

**T.C.
PAMUKKALE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
MAKİNA MÜHENDİSLİĞİ ANABİLİM DALI**

**DERİN YAPAY SİNİR AĞLARINI UYGUNLUK
FONKSİYONU OLARAK KULLANAN GENETİK
ALGORİTMA İLE JEOTERMAL SİSTEMLERİN OPTİMİZE
EDİLMESİ**

DOKTORA TEZİ

ÖZGÜR ÖZER

DENİZLİ, OCAK - 2025

**T.C.
PAMUKKALE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
MAKİNA MÜHENDİSLİĞİ ANABİLİM DALI**



**DERİN YAPAY SİNİR AĞLARINI UYGUNLUK
FONKSİYONU OLARAK KULLANAN GENETİK
ALGORİTMA İLE JEOTERMAL SİSTEMLERİN OPTİMİZE
EDİLMESİ**

DOKTORA TEZİ

ÖZGÜR ÖZER

DENİZLİ, OCAK - 2025

Bu tezin tasarımı, hazırlanması, yürütülmesi, arařtırmalarının yapılması ve bulgularının analizlerinde bilimsel etięe ve akademik kurallara özenle riayet edildiđini; bu alıřmanın doğrudan birincil ürünü olmayan bulguların, verilerin ve materyallerin bilimsel etięe uygun olarak kaynak gösterildiđini ve alıntı yapılan alıřmalara atfedildiđine beyan ederim.

ÖZGÜR ÖZER

ÖZET

DERİN YAPAY SİNİR AĞLARINI UYGUNLUK FONKSİYONU OLARAK KULLANAN GENETİK ALGORİTMA İLE JEOTERMAL SİSTEMLERİN OPTİMİZE EDİLMESİ

DOKTORA TEZİ
ÖZGÜR ÖZER

PAMUKKALE ÜNİVERSİTESİ FEN BİLİMLERİ ENSTİTÜSÜ
MAKİNA MÜHENDİSLİĞİ ANABİLİM DALI

(TEZ DANIŞMANI: PROF. DR. HARUN KEMAL ÖZTÜRK)

DENİZLİ, OCAK - 2025

Bu çalışmada, jeotermal enerji santrallerine genel bir bakış sunulmuş ve kullanılan optimizasyon yöntemleri özetlenmiştir. Bu optimizasyon yöntemlerinden olan sezgisel yöntemlerin avantajları ve geliştirilen modellerin sonuçları açıklanmıştır. Jeotermal sistemlerin optimizasyonundaki zorluklar, özellikle bu sistemlerin optimizasyonu için çok sayıda parametrenin kullanımı ve sistemlerin karmaşıklığından kaynaklanan sınırlamalar da ele alınmıştır. Sezgisel yöntemler, son dönemde yaygın olarak kullanılan yapay sinir ağları ve genetik algoritmalar genel hatlarıyla açıklanmıştır. Bu tez kapsamında İzmir ilindeki bir ORC jeotermal enerji santraline ait işletme verileri kullanılarak yenilikçi bir optimizasyon yöntemi geliştirilmiştir. Genetik algoritmada uygunluk fonksiyonu olarak yapay sinir ağlarını kullanan hesaplama yöntemi ile brüt güç 4.943 kW değerinden 6.624 kW değerine getirilerek optimum işletme şartları geliştirilmiştir. Sonuç olarak net güç çıktısında %39,41'lik bir artış sağlanmıştır. Farklı senaryolar da incelenerek geliştirilen özgün hesaplama yönteminin jeotermal sistemlerin optimizasyonunda kullanılabileceği açıklanmıştır.

ANAHTAR KELİMELER: Enerji, Jeotermal Enerji, Optimizasyon, Yapay Sinir Ağları, Genetik Algoritma

Metin girmek için burayı tıklatın.

ABSTRACT

OPTIMIZATION OF GEOTHERMAL SYSTEMS WITH GENETIC ALGORITHM USING DEEP NEURAL NETWORK AS THE FITNESS FUNCTION

PH.D THESIS

ÖZGÜR ÖZER

**PAMUKKALE UNIVERSITY INSTITUTE OF SCIENCE
MECHANICAL ENGINEERING**

(SUPERVISOR:PROF. DR. HARUN KEMAL ÖZTÜRK)

DENİZLİ, JANUARY 2025

This study presents a comprehensive analysis of geothermal power plants and provides a systematic review of the optimization methodologies employed in their operation. Particular emphasis is placed on heuristic optimization techniques, detailing their advantages and the outcomes derived from the developed models. The inherent challenges associated with geothermal system optimization specifically, the constraints arising from system complexity and the necessity of integrating numerous parameters are critically examined. Furthermore, heuristic approaches, including artificial neural networks and genetic algorithms, which have gained significant traction in recent research, are systematically outlined. Within the scope of this research, an advanced optimization methodology was developed utilizing operational data from an Organic Rankine Cycle (ORC) geothermal power plant in İzmir. By incorporating artificial neural networks as a fitness function within a genetic algorithm, the proposed computational framework successfully enhanced the gross power output from 4.943 kW to 6.624 kW, thereby determining the optimal operating conditions. Consequently, a 39.41% increase in net power output was achieved. Additionally, multiple operational scenarios were analyzed, demonstrating the efficacy and applicability of the proposed computational approach in optimizing geothermal energy systems.

KEYWORDS: Energy, Geothermal Energy, Optimization, Artificial Neural Networks, Genetic Algorithm

İÇİNDEKİLER

Sayfa

ÖZET	i
ABSTRACT	ii
İÇİNDEKİLER	iii
ŞEKİL LİSTESİ	iv
TABLO LİSTESİ	v
SEMBOL LİSTESİ	vi
ÖNSÖZ	vii
1. GİRİŞ	1
1.1 Jeotermal Enerji Santralleri ve Kullanılan Çevrim Tipleri.....	3
1.1.1 Kuru Buhar Çevrimi	4
1.1.2 Tek ve Çift Flaşlı Çevrimler	5
1.1.3 İkili (binary) Tip Çevrim	6
1.2 Jeotermal Santrallerin Optimizasyonu	8
1.3 Yapay Sinir Ağları.....	8
1.4 Genetik Algoritma	9
2. LİTERATÜR ÖZETİ	12
3. MATERYAL	21
3.1 Python Programlama Dili	21
3.1.1 Yapay Sinir Ağı ve Genetik Algoritmada Kullanılan Kütüphaneler	22
3.2 Veri Seti.....	24
3.3 Jeotermal Enerji Santrali Tasarım ve İşletme Bilgileri	27
4. METOT	32
4.1 Derin Yapay Sinir Ağlarının Modellenmesi	33
4.1.1 DSA Modelinin Yapılandırılması	38
4.1.2 Hiperparametre Ayarları	44
4.1.3 Eğitim ve Test Süreçleri	46
4.2 Genetik Algoritma Modeli	48
4.2.1 Uygulama Süreci.....	52
4.3 Modelin Değerlendirilmesi.....	53
4.4 Termodinamik Analiz Yöntemi ve ORÇ Verileri	53
5. BULGULAR	60
6. SONUÇ VE ÖNERİLER	92
7. KAYNAKLAR	95
8. ÖZGEÇMİŞ	101

ŞEKİL LİSTESİ

Sayfa

Şekil 1.1: Kuru buhar çevrimli jeotermal enerji santrali şeması (Şahin 2016)...	4
Şekil 1.2: Tek flaşlı çevrim diyagramı (Coşkun 2011).....	6
Şekil 1.3: Çift flaşlı çevrim diyagramı (Coşkun 2011).....	6
Şekil 1.4: İkili tip santralin çevrim diyagramı	7
Şekil 2.1: Genetik algoritma optimizasyon diyagramı	17
Şekil 2.2: Yapay sinir ağları yapısı şematik gösterimi	19
Şekil 3 1: Verileri kullanılan santralin ısı ve kütle diyagramı	29
Şekil 4 1: Sinir hücresinin matematiksel gösterimi (URL 4)	34
Şekil 4 2: Tek ve çok katmanlı sinir ağları (URL 4)	35
Şekil 4 3: Çok katmanlı sinir ağının yapısı (Ling ve diğ. 2024)	36
Şekil 4 4: Derin Yapay Sinir Ağının Modeli	39
Şekil 4 5: ReLU fonksiyonu grafik gösterimi	41
Şekil 4 6: ORÇ Pompa basma hattı sıcaklık göstergesi.....	54
Şekil 4 7: ORÇ Reküperatör basma hattı sıcaklık göstergesi	55
Şekil 4 8: ORÇ AB buharlaştırıcı girişi sıcaklık göstergesi	56
Şekil 4 9: ORÇ AB buharlaştırıcı girişi sıcaklık göstergesi	57
Şekil 5 1: Korelasyon matrisi	61
Şekil 5 2: Santral ısı ve kütle diyagramı	65
Şekil 5 3: Santral ORÇ SCADA ekran görüntüsü	77
Şekil 5 4: Santral brine ve buhar SCADA ekran görüntüsü	77
Şekil 5 5: DYSA öğrenme süreci.....	80
Şekil 5 6: Genetik algoritma ile üretilen olası optimum verilerin ekran görüntüsü	81
Şekil 5 7: 1. Jenerasyon kuyu verileri.....	82
Şekil 5 8: 50. Jenerasyon kuyu verileri.....	82
Şekil 5 9: 1. Jenerasyon olası net güç üretimleri	83
Şekil 5 10: 50. Jenerasyon olası net güç üretimleri	83
Şekil 5 11: Santral verileri ve hesaplama yönteminden elde edilen veriler.....	84
Şekil 5 12: Tasarım, işletme ve optimum koşullarda santralin karşılaştırmalı analiz sonuçları.....	90

TABLO LİSTESİ

Sayfa

Tablo 3.1: Üretim kuyularında kayıt altına alınan örnek veriler.....	24
Tablo 3.2: Üretim ve reenjeksiyon kuyularında kayıt altına alınan örnek veriler	25
Tablo 3.3: Organik rankine çevriminden elde edilen örnek veriler	25
Tablo 3.4: Organik rankine çevrimi ve jeneratörden elde edilen örnek veriler	26
Tablo 3.5: Santral tasarım parametreleri	31
Tablo 5.1: Üretim kuyularının debi, sıcaklık, basınç değerleri ile brüt güç ve iç tüketim değerleri arasındaki korelasyonu	61
Tablo 5.2: Santralden alınan ve hesaplama modelinde kullanılacak veriler	63
Tablo 5.1: YB Buharlaştırıcısının analiz tablosu	66
Tablo 5.4: YB ön ısıtıcı analiz tablosu	67
Tablo 5.5: AB Buharlaştırıcı analiz sonuçları	67
Tablo 5.6: YA ön ısıtıcı analiz sonuçları	68
Tablo 5.7: Reküperatör analiz sonuçları	69
Tablo 5.8: YB Türbin analiz sonuçları	70
Tablo 5.9: AB Türbin analiz sonuçları	71
Tablo 5.10: ORÇ pompası analiz sonuçları	71
Tablo 5.11: Hava soğutmalı kondenser analiz sonuçları	72
Tablo 5.12: Santralin tasarım parametrelerine göre ekipman ve genel analiz sonuçları.....	73
Tablo 5.13: İşletme verilerinin analiz sonuçları.....	75
Tablo 5.14: İşletme parametrelerine göre santral ekipmanları ve genel analiz sonuçları.....	76
Tablo 5.15: Yöntemden elde edilen ve işletme verilerinin karşılaştırılması.....	84
Tablo 5.16: Santralin çalışmasına benzer senaryonun olası parametreleri.....	85
Tablo 5.17: YB ve AB türbin analiz sonuçları.....	86
Tablo 5.18: Santral buhar olmaması durumunda olası optimum işletme parametreleri	87
Tablo 5.19: Santralin işletme şartlarına benzer verimi arttırılmış işletme koşulları.....	87
Tablo 5.20: Santralin optimum çalışma koşulları.....	89

SEMBOL LİSTESİ

- Ė:** ekserji (kW)
h: özgül entalpi (kJ/kg)
J: brine halleri
m: kütle akış debisi (kg/s)
Q: ısı transferi (kW)
s: özgül entropi (kJ/kg.K)
W: güç (kW)
0: ölü hal
1-11: iş akışkanları halleri

Yunan sembolleri

- η:** verim
ψ: akış ekserjisi

İndisler

- g:** giriş
ç: çıkış
sis: sistem
fg buharlaşma, yoğuşma
i hal numarası
o ölü hal
ORÇ organik rankine çevrimi

ÖNSÖZ

Doktora tez çalışması süresince bana rehberlik eden, bilgi ve deneyimleriyle yolumu aydınlatan değerli danışman hocam Prof. Dr. Harun Kemal ÖZTÜRK'e en içten şükranlarımı sunarım. Göstermiş olduğu sabır, anlayış ve özveri benim için her zaman yol gösterici olacaktır. Tez izleme komitesi üyelerim olan kıymetli hocalarım Prof. Dr. Mehmet Fevzi KÖSEOĞLU ve Prof. Dr. Nurdan YILDIRIM'a, çalışmamın şekillenmesinde ve tamamlanmasında sağladıkları değerli katkıları ve önerileri için sonsuz teşekkür ederim.

