

T.C.
SİNOP ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
DISİPLİNLERARASI NÜKLEER ENERJİ VE ENERJİ
SİSTEMLERİ ANABİLİM DALI



HİBRİT YAPAY ZEKÂ MODELİ İLE SİNOP İLİNİN GÜNEŞ
ENERJİ POTANSİYELİNİN HESAPLANMASI

ÖZGE DEMİRCİ

YÜKSEK LİSANS TEZİ

DANIŞMAN

Prof. Dr. Murat SARIKAYA

SİNOP – 2025

TEZ KABUL

Özge DEMİRCİ tarafından hazırlanan “**HİBRİT YAPAY ZEKÂ MODELİ İLE SİNOP İLİNİN GÜNEŞ ENERJİ POTANSİYELİNİN HESAPLANMASI**” başlıklı bu çalışma, 16.01.2025 tarihinde yapılan savunma sınavı sonucunda başarılı bulunarak, jürimiz tarafından **YÜKSEK LİSANS tezi** olarak kabul edilmiştir.

Başkan

Doç. Dr., Şenol ŞİRİN
Düzce Üniversitesi / Mühendislik Fakültesi

**Üye
(Danışman)**

Prof. Dr., Murat SARIKAYA
Sinop Üniversitesi / Mühendislik ve Mimarlık Fakültesi

Üye

Doç. Dr., Mustafa Kemal BALKİ
Sinop Üniversitesi / Mühendislik ve Mimarlık Fakültesi

Enstitü Müdürü

Doç. Dr. Hüseyin Turan ARAT

ETİK BEYANI

Tez Yazım Kurallarına uygun olarak hazırladığım bu tez çalışmasında; tez içinde sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiğimi, tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu, tez çalışmasında yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi, kullanılan verilerde herhangi bir değişiklik yapmadığımı, bu tezde sunduğum çalışmanın özgün olduğunu, bildirir, aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi beyan ederim.

Özge DEMİRCİ

ÖZET

YÜKSEK LİSANS TEZİ

HİBRİT YAPAY ZEKÂ MODELİ İLE SİNOP İLİNİN GÜNEŞ ENERJİ POTANSİYELİNİN HESAPLANMASI

ÖZGE DEMİRCİ

SİNOP ÜNİVERSİTESİ LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
DISİPLİNLERARASI NÜKLEER ENERJİ VE ENERJİ SİSTEMLERİ
ANABİLİM DALI

DANIŞMAN:PROF. DR. MURAT SARIKAYA

Günümüzde dünya'nın enerjiye duyduğu ihtiyaç teknolojik gelişme, sanayileşme gibi faktörlere de bağlı olarak gün geçtikçe artmaktadır. Bu artış enerji ihtiyacını karşılamak için sınırlı kaynakların yetersiz kaldığı bir noktaya ulaşmıştır. Bu durum enerji üretimi ile tüketimi arasındaki farkı daha da açmış ve yenilenebilir enerji kaynaklarına olan talebi artırmıştır. Modern yaşamın temel taşı haline gelen enerji, yapay zekâ gibi teknolojik gelişmeler sayesinde daha verimli ve sürdürülebilir duruma gelmiştir. Çalışma kapsamında yapay zekânın yenilikçi yaklaşımı olan ve farklı algoritmaların birleştirilmesiyle oluşturulan hibrit model tasarlanmıştır. Sinop ilinin güneş enerji potansiyeli tasarlanan hibrit çok katmanlı algılayıcı (MLP)-uzun kısa dönemli bellek (LSTM) modeli kullanılarak hesaplanmaya çalışılmıştır. Girdi parametreleri olarak bulut kapsamı, rüzgâr hızı, görünürlük, basınç, rakım, sıcaklık ve nem kullanılmıştır. Geliştirilen model gerçek veriler ile eğitilmiş ve test edilmiştir. Geliştirilen hibrit modelin tek algoritmadan oluşan modellere göre başarı oranı incelenmiştir. MLP Model-1'in mutlak yüzde hatası (MAPE) değeri %21,965 hata payı ve 0,84123 R^2 değeri olarak hesaplanmıştır. MLP Model-2'nin MAPE değeri %23,5132 hata payı ve 0,83325 R^2 değeri olarak hesaplanmıştır. LSTM modelinin MAPE değeri %29,2656 hata payı ve 0,77333 R^2 değeri olarak hesaplanmıştır. En doğru ve güvenilir sonuçlar ise geliştirilen hibrit modelde elde edilmiştir. MAPE değeri %8,4888 hata payı ve 0,96935 R^2 değeri olarak hesaplanmıştır. Bu çalışma, hibrit modelin mevcut yöntemlere göre üstün bir performans sergilediğini göstermiştir. Elde edilen sonuçlar, modelin güneş enerjisi potansiyelini tahmin etme konusunda umut vadettiğini göstermektedir. Geliştirilen hibrit model kullanılarak farklı illerde güneş enerji potansiyeli tahmini yapılabilmektedir.

ANAHTAR KELİMELER: Yapay Sinir Ağlar; Yenilenebilir Enerji; Sinop İli; Güneş Enerji Potansiyeli; Hibrit Model

Ocak 2025, 97 Sayfa

ABSTRACT

MSC THESIS

CALCULATION OF SOLAR ENERGY POTENTIAL OF SİNOP PROVINCE WITH HYBRID ARTIFICIAL INTELLIGENCE MODEL

ÖZGE DEMİRCİ

**SINOP UNIVERSITY INSTITUTE OF GRADUATE PROGRAMS
DEPARTMENT OF INTERDISCIPLINARY NUCLEAR ENERGY AND
ENERGY SYSTEMS**

SUPERVISOR:PROF. DR. MURAT SARIKAYA

Today, the world's demand for energy is increasing daily due to technological advancements and industrialisation. This rise has reached a point where limited resources are insufficient to meet energy needs. This situation has further widened the gap between energy production and consumption, amplifying the necessity for renewable energy sources. Energy, the cornerstone of modern life, has become more efficient and sustainable thanks to technological innovations like artificial intelligence. Within the scope of this study, a hybrid model—an innovative approach to artificial intelligence developed by combining various algorithms—has been designed. The solar energy potential of Sinop province was calculated using the hybrid Multi-Layer Perceptron (MLP)-Long Short-Term Memory (LSTM)model. The input parameters included cloud coverage, wind speed, visibility, pressure, altitude, temperature, and humidity. The developed model was trained and tested with precise data. The hybrid model's success rate was analysed compared to single-algorithm models. The absolute percentage error (MAPE) of MLP Model-1 was determined to be a 21.965% error margin, with an R^2 value of 0.84123. MAPE of MLP Model-2 was established at a 23.5132% margin of error, with an R^2 value of 0.83325. MAPE of the LSTM model was calculated at a 29.2656% margin of error, with an R^2 value of 0.77333. The most accurate and reliable results were obtained from the developed hybrid model, which yielded a MAPE value of 8.4888% error margin, with an R^2 value of 0.96935. This study has demonstrated that the hybrid model outperforms existing methods. The results obtained indicate that the model shows promise in estimating solar energy potential. The developed hybrid model may be employed to assess solar energy potential across various provinces.

KEYWORDS:Artificial Neural Networks; Renewable Energy; Sinop Province; Solar Energy Potential; Hybrid Model

January 2025, 97 Page

TEŞEKKÜR

Yüksek lisans öğrenimim sırasında ve tez çalışmam boyunca gösterdiği her türlü destek ve yardımlarından dolayı değerli hocam Prof. Dr. Murat SARIKAYA'ya teşekkür ederim.

Ayrıca tez savunma sürecimde sunmuş oldukları öneriler ile çalışmamın gelişmesine katkı sağlayan Sayın Doç. Dr. Şenol ŞİRİN ve Sayın Doç. Dr. Mustafa Kemal BALKİ'ye teşekkür ederim.

Çalışmamda kullandığım verilerin elde edilmesinde emeği geçen Enstitü çalışanlarına ve Sinop ili Meteoroloji Müdürlüğüne teşekkür ederim. Bu tezin hazırlanma sürecinde yanımda olan, maddi ve manevi destekleriyle her an bana güç veren sevgili aileme ve canım eşim Onur DEMİRCİ'ye en içten teşekkürlerimi sunarım.



Özge DEMİRCİ

İÇİNDEKİLER

Sayfa

TEZ KABUL	ii
ETİK BEYANI.....	iii
ÖZET	iv
ABSTRACT.....	v
TEŞEKKÜR	vi
İÇİNDEKİLER	vii
TABLolar DİZİNİ.....	ix
ŞEKİLLER DİZİNİ.....	x
SİMGELER VE KISALTMALAR DİZİNİ.....	xii
1. GİRİŞ	1
2. LİTERATÜR TARAMASI.....	3
2.1. Yapay Zekânın Enerji Alanında Kullanımı	3
2.1. Türkiye’de Güneş Enerjisi Potansiyeli Üzerine Yapılan Çalışmalar.....	6
3. ENERJİ.....	10
3.1. Enerji Kaynakları ve Türleri	12
3.1.1. Yenilenemez enerji kaynakları	12
3.1.2. Yenilenebilir enerji kaynakları	13
3.1.2.1. Hidrolik enerji.....	13
3.1.2.2. Güneş enerjisi	14
3.1.2.3. Rüzgâr enerjisi	20
3.1.2.4. Biyokütle enerjisi.....	21
3.1.2.5. Jeotermal enerjisi	21
3.1.2.6. Deniz enerjisi	22
3.1.2.7. Hidrojen enerjisi	22
3.2. Türkiye’de Güneş Enerjisi Potansiyeli	23
4. YAPAY ZEKÂ	26
4.1. Yapay Zekâ Teknikleri	26
4.1.1. Makine öğrenmesi.....	26
4.1.2. Derin öğrenme	27
4.1.3. Yapay sinir ağları.....	28

4.1.3.1. Tek katmanlı yapay sinir ağıları	31
4.1.3.2. Çok katmanlı algılayıcı yapay sinir ağıları (MLP)	32
4.1.3.3. İleri beslemeli algılayıcılar	33
4.1.3.4. Geri beslemeli algılayıcılar	33
4.1.3.5. Uzun Kısa Süreli Bellek (LSTM)	34
5. METODOLOJİ	36
5.1. Veri Seti	36
5.2. Kullanılan Yapay Zekâ Modelleri	37
5.3. Model Eğitim ve Test Süreci	42
5.4. Kullanılan Performans Ölçütleri	43
5.5. Yazılım ve Donanım Altyapısı	43
5.6. Sınırlılıklar ve Varsayımlar	44
6. BULGULAR VE SONUÇLAR	45
6.1. Modelin Tasarlanması ve Eğitilmesi	45
6.1.1. MLP Model-1	45
6.1.2. MLP Model-2	47
6.1.3. LSTM Modeli	49
6.1.4. MLP-LSTM Hibrit Modeli	51
6.2. Sinop İli İçin Güneş Enerji Potansiyeli	54
7. SONUÇ VE ÖNERİLER	59
KAYNAKLAR	61
EKLER	67
EK 1 Sinop İli Havaalanı İstasyonunun Ham Hava Durumu Verileri	67
EK 2 Dönüşüm Uygulanmış Sinop Hava Durumu Verileri	76
ÖZGEÇMİŞ	85

TABLÖLAR DİZİNİ

	Sayfa
Tablo 4.1 Biyolojik sinir sistemi elemanlarının yapay sinir sistemindeki karşılığı.....	29
Tablo 5.1 Parametrelerin birimleri.....	37
Tablo 6.1 Model parametreleri ve performans değeri	53
Tablo 6.2 Bazı gerçek değerler ve hibrit modelin tahmin sonuçları.....	54
Tablo 6.3 Günlere göre tahmin sonuçları	56



ŞEKİLLER DİZİNİ

Sayfa

Şekil 3.1 Elektrik enerjisi kurulu gücünün kaynaklara göre dağılımı	11
Şekil 3.2 Enerji kaynağı çeşitleri	12
Şekil 3.3 Hidroelektrik santral	14
Şekil 3.4 Güneş enerjisi kurulu gücünün yıllara göre değişim grafiği	15
Şekil 3.5 Güneş enerjisinin toplam kurulu güç içeriği yıllık oranı grafiği	15
Şekil 3.6 FV hücre, modül ve dizi tasarımları	16
Şekil 3.7 FV hücresinin çalışma ilkesi.....	17
Şekil 3.8 CSP teknolojileri, LFC doğrusal fresnel kollektör, PTC parabolik geçmeli kollektör, DC çanak kollektör, ST güneş kulesi	19
Şekil 3.9 Rüzgâr türbini	20
Şekil 3.10 Jeotermal enerji santrali.....	22
Şekil 3.11 Florida'daki NASA Kennedy Uzay Merkezi'ndeki bir sıvı hidrojen tankı... 23	
Şekil 3.12 Türkiye güneş enerjisi potansiyeli atlası	24
Şekil 3.13 Türkiye global radyasyon değerleri	25
Şekil 3.14 Türkiye güneşlenme süreleri	25
Şekil 4.1 Yapay zekâ, makine öğrenmesi ve derin öğrenme arasındaki ilişki.....	28
Şekil 4.2 Yapay sinir hücresi	29
Şekil 4.3 Tek Katmanlı Algılayıcı Modeli.....	32
Şekil 4.4 Çok katmanlı algılayıcı modeli.....	32
Şekil 4.5 İleri beslemeli yapay sinir ağı modeli.....	33
Şekil 4.6 Geri beslemeli yapay sinir ağı modeli	34
Şekil 4.7 LSTM ünitesinin yapısı	35
Şekil 5.1 MLP model-1'in yapısı.....	38
Şekil 5.2 MLP model-1'in yapısal analizi	38
Şekil 5.3 MLP model-2'nin yapısı.....	39
Şekil 5.4 MLP model-2'nin yapısal analizi	39
Şekil 5.5 LSTM model yapısı	40
Şekil 5.6 LSTM model yapısal analizi.....	40
Şekil 5.7 MLP-LSTM hibrit model yapısı.....	41
Şekil 5.8 MLP-LSTM hibrit modelin yapısal analizi	42

Şekil 6.1 MLP model-1'in RMSE değerleri	45
Şekil 6.2 MLP model-1'in Loss değerleri	46
Şekil 6.3 MLP model-1'in RMSE performansı	46
Şekil 6.4 MLP model-1'in hata histogramı	47
Şekil 6.5 MLP model-2'nin RMSE değerleri	47
Şekil 6.6 MLP model-2'nin Loss değerleri	48
Şekil 6.7 MLP model-2'nin performansı	48
Şekil 6.8 MLP model-2'nin hata histogramı	49
Şekil 6.9 LSTM modelin RMSE değerleri	49
Şekil 6.10 LSTM modelin RMSE değerleri	50
Şekil 6.11 LSTM modelin performansı	50
Şekil 6.12 LSTM modelin hata histogramı	51
Şekil 6.13 MLP- LSTM hibrit modelin RMSE değerleri	51
Şekil 6.14 MLP- LSTM hibrit modelin Loss değerleri	52
Şekil 6.15 MLP- LSTM hibrit modelin performansı	52
Şekil 6.16 MLP- LSTM hibrit modelin hata histogramı	53
Şekil 6.17 Sinop ili için 1 yıllık güneş enerji potansiyeli tahmini	55
Şekil 6.18 Sinop ili global radyasyon değerleri	55
Şekil 6.19 Sinop ili güneşlenme süreleri	56

SİMGELER VE KISALTMALAR DİZİNİ

Simgeler

CO₂	: Karbon Dioksit
kWh/m²	: Kilowattsaat/metrekare
MW	: Megawatt
kWp	: Kilowatt peak
W/m²	: Watt/metrekare
kW	: Kilowatt
kWh	: Kilowattsaat
Mph	: Mil/saat
incHg	: İnç cıva
hPa	: Hektopaskal
H₂/CO	: Hidrojen karbon monoksit oranı
CONNET	: Metan dönüşüm oranı
C%	: Karbon yüzdesi

Kısaltmalar

MLP	: Multi-Layer Perceptron (Çok Katmanlı Algılayıcı)
LPG	: Likit petrol gazı
HES	: Hidroelektrik santrali
FV	: Fotovoltaik
YSA	: Yapay Sinir Ağı
CNN	: Convolutional Neural Networks (Evrişimli Sinir Ağları)
RMSE	: Root Mean Squared Error (Kök Ortalama Kare Hatası)
UV	: Ultraviyole
MAPE	: Mean Absolute Percentage Error (Ortalama Mutlak Yüzde Hatası)
LNG	: Liquefied Natural Gas (Sıvılaştırılmış Doğalgaz)
CSP	: Concentrated Solar Power (Yoğunlaştırılmış Güneş Enerjisi)
ÇKA	: Çok Katmanlı Algılayıcı
LSTM	: Kısa Uzun Süreli Bellek
SVR	: Destek Vektör Regresyonu
PTF	: Piyasa Takas Fiyatı
LR	: Doğrusal Regrasyon
GSR	: Küresel Güneş Radyasyonu
SMA	: Slime-Mould Algoritması
DBN	: Derin İnanç Ağı

1. GİRİŞ

Gelecek yüzyıl için çevrenin korunması şarttır. Küresel ısınma, enerji sorununu daha da karmaşık hale getirmiştir. Yıllardır dünyanın ortalama yüzey sıcaklığı ve atmosferdeki CO₂ miktarı artmaktadır. Bu keskin yükseliş, fosil yakıtların dünyanın birincil enerji kaynağı haline gelmesi ve küresel nüfustaki büyük artış sebebiyledir (Smalley, 2005).

Dünya'nın enerjiye duyduğu ihtiyaç teknolojik gelişme, sanayileşme gibi faktörlere de bağlı olarak gün geçtikçe artmaktadır. Enerji elde etmek için en çok tercih edilen fosil yakıtların oluşturduğu olumsuz etkiler ve tükenbilir oluşları, ülkelerin farklı yenilenebilir ve doğal enerji kaynaklarına yönelmesine sebep olmuştur. Ayrıca bu enerji kaynakları hakkında yapılan araştırmalar haricinde mevcut enerji kaynaklarının da daha verimli kullanılması günümüzde alternatif bir enerji kaynağı olarak görülmektedir. Yenilenebilir enerji kaynakları sürdürülebilirlik ve artan enerji ihtiyacını karşılamada büyük bir öneme sahiptir. Bu enerji kaynaklarından biri olan güneş enerjisi, çevre dostu olup, sonsuz bir potansiyele sahiptir. Teknolojik gelişmelerle birlikte kullanım alanları artan güneş enerjisi potansiyeli, hava durumu ve coğrafi konum gibi çeşitli faktörlere bağlı olarak farklılıklar gösterebilir. Güneş enerjisi verimi, bölgesel olarak potansiyelin doğru bir şekilde tahmin edilmesiyle sağlanır. Güneş enerjisi potansiyelinin doğru şekilde tahmin edilmesi, yapılacak yatırım ve enerji planlanması açısından büyük önem taşır. Bulut kapsamı, görünürlük, sıcaklık, nem, rüzgâr hızı, basınç ve rakım gibi meteorolojik faktörlerin doğru bir şekilde analiz edilmesi geleneksel istatistiksel yöntemlerle yetersiz kalmaktadır. Bu noktada son yıllarda gelişen yapay zekâ teknikleri, enerji sektörü dahi birçok alanda çözüm sunmaktadır.

Yapay zekâ teknolojisinin enerji sektöründe kullanılması, işletmelerin, endüstrilerin ve ülkelerin maliyet ve zaman açısından önemli tasarruflar yapmasına olanak tanır. Bununla birlikte verimlilik artar, hatalar azaltılır veya ortadan kaldırılır, üretim hızı artar ve refah seviyeleri yükselir. Yani, yapay zekânın enerji sektörüne entegrasyonu, sektörün daha verimli şekilde çalışmasını sağlar (Göde vd., 2023).

Yapay zekâ teknikleri büyük ve karmaşık veri setlerini analiz etme ve karmaşık örüntüleri tanıma konusunda yardımcı olmaktadır. Yapay zekâ alanının alt dalı olan yapay sinir ağları veriler arasındaki karmaşık verileri öğrenir ve bu yeteneği sayesinde geleneksel yöntemlerin ilerisinde, tahmin ve sınıflandırmada yüksek doğruluk sunar. Bu modeller farklı alanlarda başarı gösterse de algoritmaların birbirlerine göre olan üstünlüklerini

dikkate alarak birleřtirme alıřmaları son yıllarda n plana ıkmıřtır. İki veya daha fazla algoritmanın birleřtirilmesiyle elde edilen yapılar hibrit model olarak adlandırılmaktadır. Hibrit modeller geliřtirilerek, modellerin gvenirlilięi, bařarı oranları ve esneklik zellikleri arttırılması amalanmıřtır.

lkemizde ortalama yıllık toplam gneřlenme sresi 2741 saat ve ortalama yıllık toplam ısınım deęeri $1.527,46 \text{ kWh/m}^2$ dir (Anonim, 2022b). Bu durum lkemizi gneř enerji potansiyeli aısından nemli bir konuma getirmektedir. Blgesel olarak bakıldığında, Karadeniz blgesi gneřlenme sresi aısından dięer coęrafi blgelere gre daha dřk potansiyele sahip olsa da gneřten byk lde enerji reten birok Avrupa lkesinden daha fazla gneřlenme sresine sahiptir (Tekin, 2023). Blgesel ve yerel enerji planlamasında illerin potansiyelinin belirlenmesi yatırım ve kaynakların verimli kullanılması aısından olduka nemlidir. Bu nedenden dolayı Sinop ilinin gneř enerji potansiyelinin ve kapasitesinin hesaplanması planlamaların yapılmasında nemli bir yere sahiptir. Sinop'un coęrafi zelliklerinin ve gneřlenme potansiyeli gz nnde bulundurularak, blgedeki enerji politikalarının daha verimli ve srdrlebilir bir řekilde yn verebilmek iin bu arařtırma gerekleřtirilmiřtir.

Bu alıřmada, gerek bir veri seti kullanılarak oluřturulan MLP, LSTM ve bu iki modelin birleřtirilmesiyle zgn olarak tasarlanan MLP-LSTM hibrit modeli eęitilerek test edilmiřtir. En iyi sonucu veren eęitilmiř hibrit model ile Sinop ili iin bir yıllık hava durumu verileri kullanılarak gneř enerji potansiyeli hesaplanmaya alıřılmıřtır.

2. LİTERATÜR TARAMASI

2.1. Yapay Zekânın Enerji Alanında Kullanımı

Bu bölümde, farklı alanlarda kullanılan yapay sinir ağlarının kullanımı ve yenilenebilir enerjide uygulanabilirliği konusunda yapılan araştırmalar incelenmiştir.

Ahmed vd., (2022) ve arkadaşları enerji sistemlerinde yapay zekâ kullanımı üzerine genel bir çalışma yapmıştır. Yapay zekâ kullanılarak makine arızalarının azaltılması, maliyetlerin düşürülmesi ve üretimin artırılması gibi avantajların olduğu vurgulanmıştır. Bu çalışmada, Google'ın kolu olan DeepMind, rüzgâr türbinlerinde hava durumu ve geçmiş rüzgâr türbini verilerini kullanarak 36 saat önceden enerji üretimini tahmin etmek için bir sinir ağı modelinin geliştirildiğinden bahsedilmiştir.

Llera vd., (2002) ve arkadaşlarının kısa vadeli rüzgâr hızını tahmin etmek için yaptıkları çalışmada, meteoroloji istasyonundan aldıkları rüzgâr hızı, sıcaklık, nem, basınç gibi değerleri kullanarak, 20 dakika öncesinden rüzgâr hızını minimum hata ile tahmin edebilen sinir ağı elde edilmiştir. Seçilen ağ modeli, gizli katmanında 6 nöron ve 3 girişli bir yapıya sahiptir ve genelleme yeteneği açısından en iyi sonuçları vermiştir.

Bosch vd., (2008) ve arkadaşları, dağlık bir alan üzerinde günlük güneş ışınımını yapay sinir ağlarını kullanarak tahmin etmişlerdir. Bu çalışmada, ağın girdileri otomatik alaka belirleme yöntemiyle seçilmiş ve 12 farklı istasyonda ölçülen 3 yıllık veri seti kullanılmıştır. Sonuç olarak, Yapay sinir ağlarının karmaşık dağlık arazilerde güneş radyasyonu seviyelerini tek bir radyometrik istasyon verisinden hesaplamak için etkili bir yöntem olduğu görülmüştür.

Makas ve Karaatlı (2016), Aksu ilçesi sınırlarındaki Yenice deresinden beslenen bir hidroelektrik santralin, 2007-2013 yılları arasındaki meteorolojik verilerle 2014 yılına ait 12 aylık elektrik üretimini yapay sinir ağları ile tahmin etmiştir. Kullanılan yapay sinir ağının 36 adet girdi ve on iki adet çıktı değişkeni vardır. Girdi olarak aylık ortalama yağış, aylık ortalama nisbi nem ve aylık ortalama debi verileri kullanılmıştır. Sonuç olarak elde edilen yüksek doğrulukta YSA ile 2015 yılı için de elektrik üretimi tahmin edilmiştir.

Koyuncu ve Yılmaz (2019), Afyon'da 2,7 MW kapasiteli Binary çevrim jeotermal güç santralinin optimizasyonu ve termoeconomik performansı YSA kullanılarak gerçekleştirilmiştir. Bu YSA' da 3 girdi ve 5 çıktı değişkeni vardır.

Shi vd., (2019) ve arkadaşları, Çin’ de bulunan 660 MW’ lık kömürle çalışan bir elektrik santralinde, YSA modelleri kullanılarak ısı verimliliği yaklaşık olarak %0,4 iyileştirme sağlamışlardır. Bu iyileştirme sayesinde yılda 2,6 milyar dolar tasarruf sağlanabileceği öne sürülmüştür.

