

**JEOTERMAL ENERJİ SANTRALİNİN SİSTEM PARAMETRELERİNE GÖRE
PERFORMANS TAHMİNİ İÇİN REGRESYON ANALİZİ**

YÜKSEK LİSANS TEZİ

Fatih MERCAN

Danışman

Prof. Dr. Ahmet YILDIZ

YENİLENEBİLİR ENERJİ SİSTEMLERİ ANABİLİM DALI

Aralık 2024

AFYON KOCATEPE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

YÜKSEK LİSANS TEZİ

JEOTERMAL ENERJİ SANTRALİNİN SİSTEM
PARAMETRELERİNE GÖRE PERFORMANS TAHMİNİ İÇİN
REGRESYON ANALİZİ

Fatih MERCAN

Danışman

Prof. Dr. Ahmet YILDIZ

YENİLENEBİLİR ENERJİ SİSTEMLERİ ANABİLİM DALI

Aralık 2024

TEZ ONAY SAYFASI

Fatih MERCAN tarafından hazırlanan “JEOTERMAL ENERJİ SANTRALİNİN SİSTEM PARAMETRELERİNE GÖRE PERFORMANS TAHMİNİ İÇİN REGRESYON ANALİZİ” adlı tez çalışması lisansüstü eğitim ve öğretim yönetmeliğinin ilgili maddeleri uyarınca 19 / 11 / 2024 tarihinde aşağıdaki jüri tarafından **oy birliği / oy çokluğu** ile Afyon Kocatepe Üniversitesi Fen Bilimleri Enstitüsü Yenilenebilir Enerji Sistemleri **Anabilim Dalı’nda YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

Danışman : Prof. Dr. Ahmet YILDIZ

Başkan : Prof. Dr. Ahmet YILDIZ
Afyon Kocatepe Üniversitesi, Mühendislik Fakültesi

Üye : Dr. Öğr. Üyesi Taha SEZER
Afyon Kocatepe Üniversitesi, Teknoloji Fakültesi

Üye : Doç. Dr. Ceyhun YILMAZ
Sakarya Üniversitesi, Mühendislik Fakültesi

Üye : Dr. Öğr. Üyesi Fatih SERTTAŞ
Afyon Kocatepe Üniversitesi, Mühendislik Fakültesi

Üye : Doç. Dr. Nehir TOKGÖZ
Sakarya Üniversitesi, Mühendislik Fakültesi

Afyon Kocatepe Üniversitesi
Fen Bilimleri Enstitüsü Yönetim Kurulu’nun
..... /..... /..... tarih ve
..... sayılı kararıyla onaylanmıştır.

.....
Prof. Dr. Bekir YALÇIN
Enstitü Müdürü

BİLİMSEL ETİK BİLDİRİM SAYFASI
Afyon Kocatepe Üniversitesi

Fen Bilimleri Enstitüsü, tez yazım kurallarına uygun olarak hazırladığım bu tez çalışmada;

- Tez içindeki bütün bilgi ve belgeleri akademik kurallar çerçevesinde elde ettiğimi,
- Görsel, işitsel ve yazılı tüm bilgi ve sonuçları bilimsel ahlak kurallarına uygun olarak sunduğumu,
- Başkalarının eserlerinden yararlanılması durumunda ilgili eserlere bilimsel normlara uygun olarak atıfta bulunduğumu,
- Atıfta bulunduğum eserlerin tümünü kaynak olarak gösterdiğimi,
- Kullanılan verilerde herhangi bir tahrifat yapmadığımı,
- Ve bu tezin herhangi bir bölümünü bu üniversite veya başka bir üniversitede başka bir tez çalışması olarak sunmadığımı

beyan ederim.

11 / 12 / 2024

Fatih MERCAN

ÖZET

Yüksek Lisans Tezi

JEOTERMAL ENERJİ SANTRALİNİN SİSTEM PARAMETRELERİNE GÖRE PERFORMANS TAHMİNİ İÇİN REGRESYON ANALİZİ

Fatih MERCAN

Afyon Kocatepe Üniversitesi

Fen Bilimleri Enstitüsü

Yenilenebilir Enerji Sistemleri Anabilim Dalı

Danışman: Prof. Dr. Ahmet YILDIZ

Bu çalışmada, Batı Anadolu’da bulunan, üç flaşlı+ikili çevrimli bir jeotermal enerji santralinin ölçüm verileri kullanılarak net güç üretim tahmini yapan farklı regresyon analizi yöntemlerinin performansları karşılaştırılmıştır. Bu regresyon modellerinin amacı, jeotermal enerji santralinin performansını etkileyen parametrelerin santralin net elektrik üretim miktarına etkisini istatistiksel olarak tahmin etmektir.

Santralden jeotermal akışkan sıcaklığı, akışkan debisi, hava sıcaklığı ve net güç ortalama değerlerinden oluşan 1460 adet veri temin edilmiştir. Bu verilere önce Skewness-Kurtosis normallik testi yapılmış ve bazı veriler çıkarılarak normallik şartı sağlanmıştır. Daha sonra çoklu doğrusal, polinomal, karar ağaçları, rastgele orman ve gradyan artırma regresyon modelleri oluşturulmuştur. Bazı modellerde aşırı uyum tespit edildiğinden bu modellere 5 ve 10 katlı çapraz doğrulama yöntemi uygulanmıştır. Hata ölçüm parametreleri olan R^2 , MAE, MSE ve RMSE değerlerine göre en başarılı yöntem 10 katlı çapraz doğrulama ve en başarılı model ise gradyan artırma modeli olduğu görülmüştür.

2024, xi + 96 sayfa

Anahtar Kelimeler: Jeotermal Enerji, Elektrik Santrali, Regresyon Analizi, Performans, Python.

ABSTRACT

M.Sc. Thesis

REGRESSION ANALYSIS FOR PERFORMANCE PREDICTION OF GEOTHERMAL POWER PLANT ACCORDING TO SYSTEM PARAMETERS

Fatih MERCAN

Afyon Kocatepe University

Graduate School of Natural and Applied Sciences

Department of Renewable Energy Systems

Supervisor: Prof. Ahmet YILDIZ

In this study, the performances of different regression analysis methods for predicting the net power generation using the measured data of a three-flash+binary cycle geothermal power plant located in Western Anatolia are compared. The aim of these regression models is to statistically estimate the effect of the parameters affecting the performance of the geothermal power plant on the net electricity generation of the power plant.

A total of 1460 data consisting of geothermal fluid temperature, fluid flow rate, air temperature and net power average values were obtained from the power plant. First, Skewness-Kurtosis normality test was performed on these data and normality condition was met by removing some data. Then, multiple linear, polynomial, decision tree, random forest and gradient boosting regression models were created. Since overfitting was detected in some models, 5 and 10 fold cross validation methods were applied to these models. According to the error measurement parameters R², MAE, MSE and RMSE values, the most successful method was 10 fold cross validation and the most successful model was the gradient boosting model.

2024, xi + 96 pages

Keywords: Geothermal Energy, Power Plant, Regression Analysis, Performance, Python.

TEŞEKKÜR

Tez çalışma konusunun belirlenmesi, deneysel çalışmaların yönlendirilmesi, sonuçların değerlendirilmesi ve yazımı aşamasında yapmış olduğu büyük katkılarından dolayı tez danışmanım Sayın Prof. Dr. Ahmet YILDIZ'a teşekkür ederim. Ayrıca tezimin araştırma ve yazım süresince yardımlarını esirgemeyen Sayın Doç Dr. Ceyhun YILMAZ'a, tez jürimde yer alarak çalışmama katkı koyan Dr.Öğr. Üyesi Taha SEZER'e, konuyu belirleme ve verileri işleme süreçlerindeki katkılarından dolayı mesai arkadaşım İlker Erdem KAYAOĞLU'na, veri sağlama konusundaki yardımlarından dolayı meslektaşım Mehmet KURUOĞLU'na ve santral müdürü Sayın Murat GÜLER'e teşekkür ederim.

Ayrıca tez yazım sürecinde maddi ve manevi desteklerini esirgemeyen sevgili eşim Emine Ece MERCAN'a ve oğlum Evren MERCAN'a şükranlarımı sunarım.

Fatih MERCAN
Afyonkarahisar 2024

İÇİNDEKİLER DİZİNİ

	Sayfa
ÖZET	i
ABSTRACT	ii
TEŞEKKÜR	iii
İÇİNDEKİLER DİZİNİ.....	iv
SİMGELER ve KISALTMALAR DİZİNİ	vi
ŞEKİLLER DİZİNİ	viii
ÇİZELGELER DİZİNİ.....	x
RESİMLER DİZİNİ	xi
1. GİRİŞ.....	1
2. LİTERATÜR BİLGİLERİ	2
2.1 Yenilenebilir Enerji.....	2
2.2 Jeotermal Enerji	9
2.2.1 Jeotermal Enerji Kullanım Alanları	11
2.2.1.1 Dünyada Jeotermal Enerjinin Doğrudan Kullanım Alanları	14
2.2.1.2 Türkiye’de Jeotermal Enerjinin Doğrudan Kullanım Alanları.....	18
2.2.2 Jeotermal Enerjiden Elektrik Üretimi	20
2.3 Jeotermal Elektrik Santrali (JES) Tipleri ve Ekipmanları	24
2.3.1 Kuru Buhar Jeotermal Elektrik Santrali	24
2.3.2 Flaş Buharlı Jeotermal Elektrik Santrali	26
2.3.2.1 Tek Flaşlı Jeotermal Elektrik Santrali	26
2.3.2.2 Çift Flaşlı Jeotermal Elektrik Santrali	28
2.3.2.3 Üç Flaşlı Jeotermal Elektrik Santrali	29
2.3.3 İkili Çevrimli (Binary) Jeotermal Elektrik Santrali	29
2.3.3.1 Organik Rankine Çevrimli (ORC) Jeotermal Elektrik Santrali.....	30
2.3.3.2 Kalina Çevrimli Jeotermal Elektrik Santrali	32
2.3.4 Kombine Flaşlı-İkili Jeotermal Elektrik Santrali	33
2.4 Regresyon Analizi.....	35
2.4.1 Çoklu Lineer Regresyon (ÇDR).....	35
2.4.2 Polinomal Regresyon (PR).....	36
2.4.3 Karar Ağaçları Regresyonu (KAR).....	37

2.4.4 Rastgele Orman Regresyonu (ROR)	38
2.4.5 Gradyan Artırma Regresyonu (GAR)	39
2.5 K-Katlı Çapraz Doğrulama	40
2.6 Hata Ölçüm Parametreleri	41
2.6.1 R-Kare (R^2)	41
2.6.2 Hataların Mutlak Değerinin Ortalaması (MAE)	41
2.6.3 Hataların Karesinin Ortalaması (MSE).....	42
2.6.4 Hataların Karesinin Ortalamasının Karekökü (RMSE)	42
2.7 Python Programlama Dili	42
2.8 Literatür Özeti.....	43
3. MATERYAL ve METOT	48
3.1 Jeotermal Elektrik Santralının Tanıtımı.....	48
3.2 Jeotermal Elektrik Santraline Ait Veri Setleri	51
3.3 Python Kodları ile Regresyon Analizi	53
3.3.1 Kütüphane ve Fonksiyonların Yüklenmesi.....	53
3.3.2 Verilerin Yüklenmesi ve İşlenmesi.....	53
3.3.3 Hiperparametre Optimizasyonu	54
3.3.4 Regresyon Modelleri Oluşturarak Tahmin Yapılması	54
3.3.5 Gerçek ve Tahmini Değerlerin Regresyon Grafiğinde Gösterilmesi.....	54
3.3.6 Hata Ölçüm Parametrelerinin Hesaplanması	55
3.3.7 K-Katlı Çapraz Doğrulama Yapılması.....	55
4. BULGULAR	56
4.1 Regresyon Modellerinin Net Güç Tahmin Performansları.....	56
4.1.1 Çoklu Doğrusal Regresyon	56
4.1.2 Polinomal Regresyon	57
4.1.3 Karar Ağaçları Regresyonu.....	58
4.1.4 Rastgele Orman Regresyonu.....	59
4.1.5 Gradyan Artırma Regresyonu	61
4.2 Modellerinin Hata Parametrelerine Göre Performanslarının Karşılaştırılması ...	62
5. TARTIŞMA ve SONUÇ	64
6. KAYNAKLAR.....	68
ÖZGEÇMİŞ.....	74

SİMGELER ve KISALTMALAR DİZİNİ

Simgeler

R134a	1,1,1,2-Tetrafloretan
R254fa	1,1,1,3,3-Pentafloropropan
kW	Kilowatt
MW	Megawatt
MWe	Megawatt elektrik
MWh	Megawatt saat
MWt	Megawatt termik
°C	Santigrat derece
TWh	Terawatt saat
TJ	Terajoule

Kısaltmalar

ABD	Amerika birleşik devletleri
CFC	Kloroflorokarbon
ÇDR	Çoklu doğrusal regresyon
DSA	Derin sinir ağı
DVM	Destek vektör makinesi
GAR	Gradyan artırma regresyonu
GDM	Genelleştirilmiş doğrusal model
GHF	Jeotermal ısı akışı
GHP	Jeotermal ısı pompası
HCFC	Hidrokloroflorokarbon
HFC	Hidroflorokarbon
HFO	Hidrofloroolefin
ID3	Karar ağaçlarında kullanılan bir algortima
JES	Jeotermal enerji santrali
KAR	Karar ağaçları regresyonu
KCS	Kalina çevrim sistemi
KEYK	K-en yakın komşular
LightGBM	Hafif gradyan artırma makinesi
MAE	Hataların mutlak değerlerinin ortalaması
MSE	Hataların karesinin ortalaması
MTA	Maden Tetkik Arama
ORC	Organik rankine çevrimi
PR	Polinomal regresyon
R	Korelasyon katsayısı
R ²	R-kare
RMSE	Hataların karesinin ortalamasının karekökü
ROR	Rastgele orman regresyonu
SARIMAX	Mevsimsel otoregresif entegre hareketli ortalama regresyon
SCADA	Gözetleyici kontrol ve veri toplama sistemi
TEİAŞ	Türkiye Elektrik İletim Anonim Şirketi
YEK	Yenilenebilir enerji kaynaklarının elektrik enerjisi üretimi amaçlı kullanımına ilişkin kanun

YEKA	Yenilenebilir enerji kaynak alanları
YEKDEM	Yenilenebilir enerji kaynaklarından elektrik üretimini destekleme mekanizması
YSA	Yapay sinir ağı
WGC	Dünya Jeotermal Kongresi
XGBoost	Aşırı gradyan artırma



ŞEKİLLER DİZİNİ

	Sayfa
Şekil 2.1 Yenilenebilir enerji türleri.....	2
Şekil 2.2 Dünyada 1985-2022 yılları arasında farklı enerji kaynaklarından elde edilen elektrik enerjisi üretim miktarları.....	4
Şekil 2.3 Farklı enerji kaynaklarından elde edilen elektrik üretiminin Dünya çapında sahip olduğu paylar	5
Şekil 2.4 Türkiye’de 2000-2022 yılları arasında enerji kaynaklarına göre kurulu gücün gelişimi.....	6
Şekil 2.5 Türkiye’nin 2014-2022 yıllarına ait enerji kaynaklarının kurulu güçlerinin paylarının karşılaştırılması	7
Şekil 2.6 Türkiye’de kurulu güçlerin Ekim 2023 itibariyle ait enerji kaynaklarına göre dağılımı	7
Şekil 2.7 Jeotermal sistem modeli.....	9
Şekil 2.8 Lindal Diyagramı’na göre jeotermal kaynakların sıcaklıklarına göre kullanım alanları	11
Şekil 2.9 GHP’nin ısıtma ve soğutma modunda kullanımı.....	13
Şekil 2.10 1995-2020 arası jeotermal doğrudan kullanım kurulu güç kapasitesi ve yıllık kullanım miktarı.....	15
Şekil 2.11 Türkiye’deki jeotermal kaynakların dağılımı ve uygulama haritası.....	18
Şekil 2.12 Dünyada jeotermal enerji kurulu gücü en çok olan ülkeler.....	21
Şekil 2.13 Türkiye’deki JES’lerin harita üzerinde gösterimi.....	23
Şekil 2.14 Kuru buhar JES’lerin basitleştirilmiş tasarımı.....	25
Şekil 2.15 Tek flaşlı JES’lerin basitleştirilmiş tasarımı.....	27
Şekil 2.16 Çift flaşlı JES’lerin basitleştirilmiş tasarımı.....	28
Şekil 2.17 Üç flaşlı JES’lerin basitleştirilmiş tasarımı.....	29
Şekil 2.18 İkili ORC JES’lerin basitleştirilmiş tasarımı.....	31
Şekil 2.19 Kalina çevrimli JES’lerin (KCS-34 versiyon) basitleştirilmiş tasarım.....	33
Şekil 2.20 Kombine çevrim dip konfigürasyonu basitleştirilmiş tasarımı.....	34
Şekil 2.21 Çift flaşlı-ikili kombine çevrimin basitleştirilmiş tasarımı.....	34
Şekil 2.22 Doğrusal regresyon grafiği.....	36
Şekil 2.23 Polinomal regresyon grafiği.....	36

Şekil 2.24 Karar ağacı yapısı.....	37
Şekil 2.25 GAR algoritmasının işleyiş süreci.....	39
Şekil 2.26 10 katlı çapraz doğrulama.....	40
Şekil 3.1 Batı Anadolu’da bulunan JES’ler ve Sarayköy jeotermal alanı.....	48
Şekil 3.2 Santral Ünite-1’e ait basitleştirilmiş akış şeması.....	49
Şekil 3.3 Santral Ünite-1’e ait SCADA ekran görüntüsü.....	49
Şekil 3.4 Santral türbin kesiti ve yüksek ve orta/düşük basınç türbin rotorları.....	50
Şekil 3.5 Bağımsız değişkenlerin bağımlı değişkenle ilişkisi.....	52
Şekil 4.1 ÇDR modelinin tahmini ve gerçek net güç verilerinin regresyon grafiğindeki dağılımı.....	56
Şekil 4.2 PR modelinin tahmini ve gerçek net güç verilerinin regresyon grafiğinde gösterimi.....	57
Şekil 4.3 KAR modelinin tahmini ve gerçek net güç verilerinin regresyon grafiğindeki dağılımı.....	58
Şekil 4.4 KAR modelinin 5 ve 10 katlı çapraz doğrulama regresyon grafiği.....	59
Şekil 4.5 ROR modelinin tahmini ve gerçek net güç verilerinin regresyon grafiğindeki dağılımı.....	60
Şekil 4.6 ROR modelinin 5 ve 10 katlı çapraz doğrulama regresyon grafiği.....	61
Şekil 4.7 GAR modelinin tahmini ve gerçek net güç verilerinin regresyon grafiğindeki dağılımı.....	61
Şekil 4.8 GAR modelinin 5 ve 10 katlı çapraz doğrulama regresyon grafiği.....	62

ÇİZELGELER DİZİNİ

Sayfa

Çizelge 2.1	1995-2020 arasında çeşitli kategorilere göre jeotermal enerjinin doğrudan kullanım miktarları (TJ/yıl) ve kurulu güç kapasiteleri (MWt)	15
Çizelge 2.2	Türkiye’de jeotermal enerjinin doğrudan kullanım kurulu güçleri.....	19
Çizelge 2.3	Türkiye’de bölgesel ısıtma uygulaması yapılan yerler.....	20
Çizelge 2.4	Türkiye’de bulunan JES’ler ve kurulu güçleri.....	22
Çizelge 2.5	Organik çalışma sıvılarının termofiziksel özellikleri.....	31
Çizelge 3.1	Türbinlerin giriş sıcaklıkları ve buhar debileri.....	50
Çizelge 3.2	Santral verilerinin istatistiksel özellikleri.....	51
Çizelge 3.3	Normallik testi sonuçları.....	52
Çizelge 3.4	Uyumsuz değerler çıkarıldıktan sonraki normallik testi sonuçları.....	52
Çizelge 4.1	ÇDR modelinin eğitim ve test setlerinin hata ölçüm parametreleri.....	57
Çizelge 4.2	PR modelinin eğitim ve test setlerinin hata ölçüm parametreleri.....	57
Çizelge 4.3	KAR modelinin eğitim ve test setlerinin hata ölçüm parametreleri.....	58
Çizelge 4.4	KAR modelinin 5 ve 10 katlı çapraz doğrulama ortalama hata ölçüm parametreleri.....	59
Çizelge 4.5	ROR modelinin eğitim ve test setlerinin hata ölçüm parametreleri.....	60
Çizelge 4.6	ROR modelinin 5 ve 10 katlı çapraz doğrulama ortalama hata ölçüm parametreleri.....	60
Çizelge 4.7	GAR modelinin eğitim ve test setlerinin hata ölçüm parametreleri.....	62
Çizelge 4.8	GAR modelinin 5 ve 10 katlı çapraz doğrulama ortalama hata ölçüm parametreleri.....	62
Çizelge 4.9	Bütün modellerin hata ölçüm parametreleri.....	63

RESİMLER DİZİNİ

Sayfa

Resim 3.1 Santralin genel görünümü	51
---	----



1. GİRİŞ

Jeotermal santrallerin elektrik üretim miktarı santral parametrelerine (jeotermal akışkan debisi, hava sıcaklığı vb.) bağlı belirli kurallara göre hesaplanabilir. Ancak, bu parametreler ölçülürken yapılabilecek hatalar veya göz ardı edilen diğer parametrelerden (NCG miktarı vb.) dolayı bu verilerin doğruluğuna kesin gözüyle bakılamamaktadır. Bu durumda santralin performansı hesabı, istatistiksel olarak ifade edilebileceğinden regresyon analizinin konusu olabilir. Regresyon analizi, bir veya birden fazla bağımsız değişkenin bir bağımlı değişken üzerindeki etkisini tahmin etmek için kullanılan makine öğrenme algoritmalarından birisidir (Karadaş vd. 2013).

Santralden Ekim 2022-Eylül 2023 arasındaki bir yıllık, günlük ortalama jeotermal akışkan sıcaklığı, akışkan debisi, hava sıcaklığı ve net güç değerlerini içeren toplam 1460 veri alınmış ve regresyon modellerinde kullanılmışlardır. Regresyon analizleri için çoklu doğrusal, polinomal, karar ağaçları, rastgele orman ve gradyan artırma modelleri, Google Colaboratory ortamında Python programlama dili ile oluşturulmuştur. İlk olarak bağımsız değişkenlerin normal dağılıma sahip olup olmadığını anlamak için Skewness-Kurtosis testi yapılmıştır. Test sonucunda normallik varsayımını ihlal eden koşullar olduğu tespit edildiğinden aykırı değerler veri kümesinden çıkarılarak normal dağılım koşulları sağlanmıştır. Regresyon modelleri oluşturulurken veri setleri eğitim ve test kümesi olarak ikiye ayrılmıştır. Eğitim verileri modellerimizi eğitmek, test verileri ise modellerimizin performansını ölçmek için kullanılmıştır. Modellerin aşırı uyumunu ortadan kaldırmak için 5 ve 10 katlı çapraz doğrulama yöntemleri uygulanmıştır.

Bu tez çalışmasının amacı, jeotermal enerji santrallerinin performans analizleri için en yüksek doğruluğa sahip regresyon modelinin tespit edilmesidir. Bu yöntem; santrallerin performansını izlemek ve optimize etmek, santrallerin kapasite artırımı ve yenileme çalışmaları için ve santrallerin kurulu gücünü daha doğru bir şekilde tahmin etmek için kullanılabilir. Bu çalışma ile santral işletmecilerine, kullanıcılara ve araştırmacılara, jeotermal enerji santrallerinin performans analizleri için yüksek doğruluğa sahip regresyon analiz yönteminin sunulması çalışmanın amacı olarak hedeflenmiş ve elde edilen bu sonuçların, literatüre katkı sağlaması bakımından önemli olabileceği değerlendirilmiştir.

2. LİTERATÜR BİLGİLERİ

2.1 Yenilenebilir Enerji

Fosil enerji kaynakları, dünyamızı besleyen temel enerji kaynakları olsalar da, sınırlı rezerve sahip olduklarından tükenmektedir ve çevre kirliliğine neden olmaktadır. Fosil yakıtların yakılması havaya sera gazlarının, özellikle de karbondioksitin salınmasına neden olur. Karbondioksit, güneş ışınlarının Dünya'yı ısıtmasına neden olan sera gazlarından birisidir. Sera gazları dünya çapında iklim değişikliği, aşırı hava olayları, deniz seviyesinin yükselmesi gibi olumsuz etkilere neden olmaktadır. Bu nedenle, çevreyle uyumlu yenilenebilir enerji kaynaklarının kullanımını artırmak, sürdürülebilir bir gelecek için hayati önem taşımaktadır.


Yenilenebilir enerji kaynakları Şekil 2.1'de görüldüğü gibi güneş, rüzgâr, hidroelektrik, jeotermal, biyokütle, biyogaz ve dalga enerjisi gibi kaynaklardır. Bu kaynaklar sürekli olarak yenilendiğinden sınırsız potansiyele sahiptir. Fakat günümüzde bu potansiyelden henüz tam anlamıyla yararlanılamamaktadır. Bu kaynaklardan hidroelektrik, rüzgâr ve güneş enerjisinin kullanımı iklime bağlıdır bu yüzden sürekli değildir. Jeotermal, biyogaz ve dalga enerjisi ise iklimden bağımsız sürekli enerji üretebilen kaynaklardır.