Bu süreçte yanımda olan ve her daim desteklerini hissettiğim annem Döne ÖZER ve kardeşim Gülse ÖZER ile ufkumu açıp yolumu çizmeme daha küçük yaşlarda yardımcı olan, çok erken yaşta hayata veda eden babam Zeki ÖZER'e sonsuz teşekkür ve şükranı bir borç bilirim.

En özel teşekkürlerimi ise sevgili eşim Seda Azizoglu ÖZER'e sunmak isterim. Bu süreç boyunca gösterdiği sabır, anlayış, sevgi ve desteği sayesinde motivasyonum daima canlı kalmış ve bu aşamaya daha kolay ulaşmamı sağlamıştır.

Ayrıca varlıkları ile bana güç veren tüm arkadaşlarıma, dostlarıma, yakınlarıma ve aile bireylerimin her birine ayrı ayrı teşekkür ederim.

1. GİRİŞ

Enerji tüm dünyada en önemli tüketim harcamalarından birisidir. Bu sebeple ülkeler enerji kaynaklarının kullanılması ve verimli bir şekilde işletilmesi üzerine yoğun çalışmalar yürütmektedir. Yapılan çalışmalardan özellikle yenilenebilir enerji kaynakları ile ilgili olan çalışmaların geçmişi çok daha eski olmasına rağmen ülkemizde ve dünyada son yirmi yılda büyük bir hız kazanmıştır. Şirketlerin yatırım yapacakları bölgelerdeki fizibilite analizlerinde enerji tüketimi en önemli kalemi oluşturmaktadır. Sanayileşme ve iş üretiminin ana göstergesi enerji tüketimidir. Bu sebeple enerji tüketiminin yerli kaynaklardan elde edilmesi ülkeler açısından hayati önem taşıyan politikalardan birisine dönüşmüştür. Özellikle ekonomik bağımsızlığın korunmasındaki en önemli konu enerji arzının yerli kaynaklar ile sağlanabilmesidir. Türkiye’de bu arzın karşılanması için YEKDEM yasası ile birlikte önemli ölçüde yenilebilir enerji santrali devreye girmiştir. Özellikle jeotermal enerji santralleri yatırımı konusunda son 17 yıl içerisinde çok ciddi ilerlemeler kaydedilmiştir. Jeotermal kaynakların verimli kullanılması tasarimsal olduğu kadar işletme parametrelerine de bağlıdır. Santrallerin işletilmesi ve bu sürecin değerlendirilmesi, sürekli yaşayan bir döngüye sahip jeotermal sahalarda çok önemlidir. Aynı zamanda bu parametrelere bağlı olarak santralin elektrik üretimi değişebilmektedir. Jeotermal akışkanın üretim kuyusundan çıkarılıp tekrar yer altına basılması sürecindeki işlem basamaklarının termodinamik analizler ile incelenerek jeotermal enerjiden en verimli şekilde faydalanabilmek için jeotermal enerji santrallerinin tasarım ve işletme parametrelerinin belirlenmesi üzerine önemli çalışmalar yapılmaktadır. Bu bölümde Jeotermal enerjinin doğası ve jeotermal enerji sistemlerinin optimizasyonun önemi üzerine genel bir bakış sunularak araştırmanın amaçlarından ve tezin kısa özetinden bahsedilecektir.

Jeotermal enerji, Dünya’nın iç kısımlarından kaynaklanan ısı enerjisidir. Yer kabuğunun altındaki sıcak su ve buharın kullanılmasıyla elde edilen bu enerji, sürdürülebilir ve çevre dostu bir alternatif olarak kabul edilir. Fosil yakıtlara göre daha az karbon emisyonuna sahip jeotermal enerji, teorik olarak tükenmeyen bir kaynaktır (URL 2). Jeotermal kaynaklar sıcaklıklarına göre düşük, orta ve yüksek sıcaklıklı

kaynaklar olarak sınıflandırılmaktadırlar. Kaynak sıcaklığı jeotermal enerjinin kullanım alanını da belirlemektedir. Literatürde farklı yaklaşımlar olmasına rağmen Hettiarachchi ve diğ. (2007) göre 220 °C ve üzerinde yüksek sıcaklıklı jeotermal kaynaklar, daha düşük sıcaklıkları düşük ve orta sıcaklıklı jeotermal kaynaklar olarak kabul etmişlerdir. Ülkemizde sahalarda kurulu olan santrallerin çoğunluğu düşük ve orta sıcaklıklı jeotermal kaynaklardan ısı enerjisi almaktadır. Genel olarak ise 90 °C ve üzerindeki sıcaklıklardan elektrik enerjisi üretilmektedir.

Farklı sıcaklıklardaki jeotermal kaynaklardan elektrik enerjisi elde edilmesi için her sahaya özel bir santral tasarımı gerekmektedir. Burada önemli bir mühendislik yaklaşımı olan optimizasyon çalışması karşımıza çıkmaktadır. Optimizasyon, santrallerin verimliliği, maliyet analizi, çevresel etkilerinin değerlendirilmesi ve sürdürülebilir kaynak kullanımının uygulanması gibi başlıca konuları analiz etmektedir. Bu analizlerin en önemlisi santral tasarımlarının verimlilik açısından incelenmesidir. Verimli olarak tasarlanan bir santral ekonomik ve çevresel etkileri de gözetilerek uygulanabilir hale gelmektedir. Jeotermal kaynaklardan elektrik enerjisi üretimi süreçlerinin optimizasyonu ile daha fazla elektrik enerjisi üretimi ve kaynakların daha etkili kullanılması sağlanabilmektedir (DiPippo 2012).

Optimizasyon problemlerinde en çok karşılaşılan sorun doğrusal olmayan problemlerin çözümlenmesindeki zorluklardır. Aynı zamanda birden fazla sistem ekipmanının çalışma koşullarını belirlemek için tekrar eden hesaplamalar yapmayı gerektirmektedir. Bu sorunların önüne geçebilmek için farklı hesaplama yöntemleri geliştirilmektedir. Bilgisayarların yardımı ile geliştirilen bu yöntemler sayesinde daha hızlı, verimli, doğru ve güvenilir sonuçlara ulaşmak mümkün olabilmektedir. Bu bağlamda yapay sinir ağları ve genetik algoritmaların uygun bilgisayar donanımları ile geliştirilmesi sonucu optimizasyon çalışmalarında daha çok kullanılabilir hale geldikleri görülmektedir. Son yapılan araştırmalarda jeotermal enerji santrallerinin verimlilik ve termodinamik hesaplamaları yapay sinir ağları ve genetik algoritma ile ayrı ayrı hesaplanarak karşılaştırılmaktadır. Literatürdeki önemli araştırmalar göstermektedir ki jeotermal enerji santralleri her iki yöntem ile modellenerek termodinamik hesaplamalar yapılabilmektedir (Yılmaz ve Koyuncu 2021). Bu çalışmanın yapılmasındaki en büyük etkenlerden birisi jeotermal enerji santral tasarımlarının mühendisler tarafından çok daha kısa bir sürede ve güvenilir bir şekilde

anlaşılabilmesini sağlamaktır. Dahası işletme şartlarının dinamik olarak gözlenebilmesine ve optimum şekilde santralin işletilebilmesine olanak tanımaktadırlar. Mühendislik hesaplamalarındaki insan hatalarının en aza indirilmesi ve harcanan önemli iş gücünün optimum kullanılması için yenilikçi bir yaklaşım geliştirilmiştir. Aynı zamanda literatürde bulunan çeşitli çalışmalardan farklı olarak yenilikçi bir yaklaşım benimsenmiştir.

Günümüzde yapay zeka çalışmaları çok önemli ölçüde artmıştır. Önümüzdeki yıllar içerisinde yapay zeka asistanlığı ile bilgisayar ve internetin ortaya çıktığı dönemden çok daha büyük bir bilgi çağına açılacağı düşünülmektedir. Ayrıca yapay sinir ağları optimizasyondan sağlık alanına kadar çok çeşitli uygulamalarda kullanılmaktadır. Bu kullanım alanlarına örnek olarak hastalıkların erken teşhisine olanak sağlayacak yöntemler üzerine çalışmalar yürütülmektedir (Ongun ve diğ. 2020). Bu güncel yaklaşım sayesinde araştırma konuları arasında yapay sinir ağları, makine öğrenmesi, genetik algoritma ve diğer yöntemler ile birlikte çalışan hibrit optimizasyon yöntemleri geliştirilmektedir.

Hesaplama yönteminin geliştirilmesi için jeotermal enerji santrallerinin nasıl çalıştığını bilmek gerekmektedir. Jeotermal enerji santralleri jeotermal kaynakların sıcaklığına bağlı olarak farklı tiplerde tasarlanmaktadır. Bunların yanı sıra jeotermal enerji santrallerinin nasıl çalıştığının anlaşılması derin yapay sinir ağlarının ve genetik algoritmanın modellenmesinde kullanılacak olan verilerin incelenmesi için önemlidir. Bu sebeple genel hatlarıyla jeotermal enerji santralleri tanıtarak hesaplama yönteminin anlaşılması için gerekli olan temel santral teknoloji bilgisi sağlanmış olacaktır.


1.1 Jeotermal Enerji Santralleri ve Kullanılan Çevrim Tipleri

Jeotermal enerji santralleri, yer kabuğundaki sıcak sıvı veya buhar fazındaki akışkanı yüzeye çıkarır. Daha sonra bu akışkanı sıcak ısı kaynağı olarak kullanan termodinamik çevrimler ile elektrik enerjisine çevirir. Kullanılan sıcak sıvı veya buhar fazındaki akışkan türbinleri döndürdükten sonra yeniden yer altına gönderilmek üzere reenjeksiyon kuyularına basılır ve çevrim tamamlanır. Temel olarak buharlaştırıcı, yoğunlaştırıcı, pompa ve türbin ekipmanlarından oluşur (Lund ve Boyd 2015).

Jeotermal enerji santralleri çevrim tipine göre üç ana temel sınıflandırması vardır. Bunlar; kuru buhar, flaş buharlı ve ikili çevrim santralleridir. Bunların dışında kalina çevrimi gib teorik olarak çalışılan ve günümüzde kısıtlı bir kullanım alanı olan farklı teknolojiye sahip çevrimler de bulunmaktadır. Ayrıca araştırmacılar tarafından geliştirilmeye çalışılan farklı teknolojiler literatürde mevcuttur (DiPippo 2012). Bu santral çevrimlerinden kısaca bahsedilerek, çalışma ilkeleri açıklanacaktır.

1.1.1 Kuru Buhar Çevrimi

Kuru buhar kullanan çevrimler, yer kabuğundaki kuru buharı doğrudan türbinlere yönlendirerek elektrik üretirler. Bu santraller jeotermal enerjiden elektrik üretiminin en basit ve jeotermal enerjinin doğrudan kullanıldığı yöntemlerden birisidir. Buhar türbinleri döndürerek elektrik üretir ve yoğuşturularak yer altına geri basılır (DiPippo 2012). Jeotermal enerjiden elektrik üretiminin en eski yöntemlerinden birisidir. Bununla birlikte farklı tipleri mevcuttur. Yoğuşturmalı ve yoğuşturmasız olarak kullanılmaktadır. Yoğuşturmasız santrallerde türbin çıkış buharı doğrudan atmosfere verildiği için çevresel anlamda dezavantajlıdır. Ayrıca dış atmosfer basıncına doğrudan bağlı santrallerdir. Yoğuşma vakum ortamı ile sağlanarak daha verimli ve çevreci santral tasarımları geliştirilmiştir (Kanoğlu 2005). Şekil 1.1'de çevrimin şematik görünümü verilmiştir.