Elsheikh vd., (2019) ve arkadaşları çeşitli güneş enerjisi cihazlarının performansının modellenmesinde veya tahmin edilmesinde yapay sinir ağlarının (YSA) nasıl uygulandığını incelemişlerdir. Güneş enerjisi cihazlarının modellenmesinde YSA’ları, diğer modelleme tekniklerine göre hem daha az deneyle daha yüksek doğruluk sağladığını hem de hesaplama süresinin kısa olması gibi avantajlarının olduğundan bahsedilmiştir. Güneş enerjisi uygulamalarında, basitliği nedeniyle yaygın olarak MLP kullanıldığı ve ayrıca diğer YSA modellerinin de bu uygulamalarda gün geçtikçe daha çok tercih edildiği sonucuna varılmıştır.

Kamthania ve Tiwari (2012), yarı saydam hibrit fotovoltaiik termal çift geçişli hava kollektörünün performans analizini yapay sinir ağı kullanarak gerçekleştirmiştir. Çevre hava sıcaklığı, küresel güneş radyasyonu, difüze radyasyon ve çok gün sayısı giriş parametresi olarak alınmıştır. Eğitim için yaklaşık 2000 veri seti kullanılmıştır. Ağ, ileri beslemeli geri yayılım algoritması kullanılarak eğitilmiştir. 15 nöronlu tek gizli katman kullanılmıştır. Giriş ve çıkış katmanlarında ise 4 nöron bulunmaktadır. Analiz sonucunda, analitik yöntemler ile YSA modelinden elde edilen değerlerin uyumlu olduğu görülmüştür.

Premalatha ve Amirtham (2016), çalışmalarında Hindistan’daki aylık ortalama küresel güneş ışımasını tahmin etmek için her biri dört geri yayılım algoritmasına sahip iki farklı yapay sinir ağı modeli geliştirmiştir. Hindistan’da beş istasyondan 10 yıl süreyle meteorolojik veriler toplanıp ağ eğitilmiştir. YSA model I’ de eğitim için dört istasyon verisi kullanılırken, model II’ de beş istasyon verisi hem eğitim hem de test için kullanılmıştır. YSA model II’ nin %98-99 doğrulukla ölçüm verilerine en yakın tahminleri yaptığı görülmüştür. Model II 24 nöronlu ve 1 gizli katmandan oluşmaktadır. Bu çalışma ile Hindistan’da aylık ortalama güneş enerji potansiyelini kesin olarak tahmin etmek için YSA modelinin güvenilir olduğu sonucuna varılmıştır.

Alomari vd., (2018) ve arkadaşları Ürdün’de yaptıkları çalışmada YSA kullanarak güneş fotovoltaiik enerjisi ve güneş ışımasını değerlerini kullanarak ertesi gün üretilen gücü tahmin etmek için model geliştirmeyi amaçlamışlardır. Güneş fotovoltaiik güç çıktıları

264 kWp gücündeki bir santralden alınmıştır. Gizli katman sayısı 1’den 30’ a kadar artırılmış ve optimum performans 22 gizli katmanda elde edilmiştir. Toplamda 19249 veri kullanılarak eğitilen YSA parametreleri belirlenmiştir. 24 saatlik güç tahmininde RMSE değeri 0,0721 olarak bulunmuştur. Bu sonuç, makine öğrenimi algoritmaları kullanılarak hava koşullarına dayalı güç üretimi tahmini için umut verici olmuştur.

Oyucu ve Herdem (2024), çalışmalarında CNN-LSTM hibrit derin öğrenme modelini biyogaz reform süreçlerinde çıktı parametrelerini tahmin etmek için kullanmışlardır. Bu model, Evrişimli Sinir Ağları ile veri setindeki karmaşıklıkları öğrenirken, bir yandan da Uzun Kısa Süreli Bellek (LSTM) ile zaman serisi verilerindeki uzun süreli bağımlılıkları modellemiştir. Bu çalışmada metan dönüşüm oranı (CONMET), hidrojen-karbon monoksit oranı (H_2/CO), hidrojen-metan oranı (H_2/CH_4) ve karbon yüzdesi (C%) gibi çıktı verilerinin tahmini üzerine odaklanılmıştır. 750 eğitim sonucunda CONMET için MAE değeri 0,1311, MAPE değeri 0,0036 ve RMSE değeri 0,1905 olarak hesaplanmıştır. CNN-LSTM modeli, destek vektör regresyonu ve yalnızca LSTM kullanılan modellerle karşılaştırıldığında, daha karmaşık ilişkileri modelleme kapasitesi özelliği ile üstün performans göstermiştir.

Kaysal vd., (2023) ve arkadaşları çalışmalarında, hibrit bir derin öğrenme modeli olan CNN-BLSTM’yi kullanarak rüzgâr enerjisinin elektrik üretimindeki dalgalı yapısını daha doğru tahmin edebilmeyi hedeflemişlerdir. Önerilen modelde Evrişimli Sinir Ağı (CNN) ve Çift Yönlü Uzun Kısa Bellek (BLSTM) mimarileri birleştirilmiştir. Modelin eğitimi ve testi için saatlik frekansta ölçülmüş 26.280 adet gerçek zamanlı veri kullanılmıştır. CNN-BLSTM modelinin, yalnızca BLSTM modeline göre daha yüksek bir başarı oranı elde ettiği gözlemlenmiştir. Oluşturulan modelin başarı oranı (R^2) 0,984 olarak hesaplanmıştır. Bu değer de, modelin rüzgâr enerjisinden elde edilen elektrik üretimini tahmin etmede yüksek oranda başarılı olduğunu göstermektedir.

Şimşek (2024), yaptığı çalışmada Türkiye elektrik piyasasında piyasa takas fiyatını (PTF) tahmin etmek amacıyla makine öğrenmesi ve derin öğrenme yöntemlerini inceleyerek karşılaştırmıştır. Veri seti, rüzgâr, güneş, ithal kömür, linyit, jeotermal, doğalgaz, baraj ve biyokütle gibi çeşitli enerji kaynaklarından üretilen saatlik elektrik miktarlarını ve saatlik elektrik talebinden oluşmaktadır. 17 Nisan 2023 ile 16 Nisan 2024 tarihleri arasında toplanan toplam 8772 saatlik veri kullanılmıştır. Çalışmada kullanılan yöntemler, LSTM, XGBoost, Random Forest (RF), Destek Vektör Regresyonu (SVR) ve Doğrusal Regresyon (LR) ‘dur. Bunların arasında en yüksek başarı oranına sahip olan

XGBoost modelinde MSE: 0.0005, RMSE: 0.0216, MAE: 0.0165 ve R^2 : 0.9899 olarak bulunmuştur. İkinci sırada yüksek başarı oranına sahip modelin ise Random Forest olduğu ve geriye kalan diğer modellerin ise daha düşük performans gösterdiği gözlemlenmiştir.

Ghimire vd., (2022) ve arkadaşları yaptığı çalışmada, küresel güneş radyasyonu (GSR) tahminin iyileştirmek için Slime-Mould Algoritması (SMA) tabanlı bir özellik seçimi mekanizmasını, CNN, LSTM ve MLP ile birleştiren bir hibrit model (SCLC algoritması) tasarlamışlardır. Bu model, Avustralya'nın Queensland bölgesindeki altı farklı güneş santralinde günlük zaman dilimlerinde uygulanmıştır. Performansı makine öğrenimi ve diğer derin öğrenme modelleriyle karşılaştırılmıştır. Sonuç olarak, SMA tabanlı SCLC modelinin, GSR tahmininde kullanılan diğer derin öğrenme (CNN-LSTM, DNN) ve makine öğrenimi (ANN, SADE-ELM, RFR) modellerine kıyasla yüksek bir performans sergilediği gözlemlenmiştir. Model, düşük MAE ve RMSE hata değerleri ve yüksek R^2 katsayıları ile güvenilir tahmin yapmıştır.

Gökçe (2024) çalışmasında, yapay sinir ağları modelleri ile kısa süreli güneş tahmini yapmıştır. Yapılan araştırmada, Fransa'nın Bourg kentinde bulunan 8,691 MWp kurulu güce sahip büyük ölçekli güneş enerjisi santralinin 2018-2023 yılları arasındaki saatlik hava durumu verileri ve üretilen enerji değerleri kullanılmıştır. Günlük şebekeden iletilen enerji tahmini için kullanılan YSA modelleri, Evrişimsel Sinir Ağları (CNN), Yinelemeli Sinir Ağları-Uzun Kısa Süreli Bellek (RNN-LSTM) ve Evrişimsel Sinir Ağları ile Uzun Kısa Süreli Bellek (CNN-LSTM) hibrit modelidir. Son veri setinde sensör seçimi sadeleştirilmiştir. Ayrıca düşük üretim güç değerleri çıkarılmıştır. Veri seti bölme işlemi ve hiperparametre optimizasyonu yapılarak model performansının artırılması amaçlanmıştır. MAPE, R^2 , RMSE ve MAE gibi performans kriterleri değerlendirilmiştir. Genel olarak CNN-LSTM en başarılı ve tutarlı sonuçları veren modeldir. Bu çalışma, büyük ölçekli güneş enerji santralleri için tahmin modellerini geliştirmeye yönelik önemli bilgiler verip gelecekteki çalışmalara yol göstermektedir.

2.2. Türkiye'de Güneş Enerjisi Potansiyeli Üzerine Yapılan Çalışmalar

Karaağaç vd., (2021), çalışmalarında Sinop ili koşullarında monokristalin ve polikristalin fotovoltaiik panellerin panel türü ve panel açısı yönünden kullanımı ve optimize etmeyi amaçlamıştır. Her iki panel gücü de 20W, monokristalin 430x360 mm, polikristal panel ise 419x359 mm boyutlarına sahiptir. Panellerin eğim açıları 0° ile 70° arasında artırılmış

ve en iyi eğim açısı 38° olarak bulunmuştur. Bu açıyla yerleştirilen her panelden saatlik akım ve voltaj değerleri alınmıştır. Monokristalin panelin tüm saatlik ölçümlerde daha üstünlük sağladığı belirlenmiştir. Bu çalışma, ülkemizin diğer illerindeki benzer çalışmalarla karşılaştırılmış ve bazı illere göre Sinop'taki monokristalin panel verimliliği daha yüksek bulunmuştur. Ayrıca çalışma, Sinop ilindeki panelleri en verimli şekilde kullanan gerçek kullanıcılara katkı saylayacağı belirtilmiştir.

Gabralı ve Aslan (2020), çalışmalarında YSA kullanarak güneş radyasyonu için ileriye yönelik bir tahmin çalışması yapmışlardır. İstanbul Büyükçekmece ilçesi Eskice Mevki istasyonuna ait 2016 yılındaki meteorolojik verileri mevsimlere göre dört gruba ayırmışlardır. Girdi olarak, tahmin zamanından 24 saat öncesine ait güneş radyasyonu, rüzgâr şiddeti, UV radyasyon indis, toprak üstü 5 cm, sıcaklık 2 m ve rüzgâr yönü verileri kullanılmıştır. Buna göre Mart ayı ilkbaharı, Haziran ayı yazı, Eylül ayı sonbaharı ve Aralık ayı kışı temsilen seçilmiş ve bu seçilen her mevsim için ayrı ayrı modelleme yapılmıştır. Kurulan YSA modelinde kullanılan gizli katmandaki nöron sayısı üçtür. Kullanılan transfer fonksiyonu ise tanjant sigmoid olarak belirlenmiştir. %36,74 MAPE değeri ile en yüksek başarı Haziran ayında elde edilmiştir. Diğer aylar için ise YSA modellerinin güneş radyosunu tahmin çalışmaları için uygun olmadığı görülmüştür.

Ariman vd., (2021) ve arkadaşları çalışmalarında Samsun ili için günlük güneş radyasyonu tahminini ileri beslemeli YSA modeli ile gerçekleştirmişlerdir. Oluşturulan YSA modelinde girdi değişkenleri olarak ortalama sıcaklık, nispi nem, buhar basıncı, rüzgâr hızı, güneşlenme süresi, bulutluluk oranı, maksimum ve minimum sıcaklık ve 5 cm' deki toprak sıcaklığı verileri kullanılmıştır Tek gizli katman kullanılmış ve nöron sayıları 1-20 arasında değiştirilmiştir. En yüksek korelasyon katsayısı ($R=0,9603$) olarak hesaplanmış ve girdi olarak kullanılan parametre sayısı azaldıkça R değerinin de düştüğü gözlemlenmiştir.

Kumruoğlu ve Ateş (2022), çalışmalarında Türkiye'nin güneş ışıınım verileri incelenmiş ve güneş enerjisinin üretime dönüştürülmesi sırasında uluşan kayıpları analiz etmişlerdir. Ayrıca İskenderun Teknik Üniversitesi'nin bir binası için 60 kWp gücünde bir çatı güneş enerjisi santrali tasarlanmıştır. Üretim projeksiyonları PVGIS, PVsyst ve SMA Web Design yazılımlarından yararlanılarak hesaplanmıştır. Bu üç farklı simülasyon yazılımı ile benzer sonuçlar elde edilmiş ve yıllık yaklaşık 92.000 kWh elektrik üretiminin olabileceği hesaplanmıştır. Elde edilen sonuçlara göre, yatırımın 4,9 yıl içinde geri dönüş sağladığı ayrıca 38 ton karbon emisyonunun önüne geçileceğini göstermiştir.

Kan Kaynar (2020) tarafından yapılan çalışmada, Coğrafi konumu nedeniyle en fazla güneş alan illerinden biri olan Amasya'nın güneş enerji potansiyelini incelemektedir. Bu il genelindeki yıllık ortalama güneşlenme süresi 7,49 saat-gün olarak hesaplanmıştır. Ayrıca ülkemizin günlük ışınlam şiddetinin 4,18 kWh/m²-gün iken, ortalama toplam global radyasyon değerinin ise 1524 kWh/m² -yıl (4,18x365) olarak tespit edilmiştir. Sonuç olarak Amasya ilinin güneş enerjisi potansiyeli, Karadeniz Bölgesi illeri arasında dördüncü sırada yer alır iken, mevcut ve yapım aşmasındaki santraller, güneş enerjisinin gelecekte daha verimli şekilde değerlendirileceğini göstermektedir.

Alcan vd., (2018) ve arkadaşları yaptıkları çalışmada, Sinop ilinin güneş enerji potansiyeli analiz edilerek, Türkiye ve Almanya ile karşılaştırarak incelemişlerdir. Güneşlenme süresi ve ışınlam verileri incelenen Sinop ilinin güneş enerjisi potansiyelinin, Almanya'ninkinden yüksek olmasına rağmen mevcut kullanımın sınırlı kaldığı vurgulanmıştır. Sinop'ta, sıcak su haricinde yeterince güneş enerjisinden elektrik üretimi yapılmadığı ve güneş enerjisine dayalı projelerin artırılmasının faydalı olacağı belirtilmiştir.

Mersin (2024) çalışmasında, güneş enerjisi üretiminde yapay zekâ modellerinin etkinliğini incelemiş ve bunun için Gaziantep'teki bir güneş enerji santralinin verilerini kullanmıştır. Model, veri hazırlama, ön işleme, görselleştirme ve yeni özelliklerin eklenmesi gibi adımlarla geliştirilmiştir. Modelin mevsimsel değişiklikleri daha iyi öğrenmesi amacıyla veri seti, her mevsim için %70 eğitim ve %30 test verisi olacak şekilde bölünmüştür. XGBoost, MLP, Regresyon, LightGBM, ANN gibi çeşitli makine öğrenmesi modelleri geliştirilmiştir. RMSE ve R² değerleri bakımından en iyi performans LightGBM algoritmasında gözlemlenmiştir.

Şener (2024) çalışmasında, Muş ilinin güneş enerjisi potansiyelini makine öğrenmesi ile tahmin edilmiştir. Çalışmada zaman serisi ve regresyon yöntemleri kullanarak 2018-2023 yıllarına ait meteorolojik veriler kullanılarak güneş radyasyonu tahmini yapılmıştır. Verilerin %80'i eğitim için kullanılırken, 20'si test için kullanılmıştır. Zaman serisi tahmin yöntemleri olarak LSTM ve ARIMA yöntemleri kullanılmış olup her iki yöntemle de tahmin sonuçları birbirine yakın çıkmıştır. Regresyon yöntemleri olarak da MLP, XGBoost ve SVM uygulanmıştır. Çalışma sonucunda Muş ili güneş radyasyonu tahmininde kullanılan modellerin başarılı sonuçlar verdiği görülmektedir. Tahmin edilen değerlerin gerçek ölçümlerle uyumlu olduğu belirtilmiştir. Eğer model parametreleri optimize edilirse, tahmin sonuçlarının daha da iyileşebileceğinden bahsedilmiştir. Ayrıca,

LSTM modelinin zaman serilerinde uzun dönemli bağımlılıkları öğrenme yeteneği sayesinde, ARIMA gibi doğrusal modellerden daha üstün bir performans sergilediğine değinilmiştir.

Literatür incelendiğinde yenilenebilir enerji kaynakları üzerine yapılmış farklı çalışmalar dikkat çekmektedir. Ülkemizin yüksek güneş enerji potansiyeline sahip olduğu görülmektedir. Ülkemizde bölgeler arasında en düşük potansiyele sahip Karadeniz bölgesinin bile kurulu gücünün yaklaşık %14,5'ini güneş enerjisinden sağlayan Almanya'dan daha yüksek güneş enerji potansiyeline sahip olması bu çalışmanın temelini oluşturmaktadır (Anonim, 2024b). Daha önceki çalışmalarda yapay zekâ kullanılarak Sinop ili için güneş enerji potansiyeli tahmini yapılmadığı tespit edilmiştir. Bu bağlamda Sinop ilinin güneş enerji potansiyeli gerçek veriler kullanılarak LSTM, MLP ve bu iki algoritmayla oluşturulan hibrit model ile tahmin edilmiştir. Literatürde geliştirilen hibrit modellerin tahmin başarılarını arttırdığı göz önüne alınarak özgün hibrit model tasarımı gerçekleştirilmiştir.

3. ENERJİ

Enerji, iş yapabilme yeteneği olarak tanımlanır ve mekanik (potansiyel ve kinetik), ısı elektrik, kimyasal ve nükleer gibi çeşitli türlerde bulunabilir. Bu enerji türleri uygun yöntemlerle birbirine dönüştürülebilir ve farklı şekillerde sınıflandırılabilir (Koç ve Kaya, 2015).

İnsanlık tarihinde enerji, ekonomik ve teknolojik gelişmenin temellerinden biri haline gelmiştir. İnsanlar, ateşin kontrolüyle başlayarak, elektrik çağına kadar birçok dönemi deneyimlemişlerdir. Günümüzde ise yenilenebilir enerji kaynaklarına yapılan geçiş, enerji tarihinde önemli bir dönüm noktası olarak kabul edilmektedir.

Ülkelerin ekonomik ve sosyal gelişimi için enerji hayati önem taşır. Bu nedenle, enerjiyi güvenilir, temiz, kesintisiz ve ucuz bir şekilde sağlamak ve kaynakları çeşitlendirmek önemlidir. Gelişmiş ülkeler, enerji politikalarında enerji verimliliğini artırmayı, enerji tasarrufunu teşvik etmeyi ve enerji yoğunluğunu azaltmayı hedefler. Modern enerji politikaları, enerjiyi en verimli şekilde kullanarak en az enerji harcamasıyla en fazla üretimi sağlamayı hedeflemektedir (Pamir, 2023).


Son yıllarda hızla artan nüfus ve sanayi faaliyetlerindeki büyüme, enerji ihtiyacını karşılamak için sınırlı kaynakların yetersiz kaldığı bir noktaya ulaşmıştır. Bu durum enerji üretimi ile tüketimi arasındaki farkı daha da açmış ve yenilenebilir enerji kaynaklarına olan talebi artırmıştır. Avrupa Yeşil Anlaşması gibi girişimler, sağlığını olumsuz etkileyen faktörleri en aza indirmeyi amaçlayarak 2030'a kadar yenilenebilir olmayan enerji kaynaklarının kullanımı azaltmayı hedeflemektedir. Ayrıca, iklim kriziyle mücadele edilmesi, sera gazı emisyonlarını önemli ölçüde azaltarak çevreye verilen zarar en aza indirmeyi amaçlamaktadır (Tekin, 2022).



Şekil 3.1 Elektrik enerjisi kurulu gücünün kaynaklara göre dağılımı (Anonim, 2023)

Şekil 3.1'e göre 2023 yılı verilerine bakıldığında Türkiye enerji kurulu gücünün doğalgaz ve LNG %25'ini, barajlı HES %22'sini, taş kömürü, linyit ve asfaltit %11'ini karşıladığı görülmektedir.

Şekil 3.2 incelendiğinde enerji kaynakları kullanılışlarına göre yenilenebilir ve yenilenemez olarak ikiye ayrılırken, dönüştürülebilirliklerine göre birincil ve ikincil enerji kaynakları şeklinde incelenir. Yenilenemez enerji kaynakları, kısa bir süre içinde tükenme riski taşıyan fosil ve nükleer kaynaklar olarak sınıflandırılırken, yenilenebilir enerji kaynakları ise kendini yenileyebilen ve uzun vadede tükenmeme potansiyeline sahip kaynaklardır. Enerjinin herhangi bir değişime ya da dönüşüme uğramamış doğal hali, primer (birincil) enerji olarak adlandırılır. Birincil enerji kaynakları, kömür, güneş, rüzgâr, petrol, doğal gaz, nükleer, dalga-gelgit, biyokütle ve hidroliktir. Birincil enerjinin dönüştürülmesiyle elde edilen enerji, ikincil (sekonder) enerji olarak tanımlanır. İkincil enerji kaynakları, Mazot, motorin, benzin, elektrik, hava gazı, kok kömürü, sıvılaştırılmış petrol gazı (LPG), ikincil kömür ve petrokuttur (Koç ve Kaya, 2013).



Şekil 3.2 Enerji kaynağı çeşitleri

3.1. Enerji Kaynakları ve Türleri

Yenilenebilir ve yenilenemez enerji kaynakları aşağıda sırasıyla açıklanmaktadır.

3.1.1. Yenilenemez enerji kaynakları

Yenilenemez enerji kaynağı, doğal süreçlere bağlı olarak yenilenmeyen veya çok yavaş yenilenen kaynakları tanımlar. Kömür, doğal gaz ve petrol gibi ana fosil enerji kaynaklarının mevcut rezervleri hakkında geleceğe dair tahminler bulunmaktadır. Kömürün 2080’li yıllarda, doğal gazın 2060’lı yıllarda ve petrolün 2050’li yıllarda tükeneceği tahmin edilmektedir. Bu kaynaklar, bitki ve hayvan maddelerinin yavaş çürümesiyle sürekli olarak yeniden üretilebilir, ancak bu süreçler o kadar yavaştır ki, yüz milyon yıl içinde değiştirilemezler ve bu nedenle tekrar üretilemezler (Görgülü, 2022). Ana yenilenemez kaynakları şu şekildedir:

Kömür, organik maddelerin milyonlarca yılda ve yer altındaki basınç altında çürümesi sonucu oluşan bir fosil yakıttır. Elektrik üretimi için termik santrallerde tercih edilirler.

Petrol, denizlerdeki bitki ve hayvan kalıntılarının milyonlarca yıl boyunca çürümesiyle oluşan hidrokarbon sıvıdır. Genellikle yakıt olarak kullanılırlar. Ayrıca plastik ve kimyasal ürünlerin imalatında da kullanılabilirler.

Doğal gaz, organik maddelerin milyonlarca yıl boyunca yüksek sıcaklık ve basınçta çürümesiyle oluşan fosil kaynaklı bir hidrokarbon gazıdır. Evlerde ve endüstride ısıtma amaçlı kullanılmasının yanı sıra, elektrik üretiminde de kullanılmaktadır.

Nükleer enerji ise, atomun çekirdeğindeki parçalanma sonucu ortaya çıkar. Bu enerji, uranyum, plütonyum ve toryum gibi nükleer yakıt elementlerinin bir reaktör içinde kontrollü bir şekilde parçalanmasıyla oluşur. Bu parçalanma sırasında açığa çıkan ısıyı iletme için genellikle su kullanılır. Reaktördeki sıcaklık suyu buharlaştırarak tribünleri döndürmek için kullanılır. Tribünleri dönmesi sonucu mekanik enerji elektrik enerjisine dönüştürülür ve nükleer güç santralleri elektrik üretir (Kavaz, 2021).

Yenilenemez enerji kaynakları, düşük maliyet ve kolay erişilebilirlik gibi avantajlarının yanı sıra, tükenbilir oluşları, çevreye verdikleri kirlilik ve güvenlik sorunları gibi dezavantajları da bulunmaktadır.

3.1.2. Yenilenebilir enerji kaynakları

Fosil yakıtlara dayalı enerji kullanımı, çevre sorunları, hızla tükenen rezervler, dışa bağımlılık ve yüksek ithalat maliyetleri gibi olumsuzluklar yenilenebilir enerji kaynaklarının önemini arttırmaktadır. Yenilenebilir enerji kaynakları sürdürülebilirlerdir ve çevresel etkileri çok azdır. Ayrıca teknik ve ekonomik sorunlar çözüldüğünde, 21. yüzyılın en önemli enerji kaynağı olmaları beklenmektedir (Kumbur vd., 2005).

3.1.2.1. Hidrolik enerji

Hidrolik enerjide su gücünden yararlanılır. Yüksek yerden alçak yere doğru akan suyun kinetik enerjisinden elektrik üretme işlemidir. Suyun hareket enerjisi türbinler ve jeneratörler aracılığıyla elektrik enerjisine dönüştürülür. Bu üretimin yapıldığı tesise hidroelektrik santrali (HES) denir. HES'ler barajlı ve barajsız olmak üzere iki şekilde sınıflandırılır. Barajlı HES'lerde su, belirli bir yüksekliğe kadar biriktirilir ve bu potansiyel enerji elektrik üretiminde kullanılır. Barajsız HES'lerde ise su seviyesi yükseltilmez, regülatörlerle akış artırılarak enerji elde edilir (Unsur, 2021).

