

İSTANBUL TEKNİK ÜNİVERSİTESİ ★ LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

**GÜNEŞ ENERJİ SANTRALLERİNDE MAKİNE ÖĞRENMESİ
ALGORİTMALARI VE COĞRAFİ BİLGİ VERİLERİ KULLANILARAK
ENERJİ ÜRETİMİNİN TAHMİNLENMESİ**

YÜKSEK LİSANS TEZİ

Eren POLATCAN

Bilişim Uygulamaları Anabilim Dalı

Coğrafi Bilgi Teknolojileri Programı

Tez Danışmanı: Prof. Dr. Hayri Hakan DENLİ

OCAK 2024

İSTANBUL TEKNİK ÜNİVERSİTESİ ★ LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

**GÜNEŞ ENERJİ SANTRALLERİNDE MAKİNE ÖĞRENMESİ
ALGORİTMALARI VE COĞRAFİ BİLGİ VERİLERİ KULLANILARAK
ENERJİ ÜRETİMİNİN TAHMİNLENMESİ**

YÜKSEK LİSANS TEZİ

**Eren POLATCAN
(706201023)**

Bilişim Uygulamaları Anabilim Dalı

Coğrafi Bilgi Teknolojileri Programı

Tez Danışmanı: Prof. Dr. Hayri Hakan DENLİ

OCAK 2024

ISTANBUL TECHNICAL UNIVERSITY ★ GRADUATE SCHOOL

**PREDICTION OF ENERGY PRODUCTION IN SOLAR POWER PLANTS
USING MACHINE LEARNING ALGORITHMS AND GEOGRAPHIC
INFORMATION DATA**



M.Sc. THESIS

**Eren POLATCAN
(706201023)**

INFORMATICS INSTITUTE

Geographic Information Technology Programme

Thesis Advisor: Prof. Dr. Hayri Hakan DENLİ

JANUARY 2024

İTÜ, Lisansüstü Eğitim Enstitüsü'nün 706201023 numaralı Yüksek Lisans Öğrencisi Eren POLATCAN, ilgili yönetmeliklerin belirlediği gerekli tüm şartları yerine getirdikten sonra hazırladığı “GÜNEŞ ENERJİ SANTRALLERİNDE MAKİNE ÖĞRENMESİ ALGORİTMALARI VE COĞRAFİ BİLGİ VERİLERİ KULLANILARAK ENERJİ ÜRETİMİNİN TAHMİNLENMESİ” başlıklı tezini aşağıda imzaları olan jüri önünde başarı ile sunmuştur.

Tez Danışmanı : **Prof. Dr. Hayri Hakan DENLİ**
İstanbul Teknik Üniversitesi

Jüri Üyeleri : **Prof. Dr. Serdar EROL**
İstanbul Teknik Üniversitesi

Dr. Öğr. Üyesi Ramazan AYAZ
Yıldız Teknik Üniversitesi

Teslim Tarihi : 22 Aralık 2023
Savunma Tarihi : 23 Ocak 2024



ÖNSÖZ

Lisansüstü tez çalışmamda bilgi ve tecrübeleriyle bana destek olarak hatalarımı düzelten Prof. Dr. Hayri Hakan Denli'ye teşekkürlerimi sunarım. Onun katkıları olmadan bu çalışmayı tamamlamam mümkün olmazdı.

Ayrıca enerji konusundaki deneyimlerini her fırsatta benimle paylaşan ve tez çalışmam boyunca beni cesaretlendiren kardeşim Mustafa Necip Polatcan'a da teşekkür ediyorum.

Son olarak, lisansüstü eğitim hayatım boyunca her zaman yanımda olduklarını hissettiren birbirinden değerli dostlarıma ve aileme şükranlarımı sunarım.

Aralık 2023

Eren Polatcan
(Elektrik Mühendisi)



İÇİNDEKİLER

Sayfa

ÖNSÖZ	vii
İÇİNDEKİLER	ix
KISALTMALAR	xi
SEMBOLLER	xiii
ÇİZELGE LİSTESİ.....	xv
ŞEKİL LİSTESİ.....	xvii
ÖZET.....	xix
SUMMARY	xxii
1. GİRİŞ	1
1.1 Amaç	2
1.2 Kapsam.....	2
1.3 Yöntem	3
2. GÜNEŞ ENERJİSİ	4
2.1 Güneş Enerjisi ve Önemi.....	4
2.1.1 Yenilenebilir enerji kaynağı.....	4
2.1.2 Temiz enerji kaynağı.....	5
2.1.3 Ucuz enerji kaynağı	5
2.2 Güneş Enerjisinin Kullanımı	5
2.2.1 Güneş panelleri	5
2.2.2 Güneş kollektörleri.....	6
2.3 Güneş Enerji Santralleri	7
2.4 Güneş Enerjisi Üretim Potansiyeli	7
2.4.1 Güneş ışınlarının yoğunluğu	7
2.4.2 Sıcaklık ve güneş radyasyonu	8
2.4.3 Gölgeleme	9
2.5 Güneş Takip Sistemleri	10
2.5.1 Tek eksenli güneş takip sistemi	11
2.5.2 Çift eksenli güneş takip sistemi	11
2.6 CBS'nin Enerji Sektöründeki Kullanımı.....	12
2.7 CBS'nin Enerji Sektöründeki Geleceği.....	13
3. YAPAY ZEKA	15
3.1 Konuşma.....	15
3.2 Görüntü.....	16
3.3 Robotlar	16
3.4 Planlama ve Optimizasyon	16
3.5 Uzman Sistemler	16
3.6 Dil İşleme	17
3.7 Nesnelerin İnterneti	17
3.8 Makine Öğrenmesi	17
3.8.1 Derin öğrenme.....	17
3.8.2 Yapay sinir ağları	18

4. METODOLOJİ	19
4.1 Model Seçimi.....	20
4.2 Veri Toplama.....	21
4.3 Tahmin Çıktısı	21
4.3.1 Santral üretim verileriyle tahmin.....	23
4.3.2 CBS verilerinin modele eklenmesi.....	24
4.4 Fizibilite.....	29
4.4.1 Donanım maliyetleri.....	31
4.4.2 Yazılım geliştirme maliyetleri.....	31
5. SONUÇ VE ÖNERİLER.....	33
KAYNAKLAR.....	35
ÖZGEÇMİŞ.....	38



KISALTMALAR

SCADA	: Supervisory Control And Data Acquisition
GIS	: Geographic Information System
CBS	: Coğrafi Bilgi Sistemi
HTML	: Hypertext Markup Language
CSS	: Cascading Style Sheets
EPIAŞ	: Enerji Piyasaları İşletme A.Ş.
PV	: Photovoltaics
STC	: Standard Test Conditions
AI	: Artificial Intelligence
IoT	: Internet of Things
GES	: Güneş Enerji Santrali
ARIMA	: Autoregressive Integrated Moving Average
ELK	: Elasticsearch, Logstash, and Kibana
CPU	: Central Processing Unit



SEMBOLLER

G	: Güneş ışınlımı miktarı
G_r	: Referans güneş radrasyonu miktarı
I_{ph}	: Hücrenin fotovoltaiik akımı
I_{sc}	: Standart test koşulları altındaki kısa devre akımı
K_i	: Sıcaklık katsayısı
t	: Zaman
T_c	: Hücrenin sıcak değeri
T_r	: Referans sıcaklık değeri
V	: Gerilim
MW	: Megawatt



ÇİZELGE LİSTESİ

Sayfa

Çizelge 2.1 : Fotovoltaik akım formülü.....	10
Çizelge 4.1 : Donanım ve lisans maliyetleri.....	31
Çizelge 4.2 : Yazılım geliştirme maliyetleri.....	32
Çizelge 4.3 : Operasyonel maliyetler.....	32





ŞEKİL LİSTESİ

Sayfa

Şekil 2.1 : Örnek güneş kollektörü modeli.	6
Şekil 2.2 : Tek eksenli güneş takip sistemleri.....	11
Şekil 2.3 : Çift eksenli güneş takip sistemleri.....	12
Şekil 2.4 : Enerji sahalarının CBS ile izlenmesi.....	13
Şekil 3.1 : Yapay zeka kullanım alanları.	15
Şekil 3.2 : Yapay sinir ağları.	18
Şekil 4.1 : Afta güneş enerji santrali.....	19
Şekil 4.2 : Santral üretim verilerinin modele eklenmesi.....	23
Şekil 4.3 : Sadece santral üretim verileriyle yapılan üretim tahmini.....	24
Şekil 4.4 : Sıcaklık verilerinin modele eklenmesi.	25
Şekil 4.5 : Coğrafi bilgi verilerinin modele eklenmesi.....	26
Şekil 4.6 : Modelden elde edilen tahmin verilerinin grafik gösterimi.	27
Şekil 4.7 : Gerçekleşen santral üretimi ve GIS datalarıyla yapılan üretim tahmini. .	28
Şekil 4.8 : Gerçekleşen santral üretimi ve GIS datalarıyla yapılan günlük toplam üretim tahmini.....	29
Şekil 4.9 : Modelin mantıksal topolojisi.....	30
Şekil 4.10 : Modelin üst seviye mimarisi.	31



GÜNEŞ ENERJİ SANTRALLERİNDE MAKİNE ÖĞRENMESİ ALGORİTMALARI VE COĞRAFİ BİLGİ VERİLERİ KULLANILARAK ENERJİ ÜRETİMİNİN TAHMİNLENMESİ

ÖZET

Yenilenebilir enerji, fosil yakıt enerji kaynakları kullanımını ve bu tür yakıtların kullanımını sonucu ortaya çıkan çevre kirliliğini ve dolayısıyla küresel iklim değişimini en aza indirmek adına, başta Avrupa olmak üzere bütün dünya çapında umut verici teknolojilerin en önemlilerinden birisi olarak kabul edilmektedir. Bu bağlamda dünya genelindeki yenilenebilir enerji santralleri sayısı günden güne artmaktadır. Dünyadaki yenilenebilir enerji kaynakları içerisinde en sık kullanılanlardan birisi güneş enerjisidir. Güneş enerjisinden yüksek verim elde edebilmek için, kurulacak santrallerin planlaması ve arazi tahsisi çok önemlidir. Çünkü başta güneş ışınlarının yoğunluğu ve güneşlenme süresi olmak üzere, güneşten yüksek verimde elektrik elde edebilmek için gerekli meteorolojik koşullar coğrafi konumlara göre farklılık göstermektedir. Meteorolojik koşulların haricinde arazinin fiziksel koşullarının da santral kurulumuna uygun seçilmesi, güneş panellerinin güneşten maksimum miktarda ışık almasını ve gölgelenmeden korunmasını sağlamak için önemlidir. Ayrıca kurulu santrallerden ne kadar elektrik üretilebileceğini yaklaşık olarak bilmek, termik kaynak kullanımının planlamasında büyük rol oynar. Güneş enerji santrallerinden enerji üretimi; güneş ışınlarının geliş açısı, sıcaklık, coğrafi konum, gölgeleme, hava kirliliği ve yağış gibi coğrafi bilgi katmanlarına bağlı değişkenlik göstermektedir.

Bu tez çalışması ile güneş enerjisi üretimine etki eden coğrafi bilgi katmanlarının dinamik olarak işlendiği bir matematiksel model geliştirilmiş, gerçekleştirilen enerji üretimi tahminlenmesi ile santral sahiplerine, dağıtım şirketlerine ve resmi kurumlara referans bilgilerin sunulması amaçlanmıştır. Modelde, makine öğrenmesi ve zaman serisi algoritmaları kullanılarak, yüksek başarı oranı içeren tahminlerin yapılması amaçlanmış ve yapay zeka teknikleri kullanmanın geleneksel aritmetik hesaplamalara göre tahmin başarı oranı açısından farkı da incelenmiştir.

