik sinir ağ yapısının basitleştirilmiş modeli olarak düşünülebilir. Yapay sinir ağları birbirlerine bağlı işlem birimlerinden meydana gelir. Genel bir işlem birimi toplama bölümü ve çıktı bölümü olmak üzere 2 bölümden oluşur. Toplama bölümü n adet girdi değerini alır, her birini ağırlıklandırır ve ağırlıklandığı değerleri toplar. Ağırlıklandırılmış toplam aktivasyon değeri olarak tanımlanır. Her bir değer ağırlık işareti girdinin pozitif veya negatif ağırlık olup olmadığını belirler. Girdiler kesikli veya sürekli değer olabildikleri gibi çıktı değeri de kesikli veya sürekli olabilir. Girdi ve çıktı, problem ve onun çözümünün doğasına uygun şekilde deterministik, stokastik veya bulanık olarak ele alınabilir.

Bağlantılar; Yapay bir sinir ağında, bir örüntü tanıma görevini gerçekleştirmek için bazı yapılara göre birkaç işlem birimi birbirine bağlanır. Bu nedenle bir işlem biriminin girdileri diğer işlem birimlerinin çıktılarından ve/veya bir dış kaynaktan gelebilir. Her bir bölümün çıktısı kendisi dahil birkaç bölüme verilebilir. Başka bir birim tarafından alınan bir birimin çıktısının miktarı, birimler arasındaki bağlantının gücüne bağlıdır ve bağlantının ilişkili ağırlık değerine yansıtılır. Belirli bir ANN'de " n " birim varsa, o zaman herhangi bir anda her birimin benzersiz bir aktivasyon değeri ve benzersiz bir çıktı değeri olacaktır. Ağın n aktivasyon değerlerinin kümesi, o anda ağın aktivasyon durumunu tanımlar. Benzer şekilde, ağın n çıktı değerlerinin kümesi, ağın o andaki çıktı durumunu tanımlar. Aktivasyon ve çıktı değerlerinin kesikli veya sürekli doğasına bağlı olarak, ağın durumu, kesikli veya sürekli bir n boyutlu uzaydaki bir nokta ile tanımlanabilir.

İşlemler; Çalışma sırasında, bir ANN'nin her birimi diğer bağlı birimlerden ve/veya harici bir kaynaktan girişler alır. Belirli bir anda girdilerin ağırlıklı toplamı hesaplanır. Ortaya çıkan aktivasyon değeri, çıktı fonksiyonu biriminden gerçek çıktıyı, yani birimin çıktı durumunu belirler. Çıkış değerleri ve diğer harici girişler, diğer birimlerin aktivasyon ve çıkış durumlarını belirler. Ağın birimlerinin aktivasyon değerleri (aktivasyon durumu)

zamanın bir fonksiyonu olarak aktivasyon dinamikleri olarak adlandırılır. Aktivasyon dinamikleri ayrıca ağı çıkış durumunun dinamiklerini de belirler. Tüm aktivasyon durumları kümesi, ağı durum uzayını tanımlar. Tüm çıktıların kümesi durumlar, ağı çıkış veya sinyal durum uzayını tanımlar. Aktivasyon dinamikleri, ağı durum uzayındaki durumların yolunun yörüngesini belirler [78].

Aktivasyon / Başlangıç Fonksiyonu; Bir nöronun zamanla değişen değer çıktısıdır. Eşik bazlı sınıflandırıcı (threshold based classifier) bir aktivasyon fonksiyonunda dikkate alınması gereken en önemli unsurdur. Eşik bazlı sınıflandırıcı, doğrusal dönüşümün değerinin nöronu aktive etmesinin gerekip gerekmediğini göstermektedir. Aktivasyon fonksiyonunun girişi bir eşik değerinden büyükse bir nöronun aktive olduğu veya devre dışı bırakıldığı söylenebilir. Böyle bir durumda elde edilen çıktı bir sonraki katmanın girdisi olamaz. Çok sayıda kullanılan aktivasyon fonksiyonu vardır [79].

Geri yayılım (Genelleştirilmiş Delta Kuralı); Algılayıcı (perceptron) sinir ağının bir dizi girdi modeline iyi sonuçlar üretmek için “eğitildiği” işleme verilen bir ad. Bunun ışığında, Algılayıcı ağına bazen “destek ağı” adı verilir.

Net Girdi / Eğilim; Bir nöronun harekete geçmesi için nöral aktivasyonların aşması gereken miktarla orantılıdır.

Bağlantılık; Bir sistemdeki etkileşim miktarı, sinir ağındaki ağırlıkların yapısı veya bir tablodaki ilişkili kenar sayısıdır.

Örüntü Tanıma; Önceden öğrenilmiş veriyle örüntüleri tanıma eylemidir. Bu, sinir ağı gürültülü olsa veya sinir ağının bazı verileri eksik olsa dahi gerçekleştirilebilir.

Dönem; Ağ eğitimi sırasında bir eğitim setinin tamamlanmış çıktı süresidir.

Girdi Katmanı; Dış kaynaktan beslenen girdi nöronlarıdır.

Eğitim Algoritmaları (Danışmanlı/Danışmansız); Sinir ağı ağırlıklarının ya da diğer değiştirilebilir parametrelerin otomatik olarak ayarlanıp hedefe daha kolay ulaşılabilir olmasını sağlayan adaptasyon sürecidir. Geri yayımlı algoritma örnek olarak gösterilebilir.

Eğitim Kuralı; Eğitim sırasında eğitim modelindeki bağlantı yükü ya da ağırlığını değiştirmek için kullanılan algoritmadır.

Katman; Belirli bir işleve sahip ve bütün olarak işlem gören bir grup nöronudur. En yaygın bilineni giriş, çıkış ve bir veya daha fazla ara katmana sahip ileri beslemeli bir ağ modelidir.

Monte-Carlo Metodu; Monte-Carlo yöntemi bilgisayarda çeşitli matematiksel problemlere istatistiksel örnekleme yöntemleriyle yaklaşık sonuçlar sağlar.

Çok Katmanlı Algılayıcı (MLP); En az 1 gizli katmanı bulunan bir çeşit ileri beslemeli sinir ağı türüdür. Katmanlar girişten başlayıp çıkışa kadar güncellenerek devam eder. Her nöron, net bir girdi elde etmek için gelen sinyallerin ağırlıklı bir toplamını hesaplar ve nöronun aktivasyon değerini vermek için bu değeri sigmoidal aktivasyon fonksiyonundan geçirir. Algılayıcıdan farklı olarak MLP doğrusal olmayan problemleri çözebilir.

Sinir Ağı; Sinaps veya ağırlıklarla birbirine bağlanan nöron ağıdır. Her nöron, kendisine bağlı olan nöronların aktivasyonlarının bir işlevi olan basit bir hesaplama yapar. Geri besleme mekanizmaları ve/veya nöronların doğrusal olmayan çıktı tepkisi yoluyla ağı bir bütün olarak evrensel hesaplama ve evrensel yaklaşım dahil olmak üzere son derece karmaşık görevleri yerine getirebilir. İleri beslemeli, geri beslemeli ve tekrarlayan sinir ağı olmak üzere 3 farklı türü bulunur ve sahip oldukları bağlantı derecesi ve türüne göre değişkenlik gösterir.

Nöron; Gelen sinyaller üzerinde ağırlıklı bir toplam gerçekleştiren, net bir girdi elde etmek için bu değere bir eşik veya yanlılık terimi ekleyen ve bu son değeri kendi aktivasyonunu hesaplamak için bir aktivasyon fonksiyonu aracılığıyla eşleyen basit bir hesaplama birimidir. Geri bildirimde veya Hopfield ağlarında bulunanlar gibi bazı nöronlar önceki aktivasyonların bir kısmını koruyacaktır.

Çıktı Nöronu; Çıktıları ağın sonucu olan ağ içindeki nöronudur.