Hidrolik enerji temiz ve yenilenebilir bir enerji kaynağı sağlar. Ayrıca çevre ve iklim üzerinde olumlu etkisi vardır. Uzun ömürlüdür. İşletme ve bakım maliyetleri düşüktür. Alternatif HES'ler günümüzde temiz enerji kaynakları arasında en kolay kurulan, en sürdürülebilir ve en düşük işletim maliyetine sahiptir (Özölçer vd., 2020).




Şekil 3.3 Hidrolik Santral (Anonim, 2012)


3.1.2.2. Güneş enerjisi

Güneş enerjisi, küresel ısınmaya sebep olmayan ve minimum seviyede çevresel etkileri olan bir enerji türüdür. Güneşten gelen enerji miktarı insanlık tarihi boyunca tüketilen tüm enerji kaynakları miktarından daha fazladır. Ayrıca oldukça tutarlıdır ve mevsimsel hava koşullarındaki değişikliklere savunmasız değildir. Güneş enerjisi genellikle kömür ve petrol gibi fosil enerji kaynaklarına alternatif olarak görülmektedir (Solangi vd., 2011).

Şekil 3.4' te görüldüğü gibi Haziran 2022 itibariyle ülkemizin güneş enerjisine dayalı elektrik gücü 8,479 MW'a ulaşmıştır. Bu toplam kuruluş gücünün %8,35 ini oluşturduğu da Şekil 3.5'te verilmiştir.



Şekil 3.4 Güneş enerjisi kurulu gücünün yıllara göre değişim grafiği (Çalapkulu, 2022)



Şekil 3.5 Güneş enerjisinin toplam kurulu güç içeriği yıllık oranı grafiği (Çalapkulu, 2022)


Güneş dünyaya 170 milyar MW güçte enerji yollamakta ve bu enerji, bugün dünyada kullanılan toplam enerjinin 15-16 bin katıdır. Güneş enerjisi, ısıya dönüşüm ve elektrik enerjisi üretimi olmak üzere iki şekilde kullanılır. Fotovoltaik (FV hücreleri – güneş hücreleri), çevreyi kirlilemeden ve herhangi bir hareketli mekanizma gerektirmeden güneş enerjisini doğrudan elektrik enerjisine dönüştüren sistemlerdir. Güneş enerjisi, 1370

W/m^2 sabit yoğunlukla ve 0-1100 W/m^2 arasında değişen yüzey alanına sahiptir. Türkiye’de güneş enerjisi kurulu kapasite bakımından Avrupa’da birinci sıradadır. Bu sistemlerin taşınabilir, kurulabilir, modüler (değiştirilebilir) ve uzun süre sorunsuz çalışması gibi avantajları bulunurken, dezavantajları ise yüksek maliyet, düşük verimlilik ve kesintili depolama gibi sorunlardır (Artkın, 2018).


Fotovoltaik hücre

Fotovoltaik hücreler, güneş ışığını elektrik enerjisine dönüştüren basit cihazlardır. Foton enerjisi (güneş radyasyonu) yarı iletken malzemeye çarptığında, bu malzemedeki bağlardan bir elektron koparılır. Bu elektronlar serbestçe hareket etmeye başlar ve sonuçta bir elektron akımı oluşur. Oluşan bu elektron akımı da hücrenin potansiyel alanında gerilim yaratır ve oluşan bu gerilim, elektrik akımını üretir (Küpeli, 2005).

Birden fazla fotovoltaik hücre paralel ya da seri bağlanarak daha yüksek bir elektrik gücü üretilir. Bu yapıya “FV modül” adı verilir. Bu modüllerin tasarım amacı tek bir hücreden daha fazla elektrik üretmektir. Bu modüllerin bağlanma şekli enerji talebine göre değişir. FV hücreler, yapıları basit bir P-N ekleminden oluşan diyotlara benzer. Hücreye düşen fotonlar, P-N eklemdeki elektronları harekete geçirir ve elektrik akımı oluşturur. Güneş enerjisinin FV hücrenin yapısına bağlı olarak %5 ile %20 arasında bir verimle elektrik üretme kapasitesi vardır. Bu hücrelerin yüzeyleri genellikle kare, dikdörtgen ve daire biçimindedir. Ayrıca alanları 60-160 cm^2 arasında değişmektedir. Kalınlıkları ise 0,2-0,4 mm arasındadır (Öztürk, 2008). FV hücrelerin modül ve dizi tasarımları Şekil 3.6’da verilmiştir. FV hücresinin çalışma ilkesi ise Şekil 3.7’de gösterilmiştir.



Şekil 3.6 FV hücre, modül ve dizi tasarımları



Şekil 3.7 FV hücresinin çalışma ilkesi (Öztürk, 2008)

Güneş pilleri, yapıldıkları malzemeye göre aşağıdaki gibi çeşitlere ayrılır:

- **Silikon Bazlı Güneş Pilleri**

Monokristal, polikristal ve amorf silikon olarak çeşitleri vardır. Monokristal güneş pilleri, tek bir silikon kristalinden üretilir ve en yüksek verimliliğe sahiptir. Uzun ömürlüdür fakat üretim maliyeti yüksektir. Birden fazla silikon kristalinden üretilen polikristal güneş pilleri, verimlilik açısından monokristale göre daha düşük değere sahiptir. Uygun maliyetlidir. Amorf silikon güneş pilleri ise, ince silikon katmanlarından oluşur. Düşük maliyetlidir. Fakat kısa ömürlü ve fazla alan gerektirmesi gibi dezavantajları bulunmaktadır.

- **İnce Film Güneş Pilleri**

Güneş ışığını elektriğe dönüştürmek için çok ince bir yarı iletken katmanına sahip olan bu güneş pili çeşidi, esnek ve hafiftir. Üretim süreçleri kristal silikon hücrelere kıyasla daha az maliyete sahiptir. Taşınabilir cihazlarda ve bina cepheleri gibi alanlarda kullanılabilir. Üretiminde amorf silikon, kadymyum tellürid, bakır indiyum galyum selenid ve organik malzemelerdir. Bu pil çeşitleri kristal silikon pillere göre daha az enerji üretir ve uzun süreli kullanımda performans kaybı yaşanabilir.

- **Yeni Nesil Güneş Pilleri**

Yenilikçi teknolojilere dayanan bu sistemler, daha geniş uygulama alanları sağlamayı, maliyetleri düşürmeyi ve güneş enerjisi teknolojisinin verimliliğini artırmayı hedefler. Birçok çeşidi bulunmaktadır. Bunlardan biri, perovskit adı verilen kristal yapıya sahip perovskit güneş pilleridir. Bu piller, hafif ve esnek yapıya sahip olup uygun maliyetle üretilir. Fakat kurşun içerdiği için çevresel

sorunlara yol açabilir. Bina cephelerinde, çatılarda ve elektrikli araçlar gibi kullanım alanlarına sahiptir. Bir diğer yeni nesil güneş pili, nano ölçekli kuantum noktaları kullanılarak üretilen kuantum nokta güneş pilleridir. Bu piller, geniş bir ışık spektrumunda çalışabilir. Üretim maliyeti yüksektir. Giyilebilir teknoloji, taşınabilir cihazlar gibi kullanım alanlarına sahiptir. Bir diğer yeni nesil güneş pilleri ise, birden fazla yarı iletken katmanının üst üste yerleştirilmesiyle elde edilen çok katmanlı güneş pilleridir. Güneş ışığını en yüksek verimlilikle enerjiye dönüştürür ve her katman farklı bir ışık dalya boyunu emer. Fakat üretimi çok pahalı olduğundan ticari kullanıma uygun değildir. Uzay araçları ve askeri uygulamalar gibi kullanım alanları vardır.

Yoğunlaştırılmış güneş enerjisi (CSP) sistemleri

Bu teknoloji, FV hücrelerde olduğu gibi doğrudan güneş enerjisini kullanmaz. CSP sistemleri, güneş ışığını odaklayarak ısı enerjisi üretir ve bu ısıyı elektrik enerjisine dönüştürür. CSP teknolojileri biri parabolik oluk kolektörlerdir. Bunlar, U şeklindeki aynalarla güneş ışığını bir odak hattına yönlendirir. Isı transfer akışkanı ısıyarak buhar türbinlerini çalıştırır. Bir başka CSP teknolojisi güneş kuleleridir. Bunlar Helyostat denilen aynalarla güneş ışığını merkezi bir kulede toplayıp yüksek sıcaklıklarda ısı enerjisi elde eder. Erimiş tuz gibi akışkanlar kullanılarak ısı depolanır. Bir başka CSP teknolojisi parabolik çanak sistemleridir. Bunlar çanak şeklindeki aynalarla güneş ışığını bir noktada toplayarak Stirling motorlarıyla elektrik üretir. Küçük ölçekli uygulamalarda kullanılabilir. Bir başka CSP teknoloji çeşidi de fresnel reflektörlerdir. Bunlar düz aynalarla daha basit ve ekonomik bir odaklama sağlar. Geniş alanlarda kullanılabilir (Ayvaz ve Bayrak, 2024). Farklı CSP teknolojileri Şekil 3.8’de gösterilmiştir.



Şekil.3.8 CSP teknolojileri, LFC doğrusal fresnel kollektör, PTC parabolik geçmeli kollektör, DC çanak kollektör, ST güneş kulesi (Mancera vd., 2014)

Termal Güneş Enerjisi Sistemleri

Bu enerji sistemleri güneş ışınımını yakalar ve bunu ısı enerjisine dönüştürür. Çeşitli uygulama alanında kullanılabilen sistemlerdir. Bu sistemlerin doğrudan güneş enerjisini ısıtma ve enerji üretimi için kullanıldıklarından dolayı son derece önemli bir yenilenebilir enerji teknolojisidir. Sıcaklık ve kullanım amaçlarına göre sınıflandırılmaktadır. 100 °C'nin altındaki sıcaklık ihtiyaçlarını karşılamak amacıyla düzlemsel güneş kolektörleri ve vakum tüplü kolektörler geliştirilmiştir. Düzlemsel güneş kolektörleri, güneş ışığını soğurucu bir yüzey aracılığıyla toplar ve sıcak su üretir. Vakum Tüplü kolektörler ise daha soğuk iklimlerde bile etkin bir şekilde yüksek verimlilikle çalışabilir. Düşük sıcaklık termal sistemlerin, sıcak su üretimi, mekan ısıtma ve havuz ısıtma gibi uygulama alanları vardır. 100°C ile 400 °C arasında sıcaklık ihtiyacı olan uygulamalar için orta sıcaklık termal sistemler tasarlanmıştır. Bu sistemde parabolik aynalar ve fresnel lensler kullanarak güneş ışığını bir alana odaklayan odaklayıcı kolektörler kullanılır ve yüksek sıcaklıklar elde edilir. Orta sıcaklık termal sistemleri tarım alanlarında kurutma işlemleri gibi amaçlarla kullanılır. 400 °C'nin üzerindeki yüksek sıcaklık termal sistemleri elektrik üretimi ve yoğun enerji gerektiren sanayi süreçlerinde kullanılır. Yüksek sıcaklık sistemlerinde parabolik oluk sistemleri, Dish-Stirling sistemleri ve güneş kuleleri gibi teknolojiler kullanılır.

3.1.2.3. Rüzgâr enerjisi

Rüzgâr enerjisi, rüzgârın kinetik enerjisini kullanarak elektrik enerjisi üretilmesidir. Bu işlem rüzgâr türbinleri ile gerçekleştirilir. Rüzgâr türbinleri, rüzgârın türbin kanatlarına çarpmasıyla döner ve türbinin içerisindeki jeneratörü çalıştırır. Jeneratör, mekanik enerjiyi elektrik enerjisine dönüştürür (Mitra vd., 2023).

Rüzgâr enerjisi sera gazı salınımına neden olmadığından iklim değişikliği ve küresel ısınma ile mücadelede önemli rol oynar. Ayrıca, yerli bir enerji kaynağı olduğundan enerjide dışa bağımlılığı azaltıp enerji güvenliğine katkı sağlar (Sağlam vd., 2024). Bu avantajlarının yanı sıra, kesintili bir enerji kaynağı olması, yerleşim yerlerine yakın kurulamaması, yüksek rüzgâr hızları, yüksek ses, şebekeye aktarma ve depolama sorunları, yüksek yatırım maliyeti, televizyon sinyallerini bozması, görüntü ve ışık kirliliği, kurulum için geniş sahalara ihtiyaç duyması ve kuşlara zarar vermesi gibi dezavantajları da bulunmaktadır (İçel, 2023). Şekil 3.9’da modern bir tasarımı temsil eden rüzgâr türbini görseli verilmiştir.



Şekil 3.9 Rüzgâr türbini (Anonim, 2022a)

3.1.2.4. Biyokütle enerjisi

Biyokütle enerjisi, organik malzemelerden yenilenebilir ve sürdürülebilir şekilde elektrik veya başka güç formları üretmek için kullanılır. Odun ürünleri, kurutulmuş bitki örtüsü, mahsul kalıntıları, su bitkileri ve hatta evsel atıklar kullanılarak biyokütle enerjisi üretilir. Doğal malzeme olarak tanımlanan bu malzemeler, termokimyasal ve biyokimyasal işlemler sonucu enerjiye dönüştürülür (Kademli, 2021).

Biyokütle enerji üretiminin yanı sıra mobilya, kâğıt, yalıtım malzemeleri gibi farklı alanlarda kullanılmaktadır. Enerji olarak kullanımında ise, çeşitli teknolojilerle katı, sıvı ve gaz yakıtlar elde edilmektedir. Biyogaz, biyoetanol, biyodizel gibi yakıtların yanı sıra gübre, hidrojen ve metan gibi çeşitli yakıt türleri de biyokütle kaynaklarından elde edilmektedir (Kapluhan, 2014).

Canlı maddelerden elde edilen biyokütlesel enerjinin uygun olmayan şekilde işlenmesi olumsuz sonuçlar doğurabilmektedir. Özellikle, odun ve diğer orman ürünlerinin sınırsız kullanımı çeşitli doğal kaynakların zarar görmesine neden olabilir, bu da iklim değişikliği gibi ciddi sorunlara yol açabilir (Ağaçbiçer, 2010).

3.1.2.5. Jeotermal enerji

Jeotermal enerji, yer kabuğunun çeşitli derinliklerinde bulunur. Yeryüzündeki havzalardan beslenen sularla potansiyelini oluşturan birikmiş ısının meydana getirdiği sıcaklıkları içerir. Bu sıcaklıklar bölgesel olarak değişir ve çoğunlukla su ve buhardan oluşan bir hidrotermal kütleyle sahiptir. Bazı durumlarda, sert kayaların oluşturduğu sistemlerde su içermese bile jeotermal enerji kaynağı olarak değerlendirilir (Arslan, 2006). Yani, kısaca yerin derinliklerinden gelen buhar veya suyun kullanılmasıyla elde edilen bir yenilenebilir enerji türüdür. Jeotermal enerji üretiminde sera gazı emisyonu diğer teknolojilere göre çok daha azdır. Jeotermal enerji santralleri, birincil enerji kaynaklarına göre çok daha düşük CO₂ emisyonuna sahip olduğundan bu kaynaklar daha çekici seçenek haline olabilir (Rybach, 2003). Jeotermal enerjinin, sera ısıtması, bölge ısıtması, endüstriyel kullanım, tarımsal ürün kurutma, soğuk ver kar çözme, banyo ve yüzme (termal turizm) ve elektrik üretimi gibi kullanım alanları mevcuttur (Külekçi, 2009). Şekil 3.10'da Türkiye'nin en büyük jeotermal enerji santrali görsel olarak verilmiştir.



Şekil 3.10 Jeotermal enerji santrali (Anonim, 2019)

3.1.2.6. Deniz enerjisi

Denizlerin ve okyanusların doğal hareketlerinden elde edilen enerjidir. Gel-git enerjisi, dalga enerjisi, deniz akıntıları enerjisi ve deniz yüzeyi buharlaşma gibi birçok çeşidi vardır.

Dalga dalgalarının gücü, dünya yüzeyinin farklı ısınması sonucu oluşan rüzgârların deniz yüzeyinde esmesiyle meydana gelir. Bu güç, diğer yenilenebilir enerji kaynaklarınınkinden 10-15 kat daha fazla yoğun olarak hesaplanmıştır. Güneş ve rüzgâr enerjisine göre ideal şartlarda 1 kW elektrik üretimi için çok daha az alan gerekir. Ayrıca, her türlü kirliliği dolaylı olarak azaltması, güç kaynağının sonsuz ve bol olması, fosil yakıtlara olan bağımlılığı azaltması gibi birçok avantajı vardır (Sağlam vd., 2005).

Gel-git enerjisi, denizlerin ve okyanusların Ay'ın çekim kuvveti sebebiyle alçalıp yükselmesiyle meydana gelen seviye farkıdır. Düşük karbon emisyonları, Ay'ın hareketlerine göre kolay tahmin edilebilirliği ve düşük maliyetli enerji üretimi gibi birçok avantajı bulunmaktadır.

3.1.2.7.Hidrojen enerjisi

Dünyanın yapıtaşlarında bulunan hidrojen, renksiz, kokusuz ve zehirli olmayan bir gazdır. Hidrojen enerjisi, sudan elde edilerek kullanılabilir hale gelmektedir. Bu gazın

oluşumu sırasında ortaya çıkan yanma sonucunda sadece su oluştuğundan, bu enerji yenilenebilir bir kaynaktır (Kılıç, 2023). Ayrıca hidrojen gazı, sera gazlarının yayılmasını yol açmaz ve tankerler, borular aracılığıyla kolay ve güvenilir bir şekilde taşınabilir (Aslan ve Özcan, 2008). Doğada serbest halde bulunmayan hidrojen, fosil ve nükleer enerji kaynaklarından ya da su kaynaklarından elektroliz yöntemiyle üretilir. Elektroliz yöntemi fosil yakıtlarla üretime göre çok daha az verimi olduğun pek tercih edilmezler (Ağaçbiçer, 2010). Şekil 3.11’de Florida’daki NASA Kennedy Uzay Merkezi’ndeki bir sıvı hidrojen tankı verilmiştir.




Şekil 3.11 Florida’daki NASA Kennedy Uzay Merkezi’ndeki bir sıvı hidrojen tankı (Anonim, 2021)

3.2 Türkiye’de Güneş Enerjisi Potansiyeli

Güneş Enerjisi Potansiyeli Atlası (GEPA)’na göre, Türkiye’de ortalama yıllık toplam güneşlenme süresi 2741 saat ve ortalama yıllık toplam ışıınım değeri $1.527,46 \text{ kWh/m}^2$ ’dir (Anonim, 2022b). Şekil 3.12’de açık ve koyu renkler ile gösterilen ülkemizdeki şehirler güneş ışıınmasından minimum ve maksimum yararlanmaya göre renklendirilmiştir. Güneş ışıınlarından en fazla yararlanan iller koyu turuncu iken, en az yararlanan iller koyu mavi olarak gösterilmiştir. Buna göre Türkiye’nin en çok güneş alan bölgeleri sırasıyla


Güneydoğu Anadolu bölgesi, Akdeniz Bölgesi, Doğu Anadolu Bölgesi, İç Anadolu Bölgesi, Ege Bölgesi, Marmara Bölgesi ve Karadeniz Bölgesidir.



Şekil 3.12 Türkiye güneş enerjisi potansiyeli atlası (GEPA) (YEGM, 2022)


Güneş enerjisi kurulu gücü, 2023 sonunda 11,316 MW iken, 2024 Şubat sonunda 12,425 MW'a çıkmıştır. 2023 yılında toplam güneş enerjisinde 2000 MW'lık bir artış gözlemlenirken, 2024 yılının iki ayında bu artışın yarısı kadar bir ilerleme sağlanmıştır (Anonim, 2024a).

Şekil 3.13 'te görüldüğü üzere Ülkemizin aylık olarak ortalama günlük global radyasyon değerlerine bakıldığında, en yüksek değerin haziran ayında olduğu görülmektedir. Ayrıca ülkemizin güneş ışıınım potansiyeli, aylık ortalamalar üzerinden günlük ortalama ışıınımın $4,14 \text{ kWh/m}^2$ ve bu değer, yıllık toplamda $1524,18 \text{ kWh/m}^2$ olduğu görülmektedir.



Şekil 3.13 Türkiye global radyasyon değerleri (KWh/m²-gün)(GEPA, 2019)

Şekil 3.14' e göre ülkemizin aylık bazda ortalama güneşlenme sürelerine bakıldığında, en yüksek olduğu ay temmuz, en az olduğu ay ise aralık ayıdır. Ayrıca ülkemizin aylık bazda ortalama günlük güneşlenme süreleri 7,49 saat-gün iken, yıllık ortalama toplam güneşlenme süresi 2736,89 saat-yıl'dır.



Şekil 3.14 Türkiye güneşlenme süreleri (saat) (GEPA, 2019)

Türkiye güneş enerjisinden su ısıtma açısından Avrupa'da ön sıralarda yer almakta, fakat genel olarak bu kaynağı verimli kullanamamaktadır. Artan enerji ihtiyacı ve sanayi gelişimi, enerji ithalatını artırarak dış ticaret açığını genişletmektedir (Arabacı ve Özkan, 2024).

4. YAPAY ZEKÂ

En temel anlamıyla yapay zekâ, bilgisayarları akıllı hale getirme bilimidir ve hem zekânın doğasını anlamak isteyenler tarafından hem de bilgisayarları daha faydalı hale getirmek için kullanılır (İnce vd., 2021). Yapay zekâ, bilim dünyasında bilgisayar ya da bilgisayar destekli makinenin genellikle insana özgü nitelikler olan çözüm yolu bulma, anlama, genelleme, mana çıkarma ve geçmiş deneyimlerinden öğrenme gibi yüksek düzeyli mantık süreçlerini yerine getirme yeteneğidir. Yapay zekâ öğrenme yeteneği üzerine kuruludur. Çünkü yapay zekânın da insan gibi, bir işi becermeden önce öğrenmesi gerekir. Yapay zekânın en büyük katkısı öğrendiklerini çok kolay bir şekilde uygulayabilmesidir (Öztürk ve Şahin, 2018).

Yapay zekânın ilk kullanımı bir bilgisayar bilimcisi olan McCarthy tarafından 1954 yılında yapılmıştır. Öğrenmenin ve zekânın bilgisayarlar tarafından simüle edilebileceğini belirtmiştir. Günümüzde birçok alanda hızla büyüyen yapay zekâ, pazarlama, bankacılık, tarım, sağlık, güvenlik, robotlar, konuşma, tanıma ve üretim gibi birçok alanda kullanılmaktadır. Son yıllarda ise enerji sistemlerindeki yapay zekâ uygulamaları daha önemli hale gelmiştir (Entezari, 2023).

4.1. Yapay Zekâ Teknikleri

Yapay zekâ geniş bir kapsama sahip olup çeşitli teknikler içermektedir. Bunlar genel olarak, makine öğrenmesi, derin öğrenme, yapay sinir ağları, genetik algoritmalar ve bulanık mantık teknikleridir.

4.1.1. Makine öğrenmesi

Makine öğrenimi, çeşitli veri toplama yöntemleri ile elde edilen bilgileri kullanarak, uygun tekniklerle bilgisayarların karmaşık örüntülerini anlamasını ve bilgisayara karar verme becerisini kazanmasını sağlayan bilim dalıdır (Atak, 2022). Makine öğrenimi danışmanlı (gözetimli), danışmansız (gözetimsiz), yarı danışmanlı ve takviyeli öğrenme olmak üzere dört farklı sınıfa ayrılır. Danışmanlı öğrenmede, eğitim verileri kullanılarak bir model geliştirilirken, danışmansız öğrenmede ise veri setindeki ilişkiler veriden çıkarılır. Yapay sinir ağları, destek vektör makineleri, karar ağaçları ve lojistik regresyon gibi algoritmalar, makine öğreniminde en çok kullanılan tekniklerdir (Aydın ve Aydoğdu, 2022).

- **Gözetimli öğrenme**

Girdilerle çıktılar arasında bir fonksiyon üreten bir tekniktir. Algoritmanın girdi verileri ve etiketli çıktılar arasındaki bağlantıyı öğrenmeye çalışır. Eğitim verisi, girişler ve hedef çıktılardan oluşur ve fonksiyon regresyon (sürekli değerleri tahmin etmek) ya da sınıflama (kategorilere ayırmak) için kullanılır. Gözetimli öğrenme problemini çözmek için eğitim verisi türlerinin belirlenmesi, eğitim verisi toplama, girdi özelliklerinin belirlenmesi, algoritma ve model seçimi, model tasarımı ve optimizasyonu adımları takip edilir. Böylece doğru tahmin ve sınıflama için etkili bir öğrenme modeli geliştirilir (Uzun, 2007).

- **Gözetimsiz Öğrenme**

Çıktı verileri olmadan sadece giriş verileriyle öğrenme işlemini gerçekleştiren bir makine öğrenmesi tekniği olan gözetimsiz öğrenme, kümeleme ve veri sıkıştırma gibi işlemlerde kullanılır. Kümeleme, makine öğrenmesi, veri madenciliği, örüntü tanıma ve resim analizi gibi birçok alanda uygulanır (Uzun, 2007).

- **Yarı Gözetimli Öğrenme**

Gözetimli öğrenme ile benzer uygulamaları kullanır. Eğitim seti, küçük bir kısmı etiketli verilerden oluşurken büyük çoğunluğu etiketsiz verilerden oluşan öğrenme tekniğidir. Bu teknik, yüz tanıma uygulamalarında kullanılabilir (Aydın, 2020).

- **Pekiştirmeli Öğrenme**


Bu öğrenme tekniği, ödül/ceza sistemi kurarak deneme yanılma yoluyla en iyi eylemi öğrenmesini sağlar. Yani, algoritmaya doğru karar verdiğinde ödül verirken, yanlış ya da istenmeyen kararlar verdiğinde veren ve bu sayede zamanla hangi eylemleri yapması gerektiğini öğrenmesini sağlayan bir süreçtir. Günümüzde, oyun dünyasında oyuncu hareketlerini kontrol etmek ve otonom araçların çevresel koşullarına göre karar almasını sağlayacak algoritmalarda kullanılır (Efe ve Cangır, 2022).