Bu çalışma ile, tasarımı ve demo modeli oluşturulan coğrafi bilgi sistemi sayesinde yapılacak güneş enerjisi üretim tahmini sonucu, hem mevcut hem de yeni güneş enerjisi santralleri için daha hassas değerlendirmelerin yapılmasına ve yatırımların geri dönüşünün arttırılabilmesine olanak tanıyacaktır. Geliştirilen makine öğrenimi tabanlı modelde yer alacak coğrafi katmanların haricindeki panel ve insan kaynaklı üretime etki eden faktörler ise, güneş santrallerinin kapasite ve üretim izlemesini yapan Scada sistemlerindeki veriler kullanılarak hesaplanmaktadır.

Makine öğrenmesi tabanlı tahmin modeli için yazılım geliştirme, sunucu ve operasyonel maliyetlerin hesaplanması için gerçekleştirilen fizibilite çalışması da böyle bir model oluşturmanın ve kullanmanın tahmini maliyet değerlerini ortaya koymuştur. Ayrıca santrallerde güneş takip sistemi olup olmaması durumu da göz önünde bulundurulmuş ve güneş takip sistemi dahiliyeti sonucu oluşacak üretim tahmini de hesaplanmıştır. Sonuç olarak güneş enerjisi santrallerinde üretim tahmini

yaparken coğrafi bilgi verileri ve yapay zeka modelleri kullanıyor olmanın geleneksel hesaplama yöntemlerine göre daha başarılı sonuçlar verdiği görülmüştür.



PREDICTION OF ENERGY PRODUCTION IN SOLAR POWER PLANTS USING MACHINE LEARNING ALGORITHMS AND GEOGRAPHIC INFORMATION DATA

SUMMARY

Renewable energy is considered one of the most promising technologies worldwide, especially in Europe, to reduce the use of fossil fuel energy sources and the environmental pollution and the effect to the global climate change resulting from the use of such fuels. In this context, the number of renewable energy plants worldwide is increasing day by day. One of the most frequently used renewable energy sources in the world is solar energy. For high efficiency from solar energy, planning and land allocation of the plants to be built are very important. In addition, by knowing approximately how much electricity can be generated from the installed plants plays a major role in the planning of thermal energy use.

The main objective of this study is to identify the geographic information layers that effect solar energy production by examining the economic and environmental benefits of using solar energy. Another objective of the study is to calculate the energy production of a specified solar power plant using artificial intelligence techniques and geographic information data. The study also mentions the areas of application of artificial intelligence and states that it is an important tool for improving existing processes.

Energy production from solar power plants varies depending on geographic information layers such as the angle of incidence of solar rays, temperature, geographical location, shading, air pollution, and rainfall. In the study, a mathematical model has been developed by dynamically processing the geographic information layers effecting solar energy production, and to provide reference information to power plant owners, distribution companies, and official institutions by predicting the energy production to be realized. In the model, it has been aimed to make high success rate predictions using machine learning and time series algorithms, and the difference between using artificial intelligence techniques and traditional arithmetic calculations in terms of prediction success rate has been also investigated.

In this study, a mathematical model analysis has been conducted in which geographical layers effecting solar energy production were dynamically processed. The model aims to make high-accuracy predictions using machine learning and time series algorithms. In the study, the prototype of the model has also been developed and production forecasting has been performed over a sample case, and the effects of geographical layers with high weight in energy production in solar power plants were observed on production forecasts.

The predictions in the ‘time series prediction model’, developed using the Python programming language during the study, has been made with the Facebook’s open source Prophet library. The hourly one year energy production data from the

Afta/Karapınar (a province of Konya), power plant and the geographical data as temperature, sunshine duration, precipitation amount and the average daily values of the angle of incidence of solar rays which have the highest impact on electricity production from solar energy has been used as input data in the model. Thanks to the Prophet time series prediction application based on machine learning, thousands of input data from the 2023 year has been analyzed automatically in seconds and the model has been worked out. While the model is running, a prediction method of the hourly energy production for the coming 10 days period, and by adding new data every coming day, has been developed.

The study evaluated various time series forecasting models from different libraries and ultimately utilized Facebook Prophet, an open-source forecasting software developed by Meta. ARIMA and Exponential Smoothing models were observed to be less successful than Prophet in capturing the relationships between multiple parameters. The meteorological geographic information data used in the model is defined as irregular data and can change continuously over time. Prophet is specifically designed to train data that lacks a specific pattern or structure, making it a more suitable tool for forecasting time series data with strong seasonal patterns, such as daily or monthly data.

Machine learning is a concept intertwined with artificial intelligence. Traditional rule-based algorithms used in traditional software are used together with statistical algorithms in machine learning and artificial intelligence applications to enable computers to perform capabilities such as decision-making and problem solving. In this study, the positive effect of using artificial intelligence algorithms on production forecasts has been observed. In current applications, production forecasts for solar power plants are mostly made using rule-based algorithms with arithmetic operations. Because it is not yet in practical use because it is both a new technology and the initial investment costs of the system to be developed are high to be able to develop a high-success prediction model by analyzing millions of data. However, it is expected that the process of production forecasting with artificial intelligence in the energy sector, as in traffic, weather, and the supply, production, etc. processes of large companies, will become widespread in the near future. The important thing is to be able to train artificial intelligence correctly and to choose the most appropriate prediction model for the case to be worked on.

The forecast is made based on the main layers effecting solar energy production; data on the angle of incidence of solar rays, temperature, geographic location, shading, air pollution, and precipitation. In addition, factors effecting production from panels and humans are calculated using the actual value data stored in the scada systems that monitor the capacity and production of solar power plants. The development of the model will allow for a more accurate estimation of the potential of solar energy production. This will allow for more precise evaluations for both existing and new solar power plants and increase the return on investment.

In the Feasibility section of the study, the initial investment and regular operational effort and costs required to develop such a prediction model were estimated based on the pricing of global cloud service providers and developer companies.

The development of the model will also make a significant contribution to the planning and allocation of land for solar energy production. In addition, it will help to reduce fossil fuel use and prevent environmental pollution by making solar energy production more efficient. Adaptation of the model to different countries and climatic conditions

is also an important issue for future research. These adaptations will allow the model to be used in a wider range. Since the geographic information system to be created to estimate solar energy production will have a cloud-based software infrastructure, it can become a software that can be used in many countries after the necessary configurations are made.





1. GİRİŞ

Dünyada tüketilen enerjinin yaklaşık %30,8'i ham petrol, %27,9'i kömür ve %21'i doğalgaz kaynaklarından sağlanmaktadır. Ancak bu fosil yakıt hammaddeleri sınırsız değildir ve her geçen gün azalmaktadır. [1] Fosil yakıt kaynaklarının tükenecek olması sebebiyle fiyatların çok yüksek seviyelere ulaşması ve 21. yüzyıl boyunca küresel enerji talebinin iki katına çıkması beklenmektedir. [2] Fosil yakıt kaynaklarının hızlı bir şekilde azalması ve bununla birlikte çevre kirliliğinin dikkat çekiyor olması, içerisinde bulunduğumuz asırda yenilenebilir enerji kaynaklarının kullanımının teşvik edildiği bir dönemle sonuçlanmıştır. Yenilenebilir enerjinin birçok türü bulunmaktadır. Bunların başlıcaları güneş, jeotermal, rüzgar, hidroelektrik, hidrojen ve biyokütle enerjisidir. Günümüzde fotovoltaik (PV) paneller ve rüzgâr enerji santralleri başta olmak üzere yenilenebilir enerji santralleri gelişimini hızlı bir şekilde sürdürmektedir. [3]

Fotovoltaik panellerden elektrik üretimi dünyada enerji talebine en hızlı çözüm olarak sunulan yenilenebilir kaynaklardan enerji üretim yöntemi olarak konumlanmıştır. Dünya çapında 40'dan fazla ülkede güneş enerjisi üretimine ilişkin fiyatlandırma kanunları uygulanmış olup, enerji piyasasındaki büyüme de bu doğrultuda önemli ölçüde artış göstermiştir.

Türkiye'de yenilenebilir kaynaklardan enerji üretimi son yıllarda hızla gelişmektedir. Bunun en önemli nedenlerinin başında Türkiye'nin güneş enerjisinden elektrik üretimi için ideal doğal koşullara sahip olmasıdır. Türkiye, özellikle coğrafi konumu ve iklim özellikleri sebebiyle güneş enerjisi potansiyeli yüksek ülkeler arasındadır. [4] Türkiye'de yıllık ortalama güneşlenme süresi toplam 2.640 saat olup, günde ortalama 7.2 saat güneşli gün yaşanmaktadır. Ortalama toplam radyasyon yoğunluğu ise 1.311 kWh/m²-yıl olup, günde ortalama 3,6 kWh/m² güneş enerjisi almaktadır. Bu değerlere göre, Türkiye'deki güneş enerjisi potansiyeli toplam 380 milyar kWh/yıl olarak hesaplanabilmektedir. Bu potansiyelin verimli bir şekilde kullanılması için coğrafi bilgi sistemlerinin ve jeostatistik hesaplamaların kullanılması oldukça önemlidir. [5]

Güneş enerjisi santrallerinin üretim verimini etkileyen temel şartlardan biri santral alanındaki güneş enerjisi potansiyelidir. [6] Bölgenin güneş radyasyon seviyesi üretilen enerji miktarıyla doğru orantılıdır. Panellerin verimliliği açısından bölgedeki güneş ışıınım seviyesinin günlük en az 4,5 kWh/m² olması gerekmektedir. [7] Konum, eğim, hava koşulları ve tesis koşulları güneş enerjisi üretimini etkileyen temel faktörlerdir. Tüm bu katmanlar mekansal ve matematiksel hesaplamalarla bir veri havuzunda toplanarak üretim tahmini yapmak veya santral verimliliğini artırmak için kullanılabilir.

1.1 Amaç

Bu çalışmanın amacı, güneş enerjisi kullanmanın ekonomik ve çevresel açıdan faydalarının incelenerek güneş enerjisi üretimine etki eden coğrafi bilgi katmanlarının belirlenmesidir. Çalışmanın bir diğer amacı da belirlenen bir güneş enerji santralindeki enerji üretiminin yapay zeka teknikleri ve coğrafi bilgi verileri kullanılarak hesaplanmasıdır.

1.2 Kapsam

Güneş enerji santralleri uluslararası kriterlere göre ve ulusal düzenleme ve denetmelere tabi olacak şekilde işletilmektedirler. Türkiye’de Enerji Piyasaları Denetleme Kurulu (EPDK) bu görevi üstlenmektedir. Güneş enerjisi santrallerinde hem anlık hem de geriye dönük üretilen enerjinin izlenmesi ve raporlanması için santrallerin SCADA adı verilen takip yazılımları kullanılmaktadır. Kurulu gücü 50kW ve üzeri olan güneş enerjisi santrallerinde uzaktan takip edilebilen SCADA sistemleri zorunludur. [8]

Çalışmanın dördüncü bölümünde bir güneş enerjisi santralının SCADA verileri ile santralin bulunduğu coğrafi konumun güneş enerjisinden elektrik üretimine etki eden bazı coğrafi bilgi verilerini girdi olarak kullandığı bir makine öğrenimi modeli eğitilerek ilgili santralin geleceğe dönük 10 günlük üretim tahminlemeleri yapması hedeflenmiştir. Yine aynı bölümde yer alan fizibilite çalışmasında böyle bir sistemin pratikte hayata geçirilmesinin maddi karşılığı ve eforu hesaplanmıştır.