Şekil 2.1 Yenilenebilir enerji türleri (İnt.Kyn.1)

Yenilenebilir enerji kaynakları, çevresel etkilerinin daha az olması, güvenli olmaları ve ülke içinde bulunmaları sebebiyle taşıma avantajları, ayrıca küresel enerji talebini karşılayabilecek potansiyele sahip olmaları gibi avantajlara sahiptir. Ancak, fosil yakıtlar gibi ekonomik değeri olan bir ürün olarak piyasada bulunmamaları, güneş panellerinin estetik açıdan rahatsız edici olması, rüzgâr türbinlerinin ses kirliliği ve kuşlara zarar verme potansiyeli ve barajlı hidroelektrik santralleri ile jeotermal santrallerin biyolojik kirliliğe neden olma riski gibi dezavantajları da vardır. Ayrıca, rüzgâr, güneş ve hidrolik enerjisinin iklime bağımlı olması da süreklilik açısından zorluk teşkil etmektedir. Ancak, genel olarak değerlendirildiğinde, yenilenebilir enerji kaynaklarının olumsuz etkileri, fosil kaynaklara kıyasla ihmal edilebilir seviyelerdedir (Erdoğan 2015).


Şekil 2.2'de farklı enerji kaynaklarından elde edilen elektrik üretim miktarları verilmiştir. Diğer yenilenebilir enerji kaynakları; biyokütle, atık, jeotermal, dalga ve gelgit enerjileri verilerinden oluşmaktadır. Bütün yıllar boyunca kömürden elde edilen elektrik enerjisi genel olarak artış eğilimindedir. 2007-2020 yılları arasında inişli çıkışlı bir grafik sergilese de, 2021'de tekrar yükselerek zirveye ulaşmıştır. Bu durum, kömürün hala küresel elektrik üretimi için en yaygın birincil enerji kaynağı olduğunu göstermektedir. Doğal gazdan elde edilen elektrik üretim miktarı ikinci sırada olup sürekli bir artış göstermektedir. Nükleerden elde edilen elektrik üretiminde ise 2000'li yıllar boyunca önemli bir değişim gözlenmezken, petrol kaynaklı enerji üretiminde azalma olduğu görülmektedir. Yenilenebilir enerji kaynaklarına baktığımızda, hidroelektrik enerji en fazla elektrik üretimi yapılan kaynak olarak öne çıkmaktadır ve yıllar içinde yükselen bir grafiğe sahiptir. Rüzgar ve güneş enerjisi, 2010'a kadar diğer yenilenebilir kaynaklara göre daha az üretime sahip olsa da, 2021'de hidroelektrik enerjisinden sonra en fazla enerji üreten kaynaklar haline gelmiştir. Özellikle rüzgardan enerji üretimi, 2000'lerden itibaren türbin teknolojilerindeki gelişmeler ve devlet destekleri sayesinde her yıl ortalama %15 oranında artış göstermiştir. Güneşten enerji üretimi ise 2009 yılına kadar önemli bir üretim seviyesine ulaşamamış ancak, son yıllarda güneş panellerinin maliyetlerindeki düşüş ve enerji verimliliği konusundaki farkındalığın artmasıyla birlikte hızlı bir artış göstermiştir.



Şekil 2.2 Dünyada 1985-2022 yılları arasında farklı enerji kaynaklarından elde edilen elektrik enerjisi üretim miktarları (İnt.Kyn.2)

Şekil 2.3'te farklı enerji kaynaklarından elde edilen elektrik enerjisi üretiminin Dünya çapındaki payları gösterilmiştir. Buna göre kömürün payı 2014 yılından sonra düşüşe geçse de %35 ile hala toplamda en yüksek paya sahiptir. Kömür santrallerinin yüksek karbondioksit emisyonu ve çevreye verdiği diğer zararlar, yüksek yatırım maliyeti ve geri ödeme süresinin uzun olması, işletmesel zorluklar gibi olumsuz nedenlerden dolayı kömürün payın giderek azalmaktadır. Doğal gazın payı toplam enerji üretiminde olduğu gibi giderek yükselerek %20'nin üzerine çıkmıştır. Doğal gaz yüksek ısısal enerji değeri, kolay taşınması ve depolanması, diğer enerji kaynaklarına göre fiyatının daha ucuz olması ve çevreye olumsuz etkisinin daha az olması gibi avantajları nedeniyle sanayi ve konutlarda çok yaygın olarak kullanılmaktadır. Elektrik üretiminde kullanılan doğal gaz kombine çevrim santralleri, yüksek verimli olması, kojenerasyon sistemleriyle sıcak su ve buhar üretimi yapabilmesi, yüksek kurulu güçlere sahip olduklarından hem yatırım maliyetinin düşük olması hem de enerji arzı açısından emre amadelik ve güvenilirlik sağlaması ve düşük emisyon sağlamaları, doğal gazın yıllar içinde payının giderek artmasını sağlamıştır. Petrolün payı yıllar boyunca sürekli olarak düşmüştür. Petrol elektrik üretiminden çok sanayide ham madde ve taşıtlar için yakıt olarak daha çok talep görmektedir. Petrol üretiminde siyasi, ekonomik, çevre ve doğal afetler gibi nedenlerle dalgalanmalar olması fiyatları sürekli değiştirdiğinden petrolün enerji üretimindeki

payının düşmesine neden olmuştur. Nükleer enerjinin payı 2000'lere kadar çok fazla bir değişim göstermese de 2005'ten itibaren %5'ten fazla düşüş gerçekleşmiştir. Nükleer enerjinin payındaki düşüşün nedenleri radyasyon riski, maliyetlerin yükselmesi, kamuoyunun tepkisi ile siyasi desteğin azalması ve dünya genelinde daha temiz ve güvenilir kaynak olan yenilenebilir enerjiye olan talebin artması olarak değerlendirilebilir (Erdoğan 2015).




Şekil 2.3 Farklı enerji kaynaklarından elde edilen elektrik üretiminin Dünya çapında sahip olduğu paylar (İnt.Kyn.3)

Yenilenebilir enerji paylarına baktığımızda ise hidroelektrik en yüksek paya sahip olmasına karşın yıllar içinde payı %20'den %15'e düşmüştür. Hidroelektrik santrallerde kullanılacak suyun depolanması için barajlar oluşturulması gerekir. Barajların yapımı uzun sürdüğünden ve maliyetli olduğundan amortisman süreleri uzun olmaktadır. Ayrıca bitki ve hayvan habitatlarını değiştirme, kuraklık ve sel baskını gibi iklimsel değişiklikler ve doğanın tahrip edilmesi gibi çevreye olumsuz etkilerinden dolayı kamuoyunun tepkisini çekmektedir. Bu olumsuzluklardan kaynaklı olarak son yıllarda hidroelektrik santrallerin payı yeri başta güneş ve rüzgâr olmak üzere yenilenebilir enerji kaynaklarına kaydığı görülmektedir. Diğer yenilenebilir enerji kaynaklarının (biyokütle, atık, jeotermal, dalga ve gelgit) 2000 yılına kadar kayda değer bir paya sahip olmadığından ya

da ölçüm verisi olmadığından 2000 yılından sonra değerlendirmeye alındığı düşünülmektedir. Bu kaynakların hem teknolojilerinden dolayı kurulum maliyetlerinin yüksek olması hem de kaynaklarının sınırlı olmasından dolayı paylarında ciddi bir artış olmamıştır.


2008 yılı öncesinde rüzgâr ve güneşin toplam payı %1'in altındayken 2022 yılına bakıldığında %12 paya ulaşmıştır. Bu kadar kısa sürede rüzgâr ve güneş payının bu denli artmasında yenilenebilir enerji teknolojilerinin gelişmesiyle kurulum maliyetlerinin düşmesi, çevreci ve temiz olması, düşük işletme ve bakım maliyetleri ve kısa sürede işletmeye alınabilmesi gibi faktörler etkili olmuştur. Özellikle rüzgâr türbin teknolojisinin gelişmesi, daha büyük ve güvenilir türbinlerin üretilmesine olanak sağladığından türbinlerin kapasite faktörlerini de arttırmıştır. Büyük ölçekli üretim ve kapasite faktörünün artması sayesinde de sektördeki büyüme artmış bu da kurulum, işletme, bakım ve enerji maliyetlerinin düşmesine ön ayak olmuştur. Bu durum, rüzgâr enerjisi sektörünü daha verimli, rekabetçi ve çevre dostu bir hale getirmiştir (Özbektaş vd. 2023).

Türkiye’de 2000-2022 yılları arasında enerji kaynaklarının kurulu güçlerinin yıllara göre gelişimi Şekil 2.4’te, 2014 ve 2022 yıllarına ait enerji kaynaklarının paylarının karşılaştırılması ise Şekil 2.5’te gösterilmiştir. Termik kurulu güçleri; kömür, doğalgaz, sıvı yakıtlı santrallerin toplam güçleri olarak gösterilmiştir. Yenilenebilir enerjiler olarak ise hidroelektrik, rüzgâr, güneş, jeotermal ve biyogaz kurulu güçleri gösterilmiştir.




Şekil 2.4 Türkiye’de 2000-2022 yılları arasında enerji kaynaklarına göre kurulu gücün gelişimi (İnt.Kyn.4)

Şekil 2.5'te termik ve hidroelektrik enerji kaynaklarının kurulu güçlerinin payları 2014'ten 2022'ye gelindiğinde toplamda %17 oranında azalmıştır. Yenilenebilir enerjideki paylar ise 2014'te %5 iken, 2022 yılında %20'ye çıkmıştır. Yani her geçen yıl termik ve hidroelektrik kurulu güçlerinin payları yenilenebilir enerjiye kaymaktadır.



Şekil 2.5 Türkiye'nin 2014-2022 yıllarına ait enerji kaynaklarının kurulu güçlerinin paylarının karşılaştırılması (İnt.Kyn. 4)

Şekil 2.6'da ise Ekim 2023 itibariyle ülkemizde kurulu güçlerin enerji kaynaklarına göre dağılımı ve yenilenebilir enerji kaynaklarının da kendi içindeki dağılımı aynı grafikte gösterilmiştir. Gelişmekte olan ülkemizin enerji tüketimi her geçen yıl arttığından bütün kaynak türlerinde kurulu güçlerin de arttığı görülmektedir.



Şekil 2.6 Türkiye'de kurulu güçlerin Ekim 2023 itibariyle ait enerji kaynaklarına göre dağılımı (TEİAŞ 2023)

Bu grafikleri bütün olarak ele aldığımızda, 2000’li yıllarda özellikle rüzgâr enerjisi en hızlı artan yenilenebilir enerji kaynağı olmuştur ve kurulu gücü 2010 yılında 1 000 MW üzerine çıkmıştır. 2022 yılına geldiğinde ise 11 000 MW’ın üzerine çıkmıştır. Güneş enerjisinde ilk 2014 yılında büyük ölçekte santraller kurulmaya başlanmış ve 2022 yılına gelindiğinde 10 000 MW’a yaklaşmıştır. Jeotermal ve biyokütle kurulu güçlerinde ise artış gerçekleşmiş fakat diğer yenilenebilir enerji kaynaklarına göre kayda değer kurulu güçlere ulaşamamıştır. Bunun nedenleri ise; jeotermal enerji üretimi için Türkiye’de sadece Batı Anadolu da yüksek sıcaklığa sahip jeotermal sahalarla sınırlı kalması, biyokütle için ise yüksek teknoloji gerektiren prosesler içerdiğinden kurulum maliyetlerinin yüksek olması gösterilebilir.


Ülkemizde elektrik üretiminde dışa bağımlılığı azaltmak ve yenilenebilir enerji kapasitesini arttırmak için 2005 yılında 5346 Sayılı Yenilenebilir Enerji Kaynaklarının Elektrik Enerjisi Üretimi Amaçlı Kullanımına İlişkin Kanun (YEK) çıkarılmıştır. YEK ile yenilenebilir enerji için satın alım garantisi getirilmiş olsa da bu kanun 2010 yılına kadar uygulanamamıştır. 2010 yılında Yenilenebilir Enerji Kaynaklarından Elektrik Üretimini Destekleme Mekanizması (YEKDEM) yönetmeliği devreye girmiş ve yenilenebilir enerji santrallerine on yıl süreli sabit fiyat garantisi verilmiş ve ayrıca yerli ekipman kullanımını teşvik etmek amacıyla ilave destek fiyat düzenlemesi de getirilmiştir. Bu yasal düzenlemeler, yenilenebilir enerji sektörüne yatırım yapmayı düşünen üreticilerin ilgisini çekmiş ve sektörde kapasite gelişimini hızlandırmıştır (Topal 2019).

2016 yılında ise Resmi Gazete’de yayınlanan 29852 sayılı Yenilenebilir Enerji Kaynak Alanları (YEKA) Yönetmeliği kapsamında, rüzgâr ve güneş enerjisine dayalı elektrik üretim tesisleri kurulması için ülkemiz genelinde Yenilenebilir Enerji Kaynak Alanları (YEKA) ilan edilmiştir. Böylece yenilenebilir enerji santralleri ile enerji maliyetlerinin azaltılması, yenilenebilir enerji teknolojilerinde dışa bağımlılığın azaltılarak yerli üretime kaydırılması ve yetişmiş insan kaynağının arttırılması hedeflenmektedir. Bu yönetmelik kapsamında ihale sistemi ile YEKA kullanım hakkı yarışması düzenlenmektedir. 2017 yılında YEKA-1 kapsamında ilk olarak Konya Karapınar Yenilenebilir Enerji Kaynak Alanı yarışma için belirlenmiştir. 1 000 MWe kurulu güce sahip Karapınar Güneş Enerji

Santrali'nin kurulumu ve devreye alınması 2023 yılında tamamlanmış olup enerji üretimine başlamıştır. Aynı ihale kapsamında yılda 500 MW üretim kapasitesine sahip olan Fotovoltaik Panel fabrikası ve Ar-Ge merkezi kurulmuştur. Rüzgâr enerjisi alanında ise gene 2017 yılında toplam 1 000 MWe kurulu güce sahip farklı konumlarda 6 adet rüzgar enerji santralinden oluşacak YEKA-1 ihalesi yapılmıştır. Aynı ihale kapsamında gene en az % 65 yerli ekipman kullanma şartı ile 150 adet/yıl veya 400 MW/yıl rüzgâr türbini üretim kapasitesine sahip bir fabrika kurulmuştur (İnt.Kyn.5).

2.2 Jeotermal Enerji

Jeotermal kelimesi “jeo” (yer) ve “termal (ısı)” kelimelerinin birleşimi olan yer ısısı anlamına gelmektedir (Pampudi ve Ulfa 2024). Jeotermal enerji tanım olarak, yer kabuğunun farklı derinliklerinde biriken ısınin etkisiyle oluşan, jeolojik yapının türüne göre yer kabuğunun derinliklerine ulaşarak doğrudan veya başka enerji türlerine dönüştürülerek kullanılabilen, su, buhar ve gazlar ile yeryüzüne kırıklar ve çatlaklar aracılığıyla taşınan doğal bir enerji kaynağıdır. Şekil 2.7’de gösterildiği gibi jeotermal sistemler, aşağıdaki dört temel kısımdan oluşmaktadır:



Şekil 2.7 Jeotermal sistem modeli (Yıldız 2014)

Isı Kaynağı: Jeotermal sistemlerin birinci bileşeni olan ısı kaynağı, genellikle yerkürenin en iç tabakasında bulunan mantoda meydana gelen radyoaktif mineral bozunmalarından kaynaklanan ısıdır.

Isıyı Taşıyan Akışkan: Büyük çoğunluğu meteorik kökenli olsa da magmatik, çok küçük miktarlarda metamorfik ve fosil suları da bulundurabilen ve derinlerdeki kabuk içerisinde dolaşarak ısıyı taşıyan sulardır. Hala derinlerdeki sıcaklığını muhafaza eden bir sokuluma temas ederek ısınan akışkanlar, yoğunluk farkından dolayı yukarı doğru hareket ederek rezervuar kaya içine dolar.


Rezervuar Kaya: Isıyı depolayan ve jeotermal rezervuarları oluşturan kayalardır. Rezervuarlar, yeraltındaki koşullara uygun re-enjeksiyon sistemi (akışkanın enerjisi kullanıldıktan sonra rezervuara geri basma yoluyla gönderilmesi) mevcut olduğunda yenilenebilir ve sürdürülebilir özelliğe sahip olurlar.

Örtü Kaya: Düşük termal iletkenliğe ve düşük geçirimsizliğe sahip olduğundan jeotermal sistemin sahip olduğu ısıyı korumaya yarayan kayalardır. Örtü kaya, sistemin dış etmenlerden etkilenmesini minimize ederek jeotermal enerji depolama sürecine katkıda bulunur (Akkuş ve Alan 2016).

Jeotermal enerjinin avantajları; gerekli tedbirler alındığında (re-enjeksiyon) kirlenmesinin olmaması, kapalı devre sistemlere sahip olduğundan karbon salınımının çok düşük olması, güneş ve rüzgâr gibi kısa süreli atmosferik şartlardan bağımsız olduğundan 24 saat kesintisiz enerji sağlaması, ticaret ürünü olmamasından dolayı kaynak maliyeti oluşturmaması, elektrik üretiminde buhar çevrimlerinin verimi yüksek olması ve işletme ve bakım birim maliyetlerinin düşük olması olarak sıralanabilir. Dezavantajları ise; gerekli önlemler alınmadığı takdirde jeotermal akışkanın taşındığı boruların paslanmasına, çürümesine ve kireçlenmesine ve içerdiği bor elementinden dolayı eğer dışarı atılırsa suyun ve toprağın kirlenmesine neden olması, kaynağının taşınmamasından dolayı kullanım alanının sınırlı olması sayılabilir (Adıyaman 2012).

2.2.1 Jeotermal Enerji Kullanım Alanları

Jeotermal enerji kaynakları sahip olduğu sıcaklıklara göre düşük entalpili kaynaklar ($<90^{\circ}\text{C}$), orta entalpili kaynaklar (90°C - 150°C) ve yüksek entalpili kaynaklar ($>150^{\circ}\text{C}$) şeklinde sınıflandırılır (Spadacini vd. 2017). Şekil 2.8’de jeotermal enerjinin sıcaklıklarına göre kullanıldığı alanlar Lindal Diyagramı’nda gösterilmiştir. Bu gösterim şeklinde jeotermal enerjinin kullanım şekli enerji üretimi ve doğrudan olarak kullanım ikiye ayrılmaktadır. Enerji üretimi için orta ve yüksek entalpili kaynaklar ($>90^{\circ}\text{C}$) kullanılırken doğrudan kullanımda orta ve düşük entalpili kaynakların ($<150^{\circ}\text{C}$) kullanıldığı göze çarpmaktadır.



Şekil 2.8 Lindal Diyagramı’na göre jeotermal kaynakların sıcaklıklarına göre kullanım alanları (İnt.Kyn.6)


Elektrik üretimi için yüksek entalpili buhar çevrimleri ve düşük entalpili ikili çevrimler olarak kategorize edilmiştir. Yüksek entalpili buhar çevrimleri kuru buhar, tek-çift ve üç flaşlı ve gelişmiş jeotermal sistemlerden (hibrit tek-çift-üçlü flaş sistemleri, hibrit flaş-ikili sistemler, hibrit fosil-jeotermal sistemler, hibrit diğer yenilenebilir ısı kaynakları-jeotermal sistemler ve hibrit geri basınç sistemi) oluşmaktadır. Düşük entalpili ikili çevrimler ise Organik Rankine Çevrimi (ORC) ve Kalina çevrimleridir.

Doğrudan kullanım ise ticari ve endüstri, tarım ve su ürünleri ve konut uygulamaları olarak kategorize edilmiştir. Doğrudan kullanım, genellikle 10°C ile 150°C aralığındaki sıcaklıklara sahip jeotermal kaynakların ısı enerjisinin başka bir enerji türüne çevrilmeden kullanıldığı geniş bir uygulama alanını kapsar. Bunlar jeotermal ısı pompaları, konut ısıtma-soğutma, sera ısıtma, tarım ve su ürünleri, endüstriyel kullanımlar, kaplıca ve havuz uygulamaları ve kar eritme gibi uygulamalardır (Moya vd. 2018).

Jeotermal enerjinin doğrudan kullanımının en yaygın şekli jeotermal ısı pompalarıdır (GHP). GHP ısıtma ve soğutma için yeryüzünün veya yeraltı suyunun doğal ısı depolama yeteneğini kullanan elektrikle çalışan bir cihazdır. GHP'ler, maksimum 150 m derinliklerdeki sabit toprak yüzeyi sıcaklığını kullanır. Bu derinliğe kadar 30 °C'nin altındaki düşük entalpi koşulları, evsel ve endüstriyel sektörlere ısıtma veya soğutma sağlamak için kullanılır. Kış aylarında soğuk çalışma sıvısı yeraltı borularına pompalanır, böylece nispeten daha sıcak olan çevre kaya sıcaklığı absorbe edilir. Bu sıcak su daha sonra binaları ısıtmak için kullanılır. Aynı temel prensip, yaz aylarında çevredeki atmosferik sıcaklık tarafından ısıtılan sıvının yeraltı borularına pompalanması ve böylece ısıyı nispeten daha soğuk olan kayalara aktararak yüzeye geri dönmesi ve klima görevi görmesi şeklinde işler. Şekil 2.9'da ısıtma ve soğutma modunda GHP'lerin kullanımı gösterilmiştir.

Yüzyıllardan beri sıcak suları kaplıca ve hamamlarda banyo yapmak amacı ile kullanmak jeotermal enerjinin bilinen en önemli kullanımlarından biridir. Çin, İzlanda, Japonya, Yeni Zelanda, Kuzey ABD, Türkiye gibi ülkelerde jeotermal kaynaklar 1000 yılı aşkın süredir banyo ve yemek pişirme amacıyla kullanılmaktadır. Romalılar jeotermal suyun

insan vücudu üzerinde tedavi edici etkisi olduğuna inanıyorlardı. Jeotermal suyu yüksek tansiyon, deri hastalıkları, sinir sistemi hastalıklarının tedavisinde ve romatizma belirtilerinin giderilmesinde kullanmışlardır. Günümüzde ise buhar banyolarında ve kaplıcalarda jeotermal kaynakların ısı ve buharından faydalanılmaktadır. Bu tesislerde kan dolaşımını düzenleme, cilt temizliği ve gençleştirme, kas gerginliğini azaltma ve detoksifikasyon sürecini hızlandırma gibi bazı sağlık uygulamaları yapılmaktadır (Sircar vd. 2016).



Şekil 2.9 GHP'nın ısıtma ve soğutma modunda kullanımı (İnt.Kyn.7)


Bölgesel ısıtma da jeotermal enerjinin en eski doğrudan kullanımlarından biridir. 14. yüzyılın başlarında Fransız köyü Chaudes-Aigues Cantal sakinleri, bugün hala faaliyette olan bir bölgesel ısıtma ağı aracılığıyla kendilerine sağlanan jeotermal bölge ısıtmasından yararlanmaktadırlar. ABD'nin batısındaki birçok şehir, çoğu 1900'lerin başından kalma doğrudan kullanımlı bölgesel ısıtmadan yararlanmaktadır. Bölgesel ısıtma jeotermal kuyulara bağlı yeraltı boru ağı aracılığıyla birden fazla tüketicinin ısınma ihtiyaçlarını karşılayan bir bölgesel ısıtma ağı sistemidir. Bu sistem bir veya birden fazla kuyudan veya bazı durumlarda kuyu alanlarından, kuyu ve sirkülasyon pompalarından, iletim ve dağıtım borularından, merkezi veya bireysel bina ısı eşanjörlerinden, yedek kazanlardan veya termal depolama ünitelerinden ve ölçüm sistemlerinden oluşur (Bloomquist 2003).

Jeotermal enerjinin diğ er yaygın dođrudan kullanım řekli olan sera ısıtma da iklim, ađırlıklı olarak bađıl nem ve sıcaklık kontrol edilir. Farklı sebze ve bitkilerin yetiřtirilmesi i in gereken optimum sıcaklık farklıdır. Bu nedenle seraların ısıtma ihtiya ına bađlı olarak kullanılan jeotermal suyun sıcaklıđı 40-100  C arasında deđiřmektedir. Jeotermal su, toprađın altına, toprađın  zerine veya bankların  zerine, bitki sıralarının arasına yerleřtirilen veya sera alanında asılı duran  elik borular vasıtasıyla yayılır (Sircar vd. 2016).

Tarım  r nleri kurutma ve balık ılık, end striyel kullanım, kar eritme gibi uygulamalarda da jeotermal enerjinin dođrudan kullanımının diğ er t rleridir fakat bu y ntemler diğ erlerine oranla kısıtlı kalmaktadır.

2.2.1.1 D nyada Jeotermal Enerjinin Dođrudan Kullanım Alanları

D nyada jeotermal enerjinin dođrudan ısı uygulamaları, teknolojinin geliřmesiyle sanayi ve evsel kullanımda gitgide yaygınlařmaktadır. řekil 2.10'da 1995-2020 yılları arasında d nyada jeotermal enerjinin dođrudan kullanım kurulu g   kapasitesi ve yıllık kullanım miktarları g sterilmiřtir. Bu grafiđe g re ge en 25 yılda toplam kullanım miktarının 9 kat ve kurulu g c nde 12 kat arttıđı g r lmektedir.  izelge 2.1'de jeotermal enerjinin dođrudan kullanım alanları olan GHP'ler, kaplıca ve havuz ısıtma, b lgesel ısıtma, sera ısıtma, su  r nleri havuz ısıtma, tarım  r nleri kurutma, end striyel kullanım, sođutma/kar eritme ve diğ er kullanımların (hayvancılık, spirulina yetiřtiriciliđi ve alkols z i eceklerin karbonatlanması vb.) 1995-2020 yılları arasındaki kullanım miktarları ve kurulu g   kapasite deđiřimleri g sterilmiřtir. 2020 yılına bakıldıđında jeotermal enerjinin dođrudan kullanım t rlerinde GHP toplam yıllık kullanım miktarının %58'ini, kaplıca ve havuz ısıtma %18'ini ve b lgesel ısıtma %15'ini oluřturmaktadır. Toplam kurulu g   kapasite payları ise GHP %71, kaplıca ve havuz ısıtma %11 ve b lgesel ısıtma da %11'dir. Buna g re jeotermal enerjinin d nyada en yaygın kullanımlarının bu    kategoride olduđu g r lmektedir.