4.1.2. Derin öğrenme

Derin öğrenme, sinir ağlarının birden fazla katmanını içeren bir öğrenme yaklaşımını ifade eder (Sharifani ve Amini, 2023). Derin öğrenme, genişlemeler ve ilerlemelerle birlikte daha fazla ilgi görmüş ve ayrı bir bölüm olarak kabul edilmiştir, temelde makine öğreniminin bir dalıdır. İnsan beyninin yapısını taklit ederek karmaşık sorunları çözebilen bir dizi algoritmadan oluşur (Forootan vd., 2022).

Derin öğrenme klasik makine öğrenmesini modelin karmaşıklığını artırarak ve veriyi çeşitli fonksiyonlarla dönüştürerek genişletir. Bu sayede veriler hiyerarşik bir şekilde temsil edilir. Ayrıca, ham veriden otomatik olarak özellik çıkarımı yapabilir. Derin öğrenme sadece video ve görüntüler gibi raster tabanlı verilerde değil, aynı zamanda ses, konuşma ve doğal dil gibi veri türlerinde de kullanılabilir (Kamilaris ve Prenafeta- Bodúl, 2018). Derin öğrenme modellerinin eğitimi, büyük çaba gerektirir ve en uygun hiper parametrelerin ayarlanması uzmanlık ve kapsamlı denemeler gerektirir; bu süreç oldukça zaman alıcı ve yorucudur (Muhammed ve Kora, 2023).

Şekil 4.1’de yapay zekâ, makine öğrenmesi ve derin öğrenme arasındaki ilişkiyi gösterilmiştir.



Şekil 4.1 Yapay zekâ, makine öğrenmesi ve derin öğrenme arasındaki ilişki


4.1.3. Yapay sinir ağları (YSA)

İnsanlardaki sinir sistemi sinir adı verilen hücrelerden oluşmaktadır ve bu sinirler sayesinde hayati faaliyetler yürütülür. İnsan vücudunda bulunduğu tahmin edilen 10^{10} - 10^{11} adet sinirler yalnızca insan beyninde değil, merkezi sinir sistemi üzerinde tüm vücuda yayılmıştır. Beynimizdeki sinirler sinyal alma, işlem yapma ve elektrokimyasal sinyallerin sinir ağları içerisinde iletimini sağlar. Yapay sinir ağları, biyolojik sinir sisteminden esinlenilerek uygulanan fakat gerçek sinir sistemlerinin bazı ayrıntılarının ihmal edildiği teknolojik ve bilimsel yöntemlere uygulanmasıdır (Şen, 2004).

Tablo 4.1 Biyolojik sinir sistemi elemanlarının yapay sinir sistemindeki karşılığı

Biyolojik Sinir Sistemi	Yapay Sinir Sistemi
Nöron	İşlemci Elemanı
Dentrit	Toplama Fonksiyonu
Hücre Gövdesi	Transfer Fonksiyonu
Aksonlar	Yapay Nöron Çıkışı
Sinapslar	Ağırlıklar

Yapay sinir ağı hücresi; girdiler ($x_1, x_2, x_3, \dots, x_n$), ağırlıklar ($w_{1j}, w_{2j}, w_{3j}, \dots, w_{nj}$), transfer fonksiyonu, aktivasyon fonksiyonu ve çıktı (o_j) olmak üzere beş bileşenden oluşur. Girdiler, dış ortamdan alındıktan sonra ağırlıkları ile hücreye bağlanarak net girdi değeri hesaplanır. Hücreye gelen toplam girdi miktarı, aktivasyon fonksiyonunda işlenerek hücrenin üreteceği çıktı miktarı belirlenir. Yapay sinir hücre modeli Şekil 4.2’de gösterilmiştir.



Şekil 4.2 Yapay sinir hücresi (Öztürk ve Şahin, 2018)

Girdiler: Bir yapay hücresine dış dünyadan gelen ya da bir önceki katmandan alınan bilgiler giriş olarak yapay sinir hücrelerine gönderilir (Yavuz ve Deveci, 2012).

Ağırlıklar: Girişlerin çıkışa ne ölçüde etki ettiğini belirler. Örneğin w_{1j} ağırlığı, x_1 girişinin çıkış üzerindeki etkisini gösterir. Ağırlıklar sabit ya da değişken olabilir (Öğücü, 2006).

Toplama Fonksiyonu: Bir hücrenin net girdisini hesaplamak için değişik fonksiyonlar kullanılmaktadır. En yaygın kullanılan, ağırlıklı toplam fonksiyonudur. Bu fonksiyonda,

her giriş kendi ağırlığı ile çarpılır ve elde edilen değerler toplanır. Yapay sinir ağındaki her hücre farklı toplama fonksiyonuna sahip olabilir (Öğücü, 2006).

Transfer (Aktivasyon) Fonksiyonu: Hücreye gelen net girdiyi işleyerek, hücrenin bu girdiye karşılık bir çıktı üretir. Bu fonksiyonu seçerken genelde doğrusal olmayan bir fonksiyonun tercih edilir. Aktivasyon fonksiyonu seçilirken fonksiyonun türevinin kolay hesaplanabilir olması gerekmektedir. Çünkü geri beslemeli ağlarda bu fonksiyonun türevi kullanıldığından, hesaplama sürecinin yavaşlamaması için türevi kolay hesaplanabilen fonksiyon seçilmelidir (Yazıcıoğlu, 2010).

- Doğrusal aktivasyon fonksiyonu, girdinin sabit bir katsayı ile çarpılması sonucu elde edilir ve dolayısıyla çıktı, girdi ile doğru orantılıdır. Matematiksel formülü $f(x_i)=k \cdot x_i$ 'dir. Burada $f(x_i)$ aktivasyon fonksiyonunun çıktısıdır, x_i girdidir ve k sabit bir katsayıdır. Bu denkleme göre çıktı girdinin k katıdır. Çıktı $[-\infty, +\infty]$ aralığında herhangi bir değer olabilir.
- Sigmoid fonksiyonu, S şeklinde bir eğriye sahiptir ve çıktı $[0,1]$ aralığındadır. Doğrusal olmadığından modelin farklı verilere uyum sağlayıp, çıktılar arasında ayrım yapmasını kolaylaştırdığından, doğrusal aktivasyon fonksiyonlarına göre daha çok tercih edilirler. Sigmoid fonksiyonun matematiksel formülü şu şekildedir:

$$f(x_i) = \frac{1}{1+e^{-x_i}} \quad (4.1)$$

- Tanjant fonksiyonu, sigmoid fonksiyonundan elde edilebilir ve hiperbolik tanjant fonksiyonu olarak da bilinir. Çıktısının $[-1, 1]$ aralığında oluşu, aktivasyonların büyük değer almasını önler ve öğrenmeyi daha kolay hale getirir. Bu özelliğinden dolayı yapay sinir ağlarının gizli katmanlarında kullanılır. Bu fonksiyonun matematiksel formülü şu şekildedir:

$$\tanh(x_i) = \frac{\sinh x_i}{\cosh x_i} = \frac{e^{x_i} - e^{-x_i}}{e^{x_i} + e^{-x_i}} = \frac{2}{1+e^{-2x_i}} - 1 = 2\text{sigmoid}(2x_i) - 1 \quad (4.2)$$

- ReLu fonksiyonu, genellikle yapay sinir gizli katmanlarında kullanılır. Matematiksel formülü şu şekildedir:

$$f(x_i) = \max(0, x_i) = \begin{cases} x_i, & x_i > 0 \\ 0, & x_i < 0 \end{cases} \quad (4.3)$$

ReLu fonksiyonu doğrusal değildir. Sigmoid ve tanjant fonksiyonlarına göre daha az hesaplama maliyetine sahip olduğundan yaygın olarak daha çok tercih edilirler.

- Sızma (Leaky) ReLu, negatif girdilere karşı çıktıyı 0 yerine küçük bir değerle değiştirerek sızma özelliği ekleyen bu aktivasyon fonksiyonudur. Negatif girdilere

sabit bir çarpanla çarpılarak bir çıktı değeri üretebildiğinden, ReLu 'ya göre her iki yönde de doaygunlaşmadığından daha geniş aralıkta etkin olmasını sağlar. Denklemi şu şekildedir:

$$f(x_i) = \begin{cases} x_i, & x_i > 0 \\ a, & x_i < 0 \end{cases} \quad (4.4)$$

- Parametrelili ReLu (PReLu) fonksiyonu, Sızma ReLu' ya benzer gibi gözüke de sabit bir değeri olan a_i , her bir kanal için farklı olabilir ve ağırlık geri yayılım algoritması (BP) ile öğrenilebilir. Denklemi şu şekildedir:

$$f(x_i) = \begin{cases} x_i, & x_i > 0 \\ a_i x_i, & x_i < 0 \end{cases} \quad (4.5)$$

PReLu, $a_i = 0$ olduğunda, ReLu 'ya dönüşür; a_i sabit ve küçük bir değeri olduğunda ise Sızma (Leaky) ReLu' ya dönüşür.

- RReLu, negatif girdilerin işlenmesinde etkilidir. Denklemi şu gibidir:

$$f(x_{ji}) = \begin{cases} x_{ji}, & x_{ji} \geq 0 \\ a_{ji} x_{ji}, & x_{ji} < 0 \end{cases} \quad (4.6)$$

Bu denklemde, a_{ji} negatif girdilerin eğimi, i kanalı ve j ise örneği temsil etmektedir.

- ELU (Üssel Doğrusal Birim) fonksiyonu, öğrenmeyi hızlandırır. Denklemi şu şekildedir:

$$f(x_i) = \begin{cases} x_i, & x_i > 0 \\ a_i(e^{x_i} - 1), & x_i \leq 0 \end{cases} \quad (4.7)$$

Bu denkleme göre negatif girdilerin aktivasyonları sıfıra çok yakın olması ELU' nun öğrenme hızını artırır (Feng ve Lu, 2019).

Çıktılar: Aktivasyon fonksiyonu ile belirlenen çıktı değeridir. Yani kısaca, nörona gelen farklı girdileri toplama fonksiyonunda toplanır ve net girdiye dönüştürülür (Boltürk, 2013).

Aktivasyon fonksiyonları çalışmanın amacına ve modelin yapısına göre belirlenmektedir. Öğrenmenin negatif ya da pozitif bölgelerde üreteceği çıktıya göre aktivasyon fonksiyonu belirlenir.

4.1.3.1. Tek katmanlı yapay sinir ağırları

Yapay sinir ağırlarının en basit örneklerinden biri olan tek katmanlı algılayıcılar sadece girdi ve çıktı katmanından oluşur. Algılayıcıda sorunlu girdi bir ağırlık değeri ile çarpılır ve bu çarpımların toplamı, belirli bir eşik gruplara göre sınıflandırılır. Elde edilen bu toplam değeri eşik değerden büyükse çıktı 1, eğer küçükse çıktı -1 (bazen 0) olur. Bu


algılayıcıların en büyük sorunu doğrusal olmayan verilerin öğrenilememesidir (Öztemel, 2003). Şekil 4.3'te tek katmanlı algılayıcı modeli gösterilmiştir.



Şekil 4.3 Tek Katmanlı Algılayıcı Modeli (Arı ve Berberler, 2017)

4.1.3.2. Çok katmanlı algılayıcı yapay sinir ağları (MLP)

Doğrusal olmayan problemlerin çözümünde tek katmanlı algılayıcılar ile başarı sağlanamadığından, bu modeller geliştirilip çok katmanlı (MLP) algılayıcılar elde edilmiştir. Bu algılayıcılar bir girdi katmanı, bir ya da birden fazla gizli katman ve bir çıkış katmanından meydana gelmektedir (Arı ve Berberler 2017). Katmanlardaki tüm nöronlar birbirine tam bağlıdır. ÇKA modelinde en uygun eğitim için gizli katmandaki nöron sayısı en az bir denemeye başlanarak farklı testlerle artırılabilir (İşeri ve Arıman, 2019). Girdi katmanı, herhangi bir hesaplama yapmaz sadece verinin ağı aktarılmasını sağlar. Bu modelde girdiler, ağırlıklarla çarpılarak toplanır ve bu toplam, doğrusal olmayan bir aktivasyon (transfer) fonksiyonundan geçirilir. Yani, çok katmanlı algılayıcılar, basit doğrusal olmayan fonksiyonların üst üste eklenmesiyle karmaşık tahminler yapabilir (Gardner ve Dorling, 1998). Şekil 4.4'te çok katmanlı algılayıcı modeli gösterilmiştir.



Şekil 4.4 Çok katmanlı algılayıcı modeli (Arı ve Berberler, 2017)


Bu modelin en büyük avantajı genelleme yeteneğinin olmasıdır. Fakat yüksek boyutlu verilerde ölçeklenebilirlik gibi dezavantajları da bulunmaktadır. Büyük ölçekli verilerde

tüm nöronlar birbiri ile bağlantılı olduğundan modelde hesaplama yükü artabilir ve yüksek bellek ve işlemci gereksinimi ortaya çıkabilir. Basit sınıflandırma, düşük boyutlu veriler ve regresyon analizleri için uygundur (Shiri vd., 2023).

4.1.3.3. İleri beslemeli algılayıcılar

İleri besleme, katmanlar arasındaki tüm bağlantıların bir sonraki katmana doğru aktarılmasıdır (Pradhan vd., 2010).

İleri beslemeli ağlarda, bir katmanın çıktısı bir sonraki katman için girdi olur. Bu akışta, çıktıyı girdiye geri beslemesi yoktur. Tahmin edilen çıktılar ile orijinal eğitim çıktıları karşılaştırılarak hata oranı azaltılır (Bhattacharjee vd., 2007). Şekil 4.5'te ileri beslemeli YSA modeli gösterilmiştir.



Şekil 4.5 İleri beslemeli yapay sinir ağı modeli (Fırat ve Güngör, 2004)

4.1.3.4. Geri beslemeli algılayıcılar

Dinamik bir yapıya sahip olan geri beslemeli yapay sinir ağlarında, gizli katman ve çıktı katmanındaki nöronlar, çıktı verilerini girişe veya bir önceki katmandaki nöronlara yeniden girdi olarak iletilirler. Bu algılayıcılarda, geri besleme işlemi genelde bir geciktirme elemanı aracılığı ile yapılmaktadır (Bayır, 2006).

Eğri uyurma, doğrusal olmayan sınıflama ve tahmin problemlerinde başarı oranları yüksek olduğundan çeşitli uygulamalarda tercih edilirler (Mengi ve Metlek, 2020). Kohonen ağları ve hopfield ağları gibi çeşitli geri beslemeli ağlar bulunmaktadır (Özdemir, 2013). Şekil 4.6'da geri beslemeli YSA modeli gösterilmiştir.




Şekil 4.6 Geri beslemeli yapay sinir ağı modeli (Mengi ve Metlek, 2020)

4.1.3.5. Uzun Kısa Süreli Bellek (LSTM)

LSTM mimarisi ilk olarak 1997 yılında Hochreiter ve Schmidhuber tarafından Long short-term memory makalesinde anlatılmıştır (Schmidhuber ve Hochreiter, 1997).

LSTM uzun süreli bağımlılık sorunlarını çözebildiği gibi gradyan kaybolma olasılığını azaltabilmektedir. Bu yapının giriş, unutma ve çıkış olmak üzere üç tür kapı yapısı vardır. Giriş kapısı, mevcut girdiden veya geçmiş gizli durum sigmoid fonksiyonuyla işleyerek hücre durumunu günceller. Unutma kapısı, hücre durumunda hangi bilgilerin korunacağını veya silineceğini belirler. Çıkış kapısı ise, gizli durumun hangi bilgiyi taşıyacağını kontrol eder. Hücre durumu, geçmiş bilgi ve mevcut girişin tanh ve sigmoid fonksiyonları ile işlenip birleştirilmesiyle elde edilir. Gizli durum, mevcut hücre çıkışı olarak kullanılıp bir sonraki zaman adımına aktarılır. LSTM, bias vektörleri, ağırlık matrisleri ve sigmoid ile tanh fonksiyonları gibi parametrelerle çalışır. Bu model, geri yayılım algoritması hata fonksiyonunu minimize eder (Zha vd., 2022). Şekil 4.7’ de LSTM ünitesinin yapısı gösterilmiştir.



Şekil 4.7 LSTM ünitesinin yapısı (Taroon vd., 2020)

Sıralı ve uzun vadeli bağımlılıkları yakalama performansı, diğer algoritmalara göre daha iyidir. Fakat karmaşık giriş verilerinde sınırlı performansa sahip olabilir. Buna çözüm olarak LSTM'in farklı varyasyonları kullanılabilir. Doğal dil işleme, zaman serisi analizleri, duygu tanıma alanlarında kullanılabilir (Shiri vd., 2023).

5. METODOLOJİ

5.1. Veri Seti

Veri setinde güneş enerji verileri ABD’de bulunan Illinois Üniversitesi’nden toplanmıştır (Kuzmiakova vd., 2017). Aynı veri seti içerisinde bulunan meteorolojik veriler ise Ulusal Okyanus ve Atmosfer İdaresi (NOAA) tarafından sağlanmıştır (Kuzmiakova vd., 2017). Veri seti <https://github.com/ColasGael/Machine-Learning-for-Solar-Energy-Prediction> adresinden indirilmiştir. Sistemin 20,8 dönümlük bir alanda kuruludur. Sistem 4,68 MW kurulu güce sahip olup yıllık üretim kapasitesi 7200 MWh’tir. İndirilen veri setinde bulut kapsamı, görünürlük, sıcaklık, nem, rüzgâr hızı, basınç, rakım, çiy noktası ve üretilen enerji miktarı parametreleri bulunmaktadır. Bu parametreler günlük ortalama değerlerdir. Sinop ilinin güneş enerji potansiyeli tahmini için gerekli olan veriler ise Sinop Meteoroloji Müdürlüğü’nün Sinop Havaalanı istasyonundan alınmıştır. Sinop Meteoroloji Müdürlüğünden alınan veriler içerisinde çiy noktası parametresi bulunmadığı için modelin eğitimi sırasında indirilen veriden çiy noktası parametresi çıkarılmıştır. Buradaki amaç daha güvenilir ve gerçekçi bir modelin oluşturularak doğru tahminler yapılmasıdır. Çalışmada Sinop Meteoroloji Müdürlüğü’nün Sinop Havaalanı istasyonundan alınan 2023 yılının meteorolojik verileri kullanılmıştır. Veriler arasında teknik sebeplerden dolayı ölçülemeyen değerler bulunduğundan dolayı aynı günlerin 2022 yılı verileri kullanılmıştır. Model eğitimlerinde kullanılan veri seti ABD’den alındığından, girdi parametrelerinin birimleri ülkemizden farklılık göstermektedir. Bu durumun model tarafından hesaplanacak tahminlerde yanıltıcı sonuçlar oluşturacağı için birimleri farklı olan parametrelerin dönüşümleri aşağıdaki gibi yapılmıştır:

- Bulut kapsamı, ülkemizdeki birimi 8 okta’dır. ABD verilerinde ise bu parametre % olarak verilmiştir. Bu farklılıktan dolayı Sinop’tan alınan bu parametreye ait veriler 8’e bölünerek % birimine dönüştürülmüştür.
- Rüzgâr hızı, ülkemizdeki birimi m/sn’dir. ABD verilerinde ise bu parametre Mph (Mil/saat) olarak verilmiştir. Bu farklılıktan dolayı Sinop’tan alınan bu parametreye ait veriler 0,44704’e bölünerek Mph birimine dönüştürülmüştür.
- Görünürlük için Sinop verilerinde ortalama değer ölçümü bulunmadığından, maksimum ve minimum görünürlük değerlerinin ortalaması alınmıştır. Bu parametrenin ülkemizdeki birimi km’dir. ABD verilerinde ise bu parametre

mil olarak verilmiştir. Bu farklılıktan dolayı Sinop'tan alınan bu parametreye ait veriler 1,60934'e bölünerek mil birimine dönüştürülmüştür.

- Basınç, ülkemizdeki birimi hPa'dır. ABD verilerinde ise bu parametre inchHg olarak verilmiştir. Bu farklılıktan dolayı Sinop'tan alınan bu parametreye ait veriler 0,02953 ile çarpılarak inchHg birimine dönüştürülmüştür.
- Sinop havaalanı istasyonunun rakımı 7 m'dir. ABD'de ise bu parametre inchHg birimi cinsinden verilmiştir. Alınan istasyon verisi deniz seviyesinde olmasından dolayı parametre değeri 29,92 inchHg olarak alınmıştır.

Sıcaklık ve nem parametrelerinin birimleri aynı olmasından dolayı herhangi bir dönüşüm yapılmamıştır. Parametrelerin ülkelere göre birimleri Tablo 5.1'de verilmiştir.

Tablo 5.1 Parametrelerin birimleri


Parametreler	ABD'deki veri birimi	Ülkemizdeki veri birimi
Bulut kapsamı	%	Okta
Rüzgâr Hızı	Mph	m/sn
Görünürlük	Mil	Km
Basınç	İncHg	hPa
Rakım	İncHg	M
Sıcaklık	°C	°C
Nem	%	%

13.09.2024 tarihinde Sinop Meteoroloji Müdürlüğünden alınan Sinop ili Havaalanı istasyonunun ham hava durumu verileri Ek 1'de verilmiştir. Tablo 5.1'e göre dönüşüm yapılmış ve hibrit modelin tahmin üretmesi için kullanılan Sinop ilinin hava durumu verileri Ek 2'de verilmiştir.

5.2. Kullanılan Yapay Zekâ Modelleri

Çalışmada zaman serileri analizindeki başarısından dolayı LSTM ve genelleme yeteneğinden dolayı MLP modeli tercih edilmiştir. Ayrıca bu iki modelin birbirlerine göre üstünlükleri göz önüne alınarak hibrit bir mimari geliştirilmiş ve daha etkili bir tahmin yapılması amaçlanmıştır. Modellerin yapıları aşağıda ayrıntılı bir şekilde verilmiştir.

MLP için tasarlanan model bir adet giriş, üç adet tam bağlantı, iki adet aktivasyon fonksiyonu ve çıkış katmanından oluşmaktadır. Model için 579x7 adet veri eğitim amacıyla kullanılmıştır. Model 579 adet tahmin oluşturmuştur. Modelin yapısı Şekil 5.1'de verilmiştir.




Şekil 5.1 MLP model-1'in yapısı

Yedi adet giriş verisi bulunduğundan input (giriş) katmanı değeri 7 olarak ayarlanmıştır. Birinci tam bağlantı katmanı 21, ikinci tam bağlantı katmanı 14 ve son tam bağlantı katmanında 1 adet nöron bulunmaktadır. Aktivasyon fonksiyonları olarak tanh ve relu kullanılmıştır. Çıkış katmanı sayısal değer üreteceği için regresyon olarak ayarlanmıştır. Modelin yapısal analizi Şekil 5.2'de verilmiştir.

ANALYSIS RESULT					
	Name	Type	Activations	Learnable Properties	States
1	input Sequence input with 7 dimensions	Sequence Input	$7(C) \times 1(B) \times 1(T)$	-	-
2	fc 21 fully connected layer	Fully Connected	$21(C) \times 1(B) \times 1(T)$	Weights 21×7 Bias 21×1	-
3	tanh Hyperbolic tangent	Tanh	$21(C) \times 1(B) \times 1(T)$	-	-
4	fc_1 14 fully connected layer	Fully Connected	$14(C) \times 1(B) \times 1(T)$	Weights 14×21 Bias 14×1	-
5	relu ReLU	ReLU	$14(C) \times 1(B) \times 1(T)$	-	-
6	fc_2 1 fully connected layer	Fully Connected	$1(C) \times 1(B) \times 1(T)$	Weights 1×14 Bias 1×1	-
7	regressionoutput mean-squared-error	Regression Output	$1(C) \times 1(B) \times 1(T)$	-	-

Şekil 5.2 MLP model-1'in yapısal analizi

MLP modelinde katman sayısının sonuca olan etkisinin değerlendirilmesi için ikinci bir model daha tasarlanmıştır. Model bir adet giriş, dört adet tam bağlantı, üç adet aktivasyon fonksiyonu ve çıkış katmanından oluşmaktadır. Model için 579x7 adet veri eğitim amacıyla kullanılmıştır. Model 579 adet tahmin oluşturmuştur. Modelin yapısı Şekil 5.3'de verilmiştir.




Şekil 5.3 MLP model-2 yapısı

Yedi adet giriş verisi bulunduğundan input (giriş) katmanını değeri 7 olarak ayarlanmıştır. Birinci tam bağlantı katmanını 28, ikinci tam bağlantı katmanını 21, üçüncü tam bağlantı katmanını 14 ve son tam bağlantı katmanında 1 adet nöron bulunmaktadır. Aktivasyon fonksiyonları olarak tanh ve relu kullanılmıştır. Çıkış katmanını sayısal değer üreteceği için regresyon olarak ayarlanmıştır. Modelin yapısal analizi Şekil 5.4’te verilmiştir.

ANALYSIS RESULT					
	Name	Type	Activations	Learnable Prope...	States
1	input Sequence input with 7 dimensions	Sequence Input	$7(C) \times 1(B) \times 1(T)$	-	-
2	fc 28 fully connected layer	Fully Connected	$28(C) \times 1(B) \times 1(T)$	Weights 28 × 7 Bias 28 × 1	-
3	tanh Hyperbolic tangent	Tanh	$28(C) \times 1(B) \times 1(T)$	-	-
4	fc_1 21 fully connected layer	Fully Connected	$21(C) \times 1(B) \times 1(T)$	Weights 21 × 28 Bias 21 × 1	-
5	tanh_1 Hyperbolic tangent	Tanh	$21(C) \times 1(B) \times 1(T)$	-	-
6	fc_2 14 fully connected layer	Fully Connected	$14(C) \times 1(B) \times 1(T)$	Weights 14 × 21 Bias 14 × 1	-
7	relu ReLU	ReLU	$14(C) \times 1(B) \times 1(T)$	-	-
8	fc_3 1 fully connected layer	Fully Connected	$1(C) \times 1(B) \times 1(T)$	Weights 1 × 14 Bias 1 × 1	-
9	regressionoutput mean-squared-error	Regression Output	$1(C) \times 1(B) \times 1(T)$	-	-

Şekil 5.4 MLP model-2’nin yapısal analizi

LSTM için tasarlanan model bir adet giriş, bir adet LSTM, bir adet dropout, bir adet aktivasyon fonksiyonu, bir adet tam bağlantı ve çıkış katmanından oluşmaktadır. Model için 579x7 adet veri eğitim amacıyla kullanılmıştır. Model 579 adet tahmin oluşturmuştur. Modelin yapısı Şekil 5.5’te verilmiştir.