1.3 Yöntem

Çalışmada kullanılacak güneş enerji santrali üretim verileri, EPIAŞ veritabanından alınarak kullanılmıştır. Coğrafi bilgi verileri için Meteoroloji Genel Müdürlüğü'nün santralin bulunduğu Konya şehrinin Kayapınar ilçesi verileri referans alınmıştır. Dördüncü bölümde detaylı anlatılacak modelin oluşturulması adımlarında kullanılan makine öğrenmesi zaman serisi algoritması için Facebook Prophet kütüphanesi ve Python programlama dili kullanılarak bir uygulama oluşturulmuştur. Yine dördüncü bölümdeki finansal fizibilite kısmında uygulamanın pratikte hayata geçirilmesi için gerekli altyapı ihtiyacı birer adet sanal Mongo ve Postgresql veritabanı, kapasiteleri dördüncü bölümde aktarılan özelliklerdeki bulut alanı, PHP yazılım dilinde geliştirilecek arka yüz (backend) ve HTML, CSS, JAVASCRIPT dillerinde geliştirilecek ön yüz (frontend) uygulaması için tahmini yazılım ve donanım maliyetleri hesaplanmıştır.

2. GÜNEŞ ENERJİSİ

Güneş enerjisi, Güneş'ten gelen ışıma enerjisidir ve fosil yakıtlara oranla daha temiz ve sürdürülebilir bir enerji kaynağıdır. Güneş enerjisi, elektrik üretimi, ısıtma ve soğutma, gıda üretimi ve su arıtımı gibi çeşitli uygulamalarda kullanılabilir.

Güneş enerjisinin kullanımı çok eski zamanlara dayanmaktadır. Antik Mısırlılar, güneşin ısınıp sıcak su sağlamak için kullanmışlardır. Antik Yunanlılar, güneşin ısınıp güneş saatlerini çalıştırmak için kullanmışlardır. Ancak güneşin temel enerji kaynaklarından biri haline gelmesi 20. yüzyılın sonlarına doğru başlamıştır. 1970'lerde, enerji krizi güneş enerjisi teknolojisini hızlandırdı. [9] Enerji krizi, dünya çapında insanlara enerji kaynaklarını çeşitlendirme ihtiyacını gösterdi. Güneş enerjisi, fosil yakıtlara bağımlılığı azaltmak için bir seçenek olarak ortaya çıktı. 1980'lerde ve 1990'larda, güneş enerjisi teknolojisi daha da gelişti. Güneş pillerinin verimliliği arttı ve güneş panellerinin maliyeti düştü. Bu gelişmeler, güneş enerjisinin daha geniş çapta benimsenmesine yol açtı. [10]

2.1 Güneş Enerjisi ve Önemi

Güneş enerjisi, güneşin çekirdeğinde gerçekleşen füzyon reaksiyonları sonucunda açığa çıkan elektromanyetik enerjidir. Bu enerji, yeryüzüne ulaşan güneş ışınları aracılığıyla kullanılabilir. Güneş enerjisi, yenilenebilir bir enerji kaynağıdır ve fosil yakıtlara olan bağımlılığı azaltmak için büyük bir potansiyele sahiptir. [11] Güneş enerjisi, günümüzde dünyanın birçok yerinde kullanılmaktadır. Türkiye, güneş enerjisi potansiyeli yüksek olan ülkelerden biridir. Ülkemizde, güneş enerjisi santralleri kurulumu ve kullanımı hızla artmaktadır.

2.1.1 Yenilenebilir enerji kaynağı

Yenilenebilir enerji kaynakları, doğal süreçler sonucunda sürekli olarak kendini yenileyen enerji kaynakları olarak tanımlanır. Bu kaynaklar, fosil yakıtlar gibi sınırlı bir kaynağa dayanmadığı için sürdürülebilir bir enerji kaynağı olarak kabul edilir. Güneş enerjisi de insan müdahalesi olmadan doğal süreçler sonucunda sürekli olarak

retilen bir enerji kaynađı olan gneřten elde edilmektedir. Bu nedenle, gneř enerjisinin kullanımı, gelecek nesiller iin enerji gvenliđini sađlamaya yardımcı olur.

2.1.2 Temiz enerji kaynađı

Temiz enerji, insan sađlıđına ve evreye zarar vermeyen enerji kaynaklarıdır. Bu kaynaklar, fosil yakıtlara alternatif olarak geliřtirilen ve dođaya zarar vermeyen enerji kaynaklarıdır. Temiz enerji ve yenilenebilir enerji arasındaki fark, bu iki kavramın farklı kriterlere gre sınıflandırmasının yapılmasıdır. Temiz enerji, evresel etkilerine gre sınıflandırılırken, yenilenebilir enerji, kaynaklarının yenilenebilme kapasitesine gre sınıflandırılır. Gneř enerjisi hem temiz hem de yenilenebilir bir enerji kaynađıdır. Kullanımı sırasında herhangi bir emisyon retmez. Bu nedenle, gneř enerjisinin kullanımı, hava kirliliđi ve iklim deđiřikliđi gibi evre sorunlarının azaltılmasına yardımcı olur.

2.1.3 Ucuz enerji kaynađı

Gneř enerjisi teknolojisi, son yıllarda nemli geliřmeler kaydetmiřtir. Bu geliřmeler, gneř enerjisinin maliyetinin daha da dřmesine neden olmuřtur. Gneř pillerinin verimliliđinin artması ve gneř panellerinin yaygınlařması, gneř enerjisini daha rekabeti hale getirmekte ve daha geniř apta benimsenmesine yol amaktadır. [12] Ayrıca hkmetlerin gneř enerjisini teřvik etmek iin attıđı adımlar ve sađladıđı destekler de gneřten enerji retimi maliyetlerinin ve yatırımların geri dnř srelerinin azalmasına neden olmaktadır.

2.2 Gneř Enerjisinin Kullanımı

2.2.1 Gneř panelleri

Gneř panelleri, gneř ıřıđını elektrik enerjisine dnřtren cihazlardır. Fotovoltaik panel olarak da adlandırılan paneller, bu enerjiyi kullanarak evlere, iřletmelere ve sanayi tesislerine elektrik sađlayabilirler. Gneř panelleri, gneř hcreleri ve montaj yapısı olmak zere temelde iki bileřenden oluřur. Gneř hcreleri, gneř ıřıđını elektrik enerjisine dnřtren yarı iletken malzemelerden yapılmıřtır. Montaj yapısı ise bu hcreleri bir arada tutup sabitlemektedir. [13]


Gneř panellerinin alıřma prensibi, fotovoltaik etki olarak adlandırılır. Fotovoltaik etki, ıřıđın yarı iletken bir malzemeye arpması sonucunda elektriksel bir potansiyel

fark oluşmasıdır. Güneş hücreleri, bu etkiyi kullanarak güneş ışığının enerjisini elektrik enerjisine dönüştürür. [14]

Güneş panellerinin verimliliği, güneş hücrelerinin verimliliği ve güneş panellerinin tasarımı gibi faktörlere bağlıdır. Günümüzde, güneş hücrelerinin verimliliği %20'nin üzerindedir. Güneş panellerinin verimliliği arttıkça, üretilen elektrik miktarı da artar. Güneş panelleri, ayrıca güneş enerjisi santrallerinde de kullanılır. Güneş enerjisi santralleri, büyük ölçekte elektrik üretmek için güneş panellerinden yararlanır.

2.2.2 Güneş kolektörleri

Güneş kolektörleri ve güneş panelleri, güneş enerjisinden yararlanmak için kullanılan iki farklı cihazdır. Güneş kolektörleri, güneş enerjisini ısıya dönüştürmek için kullanılırken, güneş panelleri, güneş enerjisini elektrik enerjisine dönüştürmek için kullanılır. (Şekil 2.1) Güneş kolektörleri, güneş ışınlarını toplayarak ve bu ışınları bir akışkana aktararak çalışır. [15] Bu akışkan, bir boru sistemi aracılığıyla bir depoya taşınır ve bu depodaki suyun veya başka bir akışkanın ısınmasını sağlar. Güneş kolektörleri, sıcak su üretimi, ısıtma ve soğutma gibi uygulamalarda kullanılır. [16]



Şekil 2.1 : Örnek güneş kolektörü modeli.

2.3 Güneş Enerji Santralleri

Güneş enerji santralleri, çok sayıda güneş panelinden oluşan büyük sistemlerdir. Bu paneller, güneş ışınlarını fotovoltaiik hücreler kullanarak elektrik enerjisine dönüştürürler. Güneş enerji santralleri, genellikle elektrik şebekesine bağlıdır ve üretilen elektrik enerjisi, şebeke üzerinden dağıtılır.

Güneş enerji santralleri, küresel enerji ihtiyacının karşılanması ve sürdürülebilir bir enerji geleceği inşa edilmesi için önemli bir potansiyele sahiptir. Bu potansiyelin hayata geçirilmesi için, güneş enerji santrallerinin geliştirilmesi ve yaygınlaştırılması gerekmektedir. Güneş enerji santrallerinin yaygınlaşması için, maliyetlerinin düşürülmesi ve yatırım geri dönüşü süresinin kısaltılması gerekmektedir. Ayrıca, güneş ışınlarının yeterli olmadığı durumlarda da elektrik üretimi yapabilen teknolojiler geliştirilmesi gerekmektedir.

Güneş enerji santrallerinin geliştirilmesi ve yaygınlaştırılması için, teknolojik gelişmelerin yanı sıra, politik ve yasal düzenlemeler de önemli bir rol oynamaktadır. Bu alanda yapılan çalışmalar, güneş enerjisinin küresel enerji pazarında daha önemli bir rol oynamasını sağlamaktadır.

2.4 Güneş Enerjisi Üretim Potansiyeli

Güneş enerjisi üretim potansiyeli, güneş ışınlarının yoğunluğu, güneşlenme süresi, bulutluluk, sıcaklık ve arazi kullanım koşulları gibi bir dizi faktöre bağlıdır. Güneş ışınlarının yoğunluğu, güneş enerjisi üretim miktarını doğrudan etkiler. Güneşlenme süresi, güneş enerjisi üretim süresini belirler. Arazi kullanım koşulları, güneş enerjisi santrallerinin kurulabileceği alanların büyüklüğünü ve sınırlamalarını belirler.

2.4.1 Güneş ışınlarının yoğunluğu

Güneş ışınlarının yoğunluğu, Dünya'nın ekseninin eğikliği ve Dünya'nın yörüngesi gibi faktörlerden de etkilenir. Dünya'nın ekseninin eğikliği ve yörüngesi, güneş ışınlarının Dünya'ya geliş açısını ve ulaşan miktarını belirler.

Güneş ışınlarının Dünya'ya geliş açıları, Dünya'nın kendi eksenini etrafında ve güneş yörüngesindeki dönme hareketi sebebiyle sürekli olarak değişmektedir. Güneş ışınları Dünya'ya dik ya da dike yakın açılarda geldiğinde, atmosferde daha az dağılır ve daha

kısa sürede yer yüzüne ulaşır. Bundan dolayı dik açıyla gelen Güneş ışınlarının yoğunluğu, küçük açılarla gelen Güneş ışınlarından daha yüksek olur.

Güneş enerji santrallerinin bütün sene çalışıyor olduğunu göz önünde bulundurursak bundan dolayı sene içi toplamı en fazla olan değer seçilmelidir. Açık gökyüzü radyasyon hesaplamalarına bakıldığında bu değer eğim ve enlem eşitliği olarak karşımıza çıkmaktadır.