Algılayıcı; Basit örüntü tanıma ve sınıflandırma görevini yapan yapay sinir ağıdır. Sinyallerin giriş, ardından gizli katmana ve çıktı katmanına ilerlediği ağları ağıdır. Katman içinde bağlantı yoktur.

Sigmoid Fonksiyonu; Genellikle bir sinir ağında aktivasyon işlevi olarak kullanılan S şekilli işlevdir.

Eşik Değer; Nöronun net girdisini oluşturan, bir nörona ağırlıklı girdilerin toplandığı veya çıkartıldığı bir miktardır. Sezgisel olarak net girdi bir nöronun harekete geçmesi gereken nöral aktivasyonların aşılması gereken miktarla orantılıdır.

Eğitim Seti; Bir sinir ağı bir eğitim seti kullanılarak eğitilir. Eğitim seti, girdi uyarını olarak çözülmesi gereken problem hakkındaki bilgileri içerir. Bazı bilgisayarlarda eğitim seti “gerçekler” olarak adlandırılır.

Ağırlık; Sinir ağında, iki nöron arasındaki bağlantının gücüdür. Ağırlıklar pozitif/destekleyici veya negatif/engelleyici olabilir. Bir nöronun eşiği, bir öğrenme algoritması tarafından adaptasyona tabii tutuldukları için ağırlık olarak da kabul edilir [76].

3.3 MAPE (Ortalama Mutlak Yüzde Hata)

MAPE, Regresyon ve zaman serileri modellerinde tahminlerin doğruluğunu tespit etmek için sıklıkla kullanılmaktadır Ortalama mutlak yüzde hata (MAPE) aşağıdaki denklemde gösterilmiştir.

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{\hat{x}_i - x_i}{x_i} \right| * 100\% \quad [3.8]$$

Ortalama Mutlak Yüzde Hatası (MAPE), her periyottaki mutlak hatanın o periyot için belirgin olan gözlenen değerlere bölünmesiyle hesaplanır sonra bu sabit yüzdelerin ortalaması alınır. [80][7][8]. MAPE, tahminde gerçek değerle karşılaştırıldığında ne kadar hata olduğunu gösterir [80].

Regresyon ve zaman serileri modellerinde MAPE, tahminlerin doğruluğunu tespit etmek için sıklıkla kullanılmaktadır. Gerçek değerler içerisinde sıfır (0) içerenler bulunuyorsa, sıfırla bölüneceği için MAPE hesaplanamaz yani yanlış sonuç üretir. Çok düşük tahmin değerleri için yüzde hata %100’ü aşamaz fakat çok yüksek tahmin değerleri üretildiğinde yüzde hatasının üst limiti yoktur. MAPE, tahminde kullanılan modellerin doğruluklarını kıyaslamak için kullanıldığında, tahminleri düşük olan bir modeli sistematik olarak seçmesi nedeni ile önyargılıdır [81].

3.4 RMSE (Kök Ortalama Kare Hata)

RMSE veri ile eğitilmiş veri arasında bir fark olup olmadığını araştırır. Tahmin hataların standart sapması olarak, gerçek değer ve tahmin edilen değer arasında ne kadar bir fark olduğunu öğrenmek için kullanılır. RMSE ne kadar küçükse, tahmin o kadar iyi olur ve

değer aralığının 0-∞ arasındadır. Bu durumda RMSE sıfıra eşitse model hata yapmamış sayılmaktadır.

$$RMSE = \sqrt{\frac{\sum_{j=1}^n e_j^2}{n}} \quad [3.9]$$


Formülü ile ifade edilen RMSE e_j = gerçek değer- tahmini değeri ifade eder, n veri boyutu olarak ifade edilmektedir [82].

3.5 Derin Öğrenme ile Güneş Enerji Tahmini

Enerji tahmini için en önemli faktörlerden biri doğru yöntemin belirlenmesidir. Bununla beraber tahmin doğruluğu yüksek olan bir model için büyük bir veri seti ve tahmini etkileyen faktörlerin iyi seçilmesi gerekmektedir. Enerji tahmini için kullanılan en yaygın algoritmalar yapay zeka algoritmalarıdır. Bununla beraber literatürdeki çalışmalarda birçok yöntem kullanılmış olup hata yüzdesinin aza indirilmesi amacıyla hibrit yaklaşım da incelenmiştir.


Bu çalışmada ilk olarak Türkiye’ye yönelik günlük, üretim tahmini modelleme çalışması için ANN ve LSTM karşılaştırılması hedeflenmiştir ancak çalışmada veri yetersizliği nedeniyle parametre olarak mevsimsel veriler ele alınmamış olup yalnızca popülasyon ve üretim miktarı ele alınmıştır. Matlab’da derin öğrenme metotları kullanılarak hazırlanan bu çalışmada oluşan sonuçlar tahmini yöntem değerlendirmesinde kullanımı çok yaygın olan MAPE ile ölçülmüş olup RMSE ile tahmini değer ve gözlenen değer arasındaki fark incelenmiştir.

İlk olarak LSTM modeli kullanılan çalışmada verilerin %90’ı eğitim için ayrılmış olup verilerin %10’u ise test verisi olarak kullanılmıştır. Bu çalışmaya ait MAPE değerinin Şekil 3.6’da 0.076 olduğu RMSE değerinin ise 2611 olduğu görülmektedir. Bu değer çok iyi bir değer olmayıp hata oranı yüksek bir model oluşmuştur.



Şekil 3.6 RMSE ve MAPE değerleri

Gözlenen ve tahmin değerleri ise Şekil 3.7'deki gibidir. Şekil 3.7'den de anlaşılacağı üzere tahmin ve gerçek değerler arasında çok büyük farklar mevcuttur.



Şekil 3.7 Tahmin sapma miktarı

Deney sonuçlarına göre çalışmalar iyi derecede tahmin yapamamış olup daha iyi veriler ve tahmini etkileyen faktörlerin de eklenmesi ile çok daha iyi sonuçlar elde edileceği düşünülmüştür. Türkiye için, tahmini etkileyen gerekli veriler yetersiz ve bölgesel bazda olduğundan ve yeterli sonuç alınamadığı için çalışmaya Sivas ilinin Kangal ilçesine ait Hamal güneş enerji santrali verilerinden faydalanılarak yeni bir analiz ile devam etmeye karar verilmiştir. Daha önce bahsedildiği gibi Sivas ili güneşlenme süresi günlük toplam 7,2 saat, ışıınım değeri ise toplam $4,1 \text{ kW/m}^2$ olarak Türkiye ortalaması civarındadır [65].

4. VERİ ANALİZİ VE YÖNTEMLERİN UYGULANMASI

Bu bölümde tez çalışmasından kullanılan tahmin modelinin oluşturulması, Meteoroloji Genel Müdürlüğünden ve Enerji Piyasaları İşletme A.Ş. (EPIAŞ) şeffaflık platformundan elde edilen geçmiş verilerin düzenlenip geliştirilmesi, tez çalışması için yapılan yeni bir analiz ve değerlendirmeler yer almaktadır.

Güneş enerji üretim tahmin değerlerini birçok faktör etkilemektedir. Bazı faktörler tahmini doğrudan etkilerken bazıları az miktarda etkilemektedir. Bu tahmin uygulaması için Sivas iline ait Meteoroloji Genel Müdürlüğünden, 01.01.2019 tarihinden 31.12.2020 yılları arasında gerçekleşen; sıcaklık, nem ve basınç değerleri alınmış olup, geliştirilen tahmin modelinde değişken olarak kullanılmıştır. Bununla beraber bu tez çalışmasında Enerji Piyasaları İşletme A.Ş. (EPIAŞ)'e ait yine 01.01.2019 - 31.12.2020 tarihinden itibaren Sivas ilinin Kangal ilçesinde bulunan 9 MWe kurulu güce sahip 'Hamal Güneş Enerji Santrali' üretim verileri EPIAŞ şeffaflık platformundan sağlanmıştır.