Şekil 5.5 LSTM model yapısı

Yedi adet giriş verisi bulunduğundan input (giriş) katmanı değeri 7 olarak ayarlanmıştır. LSTM’de 128 gizli birim ve son tam bağlantı katmanında 1 adet nöron bulunmaktadır. Aktivasyon fonksiyonları olarak tanh ve relu kullanılmıştır. Çıkış katmanı sayısal değer üreteceği için regresyon olarak ayarlanmıştır. Aktivasyon fonksiyonları olarak relu kullanılmıştır. Çıkış katmanı sayısal değer üreteceği için regresyon olarak ayarlanmıştır. Modelin yapısal analizi Şekil 5.6’da verilmiştir.

ANALYSIS RESULT					
	Name	Type	Activations	Learnable Properties	States
1	input Sequence input with 7 dimensions	Sequence Input	$7(C) \times 1(B) \times 1(T)$	-	-
2	lstm LSTM with 128 hidden units	LSTM	$128(C) \times 1(B) \times 1(T)$	InputWeights 512 × 7 RecurrentWeights 512 × 128 Bias 512 × 1	HiddenState 128 × 1 CellState 128 × 1
3	dropout 50% dropout	Dropout	$128(C) \times 1(B) \times 1(T)$	-	-
4	relu ReLU	ReLU	$128(C) \times 1(B) \times 1(T)$	-	-
5	fc 1 fully connected layer	Fully Connected	$1(C) \times 1(B) \times 1(T)$	Weights 1 × 128 Bias 1 × 1	-
6	regressionoutput mean-squared-error	Regression Output	$1(C) \times 1(B) \times 1(T)$	-	-


Şekil 5.6 LSTM modelinin yapısal analizi

Hibrit modeller birden fazla algoritmanın bir arada kullanıldığı yapılardır. Hibrit modellerin temel amacı farklı algoritmaların birbirlerine göre üstünlüklerini bir modelde birleştirerek daha başarılı ve güvenilir sonuçlar elde etmektir. Bu amaç doğrultusunda önerilen hibrit modelde LSTM ve MLP yapıları birleştirilmiştir. Önerilen model tek bir algoritmanın kullanıldığı modellere göre daha iyi sonuç vermiştir.

Model üç bloktan oluşmaktadır. Giriş bloğunda giriş katmanı, paralel yapıda bulunan LSTM, dropout ve tam bağlantı katmanları bulunmaktadır. Tam bağlantı katmanının ve LSTM katmanının çıkışları birleştirme katmanı ile tek bir veri haline dönüştürülmüştür. Tam bağlantı katmanı 128 nöron ve LSTM ise 128 gizli birimden oluşmaktadır.

Buradan elde edilen veriler birleştirilerek 256x1 boyutunda çıktı elde edilmiştir. Bu sayede 7x1 boyutundaki veriler 256x1 boyutundaki veriye dönüştürülmüştür. 256x1 boyutundaki veri 5 adet aktivasyon fonksiyonu katmanı ve 5 adet tam bağlantı katmanından geçirilerek çıkış katmanına aktarılmıştır. Çıkışta bulunan regresyon katmanı ile modelin tahmin değeri üretilmiştir.

Model için 579x7 adet veri eğitim amacıyla kullanılmıştır. Model 579 adet tahmin oluşturmıştır. Modelin yapısı Şekil 5.7’de verilmiştir.



Şekil 5.7 MLP-LSTM hibrit model yapısı

Hibrit modelin yapısal analizi Şekil 5.8’de verilmiştir.

ANALYSIS RESULT					
	Name	Type	Activations	Learnable Properties	States
1	input Sequence input with 7 dimensions	Sequence Input	$7(C) \times 1(B) \times 1(T)$	-	-
2	lstm LSTM with 128 hidden units	LSTM	$128(C) \times 1(B) \times 1(T)$	InputWeights 512×7 RecurrentWeights 512×128 Bias 512×1	HiddenState 128×1 CellState 128×1
3	fc 128 fully connected layer	Fully Connected	$128(C) \times 1(B) \times 1(T)$	Weights 128×7 Bias 128×1	-
4	dropout 50% dropout	Dropout	$128(C) \times 1(B) \times 1(T)$	-	-
5	concat Concatenation of 2 inputs along dimension 1	Concatenation	$256(C) \times 1(B) \times 1(T)$	-	-
6	tanh Hyperbolic tangent	Tanh	$256(C) \times 1(B) \times 1(T)$	-	-
7	fc_5 128 fully connected layer	Fully Connected	$128(C) \times 1(B) \times 1(T)$	Weights 128×256 Bias 128×1	-
8	tanh_3 Hyperbolic tangent	Tanh	$128(C) \times 1(B) \times 1(T)$	-	-
9	fc_1 64 fully connected layer	Fully Connected	$64(C) \times 1(B) \times 1(T)$	Weights 64×128 Bias 64×1	-
10	tanh_1 Hyperbolic tangent	Tanh	$64(C) \times 1(B) \times 1(T)$	-	-
11	fc_2 32 fully connected layer	Fully Connected	$32(C) \times 1(B) \times 1(T)$	Weights 32×64 Bias 32×1	-
12	tanh_2 Hyperbolic tangent	Tanh	$32(C) \times 1(B) \times 1(T)$	-	-
13	fc_3 16 fully connected layer	Fully Connected	$16(C) \times 1(B) \times 1(T)$	Weights 16×32 Bias 16×1	-
14	relu ReLU	ReLU	$16(C) \times 1(B) \times 1(T)$	-	-
15	fc_4 1 fully connected layer	Fully Connected	$1(C) \times 1(B) \times 1(T)$	Weights 1×16 Bias 1×1	-
16	regressionoutput mean-squared-error	Regression Output	$1(C) \times 1(B) \times 1(T)$	-	-

Şekil 5.8 MLP-LSTM hibrit modelinin yapısal analizi

5.3. Model Eğitim ve Test Süreci

Veri setlerinde ülkelere bağlı birimsel farklılıklardan dolayı öncelikle Sinop Meteoroloji Müdürlüğünden alınan hava durumu verileri ABD hava durumu verilerindeki birimlere dönüştürülmüştür. Dönüşüm sonucunda elde edilen veriler modele verilmeden önce normalizasyon işleminden geçirilmiştir. Böylelikle veriler $[-1, 1]$ aralığına dönüştürülmüştür. Buradaki amaç eğitimin daha hızlı ve doğru bir biçimde gerçekleştirilmesidir. Sınırlı veri setinden dolayı geliştirilen modellerin daha fazla örnek üzerinden eğitilmesi amaçlanmış ve ABD veri setinin tamamı eğitim ve test amacıyla kullanılmıştır.

Modellerin tamamında güvenilirliğin sağlanması açısından eğitim parametreleri sabit tutulmuştur. Veri setindeki ve hibrit modeldeki karmaşıklık göz önüne alınarak parametreler belirlenmiştir. Öğrenme oranının düşük seçilmesi hassasiyeti artırsa da öğrenme sürecini uzatabilir. Büyük seçilmesi ise kararsızlığa yol açabilir. Bu parametreler aşağıdaki gibi ayarlanmıştır:

```

options = trainingOptions('rmsprop', ...
'MaxEpochs',1000, ...
'InitialLearnRate',1e-3, ...
'MiniBatchSize',16, ...
'GradientThreshold',5, ...
'Shuffle','every-epoch', ...
'Verbose',true, ...
'Plots','training-progress');

```

5.4. Kullanılan Performans Ölçütleri

Modellerin başarı kriteri MAPE ve R^2 değerlerine bakılarak karşılaştırılmıştır.

MAPE, modelin tahminlerinin doğruluğunu değerlendirmek için literatürde sıklıkla kullanılan bir ölçüttür. Gerçek değerlerle modelin tahminleri arasındaki hata miktarını yüzde türünden gösterir. 0(sıfır)'a yakın olması istenir. MAPE'nin genel formülü şu şekildedir;

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left(\frac{y_i - \hat{y}_i}{y_i} \right) * 100 \quad (5.1)$$

Denklemden n toplam veriyi, y_i gerçek değerleri, $\hat{y}_i$ modelin tahmin değerlerini göstermektedir.

R^2 , modelin veri üzerindeki uygunluğunu değerlendiren bir ölçüttür. 1'e yakın olması istenir. R^2 'nin genel formülü şu şekildedir;

$$R^2 = 1 - \left(\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \right) \quad (5.2)$$

Denklemden n toplam veriyi, y_i gerçek değerleri, $\hat{y}_i$ modelin tahmin değerlerini ve $\bar{y}$ gerçek değerlerin ortalamasını göstermektedir.

5.5. Yazılım ve Donanım Altyapısı

Modeller MATLAB Deep Network Designer kullanılarak tasarlanmıştır. Modellerin kodları Generate MATLAB Code From Deep Network Designer kullanılarak oluşturulmuştur. Eğitim ve test sürecinde Intel(R) Core(TM) i5-7200U CPU @ 2.50GHz 2.70 GHz 8GB RAM donanımsal özelliğe sahip bilgisayar kullanılmıştır.

5.6. Sınırlılıklar ve Varsayımlar

Modellerin eğitiminde kullanılan veri seti yaklaşık olarak 1,5 yılı kapsamaktadır. Bu neden dolayı modeller büyük miktarda veri seti kullanılarak eğitilip test edilememiştir. Aynı şekilde ülkemizde hava durumu ve üretilen güneş enerji verilerini içeren bir veri seti bulunmadığından coğrafi durumlardan kaynaklı farklılıklar dikkate alınmalıdır. Güneş enerjisi üretim tahmini yapılacak illerde istasyonların donanımsal özelliklerinden kaynaklı eksik hava durumu verileri içermesi önemli bir sorundur. Dünya genelinde yaşanan iklim krizi birçok ülkenin ve ilin hava durumu verilerinde yıllara göre büyük değişiklikler göstermesine neden olmaktadır. Bu durum geliştirilen modellerin tahminlerinde sapmalara neden olabilir.




6. BULGULAR VE SONUÇ

Bu çalışmada Sinop ili için güneş enerjisi potansiyeli hesaplanmaya çalışılmıştır. Bu bağlamda MLP modeli, LSTM modeli ve özgün olarak tasarlanan MLP-LSTM hibrit modeli kullanılmıştır. Modeller, Github'dan indirilen gerçek veri seti ile eğitilmiş ve aynı şekilde tahminler için Sinop Meteoroloji Müdürlüğünden alınan gerçek hava durumu verileri kullanılmıştır.

6.1. Modellerin Eğitim Süreci ve Sonuçları


6.1.1. MLP Model-1

Modelin ortalama mutlak yüzde hatası (MAPE) değeri %21,965 olarak hesaplanmıştır. Determinasyon katsayısı(R^2) değeri 0,84123 olarak hesaplanmıştır. Modelin iterasyona göre Kök Ortalama Kare Hatası (RMSE) değeri Şekil 6.1'de verilmiştir.




Şekil 6.1 MLP model-1'in RMSE değerleri

Modelin eğitim sürecinde tahminleri ile gerçek değerler arasındaki farkı gösteren Loss (Kayıp) değerleri Şekil 6.2'de gösterilmiştir. Loss grafiği modelin eğitim sürecinde ne kadar öğrendiğini ve optimizasyon sürecinin nasıl ilerlediğini göstermektedir. Model tahminlerinin iterasyon süreci boyunca tahminlerin gerçek verilere ne kadar yakın olduğunu ölçer. İterasyon ilerledikçe loss değerinin azalması beklenir. Şekildeki anlık yükselmeler MiniBatchSize verilerinin anlık loss değerlerini göstermektedir.




Şekil 6.2 MLP model-1'in Loss değerleri

Modelin varyansı, gerçek ve tahmin edilen değerler Şekil 6.3'te verilmiştir.



Şekil 6.3 MLP model-1'in performansı


Şekil 6.4'te modelin tahminlerinin hata dağılımları verilmiştir. Her sütun belirli bir hata aralığında kaç tahmin ve gerçek değer olduğunu göstermektedir. Pozitif değerler model tahmininin gerçek değerden daha düşük, negatif değerler model tahmininin gerçek değerden daha büyük olduğunu belirtmektedir.



Şekil 6.4 MLP model-1'in hata histogramı


6.1.2. MLP Model-2

Modelin ortalama mutlak yüzde hatası (MAPE) değeri %23,5132 olarak hesaplanmıştır. Determinasyon katsayısı(R^2) değeri 0,83325 olarak hesaplanmıştır. Modelin iterasyona göre Kök Ortalama Kare Hatası (RMSE) değeri Şekil 6.5'te verilmiştir.




Şekil 6.5 MLP model-2'nin RMSE değerleri

Modelin eğitim sürecinde tahminleri ile gerçek değerler arasındaki farkı gösteren Loss (Kayıp) değerleri Şekil 6.6'da gösterilmiştir. Loss grafiği modelin eğitim sürecinde ne kadar öğrendiğini ve optimizasyon sürecinin nasıl ilerlediğini göstermektedir. Model tahminlerinin iterasyon süreci boyunca tahminlerin gerçek verilere ne kadar yakın olduğunu ölçer. İterasyon ilerledikçe loss değerinin azalması beklenir. Şekildeki anlık yükselmeler MiniBatchSize verilerinin anlık loss değerlerini göstermektedir.




Şekil 6.6 MLP model-2'nin Loss değerleri

Modelin varyansı, gerçek ve tahmin edilen değerler Şekil 6.7'de verilmiştir.



Şekil 6.7 MLP model-2'nin performansı


Şekil 6.8'de modelin tahminlerinin hata dağılımları verilmiştir. Her sütun belirli bir hata aralığında kaç tahmin ve gerçek değer olduğunu göstermektedir. Pozitif değerler model tahmininin gerçek değerden daha düşük, negatif değerler model tahmininin gerçek değerden daha büyük olduğunu belirtmektedir.



Şekil 6.8 MLP model-2'nin hata histogramı

6.1.3. LSTM Modeli


Modelin ortalama mutlak yüzde hatası (MAPE) değeri %29,2656 olarak hesaplanmıştır. Determinasyon katsayısı (R^2) değeri 0,77333 olarak hesaplanmıştır. Modelin iterasyona göre Kök Ortalama Kare Hatası (RMSE) değeri Şekil 6.9'da verilmiştir.



Şekil 6.9 LSTM modelin RMSE değerler


Modelin eğitim sürecinde tahminleri ile gerçek değerler arasındaki farkı gösteren Loss (Kayıp) değerleri Şekil 5.16'da gösterilmiştir. Loss grafiği modelin eğitim sürecinde ne kadar öğrendiğini ve optimizasyon sürecinin nasıl ilerlediğini göstermektedir. Model tahminlerinin iterasyon süreci boyunca tahminlerin gerçek verilere ne kadar yakın olduğunu ölçer. İterasyon ilerledikçe loss değerinin azalması beklenir. Şekildeki anlık yükselmeler MiniBatchSize verilerinin anlık loss değerlerini göstermektedir. Bu durum

dikkate alındığında LSTM modelinin Loss değerinin MLP model-1 ve MLP model-2'ye göre daha yüksek değerde olduğu Şekil 6.10'da görülmektedir.




Şekil 6.10 LSTM modelin Loss değerleri

Modelin varyansı, gerçek ve tahmin edilen değerler Şekil 6.11'de verilmiştir.



Şekil 6.11 LSTM modelinin performansı


Şekil 6.12'de modelin tahminlerinin hata dağılımları verilmiştir. Her sütun belirli bir hata aralığında kaç tahmin ve gerçek değer olduğunu göstermektedir. Pozitif değerler model tahmininin gerçek değerden daha düşük, negatif değerler model tahmininin gerçek değerden daha büyük olduğunu belirtmektedir.



Şekil 6.12 LSTM modelin hata histogramı

6.1.4. MLP-LSTM Hibrit Modeli


Modelin ortalama mutlak yüzde hatası (MAPE) değeri %8,4888 olarak hesaplanmıştır. Determinasyon katsayısı(R^2) değeri 0,96935 olarak hesaplanmıştır. Modelin iterasyona göre Kök Ortalama Kare Hatası (RMSE) değeri Şekil 6.13'te verilmiştir.



Şekil 6.13 MLP-LSTM hibrit modelin RMSE değerleri


Modelin eğitim sürecinde tahminleri ile gerçek değerler arasındaki farkı gösteren Loss (Kayıp) değerleri Şekil 5.22'da gösterilmiştir. Loss grafiği modelin eğitim sürecinde ne kadar öğrendiğini ve optimizasyon sürecinin nasıl ilerlediğini göstermektedir. Model tahminlerinin iterasyon süreci boyunca tahminlerin gerçek verilere ne kadar yakın olduğunu ölçer. İterasyon ilerledikçe loss değerinin azalması beklenir. Şekildeki anlık yükselmeler MiniBatchSize verilerinin anlık loss değerlerini göstermektedir. Bu durum

dikkate alındığında yukarıda bahsedilen modellere göre en düşük Loss değerinin tasarlanan hibrit model sayesinde elde edildiği Şekil 6.14'te görülmektedir.




Şekil 6.14 MLP-LSTM hibrit modelin Loss değerleri

Modelin varyansı, gerçek ve tahmin edilen değerler Şekil 6.15'te verilmiştir.



Şekil 6.15 MLP-LSTM hibrit modelinin performansı

Şekil 6.16'da modelin tahminlerinin hata dağılımları verilmiştir. Her sütun belirli bir hata aralığında kaç tahmin ve gerçek değer olduğunu göstermektedir. Pozitif değerler model tahmininin gerçek değerden daha düşük, negatif değerler model tahmininin gerçek değerden daha büyük olduğunu belirtmektedir.



Şekil 6.16 MLP-LSTM hibrit modelin hata histogramı

Tablo 6.1'e bakıldığında, en iyi performansı geliştirilen hibrit modelin verildiği görülmektedir. İkinci sırada MLP model-1, üçüncü sırada MLP model-2 ve dördüncü sırada ise LSTM modeli gelmektedir. MLP modellerinde katman sayısının artması başarı oranını artırmayabilir. Bunun nedeni katman sayısının artmasına bağlı olarak veri kaybı olabilir. Hibrit modelin diğer modellere göre karmaşık yapısı olmasına rağmen eğitim süresinin kısa oluşu dikkat çekmektedir. Modellerin performansı MAPE ve R^2 değerlerine bakılarak yapılmıştır. R^2 değeri 1'e ne kadar yakın olursa model performansı o kadar iyi kabul edilir. MAPE değerinin ise 0'a yakın olması istenir. Bu parametreler göz önüne alındığında R^2 değeri 0,96935 ve MAPE değeri %8,4888 olarak hesaplanan en iyi performansın, geliştirilen hibrit model ile elde edildiği görülmektedir. Hibrit model kullanılarak Sinop ilinin güneş enerji potansiyeli hesaplanmıştır.

Tablo 6.1 Model parametreleri ve performans değeri

	MLP Model-1	MLP Model-2	LSTM Model	Hibrit Model
MaxEpochs	1000	1000	1000	1000
Öğrenme Oranı	0,001	0,001	0,001	0,001
MiniBatchSize	16	16	16	16
GradientThreshold	5	5	5	5
Eğitim Süresi	15 dakika 13 saniye	8 dakika 54 saniye	7 dakika 29 saniye	13 dakika 7 saniye
MAPE değeri	%21,965	%23,5132	%29,2656	%8,4888
R^2 değeri	0,84123	0,83325	0,77333	0,96935

Hibrit modelin veri setinde hesapladığı bazı tahmin değerleri Tablo 6.2’de verilmiştir. Verilen değerler rastgele seçilmiştir.

Tablo 6.2 Bazı gerçek değerler ve hibrit modelin tahmin sonuçları


Gerçek Değerler (kWh)	Model Tahmini (kWh)	Gerçek Değerler (kWh)	Model Tahmini (kWh)
20256	21262	29735	28320
28695	27629	33236	33175
9517	10265	32029	32065
26973	27226	26080	27146
22365	23306	34654	35726
6641	8663.8	29736	27938
30910	31867	18714	19272
8105	9694.2	9741	9397.1
30358	29266	27801	29374
5814	7757.5	36515	35008
19145	18735	19152	19599
30380	29402	26108	25913
26656	26694	37038	36445
1468	2660	18860	19488
14633	15959	31243	33260
16864	18361	22913	23658
32570	32418	36095	36276
25887	23385	39413	39258
31868	32284	21961	20929
30943	31175	38978	38429
2916	3797.9	31883	31842
30271	31580	26024	27290
9662	11283	31522	28958
28622	26268	32742	33502
23194	23553	34518	35691
7561	9836.1	14632	16442
6044	8631.9	18199	19299
26187	26201	30854	31465
8354	10204	35230	34684

6.2. Sinop İli İçin Güneş Enerji Potansiyeli


Sinop ilinin güneş enerji potansiyeli, eğitilip geliştirilen hibrit model kullanılarak hesaplanmıştır. Hibrit model $\pm\%8,4888$ hata oranı ile hesaplama yapmaktadır.

Önerilen hibrit model tarafından günlük hesaplanan güneş enerji potansiyelleri Şekil 6.17’de verilmiştir. Şekil 6.17 incelendiğinde enerji üretim potansiyeli ilkbahar ve kış


aylarında düşük iken yaz ve sonbahar aylarında ise daha yüksek değerlere sahip olduğu söylenebilir. Şekil 6.17 ile Şekil 6.18’de verilen Sinop ilinin global radyasyon değerleri karşılaştırıldığında modelin tahmin sonuçlarının radyasyon değerlerinin arttığı aylarda arttığı görülmektedir. Bu durum modelin güvenilir tahminler ürettiğini göstermektedir. Şekil 6.19’da verilen Sinop ilinin güneşlenme süresi verilerini de göz önüne aldığımızda güneşlenme süresinin artmasına bağlı olarak üretilen enerjinin de artması gerektiği düşünüldüğünde önerilen hibrit modelin güvenilirliği artırmaktadır. İklim değişikliğinden kaynaklı meteorolojik verilerde oluşacak farklılıklar enerji üretim potansiyelini etkileyeceği unutulmamalıdır.



Şekil 6.17 Sinop ili için aylara göre 1 yıllık güneş enerji potansiyeli tahmini



Şekil 6.18 Sinop ili global radyasyon değerleri (GEPA) (YEGM, 2022)



Şekil 6.19 Sinop ili güneşlenme süreleri (GEPA) (YEGM, 2022)

Sinop ilinin en iyi performansı veren hibrit modele göre günlük enerji potansiyel tahminleri Tablo 6.3'te verilmiştir.