Güneş ışınlarının PV panellere mümkün olacak en dik açıyla gelmesini sağlamak için güneş panelleri eğimli olarak konumlandırılmaktadır. Örneğin; Türkiye 36-42 kuzey paralelleri arasında yer almaktadır. Bulunduğu konum itibarıyla yıl içerisinde güneş ışınları ortalama 30-40° arasındaki açılarla gelmektedir. Türkiye'nin bulunduğu enlem ve güneş ışınlarının Türkiye'ye yıl içerisinde ortalama geliş açıları göz önünde bulundurulduğunda, Türkiye'deki güneş panelleri için optimum eğim açısı 35-40° olarak kabul edilmektedir. Türkiye'de ortalama olarak 35-40° eğim aralığında konumlandırılan güneş panellerinin, 0° eğim ile konumlandırılan panellere oranlara %9 dolayında enerji üretiminden kazanç sağladığı tahmin edilmektedir. [17]

Panel yüzeyine gelen güneş ışınımının daha da artırılması için güneş takip sistemleri tercih edilebilmektedir. Ancak güneş takip sistemleri, güneş santrali kurulum maliyetlerini arttıracığından, kullanım için kurulum maliyetini karşılayabilecek bölgelerin seçilmesi önemlidir.

2.4.2 Sıcaklık ve güneş radyasyonu

Güneş enerji santrallerinde panel verimliliğini etkileyen coğrafi katmanların başında sıcaklık ve güneş radyasyonu gelmektedir. Atmosferik koşullardaki değişkenlerden olan güneş ışınım şiddeti ve sıcaklık, güneş enerjisinden elektrik üretim miktarında önemli rol oynar. Bunun nedeni, sıcaklığın panellerin elektronlarını daha kolay hareket ettirmesidir. Bu nedenle de değişen atmosfer koşullarına bağlı olarak güneş ışınım şiddetinin ve sıcaklığın panel verimliliğine etkisinin bilinmesi önemlidir. [18]

PV panel üreticileri kataloglarında, laboratuvar ortamında yapılan testler sonucunda standart test koşulları (STC) altında 1000 W/m² olarak kabul edilen güneş ışınım şiddeti ve 25 °C ortam sıcaklığı şartlarında fotovoltaiik panellerin elektriksel değerlerini verirler. PV panelin elektriksel değerleri STC dışındaki değişiklikler için ayrıca hesaplanmalıdır. Değişen atmosfer koşullarında PV panelin elektriksel değerlerinin bilinmesi üretim hesabının yapılabilmesi için gerekmektedir. Özellikle

sistemlerin tasarımında, değişen atmosfer koşullarını dikkate alarak hesaplamalar yapmak daha doğru sonuçlar verecektir. [19]

Yapılan çalışmalarda, PV panelin katalog verileri kullanılarak MATLAB ve PSIM programlarında eşdeğer devreleri oluşturulan paneller modellenmiş ve 0, 25, 50 °C ve 200, 400, 600, 800, 1000 W/m² değerleri için güneş radyasyonu şiddetlerindeki değişimler incelenerek, hücre üzerinde akım, gerilim ve güç metrikleri hesaplanmıştır. PV hücresinin fotovoltaiik akımı (I_{ph}), güneşin hücre üzerine düşen radyasyon miktarıyla doğru orantılıdır. [20] Güneş radyasyonunun hücrenin fotovoltaiik akımına etkisi aşağıdaki formülle hesaplanmaktadır; (Çizelge 2.1)

Çizelge 2.1 : Fotovoltaiik akım formülü.

Formül	Açıklama
	I_{ph}: Hücresinin fotovoltaiik akımı (A)
	I_{sc}: Standart test koşulları altındaki kısa devre akımı (A)
	K_i: I_{sc} 'nin sıcaklık katsayısı (0,0017 A/°C)
$I_{ph} = [I_{sc} + K_i * (T_c - T_r)] / (G / G_r)$	T_c: Hücresinin sıcak değeri (°C)
	T_r: Referans sıcaklık değeri (°C)
	G: Güneş ışınımı miktarı (W/m ²)
	G_r: Referans güneş radyasyonu miktarı (W/m ²)

2.4.3 Gölgeleme

Güneş panellerinde gölgelenmenin önlenmesi çok önemlidir. Ancak bazı uygulamalarda arazi sınırlı olabilir ve araziye en verimli kullanmak için mümkün olduğu kadar çok sayıda PV panelinin yerleştirilmesine ihtiyaç duyulabilir. Bu durumda ardışık ve yan yana olan panel gruplarının gölgeleme etkisinin incelenmesi gerekmektedir. [21]

Gölgeleme, toz birikmesi haricindeki panel verimliliğine etki eden önemli parametrelerden birisidir. Ağaç, bulut, bina, yaprak, baca vb. fiziksel koşulların panel üzerinde oluşturduğu gölgeler, panel üretim performansına olumsuz etkide bulunabilir.

Bu olumsuz etki, hücrelerin üzerindeki bazı engeller nedeniyle sistemin aynı miktarda radyasyona maruz kalmaması durumunda ortaya çıkar. Bunun sonucunda düşük seviyelerde radyasyona maruz kalan hücreler, diğer hücreler kadar güç üretemediği için sistemin toplam gücünü azaltır. Gölgeleme, kısmi ve homojen gölgeleme olarak iki alt kolda incelenebilir.

Güneş panelinin sadece belirli bir kısmına fiziksel engellerin oluşturduğu gölgelerin düşmeleri sonucu kısmi gölgelenme meydana gelir. Gölge altındaki hücrenin sıcaklığı ve radyasyonu değiştikçe güç azalır. Bu durumda gölge, panelin hücrelerinden üretilen akımların uyumsuzluğuna neden olur.

Güneş enerji santralleri kurulurken gölgeleme etkisine dikkat edildiği için genellikle bulutluluk ve yağış gibi meteorolojik olaylar kaynaklı gölgelemeler yaşanmaktadır. Gölgelemenin santral üretimine etkileri, güneş ışığının yeryüzüne ulaşan miktarını belirten güneşlenme süreleriyle ve yağış miktarlarıyla hesaplanmaktadır.

2.5 Güneş Takip Sistemleri


Güneş panelleri ortalama yaklaşık %20 verimlilikte çalışmaktadır. Bu, güneş enerjisinin 100 Watt'ının güneş paneli üzerine düşmesi durumunda 20 Watt elektrik üretilebileceği anlamına gelmektedir. [22] Ancak güneş takip sistemleri, güneş panellerinin güneşin yolunu takip etmesini ve gün boyunca daha fazla enerji absorbe etmesini sağlayarak daha verimli bir yenilenebilir enerji kaynağı oluşturulmasına yardımcı olur.

Sabit bir güneş paneli tüm gün güneşi görebilir, ancak dünyanın ve güneşin yörüngelerindeki hareketlerinden dolayı güneş ışınlarının geliş açısı gün içerisinde değişkenlik gösterecektir. Güneş takip sistemleri sayesinde panel gün boyunca güneşe en uygun açılarda bakabilir ve böylece daha yüksek yoğunlukta yayılan enerjinin yakalanması sağlanır.

Hareketlerine göre iki tip güneş takip sistemi bulunmaktadır; tek eksenli güneş takip sistemi ve çift eksenli güneş takip sistemi.

2.5.1 Tek eksenli güneş takip sistemi


Tek eksenli bir güneş takip sistemi, santralin kurulacağı bölgenin güneşten gelecek ışın demetlerinin yönüne bağlı olarak, solar panel hücrelerini genellikle kuzey-güney veya doğu-batı yönünde hizalanmış bir hareket ekseninde hareket ettirir. (Şekil 2.2) Bu kurulumlar, panellerin doğudan batıya doğru kavis çizmesine ve güneşi doğup batarken takip etmesine olanak tanıyarak, daha fazla güneş paneli eklemekten sisteminizin çıkışını artırır. Genellikle sıcak ve kuru olan alanlardaki düz arazilerde kullanılmaktadır.



Şekil 2.2 : Tek eksenli güneş takip sistemleri.

2.5.2 Çift eksenli güneş takip sistemi

Çift eksenli güneş takip sistemleri, panellerin hem kuzey-güney yönünde hem de doğu-batı yönünde hizalanmış iki ekseninde hareket edebilmesini sağlar. Bu tür bir sistem, normal günlük hareketin yanı sıra mevsimsel değişiklikler sonucu güneşin yüksekliğini de izleyen algoritmalar ve sensörler kullanarak yıl boyunca güneş enerjisi verimini en üst düzeye çıkarmak için tasarlanmıştır. (Şekil 2.3)



Şekil 2.3 : Çift eksenli güneş takip sistemleri.

2.6 CBS'nin Enerji Sektöründeki Kullanımı


Coğrafi bilgi sistemleri (CBS) coğrafi verileri toplamak, depolamak, analiz etmek ve görüntülemek için kullanılan bilgisayar tabanlı sistemlerdir. CBS, enerji sektöründe, enerji kaynaklarının keşfi, değerlendirilmesi, üretimi, dağıtımı ve tüketiminin iyileştirilmesi için kullanılmaktadır. CBS'lerin enerji sektöründe kullanılmasının birçok faydası bulunmaktadır. Öncelikli olarak verilerin daha verimli ve etkili bir şekilde kullanılmasını sağlar. Enerji sektöründe üretilen ve kullanılan çok çeşitli verilerin toplanması, depolanması ve analiz edilmesini sağlar. Bu, enerji sektöründeki karar verme sürecini daha iyi yönetmek için gerekli olan bilgilere erişimi kolaylaştırır.

Bir diğer faydası da karmaşık sorunları daha kolay anlama ve çözme imkanı sunmasıdır. Örneğin, enerji kaynaklarının keşfi, değerlendirilmesi ve üretimi için uygulanarak bu kaynakların daha verimli ve sürdürülebilir bir şekilde kullanılmasına yardımcı olabilir. Ayrıca karar verme sürecini daha şeffaf ve hesap verebilir hale getirir. CBS, enerji sektöründeki karar vericilerin, kararlarının temelini oluşturan verileri ve analizleri görselleştirmesine olanak sağlar. Karar vericilerin kararlarını daha iyi açıklamalarına ve savunmasına yardımcı olur.

CBS'ler, enerji sektörünün tüm alanlarında kullanılmaktadır. CBS'nin yaygın kullanıldığı alanların başında kaynak keşfi gelmektedir. Petrol, doğal gaz, kömür ve rüzgar gibi enerji kaynaklarının keşfedilmesinde CBS'den yararlanılmaktadır. Bu kaynakların bulunduğu yerleri belirlemek, bunların miktarını ve kalitesini tahmin etmek için sıklıkla kullanılmaktadır. Örneğin, petrol ve doğal gaz arama şirketleri,

potansiyel arama alanlarının belirlenmesi ve bu alanlarda yapılacak sondaj çalışmalarının verimliliğinin artırılması amacıyla coğrafi bilgi sistemlerinden yararlanmaktadır. Bunu daha çok, jeolojik harita ve modeller oluşturarak petrol ve doğal gaz oluşumu için uygun alanların belirlenmesi ve sondaj planlamalarında CBS yazılımları kullanılması şeklinde uygulamaktadırlar. [23] Enerji kaynaklarının ekonomik değerini ve çevresel etkilerini değerlendirmek için, bu kaynakların üretiminin maliyetini, çevresel etkilerini ve ekonomik faydalarını tahmin etmek için de kullanılmaktadır. [24] Ayrıca enerji santrallerinin ve diğer enerji üretim tesislerinin yerini belirlemek, tasarımını oluşturmak ve operasyonunu yönetmek, bu tesislerin verimliliğini ve güvenliğini artırmak için de CBS'den yararlanılmaktadır. (Şekil 2.4)

CBS'lerin enerji sektöründe kullanımı, giderek daha yaygın hale gelmektedir. CBS teknolojisindeki gelişmeler ve enerji sektöründeki ihtiyaçlar, CBS'lerin bu sektördeki kullanımını daha da artıracaktır. [25]



Şekil 2.4 : Enerji sahalarının CBS ile izlenmesi. (<https://www.esri.com/en-us/industries/petroleum/overview>)

2.7 CBS'nin Enerji Sektöründeki Geleceği

CBS'lerin enerji sektöründe kullanımının gelecekteki potansiyeli CBS teknolojisindeki gelişmeler, enerji sektöründeki ihtiyaçlara göre şekillenecektir.