Mevcut veride birçok günde eksik veri, tanımsız değer gibi veri setini bozacak ve tahminin iyi yapılmasına engel olacak değerlerin bulunduğu gözlenmiş olduğundan Python ile makine öğrenme analizi olan, KNN- En yakın komşu algoritması kullanarak verinin düzenlenmesi ve daha iyi hale getirilmesi sağlanmıştır. Bu uygulama, sınıflandırma işlemi için kullanılan verinin bulunduğu noktaya en yakın komşu elemanı k değeri benzerliğine göre çalışmaktadır. KNN algoritması kullanılmasındaki amaç en ideal verinin oluşturulması sağlamaktır. Bununla beraber verilerin bilgisayar ortamında düzeltilmesi sonuç değerlerinin daha iyi çıkmasını sağlarken verinin yapısında değişikliğe sebep olsa da yapılacak çalışma için bir sorun haline gelmeyecek aksine verinin daha iyi sonuçlar vermesini sağlayacaktır.

Tarih	Saat	Sıcaklık	Basınç	Nem	ÜRETİM
15/02/2020	16:00	-3,4	875.0	69.0	
15/02/2020	17:00	-3,9	875.5	73.0	
15/02/2020	18:00	-5,2	875.7	80.0	
15/02/2020	19:00	-5,8	875.9	82.0	
15/02/2020	20:00	-6,6	876.0	84.0	
15/02/2020	21:00	-7,3	875.8	83.0	
15/02/2020	22:00	-7,2	875.8	82.0	
15/02/2020	23:00	-6,8	875.9	80.0	
16/02/2020	00:00	-6,7	875.9	79.0	
16/02/2020	01:00	-6,5	875.7	81.0	
16/02/2020	02:00	-6,6	875.7	83.0	
16/02/2020	03:00	-7,5	875.9	83.0	
16/02/2020	04:00	-7,4	875.9	81.0	
16/02/2020	05:00	-8,2	876.4	84.0	
16/02/2020	06:00	-6,7	876.8	72.0	
16/02/2020	07:00	-4,8	876.8	60.0	
16/02/2020	08:00	-2,4	876.8	60.0	

Şekil 4.1 Ön işlem öncesi veriler


Şekil 4.1’de de görüldüğü gibi veri analizi yapılmadan önce birçok üretim verisi, basınç nem ve sıcaklık değerlerinin olmadığı görülmektedir.

2020-02-15 11:0	-0.2	875.0	51.0	12.466.026.119.0
2020-02-15 12:0	0.1	874.6	49.0	167.006.027.575.0
2020-02-15 13:0	-0.4	874.8	53.0	15.524.551.091.0
2020-02-15 14:0	-0.8	874.6	54.0	18.812.844.462.0
2020-02-15 15:0	-2.0	874.8	61.0	8.553.103.940.1
2020-02-15 16:0	-3.4	875.0	69.0	3.298.572.840.9
2020-02-15 17:0	-3.9	875.5	73.0	3.021.304.786.2
2020-02-15 18:0	-5.2	875.7	80.0	12.408.469.770.0
2020-02-15 19:0	-5.8	875.9	82.0	976.633.337.870.0
2020-02-15 20:0	-6.6	876.0	84.0	962.418.815.714.0
2020-02-15 21:0	-7.3	875.8	83.0	9.701.557.507.0
2020-02-15 22:0	-7.2	875.8	82.0	9.701.557.507.0
2020-02-15 23:0	-6.8	875.9	80.0	16.746.219.550.0
2020-02-16 00:0	-6.7	875.9	79.0	2.320.432.334.1
2020-02-16 01:0	-6.5	875.7	81.0	1.055.656.422.1
2020-02-16 02:0	-6.6	875.7	83.0	976.633.337.870.0
2020-02-16 03:0	-7.5	875.9	83.0	9.701.557.507.0
2020-02-16 04:0	-7.4	875.9	81.0	10.491.788.349.0
2020-02-16 05:0	-8.2	876.4	84.0	10.059.918.008.0

Şekil 4.2 Ön işlem sonrası veriler

Şekil 4.2’de ise verilerin KNN modeli ile tahmin edildikten sonra oluşan veri setinin işlem öncesindeki boş değerlerin doldurulmuş olduğu görülmektedir.

Veri seti düzenlendikten sonra parametrelerin tahmin yöntemini ne kadar etkilediğini gözlemleyebilmek, iki değişken arasındaki ilişkinin gücünü ve birbiriyle olan ilişkisini gözlemlemek için yaygın olarak kullanılan Pearson korelasyon analizi kullanılmıştır.



Şekil 4.3 Koralasyon test sonuçları

Şekil 4.3'te Pearson korelasyon analizi sonuçlarına göre üretim miktarları ile sıcaklık, basınç, nem değerleri arasındaki ilişki kıyaslanmış olup birbiri arasındaki ilişki gözlemlenmiştir. Pearson korelasyon sonuçlarına göre mevcut değerin 0,5 değerinden büyük olması iyi olarak değerlendirilebilmektedir. Bu değerlendirmeye göre hava neminin üretim değerini en yüksek oranda etkilediği ancak ters oranda etkilediği gözlemlenmiştir. Nemden sonra en iyi değeri sıcaklık takip ederken basınç değeri ters ve düşük oranda etkileşimi etkilemektedir.

Korelasyon testine göre basınç değerinin etkilemiyor gibi görünmesi doğrusal olarak tahmin yönteminde kullanmayacağımız manasına gelmemekle birlikte modelin daha iyi sonuç vermesine katkı sağlamaktadır [83].

4.2 Tahmin Modelinin Oluşturulması ve Kıyaslanması

Bu çalışmada tahmin modelinde kullanılacak modeli belirlemek üzere birçok yöntem denenmiş olup, kullanılacak en iyi modelin analizi yapılmıştır. Derin öğrenme metotlarının iyi sonuçlar verebilmesi için çok fazla veriye ihtiyaç duyulduğundan ANN, LSTM ve CNN yöntemlerine LSTM-CNN hibrit modeli de eklenmiştir. Bununla beraber

az veri ile derin öğrenme metotlarından çok daha iyi sonuçlar verebilen makine öğrenme modellerinden 3 algoritma modeli de çalışmaya eklenmiştir. Bunlar LightGBM (Light Gradient Boosting Machine), GBR (Gradient Boosting Regressor) ve RF (Random Forest Regressor) algoritmalarıdır.

LightGBM; Histogram tabanlı bir yöntemdir. Sınıflandırma, regresyon, hızlı ve yüksek verim özelliklerine sahiptir. Ayrıca düşük kalitedeki veri ile iyi sonuçlar verebilmektedir [84].

GBR; Boosting algoritması zayıf öğrenme verilerini, güçlü verilere dönüştürerek çalışmaktadır. Aşamalı bir regresyon ağaç algoritma mantığıyla çalışmaktadır [84].

RF; Karar ağaçları olarak da adlandırılan bu algoritma sınıflandırma ve regresyon problemleri için uygundur. Genellikle güçlü tahminler için kullanılmaktadır [85].

Bu üç model de kendi arasında regresyon ve sınıflandırma özelliklerine sahip olup tahmin modeli oluşturmak için hızlı ve güçlü sonuçlar verebildiği için makine öğrenimi kıyası için uygun modeller olarak belirlenmiştir.

4.2.1 Makine Öğrenmesi Modelleri Kullanarak Tahmin Modelinin Oluşturulması

Çalışmadaki veri yetersizliğinin neticesinde, az veri ile iyi sonuçlar verebilen, çabuk öğrenebilen makine öğrenme modellerinin bu çalışma için daha iyi sonuç verebileceği düşünülmüş, regresyon tabanlı makine öğrenme modelleri olan LightGBM, GBR ve RF modelleri aynı veriler üzerinde incelenmiştir.