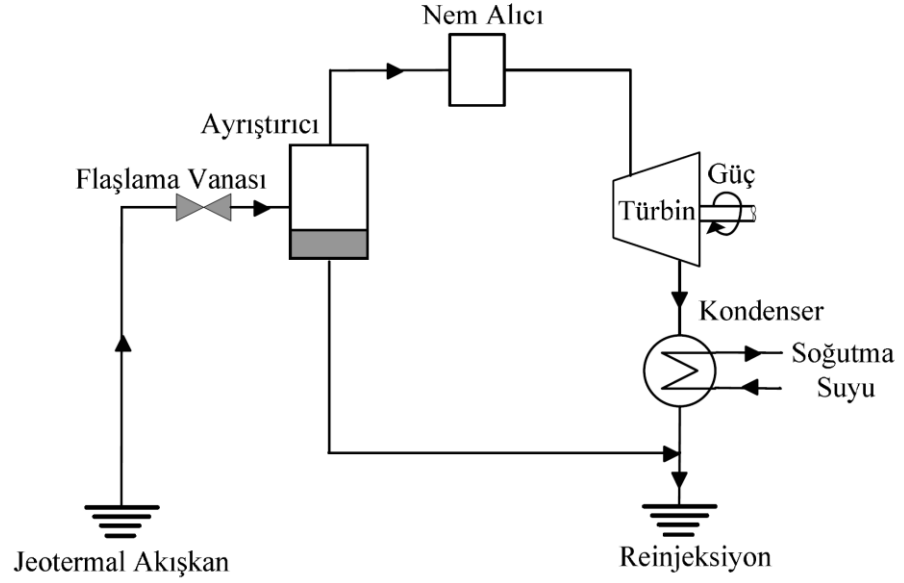


Şekil 1.1: Kuru buhar çevrimli jeotermal enerji santrali şeması (Şahin 2016)

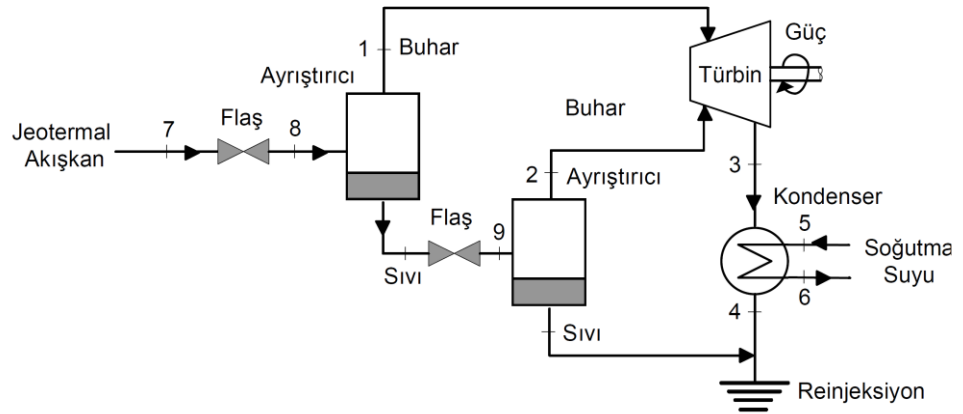
1.1.2 Tek ve Çift Flaşlı Çevrimler

Jeotermal enerji kaynakları yer kabuğunun altında yüksek basınç ve sıcaklıkta bulunmaktadır. Bu sebeple genellikle sıvı fazda bulunur. Ancak üretim kuyuları yolu ile yüzeye yaklaştıkça basınç düşer ve atmosfere açıldığı noktada buharlaşma başlar. Bu aşamada doymuş sıvı-buhar karışımında olan jeotermal akışkan üretim kuyularında kullanılan seperatör (ayrıştırıcı) ekipmanı yardımıyla sıvı ve buhar fazları birbirinden ayrılarak farklı boru hatları ile santrale taşınır. Eğer yeterli debi ve sıcaklıkta buhar mevcutsa akışkan türbine gönderilerek elektrik üretilir. Üretim kuyularından elde edilen buhar miktarı kütlece % 3-8 arasında ise düşük buhar debisi olması sebebi ile buhardan güç elde etmek için yetersiz olabilir. Bu sebeple üretim kuyularında daha fazla buhar elde edebilmek amaçlı kısılma veya püskürtme süreçleri uygulanmaktadır. Basıncı düşürülen akışkandan daha fazla buhar elde edilebilir. Ancak basıncı düşen akışkanın sıcaklığı basıncın doyma sıcaklığına bağlı olarak düşeceği bilinmelidir. Kazanılan debi ile sıcaklık düşüşünden kaybedilen enerji arasında jeotermal üretim kuyusunun ve sahanın özelliklerine bağlı olarak daha fazla bir ısı enerjisi sisteme kazandırılabilir.

Tek flaşlı çevrimlerde bu süreç bir defa uygulanarak buhardan enerji eldesi sonucu jeotermal akışkan yoğunlaştırılarak reenjeksiyon kuyularına geri basılır. Çift flaşlı çevrimlerde ise bu süreç sonrasında elde edilen sıvı fazdaki akışkan yeterince yüksek sıcaklık ve basınca sahipse yeniden kısılma veya püskürtme sürecine dahil olarak buhar üretilebilmektedir. Termodinamik özellikleri uygun olan jeotermal kaynaklarda çift flaşlı çevrim uygulamalarında tek flaşlı çevrime göre % 20-25 daha fazla güç üretilebilmektedir. Çift flaşlı santrallerin daha fazla ekipman gereksinimi sebebi ile yatırım maliyet hesaplamalarının uygulanabilir aralıkta olduğu analiz edilmelidir (DiPippo 2012). Şekil 1.2 ve Şekil 1.3'te sırasıyla tek ve çift flaşlı çevrimlerin akış diyagramları verilmiştir.



Şekil 1.2: Tek flaşlı çevrim diyagramı (Coşkun 2011)



Şekil 1.3: Çift flaşlı çevrim diyagramı (Coşkun 2011)

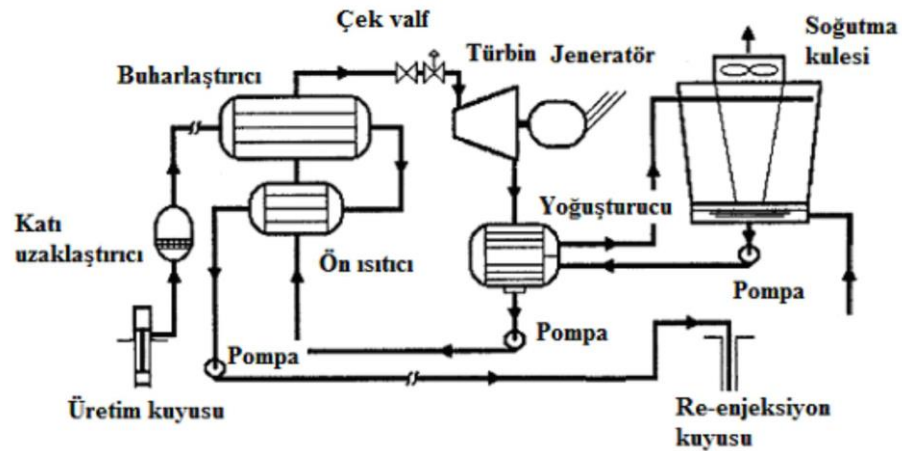
1.1.3 İkili (binary) Tip Çevrim

İkili çevrim, düşük sıcaklıklı jeotermal sahalardaki jeotermal akışkandan yeterli miktarda buhar üretilmediğinde kullanılmaktadır. Jeotermal akışkan ısı enerjisini santral içerisindeki kapalı çevrim ile çalışan ikincil bir akışkana aktararak akışkanın buharlaşmasını sağlar ve türbinden elektrik enerjisi üretilir. Bu tip santrallerde ikincil akışkan olarak genellikle organik bileşikli akışkanlar kullanılır. Buharlaşma sıcaklığı düşük olan ikincil akışkanın seçimine göre 85-170 °C sıcaklık

aralığındaki jeotermal akışkandan ikili tip çevrim ile elektrik enerjisi üretilmektedir. Yukarıda anlatılan tek flaşlı santrallerden ayrıştırılan sıvı fazdaki jeotermal akışkan ikili tip çevrim santraline gönderilerek elektrik üretimi yapılabilir. Bu sayede kaynak kullanımını daha verimli hale getirilebilir (DiPippo 2012).

Farklı jeotermal kaynaklara göre bu tip santrallerin kullanılabilmesi için kuyu içerisinde özel pompalar kullanılarak akışkan sıvı fazda santrale taşınabilir. Daha sonra jeotermal akışkan santralin tasarımına bağlı olarak bir dizi ısı değiştirici yardımıyla ısıl enerjisini ikincil akışkana aktarır. İkincil akışkan buharlaşarak özel olarak geliştirilen türbinlerde ısıl enerjiyi mekanik enerjiye dönüştürür. Bir jeneratör yardımıyla üretilen mekanik enerji elektrik enerjisine çevrilir. İkincil akışkan soğutulmuş olarak çevrim tamamlanmış olur. Soğutma işlemi su yada dış ortam havası ile yapılabilmektedir. İkincil akışkanın seçimi ve soğutma yöntemi ikili tip çevrimlerin verimini etkileyen en önemli etkenlerdir. Ayrıca santralin tasarımı ve işletme parametrelerinin doğru belirlenmesi jeotermal kaynak kullanımını önemli ölçüde etkilemektedir (Bandeian ve diğ. 2011)

Bu tez kapsamında verileri alınan ve analizi yapılarak optimize edilen santral ikili tip çevrime sahip jeotermal enerji santralidir. Türkiye’de bulunan santrallerin büyük bir çoğunluğu doğrudan ikili tip ile çalışmaktadır. Aynı zamanda flaşlı santraller ile birleşik olarak atık ısılarının geri kazanımı için ikili tip santraller kullanılmıştır. Şekil 1.4’te ikili tip santralin şeması gösterilmiştir.



Şekil 1.4: İkili tip santralin çevrim diyagramı (DiPippo 2012)

1.2 Jeotermal Santrallerin Optimizasyonu

Optimizasyon, bir veya daha fazla bağımsız değişkenin belirli koşullar altında en iyi çözümü arama işlemi olarak tanımlanabilir (Erdoğan, 2012). Optimizasyon metodları yedi farklı şekilde sınıflandırılabilir bunlar; Yapay Zeka (sezgisel), Çok Amaçlı Yaklaşım, Analitik Metod, İteratif Metod, Olasılıksal Yaklaşım, Grafikselle Yapı Metodu, Bilgisayar Yazılımlarıdır (Chauhan ve Saini 2014).

Geleneksel yöntemler olan analitik metod, iteratif metod, olasılıksal yaklaşım ve grafikselle yapı metodu yakınsama hızları yavaş olması, hesaplama sürelerinin uzun olması ve parametrelerdeki dinamik değişiklikler ile kolayca başa çıkamamaları sebebiyle günümüzde çok tercih edilmemektedir (Ayan 2019). Bu sebeple bir çok araştırmacı günümüzde yapay zeka ve çok amaçlı yaklaşımlara yönelmektedir. Bunlar arasında literatürde kullanılan özellikle yapay sinir ağları ve genetik algoritma ile optimizasyon çalışmaları önem kazanmıştır.

Jeotermal santrallerin optimizasyonu için geleneksel yöntemlerden farklı olarak bu tez kapsamında derin yapay sinir ağları ve genetik algoritma modellemeleri yardımı ile bir optimizasyon yöntemi geliştirilmiştir. Bu sayede her iki yöntemin güçlü yanlarını kullanarak özgün, yenilikçi ve güvenilir bir hesaplama yöntemi geliştirilmesi hedeflenmiştir. İlerleyen bölümlerde tezin hipotezini açıklamak amacıyla hesaplama yönteminin detayları anlatılacaktır.