CBS teknolojisindeki gelişmeler, CBS'lerin enerji sektöründe daha karmaşık ve zorlu sorunları çözmesine olanak sağlayacaktır. Örneğin, CBS, yapay zeka ve makine öğrenimi gibi teknolojilerle birlikte kullanılarak, enerji sektöründeki karar verme sürecini daha da iyileştirmek için kullanılabilir. Enerji sektörünün ihtiyaçları ise CBS'lerin bu sektörde daha geniş bir yelpazede kullanılmasına yol açacaktır. Örneğin, iklim değişikliğiyle mücadele kapsamında, CBS'ler, yenilenebilir enerji kaynaklarının kullanımını artırmak ve enerji verimliliğini artırmak için kullanılabilir.

CBS'lerin enerji sektöründe kullanımının gelecekteki potansiyeli, enerji kaynaklarının daha verimli bir şekilde kullanılmasına yardımcı olacak yeni teknolojilerin geliştirilmesinde kullanılacaktır.



3. YAPAY ZEKA

Yapay zeka, insan benzeri akıl ve yeteneği simüle etmek için makinelerin programlanmasıdır ve makinelerin öğrenme, problem çözme ve insan benzeri görevleri yerine getirme yeteneğini geliştirmeye odaklanan bir bilgisayar bilimi dalıdır. Yapay zeka, özellikle bulut bilişim teknolojilerinin gelişmesi sonucunda veri iletimi, işleme ve depolamasıyla ilgili hız ve kapasitelerin artmasıyla birlikte ortaya çıkmıştır. Milyonlarca veriyi saniyeler içerisinde analiz edebilme yeteneği bir anda bütün sektörlerin ilgisini bu alana çekmeyi başardı.

Yapay zeka, uygulama alanları bakımından çok çeşitli uygulama ve sektörlerde kullanılmaktadır. (Şekil 3.1)



Şekil 3.1 : Yapay zeka kullanım alanları.

3.1 Konuşma

Yapay zeka konuşma alanında önemli uygulamalara sahiptir. Konuşma, insanların birbirleriyle iletişim kurmasının en doğal yoludur ve yapay zeka, konuşmayı daha

verimle hale getirme potansiyeline sahiptir. Konuşma alanındaki uygulamalar genellikle doğal dil işleme ve makine öğrenimi temelli bir teknik üzerinden geliştirilen text to speech (TTS), speech to test (STT) ve sesli komut asistan uygulamalarıdır.

3.2 Görüntü

Görüntü alanında her geçen gün gelişimini sürdüren yapay zeka uygulamaları, insanların dünyayı daha etkili bir şekilde anlamalarına yardımcı olmaktadır. Güvenlik, sağlık hizmetleri ve üretim gibi sektörlerde yapay zekanın görüntü uygulamaları önemli faydalar sağlamaktadır. Görüntülerin dijital olarak analiz edilmesini ve işlenmesini sağlayan görüntü işleme teknolojisi, basılı metinlerin bilgisayarlar tarafından okunmasını sağlayan optik karakter tanıma teknolojisi ve makinelerin görüntüleri anlamasını ve yorumlamasını sağlayan makine görüntüleme teknolojisi yapay zekanın görüntü alanındaki uygulamalarının başlıcaları olarak sıralanabilir.

3.3 Robotlar

Robotların insanların yaptığı fiziksel ve zihinsel işlere dahilîyetlerinin artırılması yapay zekanın gelişimiyle doğru oranda artan bir ilerlemedir. İnsanlarla aynı ortamlarda etkileşim içinde çalışabilen cobotlar ve genellikle tıp ve savunma sanayii alanlarında yaygın kullanılmaya başlanan biyo uyumluluğu yüksek soft robotlar yapay zekayı kullanma noktasında öne çıkan robot teknolojileridir.

3.4 Planlama ve Optimizasyon

Yapay zeka; üretim, dağıtım, enerji ve finans gibi sektörlerde işletmelerin giderlerini azaltmak ve hizmet kalitelerini artırmak amacıyla süreçlerin planlamasında ve iyileştirilmesinde sıklıkla kullanılmaktadır.

3.5 Uzman Sistemler

Siber saldırıların hedefinde, kullanıcıların kişisel verileri ve bankacılık ürünleri üst sıralarda yer almaktadır. Bu tarz saldırılara ya da güvenlik açıklarına engel olabilmek adına yapay zeka destekli, çok yönlülükten ziyade tek bir amaca hizmet amaçlı geliştirilen uzman sistemler kullanılmaktadır.

3.6 Dil İşleme

Dil işleme, bilgisayarlardan doğal konuşma dillerini anlamasını ve üretmesini sağlayan bir yapay zeka dalıdır. Dilden dile çeviri uygulamaları ve sohbet robotları bütün dünyada en yaygın kullanılan yapay zeka uygulamaları olarak sıralanmaktadır. Bu tarz doğal dil işleme temelli uygulamalar çok fazla veriye ihtiyaç duydukları için çok yüksek donanım gereksinimleri bulunmaktadır. Bu nedenle genellikle global ölçekli büyük teknoloji firmaları bu alanda ürünler çıkartabilmektedir.

3.7 Nesnelerin İnterneti

IoT (Internet of Things) birbiriyle dijital olarak bağlı olan ve veri paylaşabilen fiziksel cihazların haberleşme ağıdır. Yapay zeka, IoT cihazlarından gelen verileri analiz etmek için kullanılmaktadır. Bu analizin amacı cihazların performanslarını izleyip sorunları tespit ederek verimliliği artırarak kullanım alanlarını genişletmektir. Özellikle akıllı ev ve şehirlerin çoğalıyor olması IoT cihazlarının yaygınlaşmasında ve teknolojilerinin ileriye gitmesinde rol oynamaktadır.

3.8 Makine Öğrenmesi

Makine öğrenmesi, bilgisayarların deneyimlerden öğrenmesine ve performanslarını iyileştirmesine olanak tanıyan, yapay zekanın hemen hemen bütün uygulamalarında yer alan bir yapay zeka tekniğidir. Veri kümeleri üzerinde modeller oluşturulmak için kullanılan makine öğrenmesi insan beyninin taklit eden yapay sinir ağları modelini kullanır. Yapay sinir ağları adeta insan beyninin matematiksel bir modele dönüştürülerek büyük veriler üzerinden işlemler ve testler yaparak doğru sonuca karar verme prensibiyle çalışmaktadır. Makine öğrenmesi ve yapay zeka, birbirini tamamlayan iki kavramdır. Makine öğrenmesi, yapay zekanın öğrenme ve adaptasyon yeteneğini sağlar. Yapay zeka ise makine öğrenmesinin daha etkili bir şekilde kullanılmasını sağlar.

3.8.1 Derin öğrenme


Derin öğrenme, makine öğrenmesinin alt kümesidir ve makine öğrenmesini içerir. Ancak her makine öğrenmesi modeli derin öğrenmeyi içermez. Veri sayısı ve karmaşıklık arttıkça derin öğrenme algoritmalarına ihtiyaç duyulur. Derin öğrenme

modelleri ortalama bir makine öğrenmesi modeline göre yüzlerce kat daha fazla veriyle çalışabilme yeteneğine sahiptir.

3.8.2 Yapay sinir ağları

Yapay sinir ağları, nöron adı verilen yapay düğümlerden oluşan bir ağıdır. Bu düğümler, sinir sistemindeki nöronlara benzer şekilde çalışır. Yapay sinir ağları, girdi katmanı, gizli katmanlar ve çıktı katmanı olmak üzere üç ana katmandan oluşur.

Girdi katmanı, yapay sinir ağına giren verileri temsil eder. Bu veriler, görüntüler, metinler veya sayılar olabilir. Gizli katmanlar, yapay sinir ağının öğrenme sürecini gerçekleştirir. Gizli katmanlarda bulunan nöronlar, girdi verilerini işler ve çıktı katmanına gönderilecek verileri üretir. Çıktı katmanı, yapay sinir ağının ürettiği verileri temsil eder. Bu veriler, sınıflandırma, tahmin veya kontrol gibi görevlerin çıktısını temsil edebilir. Yapay sinir ağlarında (Şekil 3.2) katmanların sayısı ve yapısı, yapay sinir ağının öğrenme kapasitesini belirler. Daha fazla gizli katman ve daha fazla nöron içeren yapay sinir ağları, daha karmaşık görevleri yerine getirebilir. [26]



Şekil 3.2 : Yapay sinir ağları.

4. METODOLOJİ

Yapılan çalışma ile güneş santrallerinde üretilecek güneş enerjisinin günlük ve saatlik tahmin edilebilmesi, makine öğrenmesi temelli yapay zeka algoritmaları ve coğrafi bilgi verileri kullanılarak gerçekleştirilmiştir. Örnek vaka çalışması, Konya Karapınar'da bulunan Afta Güneş Enerji Santrali'nin (Şekil 4.1) gerçekleşen üretim verileri ve bulunduğu koordinatlardaki coğrafi bilgi verileri kullanılarak gerçekleştirilmiştir. [27] Afta GES kurulu güç, üretim kapasitesi ve yıllık elektrik üretim değerleri göz önünde bulundurulduğunda Türkiye'nin en büyük güneş enerji santrallerinden biri olduğu için bu tesisin enerji üretiminin gerçekleşecek değere daha yakın tahmin edilmesi, daha büyük ekonomik kazançlar sağlayacaktır.



Şekil 4.1 : Afta güneş enerji santrali. (<https://www.miateknoloji.com/dunyanin-en-buyuk-gunes-enerji-santrali-guvenligi-saglaniyor>)

4.1 Model Seçimi

Yapılan çalışmada zaman serisi tahmin algoritmaları ve coğrafi bilgi verileri kullanarak coğrafi konumu ve geçmiş üretim verileri bilinen güneş enerji santrallerinin gelecek 10 gündeki tahmini üretim verileri saatlik ve günlük olarak hesaplanmıştır. Zaman serisi tahmin algoritmaları başta hava durumu ve navigasyon uygulamaları olmak üzere üretim, dağıtım ve izleme süreçlerinin yer aldığı birçok ürüne entegre edilmekte ve yoğun olarak kullanılmaktadır.

Çalışmada farklı kütüphanelerdeki zaman serisi tahmin modelleri denenerek sonuç olarak Meta'nın geliştirdiği açık kaynaklı Facebook Prophet tahminleme yazılımı kullanılmıştır. ARIMA ve Exponential Smoothing modellerinin birden fazla parametrenin birbiriyle ilişkisini tespit etme noktasında Prophet'a göre daha az başarılı olduğu görülmüştür. Modelde kullanılan meteorolojik coğrafi bilgi verileri, düzensiz veri olarak tanımlanmaktadır ve zaman içerisinde sürekli değişebilmektedirler. Prophet, özellikle belirli bir düzene ve kalıba sahip olmayan verileri eğitmek için tasarlandığından günlük veya aylık veriler gibi güçlü mevsimsel kalıplara sahip zaman serisi verilerini tahmin etmek için daha uygun bir araç olarak öne çıkmaktadır.