Oluşturulan model için, Python, scikit-learn kütüphanesinden faydalanılmıştır. Veri seti bir döngü halinde sırayla 3 modelin tahmin sonuçlarını geliştirmiştir. Oluşturulan tahminlerin sonuçları RMSE, MAE ile değerlendirilmiştir. Şekil 4.4'te makine öğrenme modelleri için oluşturulan kodun görüntüsü eklenmiştir.

```

In [1]: from pathlib import Path

import pandas as pd
from pycaret.regression import *

In [2]: DATA_PATH = Path("data/processed/")

In [3]: dataset = pd.read_csv(
    DATA_PATH / "solar-forecasting-data.csv",
    index_col="timestamp",
)
dataset.head()

Out[3]:
           temperature  pressure  humidity  solar_production
timestamp
2019-01-01 00:00:00    -6.7    877.4    86.0             0.0
2019-01-01 01:00:00    -6.7    877.4    86.0             0.0
2019-01-01 02:00:00    -6.4    877.3    85.0             0.0
2019-01-01 03:00:00    -6.1    877.0    85.0             0.0
2019-01-01 04:00:00    -6.4    877.1    84.0             0.0

In [4]: s = RegressionExperiment()
s = setup(
    data=dataset,
    target="solar_production",
    train_size=0.8,
    fold_strategy="timeseries",
    fold=5,
    session_id=42,
    experiment_name="solar-forecasting",
)

```

Şekil 4.4 Makine öğrenme modeli için oluşturulan kod görüntüsü

4.2.2 Derin öğrenme modelleri kullanarak üretilen tahminlerin değerlendirilmesi

Çalışmada derin öğrenme modellerinden olan; ANN, LSTM, CNN ve hibrit bir yaklaşım olarak CNN+LSTM modelleri kullanılmıştır. Her biri için ayrı ayrı Python’da kod yazılmış olup Keras kütüphanesinden faydalanılmıştır. Veri setinin %80’i eğitim için ayrılmış olup %20’si test için kullanılmıştır. Her bir uygulamanın ayrı ayrı incelemesi bu bölümde yer alacaktır.

4.2.2.1 ANN Modelinin İncelenmesi

ANN modeli tahmin yöntemlerinde çok sıklıkla kullanmasından dolayı bu çalışmada incelenmiştir. Yine bu uygulama için de RMSE ve MAE hataları kıyaslanmıştır. Şekil 4.5’te çalışmaya ait bir kesit eklenmiştir.

```

train_size = int ( len ( veri kümesi ) * 0.8 )
tren , test = veri kümesi . iloc [ : tren_boyutu ], veri kümesi . iloc [ tren_boyutu : ]

# Eğitim verilerini özelliklere ve etiketlere ayırın
train_X , train_y = tren . bırak ( "solar_production" , eksen = 1 ) , tren [ "solar_production" ]

# Test verilerini özelliklere ve etiketlere ayırın
test_X , test_y = test . bırak ( "solar_production" , eksen = 1 ) , test [ "solar_production" ]

# Modeli tanımlayın
model = Sıralı ()
model . ekle ( Yoğun ( 64 , input_dim = train_X . şekil [ 1 ] , aktivasyon = "relu" ))
model . ( Yoğun ( 32 , aktivasyon = "relu" )) modeli ekleyin . ekle ( Yoğun ( 1 ))

# Model modelini
derleyin . derleme (
    kayıp = "mean_squared_error" ,
    optimizör = "adam" ,
    metrikler = [
        RootMeanSquaredError () ,
        MeanAbsoluteError () ,
        MeanAbsolutePercentageError () ,
        MeanSquaredError () ,
    ] ,
)

```

Şekil 4.5 ANN modeli için kullanılan kodlar

Şekil 4.5'te hata analiz grafiklerine yer verilmiştir. Eğitim ve doğrulama değerlerinin yakınlığına göre hem MAE hem de RMSE için model oldukça iyi eğitilmiştir.

4.2.2.2 LSTM Modelinin İncelenmesi

LSTM zaman seri analizleri için popüler ve doğru sonuç veren algoritma olmasından kaynaklı bu çalışmada LSTM modeline de yer verilmiştir. Şekil 4.6'da LSTM modeli için kısa bir kod özeti eklenmiştir.

```

lstm_model = Sıralı ()
lstm_model . add (
    LSTM (
        64 ,
        input_shape = ( train_X . shape [ 1 ] , 1 ) ,
        return_sequences = True ,
        aktivasyon = "relu" ,
    )
)
lstm_model . ekle ( Bırakma ( 0.2 ))
lstm_model . ekle ( LSTM ( 32 , aktivasyon = "relu" ))
# lstm_model.add(Dropout(0.2))
lstm_model . ekle ( Yoğun ( 1 ))

lstm_modeli . derleme (
    kayıp = "mean_squared_error" ,
    optimizör = "adam" ,
    metrikler = [
        RootMeanSquaredError () ,
        MeanAbsoluteError () ,
        MeanAbsolutePercentageError () ,
        MeanSquaredError () ,
    ] ,
)

lstm_modeli . özet ()

```

Şekil 4.6 LSTM modeli için kullanılan kodlar

Şekil 4.6'ya göre MAE ve RMSE eğitim doğrulama değerleri LSTM için yüksek hata göstermiş olup bu veri seti için uygun olmadığı düşünülebilir. Ancak bu tahmin modeli için kullanılamayacağı manasına gelmemektedir.

4.2.2.3 CNN Modelinin İncelenmesi

CNN modelinin daha çok görsel ve işitsel modellerde kullanılması tercih edilmesine rağmen zaman seri analizleri için de kullanılmaktadır. Şekil 4.7'de uygulama için kullanılan kodlara yer verilmiştir.

```
cnn_fc_model = Sıralı ()
cnn_fc_model . add (
    Conv1D (
        filtreler = 32 ,
        kernel_size = 2 ,
        aktivasyon = "relu" ,
        input_shape = ( train_X . shape [ 1 ] , 1 ),
    )
)
cnn_fc_model . ( MaxPooling1D ( pool_size = 2 )) cnn_fc_model ekleyin . ekle (
    Düzleştir ()
)
cnn_fc_model . ekle ( Bırakma ( 0.2 ))
cnn_fc_model . ekle ( Yoğun ( 32 , aktivasyon = "relu" ))
cnn_fc_model . ekle ( Yoğun ( 1 ))

cnn_fc_modeli _ derleme (
    kayıp = "mean_squared_error" ,
    optimizör = "adam" ,
    metrikler = [
        RootMeanSquaredError (),
        MeanAbsoluteError (),
        MeanAbsolutePercentageError (),
        MeanSquaredError (),
    ],
)

cnn_fc_modeli _ özet ()
```

Şekil 4.7 CNN modeli için kullanılan kodlar

Şekil 4.7'ye göre CNN modelinin eğitimi, RMSE modelinde daha iyi gözlemlenmekte olup, MAE için de iyi olmasına rağmen dalgalı bir eğriye sahip olduğu gözlemlenmektedir.

4.2.2.4 CNN +LSTM Hibrit Modelin İncelenmesi

CNN ile LSTM modelinin birlikte nasıl sonuçlar vereceğini incelemek üzere hibrit bir yaklaşım ele alınmıştır. Şekil 4.8'de uygulamada kullanılan kodlara yer verilmiştir.

```

cnn_lstm_model = Sıralı ()
cnn_lstm_model . add (
    Conv1D (
        filtreler = 64 ,
        kernel_size = 2 ,
        aktivasyon = "relu" ,
        input_shape = ( train_X . shape [ 1 ], 1 ),
    )
)
cnn_lstm_model . ( MaxPooling1D ( pool_size = 2 )) ekleyin cnn_lstm_model . ekle (
    Düzleştir ()
)
cnn_lstm_model . ekle ( TekrarVektör ( 1 ))
cnn_lstm_model . ekle ( Bırakma ( 0.2 ))
cnn_lstm_model . ekle ( LSTM ( 32 , aktivasyon = "relu" ))
cnn_lstm_model . ekle ( Yoğun ( 1 ))

cnn_lstm_modeli . derleme (
    kayıp = "mean_squared_error" ,
    optimizör = "adam" ,
    metrikler = [
        RootMeanSquaredError (),
        MeanAbsoluteError (),
        MeanAbsolutePercentageError (),
        MeanSquaredError (),
    ],
)

cnn_lstm_modeli . özet ()

```

Şekil 4.8 LSTM- CNN modeli için kullanılan kodlar

Şekil 4.8'e göre CNN+LSTM hibrit yaklaşımı CNN kadar iyi sonuç vermese de tek başına LSTM'den çok daha iyi eğitilmiştir.