1.3 Yapay Sinir Ağları

Yapay sinir ağları verilerin işlenmesinde kullanılan ve insan beyninin veri işleme sürecinden ilham alınarak geliştirilmiş bir yöntemdir (Keçebaş ve diğ., 2012). Bu yöntem verileri bir tür makine algısı, etiketleme veya ham girdiyi kümeleme yoluyla yorumlar. Daha sonra belirli bir örüntü bularak bunları vektör olarak sayısallaştırır. Sonuçta veriler arasındaki ilişkiyi kurarak sınıflandırma yapar. Yapay sinir ağları aynı zamanda veriler arasında var olan özellikleri ortaya çıkararak geniş makine öğrenmesini de kapsayan bir yöntem olarak düşünülebilir. Bu sayede sınıflandırma ve regresyon gibi analizler için kullanılabilir. Karmaşık doğrusal

olmayan modellerdeki giriş ve çıkış parametreleri arasındaki ilişkiyi ortaya çıkarır (Khalil ve diğ. 2019).

Yapay sinir ağları yapı olarak 3 katman içerir. Bunlar; giriş bölgesi, nöronlar ve çıkış bölgesi. Başka bir ifade ile giriş bölümü, gizli katman ve çıkış bölümüdür. Tüm bu katmanlardaki nöron sayısı önemli ölçüde hesaplama modeline bağlı olarak değişiklik gösterir. Bu sebeple metodun hassaslığı bu tasarıma bağlıdır. Bir diğer önemli konu ise gizli katmanda kullanılacak olan transfer ve aktivasyon fonksiyonun belirlenmesidir (Yılmaz ve diğ. 2021). Yapay sinir ağının tüm bu özellikleri tasarıma göre belirlenerek geliştirilecektir. Bu sayede hassasiyet ve doğruluk açısından test edilerek kullanılabilir hale getirilecektir. Literatürde geçerliliği kanıtlanmış fonksiyonlar ve yöntemler kullanılacaktır.

Yapay sinir ağlarının yapısı çok katmanlı hale getirilerek daha gelişmiş işlem kapasitesine sahip olması sağlanabilmektedir. Buna derin yapay sinir ağları adı verilmektedir. Derin yapay sinir ağları modellenerek bu tez kapsamındaki yöntemde kullanılacaktır.

1.4 Genetik Algoritma

Genetik algoritmalar Darwin'in evrim teorisine dayanarak en güçlü olanın hayatta kalmasını temel alan mekanizmaların mühendislik sistemlerine uyarlanmasıdır. Bilimsel analogi ile doğal evrime benzer belirli bir ırkın popülasyonunun uyum sağladığı bir tasarım topluluğu yaratılır ve sonra topluluğun uyum sağlaması için gelişmesine izin verilir. Genetik algoritmanın temel matematiksel modelleri seçim ve üreme sırasındaki bilgi geçişi, ebeveynlerin özellikleri ve genetik mutasyon gibi evrimsel süreçlerdeki etkileri içerecek şekilde tasarlanır. Genetik algoritma problemin olası çözümlerini üretecek şekilde tasarlanmaktadır.

Literatürde diğer seçenekler arasında genetik algoritmalar en geniş ve kapsamlı olarak termal güç sistemlerinin optimizasyonu için kullanılmaktadır (Clarke ve diğ. 2014). Ayrıca tüm optimizasyon problemlerinde istenilen bir sonuç için diğer sonuçlardan ya da amaçlardan feragat edilir. Bu sebeple hepsinin belirli bir optimum noktada çalışmasını sağlayacak sonucu elde etmek parametrik hesaplamalarda çok

zahmetli ve uzun olabilmektedir. Bu sebeple genetik algoritma literatürde optimizasyon problem çözümlerinde güvenilir ve güçlü bir araç olarak karşımıza çıkmaktadır (Behzadi ve diğ. 2018).

Genetik algoritma temelde uygunluk fonksiyonunu esas alarak işlemler gerçekleştirmektedir (Öztürk ve diğ. 2004). Uygunluk fonksiyonu bireylerin yaşamlarını belirleyen yaşayabilme yüzdelerinin belirlenmesini sağlamaktadır. Genetik algoritmanın en önemli fonksiyonudur. Bu tez kapsamında ise uygunluk fonksiyonu olarak derin yapay sinir ağları kullanılacaktır. Literatürde çeşitli genetik algoritma yöntemleri mevcuttur. Tasarıma uygun ve hassas olan yöntem kullanılacaktır (Goldberg 1989).

Bu tez kapsamında yapay sinir ağları ve genetik algoritma modellenerek, sahada çalışan bir jeotermal enerji santralinden alınan veriler ile santral optimizasyon çalışması yapılacaktır. Geliştirilen son teknolojiler ve yazılım kütüphaneleri sayesinde yapay sinir ağları ile modellemeler günümüzde her alanda yerini almaya başlamıştır. Mühendislik problemlerinin çözümlenmesinde insan hatalarını en aza indiren ve çok hızlı bir şekilde birden fazla senaryonun oluşturularak test edilebildiği modeller geliştirilmektedir. Bu bağlamda derin yapay sinir ağlarını genetik algoritma içerisinde uygunluk fonksiyonu olarak kullanan optimizasyon yöntemi ile jeotermal sistemlerin optimize edilmesi bu tezin konusudur. Yöntemin esas konusu literatürde farklı fonksiyonların kullanıldığı genetik algoritmadaki hesaplamanın sonuçlarını doğrudan etkileyen uygunluk fonksiyonunun derin yapay sinir ağları ile modellenmesidir. Elde edilecek uygunluk fonksiyonu modeli bir jeotermal enerji santralinin verileri ile eğitilerek daha doğru ve her santralin ayrı ayrı modellenebileceği ve bu fonksiyonun kullanıldığı genetik algoritma sayesinde genel bir hesaplama yönteminin geliştirilmesi hedeflenmektedir. Literatür bölümünde yapay sinir ağları ve genetik algoritma ile jeotermal enerji sistemlerinin optimizasyonu çalışmalarına yer verilerek tezin literatürdeki yeri gösterilmeye çalışılmıştır. Yapay sinir ağları ve genetik algoritmanın yapısı materyal ve metot bölümlerinde detaylı olarak anlatılacaktır. Daha sonra çalışma sonunda elde edilen verilerin kıyaslandığı ve bu çalışmanın analizlerini oluşturacak olan bulgular bölümünde verilerin işlenmesi ve hesaplama sonuçları karşılaştırmalı olarak verilecektir. Son olarak sonuç ve öneriler kısmında tezin genel

olarak literatüre katkısı ile ortaya çıkan hesaplamaların sonuçları değerlendirilerek, gelecek çalışmalar ile ilgili bilgi ve bağlamlardan bahsedilecektir.

Gelecekte bu ve benzeri çalışmalar sayesinde mühendislik hesaplamaları daha güvenilir ve hızlı bir şekilde gerçekleştirilebilecektir. Aynı zamanda çözümü karmaşık olan optimizasyon problemleri için yenilikçi ve güvenilir analiz yöntemleri geliştirilerek verimli ve optimum santral tasarımlarının modellenmesi sağlanabilir.

2. LİTERATÜR ÖZETİ

Jeotermal sistemlerin optimize edilerek en uygun işletme şartları ve buna bağlı tasarım parametrelerinin optimize edilmesi problemi, doğrusal olmayan ilişkilerin hesaplanmasını gerektirdiği için zor ve uzun bir süreçtir. Bu süreç içerisinde insan kaynaklı hesap hataları da yapılabilir. Bu tez kapsamında derin yapay sinir ağları alanındaki gelişmelerden faydalanılarak genetik algoritma kullanan optimizasyon yöntemi geliştirilecek ve jeotermal sistemlere uygulanması ile yöntemi tutarlılığı ve elde edilen analiz sonuçları tartışılacaktır. Aynı zamanda daha verimli ve kısa sürede sonuç veren hesaplamalı simülasyonlar oluşturulması hedeflenmektedir. Bu sayede zahmetli ve ciddi iş gücü ile tecrübe gerektiren tasarımlar daha kolay anlaşılır ve hassas bir şekilde yapılabilir. Bu yöntem literatürde ve uygulamada verim artırma ve en uygun verimde çalışan tasarımlar için yenilikçi bir yaklaşım olarak ortaya çıkmaktadır.

Son yıllarda yapay sinir ağları, genetik algoritma, derin yapay sinir ağları, makine öğrenmesi ve alt kolları bir çok alanda geleneksel yöntemlere alternatif olarak kullanılmaktadır. Bu yöntemler ile tahminleme, modelleme, optimizasyon gibi uygulamalar yapılabilmektedir. Karmaşık sistemlerin yaklaşık modellenmesi ve tahminleme analizlerinde özellikle enerji alanında önemli ve yeni bir alan olarak karşımıza çıkmaktadır. Bu tez kapsamında derin yapay sinir ağlarını, genetik algoritma içerisindeki uygunluk fonksiyonu olarak kullanan yenilikçi bir yaklaşım geliştirilerek jeotermal sistemlerin optimizasyonu yapılacaktır. Bu bağlamda Organik Rankine Çevrimine göre çalışan Jeotermal Santrallerin optimizasyon yöntemi geliştirilecektir. Belirli bir süre içerisinde alınan gerçek santral verileri ile hesaplama modeli belirlenerek optimum verim çalışmaları yapılacaktır. Literatürde jeotermal enerji ile derin yapay sinir ağları ve genetik algoritma yöntemlerinin kullanıldığı çalışmalar mevcuttur. Bu tez kapsamında uygulanacak yöntem ve sistem tasarımı tarafımızdan yapılan literatür araştırmasına göre bir ilki temsil etmektedir. Bu alan ile ilgili literatür bilgisine başvurduğumuz bazı çalışmalar ise yöntemlerin jeotermal enerji optimizasyonu problemlerine uygulanmaya yakın zamanda başlanıldığını göstermektedir.

Bu bağlamda Özkaraca ve diğ. (2018) yapmış oldukları çalışmada, Artificial Beee Colony (ABC) yapay sinir ağları metodu ile Sinem JES'i modellemişlerdir. Bu modelleme ile ulaşılabilir en yüksek performans verimi ve en uygun ekonomik modeli bulmayı hedeflemişlerdir. Ayrıca klasik ve ileri ekserji analizleri de yaparak ABC metodu ile karşılaştırmışlardır. En yüksek enerji yıkımının CON1, CON2 ve VAP2 bileşenlerinde olduğunu bulmuşlardır. Klasik ekserji analizi, ileri ekserji analizi ve ABC optimizasyon metodu ile ekserji verimlerini sırasıyla %39,1, %43,1 ve %42,8 olarak bulmuşlardır. ABC yapay sinir ağları optimizasyonu ve ileri ekserji analizi ile bulunan değerlerin çok yakın olduğunu belirtmişlerdir. Ayrıca aradaki farkın ileri ekserji analizinde seçilen değerler ile ilgili olabileceğini dolayısıyla bu analizlerin yapılmasının tecrübe gerektirdiğini vurgulamışlardır. Sonuç olarak ABC yapay sinir ağı optimizasyonu ile bulunan işletme şartlarının ve iyileştirmelerin yapılması halinde diğer analiz yöntemlerinden farklı olarak 2102 kW ekserji kazanılabileceği gösterilmiştir.

Khosravi ve diğ. (2019) ise, Organik Rankine Çevrimine göre çalışan güneş enerjisi ile entegre sistemin termodinamik modelini yapay zeka yaklaşımı ile hesaplamışlardır. Termodinamik yaklaşım ile optimum tasarımı bulmak için tasarım parametreleri ve operasyon koşullarının belirlenmesinin zor olduğunu vurgulamışlardır. Bunun için deneysel çalışmalara, sürekli olarak parametrelerin değiştirilerek hesaplamaların tekrar edilmesi ve çok fazla sayıda analizlerin yapılması gerektiğini belirtmişlerdir. Bu sebeple Particle swarm optimization (PSO) algoritması ike MLP ve ANFIS yapay sinir ağları kullanılarak modelleme yapılmıştır. Ayrıca n-pentane, isopetane, R1234yf, R1234ze, R600, R600a, R152a, R161 ve R134a iş akışkanları da aynı modelde test edilerek en uygun akışkan çevresel etkileri de gözetilerek belirlenmiştir. Aynı zamanda LCOE denklemi ile ekonomik bağlamda modelin değerlendirilmesi yapılmıştır. En iyi performansı düşük küresel ısınma potansiyeline (GWP) sahip R1234yf iş akışkanı en iyi enerji ve minimum LCOE değerini sağlamıştır. Performans açısından entegre sistemin ANFIS-PSO ile MLP-PSO yapay sinir ağından daha üstün sonuçlar verdiği ortaya konmuştur.