Facebook Prophet'in bazı temel özellikleri şunlardır: [28]

- Otomatik mevsimsellik algılama: Güçlü mevsimsel kalıplara sahip verileri tahmin etmek için iyi bir seçim yapar.
- Anormallik algılama: Verileri etkileyebilecek beklenmedik olayları belirlemek için yardımcı olabilir.
- Kararsızlık tahmini: Tahminlerinin belirsizliğini tespit edebildiği için tahminlerin güvenilirliği daha belirgin şekilde yorumlanabilir.

Prophet açık kaynak kodlu tahminleme uygulamasını Python yazılım dili üzerinde kullanabilmek için aşağıdaki adımların izlenmesi gerekmektedir;

- a. pip install fbprophet komutunu kullanarak Prophet paketini yüklenir
- b. from fbprophet import Prophet satırını kullanarak Prophet modülü içe aktarılır
- c. Veriler bir Pandas DataFrame'ine yüklenir
- d. Prophet() sınıfından bir model oluşturulur
- e. model.fit(data) yöntemini kullanarak model verilere uygun hale getirilir

- f. `model.make_future_dataframe(periods)` yöntemini kullanarak gelecekteki tahminler için bir veri çerçevesi oluşturulur
- g. `model.predict(future_data)` yöntemini kullanarak gelecekteki tahminler yapılır.

4.2 Veri Toplama

Zaman serisi tahmin modelinde Konya'nın Karapınar ilçesinde bulunan Afta GES tesisinin 10.11.2022 ile 10.11.2023 tarihleri arasındaki 1 yıllık saatlik bazdaki gerçekleşen üretim verileri kullanılmıştır. Bu da üretim verileri girdisi olarak toplam 8760 (24 x 365) veri etmektedir.

Üretime etki eden coğrafi bilgi verileri olarak ise, üretime etkisi en yüksek ağırlıkta olan santralin bulunduğu Karapınar ilçesindeki 10.11.2022 ile 10.11.2023 tarihleri arasındaki gerçekleşen sıcaklık, güneşlenme süresi, yağış miktarı ve güneş ışınlarının geliş açısı gerçekleşen günlük ortalama değerler üzerinden eklenmiştir. Güneş enerjisi üretim tahmininin yapılacağı günler için de o günlere ait coğrafi bilgi verilerine ait tahmin değerleri hesaba katılarak nihai enerji tahmin değerleri elde edilmiştir.

4.3 Tahmin Çıktısı

Makine öğrenmesi modeli oluşturulurken, Afta GES'in 10.11.2022 ile 10.11.2023 tarihleri arasındaki 1 yıllık saatlik bazdaki gerçekleşen üretim verileri ve santralin bulunduğu Karapınar ilçesindeki 10.11.2022 ile 10.11.2023 tarihleri arasındaki gerçekleşen sıcaklık, güneşlenme süresi, yağış miktarı ve güneş ışınlarının geliş açısı verilerinin kronolojik olarak %80'ine tekabül eden kısmı kullanılmıştır. Bu %80'lik kısım, modelin trend ve düzensizlik gibi kalıpları öğrenmesine yardımcı olmaktadır. Kalan %20'lik kısım ise modelin performansını değerlendirmek için kullanılmıştır. Girdi verilerinin %80'i ile %20'si oranı, verilerin özelliklerine ve çıktı olarak elde edilecek tahmin değerlerinin doğruluk oranlarına göre değiştirilebilir. Daha karmaşık modellerde daha fazla eğitim verisi gerekebilir. Ancak çalışmadaki senaryo için en yüksek doğruluk oranı %80 ile %20 lik oranda yakalanmıştır. Zaman serisi tahmin uygulamalarında ideal oranlar, kullanıcı tarafından deneme yanılma yöntemleriyle belirlenmektedir.

Veriler modele aktarılırken, ilk olarak Pandas üzerindeki üretim verileri için veri ön işleme adımı uygulanmıştır. Veri işleme esnasında verilerdeki tarih, saat, enerji gibi

metrikler Prophet kütüphanesi için uygun hale getirilmiştir. Sonrasında hazırlanan verilerin Prophet modeline beslemesi gerçekleştirilmiştir.

Modelin eğitim aşamasında öncelikle büyüme eğrisi (zaman içinde verinin nasıl değiştiğini gösteren eğri) lojistik fonksiyon ile hesaplanmıştır. Sonrasında sezonsallık hesaba katılarak (bunun için katkısız veya çarpımsal faktörler seçilebiliyor), modele kronolojik üretim verisi girilmiştir. Coğrafi bilgi verilerinin ekleneceği durumda, bu veriler regresör (modelde bağımsız değişkenleri temsil eden değişken) olarak modele tanımlanmıştır.

4.3.1 Santral üretim verileriyle tahmin

Modelin daha doğru tahminler yapabilmesi için verilerin aşama aşama eklenerek modelin çalıştırılması gerekmektedir. Bu sayede model yeni eklenen verilerin üretime etkisini daha iyi ilişkilendirebilmektedir. Bu nedenle ilk olarak sadece santral üretim verileri eklenerek model çalıştırılmıştır. (Şekil 4.2)

```

import pandas as pd

# read data
df_production = pd.read_csv("/content/uretim.csv")
df_production["TarihSaat"] = df_production["Tarih"].astype(str) + " " + df_production["Saat"].astype(str)
df_production["TarihSaat"] = pd.to_datetime(df_production["TarihSaat"], format='%d.%m.%Y %H:%M')
df_production.tail(10)


```

	Tarih	Saat	Toplam(MWh)	TarihSaat
8774	18.11.2023	14:00	2.15	2023-11-18 14:00:00
8775	18.11.2023	15:00	0.21	2023-11-18 15:00:00
8776	18.11.2023	16:00	0.00	2023-11-18 16:00:00
8777	18.11.2023	17:00	0.00	2023-11-18 17:00:00
8778	18.11.2023	18:00	0.00	2023-11-18 18:00:00
8779	18.11.2023	19:00	0.00	2023-11-18 19:00:00
8780	18.11.2023	20:00	0.00	2023-11-18 20:00:00
8781	18.11.2023	21:00	0.00	2023-11-18 21:00:00
8782	18.11.2023	22:00	0.00	2023-11-18 22:00:00
8783	18.11.2023	23:00	0.00	2023-11-18 23:00:00

```

df = pd.DataFrame()
df["ds"] = df_production["TarihSaat"]
df["y"] = df_production["Toplam(MWh)"]
df['floor'] = 0
df.head()


```

	ds	y	floor
0	2022-11-18 00:00:00	0.0	0
1	2022-11-18 01:00:00	0.0	0
2	2022-11-18 02:00:00	0.0	0
3	2022-11-18 03:00:00	0.0	0
4	2022-11-18 04:00:00	0.0	0

```

from prophet import Prophet
m = Prophet()
m.fit(df[:-240])
future = m.make_future_dataframe(periods=240, freq='H')
future['floor'] = 0.1
fcst = m.predict(future)
fcst.loc[fcst["yhat"] < 0, "yhat"] = 0


INFO:prophet:Disabling yearly seasonality. Run prophet with
yearly_seasonality=True to override this.
DEBUG:cmdstanpy:input tempfile: /tmp/tmp6ud03ml/xo82ipf7.json
DEBUG:cmdstanpy:input tempfile: /tmp/tmp6ud03ml/zn0z98as.json
DEBUG:cmdstanpy:idx 0
DEBUG:cmdstanpy:running CmdStan, num threads: None
DEBUG:cmdstanpy:CmdStan args: ['/usr/local/lib/python3.10/dist-
packages/prophet/stan_model/prophet_model.bin', 'random',

```

Şekil 4.2 : Santral üretim verilerinin modele eklenmesi.

Future flow parametresi 0.1 seçilerek, modelin eksi (-) değerli tahmin yapması engellenmiştir. (Şekil 4.2)

Sadece gerçekleşen enerji üretim değerleriyle elde edilen grafik (Şekil 4.3) incelendiğinde 14.11.2023 tarihli çıktısındaki gerçekleşen enerji üretim değeri ile tahmin değeri arasında ciddi anlamda sapma olduğu tespit edilmiştir.



Şekil 4.3 : Sadece santral üretim verileriyle yapılan üretim tahmini.

4.3.2 CBS verilerinin modele eklenmesi

Modelin daha doğru tahminler yapabilmesi için atmosferik verilerin aşama aşama eklenerek modelin çalıştırılması gerekmektedir. Coğrafi bilgi verilerinin modele tek tek eklenmesinin nedeni modelin her seferinden tekrardan eğitilerek hata oranının daha düşük çıkmasının hedeflenmesidir.

Modelin tahmin başarısını arttırmak için sıcaklık değerleri de eklenerek veri ön işleme ve model eğitimi adımı sıcaklık verileri için de gerçekleştirilmiştir. (Şekil 4.4)

```
df_sicaklik = pd.read_excel("/content/sicaklik.xlsx")
df_sicaklik
```

	Aylar (santigrat)	ortalama sıcaklık (santigrat)	en yüksek sıcaklık
0	Ocak	0.0	
4.6			
1	Şubat	1.3	
6.9			
2	Mart	6.0	
12.5			
3	Nisan	10.9	
17.6			
4	Mayıs	15.9	
22.8			
5	Haziran	20.5	
27.4			
6	Temmuz	24.1	
31.0			
7	Ağustos	24.0	
30.9			
8	Eylül	19.4	
26.7			
9	Ekim	13.4	

Şekil 4.4 : Sıcaklık verilerinin modele eklenmesi.

Sıcaklık verilerinin eklenmesinin ardından diğer coğrafi bilgi verileri de modele eklenerek model bir kez daha çalıştırılmıştır. (Şekil 4.5)

```

# read data
df_production = pd.read_csv("/content/uretim.csv")
df_production["TarihSaat"] = df_production["Tarih"].astype(str) + " " + df_production["Saat"].astype(str)
df_production["TarihSaat"] = pd.to_datetime(df_production["TarihSaat"], format='%d.%m.%Y %H:%M')

df = pd.DataFrame()
df["ds"] = df_production["TarihSaat"]
df["y"] = df_production["Toplam(MWh)"]
df['floor'] = 0
df.head()

df_sicaklik = pd.read_excel("/content/sicaklik.xlsx")

def monthly_data(ds):
    date = pd.to_datetime(ds)
    return df_sicaklik.loc[date.month-1, "ortalama sıcaklık (santigrat)"]

def monthly_data_sun(ds):
    date = pd.to_datetime(ds)
    return df_sicaklik.loc[date.month-1, "ortalama güneşlenme süresi (saat)"]

#df['temperature'] = df['ds'].apply(monthly_data)
df['sunshine'] = df['ds'].apply(monthly_data_sun)

m = Prophet()
#m.add_regressor('temperature')
m.add_regressor('sunshine')
m.fit(df[:-120])
future = m.make_future_dataframe(periods=120, freq='H')

future['temperature'] = future['ds'].apply(monthly_data)
future['sunshine'] = future['ds'].apply(monthly_data_sun)
future['floor'] = 0.1
fcst = m.predict(future)
fcst.loc[fcst["yhat"] < 0, "yhat"] = 0

INFO:prophet:Disabling yearly seasonality. Run prophet with
yearly_seasonality=True to override this.
DEBUG:cmdstanpy:input tempfile: /tmp/tmp3fggl7y2/kez4v6b5.json
DEBUG:cmdstanpy:input tempfile: /tmp/tmp3fggl7y2/ht22uqec.json
DEBUG:cmdstanpy:idx 0
DEBUG:cmdstanpy:running CmdStan, num_threads: None
DEBUG:cmdstanpy:CmdStan args: ['/usr/local/lib/python3.10/dist-
packages/prophet/stan_model/prophet_model.bin', 'random',
'seed=96411', 'data', 'file=/tmp/tmp3fggl7y2/kez4v6b5.json',
'init=/tmp/tmp3fggl7y2/ht22uqec.json', 'output',
'file=/tmp/tmp3fggl7y2/prophet_modelb76pc8f6/prophet_model-
20231125082620.csv', 'method=optimize', 'algorithm=lbfgs',
'iter=10000']
08:26:20 - cmdstanpy - INFO - Chain [1] start processing
INFO:cmdstanpy:Chain [1] start processing
08:26:22 - cmdstanpy - INFO - Chain [1] done processing
INFO:cmdstanpy:Chain [1] done processing

```


Şekil 4.5 : Coğrafi bilgi verilerinin modele eklenmesi.