5. SONUÇ

Elektrik üretim tahmini, enerji sektöründe oldukça büyük öneme sahiptir. Özellikle enerji tedarikçileri, tüketiciye kesintisiz enerji iletebilmek, verimli bir şekilde elektrik üretebilmek ve kayıpları en aza indirebilmek için doğru üretim tahmini yapmak zorundadırlar. Bu tahminler, üretim maliyetlerinin optimize edilmesine, üretim hatalarının önlenmesine ve enerji dağıtımı için gerekli kaynakların doğru bir şekilde tahsis edilmesiyle enerji arzının kesintisiz bir şekilde devam etmesine, bu sayede son tüketicinin enerji kaynaklarını sürdürülebilir şekilde kullanmasına yardımcı olur. Bu sebeple, verimli çalışan bir güç şebekesinde enerji üretimindeki arzın ve enerji tüketimindeki talebin birbiriyle dengede olması beklenmektedir. Bu denge, enerji piyasasının istikrarlı şekilde devamlılığını sağlamaktadır.

Enerji üretim tahmin modelleri, artan enerji talebiyle beraber, enerjinin depolanamaması gibi sorunların önüne geçilmesi, maliyetlerin en aza indirilmesi gibi nedenlerden dolayı oldukça önem taşımaktadır. Verimliliğin artırılarak hatanın azaltılması ve sonuçların gerçeğe daha yakın olabilmesi için geliştirilen veya kullanılan tahmin modeli de oldukça önemlidir.

Bu tez çalışmasında, Türkiye genelindeki ortalama sonuçlardan yola çıkarak bölgesel bir çalışma yapılmıştır. Verilerin gerçekliğini trafo merkezinde test edebilme imkânı bulunduğu için, Sivas ili Kangal ilçesinde bulunan 9MWe kurulu gücü olan Hamal Güneş Enerji Santrali uygulama pilot bölgesi olarak seçilmiştir. Santralin Enerji Piyasaları İşletme A.Ş. (EPIAŞ)-Şeffaflık platformu üzerinden sağlanan, üretim verileri ile Meteoroloji Genel Müdürlüğü'nden alınan, aynı döneme ait sıcaklık, nem ve basınç içeren hava durumu verileri kullanılarak tahmin modelleri geliştirilmiştir. Model performansının değerlendirilmesinde öncelikle MAPE ve RMSE metrikleri kullanılmıştır ancak güneş enerji üretim verilerinde çalışılan döneme ait olan birden fazla sıfır (0) değeri içeren verilerde MAPE metriğinin iyi sonuç vermediği gözlemlenmiş olup MAPE yerine 0'ı da bir değer olarak kabul gören MAE metriği kullanılması daha uygun bulunmuştur.


Çalışmada toplam 6 farklı model geliştirilerek, gerçek zamanlı verilerle uygulamalar yapılmıştır. Bu modeller içerisinde; LSTM, ANN, CNN temelli 3 farklı derin öğrenme metodu; CNN+LSTM birlikte çalıştırılan 1 adet derin öğrenme metodlarının hibrit yaklaşımı ve son olarak 3 farklı makine öğrenme modeli; LightGBM, GBR ve RF incelenmiştir. Makine öğrenme modelleri kendi aralarında kıyaslanmış olup, sonuçta

ulařılan en iyi model, derin öğrenme modelleri ile birlikte hibrit modelle de kıyaslanmıřtır.


Çizelge 5.1 Modellerin hata oranları

Model	MAE	RMSE
LightGBM – Light Gradient Boosting Machine	1.1072	1.7479
GBR- Gradient Boosting Regressor	1.1424	1.7563
RF- Random Forest Regressor	1.1241	1.7833


Çizelge 5.1’de görüleceęi gibi incelenen bu 3 model, kendi arasında kıyaslanmış olup en iyi sonuç veren modelin 0 deęerine en yakın deęer olan LightGBM modeli olduęuna karar verilmiřtir. LightGBM modelinden sonra GBR gelmekte olup en kötü tahmin sonucu RF algoritmasına aittir. Makine öğrenmesine ait en iyi model olan LightGBM modeli, derin öğrenme metotları ile de kıyaslanmıřtır.




řekil 5.1 MAE ve RMSE analizine göre eğitim-doęrulama grafięi



Şekil 5.2 MAE ve RMSE eğitim- doğrulama grafikleri



Şekil 5.3 MAE ve RMSE eğitim-doğrulama grafikleri




Şekil 5.4 MAE ve RMSE eğitim-doğrulama grafikleri


Çizelge 5.2 Modellerin kıyaslanması

MODEL	ANN	LSTM	CNN	CNN+LSTM	LİGHTGBM
RMSE	2.1617	2.1557	2.0354	2.1036	1.7479
MAE	1.4230	1.4975	1.4654	1.6028	1.1072

Çizelge 5.2'ye göre en iyi performans sonucunu, 0'a en yakın değer olan, makine öğrenme modeli LightGBM verirken, sırasıyla ANN, CNN, LSTM ve en son olarak CNN+LSTM modeli vermektedir. Çizelge 5.2 grafiksel olarak Şekil 5.5 ve 5.6'da gösterilmiştir.



Şekil 5.5 Modellerin grafiksel olarak karşılaştırılması



Şekil 5.6 Modellerin grafiksel olarak karşılaştırılması

Şekil 5.5 ve 5.6’da verilen grafik değerlerine göre sonuçların ve hata oranlarının daha net anlaşılması mümkündür. Bu sonuçlara göre, çalışma öncesinde yapılan araştırmalara dayanılarak en iyi modelin derin öğrenme modellerinden biri olacağı beklenirken, derin öğrenme metotlarının makine öğrenmesine karşı yüksek hata oranıyla düşük verimli, gerçek değerlerden daha uzak değerler hesapladığı net olarak görülmektedir. Kullanılan veri sayısı derin öğrenme metotlarının verimliliğini artırıp azaltmakta, sonuçların iyileştirilmesinde oldukça büyük bir rol oynamaktadır. Derin öğrenme metotları kullanılarak yapılan tahmin hesaplamalarında, sonuçlar alınırken bu durumun dikkate alınması oldukça önemlidir.

Derin öğrenme metotlarının yüksek hata oranlı sonuçlar ürettiğinin tespit edilmesi ile makine öğrenme modelleri kıyaslaması yapılarak gerçek verilere en yakın değerlerin üretilmesi hedeflenmiştir. Makine öğrenme metotları ile daha az veri ile bile daha hızlı öğrenen, daha iyi performans sergileyen enerji üretim modeli geliştirilmiş ve enerji üretim tahmininde, daha az veri sayısı ile daha başarılı sonuçlara LightGBM Modeli ile ulaşıldığı tespit edilmiştir. CNN, ANN ve LSTM modellerine karşı üstünlük sağlayan LightGBM modeli enerji üretim tahmini hesaplamalarında yüksek verimli sonuçlar üretmek için kullanılabilir. Enerji üretim tahmininde arz- talep dengesinin sağlanabilmesi ve sistem kararlılığının artırılması için makine öğrenmesi ve derin öğrenme metotları birlikte kullanıldığında, makine öğrenmesinin tahmin doğruluğu dikkate alınarak hesaplamalar yapıldığında daha iyi sonuçlara ulaşılabilir.