Şekil 2.10 1995-2020 arası dünyada jeotermal doğrudan kullanım kurulu güç kapasitesi ve yıllık kullanım miktarı (Lund ve Toth 2021)

Çizelge 2.1 1995-2020 arasında çeşitli kategorilere göre jeotermal enerjinin doğrudan kullanım miktarları (TJ/yıl) ve kurulu güç kapasiteleri (MWt) (Lund ve Toth 2021)

Kullanım (TJ/yıl) Kapasite (MWt)	1995	2000	2005	2010	2015	2020
Isı pompası	14 617 1 854	23 275 5 275	87 503 15 384	200 149 33 134	326 848 50 258	599 981 77 547
Kaplıca ve havuz	15 742 1 085	79 546 3 957	83 018 5 401	109 410 6 700	119 611 9 143	184 070 12 253
Bölgesel ısıtma	38 230 2 579	42 926 3 263	55 256 4 366	63 025 5 394	88 668 7 602	162 979 12 768
Sera ısıtma	15 742 1 085	17 864 1 246	20 661 1 404	23 264 1 544	29 038 1 972	35 826 2 459
Su ürünleri	13 493 1 097	11 733 605	10 976 616	11 521 653	11 953 696	13 573 950
Tarımsal kurutma	1 124 67	1 038 74	2 013 157	1 635 125	2 030 161	3 529 257
Endüstriyel	10 120 544	10 220 474	10 868 484	11 745 533	10 454 614	16 390 852
Soğutma/Kar eritme	1 124 115	1 063 114	2 032 371	2 126 368	2 596 360	2 589 435
Diğer	2 249 238	3 034 137	1 045 86	955 42	1 440 79	1 950 106
Toplam	112 441 8 664	190 699 15 145	273 372 28 269	423 830 48 493	592 638 70 885	1 020 887 107 727

Jeotermal enerjini en büyük doğrudan kullanım (GHP ile) kurulu kapasitesine (MWt)

sahip beş ülke: Çin, ABD, İsveç, Almanya ve Türkiye'dir ve bu beş ülke dünya kapasitesinin %71,1'ini oluşturmaktadır. Aynı şekilde (GHP ile) yıllık en fazla enerji (TJ/yıl) kullanan beş ülke: Çin, ABD, İsveç, Türkiye ve Japonya'dır ve bunlar dünya kullanımının %73,4'ünü oluşturmaktadır. Kurulu kapasite (MWt) bakımından (GHP olmadan) en büyük doğrudan kullanıma sahip beş ülke: Çin, Türkiye, Japonya, İzlanda ve Macaristan'dır ve dünya kapasitesinin %76,0'ını oluşturmaktadır. GHP olmadan en büyük yıllık enerji kullanımına (TJ/yıl) sahip beş ülke: Çin, Türkiye, Japonya, İzlanda ve Yeni Zelanda'dır ve dünya kullanımının %76,5'ini oluşturmaktadır.

GHP açısından bakıldığında kurulu güç kapasitesinde (MWt) ve yıllık enerji tüketiminde (TJ/yıl) lider ülkeler sırasıyla; Çin, ABD, İsveç, Almanya ve Finlandiya'dır. Bu ülkelerin toplam kurulu güç kapasitesi dünya genelinin %77,4'ünü toplam yıllık tüketimleri ise dünya genelinin %83,5'ini oluşturmaktadır. GHP kullanımı WGC 2020 raporuna göre çoğunluğu Avrupa ülkeleri, Kuzey Amerika ve Çin olmak üzere 54 ülkeyi kapsamaktadır. ABD ve Batı Avrupa tipi 12 kW güce sahip GHP sayısı yaklaşık 6,46 milyondur.

Bölgesel ısıtmada hem kapasite hem de yıllık enerji kullanımı açısından lider ülkeler; Çin, İzlanda, Türkiye, Fransa ve Almanya'dır ve bu beş ülke dünyadaki toplam kullanımın yaklaşık %90'ını oluşturmaktadır. Bireysel alan ısıtma kurulu kapasite (MWt) açısından lider ülkeler; Türkiye, Rusya, Japonya, ABD ve Macaristan, yıllık enerji kullanımında (TJ/yıl) ise Türkiye, Japonya, Rusya, ABD ve İsviçre'dir. Bu ülkeler dünyadaki bireysel alan ısıtmasının yaklaşık %75'ini oluşturmaktadır. Toplamda 29 ülkede bireysel alan ısıtma kullanımı rapor edilmiştir.

Sera ısıtma da toplam 32 ülkenin jeotermal enerji kullandığı bilinmektedir ve yıllık enerji kullanımında (TJ/yıl) önde gelen ülkeler Türkiye, Çin, Hollanda, Rusya ve Macaristan olup, dünya toplamının yaklaşık %83'ünü oluşturmaktadır. Seralarda yetiştirilen başlıca ürünler sebze ve çiçeklerdir; ancak ağaç fideleri, kaktüsler ve muz gibi meyveler de yetiştirilmektedir.

Jeotermal enerjinin su ürünleri alanında kullanımını 21 ülke rapor etmiştir. Yıllık enerji kullanımı açısından başlıca ülkeler; Çin, ABD, İzlanda, İtalya ve İsrail'dir ve dünya geneli

yıllık kullanımın %92'sini oluşturmaktadır. Tilapia, somon, levrek ve alabalık yetiştirilen en yaygın türler gibi görünse de tropikal balıklar, ıstakoz, karides ve timsahlar da yetiştirilmektedir.

Çeşitli tahıl, sebze ve meyve mahsullerini kurutmak için 15 ülke jeotermal enerji kullandığını bildirmiştir. Kurutulan ürünlere örnek olarak; deniz yosunu (İzlanda), soğan (ABD), buğday ve tahıllar (Sırbistan), meyve (El Salvador, Guatemala ve Meksika), yonca (Yeni Zelanda), hindistan cevizi (Filipinler) ve kereste (Meksika, Yeni Zelanda ve Romanya) verilebilir. En büyük kullanıcılar olan Çin, Fransa, Macaristan, ABD ve Japonya, dünyadaki kullanımın %94'ünü oluşturmaktadır.

Jeotermal enerjinin endüstriyel kullanımı dünyada 14 ülkede görülmektedir. Örnekler arasında beton kürleme (Guatemala ve Slovenya), su ve gazlı içecek şişeleme (Bulgaristan, Sırbistan ve ABD), süt pastörizasyonu (Romanya ve Yeni Zelanda), deri endüstrisi (Sırbistan ve Slovenya), kimyasal ekstraksiyon (Bulgaristan, Polonya ve Rusya), CO₂ ekstraksiyonu (İzlanda ve Türkiye), kâğıt hamuru ve kâğıt işleme (Yeni Zelanda), iyot ve tuz ekstraksiyonu (Vietnam) ve borat ve borik asit üretimi (İtalya) bulunmaktadır. Enerji kullanımında (TJ/yıl) liderler: Çin, Yeni Zelanda, İzlanda, Rusya ve Macaristan, dünya kullanımının %98'ini oluşturmaktadır.


Neredeyse her ülkede (WGC 2020'ye göre 53' ülke) jeotermal su ile ısıtılan yüzme havuzlarına sahip kaplıcalar ve tatil köyleri bulunmaktadır; buna balneoloji, yani hastalıkların su ile tedavisi de dâhildir. Banyo ve yüzme için bildirilen en büyük yıllık enerji kullanımları Çin, Japonya, Türkiye, Brezilya ve Meksika'ya aittir ve dünya yıllık kullanımın %79,5'ini oluşturmaktadır.

Kar eritmek için jeotermal enerji kullanımı için çok az sayıda uygulama bulunmaktadır ve bunlar çoğunlukla kaldırım için kar eritme projelerinden oluşmaktadır. Bu uygulamalar İzlanda, Japonya, Arjantin, ABD ve Slovenya'da ve sınırlı ölçüde Polonya ve Norveç'te görülmektedir. Soğutma uygulaması (klima) yedi ülkede kullanılmakta olup Bulgaristan lider konumdadır ve onu Brezilya, Avustralya ve Slovenya, Cezayir, Arnavutluk ve Hindistan izlemektedir. Jeotermal enerjinin diğer kullanımları ise hayvancılık, spirulina yetiştiriciliği, tuzdan arındırma ve şişelerin sterilizasyonunu gibi

alanlarda olup 14 ülke rapor edilmiştir (Lund ve Toth 2021).

2.2.1.2 Türkiye’de Jeotermal Enerjinin Doğrudan Kullanım Alanları

Türkiye, Alp-Himalaya orojenik kuşağı üzerindeki konumu nedeniyle önemli bir jeotermal potansiyele sahiptir. Geniş bir sıcaklık aralığına sahip jeotermal kaynaklar Türkiye'nin dört bir yanına dağılmıştır ve sayısı binden fazladır (Şekil 2.11). Batı Anadolu, ülkemizin jeotermal alanlarının %78'ine sahiptir, onu %9 ile Orta Anadolu, %7 ile Marmara Bölgesi, %5 ile Doğu Anadolu ve %1 ile diğer bölgeler izlemektedir. Batı Anadolu, Neojen boyunca genişleme tektonizmasının etkisi altında kalmıştır ve Büyük Menderes Grabeni, Gediz, Simav, Dikili-Bergama, Afyon-Akşehir grabenleri gibi graben sistemlerinde önemli jeotermal alanlar içermektedir. Büyük Menderes Grabeni, Batı Anadolu'daki en büyük grabenlerden biridir ve Kızıldere (242 °C), Germencik (232 °C), Pamukören (188 °C) ve Salavatlı (171 °C) gibi en önemli ve yüksek sıcaklıklı jeotermal alanlara ev sahipliği yapmaktadır (Yalçın vd. 2023).



Şekil 2.11 Türkiye’deki jeotermal kaynakların dağılımı ve uygulama haritası (Şener vd. 2023)

Madem Tetkik Arama (MTA) Genel Müdürlüğü’nün 1960 yılındaki araştırması, Türkiye'nin jeotermal enerji araştırmalarının başlangıcı olarak kabul edilmektedir. O tarihten bu yana enerji üretimi ve doğrudan kullanım gibi farklı amaçlara uygun

akışkanlar içeren sahalar keşfedilmiştir. 1970-2000 yılları arasındaki dönem, öncelikle yüksek sıcaklıklı rezervuarların keşfi ile bilinmektedir. Şu anda 30°C ve üzeri sıcaklığa sahip 415 jeotermal saha ve 2000'den fazla kuyu bulunmaktadır. Jeotermal sahaların sayısı hem doğal kaynakları hem de açılmış kuyuları içermektedir. Dağılımlarına göre, doğal kaynak ve kuyu dibi sıcaklık değerleri baz alındığında, % 84'ü orta ve düşük sıcaklıklı alanlar olup doğrudan kullanılırken (ısıtma, termal turizm, tarım ve endüstri uygulamaları vs.), % 16'sı ise yüksek sıcaklıklı alanlarda elektrik üretimi için kullanılmaktadır. Türkiye Jeotermal Derneği tarafından Türkiye'nin toplam jeotermal teorik ısı potansiyeli (hidrotermal 0-4 km derinlik için) 60 000 MWt, toplam jeotermal teorik elektrik potansiyeli 4 500 MWe olarak hesaplanmıştır.

Çizelge 2.2'de Türkiye'nin jeotermal enerji doğrudan kullanım alanları ve kurulu güçleri verilmiştir. Türkiye Jeotermal Kaynaklar Strateji Raporu kapsamında Türkiye'nin kurulu doğrudan kullanım jeotermal kapasitesi 5 113 MWt olarak hesaplanmıştır. Bu kurulu gücün %47,8'i termal turizm uygulamaları, %27,8'i merkezi ısıtma uygulamaları, %24,1'i sera ısıtma uygulamaları ve %0,4'ü ısı pompası, kurutma ve soğutma uygulamalarıdır.

Çizelge 2.2 Türkiye'de jeotermal enerjinin doğrudan kullanım kurulu güçleri (Şener vd. 2023)

Kullanım şekli	Kapasite
Jeotermal bölge ısıtma (Şehir, konut)	1 422 MWt (158 000 konut eşdeğeri)
Sera ısıtma	1 230 MWt, (5 293 dekar)
Kaplıca, otel vb. tesis ısıtma	680 MWt (68 000 konut eşdeğeri)
Balneolojik kullanım (kaplıca ve spa)	17 63 MWt
Sebze ve meyve kurutma	9,5 MWt
Jeotermal ısı pompası	8,5 MWt
Sıvı CO ₂ , Kuru Buz Üretimi	Yıllık 400 000 ton
Soğutma	0,35 MWt
Toplam	5113 MWt

Ülkemizde jeotermal enerjinin yaygın doğrudan kullanımı bölge ısıtma uygulamalarıdır. Bölgesel ısıtma kapasitesi 1 422 MWt ve termal tesis ısıtma kapasitesi 680 MWt ile birlikte 2 102 MWt kurulu güce ulaşmaktadır. Çizelge 2.3'te Türkiye'deki bölgesel ısıtma sistemi mevcut olan ilçeler verilmiştir.

Çizelge 2.3 Türkiye’de bölgesel ısıtma uygulaması yapılan yerler (Şener vd. 2023)

Isıtılan bölge	Sıcaklık (°C)	Konut eşdeğeri
Balıkesir-Gönen	80	3 400
Kütahya-Simav	120	18 612
Ankara-Kızılcahamam	80	2 100
İzmir-Balçova-Narlidere	98-125	38 899
Afyon-Sandıklı	70	30 000
Kırşehir-Terme	57	1 800
Afyon-Ömer-Gecek	95	25 610
Balıkesir-Güre	65	1 400
Balıkesir-Sındırgı	98	4 000
İzmir-Dikili	125	1 530
Nevşehir-Kozaklı	92	3 800
Ağrı-Diyadin	70	970
Manisa-Salihli	94	10 067
Denizli-Sarayköy	140	5 000
Balıkesir-Edremit	60	5 100
Balıkesir-Bigadiç	96	1 500
Yozgat-Sorgun	80	2 100
İzmir-Bergama	65	866
TOPLAM		156 754

Ülkemizdeki jeotermal enerjinin termal turizm tesisleri olan hamamlar, kaplıcalar ve otellerde kullanılması oldukça yaygın ve eskiye dayanan bir uygulamadır. Bugün itibariyle 520'den fazla aktif termal tesis jeotermal kaynakları kullanmaktadır. Bu tesisler yılda yaklaşık 20-23 milyon kişiyi ağırlamaktadır. Türkiye, jeotermal enerjinin termal tesislerde kullanımı açısından dünyada 3. sırada yer almaktadır.

Türkiye’de jeotermal sera ısıtma kapasitesini 2022 yılında 1230 MWt'ye ve toplam sera alanını 5293 dekara çıkarmıştır. Mevcut seraların çoğu, iklim koşullarının daha elverişli olduğu güney illerinde yer almaktadır ancak son yıllarda soğuk iklim bölgelerinde de (Sivas, Afyon, Kırşehir ve Ağrı-Diyadin gibi) jeotermal enerji kullanımının yaygınlaşmasıyla seracılık faaliyetleri başlamıştır (Şener vd. 2023).


2.2.2 Jeotermal Enerjiden Elektrik Üretimi

Dünyadaki ilk jeotermal elektrik üretimi 1904 yılında Larderello'da gerçekleştirilmiştir ancak bu sadece 5 elektrik ampulünü yakmaya yetmiştir. 1914’e gelindiğinde 250 kW'lık turbo alternatör ile dolaylı çevrimli saf buhar prosesinden oluşan santral Volterra ve Pomarance'ın elektrik dağıtım sistemine bağlanarak, jeotermal enerjiden ilk ticari elektrik

üretimi gerçekleştirildi. Bu sistemde jeotermal buhar, ısı eşanjörlerine gönderilmiş ve burada saf suyu kaynatmak için kullanılmıştır. 1950'lerde, jeotermal kaynakların ticari olarak kullanımını dünyanın yüksek sıcaklığa sahip diğer bölgelerinde yaygınlaştırmak için kuru buharın yanında tek flaşlı buhar çevrimleri de kullanılmaya başlamıştır. Kuru buhar kaynaklarının sıcak su kaynaklarına göre son derece nadir olduğu göz önüne alındığında, bu gelişme jeotermal enerjiden elektrik üretimi açısından kritik öneme sahiptir. 1958 yılında Yeni Zelanda'da Wairakei jeotermal alanında ilk kez bir enerji santrali sıvı ağırlıklı bir jeotermal akışkan kullanarak 6,5 MW elektrik üretti (DiPippo 2016).

1980'lerin başında ise Ormat şirketi tarafından, düşük sıcaklıklı jeotermal kaynaklardan elektrik üretimini hedefleyen yenilikçi bir konfigürasyon olan ORC ikili çevrim teknolojisi tasarlandı, test edildi ve ticarileştirildi. Bu sistem, elektrik üretimi için düşük sıcaklığa sahip olan jeotermal kaynakların ticari olarak işletilmesini sağladığı ve bazı orta ve yüksek sıcaklıktaki kaynaklar için de daha verimli bir çözüm sunduğu için jeotermal pazarında iyi bir başarı elde etmiştir (Spadacini vd. 2017).

2023 yılı sonu itibarıyla jeotermal enerji toplam kurulu güç kapasitesi 16,335 MW'tır. En yüksek kurulu güce sahip beş ülke: ABD-3.900 MW, Endonezya-2.418 MW, Filipinler-1.952 MW, Türkiye-1.691 MW ve Yeni Zelanda 1.042 MW'tır. Dünyada kurulu güç bakımından ilk 10 ülke Şekil 2.12'de gösterilmiştir. Bu 10 ülke küresel toplam kurulu kapasitenin yaklaşık %93'ünü oluştururken, kalan 20 ülke toplam kurulu güce 1.125 MW katkıda bulunmaktadır (İnt.Kyn.9).



Şekil 2.12 Dünyada jeotermal enerji kurulu gücü en çok olan ülkeler (İnt.Kyn.9)

Dünyada en yüksek kurulu güce sahip santraller; 18 santralden oluşan Geyser Jeotermal Kompleksi (ABD) 900 MW ile birinci, 34 santralden oluşan Larderello Jeotermal Kompleksi (İtalya) 769 MW ile ikinci ve Cerro Prieto Jeotermal Kompleksi 720 MW ile üçüncü sıradadır (DiPippo 2016).

Türkiye'nin jeotermal enerjiden elektrik üretim serüveni, 1968'de Denizli ili Sarayköy ilçesi Kızıldere jeotermal alanındaki KD-1 kuyusunda 196 °C jeotermal akışkan bulunmasının ardından 1974 yılında 500 kW gücünde bir flaş ünitesinin kurulmasıyla başlamıştır. 1984 yılında, 17,4 MW gücündeki Kızıldere-1 Jeotermal Elektrik Santrali (JES) devlet desteğiyle ülkemizdeki ilk jeotermal santral olarak devreye alınmıştır. Sonraki yirmi yıllık süre boyunca başka bir jeotermal santral kurulumu gerçekleşmemiştir. 2006 yılına gelindiğinde Aydın ili Salavatlı jeotermal alanında özel bir şirket tarafından inşa edilen 7,35 MW güce sahip ikili çevrimli Dora 1 JES faaliyete geçmiştir (Aksoy 2014). Bu yıldan sonra JES kurulumları hız kazanmış, 2023 yılı itibarıyla 63 santral ve toplam 1.691 MW kurulu güce ulaşmıştır (TEİAŞ 2023). Çizelge 2.4'te Türkiye'deki JES'ler ve Şekil 2.13'te haritadaki yerleri gösterilmiştir.

Çizelge 2.4 Türkiye'de bulunan JES'lerin tipleri ve kurulu güçleri (Serpen ve DiPippo 2020)

İLİ	SANTRAL ADI	SANTRAL TİPİ	KURULU GÜÇ (MW)
Denizli	KIZILDERE1 JES	Tek Flaşlı	15,0
Aydın	3S KALE JES	İkili	25,0
Afyonkarahisar	AFJET JES	İkili	2,8
Manisa	ALA2 JES	İkili	30,0
Çanakkale	BABADERE JES	İkili	8,0
Manisa	BAKLACI JES	İkili	19,4
Denizli	BEREKET JES	İkili	6,9
Aydın	BUHARKENT JES	İkili	13,8
Aydın	DENİZ JES	İkili	24,0
Aydın	DORA1 JES	İkili	8,0
Aydın	DORA2 JES	İkili	9,5
Aydın	DORA3 JES	İkili	34,0
Aydın	DORA4 JES	İkili	17,0
Aydın	EFE6 JES	İkili	22,6
Aydın	EFE7 JES	İkili	25,0
Aydın	EFE8 JES	İkili	50,0
Aydın	EFE JES	Çift flaş+ikili	114,9
Denizli	EMİRLER 1 JES	İkili	3,5
Aydın	GALİP HOCA JES	Çift Flaşlı	47,4
Denizli	GREENECO 3 JES	İkili	25,6
Denizli	GREENECO JES	İkili	25,6
Denizli	GREENECO JES 5	İkili	28,1
Denizli	GREENECO JES 6	İkili	26,0
Aydın	GÜMÜŞKÖY JES	İkili	13,2
Çanakkale	İDA JES	İkili	11,8
Manisa	KEMALİYE JES	İkili	24,9
Aydın	KEN-3 JES	İkili	24,8
Aydın	KEN KİPAŞ JES	İkili	24,0

Çizelge 2.4 (devam) Türkiye’de bulunan JES’lerin tipleri ve kurulu güçleri (Serpén ve DiPippo 2020)

Aydın	KEREM JES	İkili	24,0
Aydın	KİPER JES-1	İkili	10,2
Denizli	KIZILDERE2 JES	Üç flaş+ikili	80,0
Denizli	KIZILDERE3 JES	Üç flaş+ikili	165,0
Aydın	KUBİLAY JES	İkili	24,0
Aydın	KUYUCAK JES	İkili	18,0
Aydın	MAREN JES	İkili	44,0
Manisa	MASPO-4 JES	İkili	10,0
Aydın	MEHMETHAN JES	İkili	24,8
Aydın	MELİH JES	İkili	33,0
Manisa	MİS-1 JES	İkili	12,3
Manisa	MİS-3 JES	İkili	48,0
Aydın	NEZİHE BEREN JES	İkili	20,0
Manisa	ÖZMEN-1 JES	İkili	23,5
Manisa	ÖZMEN 3 JES	İkili	18,6
Aydın	PAMUKÖREN JES	İkili	67,5
Aydın	PAMUKÖREN JES 2	İkili	22,5
Aydın	PAMUKÖREN JES 3	İkili	22,5
Aydın	PAMUKÖREN JES 4	İkili	32,0
Aydın	PAMUKÖREN JES 5	İkili	32,0
İzmir	RSC-1 SEFERİHİSAR JES	İkili	12,0
Manisa	SALİHLİ 1 JES	İkili	15,0
Manisa	SALİHLİ 2 JES	İkili	24,5
Manisa	SALİHLİ 3 JES	İkili	30,0
Aydın	SULTANHİSAR-2 JES	İkili	22,5
Aydın	SULTANHİSAR JES	İkili	13,8
Denizli	TOSUNLAR1 JES	İkili	3,8
Çanakkale	TRANSMARK JES	İkili	3,2
Manisa	TÜRKERLER ALAŞEHİR-1 JES	İkili	24,0
Manisa	TÜRKERLER ALAŞEHİR-2 JES	İkili	24,0
Manisa	TÜRKERLER ALAŞEHİR-3 JES	İkili	29,5
Çanakkale	TUZLA JES	İkili	7,5
Aydın	UMURLU-2 JES	İkili	12,0
Aydın	UMURLU JES	İkili	12,0
Manisa	ZORLU ALAŞEHİR JES	Çift flaş+ikili	45,0
	TOPLAM		1691,3



Şekil 2.13 Türkiye’deki JES’lerin harita üzerinde gösterimi (Şener vd. 2023)

2.3 Jeotermal Elektrik Santrali (JES) Tipleri ve Ekipmanları

Genel olarak JES’lerde elektrik üretimi işlemi, 149 °C ile 371 °C arasında değişen sıcaklıklardaki jeotermal su ve buharı yeryüzüne çıkarmak için zemine kuyu açılmasını ve daha sonra bu akışkanların türbinleri döndürmesini içerir. JES’ler, kuru buhar, flaş buhar (tek, çift ve üçlü flaş), ikili çevrim ve kombine çevrim enerji santrali olmak üzere çeşitli tiplere ayrılmıştır (Pambudi ve Ulfa 2024).

2.3.1 Kuru Buhar Jeotermal Elektrik Santrali


Bu sistemde genellikle 2000-3000 m derinlikteki kuyulardan 160°C ile 300°C arasındaki sıcaklıklarda çıkarılan, temel olarak doymuş veya atmosferik basıncın üzerinde bir basınçla kızdırılmış yüksek basınçlı kuru buhar, türbin jeneratörüne doğrudan bağlanarak elektrik elde edilir. Kuru buhar JES’ler yoğuşmasız ve yoğuşmalı olarak ikiye ayrılır.

Yoğuşmasız kuru buhar JES’ler jeotermal enerjiyi elektriğe dönüştürmek için kullanılan en basit ve ekonomik teknolojidir. Bu santral tipinde, kuyudan gelen buhar doğrudan türbinden geçirilir ve türbinden çıkan buhar herhangi bir yoğuşturucu bulunmadığından atmosfere salınır. Buharın kontrolsüz bir şekilde dışarıya salınması atmosferin kirlenmesine neden olur çünkü jeotermal buhar, yaklaşık %2-%10 oranında hidrojen sülfür, karbondioksit ve metan gibi yoğuşmayan gazları içerir (DiPippo 2016).