Bir diğer çalışmada Özkaraca ve diğ. (2019), farklı bir yöntem olarak gravitational search (GS) algoritmasını kullanarak gerçek santral verileri ile modelleme ve analiz yapmışlardır. Algoritmanın yapılan literatür araştırmalarında

gerçek dünya problemlerinde başarılı sonuçlar verdiği anlaşılmıştır. 14,18 MW net güç üretimi olan santralin GS algoritma yöntemi sonucunda 16,29 MW net güç üretebileceğini hesaplamışlardır. Bu artış yaklaşık olarak %13 artış ile 2,1 MW'tır. Ayrıca bu çalışmada ekserji verimine etki eden parametrelerin buharlaştırıcıdaki basınç farkı ve jeotermal akışkanın kütleli debisi olduğu sonucuna varılmıştır. Sonuç olarak kullanılan yöntem ile sistemin ekserji verimi %14,48 olarak hesaplanan değerden, yapılan optimizasyon ile %30,62 değerine çıkmıştır. Karmaşık ve pahalı sistemlerin optimizasyonunda GS algoritma benzeri metodlar ile sistem ve bileşenlerinde daha ekonomik sonuçlar elde edilebileceği vurgulanmıştır.

Fannou ve diğ. (2014) oluşturulacak yapay sinir ağlarında veri seçimine göre pozitif giriş parametreleri için log-sigmoid transfer fonksiyonunu, negatif giriş parametreleri için ise sigmoid tanjant fonksiyonunu seçmişlerdir. Yapay sinir ağları ile oluşturulacak model için jeotermal ısı pompasının performansını etkileyen termodinamik parametreler belirlenmiştir. Giriş parametreleri için evaporatör giriş ve çıkış sıcaklığı ve basıncını, yoğuşturucudaki soğutma suyu giriş sıcaklığını ve jeotermal akışkanı kuyudan pompalayan pompa çıkış basıncını belirlemişlerdir. Deneysel set oluşturarak laboratuvar ortamında parametreleri ölçmüşler ve veri setleri oluşturmuşlardır. Bu modelde 28 nöronlu bir yapay sinir ağı kullanılarak modeli test edilmiştir. Root mean square ya da karekök ortalama olarak bilinen RMS değeri 0,16330 olarak bulunmuştur. Benzeri çalışmalar için yapay sinir ağlarının karmaşık modellerin analizi için iyi bir alternatif olduğu vurgulanmıştır.

Farklı bir çalışma olarak Keçebaş ve diğ. (2012) Afyonkarahisar jeotermal bölgesel ısıtma sistemini yapay sinir ağları kullanarak incelemişlerdir. Vaka analizinde kullanılan yöntem ile optimizasyon ve termal izleme yapmışlardır. Sistemden 2006-2010 yılları arasında haftalık ortalama veriler alınarak yapay sinir ağları ile sistem modellenmiştir. Ölçümler için belirsizlik analizi yapılmıştır. Bu analize göre belirsizlikler sıcaklık, basınç ve hacimsel debi için sırasıyla %1,87, %1,64 ve %0,27 olarak bulunmuştur. Belirsizliklerin hesaplamalardaki küçük hatalara sebep olabileceği vurgulanmıştır. Enerji ve ekserji verimleri termodinamik yöntemler ile hesaplanmıştır. Yapay sinir ağları modellemesi ise MATLAB içerisindeki hazır araçlar yardımı ile modellenerek analiz edilmiştir. Yapay sinir ağları modellemesinde 16 adet çıkış parametresi bunun yanı sıra 4 adet giriş parametresi kullanılmıştır.

Termodinamik analiz ve yapay sinir ağı modeli enerji verimleri sırasıyla %35,38 ve %35,39 ayrıca ekserji verimleri sırasıyla %28,70 ve %28,71 olarak bulunmuştur. Analiz sonuçları yapay sinir ağlarının aynı zamanda sistem performansının izlenmesinde termal izleme yöntemi olarak kullanılabilceğini de göstermiştir. Bu sayede ısıtma sistemindeki debi kontrolü otomatik olarak yapay sinir ağları analizlerine bağlı olarak yapılabileceği vurgulanmıştır. Bu sayede kayıplar düşürülerek daha verimli, insan hatasından arındırılmış ve etkili bir işletme yapılabileceği açıklanmıştır.

Özer (2018) yaptığı çalışmada jeotermal enerji santrallerinin optimum verim analizini ASPEN PLUS programı kullanarak analiz gerçekleştirmiştir. Öncelikle iş akışkanı ve konfigürasyon belirlenerek optimum tasarım ve işletme şartları analiz edilmiştir. Bu iş akışkanları İzopentan, R141b, N-pentan, R113, R114, R142b, İzobütan, R245fa, R236fa, N-bütan olarak seçilmiştir. Ayrıca 110 °C, 135 °C ve 160 °C jeotermal kaynak sıcaklığı olarak belirlenmiştir. Reenjeksiyon sıcaklığı ise 65 °C olarak belirlenmiştir. Farklı bileşenlere sahip temel ve çift basınç kademeli organik rankine çevrimi ile çalışan santraller program içerisinde tanımlanmıştır. Analizler optimum verim için eşanjörlerdeki sıcaklık farkı 2 °C ve reenjeksiyon sıcaklığı 60 °C sabit tutularak yapılmıştır. Jeotermal kaynak sıcaklıklarına göre sonuçlar farklılık göstermiştir. Ayrıca ekonomik analiz de yapılarak sistemin uygulanabilirliği değerlendirilmiştir. Parametrik optimizasyon çalışmaları veri ve parametrelerin değiştirilerek çok fazla sayıda analizin yapılması gerektiğini ortaya koymaktadır.

Flaş buharlı sistemler ve organik rankine çevrimine göre çalışan sistemlerin birlikte kullanımı uygun sahalarda oldukça yaygındır. Süren (2012) yaptığı çalışmada böyle birleşik sistemin enerji ve ekserji analizlerini yapmıştır. Denizli ilindeki Bereket Enerji Binary jeotermal santrali ve Zorlu Kızıldere flaş buharlı enerji santralleri ayrı ayrı ve birleşik olarak modellenmiş ve analiz edilmiştir. Ekserji analizlerinde kayıplar bulunarak yapılabilecek iyileştirmeler ve buna bağlı performans arttırma yapılabileceği vurgulanmıştır. Sistemler birleştirildiğinde Zorlu Enerji santrali için kayıp olarak görülen 5503,14 kW kazanç olarak geri dönmüştür. Bu sayede daha verimli ve sürdürülebilir bir sistem tasarlanabileceği vurgulanmıştır.

Genetik algoritmalar ise temelde Darwin'in evrim teorisine dayanarak en güçlü olanın hayatta kalmasını mühendislik sistemlerine uygulanmasıdır. Bilimsel analogi ile

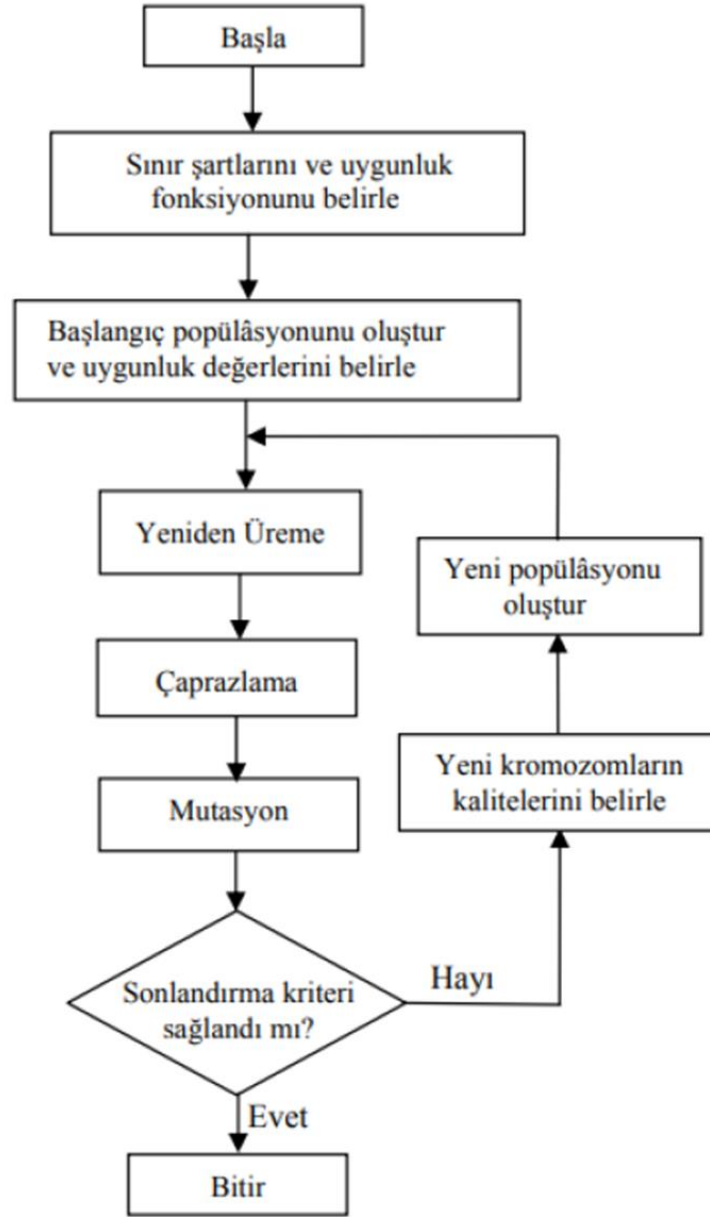
dođal evrime benzer belirli bir ırkın popölasyonunun uyum sađladığı süreç bir tasarım topluluđu yaratılır ve sonra tasrıma uyum sađlaması için gelişmesine izin verilir. Genetik algoritmanın temel işlemleri seçim ve üreme sırasındaki bilgi geçişı ebevenler ve genetik mutasyon gibi evrimsel süreçlerdeki etkileri içerecek şekilde tasarlanır. Genetik algoritma problemin olası çözümlerini üretecektir. Genetik algoritma temelde uygunluk fonsiyonuna esas alınarak işlemler gerçekleştirecektir (Öztürk ve diđ. 2004).

Genetik algoritma anlaşılması kolay bir yapı olması sebebiyle de tercih edilmektedir. Aşağıdaki Şekil 2.1’de genetik algoritmanın işlem basamakları gösterilmiştir.

Radiyanto ve diđ. (2023) yaptığı çalışmalarda genetik algoritma ile bir jeotermal enerji santrlinin türbin giriş ve üretim kuyusu kuyubaşı basınçlarına göre sistemin optimizasyonunu yapmışlardır. Modelde fiziksel olarak sınır şartları kuyubaşı basıncı için 11-13 bar ve türbin giriş basıncı için 10-11,5 bar aralığında belirlenmiştir. Optimum verim için kuyubaşı ve türbin giriş basınçlarını sırasıyla 11,98 ve 10,023 bar olarak bulmuşlardır. Sonrasında genetik algoritma modelinden elde edilen optimum koşullarda santralin ekserji analizini yaparak toplam ekserjinin %0,11 artabileceğini hesaplamışlardır.

Genetik algoritmalar karmaşık problemler için kullanışlı olan olası çözüm kümeleri oluşturulabilirler. Dahası oluşturulan bu olası çözümlerin istenilen çözümlere uygun olup olmadığı analiz edilebildiği açıklanmıştır. Genetik algoritmanın başarısı olası çözümlerin birey olarak nasıl tanımlandığına ve uygunluk fonsiyonun seçimine büyük ölçüde bađlı olduğu vurgulanmıştır. Daha sonra uygunluk fonsiyonun etkili bir şekilde seçilmesi gerekmektedir. Genetik algoritmalarda bireyler örnek olarak jeotermal enerji santralleri için işletme parametreleri ile tanımlanabilir (Kızrak 2021).

Genetik algoritmanın modellenmesinde uygunluk fonsiyonu önemli bir ayrıntı olarak karşımıza çıkmaktadır. Bu bağlamda termodinamik bađıntılar, literatürdeki farklı fonsiyonlar veya geliştirilen bir fonsiyon ile uygunluk fonsiyonu tanımlanabildiği gösterilmiştir. Ayrıca bir veya daha fazla sayıda parametre kullanılarak uygunluk fonsiyonu seçilecekse vektörel formda da yazılabilir. Uygunluk fonsiyonu genetik algoritmanın yapısı ve problemlere göre farklı olacak şekilde seçilebilirler.