Bu çalışmada enerji üretim tahmini modelleri geliştirmek ve elektrik piyasasında oldukça öneme sahip arz- talep dengesizliğini ortadan kaldırmak için tahmin modelleri üretmek hedeflenmiştir. Geleceğin elektrik şebekesi olan akıllı şebeke alt yapısında da gerekli olan şebeke kararlılığı, sürekliliği ve üretim tüketim dengesini sağlamak için yapılan enerjinin tahmini çalışmaları, verimi etkileyen parametrelerin artırılması ile geliştirilebilir. Mevcut yazılım programlarının hafızasının geliştirilmesi ile gelecek dönemlerde daha büyük veriler ile çalışılma imkânına ulaşılarak gelecekte daha verimli sonuçlara ulaşılması mümkündür.

KAYNAKLAR

- [1] **Kollia I. and Kollias, S.** (2018). A deep learning approach for load demand forecasting of power systems, *Proc. 2018 IEEE Symposium Series Computational Intelligence. (SSCI)* Kasım, 2018, (912–919), IEEE. doi: 10.1109/SSCI.2018.8628644.
- [2] **Yang, P., Zhao, L. and Li, Z.** (2010). A practical method of unit commitment considering wind power, *Proc. 2010 World Non-Grid-Connected Wind Power Energy Conference WNWEC 2010*, (84–90), IEEE. doi: 10.1109/WNWEC.2010.5673177.
- [3] **Jiao, R., Huang, X., Ma, X., Han, L. and Tian, W.** (2018). A model combining stacked auto encoder and back propagation algorithm for short-term wind power forecasting, *IEEE Access*, 6, 17851–17858, doi: 10.1109/ACCESS.2018.2818108.
- [4] **Zhang, W., Quan, H. and Srinivasan, D.,** (2019). An improved quantile regression neural network for probabilistic load forecasting, *IEEE Trans. Smart Grid*, 10(4), 4425–4434. doi: 10.1109/TSG.2018.2859749.
- [5] **Song, Z., Cao, Z., Wan, C. and Xu, S.** (2019). An ensemble wavelet deep learning approach for short-term load forecasting, *2019 IEEE Innov. Smart Grid Technol. - Asia (ISGT Asia)*, (1–6), no. 51761135015.
- [6] **Rajabi, R. and Estebarsari, A.** (2019). Deep learning based forecasting of individual residential loads using recurrence plots, *2019 IEEE Milan PowerTech, PowerTech 2019*, (1–5). doi: 10.1109/PTC.2019.8810899.
- [7] **Nichiforov, C., Stamatescu, G., Stamatescu, I., Calofir, V., Fagarasan, I. and Iliescu, S. S.** (2018). Deep learning techniques for load forecasting in large commercial buildings, *2018 22nd Int. Conf. Syst. Theory, Control Comput. ICSTCC 2018 - Proc.*, (492–497). doi: 10.1109/ICSTCC.2018.8540768.
- [8] **Amarasinghe, K., Marino, D. L. and Manic, M.** (2017). Deep neural networks for energy load forecasting,” *IEEE Int. Symp. Ind. Electron.*, (1483–1488), doi: 10.1109/ISIE.2017.8001465.
- [9] **Easley, M., Haney, L., Paul, J., Fowler, K. and Wu, H.** (2018). Deep neural networks for short-term load forecasting in ERCOT system,” *2018 IEEE Texas Power Energy Conf. TPEC 2018*, February 2018, (1–6). doi: 10.1109/TPEC.2018.8312073.
- [10] **Kong, W., Dong, Z. Y., Luo, F., Meng, K., Zhang, W., Wang, F., and Zhao, X.** (2018). Effect of automatic hyperparameter tuning for residential load forecasting via deep learning, *2017 Australas. Univ. Power Eng. Conf. AUPEC 2017*, vol. 2017-November, (1–6), doi: 10.1109/AUPEC.2017.8282478.
- [11] **Jiang, Q., Zhu, J.-X., Li, M. and Qing, H.-Y.** (2019). Electricity power load forecast via long short-term memory recurrent neural networks, *2018 4th Annu. Int. Conf. Netw. Inf. Syst. Comput.*, (265–268). doi: 10.1109/icnisc.2018.00060.
- [12] **Kumar, S., Hussain, L., Banarjee, S. and Reza, M.** (2018). Energy load forecasting using deep learning approach-LSTM and GRU in spark cluster, *Proc. 5th Int. Conf. Emerg. Appl. Inf. Technol. EAIT 2018*, (1–4). doi: 10.1109/EAIT.2018.8470406.
- [13] **Huang, B., Wu, D., Lai, C. S., Cun, X., Yuan, H., Xu, F., Lai, L. L., Tsang, K. F.** (2018). Load forecasting based on deep long short-term memory with consideration of costing correlated factor, *Proc. - IEEE 16th Int. Conf. Ind. Informatics, INDIN 2018*, (496–501). doi: 10.1109/INDIN.2018.8472040.
- [14] **Hosein, S. and Hosein, P.** (2017). Load forecasting using deep neural networks,

- 2017 IEEE Power Energy Soc. Innov. Smart Grid Technol. Conf. ISGT 2017. doi: 10.1109/ISGT.2017.8085971.
- [15] **Wang, Y., Lu, J. C. and Li, D. W.** (2014). Short term load forecasting based on fuzzy clustering, *Appl. Mech. Mater.*, vol. 672–674, (1413–1420). doi: 10.4028/www.scientific.net/AMM.672-674.1413.
- [16] **Hui, X., Qun, W., Yao, L., Yingbin, Z., Lei, S. and Zhisheng, Z.** (2018). Short-term load forecasting model based on deep neural network,” *2017 2nd International Conference on Power and Renewable Energy, ICPRE 2017*, (589–591). doi: 10.1109/ICPRE.2017.8390603.
- [17] **Hao, J., Liu, Y., Gu, H., Yang, D., Wang, R., Lei, J., Deng, M. and Huang, Z.** (2018, October). Short-Term power load forecasting for larger consumer based on tensorflow deep learning framework and clustering-regression model, *2nd IEEE Conference on Energy Internet and Energy System Integration, EI2 2018 - Proceedings*. 2018, doi: 10.1109/EI2.2018.8582583.
- [18] **Wang, S., Sun, Y., Zhai, S., Hou, D., Wang, P. and Wu, X.** (2019). Ultra-short-term wind power forecasting based on deep belief network, *Chinese Control Conf. CCC, 2019-July*, (7479–7483). doi: 10.23919/ChiCC.2019.8865854.
- [19] **Aparna, S.** (2019). Long short term memory and rolling window technique for modeling power demand prediction, *Proc. 2nd Int. Conf. Intell. Comput. Control Syst. ICICCS 2018, ICICCS*, (1675–1678). doi: 10.1109/ICCONS.2018.8663115.
- [20] **Kim, T. Y. and Cho, S. B.** (2019). Particle Swarm Optimization-based CNN-LSTM Networks for Forecasting Energy Consumption, *2019 IEEE Congr. Evol. Comput. CEC 2019 - Proc.*, (1510–1516). doi: 10.1109/CEC.2019.8789968.
- [21] **Öztürk, H. H.** (2017). Güneş enerjisinden fotovoltaik yöntemle elektrik üretiminde güç dönüşüm verimi ve etkili etmenler, *Elektrik Tesisat Ulusal Kongre ve Sergisi Bildirileri*, 1, 1-14.
- [22] **Varınca K. B. ve Gönüllü, M. T.** (2012). Türkiye’de güneş enerjisi potansiyeli ve bu potansiyelin kullanım derecesi, yöntemi ve yaygınlığı üzerine bir araştırma, *Mühendis ve Makina*, 4(42), 33–54.
- [23] **Acaroğlu, M.** Alternative energy source. Nobel Edition, 1253 (2007). [Online]. <<https://scholars.unh.edu/honors/420>>.
- [24] **URL-1** <<https://www.gunesfizigi.com/gunesin-temel-ozellikleri/>> Güneşin Temel Özellikleri – Güneş Fiziği, alındığı tarih: 05.04.2023.
- [25] **Naziksoy, A. S.** (2022). Bilecik ili Akpınar ve Düzdağ güneş enerji santrallerinin performanslarının pv syst programı yardımı ile karşılaştırılması. *Karabük Üniversitesi / Lisansüstü Eğitim Enstitüsü*, (Yüksek Lisans Tezi). Karabük.
- [26] **Koçak, M. E.** (2018). Büyükçekmece ilçesindeki güneş enerji santralının tasarımı ve ekonomik analizi. *Sakarya Üniversitesi Fen Bilimleri Enstitüsü*, (Yüksek Lisans Tezi). Sakarya.
- [27] **Cebeci, S.** (2017). Türkiye’de güneş enerjisinden elektrik üretim potansiyelinin değerlendirilmesi, *Kalkınma Bakanlığı İktisadi Sektörler ve Koordinasyon Genel Müdürlüğü*. (Uzmanlık Tezi), Ankara.
- [28] **Çaçan, F.** (2018). Fotovoltaik sistemlerin kurulum ve maliyet analizinin örnek bir otele uygulanması. *Fırat Üniversitesi Fen Bilimleri Enstitüsü*, (Yüksek Lisans Tezi) Elazığ.
- [29] **Girgin, M. H.** (2011). Bir fotovoltaik güneş enerjisi santralının fizibilitesi, karaman bölgesinde 5 mw’lık güneş enerjisi santrali için enerji üretim değerlendirmesi ve ekonomik analizi. *İstanbul Teknik Üniversitesi Enerji Enstitüsü*, (Yüksek Lisans Tezi), İstanbul.
- [30] **Kalogirou, S. A.** (2009). *Solar energy engineering: Processes and systems*.