Yoğuşmalı kuru buhar JES’lerde, türbinden çıkan buhar doğrudan atmosfere salınmaz, sıcaklığı yaklaşık 35-45°C’ye düşüren yoğuşturucuya gönderilir. Yoğuşturularak elde edilen jeotermal su daha sonra bir reenjeksiyon kuyusuyla toprağa basılır. Kullanılmış buharın yoğuşturulması sistemi daha verimli hale getirirken yoğuşmayan gazlardan kaynaklanan kirlilikte önlenir çünkü bu gazlar yoğuşturucuda izole edilir, ejektörlere çekilir ve gerekirse atmosfere salınmadan önce arıtılır. Ancak bu sistemlerin eklenmesi nedeniyle santralin kurulum ve işletme maliyetleri artmaktadır.

Yoğuşmalı kuru buhar JES’in basitleştirilmiş sistem tasarımı Şekil 2.14’te gösterilmiştir. Genel olarak sistem buhar temizleme, enerji üretimi ve soğutma ve yoğuşma sistemleri

olarak üç bölüme ayrılır. Buhar temizleme bölümünde, kuru buhar içindeki büyük katı parçacıkları ayırmak için bir parçacık giderici ve yoğunlaşmış su ve küçük katı parçacıkları gidermek için ise bir nem giderici bulunur.



Şekil 2.14 Kuru buhar JES'lerin basitleştirilmiş tasarımı (Martínez vd. 2019)

Güç üretim bölümü tipik olarak bir buhar türbini, bir jeneratör ve bir yoğusturucudan oluşur. Tek basıncılı buhar türbininde, kuru buharın türbin kanatlarına çarpması sonucu oluşan itki-tepki kuvveti, kanatları döndürür. Bu dönme hareketi mekanik enerji üretir ve bu mekanik enerji bir jeneratör aracılığıyla elektrik enerjisine çevrilerek şebekeye verilir. Buhar türbinindeki teknolojik gelişmeler ve yoğusturucu sistemi sayesinde minimum enerji kaybı oluşur ve yaklaşık %86 verimle çalışır (Aziz ve Juangsa, 2021). Yoğusturucu, türbinin çıkışında atmosfer basıncından daha küçük bir basınç yani vakum oluşturulur. Bu durumda buhar, türbini daha düşük basınçta ve sıcaklıkta yani daha düşük entalpide terk edeceğinden buharın ısı enerjisinin neredeyse tamamı güce çevrilmiş olur. Bu nedenle aynı koşullardaki yoğusturuculu kuru buhar çevrimleri yoğusturucusuz olanlardan daha fazla elektrik üretirler (Kanoğlu 2005).

Son bölüm soğutma kulesi ve yoğusturucudan oluşur. Bu bölüm, jeotermal su reenjeksiyon kuyusuna geri pompalanmadan veya türbinden çıkan buhar atmosfere

salınmadan önce ısılarının tamamen alınmasından ve emisyon arıtımından sorumludur. Kuru buhar santralinde genel olarak su soğutmalı yoğuşturucu kullanılırken, soğutma suyu ısı soğutma kulesindeki fanlar ile soğutulur. Bazı santraller hava soğutmalı yoğuşturucular kullanmaktadır fakat zaten buhar sıcaklığı düşük olan bu tip santrallerin türbin çıkış basıncı dış koşullara bağlı olarak değiştiğinden, artan çevre sıcaklıklarında hava soğutmalı yoğuşturucular elektrik üretiminin yüksek oranda düşmesine neden olmaktadır (Erdoğan ve Küçüka 2019).

Kuru buhar çevrimi ilk olarak 1911 yılında Larderello'da kullanılmıştır ve ve halen faaliyettedir. Bu tip santrallerin en yaygın olduğu ülkeler; İtalya (Larderello), ABD (Geysers), Endonezya'da (Kamojang ve Darajat), Japonya (Matsukawa) ve Yeni Zelanda (Wairakei). Dünyada kuru buhar alanlarının jeotermal akışkanlı alanlara kıyasla daha kısıtlı olmasından dolayı, kuru buharlı JES'ler flaş buharlı JES'lere göre daha az sayıda bulunmaktadır (Pambudi ve Ulfa 2024). Ülkemizde kuru buharlı JES bulunmamaktadır.


2.3.2 Flaş Buharlı Jeotermal Elektrik Santrali

Jeotermal akışkan, üretim kuyusunda yukarı doğru ilerledikçe hidrostatik basınç düşer. Bu durumda, akışkanın basıncı, kaynama noktasına karşılık gelen doyma basıncının altına düşer ve jeotermal akışkanın su bileşeninin bir kısmı buhara dönüşür. Bu sürece flaşlanma işlemi nedir (Yıldırım Özcan ve Gökçen 2009). JES'lerde en yaygın kullanılan teknoloji flaş buhar çevrimidir. Dünya çapındaki toplam kurulu gücün %61,49'unu flaş buhar çevrimi, kalan %38,51'ini ise ikili çevrim, kuru buhar ve hibrit/kombine çevrimler oluşturmaktadır. Flaş buhar JES'lerin tekli, ikili ve üçlü flaş olmak üzere üç tipi vardır (Pambudi ve Ulfa 2024).

2.3.2.1 Tek Flaşlı Jeotermal Elektrik Santrali

Tek flaş terimi, jeotermal akışkan basıncının düşürülmesiyle elde edilen jeotermal buhar-su karışımında tek bir flaşlanma gerçekleştiğini ifade eder. Basınçlı sıvının sıvı-buhar fazına geçişi üretim kuyusunda, bir rezervuarda veya bir siklon ayırıcı girişinde gerçekleşebilir. Normalde kuyu içinde gerçekleşen flaşlanma noktası, zamanla rezervuar

basıncı düşeceğinden kuyunun derinlerine doğru inebilir. Bu açıdan siklon ayırıcıda daha kararlı bir flaşlanma gerçekleşir. Türbinde kullanılmak üzere siklon ayırıcıdan elde edilen buhar için ayrılmış buhar terimi kullanılmaktadır (DiPippo 2016).




Şekil 2.15 Tek flaşlı JES’lerin basitleştirilmiş tasarımı (Martínez vd. 2019)

2.3.2.2 Çift Flaşlı Jeotermal Elektrik Santrali

Çift flaşlı buhar çevrimi, tek flaşlı çevrimin verimini artırarak enerji üretimini desteklemek için geliştirilmiştir. Çift flaşlı JES'ler, tek flaşlı JES'lere göre %25 daha fazla çıkış gücü üretebildiğinden daha avantajlı olarak kabul edilir. Fakat çift flaşlı buhar santrali teknolojisi daha karmaşıktır ve işletme ve bakımı tek flaşlı santrallere göre daha pahalıdır (Moya vd 2018). Çift flaşlı JES'ler dünyadaki kurulu gücün yaklaşık %20'sine sahiptir. Ülkemizde çift flaşlı santral sadece Aydın-Germencik'teki 47,5 MW kurulu güce sahip Galip Hoca JES'tir.


Şekil 2.16'da, çift flaşlı JES'lerin basitleştirilmiş tasarımı gösterilmektedir. Çift flaşlı JES'ler, tek flaşlı JES'lerle aynı çalışma prensibine sahiptir. Aradaki fark, çift flaşlı çevrimde flaşlama işleminin yüksek ve düşük basınçlı ayırıcılarda iki aşamada yapılması ve ayrılan buharların tek basınçlı türbin yerine çift basınçlı türbinde (yüksek ve düşük basınçlı) kullanılmasıdır. Yani flaşlama işlemi yüksek basınç ayırıcısındaki çıkan sıcak su üzerinde bir kez daha tekrarlanır. Düşük basınç ayırıcısından elde edilen buhar, düşük basınç türbininde güç ürettikten sonra yüksek basınç türbininden çıkan buhar ile karıştıktan sonra yoğuşturucuda soğutulur suya dönüştürülür ve reenjeksiyon kuyusuna basılır (Martínez vd. 2019).



Şekil 2.16 Çift flaşlı JES'lerin basitleştirilmiş tasarımı (Martínez vd. 2019)

2.3.2.3 Üç Flaşlı Jeotermal Elektrik Santrali

Üç flaşlı çevrim, iki flaşlı çevrime orta kademe eklenmesiyle oluşur. Üç farklı kademedeki flaşlama yapabilen ayırıcılar ardışık bağlanarak yüksek, orta ve düşük basınçlı buhar elde edilir. Daha sonra yüksek, orta ve düşük basınç buhar konfigürasyonuna sahip türbin döndürülerek jeneratörden elektrik üretilir. Türbinden sonraki süreç diğer çevrimlerdekilerle aynı şekilde devam eder. Şekil 2.17’de üç flaşlı JES’lerin basitleştirilmiş hali gösterilmiştir. Tıpkı çift flaşlı buhar santrali gibi verimi diğer santrallere göre daha yüksektir fakat teknolojisi daha karmaşık olduğundan işletme ve bakımı maliyetleri de yüksektir. Dünyada bu çevrime sahip santraller şunlardır: Rotokawa-140 MW (Yeni Zelanda), Kızıldere-3 (130 MW), Kızıldere-2 (60 MW), Salton Sea (49 MW+49,9 MW) (DiPippo 2016).



Şekil 2.17 Üç flaşlı JES’lerin basitleştirilmiş tasarımı (Martínez vd. 2019)

2.3.3 İkili Çevrimli (Binary) Jeotermal Elektrik Santrali

Jeotermal akışkan sıcaklığı düştükçe iki fazlı jeotermal akışkan içerisindeki sıvı oranı arttığından bu kaynakların flash teknolojisinde kullanılması mümkün olmamaktadır. Bunun gibi kaynak sıcaklığının yüksek olmadığı alanlarda (85°C-150°C) elektrik üretimi için ikili çevrim kullanılması gerekmektedir. İkili çevrimlerde kaynama noktası sıcaklığı


sudan daha düşük olan başka bir sıvı kullanılır ve jeotermal akışkandan bu ikinci akışkana ısı transferi gerçekleştirilir. İkili çevrimler çalışma sıvısının türüne göre Kalina ve Organik Rankine Çevrimi olarak ikiye ayrılır. İkili çevrimde türbin girişinde buhar yerine çalışma sıvısı kullanımının diğer çevrimlere göre bazı avantajları mevcuttur. İkili çevrimde jeotermal akışkan ile türbin arasında temas olmadığından türbin kanatlarında kireçlenme ve korozyon etkisi görülmemektedir. Diğer çevrimlerdeki gibi çalışma sıvısı yoğunlaşmayan gazları içermediğinden yoğunlaştırıcıya gaz alma sistemi eklenmesine gerek yoktur. Fakat bunun yanında ikili çevrimde de kullanılan besleme pompalarının enerji tüketimi ve ikili çevrimli JES'lerin termodinamik açıdan büyük güçlerde kurulmaya uygun olmayışı gibi dezavantajları vardır (Spadacini vd. 2017) .

2.3.3.1 Organik Rankine Çevrimli Jeotermal Elektrik Santrali

İkili çevrimde kullanılan çalışma sıvısı organik olduğu için Organik Rankine Çevrimi (ORC) olarak adlandırılır. Şekil 2.18'de gösterildiği gibi ORC iki farklı döngüden oluşur. İlk döngü, kuyudan iki faz (sıvı ve buhar) olarak çıkan jeotermal akışkanın buharlaştırıcı ve ön ısıtıcıya girmesi ve tekrar yer altına gönderilmesi ile tamamlanır. İkinci döngü kapalı çevrimdir ve çalışma sıvısı olarak bir organik soğutucu kullanılır. Bir ön ısıtıcı ve buharlaştırıcıda jeotermal akışkan tarafından ısıtılan organik çalışma sıvısı buharlaşır ve türbini döndürerek ve jeneratörden elektrik üretilir. Türbinden çıkan çalışma sıvısı yoğunlaştırıcıya gönderilir. Bu bölümde yoğunlaştırılan organik çalışma sıvısı tamamen sıvı hale geldikten sonra besleme pompası ile basınçlandırılarak tekrar ön ısıtıcıya girer (Başoğlu vd 2021).

ORC'li JES'lerde santral verimini etkileyen en önemli faktörlerden biri de ikili akışkan yani çalışma sıvısı seçimidir. Bu akışkanlar öncelikle normal kaynama noktası sıcaklığı ortam sıcaklığında veya altında olan bir hidrokarbon veya soğutucu akışkanlardır. İkili çevrimlerde kullanılma potansiyeli olan soğutucu akışkanlar, genellikle -50°C ile 50°C arasında normal kaynama noktası sıcaklıklarına sahiptir. Bu kriterleri karşılayan toplam 66 akışkan bulunmaktadır (Mines 2016). Bunlar kloroflorokarbon (CFC), hidrokloroflorokarbon (HCFC), hidroflorokarbon (HFC), hidrokarbon (HC) ve hidrofloroolefin (HFO) gibi bileşikler ve türevleridir. Bu akışkanlar teknik açıdan uygun

olsalarda, ancak CFC ve HCFC akışkanları yüksek ozon delme potansiyelleri nedeniyle yasaklanmıştır. Geleneksel HFC'lerde yüksek küresel ısınma potansiyelleri nedeniyle yerini aşamalı olarak HFO'lara bırakmaktadır. HC çalışma sıvıları ya izopentan ve pentan gibi yanıcı bir sıvı ya da izobütan, n-bütan ve propan gibi sıvılaştırılmış petrol gazı olduklarından kullanıldıkları tesislerde yangın koruma sistemleri gerektirir fakat düşük zehirlilik ve çevresel risk barındırdığından nispeten ucuzdurlar (Spadacini 2017). Çizelge 2.5'te görüldüğü gibi HFC grubu soğutucu akışkanlarından R245fa yüksek kritik sıcaklığa ve R134a düşük kaynama noktasına sahip ve nispeten daha güvenli olduklarından ikili ORC JES'lerde en yaygın olarak kullanılan çalışma sıvılarıdır (Mines 2016).



Şekil 2.18 İkili ORC JES'lerin basitleştirilmiş tasarımı (Martínez vd. 2019)

Çizelge 2.5 Organik çalışma sıvılarının termofiziksel özellikleri (Spadacini 2017)

İsim	Sınıfı	Kaynama sıcaklığı (°C)	Kritik sıcaklığı (°C)
R134a	HFC	-26,1	101,1
R245fa	HFC	15,1	154,0
İzobütan	HC	-11,8	134,7
Bütan	HC	-0,5	152,0
İzopentan	HC	27,8	187,2
Pentan	HC	36,1	196,6


ORC'li JES'ler dünyada oldukça yaygındır. Kurulu güç olarak toplam kurulu gücün yaklaşık %10'unu oluştursa da, toplam ünite sayısı olarak payı %40'tan fazladır. Ülkemizde de birkaç santral dışında neredeyse bütün santraller ORC'li JES tipindedir.

2.3.3.2 Kalina Çevrimli Jeotermal Elektrik Santrali

Diğer ikili çevrim türü olan Kalina Çevrimi'nin ORC'den farkı çalışma sıvısı olarak tek bir soğutucu akışkan değil, belirli oranlarda amonyak-su karışımı kullanılmasıdır. Su ve amonyak benzer moleküler ağırlıklara sahip olsa da termofiziksel özellikleri oldukça farklıdır. Karıştırıldığında, su ve amonyak nonazeotropik bir karışım oluşturur çünkü amonyak, sudan daha düşük kaynama ($-33,3\text{ }^{\circ}\text{C}$) ve kritik sıcaklığa ($101,1\text{ }^{\circ}\text{C}$) sahip olan daha uçucu bir bileşendir (Spadacini 2017).

Şekil 2.19'da gösterildiği gibi Kalina çevriminin versiyonlarından biri olan KCS34'ün basitleştirilmiş tasarımı gösterilmiştir. Buna göre üretim kuyusundan çıkan jeotermal akışkan buharlaştırıcıdaki çalışma sıvısına enerjisini aktardıktan sonra reenjeksiyon kuyusuna basılır. Buharlaştırıcıdan çıkan iki fazlı akışkan ayırıcıda amonyak içerikli buhar ve su olarak ayrışır. Amonyak bakımından zengin olan buhar türbine gider ve daha yüksek su konsantrasyonuna sahip olan sıvı ise, ön ısıtma için yüksek sıcaklıklı ısı değiştiriciden çıktıktan sonra, türbinden çıkan buharla birleşir ve daha sonra besleme pompasından çıkan çalışma sıvısının ilk ısıtmasını gerçekleştirir. Amonyak bakımından zengin buhar, türbine doymuş olarak girdiğinden, türbinden çıkarken iki fazlı olacak ve yoğunlaştırucuya girip yoğunlaşma işlemi tamamlanana kadar iki fazlı kalacaktır (Mines 2016).



Kalina çevrimi ORC ile karşılaştırıldığında teorik olarak daha yüksek güçler sunmasına ve ORC'ye göre daha çevreci bir akışkana sahip olmasına rağmen, işletimi sırasında bazı ciddi sorunlarla karşılaşılması ve yüksek maliyeti nedeniyle bu teknoloji jeotermal enerji pazarında fazla tercih edilmemiştir. Bu teknolojinin çeşitli versiyonları daha çok deneysel olarak kullanılsa da ticari kullanım örneği olarak İzlanda'nın Husavík kentindeki 2 MW'lık KCS-34 santrali bulunmaktadır (Spadacini 2017).



Şekil 2.19 Kalina çevrimli JES'lerin (KCS-34 versiyon) basitleştirilmiş tasarımı (Mines 2016)

2.3.4 Kombine Flaşlı-İkili Jeotermal Elektrik Santrali

Kombine çevrimler yüksek entalpiye ve dolayısıyla çok yüksek buhar miktarına sahip kaynaklar için uygundur. İkili çevrim ünitesi, ayırma işleminden sonra jeotermal sıvı akışından yararlanarak buhar türbinine paralel olarak veya geri basınç türbininden gelen bir buhar akışının eklenmesiyle seri olarak çalışabilir. Bu çevrim dünyada iki şekilde kullanılmaktadır. Birincisi Şekil 2.20'de gösterilen, ORC'nin yüksek basınçlı ayırıcıdan çıktıktan sonra jeotermal akışkanda kalan ısının ORC'de kullandığı "dip" konfigürasyonudur (Spadacini 2017). İkincisi ise Şekil 2.21'de gösterilen yüksek entalpili bir kaynaktan faydalanmanın en verimli yolu olan kombine çevrim konfigürasyonudur ve özellikle yüksek yoğunlaşmayan gaz (NCG) içeriğine sahip kaynaklara uygundur. NCG giderme sistemi santral açısından büyük yatırımlar gerektirir fakat kombine çevrimde NCG'lerin çoğu ilk flaşla YB buharına taşınır ve bu sayede NCG ekipmanı gerektirmez. DB kısmında, kondenser için sadece daha basit bir NCG giderme sistemi gerektirir. Çevrimin YB kısmı, bir dip ikili ile bir geri basınç buhar türbininden oluşur. Tipik jeotermal ORC sisteminden farklı olarak, kombine çevrim JES'ler genellikle tamamen su soğutmalıdır ve soğutma kuleleri sistemi için bir takviye olarak yoğunlaşan buhardan gelen saf sudan faydalanır (Harvey ve Wallace 2016).



Kombine JES'ler dünyada çoğunluğu dip konfigürasyonu olmak üzere bazı ülkelerde mevcuttur. Ülkemizde dip konfigürasyonuna sahip santal bulunmamasına rağmen kombine flaş-binary konfigürasyonuna sahip JES'ler sadece ülkemizde mevcuttur. Bunlar üçlü flaşlı- ikili çevrimli Kızıldere-3 (130 MW üç flaş+35 MW ikili çevrim), Kızıldere-2 (60 MW üç flaş+20 MW ikili çevrim) ve Alaşehir-1 (30 MW çift flaş+15 MW ikili çevrim) JES'lerdir.

2.4 Regresyon Analizi

Regresyon analizi; bir bağımlı değişkenin, bir veya birden fazla bağımsız değişken ile arasındaki en uygun ilişkinin matematik bir fonksiyon şeklinde ifade edilmesidir ve bu fonksiyona da regresyon denklemi denir. (Tezcan 2011). Regresyon tanımında bahsi geçen bağımsız değişken ifadesi sabit değerli olan ve bağımlı değişkeni etkileyen verileri, bağımlı değişken ise bağımsız değişkenlere göre değişen veriyi ifade eder. Regresyon analizinin amacı bu iki değişkenlerin ilişkisini açıklayan denkleme göre başka değişkenler kullanarak tahmin yapmayı sağlamaktır.


İstatistik alanında en yaygın kullanılan regresyon yöntemleri; doğrusal regresyon, polinomal regresyon, gradyan artırma regresyonu, karar ağaçları regresyonu, rastgele orman regresyonlarıdır. Bunlar haricinde bilimsel çalışmalarda tahmin yapmak maksadıyla kullanılan çok fazla sayıda regresyon yönetimi bulunmaktadır.

2.4.1 Çoklu Doğrusal Regresyon (ÇDR)

Bağımlı değişkeni tahmin etmek için oluşturulan modelde girdi olarak; tek bir bağımsız değişken varsa basit regresyon, birden fazla bağımsız değişken kullanılıyorsa çoklu regresyon analizi olarak tanımlanır. Bağımlı ve bağımsız değişken ya da değişkenler arasındaki ilişkinin doğrusallığına göre de doğrusal ya da doğrusal olmayan regresyon ifadeleri kullanılır. Birden fazla bağımsız değişken ve değişkenler arasındaki ilişkinin doğrusal olduğu regresyon türüne ise çoklu doğrusal regresyon denir. Çoklu doğrusal regresyonda bağımsız değişkenler ($x_1, x_2, x_3 \dots x_n$) ile bağımlı değişken (y) arasındaki doğrusal ilişki denklem 2.1'deki gibidir. Bu denklemde; y bağımsız değişkeni x_n bağımlı değişkenlerin doğrusal bir fonksiyonunu, b_n değerleri modeldeki katsayıları, b_0 doğrunun

Y eksenini kestiği noktayı ve e ise hata terimini ifade etmektedir (Gabralı ve Aslan 2020).

$$y = b_0 + b_1x_1 + b_2x_2 + \dots + b_nx_n + e \quad (2.1)$$



Şekil 2.22 Doğrusal regresyon grafiği

2.4.2 Polinomal Regresyon (PR)

Bağımsız değişkenlerle bağımlı değişken arasındaki ilişkinin doğrusal olmadığı durumda polinomal regresyon devreye girer. Polinomal regresyonda, bağımsız değişkenler ve bağımlı değişken arasındaki ilişki denklem 2.2'deki eşitlikle ifade edilir. Bu denklemde y_i bağımlı değişkeni, x_i bağımsız değişkenleri, b_k regresyon katsayılarını, e_i hata terimini, k polinomun derecesini ve $i=1,2,3,\dots,n$ polinomdaki değişken sayısını belirtmektedir.


$$y_i = b_0 + b_1x_i + b_2x_i^2 + \dots + b_kx_i^k + e_i \quad (2.2)$$



Şekil 2.23 Polinomal regresyon grafiği

2.4.3 Karar Ağaçları Regresyonu (KAR)

Karar ağaçları hem sınıflandırma hem de regresyon analizinde çok yaygın olarak kullanılan bir denetimli öğrenme modelidir. Şekil 2.24'te görüldüğü gibi karar ağacı yapısı üç farklı türde düğüm içerir. Kök düğüm olarak bilinen ve tüm örneği temsil eden orijinal düğüm, diğer düğümlere bölünebilir. İç düğümler bir veri kümesinin özelliklerini temsil ederken, dallanma karar verme prosedürlerini temsil eder. Yaprak düğümler ise ortaya çıkan sonucu gösterir. Karar ağacı yapılarının oluşturulmasında, verilerle ilgili belirli sorular sorularak karar kurallarının oluşturulması için kök düğümünde başlanır. Ardından ağaç yapısı dallanır veya büyür, önce iç düğüme daha sonra son eleman olan yapraklara ulaşıncaya kadar sürekli sorular sorulur veya dallanma gerçekleşir (Nuray vd. 2021).



Şekil 2.24 Karar ağacı yapısı (Kassim vd. 2023)

Denklem 2.3 bir karar ağacı içindeki bir düğümün bölünmesi sonucu elde edilen bilgi kazanımıdır. Burada s , herhangi bir t düğümündeki potansiyel bir bölünmeye karşılık gelir. Buna göre; s tarafından sırasıyla P_L ve P_R ile orantılı olarak sol (t_L) ve sağ (t_R) alt düğümlere bölme gerçekleştirilmiştir. Burada, $i(t)$ bölünme için önceden tanımlanmış bir safsızlık standardıdır ve $\Delta i(s,t)$ bölünmüş s 'den azalan safsızlığın nihai ölçüsüdür.

$$\Delta i(s, t) = i(t) - P_L i(t_L) - P_R i(t_R) \quad (2.3)$$

En sık kullanılan üç safsızlık ölçümü: kazanç oranı, Gini endeksi ve Ki-kare'dir. Python kütüphanesinde bulunan Sklearn kütüphanesi içindeki karar ağacı regresyonu Gini endeksini kullanmaktadır. Gini safsızlık endeksi (I_G) 0 ile 1 arasında değişir ve denklem 2.4'teki şekilde formüle edilir. Burada $f(t_{X(x_i)}, k)$ t düğümündeki k kadar yaprağın her bir örneğinin x_i sayıdaki olasılıklarını temsil eder. Karar ağacındaki bölünme kriteri, en düşük I_G 'ye sahip olma özelliğinin belirlenmesinden türetilir (Kassim vd. 2023).

$$I_G(t_{X(x_i)}) = 1 - \sum_{k=1}^m f(t_{X(x_i)}, k)^2 \quad (2.4)$$

2.4.4 Rastgele Orman Regresyonu (ROR)

Rastgele orman regresyonu (ROR), birden fazla karar ağacının bir araya getirilmesiyle oluşturulan makine öğrenme algoritmasıdır. Karar ağaçlarının bir kombinasyonu olan Rastgele orman regresyonu, torbalama yönteminin rastgelelik özelliği eklenerek daha gelişmiş bir versiyonu olarak kullanılmaktadır. ROR, tüm değişkenler içinden en iyi dalı seçerek her bir düğümü dallara ayırmak yerine, her bir düğümden rastgele olarak seçilen değişkenlerin en iyisini kullanarak her bir düğümü dallara ayırır. Bütün veri seti orijinal veri setinin yerleri değiştirilerek üretilir ve rastgelelik özelliği kullanılarak ağaçlar geliştirilir. Çabuk ve istenilen sayı kadar regresyon ağacı üreten ve çalıştıran ROR, bir veriyi tahmin etmek için, girdi verisini ormandaki bütün ağaçlara yerleştirir. Orijinal veri setinden yeniden örnekleme ile veri setleri teker teker üretilir. Sonuç olarak ROR, birden fazla karar ağacını oluşturup onları birleştirerek daha doğru ve istikrarlı bir tahmin etmektedir.