Şekil 2.1: Genetik algoritma optimizasyon diyagramı (Goldberg 1989)

Burada önemli bir ayrıntı spesifik problemler için çözüm uzayı ve uygunluk fonksiyonunun tanımlanmasıdır. Yapılan çalışmada güç tüketimi çözüm uzayı ve tanımlanan $R_{sys}=QIT/W_{sys}$ denklemi uygunluk fonksiyonu olarak belirlenmiştir. Analizler sonucunda enerji veriminde ortalama % 16,18 artış olduğu görülmüştür (He ve diğ. 2021). Uygunluk fonksiyonu seçimi önemli bir kriter olarak karşımıza çıkmaktadır. Bu bağlamda termodinamik bağıntılar yoluyla ya da literatürde kullanılan farklı fonksiyonlar uygunluk fonksiyonu olarak kullanılabilir. Bir veya daha fazla

parametre aynı anda uygunluk fonksiyonu içerisinde yer alacaksa vektörel formda da yazılabilir (Mokarram ve Mosaffa 2018). Ancak burada belirtilmesi gereken önemli bir konu seçilecek parametrelerin sayısıdır. Birden fazla parametre ile özellikle bu parametrelerdeki dinamik değişimlerin sistem üzerinde önemli etkisi olduğunda karşımıza farklı bir problem çıkmaktadır. Bu tezin konusu olan uygunluk fonksiyonu için derin yapa sinir ağlarının kullanımı ile bu problem çözülebilir. Çünkü yapay sinir ağları yapısı gereği bir fonksiyondur.

Tüm diğer mühendislik problemlerinde olduğu gibi jeotermal enerji uygulamalarının da belirli sınır şartları vardır. Bu sınır şartları belirlendikten sonra genetik algoritma içerisinde uygunluk fonksiyonu belirlemek en önemli konudur. Uygunluk fonksiyonu için literatürde bilinen farklı fonksiyonlar kullanılabileceği gibi kendisi de bir fonksiyon olarak tanımlanabilecek olan yapay sinir ağları da uygunluk fonksiyonu olarak değerlendirilebilir. Bu tez kapsamında yenilikçi bir yaklaşım olarak uygunluk fonksiyonu için yapay sinir ağlarının gelişmiş bir versiyonu olan derin yapay sinir ağları kullanılacaktır.


Derin yapay sinir ağları verilerin işlenmesinde kullanılan ve insan beyninin veri işleme sürecinden ilham alınarak geliştirilmiş bir yöntemdir (Keçebaş ve diğ., 2012). Bu yöntem ile verileri bir tür makine algısı, etiketleme veya ham girdiyi kümeleme yoluyla yorumlar. Daha sonra belirli bir örüntü bularak bunları vektör olarak sayısallaştırır. Veriler arasındaki ilişkiyi kurarak sınıflandırma yapar. Derin yapay sinir ağları aynı zamanda var olan özellikleri ortaya çıkararak geniş makine öğrenmesinin bir bileşeni olarak düşünülebilir. Bu sayede sınıflandırma ve regresyon gibi analizler için kullanılabilir. Karmaşık doğrusal olmayan modellerdeki giriş ve çıkış parametreleri arasındaki ilişkiyi ortaya çıkarır (Khalil ve diğ. 2019).

Derin yapay sinir ağları yapı olarak 3 katman içerir. Bunlar; giriş bölgesi, nöronlar ve çıkış bölgesi. Başka bir ifade ile giriş bölümü, gizli katman ve çıkış bölümüdür. Tüm bu katmanlardaki nöron sayısı önemli ölçüde tasarıma bağlı olarak değişiklik gösterir. Bu sebeple metodun hassaslığı bu tasarıma bağlıdır. Bir diğer önemli konu ise gizli katmanda kullanılacak olan transfer veya aktivasyon fonksiyonunun belirlenmesidir (Yılmaz ve diğ. 2021). Derin yapay sinir ağının tüm bu özellikleri tasarıma göre belirlenerek geliştirilecektir. Bu sayede hassasiyet ve

doğruluk açısından test edilerek kullanılabilir hale getirilecektir. Literatürde geçerliliği kanıtlanmış fonksiyonlar ve metotlar kullanılacaktır.

Huster ve diğ. (2020), yapmış oldukları çalışmada bir ORC içerisinde bulunan iş akışkanını karışım olarak modellemişlerdir. Bu modellemeyi yapay sinir ağı kullanarak yapmışlardır. İş akışkanı karışımının karışım oranı ve kütleli debisinin belirlenmesi amaçlanmıştır. İki katmanlı yapay sinir ağı modellemesi ile hata oranı düşük ve termodinamik olarak tutarlı sonuçlar elde etmişlerdir. Akışkanların termodinamik özellikleri sebebiyle lineer olmayan davranışlarının yapay sinir ağları ile kolayca hesaplanabilir olması önemli bir konu olarak karşımıza çıkmaktadır. Araştırmacılar sonuçların tutarlılığının en önemli sebebinin öğrenme prosedüründe yer alan yöntem ve veriler olduğunu vurgulamışlardır.

Yapay sinir ağları bir fonksiyondur. Aşağıdaki Şekil 2.2’de görüleceği üzere yapay sinir ağları giriş, gizle ve çıkış katmanlı olmak üzere üç ana bölümden oluşur. Her bölüm içerisinde nöron adı verilen biyolojik nöronları sayısal olarak simüle eden birer yapıdır. Nöronlar sıfır ile bir arasındaki sayısal değerlerdir. Bu değerlere weight ve bias eşlik ederek nöronların sinirsel aktivitelerini simüle etmektedirler. Bunun için ayrıca toplam ve aktivasyon fonksiyonlarını kullanırlar.



Şekil 2.2: Yapay sinir ağları yapısı şematik gösterimi (URL 4)

Aktivasyon fonksiyonu olarak literatürde en çok sigmoid, tanh ve ReLU fonksiyonları kullanılmaktadır. Günümüzde hızlı ve popüler olarak kullanılan aktivasyon fonksiyonu ReLU’dur. Yapay sinir ağları gücünü öğrenmeden alır. İyi bir veri seti ile öğrenmiş olan yapay sinir ağları ile bir çok hesaplama farklı parametre ile yapılabilmektedir. Öğrenme prosedürü farklılık göstermektedir. Burada weight için bir

fonksiyon belirlenmelidir. Bu da iki farklı fonksiyon olan kayıp fonksiyonu ve gradient inişi fonksiyonlarıdır. Bu sayede çok sayıda öğrenme denemesi içerisinde yerel minimumlar vasıtasıyla doğru sonuca ulaşmak için hesaplamalar yapar. Literatürde yapay sinir ağları ile uygulanan hesaplama yöntemleri yüksek oranda tutarlıdır (Sun 2017).

Literatürde yapay sinir ağları ve genetik algoritmanın jeotermal sistemlerin modellenmesi ve optimizasyonunda kullanımı yeni gelişen bir araştırma alanı olarak karşımıza çıkmaktadır. Ayrıca yapılan çalışmalar yapay sinir ağı ve genetik algoritmaların ayrı ayrı kullanılarak santralleri modellediği literatür araştırmasında anlaşılmaktadır. Genetik algoritmanın doğru bir şekilde çalışabilmesini sağlayan ve optimizasyonun başarısını etkileyen en önemli etkenin uygunluk fonksiyonu olduğu anlaşılan bir diğer sonuçtur. Uygunluk fonksiyonu için seçilen fonksiyonlar termodinamik bağıntılar olabileceği gibi daha farklı fonksiyonlar da seçilebilir. Bu aşamada jeotermal enerji santralleri gibi optimizasyonu karmaşık ve zahmetli olan problemlerin çözümünde yeni bir yaklaşım ile özgün bir yöntemin geliştirilmesi hedeflenmiştir. Bu çalışmada özellikle uygunluk fonksiyonu için yapay sinir ağı geliştirilmesi ve bu yapay sinir ağının da gerçek jeotermal santral verileri kullanılarak öğrenmesinin sağlanması ile yenilikçi bir uygulama geliştirilmiştir. Bu sayede jeotermal santrallerin işletilmesinde karşımıza çıkan çok fazla sayıda fiziksel parametrenin güç üretimi ve iç tüketime etkisi yapay sinir ağı tarafından belirlenerek bir fonksiyon oluşturulmaktadır. Belirlenen derin yapay sinir ağlarını uygunluk fonksiyonu olarak kullanan genetik algoritma optimizasyon yöntemi ile jeotermal sistemlerin karmaşık doğasından ortaya çıkan belirsizlikler, doğrusal olmayan ilişkiler, zor ve zahmetli hesaplama yöntemleri ile insan hataları en aza indirilerek verimli, sürdürülebilir ve optimum işletme ve tasarım parametreleri belirlenebilecektir.

3. MATERYAL

Jeotermal santral optimizasyonu için bu tez kapsamında geliştirilen derin yapay sinir ağlarını uygunluk fonksiyonu olarak kullanan genetik algoritma yöntemi geliştirilmiştir. Daha önceki bölümlerde yöntemde kullanılan yapay sinir ağları ve genetik algoritmanın temel işleyişinden bahsedilmiştir. Bu bölümde ise hesaplama yönteminin detayları, hangi araçlar ile programlama dilinin seçildiği ve nasıl çalıştığı anlatılarak kullanılan verilerin kaynaklarından ve nasıl elde edildiğinden bahsedilecektir.

Yöntemin tasarlandığı programlama dili Python programlama dilidir. Modelin Python dilinde oluşturulması için gereken kodlar farklı araçlar kullanılarak yazılabilir. Literatürde ve çevrimiçi sitelerde Eclipse PyDev, Visual Studio Code, Vim, PyCharm, IDLE ve Google Colab gibi araçlar kullanılarak python dilinde modeller oluşturulabildiği görülmektedir. Bahsedilen araçların kendi içerisinde avantaj ve dezavantajları mevcuttur. Aynı zamanda kullanıcı için kullanıcı arayüzünün zorluk seviyesi, ücretli olup olmaması veya başlangıç seviyesinde olup karmaşık problem çözümleri için yeterli olmaması gibi problemlerden dolayı bu çalışma için en uygun araç Google Colab seçilmiştir. Modelleme kütüphanelerinin entegre olarak içerisinde bulunması, kesintisiz kod çalıştırma ve herkes tarafından ücretsiz olarak kullanılabilmesi sebebiyle Google Colab tercih edilmiştir. Google Colab makine öğrenimi modelleri oluşturmak ve Python dil kodlarını derleyerek model oluşturmak için tasarlanmıştır. (URL 3).

Bu çalışmada Google Colab içerisindeki entegre Python kütüphaneleri ile derin yapay sinir ağı ve genetik algoritma modellemeleri yapılmıştır. Aynı zamanda optimizasyon problemlerini çözmek için gerekli olan veriler google drive veya bulut ile modele yüklenebilmektedir. Bu sayede kullanıcı için esnek ve hızlı çalışma olanağı sağlanmaktadır. Python programlama dili ve modelin geliştirilmesinde kullanılan Python kütüphanelerinin detayları anlatılarak yöntemin temeli oluşturulacaktır.

3.1 Python Programlama Dili

Python, Guido van Rossum tarafından 1990 yılında geliştirilip piyasaya sürülen genel amaçlı bir programlama dilidir. Anlaşılması kolay ve geniş kütüphanesi sayesinde literatürdeki bir çok araştırmacı tarafından yapay sinir ağı ve genetik

modelleme için tercih edilmektedir. Başlangıç seviyesinden çok daha karmaşık problemlerin çözümüne kadar makine öğrenmesi tabanlı modeller geliştirmeye olanak tanımaktadır. Özellikle veri işleme ve yapay zeka alanında sağlamış olduğu pandas, NumPy, Matplotlib, Tensorflow ve Keras gibi kütüphaneler sayesinde araştırmacıların çalışmalarında önemli bir araç olarak karşımıza çıkmaktadır. Açık kaynak kodlu olması sebebiyle ilk piyasaya sürülmesinden bu yana bir çok versiyon geliştirilmiştir.