- Academic press.
- [31] **Sztejnberg, A.** (2019). Priestley, scheele, lavoisier, and the burning lenses, *Rev. CENIC. Ciencias Químicas*, 50(1), 103–113.
- [32] **Özçelik, S.** Fotovoltaik PvTeknolojileri, <www.fotonik.gazi.edu.tr>, alındığı tarih: 29.06.2022.
- [33] **URL-2** Tarihte Güneş Enerjisi, <<https://www.ekolojist.com/ekoloji/tarihsel-surecte-gunes-enerjisi/>> alındığı tarih: 05.04.2023.
- [34] **Aksungur, K. M., Kurban, M., and Filik, Ü. B.** (2009). Türkiye'nin farklı bölgelerindeki güneş ışınım verilerinin analizi ve değerlendirilmesi, *Enerji. Veriml. ve Kalitesi Sempozyumu*, (3–6).
- [35] **Başar, E. E. ve Durmaz, A.** (2018). İnovasyon: Ekonomik ve sosyal eğilimler. *İmaj Yayınevi*, Ankara.
- [36] **Onat, N.** (2018). Türkiye'de yenilenebilir kaynaklardan elektrik enerjisi üretimi: Mevcut durum ve gelecek beklentileri, *Akıllı Ulaşım Sistemleri ve Uygulamaları Dergisi*, 1(1), 8–15.
- [37] **URL-3** World Solar Energy Efficiency Map, EVANERGY. <<https://en.evanergy.com.tr/detay/407-world-solar-energy-efficiency-map>>, alındığı tarih: 29.09.2022.
- [38] **Murdock, H. E., Gibb, D., André, T., Sawin, J. L., Brown, A., Ranalder, L., ... and Brumer, L.** (2021). Renewables 2021-global status report.
- [39] **Internacional Energy Agency**, (2021). Renewable Energy Market Update, p. 26.
- [40] **Geçmez, A. ve Genç, Ç.** Güneş enerji santrali üretim verilerinin meteorolojik verilere bağlı olarak yapay zeka yöntemleri ile tahmini. *International Studies on Natural and Engineering Sciences*, 39.
- [41] **Dinçer, İ., Alma, M. H., Arcaklıoğlu, E., Bayazıtöğlu, Y., Hepbaşlı, A., Kakaç, S., ... and Turan, R.** (2018). TÜBA-Güneş Enerjisi Teknolojileri Raporu.
- [42] **URL-4** GEPA. <<https://gepa.enerji.gov.tr/MyCalculator/Default.aspx>> alındığı tarih: 09.04.2023.
- [43] **URL-5** TSKB, Enerji görünümü, 2020. <<https://www.tskb.com.tr/i/assets/document/pdf/enerji-sektor-gorunumu-2020.pdf>>, alındığı tarih: 09.03.2023.
- [44] **Erdem, R., Atalay, Ö. ve Yorgun, B.** (2019). Fotovoltaik (pv) güneş enerjisi sistemleri ve çatı uygulamaları, 8. *Güneş Enerjisi Sistemleri Sempozyumu ve Sergisi*, 8-9 Kasım. (1-10). Mersin.
- [45] **Kılıç, F. Ç.** (2015). Güneş enerjisi, Türkiye'deki son durumu ve üretim teknolojileri, *Mühendis ve Makina Derg.*, 56(671), 28–40.
- [46] **Girgin, M. H.** (2011). Bir fotovoltaik güneş enerjisi santralının fizibilitesi, karaman bölgesinde 5 mw'lık güneş enerjisi santrali için enerji üretim değerlendirmesi ve ekonomik analizi. *İstanbul Teknik Üniversitesi Enerji Enstitüsü*, (Yüksek Lisans Tezi), İstanbul.
- [47] **Kantaroğlu, F.** (2013). Fotovoltaik Sistemler, *J. Chem. Inf. Model.*, 53(9), 1689–1699.
- [48] **Erkul, A.** (2010). Monokristal, polikristal ve amorf-silisyum güneş panellerinin verimliliğinin incelenmesi ve aydınlatma sistemi uygulaması, *Gazi Üniversitesi Fen Bilimleri Enstitüsü*, (Yüksek Lisans Tezi). (13–15s), Ankara.
- [49] **Ari, M., Bilgin, G. and Özcan, O.** (2017). Alternatif Enerji Kaynaklarından Güneş Enerjisinin Günlük Hayatta Kullanılabilirliği ve Güneş Enerjisi ile Çalışan Piknik Sepeti Tasarımı, *Mehmet Akif Ersoy Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 8(Özel 1), 163–171.
- [50] **URL-6** N-Tipi ve P-Tipi Yarı İletkenler - diyot.net nedir ? <<https://diyot.net/n-tipi>>