ROR için kullanıcı tarafından Karar Ağacı sayısı (N) ve her bir düğümde kullanılacak değişken sayıları (m) olmak üzere iki parametre tanımlanması gerekmektedir. ROR için Python kütüphanesinde bulunan Sklearn kütüphanesi içindeki ID3 algoritması karar ağaçları üretir ve ID3 algoritması kurallarına göre belirsizlik entropi ile ölçülür ve denklem 2.5'teki gibi ifade edilir. Burada H entropiyi, $p(x_i)$ belirli bir veri sınıfına ait grubun yüzdesini, t ise seçilen eğitim kümesindeki elemanları belirtmektedir. Entropi ne kadar yüksek olursa belirsizlikte o kadar yüksek olur. Bu yüzden entropi, “0” olana kadar

ağaçların dallanması sürer veya ağaç derinliğinin belirli bir düzeyde kalması için ağaç budaması yapılabilir (Nuray vd. 2021).

$$H(t) = - \sum_{i=1}^n p(x_i) \log p(x_i) \quad (2.5)$$

2.4.5 Gradyan Artırma Regresyonu (GAR)

Gradyan artırma regresyonu (GAR), karar ağaçlarının tahminini iyileştirmek için geliştirilmiş bir makine öğrenmesi algoritmasıdır. Bu algoritma temel olarak, genellikle karar ağaçlarından oluşan bir dizi zayıf tahminleyici modeli bir araya getirerek güçlü bir tahminleyici oluşturur. Şekil 2.25'te gösterildiği gibi gradyan artırma algoritmasında başlangıç olarak ilk iterasyonda karar ağacı kullanılarak bir tahmin fonksiyonu oluşturulur. Bir sonraki ağaç oluşturulmadan, daha önce oluşturulan ağaçların hata oranları kaydedilir. Tahminler ile gerçek veriler arasındaki farklar hesaplanarak bir kayıp fonksiyonunu elde edilir. İkinci iterasyonda ise tahmin ve kayıp fonksiyonları birleştirilir ve tahminler ile gerçek veriler arasındaki fark tekrar hesaplanır. Tahmin fonksiyonunun başarısını artırmak için sürekli ekleme yapılarak sıfıra yakın hata oranının elde edilmeye çalışılır (Bayrakçı vd. 2021). GAR, tahminlerdeki hatayı minimize etmek için gradyan iniş algoritmasını kullanır. Bu, her bir iterasyonda hataları minimize etmek için model parametrelerini günceller. Bu süreç, bir kayıp fonksiyonunu genellikle (ortalama karesel hata gibi) optimize ederek gerçek değerlerle tahminler arasındaki farkı minimize eder.




Şekil 2.25 GAR algoritmasının işleyiş süreci (Bayrakçı vd. 2021)

2.5 K-Katlı Çapraz Doğrulama

Regresyon analizinde en iyi modeli oluşturmak için model parametrelerinin doğru şekilde belirlenmesi ve modelin daha önce görmediği veriler üzerinde de yüksek performans göstermesi kritik önem taşır. Bunu gerçekleştirebilmek için veri seti, eğitim ve test seti olmak üzere iki gruba ayrılır. Eğitim seti, modelin eğitilmesi için kullanılan verilerden oluşur. Test seti ise, modelin eğitildiği verilerin ne kadarını öğrendiğini ölçmek için seçilen verilerden oluşur (Aslan ve Yıldız 2022). Eğer bir model test setinde yüksek performans gösteriyorsa, bu modelin eğitim setindeki verileri ezberlemeden, genel bir öğrenme gerçekleştirdiğini gösterir. Ama eğitim setinin performansı test setinden daha yüksekse modelin aşırı uyum gösterdiği söylenebilir. Bunun nedeni modelin gördüğü verileri ezberlemesi ve görülmemiş örneklere genelleme yapamamasıdır (İnt.Kyn.10).

Çapraz doğrulama, modelin esnekliğini ve performansını iyileştirerek aşırı uyumu engellediğinden yaygın olarak kullanılan bir yöntemdir. K-katlı çapraz doğrulama da veri seti önce k alt örneğe bölünür, bir örnek test için kullanılır ve geri kalan k-1 örnek veri kümesinin eğitimi amacıyla kullanılır. Eğitim ve test veri kümeleri değiştirilerek tüm süreç k kez tekrarlanır (Saud vd. 2020). Genelde k değeri için 5 ve 10 kullanılır ve her katın hata katsayılarının ortalaması alınarak modelin hata katsayısı hesaplanır. Şekil 2.26'da 10 katlı çapraz doğrulama algoritmasının işleyiş süreci gösterilmiştir.



Şekil 2.26 10 katlı çapraz doğrulama (İnt.Kyn.11)

2.6 Hata Ölçüm Parametreleri

Tahmin verileri ile gerçek veriler arasındaki farkları hesaplayarak tahmin algoritmasının performansını ölçmek ve hata analizlerini gerçekleştirmek için hata ölçüm yöntemleri kullanılmaktadır. Bunlar; R^2 , hataların mutlak değerlerinin ortalaması (MAE), hataların karesinin ortalaması (MSE) ve hataların karesinin ortalamasının karekökü (RMSE) yöntemleridir. Analize dahil edilen bağımsız değişkenlere göre bağımlı değişkenin oranı korelasyon katsayısını (R) verir. Korelasyon katsayısı 0 – 1 arasında değişen bir değerdir.

2.6.1 R-Kare (R^2)

R^2 , bağımsız değişkenlerin bağımlı değişkende oluşturduğu varyasyon oranını hesaplayarak modelin doğruluğunu belirleyen metrik ölçümdür. R^2 değerinin 1'e yakın olması, tahmin verilerinin gerçek verilerle uyumlu olduğunu gösterir. Denklem 2.6'da R^2 'nin nasıl hesaplandığı gösterilmiştir. Bu denklemde y_i gerçek değer, x_i tahmini değer, $\hat{y}$ ise ortalama gerçek değer ve n ise veri sayısıdır.

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - x_i)^2}{\sum_{i=1}^n (y_i - \hat{y})^2} \quad 2.6$$

2.6.2 Hataların Mutlak Değerlerinin Ortalaması (MAE)

MAE, regresyon ve zaman serisi algoritmalarında çok sık kullanılan bir performans ölçüm tekniğidir ve gerçek ile tahmin verileri arasındaki mutlak farkların ortalamasını hesaplamaya yarar. MAE, her bir verinin model performansına aynı şekilde etki ettiği bir hata ölçüm tekniği olduğundan küçük ya da büyük hata ayrımının yapılmadığı durumlarda kullanılmaktadır. MAE değeri sıfıra yaklaştıkça, modelin tahmin ve gerçek değerler arasındaki fark küçülmekte ve modelin performansı artmaktadır. Denklem 2.7'de MAE'nin formülü verilmiştir. Bu denklemde y_i gerçek değer, x_i tahmini değer, n ise veri sayısıdır.

$$MAE = 1 - \frac{\sum_{i=1}^n |y_i - x_i|}{n} \quad (2.7)$$

2.6.3 Hataların Karesinin Ortalaması (MSE)

MSE, özellikle regresyon analizlerinde çok sık kullanılan bir performans ölçüm tekniğidir. MSE, gerçek ve tahmin verileri arasındaki farkların karelerinin ortalamasıdır. Daha büyük hatalar daha fazla ağırlığa sahip olduğundan bu yöntem büyük hataların modelin performansını daha çok azaltacağı durumlarda kullanılır. MSE değeri sıfıra yaklaştıkça, modelin tahmin ve gerçek değerler arasındaki fark küçülmekte ve modelin performansı artmaktadır. Denklem 2.8’de MSE’nin formülü verilmiştir.

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y})^2 \quad (2.8)$$

2.6.4 Hataların Karesinin Ortalamasının Karekökü (RMSE)

MSE’nin karekökü alınarak RMSE hesaplanır ve gerçek ve tahmin verileri arasındaki farkların büyüklüklerinin ortalamasıdır. RMSE, MSE’den farklı olarak büyük hatalara daha az ağırlık verdiği için, büyük hataların önemli olduğu durumlarda daha kullanışlı bir hata ölçüm tekniğidir. Ayrıca, RMSE değeri, MSE değerinin kolayca karşılaştırılamayacak kadar büyük olduğu durumlarda yorumlamayı kolaylaştırmak içinde kullanılır. Denklem 2.9’da RMSE’nin nasıl hesaplandığı gösterilmiştir (Çelik ve Özdemir 2023).

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y})^2} \quad (2.9)$$

2.7 Python Programlama Dili

Python, web uygulamaları, yazılım geliştirme, veri bilimi ve makine öğrenimi alanlarında çok yaygın kullanılan bir programlama dilidir. İlk olarak Hollandalı bilgisayar programcısı olan Guido van Rossum tarafından 1989 yılında geliştirilmeye başlanan Python’un ilk sürümü olan Python 0.9.0 olarak 1991 yılında yayımlandı. Daha sonra sırasıyla; 1994 yılında Python 1.0, 2000 yılında Python 2.0 ve 2008 yılında Python 3.0 kullanıma sürüldü. Python, açık kaynaklı ve özgür olması, öğrenmesi ve kullanımının

kolay olması, kütüphane ve araçlarının geniş kapsamlı olması, nesneye yönelik programlamayı desteklemesi ve farklı platformlarda çalıştırmaya uygun olması gibi özellikleri nedeniyle başlangıç seviyesindeki öğrencilerden profesyonel geliştiricilere kadar geniş bir kullanıcı kitlesine hitap eder. Python'un Sklearn, NumPy, Pandas, Matplotlib, Seaborn gibi kütüphaneleri, makine öğrenme ve yapay zekâ uygulamaları geliştirme imkânı sağlar (İnt.Kyn.12).

2.8 Literatür Özeti

Tez çalışmasının kapsamına uygun olarak gerek yerli ve gerekse yabancı araştırmacılar tarafından yapılan çalışmalara ait özet bilgiler tarih sırasına göre aşağıda verilmiştir.

Karadaş vd. (2013) yaptıkları çalışmada Aydın Salavatlı jeotermal sahasında faaliyet gösteren, çift akışkanlı çevrime ve hava soğutmalı yoğunlaştırucuya sahip DORA-1 JES'in net güç tahmin performansının jeotermal akışkan debisi ve sıcaklığı ile dış hava sıcaklığına göre değişimini incelemişlerdir. Santralin 2010 yılına ait 8.412 saatlik verileri ile çoklu regresyon analizi yapmışlar ve doğrusal ve logaritmik regresyon modelleri oluşturmuşlardır. Bu regresyon analizinin amacı, sistem parametrelerin aynı anda değişmesi sonucu santralin net üretim gücünü tahmin etmektir. Yaptıkları incelemede, jeotermal akışkan debisi ve dış hava sıcaklığının santral performansına %95 oranında etki ettiğini görmüşlerdir. Her iki modelde de klasik doğrusal regresyonun temel varsayımlarını test etmişler, hatalar arasında pozitif otokorelasyon bulmuşlar ve bu otokorelasyonu Orcutt-Cochran Yöntemi ile yok etmeye çalışmışlardır. Doğrusal regresyon modeli Durbin-Watson istatistiğinde 2'ye en yakın sonucu verdiği için, DORA-1 jeotermal santralinin performansını en iyi açıklayan model olarak seçmişlerdir.

Martínez vd. (2019) yaptıkları çalışmada çok değişkenli doğrusal regresyon analizini kullanarak Meksika'nın Cerro Prieto kentindeki tek ve çift flaş döngüsüne sahip jeotermal enerji santralinin net güç ve termal verimliliğini tahmin etmişlerdir. Tek flaş döngüsü için çok değişkenli doğrusal regresyon analizinde kuyu sıcaklığı, ayırıcı basıncı ve yoğunlaştırucu basıncı olmak üzere 3 bağımsız değişken, çift flaş döngüsü içinse kuyu sıcaklığı, yüksek basınçlı ayırıcı basıncı, düşük basınçlı ayırıcı basıncı ve yoğunlaştırucu basıncı olmak üzere 4 bağımsız değişken kullanmışlardır. Toplamda regresyon analizi

için 263.402 simülasyondan 68.921'i tek flaş döngüsü ve 194.481'i çift flaş döngüsü için kullanmışlardır. Çevrimlerin net gücünü ve termal verimliliğini tahmin etmeye yönelik matematiksel modellerin başarımlarını R^2 olarak seçmişlerdir. Tek flaş döngüsünde net güç ve termal verim için R^2 değeri sırasıyla 0,999769 ve 0,9992560, çift flaş döngüsünde ise 0,999722 ve 0,999612 olarak bulmuşlardır. Genel olarak R^2 değerleri 0,90'ın üzerindedir ve bu durum modellerin çevrimin net gücünü ve termal verimliliğini tahmin etme açısından güvenilir olduğunu gösterir.

Tut Haklıdır ve Haklıdır (2019) yılında yaptıkları çalışmada, Batı Anadolu'daki doğal kaplıcalar ve jeotermal kuyulardan oluşan farklı jeotermal sistemlerden seçilmiş hidrojeokimya verilerini kullanarak jeotermal rezervuar sıcaklıklarını tahmin etmek için bir derin öğrenme modeli geliştirmişlerdir. Toplam 83 termal kaynaktan 66'sını eğitim veri seti analizi için, 17'sini ise test veri seti için seçmişlerdir. Geliştirdikleri derin öğrenme modelinin tahmin performansını karşılaştırmak için ise iki geleneksel regresyon yaklaşımı, doğrusal regresyon ve doğrusal destek vektör makinesini tercih etmişlerdir. Derin sinir ağı (DSA) modelinin rezervuar sıcaklığı açısından jeotermometre hesaplamalarına en yakın değerleri sağladığından en düşük ortalama karekök hatasına ve ortalama mutlak hataya sahip olduğunu tespit etmişlerdir. Sonuç olarak, derin öğrenme modelinin geleneksel makine öğrenme tekniklerine kıyasla daha iyi tahmin performansını elde ettiğini göstermişlerdir.

He vd. (2021) yılında yaptıkları çalışmada, Çin'deki Bohai Körfezi Havzası'ndaki jeotermal kaynaklardan elde edilen sekiz jeolojik parametreyi kullanarak, jeotermal ısı akışı (GHF) verilerini tahmin etmişlerdir. Bu tahminleri genelleştirilmiş doğrusal model (GDM), DSA, GAR ve destek vektör makinesinden (DVM) oluşan dört farklı makine öğrenme algoritmalarıyla geliştirmişlerdir. Toplamda 249 GHF ölçümü kullanmışlar; bunların %60'ını eğitim ve %40'ını test veri seti için seçmişlerdir. Hem SVM hem de DSA algoritmalarının, GHF'yi tahmin etmede sırasıyla %13,3 ve %12,7'lik ortalama bağıl tahmin hatalarıyla GAR ve GDM'den daha iyi performans gösterdiğini gözlemlemişlerdir. Ayrıca SVM ve DSA algoritmalarının GAR ve GDM ile karşılaştırıldığında, tahmin edilen ve gerçek GHF'ler arasındaki benzerlik ve korelasyonun daha yüksek olduğunu görmüşlerdir.

Shahdi vd. (2021) yaptıkları çalışmada, kuyulardan alınan 20 750 adet kuyudibi sıcaklığı verilerini ve jeolojik bilgileri kullanarak, ABD'nin kuzeydoğusundaki yeraltı sıcaklıklarını tahmin etmede dört makine öğrenimi yönteminin uygulanabilirliğini araştırmışlardır. Bu makine öğrenme yöntemleri Ridge regresyonu, Aşırı Gradyan Artırma (XGBoost), ROR ve DSA'dır. XGBoost ve ROR'nin 3,21 °C ve 3,25 °C'nin ortalama mutlak hata değerleri ile tüm modellerden daha iyi performans gösterdiği gözlemlenmiştir. Ayrıca makine öğrenimi ve fizik tabanlı modellerden elde edilen tahminleri, Batı Virginia eyaletindeki 58 kuyulu ekstra bir veri setinden elde edilen ölçülen sıcaklık verileriyle karşılaştırmışlar ve XGBoost'un farklı derinliklerdeki sıcaklığı başarıyla tahmin edebildiğini göstermişlerdir.

Varol Altay vd. (2022) yaptıkları çalışmada, farklı bölgelerdeki jeotermal kaynaklardan elde edilen hidrojeokimyasal ve rezervuar sıcaklık verilerini kullanarak, sınıflandırma algoritmaları ve hibrit metasezgisel optimizasyon algoritmasına dayalı bir yapay sinir ağı (YSA) aracılığıyla jeotermal kaynağın kullanım alanını tahmin etmişlerdir. Bu tahminler için literatürde yaygın olarak kullanılan Naive Bayes sınıflandırıcı, K-en yakın komşu (KEYK), doğrusal ayırım analizi, ikili karar ağacı, DVM ve YSA algoritmalarını kullanmışlardır. Ayrıca hibrit metasezgisel bir yapay sinir ağı modeli tasarlanarak ümit verici sonuçlar elde etmişlerdir. Geleneksel makine öğrenmesi yöntemlerinde %71 ile %82 arasında bir doğruluk elde ederlerken, önerilen hibrit metasezgisel yapay sinir ağı modelinde %91,84 doğruluk elde etmişlerdir.

Anıl (2022), yaptığı çalışmada makine öğrenimi, derin öğrenme ve zaman serisi metotlarını kullanarak kurulu gücü yüksek beş jeotermal santralin toplam üretimini Mart ve Nisan aylarının birinci ve ikinci haftası için tahmin etmiştir. Daha sonra bu tahminleri ile gerçek değerlerle karşılaştırmış ve bu tahminler arasındaki fark için şirketlerin ödemesi gereken cezaları hesaplamıştır. Bu tahminleri, şirketlere ait santrallerin toplam jeotermal üretimi ile santrallerin bulunduğu şehirlere göre sıcaklık ve nem değişkenleri ana veri setleri kullanarak Mart ve Nisan aylarının birinci ve ikinci haftası için yapmıştır. Test ettiği tüm modellere ve tüm tahmin süreçlerine göre geleneksel makine öğrenme modelleri destek vektör regresyonu ve rastgele orman regresyonu (ROR), zaman serisi modelleri SARIMAX ve Prophet ve derin öğrenme modeli olan zamansal evrimsel ağların en iyi performansı gösterdiğini tespit etmiştir.

Ibrahim vd. (2023) yaptıkları çalışmada, Batı Anadolu bölgesindeki jeotermal sahaların rezervuar sıcaklığını tahmin etmek için çeşitli makine öğrenme modelleri geliştirmişlerdir. Bu modellerde rezervuar sıcaklığını tahmin etmek için giriş parametreleri olarak elektrik iletkenliği, pH değerleri, bazı iyonlar ve bileşiklerden oluşan bir hidrojeokimyasal veri tabanı kullanmışlardır. Geliştirilen modeller, doğal gradyan artırma, aşırı öğrenme makinesi, grup veri işleme yöntemi, genelleştirilmiş regresyon sinir ağı ve geri yayımlı sinir ağıdır. Değerlendirme ölçütleri ise RMSE, MAE ve R^2 değerleridir. Geliştirilen tüm modellerin rezervuar sıcaklığını tahminde makul bir performans sağladığını görmüşlerdir. Doğal gradyan artırma modelinin, sırasıyla 0,9959 ile en yüksek R^2 ve 4,5938 ve 3,9678 ile en düşük RMSE ve MAE değerlerini elde ettiklerinden, diğer makine öğrenme modellerine göre daha başarılı olduğunu tespit etmişlerdir.

Xue vd. (2023) yaptıkları çalışmada, Çin'deki Qiabuqia sahasındaki jeotermal elektriği tahmin etmek için sayısal simülasyonları ve makine öğrenme algoritmalarını birleştiren verilere dayalı modeller oluşturmuşlardır. Sayısal simülasyonların, dolaşımdaki suyun enjeksiyon hızı ve sıcaklığının, kırıkların sayısı ile yarı uzunluğunun ve kuyu aralığının jeotermal elektriği etkilediğini ve veriye dayalı modeller için girdi özellikleri olarak seçildiğini göstermişlerdir. Bu veri modelini, 1510 veriye sahip Grup A ve 755 veriye Grup B olarak ayırmışlar, bu veri setlerinden eğitim, doğrulama ve test veri setleri oluşturarak KEYK, DVM, XGBoost ve YSA algoritmalarında tahminler üretmişler ve daha sonra bu tahmin değerlerinin karşılaştırılmasını yapmışlardır. Karşılaştırma sonuçlarına göre, Grup A'daki tahmin doğruluğu sırasını $DVM \geq YSA > XGBoost > KEYK$, Grup B'deki ise $YSA > XGBoost \geq DVM > KEYK$, kararlılık açısından $YSA > DVM > XGBoost > KEYK$, uyarlanabilirlik açısından ise $YSA > KEYK > XGBoost > DVM$ şeklinde gözlemlemişlerdir. Sonuç olarak, jeotermal gelişimi tahmin etmede, KEYK'nin aşırı uyum nedeniyle, XGBoost ve DVM'nin ise bağlantısız olarak istenmeyen stabilite ve uyarlanabilirlik sundukları için uygulanamaz olduklarını, diğer yandan YSA'nın ise eğitim seti ile doğrulama seti arasındaki minimum hata performansı ile ($R^2=0,998$) en iyi istikrarı sağladığından daha uygulanabilir olduğunu tespit etmişlerdir.


Literatür arařtırmasında jeotermal enerji alanında makine öğrenmesi ve derin öğrenme metotları kullanılarak yapılmıř alıřmalar incelenmiřtir. Bu alıřmalardan jeotermal enerji santrallerinde regresyon analizi ile net gü tahmini üzerine yapılan alıřmaların sınırlı olduėu görölmektedir. Bu tez alıřmasında literatürdeki bu boşluėa dikkat çekmek istenmiřtir. Batı Anadolu Bölgesi'nde bulunan jeotermal enerji santralinin sistem parametreleri kullanılarak Python ortamında regresyon analizi yöntemleri ile net gü tahmini yapılmıř ve en yüksek performansa sahip model tespit edilmiřtir. Bu alıřma ile diėer tahmin algortimalarının yanında regresyon analizi yöntemlerinin de jeotermal enerji santrallerinde net gü tahmini için kullanılabileceėini göstermek amaçlanmıřtır.



[illegible]

49

Santralde Şekil 3.4’te görüldüğü gibi ortak bir gövde altında çalışan orta ve düşük basınç türbinleri ile bu gruptan bağımsız bir ünite olarak çalışan yüksek basınç türbini olmak üzere toplamda 3 adet türbin bulunmaktadır. Tüm bu türbin grupları tek bir şaft ile jeneratöre bağlanarak elektrik üretmektedir (Halaçoğlu 2015). Santralin türbin giriş sıcaklıkları ve buhar debileri Çizelge 3.1’de gösterilmiştir.



Şekil 3.4 Santral türbin kesiti ve yüksek ve orta/düşük basınç türbin rotorları (Serpen ve DiPippo 2020)

Çizelge 3.1 Türbinlerin giriş sıcaklıkları ve buhar debileri

Türbin	Giriş sıcaklığı (°C)	Buhar debisi (ton/saat)
Yüksek basınç	163	348
Orta basınç	132	175
Düşük basınç	101	101

Elektrik iletim kısmından kısaca bahsetmek gerekirse; buhar türbinleri ve ikili çevrim türbinlerinden elde edilen mekanik enerji jeneratörlerle elektrik enerjisine çevrilir. 15 kV olan jeneratör çıkış gerilimi yükseltici trafo ile 154 kV’a yükseltilir. Son olarak üretilen elektrik santral sahasındaki 154 kV Şalt Tesisi ve TEİAŞ elektrik iletim hatları aracılığıyla ulusal elektrik şebekesine verilir. Resim 3.1’de santralin genel görünümü verilmiştir.



Resim 3.1 Santralin genel görünümü (İnt.Kyn.14)


3.2 Jeotermal Elektrik Santraline Ait Veri Setleri

Jeotermal akışkan sıcaklığı ve debisi, jeotermal buharının debisi ve içerisindeki yoğuşmayan gazların oranı ve dış hava sıcaklığındaki değişimlere göre net elektrik üretimi değişir (Karadaş vd. 2013). Bu çalışmada, performansı etkileyen değişkenlerden oluşan istatistiksel tahmin modelleri oluşturulmuştur. Ancak, jeotermal su buharı ve NCG miktarı verileri mevcut olmadığından çalışmaya dâhil edilememiştir. Tez çalışması için santralden Ekim 2022-Eylül 2023 ayları arasında, bir yıla ait jeotermal akışkan sıcaklığı, akışkan debisi, hava sıcaklığı ve net güç günlük ortalama değerlerinden oluşan 1460 adet veri temin edilmiştir ve Ek 1’de verilmiştir. Çizelge 3.2’de ölçülebilen bağımsız değişkenler ile bağımlı değişken ve bunların minimum, maksimum, ortalama değerleri ve standart sapmaları verilmiştir.