Google Colab kullanılarak hazırlanan son sürümü 2.14.0 olan python dili yardımıyla bu tez kapsamındaki hesaplama modeli geliştirilmiştir. Bu modelin içerisinde kullanılan kodlamaların bir kısmı ile geniş kütüphanelerin nasıl çalıştığı anlatılacaktır. Aynı zamanda veri seti ve jeotermal enerji santrali hakkında bilgiler verilecektir.

3.1.1 Yapay Sinir Ağı ve Genetik Algoritmada Kullanılan Kütüphaneler

Python programı içerisinde kullanılan çok farklı kütüphaneler mevcuttur. Özellikle yapay sinir ağı ve genetik algoritma için literatürde sıkça kullanılan tensorflow ve keras kütüphaneleri bu çalışmada da kullanılmıştır. Aynı zamanda matematiksel işlemler ve veri analizleri için, Pandas, NumPy ve Mathplotlib kütüphaneleri model içerisinde işlemleri kolaylaştırmak için tercih edilmiştir (Müller ve Guido 2016).

Bu tez kapsamında geliştirilen hesaplama yönteminin modellenmesinde kullanılan kütüphaneler; TensorFlow, NumPy, Mathplotlib, Pathlib, Keras tır. Aynı zamanda bazı matematiksel işlemleri yapabilen randint, seed, gauss, randrange ve random komutları ile çalışan hazır kütüphanelerdir.

TensorFlow, Google mühendisleri tarafından makine öğrenmesi için geliştirilen açık kaynak kodlu yazılım kütüphanesidir. Veri akış grafiklerini kullanarak sayısal hesaplamalar yapabilmektedir. Özellikle derin öğrenme ve yapay zeka araştırmalarında kullanılmaktadır. NumPy, verileri çok büyük dizi ve matrisler ile üst düzey matematiksel işlemler yapabilmeye olanak tanıyan Python kütüphanesidir. Bu sayede verilerin işlenmesi daha hızlı ve kolay hale gelmektedir. Mathplotlib ise, verilerin görselleştirilmesi için kullanılan bir kütüphanedir. Grafiklerin görselleri bu

kütüphane ile oluşturularak analiz sonuçları yorumlanabilmektedir. Pathlib, dosyalama sistemi yoluyla veriler ile çalışmayı kolaylaştıran Python kütüphanesidir.

Bir diğer kütüphane olan Keras, TensorFlow üzerine inşa edilmiş açık kaynak kodlu bir sinir ağı kütüphanesidir. Kolay bir kullanım sunarak derin sinir ağı modellemesi ve eğitilmesine olanak sağlar. Tüm bu kütüphaneler ile derin yapay sinir ağları ve genetik algoritma modellenebilmektedir.

Bir başka sık kullanılan kodlar ise matematiksel işlemlerin bir kod ile yapılabildiği hazır modüllerdir. Randint, random modülünün yine bir fonksiyonu olup rastgele sayıları üretmek ve belirli bir sayı aralığında döngü oluşturmak için kullanılır. Genelde eklenecek rastgelelik için kullanılmaktadır. Seed ise, oluşturulacak rastgele sayıların başlangıç noktasıdır. Bu sayede rastgele sayı üretiminin tekrarlanabilir olması sağlanmış olur. Matematiksel bir dizi olan gauss dağılımından yola çıkarak gauss modülü ile belirli bir aralıkta gauss dağılımına göre rastgele sayılar üretilmektedir. Özellikle olası verilerin üretilmesi için kullanılmaktadır. Gauss dağılımının yapay sinir ağı ve genetik algoritmalarda kullanılmasının başlıca sebebi ise bu dağılımın doğada en çok görülen matematiksel örüntülerden birisi olmasıdır. Randrange ise, yine belirli bir aralıkta sayı döngüleri oluşturmayı sağlar. Son olarak Random ise tüm bu matematiksel işlemlerin temelidir. Random 0 ve 1 değeri arasında ondalık sayılar üretmektedir. Tüm rastgele sayı üreten modüller ve komutlar modelin belirli bir aşamasında farklı değerlerde rastgeleliğe ihtiyaç duyulması sebebiyle kullanılmaktadır. Aynı zamanda modellenen yapay sinir ağı ve genetik algoritmada önemli işlemler yapmaktadırlar. Her bir kütüphane ve matematiksel fonksiyon, modelin farklı bir aşamasını destekleyerek karmaşık yapay zeka sistemlerinin geliştirilmesine olanak tanırırlar.

Derin yapay sinir ağları ile genetik algoritma bu kütüphane ve matematiksel yöntemler sayesinde modellenerek hesaplama yöntemi oluşturulmuştur. Oluşturulan bu yöntemin analiz yapabilmesi için gerekli olan en önemli materyal ise veri setleridir. Yapay sinir ağlarının doğası gereği çok fazla sayıda ve çeşitte verinin toplanması yöntemin tutarlılığını arttırmaktadır. Bu sebeple verilerin nereden ve nasıl elde edildiği en önemli konulardan bir tanesidir. Veri seti ile verinin temin edildiği santralin tasarım ve işletme parametrelerinin detaylı bilgileri aşağıda açıklanmıştır.

3.2 Veri Seti

Joetermal enerji santrali optimizasyonu için geliştirilen yöntem santralin SCADA sisteminde kayıt edilen verilere ihtiyaç duymaktadır. Yöntemin girdi ve çıktıları bu kaynaktan elde edilecek veriler ile oluşturulmuştur. İzmir ili içerisinde faaliyet gösteren bir jeotermal enerji santralinden kayıt altına alınan veriler ile analizler gerçekleştirilmiştir. Santral verileri için firma ile gizlilik sözleşmesi yapılmıştır. Bu sözleşme maddelerine göre santral verileri akademik çalışmalar için kullanılacaktır.

Veri setleri santralin SCADA sisteminden elde edilen verilerdir. Bu veriler santral tasarımında SCADA üzerinde kayıt altına alınmaktadır. Santral çalışanları ve yetkilileri tarafından bilgisayar ortamında hazırlanan ve toplanan veriler excel formatında tarafımıza iletilmiştir. Verilerin santral SCADA sistemine bağlı olarak belirli bir kısmının kayıt altına alındığı bildirilmiştir. Bu sebeple excel dışındaki verilerin kayıt edilemediği unutulmamalıdır. Firma tarafından sağlanan verilerden bir kısmı örnek olarak Tablo 3.1, Tablo 3.2, Tablo 3.3, Tablo 3.4'te gösterilmiştir.

Tablo 3.1: Üretim kuyularında kayıt altına alınan örnek veriler

Kuyu 1					
Debi	Basınç	Sıcaklık	Pompa Devir	Pompa Frekans	Pompa Akım
m ³ /h	bar	°C	rpm	Hz	A
214,2	9,8	143,5	1500	92	361
213,2	9,8	143,5	1500	92	360
216,8	9,7	143,5	1500	92	360
214,1	9,9	143,5	1500	92	361
212,7	9,9	143,5	1500	92	361
Kuyu 2					
Debi	Basınç	Sıcaklık	Pompa Devir	Pompa Frekans	Pompa Akım
m ³ /h	bar	°C	rpm	Hz	A
146,9	6,9	127,7	1500	87	341
147,2	7	127,7	1500	87	342
150,2	6,8	127,7	1500	87	342
144,4	6,9	127,8	1500	87	342
144,3	6,9	127,8	1500	87	342

Tablo 3.2: Üretim ve reenjeksiyon kuyularında kayıt altına alınan örnek veriler

Kuyu 3				Reenjeksiyon 1	
Debi	Kuyubaşı Basıncı	Seperasyon Basıncı	Seperasyon Sıcaklığı	Debi	Kuyubaşı Basıncı
m ³ /h	bar	bar	°C	m ³ /h	bar
255,8	6,3	5,6	162,2	75,3	3,8
258,8	6,4	5,8	162,7	85,2	3,8
249,4	6,3	5,9	163,7	75,2	3,7
252,3	6,3	5,8	163	85,9	3,6
254	6,3	5,8	163,2	85,8	3,7
Reenjeksiyon 2		Reenjeksiyon 3		Üretim	Reenjeksiyon
Debi	Kuyubaşı Basıncı	Debi	Kuyubaşı Basıncı	Debi	Debi
m ³ /h	bar	m ³ /h	bar	m ³ /h	m ³ /h
515	3,1	0	0	598,2	598,2
515,9	3,1	0	0	601,1	601,1
515,4	3,1	0	0	590,6	590,6
508,7	3	0	0	594,6	594,6
509,5	3	0	0	595,3	595,3

Tablo 3.3: Organik rankine çevriminden elde edilen örnek veriler

ORÇ Türbin Giriş	ORÇ Türbin Çıkış	Brine Reenjeksiyon	Brine Giriş	Brine Çıkış	Giren Brine	Giren Brine	Dış Ortam
Basınç	Basınç	Sıcaklık	Basınç	Basınç	Sıcaklık	Debi	Sıcaklık
bar	bar	°C	bar	bar	°C	t/h	°C
19,5	3,78	65,9	10	3,4	143,7	598,2	23,5
19,3	3,73	65	9,8	3,4	147,2	601,1	22
19,4	3,72	64,9	9,9	3,3	147,6	590,6	22
19,4	3,67	64,8	9,9	3,3	147,6	594,6	21
19,4	3,74	65,2	9,9	3,3	147,6	595,3	21

Yukarıdaki şekillerden de anlaşılacağı üzere santral yetkilileri tarafından kayıt altına alınan veriler üretim kuyuları, reenjeksiyon kuyuları, santral giriş ve çıkışındaki toplam jeotermal akışkan debi, sıcaklık ve basınç değerleri, organik rankine çevriminin olduğu türbin giriş çıkış basıncı, dış hava sıcaklığı, brüt güç üretimi, iç tüketim ve bunların farkı olan net güç üretimidir. Santralde ısı değiştiriciler ve pompaların giriş çıkış özellikleri kayıt altına alınmamaktadır. Ancak santral ziyaretleri sırasında tasarımda olmayan ve montaj aşamasında yerleştirilen sıcaklık ve basınç

göstergeleri tespit edilmiştir. Bu göstergeler reküperatör giriş ve çıkışındaki, düşük basınç buharlaştırıcısı girişindeki, yüksek basınç girişindeki sıcaklık ve basınçları ölçmektedir. Bu ölçümler araştırmacı tarafından sahada gözlenerek kayıt altına alınmıştır. Ölçümün alındığı süre içerisinde SCADA ekran görüntüsü de alınarak termodinamik analizler için veriler alınabilmektedir. Eldeki veriler ile kuyuların ve güç üretiminin gerçekleştiği türbinin optimizasyonu yapılarak işletme şartları bulunabilir. Bulunan değerler ile yapılacak karşılaştırmalı termodinamik analiz sonucunda santral işletmesi yeniden düzenlenerek verimli bir işletme sağlanabilir.

Tablo 3.4: Organik rankine çevrimi ve jeneratörden elde edilen örnek veriler

Buhar ve NCG	Buhar ve NCG	NCG Çıkış	NCG Çıkış	Brüt Güç	İç Tüketim	Net Güç
Debi	Basınç	Basınç	Sıcaklık	Güç	Güç	Güç
m ³ /sa	bar	bar	°C	MW	MW	MW
4693	5,47	7,1	36,6	8,00	1,915	6,09
4050	5,71	6,8	36,1	8,13	1,935	6,20
4185	5,74	6,8	26,9	8,12	1,885	6,24
4482	5,66	6,8	29,5	8,31	1,925	6,39
4410	5,66	6,8	31,6	8,13	1,89	6,24

Veriler excel formatında toplamda 41 sütun ve 11944 satırdan oluşmaktadır. Toplamda 489.704 adet veri bulunmaktadır. Bu verilerden sadece brüt güç ve iç tüketim çıktı olarak kullanılmaktadır. Ayrıca diğer tüm veriler girdi olarak kullanılacaktır. İlerleyen bölümlerde açıklanacağı gibi verilerden üretilen korelasyon matrisi ile brüt güç üretimi ve iç tüketime etki eden veriler belirlenerek modelin son halinde girdi olarak kullanılacaktır. Amaç fonksiyonu ise bu iki verinin farkı olan net güç üretimidir. Net güç üretimini maksimum yapabilmek için hesaplama yöntemi brüt güç üretimini maksimum ve iç tüketimi ise minimumda olacak şekilde santrali optimize etmeye çalışacaktır. Hesaplama yönteminin doğası gereği özellikle yapay sinir ağı uygulamalarında çok fazla sayı ve çeşitte veriye ihtiyaç duyulmaktadır. Tez kapsamında yapılan çalışmalarda elde edilen veriler gizlilik sözleşmesinin yapıldığı 01.01.2022 tarihinden 18.05.2023 tarihine kadar olan toplamda 17 aylık verilerdir. Araştırma başlangıcından itibaren gönderilen verilerin adeti arttıkça hesaplama yönteminin güvenilirliği ve tutarlılığının iyileştiği görülmüştür. Yöntem bölümünde ise çalışmanın süreci ve detayları anlatılacaktır. Santralin tasarımı ve işletme

parametreleri ile elde edilen sonuçların karşılaştırılabilmesi için santral tasarımı hakkında bilgi verilecektir. Yapılan gizlilik anlaşması sebebiyle santral verileri ve bilgilerindeki firma ismi gizlenmiştir.