Tablo 6.3 Günlere göre tahmin sonuçları

Gün	Tahmin	Gün	Tahmin	Gün	Tahmin	Gün	Tahmin
1	16833,57617	92	22701,25	183	20530,27	274	24868,89
2	16786,10547	93	22989,21	184	28552,63	275	27833,87
3	16216,05176	94	17787,18	185	31213,42	276	25107,22
4	15022,24609	95	25015,1	186	34447,56	277	24006,28
5	18661,03516	96	18238,67	187	29746,4	278	23445,44
6	9800,265625	97	5341,749	188	24937,98	279	24258,71
7	15690,95996	98	20247,55	189	22517,39	280	22819,58
8	14883,21484	99	23383,36	190	10629,33	281	22136,95
9	17237,05859	100	22638,04	191	23315,13	282	23938,83
10	19110,58008	101	23156,67	192	36956,82	283	24883,79
11	20701,81055	102	2833,238	193	38175,11	284	15316,18
12	18040,55273	103	19815,22	194	26049,77	285	30566,83
13	12013,98828	104	25052,2	195	33603,96	286	22597,59
14	10994,99707	105	24658,07	196	26089,92	287	22946,39
15	8351,59082	106	21999,52	197	30704,48	288	25796,21
16	9721,244141	107	25391,68	198	35649,12	289	26358,62
17	25710,94922	108	19626,97	199	35592,24	290	22701,69
18	22274,14648	109	15752,71	200	39382,88	291	19391,6
19	20637,18359	110	17955,31	201	31278,88	292	22814,77
20	20867,54102	111	8070,495	202	34565,53	293	25326,07
21	22843,38672	112	31214,55	203	27009,51	294	26121,9

Tablo 6.3'ün devamı

22	12091,66406	113	9046,672	204	27737,09	295	25068,31
23	18262,03125	114	21167,28	205	26424,68	296	26220,97
24	16216,3877	115	24065,3	206	30222,65	297	26013,72
25	18411,35352	116	23847,82	207	31825,63	298	24848,46
26	9248,942383	117	21728,3	208	26193,12	299	26892,91
27	28224,9707	118	618,3062	209	27433,14	300	23790,6
28	24858,08594	119	22725,64	210	37532,86	301	27123,61
29	7045,380859	120	9455,315	211	26193,78	302	27874
30	13874,23535	121	14964,43	212	28387,25	303	22565,24
31	2490,338379	122	24728,59	213	29388,42	304	26514,5
32	6940,748047	123	25379	214	26869,3	305	26087,38
33	12488,56055	124	24779,96	215	27840,09	306	20268,82
34	18902,36914	125	21232,72	216	27101,5	307	26650
35	21570,41016	126	12049,43	217	25585,71	308	22248,47
36	16837,74023	127	6844,85	218	28004,75	309	27651,8
37	5636,96875	128	1600,634	219	26156,54	310	35533,91
38	6700,910156	129	24595,78	220	29500,03	311	23847,02
39	1544,098389	130	16817,8	221	21400,45	312	25801,97
40	5512,770508	131	18495,57	222	29319,38	313	17365,43
41	15105,1084	132	23050,82	223	17664,08	314	22037,62
42	14626,91309	133	26920,98	224	23945,85	315	33066,34
43	21073,47656	134	35451,39	225	18425,61	316	16621,29
44	14532,98242	135	28924,51	226	28919,27	317	16290,73
45	23392,74414	136	16404,52	227	28714,68	318	23358,94
46	3537,466064	137	23852,02	228	24937,42	319	24545,99
47	15590,44141	138	20747,63	229	24880,08	320	14450,11
48	25732,02344	139	22211,66	230	28244,53	321	23810,87
49	18274,82031	140	10314,35	231	27723,63	322	16475,34
50	24907,01367	141	8262,212	232	27784,76	323	26484,19
51	9131,980469	142	18305,01	233	28801,74	324	8454,571
52	32665,72461	143	15664,36	234	38929,98	325	21641,5
53	22917,62305	144	13679,53	235	27181,59	326	24429,67
54	20374,22656	145	19196,59	236	37401,51	327	11294,21
55	12348,78125	146	19073,25	237	35092,39	328	15631,56
56	23507,20703	147	23172,81	238	31188,88	329	24867,59
57	27253,73242	148	10043,38	239	27293,61	330	23490,05
58	26776,65039	149	17696,59	240	25605,2	331	13124,28
59	17876,39258	150	19651,37	241	32371,16	332	23793,06
60	779,3021851	151	16882,76	242	27018,27	333	24996,28
61	5272,532227	152	34971,66	243	36479,2	334	11526,79
62	9243,578125	153	31999,73	244	32531,06	335	26430,91
63	15145,09473	154	15453,58	245	33019,77	336	23851,32
64	6920,541504	155	13581,12	246	13933,9	337	22528,81
65	3405,544922	156	10347,56	247	36660,2	338	21565,38

Tablo 6.3'ün devamı

66	26211,98828	157	28906,82	248	35281,99	339	5539,792
67	23468,71094	158	29022,85	249	21606,27	340	21917,58
68	26018,02539	159	29991,98	250	24982,45	341	20679,71
69	25180,6582	160	13377,79	251	28968,49	342	5742,501
70	28030,11914	161	30150,79	252	26464,48	343	4862,886
71	1001,623596	162	28005,3	253	21851,81	344	7816,233
72	18749,08398	163	28272,92	254	26828,44	345	20561,23
73	23020,99805	164	25095,06	255	25479,63	346	13155,62
74	15899,10938	165	35760,68	256	23874,59	347	21360,5
75	2786,527832	166	33459,23	257	26462,61	348	28149,61
76	20092,6875	167	27868,42	258	28152,77	349	22471,86
77	10193,01758	168	23315,04	259	25577,18	350	13404,13
78	2593,565918	169	20288,56	260	25733,73	351	9849,895
79	6182,79248	170	30144,9	261	24916,92	352	20757,32
80	20583,13086	171	20423,52	262	25588,71	353	23102,41
81	13376,00293	172	24784,32	263	24732,63	354	16740,16
82	18349,25391	173	32156,78	264	22940,06	355	19509,38
83	24054,88281	174	31088,69	265	24676,78	356	11526,42
84	6694,45459	175	28042,48	266	23983,58	357	20020,88
85	5955,76416	176	28342,16	267	25017,44	358	11818,69
86	24965,67383	177	33523,27	268	21336,66	359	24572,9
87	26084,58008	178	34161,05	269	27698,53	360	24621,55
88	3502,648438	179	29200,76	270	27551,32	361	25710,85
89	11532,40918	180	25195,66	271	27883,97	362	24373,49
90	22442,42188	181	28138,62	272	25550,2	363	20435,61
91	20248,30664	182	36035,31	273	25181,14	364	17900,86
						365	11289,13

7. SONUÇ VE ÖNERİLER

Dünyadaki nüfus artışı ve sanayileşme gibi faktörler enerjiye duyulan ihtiyacı artırmıştır. Enerji elde etmek için genellikle tercih edilen fosil yakıtların dünya gündeminin birinci sırasında yer alan küresel ısınmaya etkisi, ülkelerin farklı yenilenebilir ve doğal enerji kaynaklarına yönelmesine sebep olmuştur. Sadece yenilenebilir enerji kaynaklarına yönelim yetersiz kalmış ve dolayısıyla yapay zekâ teknolojisinin enerji sektörüne entegrasyonu yaygınlaşmıştır.

Bu çalışmada ülkemizde de giderek yaygınlaşan güneş enerjisinin Sinop ili için üretim potansiyeli yapay sinir ağları kullanılarak tahmin edilmeye çalışılmıştır. Farklı modeller denenerek optimum model belirlenmiştir. Modeller MATLAB programı kullanılarak oluşturulmuştur. Model gerçek veri setinde eğitilmiştir. Girdi değerleri bulut kapsamı, rüzgâr hızı, görünürlük, basınç, rakım, sıcaklık ve nem değerleri kullanılmıştır. Çıktı olarak ise enerji üretim miktarı değeri elde edilmiştir. Çalışmada farklı katman sayılarına sahip MLP modelleri, LSTM modeli ve bu iki modelin birleştirilmesiyle oluşturulan hibrit bir model kullanılmıştır. En iyi performans önerilen ve geliştirilmiş olan hibrit modelde elde edilmiştir. Çalışma sonucunda en iyi MAPE değeri %8,4888 ve R^2 değeri 0,96935 olarak hibrit modelde bulunmuştur. Geliştirilen hibrit model sayesinde MLP Model-1'in MAPE değerinde yaklaşık %13, MLP Model-2 de yaklaşık %15 ve LSTM modelinde ise yaklaşık %20 iyileştirme sağlanmıştır. R^2 değerlerinde ise MLP Model-1'e göre yaklaşık 0,12, MLP Model-2'ye göre 0,13 ve LSTM modelinde ise 0,19 artış sağlanmıştır. MLP modellerinde katman yapısının artırılması durumunda veri kayıpları yaşanabileceği görülmüştür. Katman sayısı artırıldığında MAPE değeri artmıştır.

Yapılan çalışma %8,4888 hata payı ve 0,96935 R^2 değeri ile Sinop ilinin güneş enerji potansiyelini hesaplamıştır. Bu sayede yatırım planları yapılmadan önce belirlenen yerlerin güneş enerji potansiyeli hesaplanabilecek ve kaynaklar verimli bir şekilde kullanılabilir. Çalışma yapay zekâ tabanlı hibrit modellerin enerji politikaların oluşturulması ve geliştirilmesi süreçlerindeki potansiyelini ve etkinliğini ortaya koymuştur. Kullanılan hibrit model sayesinde yenilenebilir enerji kaynaklarının daha verimli bir şekilde değerlendirilmesine, sürdürülebilir enerji hedeflerine ulaşılmasında ve maddi kaynakların en verimli bir şekilde kullanılmasına katkıda bulunabilecek güçlü bir araç olarak verilmiştir. Bu bağlamda, hibrit modellerin yenilenebilir enerji kaynaklarının

daha stratejik ve etkin bir şekilde kullanılmasına olanak saęlayan karar destek sistemlerinde başarılı bir şekilde uygulanabileceęi gösterilmiştir.

Bu incelemede sadece Sinop iline ait meteorolojik veriler kullanılarak güneş enerji üretim tahminleri yapılmıştır. Modelin performansı dięer iller ve bölgeler için test edilmemiştir. Ülkemizde bu alanda geniş kapsamlı meteorolojik verilere baęlı olarak üretilen enerjiyi içeren veri seti bulunmamaktadır. Bundan sonraki çalışmalar için güneş enerjisi gibi spesifik bir alanda açık kaynaklı veri seti bulmanın zorluğu göz önüne alınıp uzun süreli bir veri seti hazırlanabilir. Hazırlanacak veri setlerinde farklı meteorolojik parametreler de toplanarak modelin güvenilirliği ve performansı artırılabilir. Elde edilen veri seti ile farklı yapay zekâ modelleri test edilerek karşılaştırmalar yapılabilir. Dięer yenilenebilir enerji kaynakları için de benzer modeller geliştirilerek potansiyel enerji tahmini sonuçları elde edilebilir.

KAYNAKLAR

- Ahmad, T., Zhu, H., Zhang, D., Tariq, R., Bassam, A., Ullah, F., AlGhamdi, S.A. & Alshamrani, S. S. (2022). Energetics systems and artificial intelligence: Applications of industry 4.0. *Energy Reports*, 8, 334-361. <https://doi.org/10.1016/j.egy.2021.11.256>
- Ağaçbiçer, G. (2010). *Yenilenebilir enerji kaynaklarının Türkiye ekonomisine katkısı ve yapılan swot analizler* (Yayın No. 2010/298012) [Yayınlanmış yüksek lisans tezi, Çanakkale Onsekiz Mart Üniversitesi].
- Alcan, Y., Demir, M., & Duman, S. (2018). Sinop ilinin güneş enerjisinden elektrik üretim potansiyelinin ülkemiz ve Almanya ile karşılaştırarak incelenmesi. *El-Cezeri*, 5(1), 35-44. <https://doi.org/10.31202/ecjse.340459>
- Alomari, M. H., Adeeb, J., & Younis, O. (2018). Solar photovoltaic power forecasting in Jordan using artificial neural networks. *Int. J. Electr. Comput. Eng*, 8(1), 497-504. <https://doi.org/10.11591/ijece.v8il.pp497-504>
- Anonim, (2012). <https://argevetasarim.com/hidroelektrik-enerjisi-nedir/> (Erişim tarihi: 10.08.2024)
- Anonim, (2019). <https://www.solar.ist/turkiyenin-en-buyuk-jeotermal-enerji-santrali-kizildere-3-muhendislik-yarismasinda-birincilik-odulu-kazandi/> (Erişim tarihi: 14.08.2024)
- Anonim, (2021). <https://www.nasa.gov/centers-and-facilities/kennedy/kennedy-plays-critical-role-in-large-scale-liquid-hydrogen-tank-development/> (Erişim tarihi: 15.08.2024)
- Anonim, (2022a). <https://www.aydemperakende.com.tr/blog/ruzgar-enerjisi-nedir-ruzgar-turbinleri-enerji-uretimi> (Erişim tarihi: 20.08.2024)
- Anonim, (2022b). <https://enerji.gov.tr/eigm-yenilenebilir-enerji-kaynaklar-gunes#:~:text=%C3%9Ckemiz%2C%20co%C4%9Fraf%C4%B1nemli,kWh%2Fm2%20olarak%20hesaplanm%C4%B1%C5%9Ft%C4%B1r.> (Erişim tarihi: 21.08.2024)
- Anonim, (2023). https://www.emo.org.tr/genel/bizden_detay.php?kod=88369. (Erişim tarihi: 21.05.2024)
- Anonim, (2024a). <https://enerji.gov.tr/haber-detay?id=21270> (Erişim tarihi: 01.01.2025)
- Anonim, (2024b). <https://strom-report.com/strommix/> (Erişim tarihi: 01.01.2025)
- Arabacı, H., & ÖZKAN, N. (2024). Güneş enerjisi sistemlerinin ekonomiye ve çevreye katkıları. *Balkan & Near Eastern Journal of Social Sciences (BNEJSS)*, 10(3).
- Arı, A., & Berberler, M. E. (2017). Yapay sinir ağları ile tahmin ve sınıflandırma problemlerinin çözümü için arayüz tasarımı. *Acta Infologica*, 1(2), 55-73.
- Arıman, S., Taflan, G. Y., & Çelik, E. (2021). Samsun bölgesi için güneş radyasyonunun yapay sinir ağı ile tahmini. *Avrupa Bilim ve Teknoloji Dergisi*, (25), 680-687. <https://doi.org/10.31590/ejosat.866139>
- Arslan, E. (2006). Jeotermal enerjiden yararlanılarak kuyu içi eşanjörü yardımıyla konut ısıtılması ve sıcak su ihtiyacının karşılanması (Yayın No. 2006/180593) [Yayınlanmış yüksek lisans tezi, Pamukkale Üniversitesi].
- Artkım, F. (2018). Türkiye'de yenilenebilir enerji kaynakları ve potansiyeli teknolojileri. *Avrasya Bilim Teknoloji Mühendislik ve Matematik Bildirileri*, (4), 285-295.
- Atak, Ü. (2022). Konteyner liman operasyonlarının makine öğrenmesi yöntemleri ile analizi (Yayın No. 2022/721475) [Yayınlanmış doktora tezi, İstanbul Teknik Üniversitesi].

- Aydın, Ö. (2020). Mobbing içerikli yargı kararlarının makine öğrenmesi algoritmaları ile sınıflandırılması (Yayın No. 2020/650683) [Yayınlanmış yüksek lisans tezi, Balıkesir Üniversitesi].
- Aydın, S. G., & Aydoğdu, G. (2022). Makine öğrenmesi algoritmaları kullanılarak Türkiye ve AB ülkelerinin CO₂ emisyonlarının tahmini. *Avrupa Bilim ve Teknoloji Dergisi*, (37), 42-46. <https://doi.org/10.31590/ejosat.1129958>
- Ayvaz, B. Ş., & Bayrak, A. (2024). Electricity generation methods from solar energy. *Mühendis ve Makina*, (716), 521-557.
- Bayır, F. (2006). Yapay sinir ağları ve tahmin modellemesi üzerine bir uygulama (Yayın No. 2006/215542) [Yayınlanmış yüksek lisans tezi, İstanbul Üniversitesi].
- Bhattacharjee, D., & Kothari, V. K. (2007). A neural network system for prediction of thermal resistance of textile fabrics. *Textile Research Journal*, 77(1), 4-12. <https://doi.org/10.1177/0040517506070065>
- Boltürk, E. (2013). Elektrik talebi tahmininde kullanılan yöntemlerin karşılaştırılması (Yayın No. 2013/350669) [Yayınlanmış yüksek lisans tezi, İstanbul Teknik Üniversitesi].
- Bosch, J. L., Lopez, G., & Batlles, F. J. (2008). Daily solar irradiation estimation over a mountainous area using artificial neural networks. *Renewable Energy*, 33(7), 1622-1628. <https://doi.org/10.1016/j.renene.2007.09.012>
- Çalapkulu, (2022). <https://www.baretdergisi.com/yazarlar/semih-calapkulu/gunes-enerjisi-hakkinda-merak-edilenler/105/> (Erişim tarihi: 19.08.2024)
- Efe, M., Cangır, A.K. (2022). Yapay Zeka, Makine Öğrenmesi ve Tıp Uygulamaları. *Journal of Ankara University Faculty of Medicine*, 75(1), 1-6. <https://doi.org/10.4274/atfm.galenos.2022.78557>.
- Elsheikh, A. H., Sharshir, S. W., Abd Elaziz, M., Kabeel, A. E., Guilan, W., & Haiou, Z. (2019). Modeling of solar energy systems using artificial neural network: A comprehensive review. *Solar Energy*, 180, 622-639. <https://doi.org/10.1016/j.solener.2019.01.037>
- Entezari, A., Aslani, A., Zahedi, R., & Noorollahi, Y. (2023). Artificial intelligence and machine learning in energy systems: A bibliographic perspective. *Energy Strategy Reviews*, 45, 101017. <https://doi.org/10.1016/j.esr.2022.101017>
- Feng, J., & Lu, S. (2019, June). Performance analysis of various activation functions in artificial neural networks. In *Journal of physics: conference series* (Vol. 1237, No. 2, p. 022030). IOP Publishing. <https://doi.org/10.1088/1742-6596/1237/2/022030>
- Fırat, M., & Güngör, M. (2004). Askı madde konsantrasyonu ve miktarının yapay sinir ağları ile belirlenmesi. *Teknik Dergi*, 15(73).
- Forootan, M. M., Larki, I., Zahedi, R., & Ahmadi, A. (2022). Machine learning and deep learning in energy systems: A review. *Sustainability*, 14(8), 4832. <https://doi.org/10.3390/su14084832>
- Gabralı, D., & Aslan, Z. (2020). Güneş enerjisi potansiyelinin çoklu lineer regresyon ve yapay sinir ağları ile modellenmesi. *AURUM Journal of Engineering Systems and Architecture*, 4(1), 23-36.
- Gardner, M. W., & Dorling, S. R. (1998). Artificial neural networks (the multilayer perceptron)-a review of applications in the atmospheric sciences. *Atmospheric environment*, 32(14-15), 2627-2636. [https://doi.org/10.1016/S1352-2310\(97\)00447-0](https://doi.org/10.1016/S1352-2310(97)00447-0)
- Ghimire, S., Deo, R. C., Casillas-Pérez, D., Salcedo-Sanz, S., Sharma, E., & Ali, M. (2022). Deep learning CNN-LSTM-MLP hybrid fusion model for feature optimizations and daily solar

- Göde, A. & Doğan, A. & Özköse, H. (2023). Enerji Sektörünün Dijital Dönüşümünde Yapay Zeka. Çevik Tekin, İ. (ed.), *Yönetim Bilişim Sistemleri: İşletmelerde Dijital Dönüşüm Yönetimi*. Özgür Yayınları. <https://doi.org/10.58830/ozgur.pub137.c1389>
- Görgülü, Y. F. (2022). Enerji krizi ve yenilenemez enerji kaynakları. *Teknobilim-2022: Enerji Krizi ve Yenilenebilir Enerji*, 7.
- Gökçe, S., (2024). Short-term solar power forecasting with artificial neural network models. (Publication No. 2024/863485) [Master's thesis dissertation, Istanbul Technical University].
- İçel, Y. (2023). Mikro rüzgâr türbin modelleri üzerine bir araştırma. *Avrupa Bilim ve Teknoloji Dergisi*, (47), 47-52. <https://doi.org/10.31590/ejosat.1241992>
- İnce, H., İmamoğlu, S. E., & İmamoğlu, S. Z. Yapay zekâ uygulamalarının karar verme üzerine etkileri: Kavramsal bir çalışma. *International Review of Economics and Management*, 9(1), 50-63. <https://doi.org/10.18825/iremjournal.866432>
- İşeri, İ., & Arıman, S. (2019). Sedimandaki ağır metal konsantrasyonunun çoklu değişken regresyon modelleri ve çok katmanlı algılayıcı ağ modeli ile tahmini. *Avrupa Bilim ve Teknoloji Dergisi*, 389-397. <https://doi.org/10.31590/ejosat.638354>
- Kademli, M. (2021). Yenilenebilir enerji kaynaklarının sürdürülebilir kalkınma ve ekonomik büyümedeki rolü ve önemi. *Yeni Türkiye*, 27(117).
- Kamilaris, A., & Prenafeta-Bodúl, F. X. (2018). Deep learning in agriculture: A survey. *Computers and electronics in agriculture*, 147, 70-90. <https://doi.org/10.1016/j.compag.2018.02.016>
- Kamthania, D., & Tiwari, G. N. (2012). Performance analysis of a hybrid photovoltaic thermal double pass air collector using ANN. *Applied Solar Energy*, 48, 186-192. <https://doi.org/10.3103/S0003701X12030073>
- Kapluhan, E. (2014). Enerji coğrafyası açısından bir inceleme: Biyokütle enerjisinin dünyadaki ve Türkiye'deki kullanım durumu. *Marmara Coğrafya Dergisi*, (30). <https://doi.org/10.14781/mcd.98631>
- Karaağaç, M. O., Oğul, H., & bulut, F. (2021). Evaluation of monocrystalline and polycrystalline photovoltaic panels in Sinop Province conditions. *Türk Doğa ve Fen Dergisi*, 10(1), 176-181.
- Kavaz, İ. (2021, August). Dünyada ve Türkiye'de nükleer enerji (Nuclear energy in the World and Turkey). In *International Conference on Eurasian Economies* (pp. 286-294).
- Kaynar, N. K. (2020). Yenilenebilir enerji kaynaklarından güneş enerjisinin Amasya ilindeki potansiyeli. *Bilge International Journal of Science and Technology Research*, 4(2), 48-54.
- Kaysal, K., Yurttakal, A. H., & Hocoğlu, F. O. (2023). Hibrit derin öğrenme yöntemi kullanılarak hiperparametre optimizasyonu ile yenilenebilir elektrik enerjisi tahmini. *Niğde Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi*, 12(3), 770-777. <https://doi.org/10.28948/ngumuh.1263782>
- Kılıç, F. (2023). Alternatif bir kaynak olarak Türkiye'de hidrojen enerjisi (Yayın No. 2023/827125) [Yayınlanmış yüksek lisans tezi, Karabük Üniversitesi].
- Koç, E., & Kaya, K. (2015). Enerji kaynakları-yenilenebilir enerji durumu. *Mühendis ve Makina*, 56(668), 36-47.

- Koç, E., & Şenel, M. C. (2013). Dünyada ve Türkiye’de enerji durumu-genel değerlendirme. *Mühendis ve Makina*, 54(639), 32-44.
- Koyuncu, İ., & Yılmaz, C. (2019). Afyon Jeotermal enerji santralinin yapay sinir ağları ile modellenmesi ve optimizasyonu. *I. Uluslararası Bilim ve İnovasyon Kongresi*, 26-29 Ağustos 2019, Pamukkale, Denizli/Türkiye
- Kumbur, H., Özer, Z., Özsoy, H. D., & Avcı, E. D. (2005). Türkiye’de geleneksel ve yenilenebilir enerji kaynaklarının potansiyeli ve çevresel etkilerinin karşılaştırılması. *Yeksem 2005, III. Yenilenebilir Enerji Kaynakları Sempozyumu ve Sergisi*, 19-21.
- Kumruoğlu, L. C., & Ateş, S. B. (2022). Türkiye’nin güneş enerjisi potansiyeli ve İskenderun için örnek üretim projeksiyonu. *Çukurova Üniversitesi Mühendislik Fakültesi Dergisi*, 37(1), 293-305. <https://doi.org/10.21605/cukurovaumfd.1095104>
- Kuzmiakova, A., Colas, G., & McKeenan, A. (2017). Short-term memory solar energy forecasting at University of Illinois. *no. December*, 1-6.
- Küleki, Ö. C. (2009). Yenilenebilir enerji kaynakları arasında jeotermal enerjinin yeri ve Türkiye açısından önemi. *Ankara Üniversitesi Çevre Bilimleri Dergisi*, 1(2), 83-91. https://doi.org/10.1501/Csaum_0000000017
- Küpel, A. Ö. (2005). Güneş pilleri ve verimleri (Yayın No. 2005/198822) [Yayınlanmış yüksek lisans tezi, Eskişehir Osmangazi Üniversitesi].
- Makas, Y., & Karaatlı, M. (2016). Yapay sinir ağlarıyla hidroelektrik enerji üretiminin çok dönemli tahmini. *Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 21(3), 757-772.
- Mancera, D., Schroedter-Homscheidt, M., & Klueser, L. Aerosol estimation in the lower planet boundary layer for solar power tower plants’ assessment. <https://doi.org/10.14644/dust.2014.009>
- Mersin, G., (2024). Yapay zeka sayesinde güneş enerjisi üretim tahminlemesi ve gerçekleşen üretim değerleri (Yayın No. 2024/896417) [Yayınlanmış yüksek lisans tezi, Ege Üniversitesi].
- Mitra, M., Singha, N. R., & Chattopadhyay, P. K. (2023). Review on renewable energy potential and capacities of South Asian countries influencing sustainable environment: A comparative assessment. *Sustainable Energy Technologies and Assessments*, 57, 103295. <https://doi.org/10.1016/j.seta.2023.103295>
- Muhammed, A. and Kora, R. (2023). A comprehensive review of ensemble deep learning: Opportunities and challenges. *King Saud University-Journal of Computer and Information Sciences*, 35 (2), 757-774
- Oyucu, S., & Herdem, M. S. (2024). Hibrit derin öğrenme algoritmaları kullanılarak biyogaz reform süreçlerinin optimizasyonu: CNN-LSTM modeli ile çıktı parametrelerinin tahmini. *Adıyaman Üniversitesi Mühendislik Bilimleri Dergisi*, 11(23), 301-316. <https://doi.org/10.54365/adyumbd.1488710>
- Öğücü, M. O. (2006). Yapay sinir ağları ile sistem tanıma (Yayın No. 2006/223555) [Yayınlanmış yüksek lisans tezi, İstanbul Teknik Üniversitesi].
- Özcan, B. (2008). Sürdürülebilir kalkınma ve hidrojen enerjisi. *Humanities Sciences*, 3(2), 152-160.
- Özdemir, H. (2013). Yapay sinir ağları ve doküman teknolojisinde kullanımı. *Electronic Journal of Vehicle Technologies/Tasit Teknolojileri Elektronik Dergisi*, 7(1).
- Özölçer, İ. H., Aksoy, B., & Dünder, O. (2020). Kızılcapınar içmesuyu barajında hidroelektrik potansiyeli değerlendirilmesi. *Türk Hidrolik Dergisi*, 4(1), 25-30.