Çizelge 3.2 Santral verilerinin istatistiksel özellikleri

Grup	Değişken	Birim	Min	Max	Ortalama	Std. Sapma
Bağımlı	Net Güç	MWh	86,07	118,93	108,55	5,93
Bağımsız	Akışkan Sıcaklığı	°C	166,43	168,19	166,82	0,27
Bağımsız	Hava Sıcaklığı	°C	2,6	33,9	18,63	7,83
Bağımsız	Akışkan Debisi	Ton/saat	4575	5695	5311,37	211

İlk olarak tüm bağımsız değişkenlerin normal dağılım gösterip göstermediği Şekil 3.5'teki grafikler ve Çizelge 3.3'teki Skewness-Kurtosis testi sonuçları incelenmiştir. Kurtosis ve Skewness değerleri -1.5 ile +1.5 olduğu zaman normal dağılım olduğu kabul edilmektedir (Tabachnick ve Fidell 2013). Python kodlarıyla elde edilen Çizelge 3.3'teki Skewness-Kurtosis normallik testi sonuçlarına göre hava sıcaklığı ve akışkan debisinin normal dağılım gösterdiği görülmektedir. Fakat akışkan sıcaklığı Kurtosis değerinden dolayı normal dağılım şartını ihlal etmektedir.



Şekil 3.5 Bağımsız değişkenlerin bağımlı değişkenle ilişkisi

Çizelge 3.3 Normallik testi sonuçları

Bağımsız Değişkenler	Skewness	Kurtosis
Akışkan Sıcaklığı	1,079	2,917
Hava Sıcaklığı	0,051	-1,014
Akışkan Debisi	-0,953	1,061

Şekil 3.5'teki grafiklerde kırmızı renkli işaretlenmiş uyumsuz değerler çıkarılarak tekrar Skewness-Kurtosis testi uygulanmış ve Çizelge 3.4'te görüldüğü gibi normallik şartı sağlanmıştır.

Çizelge 3.4 Uyumsuz değerler çıkarıldıktan sonraki normallik testi sonuçları

Bağımsız Değişkenler	Skewness	Kurtosis
Akışkan Sıcaklığı	0,251	-1,065
Hava Sıcaklığı	0,059	-0,989
Akışkan Debisi	-0,896	0,864

3.3 Python Kodları ile Regresyon Analizi

Normallik varsayımı sağlandıktan sonra kalan verilerle, Python kodu kullanarak ÇDR, PR, KAR, ROR ve GAR olmak üzere beş farklı regresyon modeli oluşturulmuştur. Python kodu oluşturmak için Idle, Spyder gibi editörler mevcut olsa da, 2017 yılında kullanıma sunulan Google Colab, makine öğrenimi ve derin öğrenme için kurulum gerektirmeyen ve ücretsiz kütüphaneleri nedeniyle tercih edilmiştir. Regresyon modellerini oluştururken kullanılan Python kodları Ek 2’de verilmiş olup kodların açıklaması başlıklar halinde anlatılmıştır.

3.3.1 Kütüphane ve Fonksiyonların Yüklenmesi

Sklearn, veri analizi, regresyon ve veri işleme gibi işlemleri gerçekleştirmeye yarayan çok fonksiyonlu bir kütüphanedir. Pandas farklı formattaki verilerin okunup yazılması için, numpy nümerik işlemler için, matplotlib.pyplot grafik oluşturmak için ve seaborn daha gelişmiş görselleştirmeler için kullanılan kütüphanelerdir. Sklearn.model_selection, farklı modeller arasında karşılaştırma yapmaya ve en iyi modeli seçmeye yarayan fonksiyonları içeren kütüphanedir. Bu kütüphanedeki fonksiyonlardan train_test_split veri kümelerini rastgele eğitim ve test setlerine ayırma, Kfold veri kümelerini k eşit büyüklükteki katmanlara ayırıp çapraz doğrulama yapma, GridSearchCV ise hiperparametre optimizasyonu gerçekleştirmeyi sağlar. Sklearn.linear_model, çoklu doğrusal regresyon modeli oluşturmak için, sklearn.preprocessing polinomal özellik oluşturma için, sklearn.tree karar ağaçları oluşturmak için ve sklearn.ensemble birden fazla makine öğrenmesi modelinin birleşimi olan toplu öğrenme yöntemini kullanarak rastgele orman ve gradyan artırma regresyon modellerini oluşturmak için kullanılan fonksiyonlardır. Sklearn.metrics, model performansını değerlendirmek için R^2 , MAE, MSE değerlerini hesaplamaya yarayan fonksiyondur.

3.3.2 Verilerin Yüklenmesi ve İşlenmesi

Santralden alınan veriler .csv formatına dönüştürülerek "jeothermal_veri.csv" adlı dosyaya kaydedilmiş ve içindeki veriler “data” isimli bir DataFrame'e aktarılmıştır. Daha sonra

akışkan debisi, akışkan sıcaklığı ve hava sıcaklığı bağımsız değişkenlerini içeren bir “X” veri kümesi ve net güç bağımlı değişkenini içeren bir “y” veri kümesi oluşturulmuştur. Daha sonra veriler %70 eğitim ve %30 test olacak şekilde rastgele iki parçaya bölünmüştür. Eğitim ve test verilerini ayırma işlemi, eğitildiği veri setine uyum sağlamaya zorlayarak modelin genelleme yeteneğini artırır.

3.3.3 Hiperparametre Optimizasyonu

Hiperparametre optimizasyonu, modellere ait parametrelerin bütün kombinasyonlarını deneyerek en iyi sonucu veren kombinasyonu seçme işlemidir. Bu parametreler: PR için polinomun derecesi ve yanlılık oluşturulup oluşturulmayacağı; KAR için maksimum derinlik, bir düğümün bölünmesi için gereken minimum veri noktası ve bir yaprağın minimum veri noktası; ROR için rastgele ormanda oluşturulacak karar ağaçlarının sayısı ve her bir karar ağacının maksimum derinliği ve GAR için zayıf öğrenenlerin sayısı, her zayıf öğrenenin modele katkı oranı ve her zayıf öğrenenin maksimum derinliğidir.

Daha sonra bu parametrelerle eğitim verisi üzerinde GridSearchCV fonksiyonu kullanılarak hiperparametre optimizasyonu yapılmış ve en iyi hiperparametreler “best_params” değişkenine atanmıştır.

3.3.4 Regresyon Modelleri Oluşturarak Tahmin Yapılması

Regresyon yöntemine göre “best_params” değişkenine atanan parametrelere göre eğitim verisi olarak ayrılmış veri setleri üzerinde eğitilerek modeller oluşturulmuştur. Bu modele eğitim seti ve test seti üzerinde tahminler yapılmıştır.

3.3.5 Gerçek ve Tahmini Değerlerin Regresyon Grafiğinde Gösterilmesi

Seaborn kütüphanesinin regplot fonksiyonu kullanılarak gerçekleşen net güç ile tahmini net güç arasındaki ilişki bir grafikte gösterilmiştir. Bu grafikte her gerçek üretim değerine denk gelen tahmini üretim değeri mavi noktalarla işaretlenerek oluşan dağılım ve regresyon çizgisi matplotlib kütüphanesi ile çizdirilmiştir.

3.3.6 Hata Ölçüm Parametrelerinin Hesaplanması

Eğitim ve test verilerinin ayrı ayrı R^2 , MAE, MSE ve RMSE değerleri hesaplatılarak karşılaştırma yapılmış ve aşırı uyum kontrolü sağlanmıştır.

3.3.7 K-Katlı Çapraz Doğrulama Yapılması

K-katlı çapraz doğrulama yöntemi aşırı uyum tespit edilen modellerde, veri seti k (5 ve 10) kata ayrılarak her katman farklı örnekler içerecek şekilde döngüler oluşturulmuştur. Buna göre model yeniden tasarlanmış ve her bir katın ortalama hata katsayıları elde edilmiştir.


4. BULGULAR

Bu bölümde Python kodları ile oluşturulan regresyon modellerinden elde edilen sonuçlar değerlendirilmiştir. Bu sonuçlar, hiperparametre optimizasyona göre elde edilen tahmini net güç değerleri ile gerçek net güç değerlerinin gösterildiği regresyon grafiği ve hata ölçüm parametreleri ile gösterilmiştir. Regresyon grafiğinde mavi noktalar test veri seti tahminlerine karşılık gelen gerçek net güç üretim verilerini, kırmızı çizgi ise regresyon çizgisini göstermektedir. Modellerde aşırı uyum olup olmadığını değerlendirmek amacıyla hata ölçüm parametreleri eğitim ve test verileri için ayrı ayrı hesaplanmıştır. Aşırı uyum tespit edilen modellere k-katlı çapraz doğrulama işlemi uygulanmıştır.

4.1 Regresyon Modellerinin Net Güç Tahmin Performansları

4.1.1 Çoklu Doğrusal Regresyon

ÇDR modelinin Şekil 4.1’de regresyon grafiği, Çizelge 4.1’de ise eğitim ve test verilerinin ayrı ayrı hata katsayıları verilmiştir.



Şekil 4.1 ÇDR modelinin tahmini ve gerçek net güç verilerinin regresyon grafiğindeki dağılımı


Çizelge 4.1’e göre bütün hata ölçüm parametreleri değerlendirildiğinde, test verileri ve eğitim verileri yakın değerlere sahip olduğundan aşırı uyum söz konusu değildir. Bu durumda k-katlı çapraz doğrulama yapmaya gerek yoktur.

Çizelge 4.1 ÇDR modelinin eğitim ve test setlerinin hata ölçüm parametreleri

Hata parametresi	Eğitim Seti	Test Seti
R^2	0,70	0,71
MAE	2,32	2,45
MSE	8,91	9,09
RMSE	2,98	3,01

4.1.2 Polinomal Regresyon

Hiperparametre optimizasyonu sonucunda polinom derecesi (poly_degree:2) ve yanlılık içirme (poly_include_bias:True) durumları elde edilmiştir ve bu parametrelere en uygun PR modeli seçilmiştir. Bu modelin Şekil 4.2’de regresyon grafiği verilmiştir.



Şekil 4.2 PR modelinin tahmini ve gerçek net güç verilerinin regresyon grafiğinde gösterimi


Çizelge 4.2’ye göre de aşırı uyum söz konusu değildir. Bu durumda k-katlı çapraz doğrulama yapmaya gerek yoktur.

Çizelge 4.2 PR modelinin eğitim ve test setlerinin hata ölçüm parametreleri

Hata parametresi	Eğitim Seti	Test Seti
R^2	0,73	0,74
MAE	2,25	2,31
MSE	8,09	7,93
RMSE	2,84	2,81

4.1.3 Karar Ağaçları Regresyonu

Hiperparametre optimizasyonu sonucunda maksimum derinlik (max_depth:16), bir düğümün bölünmesi için gereken minimum veri noktası (min_samples_leaf:1) ve bir yaprağın minimum veri noktası (min_samples_split:10) değerlerine ulaşılmıştır ve bu parametrelere en uygun KAR modeli seçilmiştir. Bu modelin Şekil 4.3’de regresyon grafiği verilmiştir.



Şekil 4.3 KAR modelinin tahmini ve gerçek net güç verilerinin regresyon grafiğinde gösterimi

Çizelge 4.3’e göre eğitim seti R^2 skoru 0,96 gibi oldukça yüksek bir değerken, test setinin R^2 skoru 0,80 eğitim setine göre düşük bir değerdir. Bu da modelin eğitim verisi dışında yeni verilere uyum sağlamakta zorlandığını gösterir. Hem eğitim hem de test setleri için MAE, MSE ve RMSE değerlerini karşılaştırdığımızda, test setindeki değerlerin eğitim setine göre belirgin şekilde yüksek olduğu görülmektedir. Bu durum, modelin eğitim verisi üzerindeki hatalarının test verisi üzerindeki hatalara göre çok daha düşük olduğunu bu da aşırı uyum olduğunu gösterir.


Çizelge 4.3 KAR modelinin eğitim ve test setlerinin hata ölçüm parametreleri

Hata parametresi	Eğitim Seti	Test Seti
R^2	0,96	0,80
MAE	0,53	1,85
MSE	1,13	6,25
RMSE	1,06	2,50

Aşırı uyumu engellemek için k-katlı çapraz doğrulama metoduna başvurulmuştur. Çizelge 4.4'te 5 ve 10 katlı çapraz doğrulama test verilerine ait katların ortalama hata ölçüm parametrelerini içeren değerler ve Şekil 4.4'te ise regresyon grafiği verilmiştir.

Çizelge 4.4 KAR modelinin 5 ve 10 katlı çapraz doğrulama ortalama hata ölçüm parametreleri

Hata parametresi	5 katlı	10 katlı
Ortalama R^2	0,70	0,75
Ortalama MAE	1,81	1,67
Ortalama MSE	9,98	7,66
Ortalama RMSE	2,95	2,65




Şekil 4.4 KAR modelinin 5 ve 10 katlı çapraz doğrulama regresyon grafiği

4.1.4 Rastgele Orman Regresyonu

Hiperparametre optimizasyonu sonucunda rastgele ormanda oluşturulacak karar ağaçlarının sayısı ($n_estimators:50$) ve her bir karar ağacının maksimum derinliği ($max_depth:16$) değerlerine ulaşılmıştır ve bu parametrelere en uygun ROR modeli seçilmiştir. Bu modelin Şekil 4.5'te regresyon grafiği verilmiştir.

Çizelge 4.5'e göre bu modelde de R^2 değerine bakıldığında göre eğitim seti test setinden daha yüksek ve MAE, MSE ve RMSE değerlerine bakıldığında ise, test seti değerlerinin eğitim setine göre belirgin şekilde yüksek olduğu görüldüğünden aşırı uyum söz konusudur.



Şekil 4.5 ROR modelinin tahmini ve gerçek net güç verilerinin regresyon grafiğinde gösterimi


Çizelge 4.5 ROR modelinin eğitim ve test setlerinin hata ölçüm parametreleri

Hata parametresi	Eğitim Seti	Test Seti
R^2	0,98	0,86
MAE	0,51	1,48
MSE	0,60	4,14
RMSE	0,77	2,03

Bu modelde de aşırı uyumu engellemek için k-katlı çapraz doğrulama metoduna başvurulmuştur. Çizelge 4.6’da 5 ve 10 katlı çapraz doğrulama test verilerine ait katların ortalama hata ölçüm parametrelerini içeren değerler ve Şekil 4.6’da ise regresyon grafiği verilmiştir.

Çizelge 4.6 ROR modelinin 5 ve 10 katlı çapraz doğrulama ortalama hata ölçüm parametreleri


Hata parametresi	5 Katlı	10 Katlı
Ortalama R^2	0,83	0,85
Ortalama MAE	1,44	1,38
Ortalama MSE	4,91	4,29
Ortalama RMSE	2,19	2,02



Şekil 4.6 ROR modelinin 5 ve 10 katlı çapraz doğrulama regresyon grafiği

4.1.5 Gradyan Artırma Regresyonu

Hiperparametre optimizasyonu sonucunda zayıf öğrenenlerin sayısı ($n_estimators:100$), her zayıf öğrenenin modele katkı oranı ($learning_rate:0,1$) ve her zayıf öğrenenin maksimum derinliği ($max_depth:4$) değerlerine ulaşılmıştır ve bu parametrelere en uygun GAR modeli seçilmiştir. Bu modelin Şekil 4.7’de regresyon grafiği ve Çizelge 4.7’de ise eğitim ve test verilerinin hata katsayıları verilmiştir.



Şekil 4.7 GAR modelinin tahmini ve gerçek net güç verilerinin regresyon grafiğinde gösterimi


Çizelge 4.7 GAR modelinin eğitim ve test setlerinin hata ölçüm parametreleri

Hata parametresi	Eğitim Seti	Test Seti
R^2	0,98	0,86
MAE	0,43	1,50
MSE	0,34	4,19
RMSE	0,59	2,04

Çizelge 4.7’de ROR modeline benzer skorlar olduğundan bu modelde de aşırı uyum gözlenmiş ve aşırı uyumu engellemek için k-katlı çapraz doğrulama metoduna başvurulmuştur. Çizelge 4.8’de 5 ve 10 katlı çapraz doğrulama test verilerine ait katların ortalama hata ölçüm parametrelerini içeren değerler ve Şekil 4.8’de regresyon grafiği verilmiştir.

Çizelge 4.8 GAR modelinin 5 ve 10 katlı çapraz doğrulama ortalama hata ölçüm parametreleri

Hata parametresi	5 Katlı	10 Katlı
Ortalama R^2	0,82	0,86
Ortalama MAE	1,53	1,43
Ortalama MSE	5,25	4,22
Ortalama RMSE	2,26	2,01



Şekil 4.8 GAR modelinin 5 ve 10 katlı çapraz doğrulama regresyon grafiği

4.2 Modellerinin Hata Parametrelerine Göre Performanslarının Karşılaştırılması

Çizelge 4.9’da modellerin test verilerine üç farklı şekilde elde edilen hata parametreleri gösterilmiştir. ÇDR ve PR modellerinde çapraz doğrulama yapılmadığından normal hata parametreleri; KAR, ROR ve GAR modellerinde ise 5 ve 10 katlı çapraz doğrulama hata

parametreleri kullanılmıştır.

Çizelge 4.9 Bütün modellerin hata ölçüm parametreleri

Hata par.	ÇDR	PR	KAR5	ROR5	GAR5	KAR10	ROR10	GAR10
R ²	0,71	0,74	0,70	0,83	0,82	0,75	0,85	0,86
MAE	2,45	2,31	1,81	1,44	1,53	1,67	1,38	1,43
MSE	9,09	7,93	9,98	4,91	5,25	7,66	4,29	4,22
RMSE	3,01	2,81	2,95	2,19	2,26	2,65	2,02	2,01

*Modellerin yanında yazan 5 ve 10 çapraz doğrulama kat sayısını göstermektedir.

Bu çizelgeye göre en iyiden en kötüye doğru hata parametrelerine göre performansları sırasıyla;

R² için GAR10 > ROR10 > ROR5 > GAR5 > KAR10 > PR > ÇDR > KAR5

MAE için ROR10 > GAR10 > ROR5 > GAR5 > KAR10 > KAR5 > PR > ÇDR

MSE için GAR10 > ROR10 > ROR5 > GAR5 > KAR10 > PR > KAR5 > ÇDR

RMSE için GAR10 > ROR10 > ROR5 > GAR5 > KAR10 > PR > KAR5 > ÇDR şeklindedir.

Sonuç olarak en iyi performansı 10 katlı çapraz doğrulama yöntemi kullanılan GAR ve ROR modelleri göstermiştir.

5. TARTIŞMA ve SONUÇ

5.1 Tartışma

Tez çalışmasında jeotermal enerji santrallerinin net güç miktarını tahmin etmek için farklı regresyon modellerini kullanarak en doğru tahmin yöntemini bulmak amaçlanmıştır. Bu amaca ulaşmak için Batı Anadolu’da bulunan bir jeotermal santralden günlük ortalama jeotermal akışkan sıcaklığı, akışkan debisi ve hava sıcaklığı ve net güç üretim verileri alınmıştır.

Literatür araştırmasında, jeotermal enerji alanında makine öğrenmesi ve derin öğrenme yöntemleri kullanılarak çeşitli çalışmalar yapılmış olsa da tez çalışmasındaki gibi jeotermal enerji santrallerinde net güç tahmini için regresyon analizi kullanılan sadece Karadaş vd. (2013) ve Martínez vd. (2019)’un çalışmaları olduğu görülmüştür.

Bu çalışmalar ile tez çalışması arasındaki benzerlikler ve farklılıklar şu şekilde sıralanmıştır:

- Tez çalışmasında, iki çalışmada olduğu gibi sistem parametrelerine göre regresyon analizi ile net güç tahmini yapılarak regresyon modellerinin performanslarının karşılaştırılması amaçlanmıştır. Buna ek olarak tez çalışmasında, Karadaş vd. (2013) ile aynı bağımsız değişkenler (jeotermal akışkan sıcaklığı, akışkan debisi ve hava sıcaklığı) ve bağımlı değişkenin (net güç) kullanıldığı görülmektedir.
- İki çalışma sırasıyla 8.412 ve 263.402 gibi çok büyük sayıda veri ile yapılmış olup buna karşılık tez çalışmasında 1.460 gibi görece daha az sayıda veri kullanılmıştır. Her iki çalışmada da R^2 değeri 0,99 olarak bulunmasına rağmen bu çalışmada en yüksek R^2 değeri 0,86 olarak bulunmuştur. Bu durumun veri sayıları arasındaki büyük farktan kaynaklandığı düşünülmektedir.
- Her iki çalışmada da klasik regresyon yöntemleri olan doğrusal ve logaritmik yöntemler kullanılmışken tez çalışmasında bu yöntemlere ek olarak daha gelişmiş regresyon yöntemleri olan KAR, ROR ve GAR kullanılmıştır.

Sonuç olarak literatür özeti incelendiğinde, jeotermal enerji alanında regresyon analizi ve

makine öğrenmesi yöntemlerinin kullanımı giderek yaygınlaştığı görülmektedir. Fakat jeotermal enerji santrallerinden alınan çok değişkenli veri setlerinden net güç tahmini için klasik regresyon yöntemleri dışında makine öğrenmesi yöntemi ile daha gelişmiş regresyon türlerinin kullanımı konusunda literatürde boşluk olduğu görülmüş ve tez çalışmasında bu boşluğa dikkat çekmek amaçlanmıştır.

5.2 Sonuçlar

Bu çalışmadan çıkarılan sonuçlar aşağıda sıralanmıştır:

- ÇDR modeli, değişkenler arasında doğrusal bir ilişki olduğunu varsayar. R^2 değerinin hem eğitim hem de test verileri için oldukça düşük olduğu görülmüştür (sırasıyla 0,70 ve 0,71). Bu durum, ÇDR modelinin kullanılan veri seti için yeterince uygun olmadığını dolayısıyla değişkenler arasındaki ilişkinin de doğrusal olmadığını gösterir.
- PR modeli, değişkenler arasında doğrusal olmayan, polinomal bir ilişki olduğunu varsayar. Ancak, PR modelinin performansı da ÇDR modeline benzer şekilde düşük çıkmıştır. R^2 değeri, hem eğitim hem de test verileri için sırasıyla 0,73 ve 0,74 olarak hesaplanmıştır. Bu sonuçlar, değişkenler arasındaki ilişkinin polinomal bir yapıda da tam olarak temsil edilemediğini göstermektedir.
- KAR modeli, verileri belirli kurallara göre bölerek tahminler yapar. Eğitim verilerinin R^2 değeri 0,96 iken, test verilerinin R^2 değeri 0,80 olarak hesaplanması modelin aşırı uyum yaptığını göstermektedir. 5 ve 10 katlı çapraz doğrulama test verilerinin ortalama R^2 değeri sırasıyla 0,70 ve 0,75 gibi düşük değerler olarak hesaplanmıştır. Bu durum, KAR modelinin de bu veri seti için uygun bir model olmadığına işaret etmektedir.
- ROR modeli, birden çok karar ağacını birleştirerek tahminler yaptığından aşırı uyumu azaltmada etkili olsa da bu modelde de eğitim verilerinin test verilerinden daha iyi performans göstermesi aşırı uyuma işaret etmektedir. 5 ve 10 katlı çapraz doğrulama ile test verilerinde ortalama R^2 değeri sırasıyla 0,83 ve 0,85 olarak hesaplandığından ROR modeli, KAR modeline göre daha iyi bir performans göstermiştir. Bu sonuçlara göre, ROR modelinin jeotermal santral performans tahmini için potansiyel bir model olduğu söylenebilir.

- GAR modeli, zayıf tahmin modelleri birleştirilerek güçlü bir tahmin modeli oluşturur. Bu çalışmada da aşırı uyum tespit edildiğinden 5 ve 10 katlı çapraz doğrulama uygulanmıştır. Test verilerinde ortalama R^2 değeri olarak sırasıyla 0,82 ve 0,86'ya ulaşıldığından GAR modeli en iyi performansı göstermiştir. Özellikle 10 katlı çapraz doğrulama ile elde edilen sonuçlar, GAR modelinin jeotermal santral performans tahmini için en uygun model olduğunu göstermektedir.

5.3 Öneriler

Bu tez çalışması, jeotermal enerji santrallerinin performans tahmini için regresyon analizinin kullanımını başarılı bir şekilde göstermiştir. Ancak, gelecekteki çalışmalarda daha iyi sonuçlar elde etmek ve modelin uygulanabilirliğini artırmak için aşağıdaki öneriler dikkate alınabilir:

- Mevcut çalışmada akışkan debisi, akışkan sıcaklığı ve hava sıcaklığı gibi temel parametreler kullanılmıştır. Net güç üretimini etkileyen yoğunlaşmayan gaz (NCG) oranı, buhar basıncı, türbin hızı, soğutma suyu sıcaklığı, re-enjeksiyon debisi ve basıncı, jeotermal akışkanın kimyasal bileşimi (pH, silika, vb.) gibi diğer faktörlerin de modele dahil edilmesi, tahmin doğruluğunu artırabilir. Ayrıca değişkenlerin ölçeklendirilmesi, normalleştirilmesi veya dönüştürülmesi gibi ön işleme teknikleri, model performansını iyileştirebilir. Bu teknikler ile aykırı değerlerin etkileri azaltılabilir ve değişkenler arasındaki ilişkiler daha net bir şekilde ortaya konulabilir.
- Bu çalışmada bir yıla ait günlük ortalama değerler kullanılmıştır. Daha uzun süreli ve daha sık aralıklarla toplanan veriler (örneğin saatlik veya dakikalık veriler), modelin daha iyi eğitilmesini ve daha doğru tahminler yapmasını sağlayabilir. Veri setinin, santralin farklı işletme koşullarını (yük değişimleri, bakım dönemleri, vb.) yansıtması önemlidir. Bu, modelin daha genelleştirici olmasını ve gerçek koşullarda daha iyi performans göstermesini sağlayacaktır.
- Bu çalışma, üç flaşlı+ikili çevrimli bir jeotermal santralin verileri üzerinde gerçekleştirilmiştir. Farklı tasarımlara sahip jeotermal santraller (kuru buhar, tek/çift flaşlı, ikili çevrimli, vb.) için de modeller geliştirilerek, modellerin farklı

santral tiplerine uygulanabilirliđi test edilebilir. Hatta ek olarak jeotermal enerjinin güneş, rüzgâr veya biyokütle gibi diğeryenilenebilir enerji kaynaklarıyla birlikte kullanıldıği hibrit santraller için de regresyon modelleri geliştirilebilir.