- ve-p-tipi-yari-iletkenler/>, alındığı tarih: 08.04.2023.
- [51] **Altaş İ. H.** (1998). Fotovoltaik güneş pilleri : Yapısal özellikleri ve karakteristikleri, *Enerji. Elektr. Elektromekanik-3e*, 47, 66–71.
- [52] Sarioğlu, G. ve Eke, R. (2012). Çok kristalli silisyum (mc-Si) Bir fotovoltaik modülün kısmi gölgelenme altında parametrelerinin incelenmesi. *Süleyman Demirel Üniversitesi Fen Edebiyat Fakültesi Fen Dergisi*, 7(2), 123-140.
- [53] **Süleyman, A. D. A. K., Cangı, H., and Yılmaz, A. S.** (2019). Fotovoltaik Sistemin Çıkış Gücünün Sıcaklık ve Işımaya Bağlı Matematiksel Modellemesi ve Simülasyonu. *International Journal of Engineering Research and Development*, 11(1), 316-327.
- [54] **Çıkılı, E.B.** (2017). Güneş panellerinin temel tasarımında mevcut yöntemlerin değerlendirilmesi. *İstanbul Üniversitesi Fen Bilimleri Enstitüsü*, (Yüksek Lisans Tezi), İstanbul.
- [55] **URL-7** 410 Watt Monokristal Güneş Paneli, <<https://www.3de3enerji.com.tr/lexron-410-watt-monokristal-gunes-paneli/>>, alındığı tarih: 08.04.2023.
- [56] **Kocakusak, R.** (2018). Yenilenebilir enerji kaynaklarından güneş enerjisinin, Türkiye’deki önemi ve ges kurulum araştırması,” *Maltepe Üniversitesi Sosyal Bilimler Enstitüsü*, (Yüksek Lisans Tezi). İstanbul.
- [57] **URL-8** Monokristal ve Polikristal Güneş Panelleri Arasındaki Fark Nedir? - Aydınlatma Portalı. <<https://www.aydinlatma.org/monokristal-ve-polikristal-gunes-panelleri-arasindaki-fark-nedir.html>>, alındığı tarih: 08.04.2023.
- [58] **Tascioğlu, A.** (2015). Monokristal ve polikristal güneş panellerinin bursa koşullarındaki güç performansı üzerine bir araştırma, *Uludağ Üniversitesi Fen Bilimleri Enstitüsü*. (Yüksek Lisans Tezi). Bursa.
- [59] **Oğuz, Y., Karakan, A. and Uslu, B.** (2015). Afyonkarahisar’da kurulu olan monokristal, polikristal ve ince film güneş panellerinin verimliliğinin incelenmesi,” *Tesisat Mühendisliği Dergisi*, 23(149),47–58,.
- [60] **Kandemir, Ç. ve Bayrak, M.** (2015). Fotovoltaik sistemler şebekeye bağlı olduğunda oluşan sorunlar. 6. *Enerji Verimliliği, Kalitesi Sempozyumu ve Sergisi*.
- [61] **URL-9** Şebeke Bağlantılı (ON Grid) Solar Sistemler - ESMühendisliği. <<https://www.enerjisistemlerimuhendisligi.com/sebeke-baglantili-on-grid-solar-sistemler.html>>, alındığı tarih: 08.03.2023.
- [62] **Arıcı, N. and Iskender, A.** (2020). Problems and Solutions of Grid-Connected in Photovoltaic Solar Plants, *Politeknik Dergisi*, 900(1), 215–222. doi: 10.2339/politeknik.
- [63] **URL-10** Meteoroloji Genel Müdürlüğü. <<https://mgm.gov.tr/veridegerlendirme/il-ve-ilceler-istatistik.aspx?m=SIVAS>>, alındığı tarih: 08.03.2023.
- [64] **URL-11** Untitled Page.” <<https://gepa.enerji.gov.tr/MyCalculator/pages/58.aspx>>, alındığı tarih: 08.03.2023.
- [65] **URL-12** Gürün enerji ihtisas endüstri bölgesi fizibilite raporu, Oran Kalkınma. <<https://www.kalkinmakutuphanesi.gov.tr/dokuman/gurun-enerji-ihisas-endustri-bolgesi-fizibilite-raporu/726>>, alındığı tarih: 02.04.2023.
- [66] **Kim, P.** (2017). Matlab deep learning with machine learning, neural networks and artificial intelligence. by Phil Kim.
- [67] **Gökalp, Ö. M.** (2022). Makine Öğrenmesi, 1-14. <https://www.academia.edu/68874574/Machine_Learning>, alındığı tarih: 02.04.2023.
- [68] **Nacar, E. and Erdebilli, B.** (2021). Makine öğrenmesi algoritmaları ile satış

- tahmini,” *J. Ind. Eng.*, 2(2), 307–320.
- [69] **Michael Paluszek, E. H. and Thomas, S.** (2020). *Practical MATLAB Deep Learning*, 5(3).
- [70] **Lecun, Y., Bengio, Y. and Hinton, G.** (2015). Deep learning, *Nature*, 521(7553), 436–444. doi: 10.1038/nature14539.
- [71] **Toubeau, J. F., Bottieau, J., Vallee, F. and De Greve, Z.** (2019). Deep Learning-Based Multivariate Probabilistic Forecasting for Short-Term Scheduling in Power Markets,” *IEEE Trans. Power Syst.*, 34(2), 1203–1215. doi: 10.1109/TPWRS.2018.2870041.
- [72] **Wang, Y., Huang, M., Zhao, L. and Zhu, X.** (2016). Attention-based LSTM for aspect-level sentiment classification,” *EMNLP 2016 - Conf. Empir. Methods Nat. Lang. Process. Proc.*, no. 2016, January (606–615). doi: 10.18653/v1/d16-1058.
- [73] **D. C. M. E. A. P. & G. G. Vining, Ed.,** *Linear Regression Analysis*. 2012.
- [74] **De Mol, J.** (2016). Analysis of deep learning models.
- [75] **Okwu, M. O. and Tartibu, L. K.** (2021). Metaheuristic optimization: nature-inspired algorithms swarm and computational intelligence, *Theory and Applications*, 927.
- [76] **Elsheikh, A. H. and Abd Elaziz, M. E.** (2022). Artificial neural networks for renewable energy systems and real-world applications. *Elsevier Inc.*
- [77] **Zhang, Z.** (2016). A gentle introduction to artificial neural networks, *Ann. Transl. Med.*, 4(19), 1–6. doi: 10.21037/atm.2016.06.20.
- [78] **Yegnanarayana, B.** (1994). Artificial neural networks for pattern recognition, *Sadhana*, 19(2), 189–238. doi: 10.1007/BF02811896.
- [79] **Sharma, S. Sharma, S. and Anidhya, A.** (2017). Understanding Activation Functions in Neural Networks,” *Int. J. Eng. Appl. Sci. Technol.*, 4(12), 310–316.
- [80] **Khair, U., Fahmi, H., Al Hakim, S. and Rahim, R.** (2017). Forecasting error calculation with mean absolute deviation and mean absolute percentage error, *J. Phys. Conf. Ser.*, 930(1). doi: 10.1088/1742-6596/930/1/012002.
- [81] **Noyan, M.** Regresyon ve sınıflandırmada hata metrikleri, Deep Learning Türkiye Medium. <<https://medium.com/deep-learning-turkiye/regresyon-ve-sınıflandırmada-hata-metrikleri-143a40c6b656>>, alındığı tarih: 08.03.2023.
- [82] **Thomas, M.** (2020). A new encryption algorithm based on Fibonacci Polynomial and matrices, *Fiabilité, Maint. prédictive Vib. des Mach.*, 39(5), 259–302. doi: 10.2307/j.ctv18ph9kr.16.
- [83] **URL-13** Pearson Korelasyon Katsayısı: Ücretsiz Örnekler, QuestionPro. <<https://www.questionpro.com/blog/tr/pearson-korelasyon-katsayisi-giris-formul-hesaplama-ve-ornekler/>>, alındığı tarih: 08.03.2023.
- [84] **Zhang, D. and Gong, Y.** (2020). The comparison of LightGBM and XGBoost coupling factor analysis and prediagnosis of acute liver failure, *IEEE Access*, 8. doi: 10.1109/ACCESS.2020.3042848.
- [85] **Migabo, M. E., Djouani, K., Kurien, A. M. and Olwal, T. O.** (2015). A stochastic energy consumption model for wireless sensor networks using GBR techniques, *AFRICON 2015, Addis Ababa, Ethiopia*, (1-5), doi: 10.1109/AFRCON.2015.7331987.
- [86] **Irfan, A. S. M., Bhuiyan, N. H., Hasan, M. and Khan, M. M.** (2021). Performance analysis of machine learning techniques for wind speed prediction, *2021 12th International Conference on Computing Communication and Networking Technologies (ICCCNT)*, (1-6), Kharagpur, India, doi: 10.1109/ICCCNT51525.2021.9579564.