- Öztemel, E. (2003). Yapay sinir ağıları. *PapatyaYayincılık, İstanbul*.
- Öztürk, H. H. (2008). Güneş enerjisinden fotovoltaik yöntemle elektrik üretiminde güç dönüşüm verimi ve etkili etmenler.
- Öztürk, K., & Şahin, M. E. (2018). Yapay sinir ağıları ve yapay zekâ'ya genel bir bakış. *Takvim-i Vekayi*, 6(2), 25-36.
- Pamir, A. N. (2003). Dünyada ve Türkiye'de enerji, Türkiye'nin enerji kaynakları ve enerji politikaları. *Metalurji Dergisi*, 134(23), 1-39.
- Perez-Llera, C., Fernandez-Baizan, M. C., Feito, J. L., & González del Valle, V. (2002). Local short-term prediction of wind speed: a neural network analysis.
- Pradhan, B., Lee, S., & Buchroithner, M. F. (2010). A GIS-based back-propagation neural network model and its cross-application and validation for landslide susceptibility analyses. *Computers, Environment and Urban Systems*, 34(3), 216-235. <https://doi.org/10.1016/j.compenvurbsys.2009.12.004>
- Premalatha, N., & Valan Arasu, A. (2016). Prediction of solar radiation for solar systems by using ANN models with different back propagation algorithms. *Journal of applied research and technology*, 14(3), 206-214. <https://doi.org/10.1016/j.jart.2016.05.001>
- Rybach, L. (2003). Geothermal energy: sustainability and the environment. *Geothermics*, 32(4-6), 463-470. [https://doi.org/10.1016/S0375-6505\(03\)00057-9](https://doi.org/10.1016/S0375-6505(03)00057-9)
- Sağlam, M., Uyar, T. S., & Göztepe, İ. (2005). Dalga enerjisi ve Türkiye'nin dalga enerjisi teknik potansiyeli. *Elektrik Mühendisleri Odası*, 19, 2020.
- Sağlam, N. A., Dalfidan, F., & Kızıltepe, B. Çanakkale'deki rüzgâr enerjisi santrallerinin kırsal sürdürülebilirliğe etkileri. *Akademik İncelemeler Dergisi*, 19(2), 258-288. <https://doi.org/10.17550/akademikincelemeler.1426566>
- Schmidhuber, J., & Hochreiter, S. (1997). Long short-term memory. *Neural Comput*, 9(8), 1735-1780.
- Şener, İ. F., (2024). Muş ili güneş enerjisi potansiyelinin makine öğrenmesi ile tahmini (Yayın No. 2024/902175) [Yayınlanmış yüksek lisans tezi, Muş Alparslan Üniversitesi].
- Şimşek, A. İ. (2024). Comparative analysis of machine and deep learning methods in estimating the Turkish electricity market clearing price. *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, 36(2), 859-867. <https://doi.org/10.35234/fumbd.1473145>
- Sharifani, K., & Amini, M. (2023). Machine learning and deep learning: A review of methods and applications. *World Information Technology and Engineering Journal*, 10(07), 3897-3904.
- Shi, Y., Zhong, W., Chen, X., Yu, A. B., & Li, J. (2019). Combustion optimization of ultra supercritical boiler based on artificial intelligence. *Energy*, 170, 804-817. <https://doi.org/10.1016/j.energy.2018.12.172>
- Shiri, F. M., Perumal, T., Mustapha, N., & Mohamed, R. (2023). A comprehensive overview and comparative analysis on deep learning models: CNN, RNN, LSTM, GRU. *arXiv preprint arXiv:2305.17473*. <https://doi.org/10.48550/arXiv.2305.17473>
- Smalley, R. E. (2005). Future global energy prosperity: the terawatt challenge. *Mrs Bulletin*, 30(6), 412-417. <https://doi.org/10.1557/mrs2005.124>
- Solangi, K. H., Islam, M. R., Saidur, R., Rahim, N. A., & Fayaz, H. (2011). A review on global solar energy policy. *Renewable and sustainable energy reviews*, 15(4), 2149-2163. <https://doi.org/10.1016/j.rser.2011.01.007>
- Şen, Z. (2004). Yapay sinir ağıları. *Su Vakfı*.

- Taroon, G., Tomar, A., Manjunath, C., Balamurugan, M., Ghosh, B., & Krishna, A. V. (2020, November). Employing deep learning in intraday stock trading. In *2020 Fifth International Conference on Research in Computational Intelligence and Communication Networks (ICRCICN)* (pp. 209-214). <https://doi.org/10.1109/ICRCICN50933.2020.9296174>
- Tekin, P. (2022). Çukurova bölgesi için kısa vadeli yapay zekâ tabanlı rüzgâr güç tahmini. *Çukurova Üniversitesi Mühendislik Fakültesi Dergisi*, 37(4), 1143-1154. <https://doi.org/10.21605/cukurovaumfd.1230965>
- Unsur, C. (2021). Kale HES'in enerji üretimine katkısı Güneysu/Rize. *Türk Hidrolik Dergisi*, 5(1), 18-24.
- Uzun, E. (2007). İnternet tabanlı bilgi erişimi destekli bir otomatik öğrenme sistemi (Yayın No. 2007/199972) [Yayınlanmış doktora tezi, Trakya Üniversitesi].
- Venkatraman, D., & Pitchaipillai, V. (2024). Deep learning-based Auto-LSTM approach for renewable energy forecasting: A hybrid network model. *Traitement du Signal*, 41(1). <https://doi.org/10.18280/ts.410148>
- Yavuz, S., & Deveci, M. (2012). İstatiksel normalizasyon tekniklerinin yapay sinir ağı performansına etkisi. *Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, (40), 167-187.
- Yazıcıoğlu, N. (2010). Yapay zeka ile talep tahmini (Yayın No. 2010/340054) [Yayınlanmış yüksek lisans tezi, Bursa Uludağ Üniversitesi].
- Yegm, (2022). Yenilenebilir enerji kaynağı Genel Müdürlüğü. <http://www.yegm.gov.tr/MyCalculator/Default.aspx> (Erişim tarihi:20.09.2024).
- Zha, W., Liu, Y., Wan, Y., Luo, R., Li, D., Yang, S., & Xu, Y. (2022). Forecasting monthly gas field production based on the CNN-LSTM model. *Energy*, 260, 124889. <https://doi.org/10.1016/j.energy.2022.124889>

EKLER

EK 1 Sinop İli Havaalanı İstasyonunun Ham Hava Durumu Verileri

Görünürlük Ort	Sıcaklık	Nem	Rüzgâr Hızı	Basınç	Rakım
10	6.8	81.6	2,4	1032	7
10	6.0	82.6	2,5	1032	7
10	6.0	83.6	2,4	1027	7
10	5.8	82.7	4,2	1024	7
10	9.1	82.3	2,7	1022	7
8,5	6.9	90.9	3,8	1015	7
10	8.4	80.1	4,3	1023	7
10	6.3	85.3	3,3	1025	7
10	4.8	78.3	3,9	1026	7
10	6.0	74.5	3,6	1020	7
10	8.8	73.2	3,3	1018	7
10	10.1	82.4	2	1017	7
10	9.3	86.2	2,5	1017	7
9	7.9	86.9	1,7	1019	7
10	6.5	88.2	1,7	1021	7
8,5	4.7	89.6	2,8	1018	7
10	11.6	62.3	2,4	1015	7
10	11.7	64.6	1,3	1015	7
10	10.0	71.5	2,6	1019	7
10	8.9	72.8	2,4	1014	7
10	10.5	76.2	3,9	1018	7
10	9.5	88.9	2,6	1023	7
10	8.8	82.8	1,9	1026	7
10	8.4	82.5	1,9	1028	7
7,5	7.7	82.0	2	1027	7
10	6.7	87.4	4,2	1024	7
10	11.3	69.8	5,5	1014	7
10	12.4	68.5	3,7	1009	7
10	8.0	81.4	5,7	1014	7
10	6.5	75.8	4,8	1015	7
8	4.6	92.1	2,3	1011	7
9	3.9	89.3	3,6	1012	7
10	4.0	83.0	3	1016	7
9	4.3	79.3	3,4	1018	7
10	6.1	73.3	2,9	1017	7
10	5.7	81.0	2,6	1012	7
9,5	6.6	77.5	8,7	1010	7
6,2	3.3	78.4	8	1018	7

Ek 1'in devamı

6,25	2.3	86.3	6,3	1024	7
8	2.0	91.6	3,3	1030	7
10	2.9	83.5	3,5	1034	7
10	2.7	84.1	2,6	1033	7
10	3.7	73.0	3	1027	7
10	5.1	60.4	6	1031	7
10	4.4	60.0	4,6	1027	7
8	5.6	67.3	7,6	1021	7
8,5	5.7	58.6	7,8	1027	7
10	8.7	51.7	2,7	1025	7
10	7.3	72.2	2,5	1022	7
10	10.9	77.0	4,8	1017	7
8	10.7	82.2	7	1015	7
10	13.0	46.6	5,8	1013	7
10	10.1	74.5	4,8	1015	7
10	8.7	73.7	4,3	1020	7
10	7.9	79.8	9,1	1017	7
10	9.3	78.7	3,2	1014	7
10	13.5	63.0	1	1017	7
10	13.6	60.0	1,2	1019	7
10	11.2	75.7	3,3	1024	7
7,5	8.9	95.0	2	1022	7
4,5	8.0	94.3	2,6	1022	7
7,5	8.0	92.5	4,1	1015	7
9,5	9.5	88.7	3,3	1018	7
9	10.1	89.0	3,6	1008	7
7,5	8.2	87.0	6,6	1010	7
10	11.7	61.4	2,5	1014	7
10	11.1	69.0	2,3	1014	7
10	14.2	62.3	2,7	1012	7
10	15.9	59.5	2,6	1011	7
10	14.9	66.7	2,9	1005	7
7,5	8.3	92.0	6,2	1011	7
7,5	7.1	76.3	5	1020	7
10	7.3	76.8	2,5	1017	7
10	8.3	82.7	3,9	1010	7
7	9.2	92.4	2,8	1007	7
8	10.1	81.6	3	1015	7
7,5	9.4	91.3	0,8	1016	7
1,85	7.8	95.0	4,1	1017	7
9	8.6	82.7	7,9	1019	7
10	9.3	74.6	2,7	1017	7
8,5	9.8	83.0	5,9	1014	7
10	10.6	84.3	3,1	1015	7

Ek 1'in devamı

10	11.2	77.7	4,4	1018	7
6,5	9.3	88.7	4,1	1015	7
4,6	8.8	96.0	2,3	1009	7
10	13.9	65.5	4,5	1012	7
7,5	12.5	76.8	5,5	1004	7
9	6.7	71.7	9,2	1011	7
8	5.3	69.8	6	1021	7
10	5.7	61.7	2,7	1020	7
10	11.6	69.0	6,7	1012	7
10	14.4	74.6	4,1	1008	7
10	13.5	83.0	5,7	1013	7
8,5	14.8	74.7	7,2	1005	7
8	13.6	77.8	4,6	1007	7
10	9.8	77.3	4,1	1015	7
6,5	9.5	90.9	3,6	1013	7
10	10.2	83.6	7,2	1021	7
10	10.7	84.8	7,2	1020	7
10	11.8	79.6	5,1	1012	7
10	11.3	78.4	2,8	1006	7
10	10.9	83.7	11,2	1004	7
8,5	11.7	80.4	6,8	1010	7
10	15.2	59.5	3,4	1014	7
10	16.1	63.7	2,6	1014	7
10	13.3	84.0	3,8	1016	7
9	15.5	76.3	3,1	1012	7
8	16.3	75.1	7,5	1010	7
7,5	14.0	84.4	7,2	1010	7
9	12.2	84.8	3,6	1010	7
7	11.9	87.0	8,2	1009	7
10	13.1	69.1	6,2	1014	7
8,5	10.4	89.4	3,1	1017	7
6,5	12.1	79.6	4,8	1016	7
10	13.9	80.3	4,6	1012	7
9,5	16.0	71.2	4,6	1008	7
9	14.4	83.8	2,2	1006	7
9	12.6	80.2	12,3	1012	7
10	11.6	74.0	4,1	1012	7
9	10.4	87.8	3,3	1012	7
10	13.7	60.8	5,7	1018	7
10	14.3	59.9	3,6	1025	7
10	13.5	70.8	4	1026	7
10	14.7	80.0	2,9	1021	7
3,7	14.3	86.9	3,6	1017	7
6	12.5	87.4	4,6	1013	7

Ek 1'in devamı

10	13.1	90.3	6	1012	7
4,6	12.6	94.6	5,1	1019	7
10	14.3	80.6	2,5	1019	7
9	12.0	87.3	2,5	1020	7
7	11.2	87.6	2,1	1023	7
10	13.3	77.0	3,6	1019	7
9	14.3	75.7	8	1020	7
10	16.4	53.8	7,2	1023	7
10	16.1	61.3	4,1	1019	7
10	16.2	71.9	8,7	1016	7
8,5	16.5	73.3	1,5	1012	7
10	15.2	86.3	3,1	1009	7
9,5	15.9	83.8	6,2	1012	7
9	16.3	82.7	8,2	1012	7
5	14.2	94.8	3,1	1011	7
6,5	15.9	87.8	4,5	1010	7
8	16.0	90.6	3,4	1011	7
6,5	16.4	91.1	4,4	1014	7
10	17.9	85.7	4,6	1015	7
7	17.6	88.9	5,4	1015	7
8,5	17.9	87.3	4,1	1013	7
10	19.1	84.1	6,7	1010	7
8	18.2	90.7	2,6	1010	7
9,5	18.9	89.7	2,6	1012	7
10	20.6	76.6	7,7	1014	7
10	20.7	64.8	6,2	1015	7
10	19.8	74.1	4,6	1014	7
6,75	19.0	94.4	3	1011	7
5	18.2	94.3	7,8	1014	7
7	18.0	92.5	6,4	1017	7
10	20.2	77.0	4,5	1020	7
10	19.4	81.3	4,5	1018	7
10	20.7	82.0	4,1	1014	7
9	19.2	92.5	3,9	1011	7
10	20.8	75.2	3,9	1009	7
10	20.3	75.6	3,1	1008	7
10	21.7	76.1	1,5	1007	7
10	20.4	84.5	3,1	1009	7
10	22.1	75.4	5,1	1011	7
8,5	21.3	80.5	5,1	1013	7
10	22.4	68.2	4,1	1010	7
10	22.2	83.4	6,7	1005	7
10	20.1	89.8	2,6	1007	7
10	23.0	76.9	4,6	1010	7

Ek 1'in devamı

10	22.0	82.2	3,7	1012	7
10	23.9	74.5	8,3	1015	7
10	24.3	76.3	6	1018	7
10	24.2	71.0	4,7	1018	7
10	22.6	69.6	3,6	1017	7
10	22.9	85.5	4,3	1012	7
10	24.4	74.5	5,1	1008	7
10	25.1	69.1	5,7	1011	7
10	23.9	70.8	3,6	1011	7
10	23.7	72.9	5,1	1012	7
10	21.1	78.4	3,5	1013	7
10	24.4	59.1	4,8	1012	7
10	24.2	66.3	7,7	1009	7
10	25.1	78.1	3,6	1011	7
10	26.1	73.5	3,6	1014	7
10	26.8	63.1	2,6	1012	7
10	26.6	76.7	3,1	1008	7
10	27.3	71.1	7,2	1008	7
10	25.9	70.8	10,8	1008	7
10	23.7	74.2	7,2	1006	7
10	24.5	66.5	7,7	1014	7
10	25.5	59.5	5,1	1016	7
10	27.3	53.7	4,1	1017	7
10	24.8	71.1	2,1	1018	7
10	25.6	64.1	3,1	1014	7
10	26.0	70.9	2,8	1016	7
10	23.9	77.8	5,9	1017	7
10	26.5	54.0	2,1	1018	7
10	25.7	56.0	5,9	1015	7
10	27.4	48.4	3,4	1012	7
10	26.4	62.7	5,7	1010	7
10	25.2	66.8	3,6	1011	7
10	24.9	70.0	5,1	1015	7
10	26.2	61.4	1,5	1013	7
7,25	24.0	77.7	2,6	1014	7
10	25.8	65.5	2,4	1013	7
10	25.7	67.2	4,4	1009	7
10	27.9	69.3	2,6	1003	7
10	23.4	62.1	11,3	1013	7
10	23.1	65.0	4,6	1013	7
10	20.4	77.3	2,9	1013	7
10	23.0	69.9	3	1009	7
10	26.1	69.2	2,6	1008	7
10	24.6	80.0	2,1	1009	7

Ek 1'in devamı

10	25.9	77.0	2,6	1013	7
10	25.5	71.6	5,1	1013	7
10	26.3	72.3	7,5	1009	7
10	26.4	76.3	2,8	1003	7
10	25.8	70.1	1,9	1007	7
10	25.7	81.0	2,3	1010	7
10	23.7	77.9	2,8	1014	7
10	24.5	81.9	2,7	1012	7
10	25.4	81.4	5,1	1012	7
10	25.1	72.7	3,6	1017	7
10	23.3	80.6	3,6	1017	7
10	27.1	76.5	7,7	1017	7
10	27.9	78.6	2,7	1015	7
8	24.6	88.6	1,5	1013	7
6	26.4	80.6	0,9	1011	7
10	27.1	77.0	3,1	1012	7
10	26.1	83.6	3	1013	7
10	24.2	73.8	3,1	1012	7
10	26.2	75.6	3,4	1012	7
10	29.0	51.6	3,4	1014	7
2,9	23.7	87.3	3,4	1015	7
10	27.9	58.4	2,5	1015	7
10	25.4	61.8	4	1015	7
10	24.7	68.8	4,1	1015	7
10	24.0	67.7	2,5	1011	7
10	24.4	69.7	2	1008	7
10	27.3	73.6	3,2	1006	7
10	25.7	72.6	6,4	1006	7
10	28.0	60.0	4	1009	7
10	27.0	69.0	3,3	1013	7
10	25.8	75.7	3,3	1015	7
10	21.9	88.0	3,8	1014	7
10	24.7	68.8	5,7	1011	7
10	25.3	74.5	4,4	1012	7
10	25.0	77.0	3,2	1016	7
10	24.6	74.0	2,2	1018	7
10	22.5	72.8	4,1	1017	7
10	18.9	73.2	3,1	1016	7
10	18.6	70.7	4,1	1018	7
10	17.5	71.2	3,1	1017	7
10	18.4	72.5	2,8	1017	7
10	17.8	75.5	2,6	1019	7
10	17.8	71.5	3,8	1019	7
10	20.6	66.2	4,5	1018	7

Ek 1'in devamı

10	19.0	75.9	2,9	1019	7
10	19.1	76.5	2,9	1020	7
10	18.3	73.6	3,2	1019	7
10	17.6	77.6	3,5	1017	7
10	18.9	80.6	2,8	1016	7
10	17.5	84.5	2,9	1017	7
10	19.5	85.3	2,3	1017	7
10	19.5	85.7	2,7	1018	7
8	19.9	82.9	2,8	1016	7
10	17.1	92.1	2,1	1016	7
10	22.5	79.3	3,1	1015	7
10	21.1	76.3	3,6	1015	7
10	22.7	76.2	3,1	1015	7
9	21.8	82.7	2,4	1016	7
10	20.3	87.0	2,2	1014	7
10	20.0	84.3	3	1011	7
10	21.6	74.6	6,1	1013	7
10	18.4	70.9	5,6	1021	7
10	15.1	74.4	2,9	1024	7
10	15.3	79.8	2,7	1024	7
10	15.6	79.4	2,5	1021	7
10	16.8	87.0	2,3	1023	7
8	15.4	82.0	2,6	1016	7
7	14.3	81.6	3,3	1022	7
10	14.2	78.6	2,4	1019	7
10	15.4	73.5	4,6	1024	7
10	16.2	63.3	4,6	1025	7
10	14.9	77.7	2,6	1021	7
10	15.3	83.3	4,1	1019	7
10	18.2	81.3	3,7	1012	7
7	17.2	80.4	4,3	1010	7
8	14.7	71.3	4,1	1022	7
3	14.5	79.9	6,7	1017	7
9,5	14.7	80.7	3,3	1018	7
7	16.2	73.5	3,2	1015	7
9	17.3	71.7	2,5	1015	7
10	18.4	72.4	2,4	1018	7
10	18.7	73.0	2,8	1016	7
10	19.1	78.6	2,4	1016	7
10	18.5	86.6	2,9	1012	7
9	17.7	77.4	2,4	1009	7
10	19.8	65.9	2,5	1009	7
10	20.8	67.5	3,6	1009	7
10	19.1	76.7	2	1015	7

Ek 1'in devamı

9	17.7	89.5	3,9	1020	7
8	19.2	87.4	4,8	1018	7
10	20.1	80.1	2,3	1014	7
8	17.9	88.6	3,4	1014	7
10	19.6	78.3	2,8	1011	7
10	19.1	70.0	3,6	1010	7
9	19.2	81.0	3,7	1011	7
10	21.1	66.0	4,7	1009	7
10	18.8	70.4	1,9	1022	7
10	18.4	71.4	2,2	1017	7
9	14.0	87.4	4,1	1016	7
10	13.4	83.5	4,7	1022	7
10	17.3	69.9	5,6	1013	7
10	16.7	86.5	2,9	1012	7
10	15.7	91.1	3,7	1015	7
10	14.9	82.0	3,9	1015	7
10	12.4	80.0	2,7	1012	7
3,5	12.7	88.9	3,6	1011	7
10	12.2	75.7	3,4	1018	7
10	12.0	73.8	3,4	1005	7
10	11.6	57.0	3,7	996,3	7
7	10.2	73.2	8,6	1007	7
10	10.5	82.8	3,5	1015	7
9,5	11.7	77.6	2,4	1015	7
5,25	11.8	90.4	3,3	1018	7
10	12.5	87.1	2,1	1009	7
10	15.7	69.7	2,5	999,2	7
8	16.3	57.2	6,3	990,6	7
10	6.6	64.7	5,6	1009	7
10	6.4	47.7	3,2	1016	7
10	13.8	61.5	3,8	1009	7
8	10.8	88.1	3,3	1016	7
8,5	15.3	75.3	3,1	1017	7
9	15.9	74.0	2,7	1014	7
8	13.6	74.0	2	1013	7
10	12.1	84.0	3,7	1018	7
6,5	10.7	86.8	5,8	1023	7
10	10.9	84.4	3,5	1014	7
10	13.9	81.7	3,1	1012	7
8,5	11.9	92.9	2,1	1012	7
5,5	11.6	96.0	1,7	1009	7
10	9.9	86.5	6,1	1014	7
10	11.1	81.7	2,2	1017	7
10	11.9	87.3	2,6	1015	7

Ek 1'in devamı

9,5	11.2	79.5	4,1	1016	7
10	12.8	65.0	2	1013	7
8	13.5	79.0	2,8	1016	7
9,5	9.4	82.0	5,1	1025	7
9	5.7	89.3	3,5	1033	7
10	7.0	71.4	3,3	1032	7
5,75	8.7	80.0	2	1027	7
9	7.1	85.3	2,7	1020	7
9	9.4	75.8	2,3	1010	7
4	10.8	91.7	2,1	1000	7
9,5	11.3	57.5	6,4	997,9	7
9	5.1	63.0	7	1007	7
6,5	10.7	74.0	2,4	1014	7
7,5	13.3	69.6	3,5	1018	7
10	13.7	66.8	4,2	1020	7
9	9.9	77.8	2,9	1028	7
10	10.0	70.5	1,5	1023	7
10	3.9	76.0	3,4	1021	7
10	9.8	87.7	2,7	1020	7

EK 2 Dönüşüm Uygulanmış Sinop Hava Durumu Verileri

Bulut Kapsamı(%)	Görünürlük	Sıcaklık	Nem	Rüzgâr Hızı	Basınç	Rakım
0,0875	6,21372737	6,8	81,6	5,368647101	30,47791	29,92
0	6,21372737	6	82,6	5,59234073	30,4661	29,92
0	6,21372737	6	83,6	5,368647101	30,32436	29,92
0,2875	6,21372737	5,8	82,7	9,395132427	30,22396	29,92
0,3625	6,21372737	9,1	82,3	6,039727989	30,18261	29,92
0,95	5,28166826	6,9	90,9	8,50035791	29,98476	29,92
0,875	6,21372737	8,4	80,1	9,618826056	30,2151	29,92
0,8375	6,21372737	6,3	85,3	7,381889764	30,27416	29,92
0,2125	6,21372737	4,8	78,3	8,724051539	30,28302	29,92
0	6,21372737	6	74,5	8,052970651	30,11174	29,92
0	6,21372737	8,8	73,2	7,381889764	30,04973	29,92
0,8	6,21372737	10,1	82,4	4,473872584	30,0202	29,92
0,7125	6,21372737	9,3	86,2	5,59234073	30,03792	29,92
0,6625	5,59235463	7,9	86,9	3,802791696	30,09107	29,92
0,5375	6,21372737	6,5	88,2	3,802791696	30,14422	29,92
0,25	5,28166826	4,7	89,6	6,263421618	30,07335	29,92
0,5375	6,21372737	11,6	62,3	5,368647101	29,96704	29,92
0,05	6,21372737	11,7	64,6	2,90801718	29,98476	29,92
0	6,21372737	10	71,5	5,816034359	30,07926	29,92
0,275	6,21372737	8,9	72,8	5,368647101	29,93456	29,92
0,0375	6,21372737	10,5	76,2	8,724051539	30,06154	29,92
0,875	6,21372737	9,5	88,9	5,816034359	30,19443	29,92
0,8375	6,21372737	8,8	82,8	4,250178955	30,29187	29,92
0,975	6,21372737	8,4	82,5	4,250178955	30,3657	29,92
0,8375	4,66029552	7,7	82	4,473872584	30,3155	29,92
0,8	6,21372737	6,7	87,4	9,395132427	30,23281	29,92
0,275	6,21372737	11,3	69,8	12,30314961	29,94047	29,92
0,6	6,21372737	12,4	68,5	8,276664281	29,78396	29,92
0,85	6,21372737	8	81,4	12,75053686	29,93751	29,92
0,7625	6,21372737	6,5	75,8	10,7372942	29,98181	29,92
0,95	4,97098189	4,6	92,1	5,144953472	29,84597	29,92
0,975	5,59235463	3,9	89,3	8,052970651	29,88436	29,92
0,2875	6,21372737	4	83	6,710808876	30,00839	29,92
0,7	5,59235463	4,3	79,3	7,605583393	30,04678	29,92
0,5	6,21372737	6,1	73,3	6,487115247	30,01725	29,92
0,6625	6,21372737	5,7	81	5,816034359	29,8755	29,92
0,9125	5,903041	6,6	77,5	19,46134574	29,83121	29,92
0,825	3,85251097	3,3	78,4	17,89549034	30,06449	29,92
0,975	3,8835796	2,3	86,3	14,09269864	30,24758	29,92
0,7625	4,97098189	2	91,6	7,381889764	30,42476	29,92
0,6375	6,21372737	2,9	83,5	7,829277022	30,52811	29,92