- Bu çalışmada beş farklı regresyon modeli kullanılmıştır. Diğery regresyon modelleri (Destek Vektör Regresyonu, K-En Yakın Komşu Regresyonu, XGBoost, LightGBM vb.) ve derin öğrenme modelleri de denenerek, daha uygun model belirlenebilir. Ayrıca model performansını artırmak için diğery hiperparametre optimizasyon teknikleri (Random Search, Bayesian Optimization vb.) kullanılabilir.
- Şu an gelişmekte olan enerji depolama sistemlerinin (termal enerji depolama, batarya depolama, hidrojen depolama vb.) jeotermal enerji santrallerine entegre edilmesinin etkisi de modele dahil edilebilir. Bu, depolama sistemlerinin santral performansına ve net güç üretimine olan etkisinin daha iyi anlaşılmasını sağlayacaktır. Enerji depolama sistemlerinin entegrasyonu ile tahmin imkânları genişletilebilir ve daha uzun vadeli net güç tahminleri yapılabilir.

Bu çalışmanın amacı, jeotermal enerji santrallerinin net güç miktarını en doğru şekilde tahmin etmektir. Bu tahminler, sistem işletmecileri için ulusal elektrik şebekesinin arz güvenilirliğini arttırarak kesinti riskini azaltmaya ve enerji üretimini optimize etmeye, yatırımcılar için ise jeotermal enerji projelerinin karlılığını daha doğru bir şekilde hesaplayarak yatırım kararlarını daha bilinçli bir şekilde vermesine yardımcı olacaktır.

6. KAYNAKLAR

- Adıyaman Ç, 2012, Türkiye'nin Yenilenebilir Enerji Politikaları, Niğde Üniversitesi, Sosyal Bilimler Enstitüsü, Yüksek Lisans Tezi, 146s, Niğde.
- Akkuş İ, Alan H, 2016 Türkiye'nin Jeotermal Kaynakları, Projeksiyonlar, Sorunlar ve Öneriler Raporu, TMMOB Jeoloji Mühendisleri Odası Rapor No: 123, Ankara.
- Aksoy N, 2014, Power Generation from Geothermal Resources in Turkey, Renewable Energy, 68, 595-601.
- Anıl H, 2022, Effects of Geothermal Production Prediction on the Energy Market with Artificial Intelligence Methods, Bahçeşehir Üniversitesi, Lisansüstü Eğitim Enstitüsü, Yüksek Lisans Tezi, 127p, İstanbul.
- Aslan S, Yıldız T, 2022, Makine Öğrenmesinde Rastgele Oran ve Sıralı Küme Örneklemesi Yöntemlerinin Doğrusal Regresyon Modellerine Etkisi, Dokuz Eylül Üniversitesi Mühendislik Fakültesi Fen ve Mühendislik Dergisi, 24, 29-36.
- Aziz M, Juangsa F B, 2021, Dry Steam Power Plant: Thermodynamic Analysis and System Improvement, Çolpan C O, Ezan M A, Kızıllan Ö (Ed.), Thermodynamic Analysis and Optimization of Geothermal Power Plants (97-110), Elsevier, 344p, USA.
- Başoğlu Y, Güler O V, Keçebaş A, 2021, Binary Geothermal Power Plant, Çolpan C O, Ezan M A, Kızıllan Ö (Ed.), Thermodynamic Analysis and Optimization of Geothermal Power Plants (113-129), Elsevier, 344p, USA.
- Bayrakçı H C, Çiçekdemir R S, Özkahraman M, 2021, Tarım Arazilerinde Harcanan Su Miktarını Yapay Zekâ Teknikleri Kullanarak Belirlenmesi, Düzce Üniversitesi Bilim ve Teknoloji Dergisi, 9, 237-250.
- Bloomquist R G, 2003, Geothermal Space Heating, Geothermics, 32, 513-526.
- Çelik S, Özdemir D, 2023, Rastgele Orman Regresyon Algoritması ile Bitcoin Fiyat Tahmini, Journal of Scientific Reports-B, 8, 55-64.
- DiPippo R, 2016, Geothermal Power Plants, Elsevier, 800p, USA.
- Erdoğan A, Küçüka S, 2019, Bir Jeotermal Enerji Santralinin Termodinamik Analizi ve

- Hava ve Su Soğutmalı Çevrim Performanslarının Değerlendirilmesi, 14. Ulusal Tesisat Mühendisliği Kongresi, 17-20 Nisan, İzmir, 183-194.
- Erdoğan S, 2015, Enerji Arz Güvenliği Bağlamında Türkiye'de Enerji Politikaları, Gazi Üniversitesi, Sosyal Bilimler Enstitüsü, Doktora Tezi, 255s, Ankara.
- Gabralı D, Aslan Z, 2020, Güneş Enerjisi Potansiyelinin Çoklu Lineer Regresyon ve Yapay Sinir Ağları ile Modellenmesi, Aurum Mühendislik Sistemleri ve Mimarlık Dergisi, 4, 23-36.
- Halaçoğlu U, 2015, Kızıldere-II Jeotermal Enerji Santrali'nin Performans Analizi, Yıldız Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, 81s, İstanbul.
- Harvey W, Wallace K, 2016, Flash Steam Geothermal Energy Conversion Systems: Single-, Double-, and Triple-Flash and Combined-Cycle Plants, Dipippo R (Ed.), Geothermal Power Generation Developments and Innovation (249-290), Elsevier, 854p, USA.
- He J, Li K, Wang X, Gao N, Mao X, Jia L, 2022, A Machine Learning Methodology for Predicting Geothermal Heat Flow in the Bohai Bay Basin, China, Natural Resources Research, 31, 237-260.
- Ibrahim B, Konduah J. O, Ahenkorah I, 2023, Predicting Reservoir Temperature of Geothermal Systems in Western Anatolia, Turkey: A Focus on Predictive Performance and Explainability of Machine Learning Models, Geothermics, 112, 1-14.
- Kanoğlu M, 2005, Jeotermal Elektrik Üretim Sistemleri ve Kojenarasyon, 7. Ulusal Tesisat Mühendisliği Kongresi, 23-26 Kasım, İzmir, 289-302.
- Karadaş M, Çelik M, Toksoy M, Gökçen G, 2013, Regresyon Analizi İle Bir Jeotermal Santralin Performans Modellemesi, 11. Ulusal Tesisat Mühendisliği Kongresi, 17-20 Nisan, İzmir, 197-209.
- Kassim N M, Santhiran S, Alkahtani A A, Islam M A, Tiong S K, Yusof M Y M, vd., 2023, An Adaptive Decision Tree Regression Modeling for the Output Power of Large-Scale Solar (LSS) Farm Forecasting, Sustainability 2023, 15, Article number 13521.

- Lund J W, Toth A N, 2021, Direct Utilization of Geothermal Energy 2020 Worldwide Review, *Geothermics* 90, Article number 101915.
- Mainar-Toledo M D, Halaçoğlu U, Sahiller H A, Hazar T, Zuffi C, Díaz-Ramírez M, vd., Environmental Benefits for a Geothermal Power Plant with CO₂ Reinjection: Case Study of the Kizildere 3 U1 Geothermal Power Plant, *Energy Storage and Saving*, 2, 631-638.
- Martínez E H, Carlos P A, Solís J I C, Avalos M C P, 2019, Thermodynamic Simulation and Mathematical Model for Single and Double Flash Cycles of Cerro Prieto Geothermal Power Plants, *Geothermics*, 83, Article number 101713.
- Mines G, 2016, Binary Geothermal Energy Conversion Systems: Basic Rankine, Dual-Pressure, And Dual-Fluid Cycles, DiPippo R (Ed.), *Geothermal Power Generation Developments and Innovation*, 353-389, 854p, Elsevier, USA.
- Moya D, Aldás C, Kaparaju P, 2018, Geothermal Energy: Power Plant Technology and Direct Heat Applications, *Renewable and Sustainable Energy Reviews*, 94, 889-901.
- Nuray S E, Gençdal H B, Arama Z A, 2021, Zeminlerin Kıvam ve Kompaksiyon Özelliklerinin Tahmininde Rastgele Orman Regresyonu Yönteminin Uygulanabilirliği, *Mühendislik Bilimleri ve Tasarım Dergisi*, 9, 265-281.
- Özbektaş S, Şenel M C, Sungur B, 2023, Dünyada ve Türkiye’de Yenilenebilir Enerji Durumu ve Kurulum Maliyetleri, *Mühendis ve Makina* 64, 711, 317-351.
- Pambudi N A, Ulfa D K, 2024, The Geothermal Energy Landscape in Indonesia: A Comprehensive 2023 Update on Power Generation, Policies, Risks, Phase and the Role of Education, *Renewable and Sustainable Energy Reviews*, 189, Article number 114008.
- Saud S, Jamil B, Upadhyaya Y, Irshad K, 2020, Performance Improvement of Empirical Models for Estimation of Global Solar Radiation in India: A K-Fold Cross-Validation Approach, *Sustainable Energy Technologies and Assessment*, 40, Article number 100768.
- Serpen Ü, DiPippo R, 2022, Turkey - A Geothermal Success Story: A Retrospective and Prospective Assessment, *Geothermics*, 101, Article number 102370.

- Shahdi A, Lee S, Karpatne A, Nojabaei B, 2021, Exploratory Analysis of Machine Learning Methods in Predicting Subsurface Temperature and Geothermal Gradient of Northeastern United States, *Geotherm Energy*, 9, Article number 18.
- Sircar A, Yadav K, Sahajpal S, 2016, Overview on Direct Applications of Geothermal Energy, *International Advanced Research Journal in Science, Engineering and Technology*, 3, 128-137.
- Spadacini C, Xodo L G, Quaia M, 2017, Geothermal Energy Exploitation with Organic Rankine Cycle Technologies, Macchi E, Astolfi M (Ed.), *Organic Rankine Cycle (ORC) Power Systems Technologies and Applications (473-524)*, Woodhead Publishing, 698, USA.
- Şener M F, Uzelli T, Akkuş İ, Mertoğlu O, Baba A, 2023, The Potential, Utilization and Development of Geothermal Energy in Türkiye, *Bulletin of the Mineral Research and Exploration*, 171, 69-90.
- Tabachnick, B G, Fidell, L S, 2013, *Using Multivariate Statistics*, Pearson Education, 983p, USA.
- TEİAŞ, 2023, Türkiye Elektrik İletim A.Ş. Kurulu Güç Ekim 2023 Raporu, Rapor No:58, 14s.
- Tezcan N, 2011, Parametrik Olmayan Regresyon Analizi, *Atatürk Üniversitesi İİBF Dergisi* 10. Ekonometri ve İstatistik Sempozyumu Özel Sayısı, 341-352.
- Topal F, 2019, Yenilenebilir Enerji Destekleme Mekanizmasının (YEKDEM) Elektrik Piyasalarına Olan Etkileri ve Sürdürülebilir Bir Model Önerisi, *Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi*, 101s, Afyonkarahisar.
- Tut Haklıdır F. S, Haklıdır M, 2019, Prediction of Reservoir Temperatures Using Hydrogeochemical Data, Western Anatolia Geothermal Systems (Turkey): A Machine Learning Approach, *Natural Resources Research*, 29, 2333-2346.
- Varol Altay E, Gürgeç E, Altay O, Dikici A, Hybrid Artificial Neural Network Based on a Metaheuristic Optimization Algorithm for the Prediction of Reservoir Temperature Using Hydrogeochemical Data of Different Geothermal Areas in Anatolia (Turkey), *Geothermics*, 104, Article number 102476.

- Yalcin M, Sarı F, Yıldız A, 2023, Exploration of Potential Geothermal Fields Using MAXENT and AHP: A Case Study of the Büyük Menderes Graben, Geothermics, 114, Article number 102792.
- Yıldırım Özcan N, Gökçen G, 2009, Jeotermal Elektrik Santralleri ve Gaz Alma Sistemleri, 9. Ulusal Tesisat Mühendisliği Kongresi, 6-9 Mayıs, İzmir, 171-190.
- Yıldız A, 2014, Jeotermal Enerji Kaynakları, Afyon Kocatepe Üniversitesi 3. Uluslararası Yenilenebilir Enerji Sistemleri Kış Okulu, 13-17 Ocak, Afyonkarahisar.
- Xue Z, Zhang K, Zhang C, Ma H, Chen Z, 2023, Comparative Data-Driven Enhanced Geothermal Systems Forecasting Models: A Case Study of Qiabuqia Field in China, Energy, 280, Article number 128255.

İnternet Kaynakları

- 1- <https://www.ultraenerji.com/yenilenebilir-enerji-2/yenilenebilir-enerji-cesitlerini-anlatiyoruz.html>, 5.12.2023
- 2- <https://ourworldindata.org/grapher/electricity-prod-source-stacked>, 6.12.2023
- 3- <https://ourworldindata.org/grapher/share-elec-by-source>, 7.12.2023
- 4- <https://www.teias.gov.tr/turkiye-elektrik-uretim-iletim-istatistikleri>, 28.12.2023
- 5- <https://enerji.gov.tr/eigm-yenilenebilir-enerji-uretim-faaliyetleri-yeka-modeli>, 28.12.2023
- 6- <https://www.thinkgeoenergy.com/geothermal/geothermal-energy-production-utilisation/>, 5.1.2024
- 7- <https://www.a2gov.org/departments/sustainability/Sustainability-Me/Families-Individuals/Pages/Geothermal.aspx>, 19.1.2024
- 8- <https://www.thinkgeoenergy.com/the-untapped-potential-of-geothermal-energy-a-personal-view/>, 19.1.2024
- 9- <https://www.thinkgeoenergy.com/thinkgeoenergys-top-10-geothermal-countries-2023-power-generation-capacity/>, 31.1.2024

10- <https://medium.com/kodluyoruz/makine-öğrenmesinde-overfitting-underfitting-best-fitting-kavramları-9f80a5d42719>, 20.2.2024

11- https://www.researchgate.net/figure/Diagram-of-k-fold-cross-validation-with-k-10-Image-from-Karl-Rosaen-Log_fig1_332370436, 4.3.2024

12- <https://aws.amazon.com/tr/what-is/python/>, 5.3.2024

13- <https://www.thinkgeoenergy.com/map/>, 16.03.2024

14- <https://babahaber.com/haber/14713983/zorlu-enerji-ilk-hibrit-enerji-santralini-devreye-alDI>, 17.3.2024



EKLER

EK 1. Veri setleri (Ekim 2022-Eylül 2023)

Akışkan debisi (Ton/saat)	Akışkan sıcaklığı (°C)	Hava sıcaklığı (°C)	Net güç (MWh)
5270	166,7645	26,6	108,10
5270	166,7221	25,8	109,90
5270	166,7311	22,9	113,45
5270	166,7401	21,6	112,98
5270	166,7914	19,9	114,10
5270	166,7857	20,8	112,52
5270	166,7799	19,4	111,26
5270	166,7760	20,1	113,87
5270	166,7529	19,9	112,25
5270	166,7298	20,7	108,17
5270	166,7337	20,9	107,82
5270	166,7394	20,3	111,70
5270	166,7452	19,5	112,22
5270	166,7144	18,8	112,26
5270	166,7086	18,2	111,52
5270	166,7028	18,9	111,58
5270	166,7067	21,0	111,16
5270	166,7028	20,9	111,90
5270	166,6990	19,8	111,71
5270	166,6874	19,2	111,15
5270	166,6874	18,9	113,00
5270	166,6874	15,3	115,27
5270	166,6990	14,7	115,45
5270	166,6971	17,7	114,62
5270	166,6951	17,7	114,78
5270	166,6913	17,6	114,41
5270	166,6874	18,4	113,26
5270	166,6836	19,3	112,54
5270	166,6605	17,6	113,94
5270	166,6547	15,5	115,44
5270	166,6489	15,6	115,02
5270	166,6219	16,5	115,01
5270	166,6123	16,3	114,55
5270	166,6027	16,1	115,00
5270	166,6142	16,9	114,05
5270	166,6219	17,5	113,17
5270	166,6296	16,5	113,24
5270	166,6219	14,4	111,64
5270	166,6200	14,4	112,72

5270	166,6181	13,9	113,26
5270	166,6027	13,3	113,04
5270	166,5911	13,1	113,28
5270	166,5796	13,5	113,07
5270	166,5969	13,7	112,67
5270	166,6142	12,8	113,15
5270	166,6296	11,7	113,73
5270	166,6200	12,5	112,93
5270	166,6104	14,0	111,80
5270	166,5873	17,7	109,25
5270	166,5815	21,4	107,13
5270	166,5757	18,6	108,80
5270	166,5873	19,7	108,44
5270	166,5796	15,4	109,60
5270	166,5719	13,3	110,47
5270	166,5565	13,3	110,46
5270	166,5584	11,4	110,70
5270	166,5603	11,8	111,81
5270	166,5796	8,8	113,30
5270	166,5892	9,3	112,55
5270	166,5988	10,6	111,73
5270	166,5834	11,4	110,50
5270	166,5738	11,4	109,76
5270	166,5642	12,0	109,57
5270	166,5642	12,9	109,54
5270	166,5661	12,1	110,06
5270	166,5680	11,3	109,95
5270	166,5410	10,6	110,83
5270	166,5391	7,9	111,92
5270	166,5372	8,9	111,17
5270	166,6014	11,8	109,50
5270	166,7760	12,3	109,09
5270	166,8146	17,6	107,04
5270	166,6553	17,2	106,41
5270	166,6117	16,2	106,75
5270	166,5680	13,5	107,33
5270	166,5372	13,1	106,95
5270	166,5237	15,7	90,88
5270	166,5102	13,8	106,21
5270	166,5064	13,1	107,09
5270	166,5237	12,1	107,50
5270	166,5410	10,8	109,94
5270	166,5526	6,6	111,49
5270	166,5468	6,6	111,20

5270	166,5410	7,7	110,56
5270	166,5410	10,0	109,96
5270	166,5545	10,2	110,42
4975	166,5680	9,2	110,72
4975	166,5680	7,0	110,79
4975	166,5545	7,7	111,24
4975	166,5410	8,0	110,76
4975	166,5064	8,5	109,89
4975	166,5044	9,9	109,97
4975	166,5025	9,2	110,17
4975	166,5102	7,2	111,09
4975	166,5141	6,4	111,62
4975	166,5179	6,4	111,63
4975	166,5256	7,6	111,06
4975	166,5256	7,5	111,05
4975	166,5256	7,6	110,30
4975	166,5372	6,8	111,40
4975	166,5199	6,2	111,75
4975	166,5025	8,6	107,82
4575	166,4910	10,4	99,48
4575	166,5064	9,4	91,64
4575	166,5218	9,7	106,06
4575	166,5218	10,2	105,89
4575	166,5353	10,5	105,04
4955	166,5487	9,0	108,40
4955	166,5179	11,8	108,01
4955	166,4871	17,0	104,98
4955	166,4621	15,3	106,73
4955	166,4370	10,6	108,49
4955	166,4428	13,9	109,52
4807	166,4486	12,4	110,80
4807	166,4910	10,3	109,74
4807	166,5680	9,8	110,33
4807	166,6836	9,0	112,33
4807	167,0842	8,7	112,37
4807	167,2383	10,1	111,74
4907	167,5157	7,0	112,01
4807	166,5911	8,9	112,27
4907	166,5565	7,0	114,52
5007	166,5719	5,3	116,24
5007	166,5873	4,0	86,07
5007	166,6258	3,8	114,77
5007	166,6335	4,0	115,33
4907	166,6412	3,5	116,37

4907	166,6528	3,5	117,11
4907	166,6528	5,6	117,50
4907	166,6528	5,2	116,22
4907	166,6451	3,6	116,35
4907	166,6431	3,3	115,86
4907	166,6412	4,1	115,91
4907	166,6489	2,6	115,58
5410	166,6489	5,3	116,44
5410	166,6489	5,3	116,70
5410	166,5796	5,1	116,70
5410	166,5449	6,5	116,23
5410	166,5102	5,8	115,84
5410	166,5064	7,4	115,45
5410	166,5102	9,0	114,29
5410	166,5141	10,6	113,43
5410	166,5218	11,8	112,79
5410	166,5256	11,6	112,58
5410	166,5295	11,9	112,67
5410	166,5102	12,8	111,89
5310	166,5083	12,9	111,69
5310	166,5064	15,1	110,55
5310	166,4948	15,0	110,76
5310	166,4794	17,7	109,82
5310	166,4640	17,8	108,27
5310	166,5565	18,5	107,97
5310	166,7683	15,5	108,30
5310	166,8877	14,4	108,88
5310	166,8839	11,6	109,72
5310	166,8800	11,2	108,66
5310	166,8762	12,0	108,54
5310	166,8877	11,3	108,99
5260	166,8993	13,5	109,23
5260	166,8646	14,5	111,37
5260	166,8608	15,5	110,35
5260	166,8569	18,5	109,42
5260	166,8762	14,5	110,35
5260	166,8890	12,2	112,02
5260	166,9019	11,3	112,92
5307	166,9609	12,9	113,20
5400	166,9977	13,8	112,45
5400	167,0346	12,5	114,40
5400	167,1466	12,0	114,24
5400	167,1925	14,1	113,73
5400	167,2383	13,6	111,74

5400	167,2267	14,4	112,54
5400	167,2036	15,0	106,58
5453	167,1805	14,4	112,26
5558	167,1690	15,6	114,95
5558	167,1767	15,9	115,40
5558	167,1844	16,9	115,48
5558	167,2075	17,9	115,53
5558	167,1979	16,3	115,56
5558	167,1882	9,6	118,93
5558	167,1343	7,9	115,97
5558	167,1401	10,6	118,52
5558	167,1458	16,4	115,59
5558	167,1536	20,1	114,19
5558	167,1381	20,2	115,37
5558	167,1227	17,7	115,19
5558	167,1093	15,3	112,86
5558	167,0958	12,2	116,32
5558	167,0996	13,0	116,73
5558	167,0958	12,3	116,70
5558	167,0919	15,6	115,04
5558	167,0765	12,9	115,24
5558	167,0669	11,8	116,17
5558	167,0572	12,2	116,25
5558	167,0457	14,0	115,73
5558	167,0322	16,9	114,40
5558	167,0187	18,5	114,08
5558	166,9763	19,1	114,01
5558	167,0842	19,6	113,60
5558	167,3192	19,0	114,07
5558	167,2999	18,8	113,87
5558	167,0842	17,2	114,00
5558	166,9725	18,5	113,94
5558	166,9783	18,1	114,12
5558	166,9841	15,5	113,42
5558	166,9956	15,3	114,88
5558	166,9995	17,8	115,21
5558	167,0033	18,5	114,38
5558	166,9802	17,5	113,82
5558	166,9667	14,8	113,29
5558	166,9532	13,5	116,36
5558	166,9532	14,3	115,91
5558	166,9532	17,2	114,30
5558	166,9532	20,0	112,65
5558	166,9532	21,6	112,07

5558	166,9532	19,1	110,73
5558	166,9532	16,9	110,04
5558	166,9494	16,0	111,72
5558	166,9359	17,1	110,00
5558	166,9224	19,6	109,22
5558	166,9186	19,6	108,87
5558	166,9282	20,7	108,84
5558	166,9378	19,1	108,25
5558	166,9263	18,2	108,13
5558	166,9243	18,6	108,62
5558	166,9224	20,3	109,58
5558	166,9301	23,0	106,66
5558	166,9340	25,8	102,04
5558	166,9378	22,2	107,76
5558	166,9455	20,5	108,73
5558	166,9398	16,7	109,33
5558	166,9340	20,5	108,99
5558	166,9224	21,7	108,74
5558	166,9224	20,5	107,22
5558	166,9224	18,3	106,31
5558	166,9224	18,4	107,04
5558	166,9186	20,4	106,87
5558	166,9147	22,4	105,10
5558	166,9301	21,9	104,99
5558	166,9340	19,6	107,05
5558	166,9378	19,8	107,21
5558	166,9378	19,7	104,68
5350	166,9301	19,9	104,21
5350	166,9224	22,1	104,82
5350	166,9070	20,4	103,49
5350	166,9166	20,9	103,96
5350	166,9263	21,2	103,30
5350	166,9301	23,5	103,75
5350	166,9320	24,7	103,02
5350	166,9340	26,2	102,34
5350	166,9378	23,5	102,53
5350	166,9378	23,1	103,05
5350	166,9378	25,2	103,05
5350	166,9494	25,0	105,05
5350	166,9552	23,6	104,92
5350	166,9609	21,4	103,53
5350	166,9648	23,3	104,79
5350	166,9686	26,1	104,55
5350	166,9686	25,5	104,04