Bütün girdi parametreleri modelin çalıştıracağı şekilde düzenlenip, model eğitimi tamamlandıktan sonra modelin bütün girdi parametrelerini dikkate alarak tahmin çıktısı oluşturması sağlanmıştır. Yalnızca santral üretim verileri kullanılarak yapılan tahminde; 14.11.2023 tarihinde gerçekleşen enerji üretim değeri ile tahmin değeri arasındaki farkın diğer tarihlere göre çok daha fazla olması sebebiyle, (Şekil 4.3)

coğrafi bilgi verilerinin modele dahililiyetinin tahmin çıktısına etkisi 14.11.2023 tarihi üzerinden değerlendirilmiştir. (Şekil 4.6)


Zaman serisi tahmin modellerinde, tahmin değerleriyle gerçekleşen değerler arasındaki farkın çok fazla olduğu günler, modelin performansını değerlendirmede ve iyileştirmede referans alınarak, modelin geliştirilmesi için sağlanacak ek bilgilerin bu tarz sapmanın fazla olduğu günler üzerinden incelenmesi sıklıkla kullanılan bir yöntemdir.

Coğrafi bilgi verileri modele eklendikten sonra (Şekil 4.5) tahmin değerleri ile gerçekleşen değerler arasındaki sapmanın en fazla olduğu 14.11.2023 tarihine ait gerçekleşen üretim, sadece üretim değerleri üzerinden yapılan tahmin ve bütün girdi verileri (üretim ve CBS verileri) kullanılarak yapılan tahmin değerleri saatlik bazda oluşturulmuştur. (Şekil 4.6)



Şekil 4.6 : Modelden elde edilen tahmin verilerinin grafik gösterimi.

Grafikte, santralde gerçekleşen üretim değeri yeşil renkte, sadece gerçek üretim değerleri kullanılarak yapılan tahmin neticesinde oluşan üretim değeri kırmızı renkte ve hem üretim verileri hem de coğrafi bilgi verileri kullanılarak yapılan tahmin değeri mavi renkte gösterilmiştir. Üretim değerleri MWh cinsindendir. (Şekil 4.6 ve Şekil 4.7)




Şekil 4.7 : Gerçekleşen santral üretimi ve GIS datalarıyla yapılan üretim tahmini.

Yapılan 10 günlük üretim tahmininde, hem üretim hem de GIS verilerinin modele birlikte dahil edilmesiyle birlikte gerçekleştirilen ve sadece üretim verileriyle gerçekleştiren tahmin çıktılarıyla birlikte santralde gerçekleşen üretim değerleri (Şekil 4.7) incelendiğinde, GIS datalarının modele eklenmesinin gerçekleşen üretim değerlerine daha yakın tahminler yapılmasını sağlamıştır.

Elde edilen grafikteki günlük veriler toplam değer üzerinden yeni bir grafiğe taşınarak (Şekil 4.8) modele GIS datalarının eklenmesinin tahmin değerleri üzerindeki etkisi incelenmiştir. 10 günlük tahmin ve gerçekleşen değerler incelendiğinde, toplam gerçekleşen üretim 468,4 MWh, üretim ve GIS datalarıyla yapılan tahminin toplam üretimi 345,1 MWh, yalnızca üretim verileriyle gerçekleştirelen zaman serisi tahminindeki toplam üretim 313,4 MWh olarak hesaplanmıştır.

Modelin yaptığı ilk analiz neticesinde sadece üretim verileriyle yapılan 10 günlük toplam tahmin %49,4, GIS datalarının eklenmesiyle yapılan 10 günlük tahmin ise gerçekleşen değere göre %35,7 bir farkla tahminde bulunmuştur. GIS datalarının eklenmesi modelin ilk çalışmasında yaklaşık %14'lük bir iyileştirme sağlamıştır. Modelin dinamik olarak çalışması yeni verilerle daha başarılı tahminler yapması ve sapma oranlarının daha çok düşmesi beklenmektedir.




Şekil 4.8 : Gerçekleşen santral üretimi ve GIS datalarıyla yapılan günlük toplam üretim tahmini.

4.4 Fizibilite

Çalışma, coğrafi bilgi teknolojilerini kullanarak güneş enerjisi üretim veri tabanı ve geleceğe yönelik zaman serisi analizleriyle tahmin yapılmasını sağlayan bir yazılım modülünün geliştirilmesine yönelik analiz, tasarım ve test aşamalarını içermektedir. Çalışmada önerilen modülün sürekliliği ve birden fazla santral için kullanılabilmesi için gereken yazılım, donanım ve operasyonel maliyetler fizibilite çalışması altında incelenmiştir. Geliştirilebilecek yazılım modelinde girdi verileri resmi kurumlardan elde edilecek coğrafi bilgi dataları ile yine güneş santrallerinin Scada sistemlerinde yer alan skaler verilerdir. Bu veriler geliştirilecek bulut tabanlı bir coğrafi bilgi sisteminde toplanıp matematiksel hesaplamalar gerçekleştirildikten sonra yetkili son kullanıcılara bir web arayüzü üzerinden sunulabilecektir.

Güneş enerjisi üretim tahmini yapılacak santrale ait, üretime etki eden yüksek ağırlıktaki coğrafi katman verileri anlamlı hale getirelerek bir coğrafi veritabanı oluşturulur. Geliştirilecek makine öğrenmesi temelli tahmin modelinde dinamik olarak beklenen sıcaklık, güneş radyasyonu, bulutluluk, yağış ve ışınların geliş açısı ile zaman serisi tahmin modeli birleştirilerek bir üretim tahmin çıktısı elde edilecektir. Üretim


tahmininde santralin kapasite durumu da dikkate alınacaktır. Bütün bileşenler neticesinde modelin mantıksal topolojisi Şekil 4.9’da gösterilmiştir.



Şekil 4.9 : Modelin mantıksal topolojisi.

Modelin dinamik bir şekilde enerji sektöründe kullanılabilmesi ve farklı santraller için de uygulanabilmesi için oluşturulacak ilişkisel coğrafi veritabanında, santrallere ait geçmiş dönem üretim verileri, geçmiş dönem meteorolojik verileri ve meteorolojik tahmin verilerinin yer alması gerekmektedir. Temelde bu üç tablo kullanılarak, zaman serisi analizi neticesinde makine öğrenmesi algoritmaları ile tahmini üretim değeri hesaplanmalıdır. Güneş takip sistemi kullanan santraller için, güneş takip sistemini kullandıkları dönemlere ait üretim verileri modele girdi olarak eklenmelidir.

Santral ve meteorolojik verilerinin eklendiği modelde yapılan veri analizi ve tahminler neticesinde ortaya çıkan tahmin verileri bir web arayüzü üzerinden son kullanıcılara gösterilecek şekilde oluşturulacak üst seviye topolojisi yazılım geliştirme süreçlerinde referans olarak alınabilecektir. (Şekil 4.10)



Şekil 4.10 : Modelin üst seviye mimarisi.

4.4.1 Donanım maliyetleri

Oluşturulacak bulut tabanlı uygulamada verilerin ve logların tutulması için birer veri tabanı sunucusunun yanı sıra uygulama backend ve frontend kodlarının çalıştırılacağı alanlara ihtiyaç bulunacaktır. Bulut ortamdaki bu alanlar için tahmini ram, cpu ve disk boyutlarına göre 5 yıllık bir maliyet fizibilitesi oluşturulmuştur. (Şekil 2.2)

Çizelge 2.2 : Donanım ve lisans maliyetleri.

Kaynak Adı	Büyükölük	Adet	Tutar (\$)
CPU (Core)	8	1	3.718,53
Memory	16GB	1	650,74
IP	IPv4	1	500,00
CEPH	200GB	1	264,40
ELK Cost	100GB	1	423,57
Backup	200GB	1	246,09
TOPLAM			10.305,18

4.4.2 Yazılım geliştirme maliyetleri

Yazılım geliştirme ve operasyonel maliyetler için uygulama geliştirme aşamasında kullanılacak yazılım dili, sunucu işletim sistemi ve veritabanı türüne göre ilgili uzman insan kaynaklarının sağlanması gerekmektedir. Ayrıca uygulama geliştirildikten sonra

operasyonel aktiviteler ve sistemin sürekliliğinin sağlanması için kalıcı insan kaynağı ihtiyacı bulunmaktadır.

Aşağıdaki tablodaki hesaplar tahmini olarak personel sayısından bağımsız, benzer ortalama bir işin efor gereksinimleri değerlendirilerek çıkartılmıştır. (Çizelge 2.3)

Çizelge 2.3 : Yazılım geliştirme maliyetleri.

Kaynak Adı	Adam/Gün	Birim Maliyet (\$)	Tutar (\$)
Frontend (Ön Yüz)	20	150	3.000,00
Backend (Arka Yüz)	40	200	8.000,00
Mongo Veri Tabanı	20	200	4.000,00
Postgre Sql Veri Tabanı	40	200	8.000,00
Test	20	150	3.000,00
Devreye Alım	10	150	1.500,00
TOPLAM			27.500,00

Yıllık operasyonel maliyetler ve iyileştirmeler için gereken efor ve maliyet gereksinimleri; (Çizelge 2.4)

Çizelge 2.4 : Operasyonel maliyetler.

Kaynak Adı	Adam/Gün	Birim Maliyet (\$)	Tutar (\$)
Fullstack Developer	20	200	4.000,00
Operasyon Uzmanı	20	150	3.000,00
TOPLAM			7.000,00

5. SONUÇ VE ÖNERİLER

Güneş santrallerinden enerji üretiminin, gerçekleşecek üretim değerlerine yakın bir şekilde tahminlenememesi, günümüzde yaşanan önemli bir sorundur. Fosil enerji kaynaklarının hava kirliliği, küresel ısınma ve iklim değişikliği gibi çevreye olumsuz etkileri de düşünüldüğünde, çevre dostu yenilebilir enerji kaynaklarından maksimum seviyede yararlanabilmek ve kalan talebi fosil kaynaklardan karşılamak, tüm dünyanın hedefinde olan bir süreçtir. Güneş enerji santrallerinden üretilecek elektrik enerjisinin yaklaşık olarak tahmin edilebilmesi, termik santral kullanım planlamaları üzerinde doğrudan etkili olduğu için hatalı üretim tahminlemeleri arz talep dengesizlikleri yaratabilmektedir.