Ek 2'nin devamı

0,8625	6,21372737	2,7	84,1	5,816034359	30,50154	29,92
0,75	6,21372737	3,7	73	6,710808876	30,32731	29,92
0,675	6,21372737	5,1	60,4	13,42161775	30,43657	29,92
0,675	6,21372737	4,4	60	10,28990694	30,33912	29,92
0,8	4,97098189	5,6	67,3	17,00071582	30,15899	29,92
0,7625	5,28166826	5,7	58,6	17,44810308	30,33912	29,92
0,4	6,21372737	8,7	51,7	6,039727989	30,25939	29,92
0,0625	6,21372737	7,3	72,2	5,59234073	30,18557	29,92
0,75	6,21372737	10,9	77	10,7372942	30,0202	29,92
0,85	4,97098189	10,7	82,2	15,65855404	29,96704	29,92
0,25	6,21372737	13	46,6	12,97423049	29,89913	29,92
0,5	6,21372737	10,1	74,5	10,7372942	29,95819	29,92
0,6625	6,21372737	8,7	73,7	9,618826056	30,12946	29,92
0,6125	6,21372737	7,9	79,8	20,35612026	30,04087	29,92
0,6625	6,21372737	9,3	78,7	7,158196135	29,93161	29,92
0,75	6,21372737	13,5	63	2,236936292	30,0202	29,92
0,5	6,21372737	13,6	60	2,68432355	30,09402	29,92
0,9625	6,21372737	11,2	75,7	7,381889764	30,25053	29,92
0,875	4,66029552	8,9	95	4,473872584	30,19147	29,92
0,875	2,79617731	8	94,3	5,816034359	30,1649	29,92
1	4,66029552	8	92,5	9,171438797	29,97295	29,92
0,9125	5,903041	9,5	88,7	7,381889764	30,05268	29,92
0,8125	5,59235463	10,1	89	8,052970651	29,76919	29,92
1	4,66029552	8,2	87	14,76377953	29,83416	29,92
0,575	6,21372737	11,7	61,4	5,59234073	29,94342	29,92
0,35	6,21372737	11,1	69	5,144953472	29,92866	29,92
0,6	6,21372737	14,2	62,3	6,039727989	29,89027	29,92
0,6	6,21372737	15,9	59,5	5,816034359	29,85483	29,92
0,7125	6,21372737	14,9	66,7	6,487115247	29,68356	29,92
1	4,66029552	8,3	92	13,86900501	29,86074	29,92
0,95	4,66029552	7,1	76,3	11,18468146	30,1206	29,92
0,65	6,21372737	7,3	76,8	5,59234073	30,03496	29,92
0,8125	6,21372737	8,3	82,7	8,724051539	29,82825	29,92
0,85	4,34960916	9,2	92,4	6,263421618	29,73966	29,92
0,8	4,97098189	10,1	81,6	6,710808876	29,9759	29,92
0,975	4,66029552	9,4	91,3	1,789549034	29,99362	29,92
1	1,14953956	7,8	95	9,171438797	30,0261	29,92
0,8375	5,59235463	8,6	82,7	17,67179671	30,09993	29,92
0,2875	6,21372737	9,3	74,6	6,039727989	30,04087	29,92
0,675	5,28166826	9,8	83	13,19792412	29,94637	29,92
0,8125	6,21372737	10,6	84,3	6,934502505	29,97295	29,92
0,725	6,21372737	11,2	77,7	9,842519685	30,07335	29,92
0,8125	4,03892279	9,3	88,7	9,171438797	29,97886	29,92
0,6875	2,85831459	8,8	96	5,144953472	29,79282	29,92

Ek 2'nin devamı

0	6,21372737	13,9	65,5	10,06621331	29,88436	29,92
0,6375	4,66029552	12,5	76,8	12,30314961	29,63926	29,92
0,875	5,59235463	6,7	71,7	20,57981389	29,85778	29,92
0,675	4,97098189	5,3	69,8	13,42161775	30,16194	29,92
0,825	6,21372737	5,7	61,7	6,039727989	30,10879	29,92
0,6	6,21372737	11,6	69	14,98747316	29,88141	29,92
0,75	6,21372737	14,4	74,6	9,171438797	29,76919	29,92
0,6625	6,21372737	13,5	83	12,75053686	29,90208	29,92
0,75	5,28166826	14,8	74,7	16,1059413	29,6747	29,92
0,6375	4,97098189	13,6	77,8	10,28990694	29,7249	29,92
0,875	6,21372737	9,8	77,3	9,171438797	29,96114	29,92
0,9375	4,03892279	9,5	90,9	8,052970651	29,90208	29,92
0,65	6,21372737	10,2	83,6	16,1059413	30,15899	29,92
0,375	6,21372737	10,7	84,8	16,1059413	30,12355	29,92
0,6875	6,21372737	11,8	79,6	11,40837509	29,88731	29,92
0,7375	6,21372737	11,3	78,4	6,263421618	29,71013	29,92
0,775	6,21372737	10,9	83,7	25,05368647	29,63336	29,92
0,6625	5,28166826	11,7	80,4	15,21116679	29,81939	29,92
0	6,21372737	15,2	59,5	7,605583393	29,94047	29,92
0,2375	6,21372737	16,1	63,7	5,816034359	29,95228	29,92
0,725	6,21372737	13,3	84	8,50035791	30,00248	29,92
0,4875	5,59235463	15,5	76,3	6,934502505	29,8755	29,92
0,725	4,97098189	16,3	75,1	16,77702219	29,83711	29,92
0,7625	4,66029552	14	84,4	16,1059413	29,81349	29,92
0,8125	5,59235463	12,2	84,8	8,052970651	29,83711	29,92
0,85	4,34960916	11,9	87	18,34287759	29,80758	29,92
0,4	6,21372737	13,1	69,1	13,86900501	29,94637	29,92
0,725	5,28166826	10,4	89,4	6,934502505	30,03792	29,92
0,875	4,03892279	12,1	79,6	10,7372942	29,99953	29,92
0,3375	6,21372737	13,9	80,3	10,28990694	29,87255	29,92
0,725	5,903041	16	71,2	10,28990694	29,76033	29,92
0,7625	5,59235463	14,4	83,8	4,921259843	29,71899	29,92
0,75	5,59235463	12,6	80,2	27,51431639	29,87845	29,92
0,7	6,21372737	11,6	74	9,171438797	29,89617	29,92
0,75	5,59235463	10,4	87,8	7,381889764	29,87255	29,92
0,675	6,21372737	13,7	60,8	12,75053686	30,04678	29,92
0	6,21372737	14,3	59,9	8,052970651	30,28006	29,92
0,025	6,21372737	13,5	70,8	8,947745168	30,28892	29,92
0,6875	6,21372737	14,7	80	6,487115247	30,13832	29,92
0,5	2,29907913	14,3	86,9	8,052970651	30,03792	29,92
0,8	3,72823642	12,5	87,4	10,28990694	29,90798	29,92
1	6,21372737	13,1	90,3	13,42161775	29,87845	29,92
0,875	2,85831459	12,6	94,6	11,40837509	30,08221	29,92
0,75	6,21372737	14,3	80,6	5,59234073	30,08221	29,92

Ek 2'nin devamı

0,975	5,59235463	12	87,3	5,59234073	30,12355	29,92
0,8	4,34960916	11,2	87,6	4,697566213	30,20624	29,92
0,725	6,21372737	13,3	77	8,052970651	30,10288	29,92
0,3625	5,59235463	14,3	75,7	17,89549034	30,10584	29,92
0,175	6,21372737	16,4	53,8	16,1059413	30,19738	29,92
0,0875	6,21372737	16,1	61,3	9,171438797	30,09107	29,92
0,35	6,21372737	16,2	71,9	19,46134574	30,00248	29,92
0,175	5,28166826	16,5	73,3	3,355404438	29,89322	29,92
0,625	6,21372737	15,2	86,3	6,934502505	29,79577	29,92
0,6625	5,903041	15,9	83,8	13,86900501	29,87255	29,92
0,6375	5,59235463	16,3	82,7	18,34287759	29,88436	29,92
0,875	3,10686368	14,2	94,8	6,934502505	29,84892	29,92
0,975	4,03892279	15,9	87,8	10,06621331	29,8253	29,92
0,875	4,97098189	16	90,6	7,605583393	29,86664	29,92
0,85	4,03892279	16,4	91,1	9,842519685	29,93751	29,92
0,7875	6,21372737	17,9	85,7	10,28990694	29,97295	29,92
0,825	4,34960916	17,6	88,9	12,07945598	29,96409	29,92
0,7375	5,28166826	17,9	87,3	9,171438797	29,90503	29,92
0,75	6,21372737	19,1	84,1	14,98747316	29,83121	29,92
0,8125	4,97098189	18,2	90,7	5,816034359	29,81644	29,92
0,7375	5,903041	18,9	89,7	5,816034359	29,87255	29,92
0,6375	6,21372737	20,6	76,6	17,22440945	29,93751	29,92
0,3125	6,21372737	20,7	64,8	13,86900501	29,98476	29,92
0,3625	6,21372737	19,8	74,1	10,28990694	29,94933	29,92
1	4,19426597	19	94,4	6,710808876	29,84007	29,92
0,875	3,10686368	18,2	94,3	17,44810308	29,94933	29,92
0,9125	4,34960916	18	92,5	14,31639227	30,04087	29,92
0,25	6,21372737	20,2	77	10,06621331	30,11174	29,92
0	6,21372737	19,4	81,3	10,06621331	30,06154	29,92
0,4375	6,21372737	20,7	82	9,171438797	29,94637	29,92
0,9375	5,59235463	19,2	92,5	8,724051539	29,84597	29,92
0,2875	6,21372737	20,8	75,2	8,724051539	29,78986	29,92
0,45	6,21372737	20,3	75,6	6,934502505	29,75148	29,92
0,65	6,21372737	21,7	76,1	3,355404438	29,74852	29,92
0,8875	6,21372737	20,4	84,5	6,934502505	29,79872	29,92
0,5	6,21372737	22,1	75,4	11,40837509	29,85483	29,92
0,625	5,28166826	21,3	80,5	11,40837509	29,92275	29,92
0	6,21372737	22,4	68,2	9,171438797	29,83416	29,92
0,5	6,21372737	22,2	83,4	14,98747316	29,6747	29,92
0,75	6,21372737	20,1	89,8	5,816034359	29,72195	29,92
0,25	6,21372737	23	76,9	10,28990694	29,81939	29,92
0,7125	6,21372737	22	82,2	8,276664281	29,88141	29,92
0,2375	6,21372737	23,9	74,5	18,56657122	29,9759	29,92
0,425	6,21372737	24,3	76,3	13,42161775	30,05859	29,92

Ek 2'nin devamı

0,2	6,21372737	24,2	71	10,51360057	30,06449	29,92
0	6,21372737	22,6	69,6	8,052970651	30,01725	29,92
0,475	6,21372737	22,9	85,5	9,618826056	29,88731	29,92
0,5375	6,21372737	24,4	74,5	11,40837509	29,75148	29,92
0,525	6,21372737	25,1	69,1	12,75053686	29,86369	29,92
0,075	6,21372737	23,9	70,8	8,052970651	29,85778	29,92
0,6625	6,21372737	23,7	72,9	11,40837509	29,88731	29,92
0,575	6,21372737	21,1	78,4	7,829277022	29,9198	29,92
0,05	6,21372737	24,4	59,1	10,7372942	29,89617	29,92
0	6,21372737	24,2	66,3	17,22440945	29,78691	29,92
0,1125	6,21372737	25,1	78,1	8,052970651	29,85188	29,92
0,1625	6,21372737	26,1	73,5	8,052970651	29,92866	29,92
0	6,21372737	26,8	63,1	5,816034359	29,89027	29,92
0,1125	6,21372737	26,6	76,7	6,934502505	29,7751	29,92
0,175	6,21372737	27,3	71,1	16,1059413	29,77805	29,92
0,275	6,21372737	25,9	70,8	24,15891195	29,76329	29,92
0,85	6,21372737	23,7	74,2	16,1059413	29,71604	29,92
0,6875	6,21372737	24,5	66,5	17,22440945	29,93751	29,92
0,125	6,21372737	25,5	59,5	11,40837509	30,00839	29,92
0	6,21372737	27,3	53,7	9,171438797	30,03201	29,92
0,1125	6,21372737	24,8	71,1	4,697566213	30,06745	29,92
0	6,21372737	25,6	64,1	6,934502505	29,94342	29,92
0,3875	6,21372737	26	70,9	6,263421618	30,01134	29,92
0,4125	6,21372737	23,9	77,8	13,19792412	30,03496	29,92
0,0125	6,21372737	26,5	54	4,697566213	30,06449	29,92
0,0125	6,21372737	25,7	56	13,19792412	29,96704	29,92
0,025	6,21372737	27,4	48,4	7,605583393	29,89617	29,92
0	6,21372737	26,4	62,7	12,75053686	29,82825	29,92
0,1	6,21372737	25,2	66,8	8,052970651	29,84892	29,92
0	6,21372737	24,9	70	11,40837509	29,97	29,92
0	6,21372737	26,2	61,4	3,355404438	29,92275	29,92
0,5875	4,50495234	24	77,7	5,816034359	29,94933	29,92
0,0375	6,21372737	25,8	65,5	5,368647101	29,89913	29,92
0,025	6,21372737	25,7	67,2	9,842519685	29,78691	29,92
0,3125	6,21372737	27,9	69,3	5,816034359	29,61859	29,92
0,25	6,21372737	23,4	62,1	25,2773801	29,89913	29,92
0,2875	6,21372737	23,1	65	10,28990694	29,9198	29,92
0,0625	6,21372737	20,4	77,3	6,487115247	29,9198	29,92
0,025	6,21372737	23	69,9	6,710808876	29,79282	29,92
0,125	6,21372737	26,1	69,2	5,816034359	29,77805	29,92
0,4375	6,21372737	24,6	80	4,697566213	29,80758	29,92
0	6,21372737	25,9	77	5,816034359	29,90208	29,92
0	6,21372737	25,5	71,6	11,40837509	29,9198	29,92
0	6,21372737	26,3	72,3	16,77702219	29,78396	29,92

Ek 2'nin devamı

0	6,21372737	26,4	76,3	6,263421618	29,60973	29,92
0	6,21372737	25,8	70,1	4,250178955	29,73671	29,92
0,275	6,21372737	25,7	81	5,144953472	29,81349	29,92
0,7375	6,21372737	23,7	77,9	6,263421618	29,93751	29,92
0,4375	6,21372737	24,5	81,9	6,039727989	29,88436	29,92
0,7625	6,21372737	25,4	81,4	11,40837509	29,89617	29,92
0,6625	6,21372737	25,1	72,7	8,052970651	30,03201	29,92
0,875	6,21372737	23,3	80,6	8,052970651	30,02315	29,92
0,05	6,21372737	27,1	76,5	17,22440945	30,01725	29,92
0,0375	6,21372737	27,9	78,6	6,039727989	29,96704	29,92
0,1375	4,97098189	24,6	88,6	3,355404438	29,89913	29,92
0,1625	3,72823642	26,4	80,6	2,013242663	29,84597	29,92
0,0125	6,21372737	27,1	77	6,934502505	29,89322	29,92
0,05	6,21372737	26,1	83,6	6,710808876	29,91684	29,92
0	6,21372737	24,2	73,8	6,934502505	29,8755	29,92
0,0625	6,21372737	26,2	75,6	7,605583393	29,88436	29,92
0	6,21372737	29	51,6	7,605583393	29,92866	29,92
0,4125	1,80198094	23,7	87,3	7,605583393	29,96114	29,92
0,0625	6,21372737	27,9	58,4	5,59234073	29,95819	29,92
0	6,21372737	25,4	61,8	8,947745168	29,96409	29,92
0,0625	6,21372737	24,7	68,8	9,171438797	29,97	29,92
0	6,21372737	24	67,7	5,59234073	29,86369	29,92
0	6,21372737	24,4	69,7	4,473872584	29,76329	29,92
0,2	6,21372737	27,3	73,6	7,158196135	29,71604	29,92
0	6,21372737	25,7	72,6	14,31639227	29,71013	29,92
0	6,21372737	28	60	8,947745168	29,80168	29,92
0	6,21372737	27	69	7,381889764	29,90208	29,92
0,375	6,21372737	25,8	75,7	7,381889764	29,98181	29,92
0,875	6,21372737	21,9	88	8,50035791	29,94047	29,92
0,475	6,21372737	24,7	68,8	12,75053686	29,85188	29,92
0,4125	6,21372737	25,3	74,5	9,842519685	29,88141	29,92
0,725	6,21372737	25	77	7,158196135	30,00248	29,92
0,425	6,21372737	24,6	74	4,921259843	30,04678	29,92
0,5625	6,21372737	22,5	72,8	9,171438797	30,02906	29,92
0,0625	6,21372737	18,9	73,2	6,934502505	30,00543	29,92
0,725	6,21372737	18,6	70,7	9,171438797	30,04678	29,92
0,475	6,21372737	17,5	71,2	6,934502505	30,02315	29,92
0,5875	6,21372737	18,4	72,5	6,263421618	30,03201	29,92
0,2375	6,21372737	17,8	75,5	5,816034359	30,09993	29,92
0	6,21372737	17,8	71,5	8,50035791	30,07926	29,92
0	6,21372737	20,6	66,2	10,06621331	30,05563	29,92
0	6,21372737	19	75,9	6,487115247	30,08516	29,92
0,6625	6,21372737	19,1	76,5	6,487115247	30,10584	29,92
0,35	6,21372737	18,3	73,6	7,158196135	30,07926	29,92

Ek 2'nin devamı

0,0875	6,21372737	17,6	77,6	7,829277022	30,0261	29,92
0,075	6,21372737	18,9	80,6	6,263421618	30,01429	29,92
0,2125	6,21372737	17,5	84,5	6,487115247	30,04087	29,92
0,35	6,21372737	19,5	85,3	5,144953472	30,04382	29,92
0,25	6,21372737	19,5	85,7	6,039727989	30,05563	29,92
0,375	4,97098189	19,9	82,9	6,263421618	30,00248	29,92
0	6,21372737	17,1	92,1	4,697566213	30,00248	29,92
0,1625	6,21372737	22,5	79,3	6,934502505	29,98181	29,92
0,125	6,21372737	21,1	76,3	8,052970651	29,9759	29,92
0,1	6,21372737	22,7	76,2	6,934502505	29,97886	29,92
0,875	5,59235463	21,8	82,7	5,368647101	30,00543	29,92
0,625	6,21372737	20,3	87	4,921259843	29,95523	29,92
0,875	6,21372737	20	84,3	6,710808876	29,86369	29,92
0,625	6,21372737	21,6	74,6	13,64531138	29,89913	29,92
0,7	6,21372737	18,4	70,9	12,52684324	30,14127	29,92
0,15	6,21372737	15,1	74,4	6,487115247	30,23281	29,92
0,2875	6,21372737	15,3	79,8	6,039727989	30,22396	29,92
0,375	6,21372737	15,6	79,4	5,59234073	30,14718	29,92
0,625	6,21372737	16,8	87	5,144953472	30,19443	29,92
0	4,97098189	15,4	82	5,816034359	30,00839	29,92
0,7875	4,34960916	14,3	81,6	7,381889764	30,17375	29,92
0,675	6,21372737	14,2	78,6	5,368647101	30,09698	29,92
0,875	6,21372737	15,4	73,5	10,28990694	30,22986	29,92
0,2	6,21372737	16,2	63,3	10,28990694	30,27416	29,92
0	6,21372737	14,9	77,7	5,816034359	30,14127	29,92
0,5625	6,21372737	15,3	83,3	9,171438797	30,09402	29,92
0,3125	6,21372737	18,2	81,3	8,276664281	29,87255	29,92
0	4,34960916	17,2	80,4	9,618826056	29,83711	29,92
0,875	4,97098189	14,7	71,3	9,171438797	30,17375	29,92
1	1,86411821	14,5	79,9	14,98747316	30,02906	29,92
0,225	5,903041	14,7	80,7	7,381889764	30,06745	29,92
0,0375	4,34960916	16,2	73,5	7,158196135	29,96114	29,92
0,6625	5,59235463	17,3	71,7	5,59234073	29,97295	29,92
0	6,21372737	18,4	72,4	5,368647101	30,05268	29,92
0,5375	6,21372737	18,7	73	6,263421618	30,00543	29,92
0,4625	6,21372737	19,1	78,6	5,368647101	29,99657	29,92
0	6,21372737	18,5	86,6	6,487115247	29,89322	29,92
0,65	5,59235463	17,7	77,4	5,368647101	29,80168	29,92
0,55	6,21372737	19,8	65,9	5,59234073	29,80168	29,92
0	6,21372737	20,8	67,5	8,052970651	29,78101	29,92
0,625	6,21372737	19,1	76,7	4,473872584	29,9759	29,92
0,5	5,59235463	17,7	89,5	8,724051539	30,12946	29,92
0,35	4,97098189	19,2	87,4	10,7372942	30,05268	29,92
0,35	6,21372737	20,1	80,1	5,144953472	29,94047	29,92

Ek 2'nin devamı

0,75	4,97098189	17,9	88,6	7,605583393	29,95228	29,92
0,475	6,21372737	19,6	78,3	6,263421618	29,85188	29,92
0,75	6,21372737	19,1	70	8,052970651	29,81054	29,92
0,5875	5,59235463	19,2	81	8,276664281	29,85188	29,92
0,3375	6,21372737	21,1	66	10,51360057	29,79577	29,92
0,125	6,21372737	18,8	70,4	4,250178955	30,18852	29,92
0,4	6,21372737	18,4	71,4	4,921259843	30,0202	29,92
0,8125	5,59235463	14	87,4	9,171438797	29,99657	29,92
0,375	6,21372737	13,4	83,5	10,51360057	30,18557	29,92
0,4125	6,21372737	17,3	69,9	12,52684324	29,92275	29,92
1	6,21372737	16,7	86,5	6,487115247	29,87845	29,92
0,8125	6,21372737	15,7	91,1	8,276664281	29,97	29,92
0,5	6,21372737	14,9	82	8,724051539	29,96409	29,92
0,525	6,21372737	12,4	80	6,039727989	29,87255	29,92
0,95	2,17480458	12,7	88,9	8,052970651	29,85778	29,92
0,65	6,21372737	12,2	75,7	7,605583393	30,05563	29,92
1	6,21372737	12	73,8	7,605583393	29,68651	29,92
0,75	6,21372737	11,6	57	8,276664281	29,42074	29,92
0,9	4,34960916	10,2	73,2	19,23765211	29,73671	29,92
0,725	6,21372737	10,5	82,8	7,829277022	29,97	29,92
0,85	5,903041	11,7	77,6	5,368647101	29,97886	29,92
0,9125	3,26220687	11,8	90,4	7,381889764	30,06449	29,92
0,675	6,21372737	12,5	87,1	4,697566213	29,80758	29,92
0,85	6,21372737	15,7	69,7	5,59234073	29,50638	29,92
0,875	4,97098189	16,3	57,2	14,09269864	29,25242	29,92
0,475	6,21372737	6,6	64,7	12,52684324	29,79282	29,92
0,3	6,21372737	6,4	47,7	7,158196135	30,01429	29,92
0,775	6,21372737	13,8	61,5	8,50035791	29,78691	29,92
0,725	4,97098189	10,8	88,1	7,381889764	29,99657	29,92
0,7875	5,28166826	15,3	75,3	6,934502505	30,03496	29,92
0,125	5,59235463	15,9	74	6,039727989	29,94047	29,92
0	4,97098189	13,6	74	4,473872584	29,91684	29,92
0,725	6,21372737	12,1	84	8,276664281	30,05268	29,92
0,875	4,03892279	10,7	86,8	12,97423049	30,20033	29,92
0	6,21372737	10,9	84,4	7,829277022	29,93751	29,92
0,85	6,21372737	13,9	81,7	6,934502505	29,88731	29,92
0,8375	5,28166826	11,9	92,9	4,697566213	29,8755	29,92
0,875	3,41755005	11,6	96	3,802791696	29,80758	29,92
0,75	6,21372737	9,9	86,5	13,64531138	29,95228	29,92
0,6625	6,21372737	11,1	81,7	4,921259843	30,03792	29,92
0,7875	6,21372737	11,9	87,3	5,816034359	29,98476	29,92
0,6625	5,903041	11,2	79,5	9,171438797	30,00248	29,92
0,725	6,21372737	12,8	65	4,473872584	29,91389	29,92
0,2	4,97098189	13,5	79	6,263421618	29,99362	29,92

Ek 2'nin devamı

1	5,903041	9,4	82	11,40837509	30,26825	29,92
0,8375	5,59235463	5,7	89,3	7,829277022	30,50449	29,92
0,5	6,21372737	7	71,4	7,381889764	30,47791	29,92
0,75	3,57289324	8,7	80	4,473872584	30,3214	29,92
0	5,59235463	7,1	85,3	6,039727989	30,10879	29,92
0,2	5,59235463	9,4	75,8	5,144953472	29,82235	29,92
0,875	2,48549095	10,8	91,7	4,697566213	29,53295	29,92
0,6625	5,903041	11,3	57,5	14,31639227	29,46799	29,92
0,625	5,59235463	5,1	63	15,65855404	29,73966	29,92
0,675	4,03892279	10,7	74	5,368647101	29,92866	29,92
0,05	4,66029552	13,3	69,6	7,829277022	30,05268	29,92
0	6,21372737	13,7	66,8	9,395132427	30,10584	29,92
0,65	5,59235463	9,9	77,8	6,487115247	30,35389	29,92
0,0625	6,21372737	10	70,5	3,355404438	30,221	29,92
0	6,21372737	3,9	76	7,605583393	30,14718	29,92
0,7875	6,21372737	9,8	87,7	6,039727989	30,12651	29,92

ÖZGEÇMİŞ

Adı Soyadı : Özge DEMİRCİ

Eğitim Durumu

Lise : Karşıyaka Lisesi, 2011

Lisans : Amasya Üniversitesi, 2016

Yüksek Lisans : Sinop Üniversitesi, 2025

Mesleki Deneyim

İş Yeri : Rona Asansör Sanayi ve Ticaret Limited Şirketi, 2017-2018