5350	166,9686	22,9	105,19
5350	166,9686	21,9	104,38
5350	166,9571	22,8	103,71
5350	166,9552	25,6	104,20
5350	166,9532	26,6	104,14
5350	166,9417	27,1	104,04
5350	166,9359	27,7	105,13
5350	166,9301	27,9	105,67
5350	166,8377	28,6	104,18
5350	166,6123	29,2	102,43
5350	166,5372	29,3	102,13
5350	166,5487	28,7	101,91
5350	166,5584	27,6	103,01
5350	166,5680	27,7	103,29
5350	166,5680	27,1	103,45
5350	166,5738	28,6	102,61
5210	166,5796	28,9	96,18
5210	166,5834	30,0	95,24
5210	166,5834	30,0	92,63
5210	166,5834	26,8	96,31
5210	166,5834	29,1	97,03
5210	166,5776	29,6	97,30
5210	166,5719	27,2	98,45
5210	166,5642	26,7	99,36
5210	166,5584	28,1	98,48
5210	166,5526	29,8	98,28
5210	166,5603	30,5	97,02
5210	166,5603	32,9	97,52
5210	166,5603	33,4	96,09
5210	166,5295	32,6	96,79
5210	166,5141	31,9	96,58
5210	166,4987	32,0	96,46
5210	166,5256	31,9	96,82
5210	166,7041	31,9	97,38
5210	166,5295	32,7	95,47
5210	166,8646	33,4	96,91
5207	166,9070	33,9	96,56
5130	166,9109	31,9	93,47
5125	166,9263	31,3	95,83
5020	166,9417	31,6	92,93
5020	167,0072	30,6	90,76
5068	167,1458	28,7	93,97
5165	167,3308	28,7	98,63
5165	168,0909	29,3	98,07

5165	168,1975	29,9	97,00
5090	168,1012	29,5	94,90
5090	167,6569	29,7	95,87
5200	167,1458	30,1	97,05
5159	166,9956	30,9	94,34
5420	167,0110	30,9	101,42
5420	167,0110	29,9	102,58
5512	167,0110	28,3	107,45
5695	166,9995	29,8	109,83
5090	166,9918	29,1	108,79
5090	166,9841	27,8	108,75
5695	166,9571	28,7	110,26
5454	166,9552	29,0	102,65
5480	166,9532	29,0	102,87
5480	166,9532	29,2	102,87
5540	166,9532	29,9	101,38
5540	166,9532	30,2	100,77
5540	166,9532	31,6	100,54
5540	166,9494	31,6	99,74
5540	166,9455	30,8	100,63
5540	166,9301	30,5	100,97
5540	166,9455	31,4	103,83
5540	166,9609	31,6	103,49
5540	166,9706	31,5	103,57
5540	166,9802	30,4	101,60
5540	166,9609	30,5	103,86
5540	166,9475	29,7	104,28
5540	166,9340	26,0	103,98
5540	166,9378	27,5	105,15
5400	166,9378	27,9	105,19
5400	166,9378	28,1	103,27
5400	166,9802	27,7	105,49
5400	167,0714	27,5	105,91
5400	167,0406	27,3	106,52
5400	167,0097	26,5	105,88
5400	166,9757	24,0	106,95
5400	166,9417	24,2	106,88
5400	166,9686	27,4	105,86
5400	166,9860	27,6	104,22
5400	167,0033	27,7	104,52
5445	167,1478	27,4	106,08
5520	167,2354	27,0	108,48
5520	167,3231	26,4	101,10
5520	167,2938	24,9	109,79

5520	167,2776	24,9	110,77
5520	167,2614	24,6	110,83
5520	167,2267	25,5	110,58
5520	167,2287	26,0	111,13
5520	167,2306	26,2	109,00
5520	167,2113	26,3	108,55
5520	167,2036	24,9	111,11
5520	167,1959	24,5	111,29
5370	167,2075	24,8	112,87
5370	167,2287	25,2	113,21
5370	167,2499	26,9	111,80
5370	167,2383	26,8	111,83
5370	167,2190	26,9	111,17
5370	167,1998	26,0	110,60
5370	167,1767	23,6	109,86
5370	167,1670	23,3	108,45
5370	167,1574	22,9	109,47
5370	167,1536	22,5	108,65

EK 2. Python Kodları

Skewness-Kurtosis Testi

```
import pandas as pd
import scipy.stats as stats
# Verileri CSV dosyasından oku
data = pd.read_csv("jeotermal_veri.csv")
# İstenen sütunları seç
# (Verilerinizin sütun adlarını değiştirin)
veri_sutunlari = ["akiskan_debisi", "akiskan_sicakligi", "hava_sicakligi"]
veri = data[veri_sutunlari]
# Skewness ve kurtosis değerlerini hesapla
for sutun_adi in veri_sutunlari:
    skewness = stats.skew(veri[sutun_adi])
    kurtosis = stats.kurtosis(veri[sutun_adi])
    print(f'{sutun_adi} için skewness: {skewness:.3f}')
    print(f'{sutun_adi} için kurtosis: {kurtosis:.3f}')
```

Çoklu Doğrusal Regresyon

```
# Kütüphane ve fonksiyonların yüklenmesi
import pandas as pd
import matplotlib.pyplot as plt
import numpy as np
import seaborn as sns
from sklearn.model_selection import train_test_split
from sklearn.linear_model import LinearRegression
from sklearn.metrics import r2_score, mean_absolute_error, mean_squared_error
# Verileri yüklenmesi ve işlenmesi
data = pd.read_csv("jeotermal_veri.csv")
X = data[["akiskan_debisi", "akiskan_sicakligi", "hava_sicakligi"]]
y = data["net_guc"]
X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.3, random_state=42)
# Regresyon modeli oluşturularak tahmin yapılması
model = LinearRegression()
model.fit(X_train, y_train)
```

```

y_pred_train = model.predict(X_train)
y_pred_test = model.predict(X_test)
#Gerçek ve tahmini verinin regresyon grafiğinde gösterilmesi
g = sns.regplot(x=y_pred_test, y=y_test, scatter_kws={'color': 'b', 's': 9}, ci=False, color="r")
g.set_ylabel("Gerçekleşen net güç")
g.set_xlabel("Tahmini net güç")
plt.show()
# Hata ölçüm parametrelerinin hesaplanması
r2_train = r2_score(y_train, y_pred_train)
mae_train = mean_absolute_error(y_train, y_pred_train)
mse_train = mean_squared_error(y_train, y_pred_train)
rmse_train = np.sqrt(mean_squared_error(y_train, y_pred_train))
r2_test = r2_score(y_test, y_pred_test)
mae_test = mean_absolute_error(y_test, y_pred_test)
mse_test = mean_squared_error(y_test, y_pred_test)
rmse_test = np.sqrt(mean_squared_error(y_test, y_pred_test))
print("\nEğitim Seti Performansı:")
print("R2:", r2_train)
print("MAE:", mae_train)
print("MSE:", mse_train)
print("RMSE:", rmse_train)
print("\nTest Seti Performansı:")
print("R2:", r2_test)
print("MAE:", mae_test)
print("MSE:", mse_test)
print("RMSE:", rmse_test)
# Aşırı uyum kontrolü
if r2_test < r2_train:
    print("\nAşırı Uyum Olabilir!")
else:
    print("\nAşırı Uyum Belirtileri Yok.")

```

Polinomal Regresyon

```

# Kütüphane ve fonksiyonların yüklenmesi
import pandas as pd

```

```

import numpy as np
import seaborn as sns
import matplotlib.pyplot as plt
from sklearn.model_selection import train_test_split, GridSearchCV
from sklearn.preprocessing import PolynomialFeatures
from sklearn.linear_model import LinearRegression
from sklearn.metrics import r2_score, mean_absolute_error, mean_squared_error
from sklearn.pipeline import Pipeline

# Verileri yüklenmesi ve işlenmesi
data = pd.read_csv("jeotermal_veri.csv")
X = data[["akiskan_debisi", "akiskan_sicakligi", "hava_sicakligi"]]
y = data["net_guc"]
X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.3, random_state=42)

# Hiperparametre optimizasyonu
param_grid = { "poly__degree": [2, 3, 4], "poly__include_bias": [True, False]
grid_search = GridSearchCV(Pipeline([("poly", PolynomialFeatures()), ("linear",
LinearRegression())]), param_grid, scoring="r2", cv=5)
grid_search.fit(X_train, y_train)
best_params = grid_search.best_params_
best_score = grid_search.best_score_
print("En İyi Parametreler:")
print(best_params)
print("En İyi R2 Skoru:", best_score)

# Regresyon modeli oluşturularak tahmin yapılması
model = Pipeline([ ("poly", PolynomialFeatures(degree=best_params['poly__degree'],
include_bias=best_params['poly__include_bias'])), ("linear", LinearRegression())])
model.fit(X_train, y_train)
y_pred_train = model.predict(X_train)
y_pred_test = model.predict(X_test)

#Gerçek ve tahmini verinin aynı grafikte çizilmesi
g = sns.regplot(x=y_pred_test, y=y_test, scatter_kws={'color': 'b', 's': 9}, ci=False, color="r")
g.set_ylabel("Gerçekleşen net güç")
g.set_xlabel("Tahmini net güç")
plt.show()

# Hata ölçüm parametrelerinin hesaplanması

```

```

r2_train = r2_score(y_train, y_pred_train)
mae_train = mean_absolute_error(y_train, y_pred_train)
mse_train = mean_squared_error(y_train, y_pred_train)
rmse_train = np.sqrt(mean_squared_error(y_train, y_pred_train))
r2_test = r2_score(y_test, y_pred_test)
mae_test = mean_absolute_error(y_test, y_pred_test)
mse_test = mean_squared_error(y_test, y_pred_test)
rmse_test = np.sqrt(mean_squared_error(y_test, y_pred_test))
print("\nEğitim Seti Performansı:")
print("R2:", r2_train)
print("MAE:", mae_train)
print("MSE:", mse_train)
print("RMSE:", rmse_train)
print("\nTest Seti Performansı:")
print("R2:", r2_test)
print("MAE:", mae_test)
print("MSE:", mse_test)
print("RMSE:", rmse_test)
# Aşırı uyum kontrolü
if r2_test < r2_train:
    print("\nAşırı Uyum Olabilir!")
else:
    print("\nAşırı Uyum Belirtileri Yok.")

```

Karar Ağaçları Regresyonu

Kütüphane ve fonksiyonların yüklenmesi

```

import pandas as pd
from sklearn.model_selection import train_test_split, GridSearchCV
from sklearn.tree import DecisionTreeRegressor
from sklearn.metrics import r2_score, mean_absolute_error, mean_squared_error
import seaborn as sns
import numpy as np
import matplotlib.pyplot as plt
# Verileri yüklenmesi ve işlenmesi
data = pd.read_csv("jeothermal_veri.csv")

```

```

X = data[["akiskan_debisi", "akiskan_sicakligi", "hava_sicakligi"]]
y = data["net_guc"]
X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.3, random_state=42)
# Hiperparametre optimizasyonu
param_grid = { "max_depth": [4, 8, 16, 32], "min_samples_split": [2, 5, 10],
"min_samples_leaf": [1, 2, 4]}
grid_search = GridSearchCV(DecisionTreeRegressor(), param_grid, scoring="r2", cv=5)
grid_search.fit(X_train, y_train)
best_params = grid_search.best_params_
best_score = grid_search.best_score_
print("En İyi Parametreler:")
print(best_params)
print("En İyi R2 Skoru:", best_score)
# Regresyon modeli oluşturularak tahmin yapılması
model = DecisionTreeRegressor(**best_params)
model.fit(X_train, y_train)
y_pred_train = model.predict(X_train)
y_pred_test = model.predict(X_test)
#Gerçek ve tahmini verinin aynı grafikte çizilmesi
g = sns.regplot(x=y_pred_test, y=y_test, scatter_kws={'color': 'b', 's': 9}, ci=False, color="r")
g.set_ylabel("Gerçekleşen net güç")
g.set_xlabel("Tahmini net güç")
plt.show()
# Hata ölçüm parametrelerinin hesaplanması
r2_train = r2_score(y_train, y_pred_train)
mae_train = mean_absolute_error(y_train, y_pred_train)
mse_train = mean_squared_error(y_train, y_pred_train)
rmse_train = np.sqrt(mean_squared_error(y_train, y_pred_train))
r2_test = r2_score(y_test, y_pred_test)
mae_test = mean_absolute_error(y_test, y_pred_test)
mse_test = mean_squared_error(y_test, y_pred_test)
rmse_test = np.sqrt(mean_squared_error(y_test, y_pred_test))
print("\nEğitim Seti Performansı:")
print("R2:", r2_train)
print("MAE:", mae_train)

```

```

print("MSE:", mse_train)
print("RMSE:", rmse_train)

print("\nTest Seti Performansı:")
print("R2:", r2_test)
print("MAE:", mae_test)
print("MSE:", mse_test)
print("RMSE:", rmse_test)
# Aşırı uyum kontrolü
if r2_test < r2_train:
    print("\nAşırı Uyum Olabilir!")
else:
    print("\nAşırı Uyum Belirtileri Yok.")

```

Rastgele Orman Regresyonu

```

# Kütüphane ve fonksiyonların yüklenmesi
import pandas as pd
import seaborn as sns
import matplotlib.pyplot as plt
from sklearn.model_selection import train_test_split, GridSearchCV
from sklearn.ensemble import RandomForestRegressor
from sklearn.metrics import r2_score, mean_absolute_error, mean_squared_error
import numpy as np

# Verileri yüklenmesi ve işlenmesi
data = pd.read_csv("jeotermal_veri.csv")
X = data[["akiskan_debisi", "akiskan_sicakligi", "hava_sicakligi"]]
y = data["net_guc"]
X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.3, random_state=42)

# Hiperparametre optimizasyonu
param_grid = {"n_estimators": [50, 100, 200, 500], "max_depth": [4, 8, 16, 32]}
grid_search = GridSearchCV(RandomForestRegressor(), param_grid, scoring="r2", cv=5)
grid_search.fit(X_train, y_train)
best_params = grid_search.best_params_
best_score = grid_search.best_score_
print("En İyi Parametreler:")

```

```

print(best_params)
print("En İyi R2 Skoru:", best_score)
# Regresyon modeli oluşturularak tahmin yapılması
model = RandomForestRegressor(**best_params)
model.fit(X_train, y_train)
y_pred_train = model.predict(X_train)
y_pred_test = model.predict(X_test)
#Gerçek ve tahmini verinin aynı grafikte çizilmesi
g = sns.regplot(x=y_pred_test, y=y_test, scatter_kws={'color': 'b', 's': 9}, ci=False, color="r")
g.set_ylabel("Gerçekleşen net güç")
g.set_xlabel("Tahmini net güç")
plt.show()
# Hata ölçüm parametrelerinin hesaplanması
r2_train = r2_score(y_train, y_pred_train)
mae_train = mean_absolute_error(y_train, y_pred_train)
mse_train = mean_squared_error(y_train, y_pred_train)
rmse_train = np.sqrt(mean_squared_error(y_train, y_pred_train))
r2_test = r2_score(y_test, y_pred_test)
mae_test = mean_absolute_error(y_test, y_pred_test)
mse_test = mean_squared_error(y_test, y_pred_test)
rmse_test = np.sqrt(mean_squared_error(y_test, y_pred_test))
print("\nEğitim Seti Performansı:")
print("R2:", r2_train)
print("MAE:", mae_train)
print("MSE:", mse_train)
print("RMSE:", rmse_train)
print("\nTest Seti Performansı:")
print("R2:", r2_test)
print("MAE:", mae_test)
print("MSE:", mse_test)
print("RMSE:", rmse_test)
# Aşırı uyum kontrolü
if r2_test < r2_train:
    print("\nAşırı Uyum Olabilir!")
else:

```



```
print("\nAşırı Uyum Belirtileri Yok.")
```

Gradyan Artırma Regresyonu

```
# Kütüphane ve fonksiyonların yüklenmesi
```

```
import pandas as pd
```

```
import seaborn as sns
```

```
import matplotlib.pyplot as plt
```

```
from sklearn.model_selection import train_test_split, GridSearchCV
```

```
from sklearn.ensemble import GradientBoostingRegressor
```

```
from sklearn.metrics import r2_score, mean_absolute_error, mean_squared_error
```

```
import numpy as np
```

```
# Verileri yüklenmesi ve işlenmesi
```

```
data = pd.read_csv("jeotermal_veri.csv")
```

```
X = data[["akiskan_debisi", "akiskan_sicakligi", "hava_sicakligi"]]
```

```
y = data["net_guc"]
```

```
X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.3, random_state=42)
```

```
# Hiperparametre optimizasyonu
```

```
param_grid = { "n_estimators": [50, 100, 200], "learning_rate": [0.01, 0.05, 0.1],
```

```
"max_depth": [4, 8, 16]}
```

```
grid_search = GridSearchCV(GradientBoostingRegressor(), param_grid, scoring="r2", cv=5)
```

```
grid_search.fit(X_train, y_train)
```

```
best_params = grid_search.best_params_
```

```
best_score = grid_search.best_score_
```

```
print("En İyi Parametreler:")
```

```
print(best_params)
```

```
print("En İyi R2 Skoru:", best_score)
```

```
# Regresyon modeli oluşturularak tahmin yapılması
```

```
model = GradientBoostingRegressor(**best_params)
```

```
model.fit(X_train, y_train)
```

```
y_pred_train = model.predict(X_train)
```

```
y_pred_test = model.predict(X_test)
```

```
#Gerçek ve tahmini verinin aynı grafikte çizilmesi
```

```
g = sns.regplot(x=y_pred_test, y=y_test, scatter_kws={'color': 'b', 's': 9}, ci=False, color="r")
```

```
g.set_ylabel("Gerçekleşen net güç")
```

```
g.set_xlabel("Tahmini net güç")
```

```

plt.show()
# Hata ölçüm parametrelerinin hesaplanması
r2_train = r2_score(y_train, y_pred_train)
mae_train = mean_absolute_error(y_train, y_pred_train)
mse_train = mean_squared_error(y_train, y_pred_train)
rmse_train = np.sqrt(mean_squared_error(y_train, y_pred_train))
r2_test = r2_score(y_test, y_pred_test)
mae_test = mean_absolute_error(y_test, y_pred_test)
mse_test = mean_squared_error(y_test, y_pred_test)
rmse_test = np.sqrt(mean_squared_error(y_test, y_pred_test))
print("\nEğitim Seti Performansı:")
print("R2:", r2_train)
print("MAE:", mae_train)
print("MSE:", mse_train)
print("RMSE:", rmse_train)
print("\nTest Seti Performansı:")
print("R2:", r2_test)
print("MAE:", mae_test)
print("MSE:", mse_test)
print("RMSE:", rmse_test)
# Aşırı uyum kontrolü
if r2_test < r2_train:
    print("\nAşırı Uyum Olabilir!")
else:
    print("\nAşırı Uyum Belirtileri Yok.")

```

Karar Ağaçları Regresyonu için K-Katlı Çapraz Doğrulama

```

import pandas as pd
from sklearn.model_selection import train_test_split, KFold
from sklearn.tree import DecisionTreeRegressor
from sklearn.metrics import r2_score, mean_absolute_error, mean_squared_error
import numpy as np
import seaborn as sns
import matplotlib.pyplot as plt
data = pd.read_csv("jeothermal_veri.csv")

```

```

X = data[["akiskan_debisi", "akiskan_sicakligi", "hava_sicakligi"]]
y = data["net_guc"]
# K-Katlı Çapraz Doğrulama
k = 5/10 # K değerinin hangisi kullanılacaksa o değer yazılır
r2_scores = []
mae_scores = []
mse_scores = []
rmse_scores = []
# K-katlı çapraz doğrulama için döngü
for train_index, test_index in KFold(n_splits=k, shuffle=True, random_state=42).split(X):
    X_train, X_test = X.iloc[train_index], X.iloc[test_index]
    y_train, y_test = y.iloc[train_index], y.iloc[test_index]
    model = DecisionTreeRegressor()
    model.fit(X_train, y_train)
    y_pred = model.predict(X_test)
    r2_score_ = r2_score(y_test, y_pred)
    mae_test = mean_absolute_error(y_test, y_pred)
    mse_test = mean_squared_error(y_test, y_pred)
    rmse_test = np.sqrt(mean_squared_error(y_test, y_pred))
    r2_scores.append(r2_score_)
    mae_scores.append(mae_test)
    mse_scores.append(mse_test)
    rmse_scores.append(rmse_test)
# Ortalama Hata katsayılarını Hesaplama
ortalama_r2_score = sum(r2_scores) / len(r2_scores)
ortalama_mae = sum(mae_scores) / len(mae_scores)
ortalama_mse = sum(mse_scores) / len(mse_scores)
ortalama_rmse = sum(rmse_scores) / len(rmse_scores)
g = sns.regplot(x=y_pred, y=y_test, scatter_kws={'color': 'b', 's': 9}, ci=False, color="r")
g.set_ylabel("Gerçekleşen net güç")
g.set_xlabel("Tahmini net güç")
plt.title("5/10 Katlı Çapraz Doğrulama")
plt.show()
print("K Katlı Çapraz Doğrulama R2 Skorları:", r2_scores)
print(f"Ortalama R-kare Değeri (KAR): {ortalama_r2_score:.3f}")

```

```

print(f"Ortalama MAE: {ortalama_mae:.3f}")
print(f"Ortalama MSE: {ortalama_mse:.3f}")
print(f"Ortalama RMSE: {ortalama_rmse:.3f}")

```

Rastgele Orman Regresyonu için K-Katlı Çapraz Doğrulama

```

import pandas as pd
from sklearn.model_selection import train_test_split, KFold
from sklearn.ensemble import RandomForestRegressor
from sklearn.metrics import r2_score, mean_absolute_error, mean_squared_error
import numpy as np
import seaborn as sns
import matplotlib.pyplot as plt

data = pd.read_csv("jeotermal_veri.csv")
X = data[["akiskan_debisi", "akiskan_sicakligi", "hava_sicakligi"]]
y = data["net_guc"]

# K-Katlı Çapraz Doğrulama
k = 5/10 # K değeri (kat sayısı)
r2_scores = []
mae_scores = []
mse_scores = []
rmse_scores = []

# K-katlı çapraz doğrulama için döngü
for train_index, test_index in KFold(n_splits=k, shuffle=True, random_state=42).split(X):
    X_train, X_test = X.iloc[train_index], X.iloc[test_index]
    y_train, y_test = y.iloc[train_index], y.iloc[test_index]

    model = RandomForestRegressor()
    model.fit(X_train, y_train)
    y_pred = model.predict(X_test)

    r2_score_ = r2_score(y_test, y_pred)
    mae_test = mean_absolute_error(y_test, y_pred)
    mse_test = mean_squared_error(y_test, y_pred)
    rmse_test = np.sqrt(mean_squared_error(y_test, y_pred))

    r2_scores.append(r2_score_)
    mae_scores.append(mae_test)
    mse_scores.append(mse_test)

```

```

rmse_scores.append(rmse_test)
# Ortalama R-kare Değerini Hesaplama
ortalama_r2_score = sum(r2_scores) / len(r2_scores)
ortalama_mae = sum(mae_scores) / len(mae_scores)
ortalama_mse = sum(mse_scores) / len(mse_scores)
ortalama_rmse = sum(rmse_scores) / len(rmse_scores)

g = sns.regplot(x=y_pred, y=y_test, scatter_kws={'color': 'b', 's': 9}, ci=False, color="r")
g.set_ylabel("Gerçekleşen net güç")
g.set_xlabel("Tahmini net güç")
plt.title("5/10 Katlı Çapraz Doğrulama")
plt.show()
print("K Katlı Çapraz Doğrulama R2 Skorları:", r2_scores)
print(f"Ortalama R-kare Değeri (ROR): {ortalama_r2_score:.3f}")
print(f"Ortalama MAE: {ortalama_mae:.3f}")
print(f"Ortalama MSE: {ortalama_mse:.3f}")
print(f"Ortalama RMSE: {ortalama_rmse:.3f}")

```

Gradyan Artırma Regresyonu için K-Katlı Çapraz Doğrulama

```

import pandas as pd
from sklearn.model_selection import train_test_split, KFold
from sklearn.ensemble import GradientBoostingRegressor
from sklearn.metrics import r2_score, mean_absolute_error, mean_squared_error
import numpy as np
import seaborn as sns
import matplotlib.pyplot as plt
data = pd.read_csv("jeothermal_veri.csv")
X = data[["akiskan_debisi", "akiskan_sicakligi", "hava_sicakligi"]]
y = data["net_guc"]
# K-Katlı Çapraz Doğrulama
k = 10 # K değeri (kat sayısı)
r2_scores = []
mae_scores = []
mse_scores = []
rmse_scores = []

```

```

# K-katlı çapraz doğrulama için döngü
for train_index, test_index in KFold(n_splits=k, shuffle=True, random_state=42).split(X):
    X_train, X_test = X.iloc[train_index], X.iloc[test_index]
    y_train, y_test = y.iloc[train_index], y.iloc[test_index]
    model = GradientBoostingRegressor()
    model.fit(X_train, y_train)
    y_pred = model.predict(X_test)
    r2_score_ = r2_score(y_test, y_pred)
    mae_test = mean_absolute_error(y_test, y_pred)
    mse_test = mean_squared_error(y_test, y_pred)
    rmse_test = np.sqrt(mean_squared_error(y_test, y_pred))
    r2_scores.append(r2_score_)
    mae_scores.append(mae_test)
    mse_scores.append(mse_test)
    rmse_scores.append(rmse_test)
# Ortalama R-kare Değerini Hesaplama
ortalama_r2_score = sum(r2_scores) / len(r2_scores)
ortalama_mae = sum(mae_scores) / len(mae_scores)
ortalama_mse = sum(mse_scores) / len(mse_scores)
ortalama_rmse = sum(rmse_scores) / len(rmse_scores)
g = sns.regplot(x=y_pred, y=y_test, scatter_kws={'color': 'b', 's': 9}, ci=False, color="r")
g.set_ylabel("Gerçekleşen net güç")
g.set_xlabel("Tahmini net güç")
plt.title("5 Katlı Çapraz Doğrulama")
plt.show()
print("K Katlı Çapraz Doğrulama R2 Skorları:", r2_scores)
print(f"Ortalama R-kare Değeri (GAR): {ortalama_r2_score:.3f}")
print(f"Ortalama MAE: {ortalama_mae:.3f}")
print(f"Ortalama MSE: {ortalama_mse:.3f}")
print(f"Ortalama RMSE: {ortalama_rmse:.3f}")

```