Bu tez çalışmasında, güneş santrallerinde gerçekleşen geçmiş üretim değerleri ile santralin bulunduğu konumdaki coğrafi bilgi verilerinden sıcaklık, güneşlenme süresi, yağış miktarı ve güneş ışınlarının geliş açısı değerleri üzerinden bir yapay zeka destekli tahmin modeli geliştirilmiştir. Modelde kullanılan makine öğrenmesi ve zaman serisi algoritmaları ile gerçekleşen üretim değerlerine yakın tahmin çıktıları elde edilmiştir. Python programlama dili kullanılarak geliştirilen zaman serisi tahmin modelinde, tahminlemeler Facebook'un açık kaynak kodlu Prophet kütüphanesi kullanılarak yapılmıştır. Örnek vaka çalışmasında, yüksek üretim kapasitesine sahip olduğu için Türkiye'nin en büyük güneş enerji santrallerinden biri olan Konya ilinin Karapınar ilçesindeki Afta Güneş Enerji Santrali seçilmiştir. Modelin yüksek üretim kapasitesine sahip santrallerde uygulanması, daha büyük maddi kazanımlar sağlayacaktır.

Makine öğrenmesi tabanlı çalışan Prophet zaman serisi tahmin uygulaması sayesinde modele uygun şekilde derlenen binlerce girdi verisinin birbiriyle ilişkisi ve üretime etkisi saniyeler içerisinde model tarafından analiz edilerek modelin eğitilmesi sağlanmıştır. Model canlıya alındığında her yeni gün eklenecek yeni verilerle birlikte önündeki 10 günlük süreçteki enerji üretimini saatlik olarak tahmin edecek şekilde geliştirilmiştir.

Çalışmada geliştirilen zaman serisi tahmin modeline coğrafi bilgi verilerinin eklenmesiyle, güneş enerjisi üretim potansiyelinin sadece üretim verileri kullanılarak

tahminlenmesinden daha doğru bir şekilde tahmin edilmesi sağlanmıştır. Bu modelin gerçek hayatta kullanılması hem mevcut, hem de yeni güneş enerjisi santralleri için daha hassas değerlendirmeler yapılmasına ve yatırımların geri dönüşünün artmasına olanak tanıyacaktır.

Çalışmanın fizibilite bölümünde böyle bir tahmin modelinin sürekli ve dinamik olarak kullanılabilmesi için gereken ilk yatırım ve verilerin son kullanıcılarla düzenli olarak paylaşılabilmesi için gerekli operasyonel efor ve maliyetler, global ölçekli bulut servis sağlayıcısı ve geliştirici firmaların fiyatlandırmaları üzerinden tahmini olarak hesaplanmıştır. Çalışmada geliştirilen prototip yazılımın, birden fazla santral için kullanılabilen ve sürekli çalışan bir uygulama haline getirilmesi için fizibilite kısmında belirtilen kapasitelere yakın boyutlardaki sunucularda konumlandırılması önerilmektedir. Ayrıca veri gizliliği ve güvenliğinin sağlanması amacıyla gerekli yazılım lisanslarının temin edilmesi de önemlidir.

Modelin enerji sektöründe kullanılması, güneş enerjisi üretiminin planlanması ve arazi tahsisi için de önemli bir katkı sağlayacaktır. Ayrıca, termik kaynaklardan üretilen enerjinin daha verimli bir şekilde kullanılmasını sağlayarak, fosil yakıt kullanımının azaltılmasına ve çevre kirliliğinin önlenmesine yardımcı olacaktır. Modelin, farklı ülkeler ve iklim koşulları için uyarlanması da gelecekteki araştırmalar için önemli bir konudur. Bu uyarlamalar, modelin daha geniş bir yelpazede kullanılmasına olanak tanıyacaktır. Güneş enerjisi üretiminin tahmin edilebilmesi için oluşturulacak coğrafi bilgi sistemi bulut tabanlı bir yazılım altyapısına sahip olacağı için gerekli konfigürasyonlar yapıldıktan sonra birçok ülkede kullanılabilen bir uygulama haline gelebilecektir.

KAYNAKLAR

- [1] **Masters, G. M.** (2004). Renewable and efficient electric power systems. John Wiley & Sons.
- [2] **Lozano, J. M. S., Solano, J. T., Elvira, P. L. S., & Cascales, M. S. G.** (2013). Geographical information systems (GIS) and Multi-criteria decision making (MCDM) methods for the evaluation of solar farms locations: Case study in south-eastern Spain. *Renewable and Sustainable Energy Reviews*, 24, 544-556.
- [3] **Xu, J. P., Song, X. L., Wu, Y. M., & Zeng, Z. Q.** (2015). GIS-modelling based coal-fired power plant site identification and selection. *Applied Energy*, 159, 520-539.
- [4] **YILMAZ, M.** (2012). Türkiye'nin enerji potansiyeli ve yenilenebilir enerji kaynaklarının elektrik enerjisi üretimi açısından önemi. *Ankara Üniversitesi Çevre Bilimleri Dergisi*, 4(2), 33-54.
- [5] **Gürbüz, S., & ERDOĞAN, S.** (2012). Türkiye'de Enerji Tüketimi ve Ekonomik Büyüme İlişkisi: Ampirik Bir Uygulama (Doctoral dissertation, Yüksek Lisans Tezi, Konya).
- [6] **General directorate of renewable energy.** (2016, January 22). Solar Potential Atlas. Retrieved from <http://www.eie.gov.tr/MyCalculator/pages/42.aspx>
- [7] **KAYNAR, N. K.** (2020). Yenilenebilir enerji kaynaklarından güneş enerjisinin Amasya ilindeki potansiyeli. *Bilge International Journal of Science and Technology Research*, 4(2), 48-54.
- [8] **31479 Elektrik Piyasası Bağlantı Ve Sistem Kullanım Yönetmeliğinde Değişiklik Yapılmasına Dair Yönetmelik.** (2021). T. C. Resmi Gazete, 3945, 9 Mayıs 2021.
- [9] **Fraunhofer ISE.** (2016). Photovoltaic Report.
- [10] **Küsbeci, B.** (2011). Türkiye ekonomisinin enerji bağımlılığı (Master's thesis, Adnan Menderes Üniversitesi, Sosyal Bilimler Enstitüsü).
- [11] **ULUSOY, C. K.** (2019). Yenilenebilir enerji kaynaklarının kullanımındaki gelişmeler; güneş enerji sistemleri ve finansman modelleri. *Assam Uluslararası Hakemli Dergi*, 6(13), 65-84.
- [12] **KILIÇ, F. Ç.** (2015). Güneş enerjisi, Türkiye'deki son durumu ve üretim teknolojileri. *Mühendis ve Makina*, 56(671), 28-40.
- [13] **Watson, J. J. W., & Hudson, M. D.** (2015). Regional scale wind farm and solar farm suitability assessment using GIS-assisted multi-criteria evaluation. *Landscape and Urban Planning*, 138, 20-31.

- [14] **Boz, O. H. (2011).** Günümüzün alternatif enerji kaynağı: Fotovoltaik güneş pilleri (Master's thesis, Balıkesir Üniversitesi Fen Bilimleri Enstitüsü).
- [15] **CEYLAN, İ., AKTAŞ, M., & DOĞAN, H. (2006).** Sıcak su hazırlamak için kullanılan güneş enerjili sistemlerde sıvı ve hava akışkanlarının performans üzerindeki etkileri. *Politeknik Dergisi*, 9(3), 181-184.
- [16] **Cheng-Wei, C., Chien-Yao, L., Kun-Hung, C., & Yaow-Ming, C. (2015).** Modeling and controller design of a semiisolated multiinput converter for a hybrid PV/Wind power charger system. *IEEE Transactions on Power Electronics*, 30(9), 4843-4853.
- [17] **Yılmaz, M. (2013).** Güneş takip sistemi ile güneş enerjisinden elektrik enerjisi elde etme yöntemleri ve optimum verimin belirlenmesi (Doctoral dissertation, Marmara Üniversitesi (Turkey)).
- [18] **Tian, Y., & Zhao, C. Y. (2013).** A review of solar collectors and thermal energy storage in solar thermal applications. *Applied energy*, 104, 538-553.
- [19] **Inamdar, S. S., & Vaidya, A. P. (2015).** Performance analysis of solar photovoltaic module for multiple varying factors in MATLAB/Simulink. In *Smart Technologies and Management for Computing, Communication, Controls, Energy and Materials (ICSTM), 2015 International Conference on* (pp. 562-567). IEEE.
- [20] **Karafil, A., Özbay, H., & Kesler, M. (2016).** Sıcaklık ve Güneş Işınım Değişimlerinin Fotovoltaik Panel Gücü Üzerindeki Etkilerinin Simülasyon Analizi. *Elektrik-Elektronik ve Bilgisayar Sempozyumu*.
- [21] **KESKİN, V., KHALEJAN, SHPR, & ÇIKLA, R. (2021).** Samsun/Türkiye'de Şebekeye Bağlı bir FV Tesisinin Performansına Gölgeleme Etkisinin İncelenmesi. *Politeknik Dergisi*, 24 (2).
- [22] **SAVAŞ, S., DURAKLAR, K., ÇINAR, O. A., Mustafa, K. O. Ç., TURAN, A., Uğur, U. S. L. U., ... & DUŞBUDAK, H. (2022).** Güneş Enerjisi Sistemlerinde Yenilikçi ve Akıllı Bakım Onarım. *Journal of Information Systems and Management Research*, 4(2), 35-49.
- [23] **Janke, J. R. (2010).** Multicriteria GIS modeling of wind and solar farms in Colorado. *Renewable Energy*, 35(10), 2228-2234.
- [24] **Kavlak, M. Ö., & Çabuk, S. N.** CBS Destekli Yenilenebilir Enerji Çalışmaları: Enerji Bitkisi Yetiştirme Alanları Yer Seçimi.
- [24] **Minelli, A., Marchesini, I., Taylor, F. E., De Rosa, P., Casagrande, L., & Cenci, M. (2014).** An open source GIS tool to quantify the visual impact of wind turbines and photovoltaic panels. *Environmental Impact Assessment Review*, 49, 70-78.
- [25] **Url-2** < <https://www.esri.com/en-us/industries/petroleum/overview> >, erişim tarihi 01.11.2023
- [26] **Yegnanarayana, B. (2009).** Artificial neural networks. PHI Learning Pvt. Ltd.
- [27] **Url-3** < <https://www.miateknoloji.com/dunyanin-en-buyuk-gunes-enerji-santrali-guvenligi-saglaniyor> >, erişim tarihi 01.11.2023

- [28] **Toharudin, T., Pontoh, R. S., Caraka, R. E., Zahroh, S., Lee, Y., & Chen, R. C.** (2023). Employing long short-term memory and Facebook prophet model in air temperature forecasting. *Communications in Statistics-Simulation and Computation*, 52(2), 279-290.



ÖZGEÇMİŞ

Ad-Soyad : Eren Polatcan

ÖĞRENİM DURUMU:

- **Lisans** : 2017, Yıldız Teknik Üniversitesi, Elektrik, Elektronik Fakültesi, Elektrik Mühendisliği

MESLEKİ DENEYİM VE ÖDÜLLER:

- 2021 yılından günümüze ITU'da (International Telecommunication Union) delege olarak görev yapmaktadır.
- 2019 yılından günümüze Türk Telekom Teknoloji Genel Müdürlüğü'nde çalışmaktadır.

YÜKSEK LİSANS TEZİNDEN TÜRETİLEN YAYINLAR, SUNUMLAR VE PATENTLER:

- **Polatcan E., Özdem M.** 2023. Increasing Quality Of Service For Mobile And Electrical Networks And With Electricity Supply Measurements From Base Stations, 4. *Ispac International Congress On Contemporary Scientific Research*, Dec. 1, 2023 Baku, Azerbaijan. 668-669
- **Polatcan E., Özdem M.** 2023. Increasing Electricity Quality And Availability In Rural Areas With Large Scale Energy Storage Systems And Renewable Energy Deployment, 4. *Ispac International Congress On Contemporary Scientific Research*, Dec. 1, 2023 Baku, Azerbaijan. 666-667