3.3 Jeotermal Enerji Santrali Tasarım ve İşletme Bilgileri

Jeotermal santraller arasında Türkiye’de en çok kullanılan teknoloji organik rankine çevrimine göre çalışan ikili tip jeotermal enerji santralleridir. Bu santraller düşük ve orta derece jeotermal sahalarda kullanılabilmesi ve flaş buharlı santrallerde yoğunlaştırılan veya ayrıştırılan jeotermal akışkanın geri kazanımının sağlanabilmesi açısından tercih edilmektedir.

Araştırma kapsamında kullanılmak üzere İzmir ili içerisinde işletmede olan jeotermal enerji santrali yönetimi ile 2022 yılının Mart ayında gizlilik sözleşmesi imzalanmıştır. Bu sözleşmeye göre firma ismi gizli kalmak koşulu ile santral verileri hesaplama yönteminin geliştirilmesi ve analizlerin akademik olarak yayınlanabilmesi için mutabakata varılmıştır.

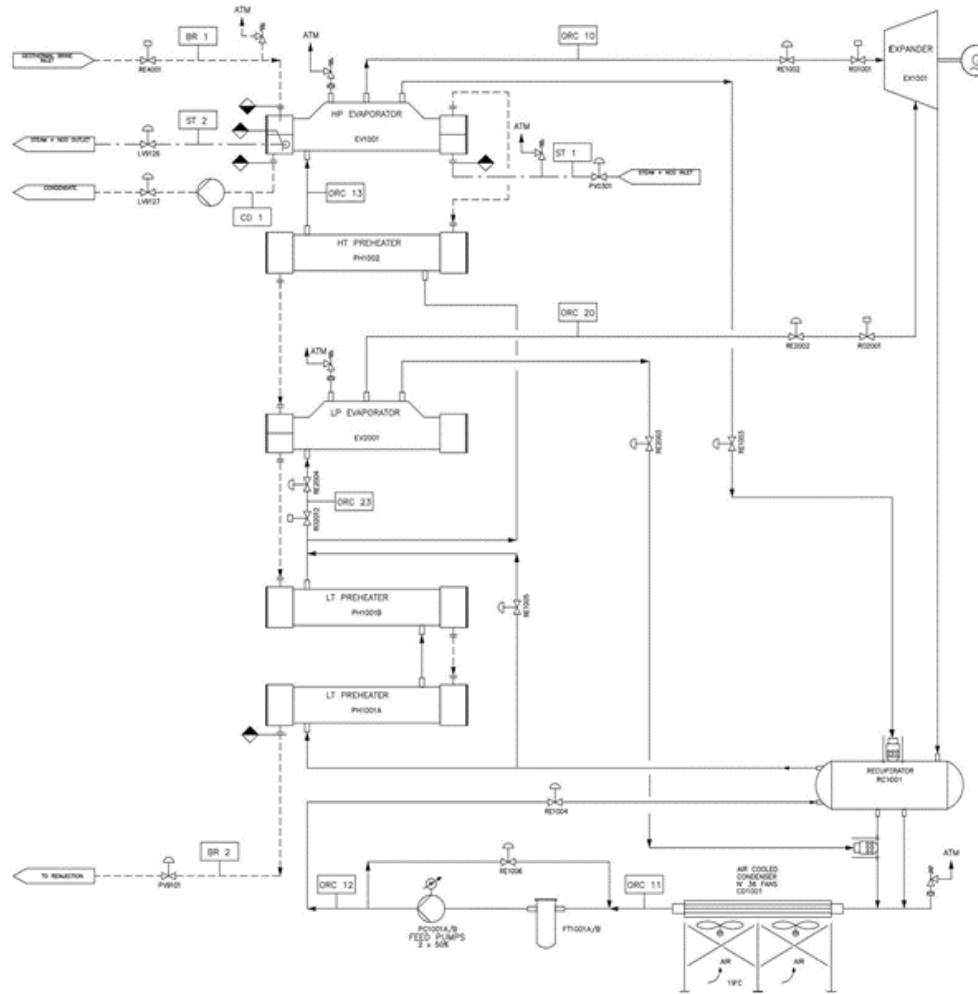
Jeotermal enerji santrali 12,24 MWe brüt güç üretimi olacak şekilde tasarlanmıştır. İkincil akışkan olarak ise n-bütan tercih edilmiştir. Exergy marka türbin kullanan santral çift basınç kademeli ısı değiştirici ve türbin tasarımına sahiptir. Yoğuşma sistemi hava soğutmalı olacak şekilde tercih edilmiştir. Hava soğutmalı santrallerin verimi mevsimsel olarak dış hava sıcaklığına doğrudan bağlıdır (DiPippo 2012). Yakınında akarsu veya benzeri bir su kaynağı olmayan santrallerde en çok tercih edilen sistem hava soğutmalı yoğunlaştıruculardır.

Jeotermal enerji santralinin tasarımsal olarak nasıl çalıştığını anlamak araştırmacının analiz sonuçlarını karşılaştırmalı olarak yorumlamasına olanak tanımaktadır. Bu santralde jeotermal akışkanın sıvı fazı olan brine ile buhar fazındaki jeotermal akışkan farklı boru hatları ve ısı değiştirici yüzeyleri olan yüksek basınç (YB) buharlaştırıcısına girmektedir. Buhar YB buharlaştırıcısından ayrılarak bir yoğuşma tankında aktarılıp reenjeksiyon kuyularına gönderilmektedir. Daha sonra YB buharlaştırıcısından çıkan brine YB ön ısıtıcısına girmektedir. İki basınç kademeli olan santralde brine, YB buharlaştırıcısından çıktıktan sonra alçak

basınç (AB) buharlaştırıcısına bir miktar ısı enerjisi aktarır. Santralde organik akışkan bölümünün henüz YB veya AB olarak ayrışmadığı noktada brine 2 adet ön ısıtıcı eşanjöre ilerler ve son olarak santralden çıkıp reenjeksiyon kuyularından yeraltına basılmaktadır. Organik Rankine çevriminde (ORC) ise besleme pompalarında basınçlandırılan n-bütan iş akışkanı önce reküperatörden bir miktar ısı enerjisi alarak 2 adet ön ısıtıcıya girmektedir. Sonrasında aktüatör kontrollü vana yardımıyla YB ve AB kademelerine ayrılarak bir kısmı AB buharlaştırıcısına girmekte ve oradan kızgın buhar halinde türbinin AB kısmında genişlemektedir. Daha sonra YB kısmına giden iş akışkanı YB ön ısıtıcısı ve buharlaştırıcısından geçerek türbinin YB kısmında genişlemektedir. Her iki basınç kademesinden türbine gelen akışkanlar aynı sıcaklık ve basınçta türbinden çıkarak hava soğutmalı yoğunlaştırıcıya sıvı faza geçtikten sonra çevrim tamamlanmaktadır. Özel tasarlanan türbin sayesinde yüksek ve alçak basınç kademeleri aynı anda tek bir türbinde toplanmıştır. Bu sayede daha düşük yatırım ve işletme maliyetleri ile daha fazla enerji üretilmesi hedeflenmiştir.

Santral verimi dış hava sıcaklığı, santral tasarımı, jeotermal kuyu işletmesi ve santralin işletme algoritmasına bağlı olarak değişkenlik göstermektedir. Bu nedenle her santralin optimizasyonu, kendine özgü koşulları ve tasarımı gereği farklılık gösterebilir. Optimizasyonu yapılacak olan santralin tasarım ve işletme şartları analiz edilerek hesaplama yöntemi ile karşılaştırmalı olarak sunulması hem santralin termodinamik çıktılarının bulunması hem de hesaplama modelinin işlevinin araştırılması açısından önemlidir. Santralin tasarımında kullanılan değerler ile ısı ve kütle diyagramı Şekil 3.1’de verilmiştir. Ayrıca santralin tasarım parametreleri Tablo 3.5’te özetlenmiştir.

Santralin tasarım parametreleri optimizasyon çalışmalarında fiziksel sınırları gösteren en önemli verilerdir. Bunların yanı sıra işletme parametreleri ile tasarıma uygun şekilde optimizasyon yapılabilir. Santral tasarımı yapan firmalar tasarım parametrelerinin %10 üzerinde çalışabilecek şekilde imalat ve montaj yapabilirler. Bu sebeple işletme parametrelerinin bilinmesi tasarıma göre en uygun şartların seçilebilmesine olanak tanımaktadır. Santralde kayıt altına alınan verilerine göre sistem farklı zaman dilimlerinde ve işletme şartlarına göre 1 – 11 MW aralığında brüt güç üretecek şekilde çalıştırılmıştır.




PERFORMANCE DATA

ORC Gross Power (2)		MW		12,240			
ORC Auxiliary Power Consumption (2)		MW		1,800			
ORC Net Power		MW		10,440			
ORC 10	M	U/h	340	BR 1	M	U/h	823.7
	T	°C	123		T	°C	248.2
	P	bar	21.6		P	bar	11
ORC 11	M	U/h	269	BR 2	M	U/h	823.7
	T	°C	37		T	°C	79
	P	bar	3.6		P	bar	0.5
ORC 13	M	U/h	259	ST 1	M	U/h	25.4 + 0.25
	T	°C	38		T	°C	152
	P	bar	27.8		P	bar	0
ORC 13	M	U/h	240	ST 2	M	U/h	0.3 + 0.3
	T	°C	123		T	°C	139
	P	bar	21.6		P	bar	0.5
ORC 20	M	U/h	189	CD 1	M	U/h	25.1
	T	°C	100		T	°C	139
	P	bar	13.7		P	bar	0.5
ORC 23	M	U/h	189				
	T	°C	98				
	P	bar	13.7				

NOTES
 (2) At motor terminals and generator terminals at each-1

LEGEND
 M = Mass flow rate
 T = Temperature
 P = Pressure



Şekil 3 1: Verileri kullanılan santralin ısı ve kütle diyagramı

Bu araştırma kapsamında brüt güç ve iç tüketim için minimum ve maksimum değerler belirlenmiştir. Hesaplama yöntemi bu değerler arasında santrali modellemiş ve olası işletme şartlarını hesaplayarak optimizasyon çalışması yapmıştır. Aynı zamanda yöntemin tutarlılığını gösteren bir diğer önemli veri ise hesaplamalar sonucunda santralin işletme parametrelerine çok yakın değerler üretmesidir. Bu sayede hesaplama modelinin optimizasyon analizlerinde kullanılacak veriler üretebileceği ve bu verileri üzerinde çalışılan santralin işletme şartlarına göre yapabileceği gösterilebilir.

Elde edilen veriler ile yapay sinir ağlarını uygunluk fonksiyonu olarak kullanan genetik algoritma optimizasyon yöntemi geliştirilmiştir. Jeotermal enerji santrallerinin optimizasyonunda yenilikçi ve özgün bir yaklaşım olarak sunulmuştur. Sonraki bölümde yöntemin detayları, geliştirme süreci, kullanılan kütüphane ve kodlar ile yöntemden elde edilen veriler açıklanacaktır. Bunun yanı sıra termodinamik analiz yöntemleri ve hesaplamalarından bahsedilecektir. Sonuçlar termodinamik bakış açısıyla karşılaştırmalı olarak analiz edilerek bulgular bölümünde açıklanacaktır.

Tablo 3.5: Santral tasarım parametreleri

İZMİR JES	DEBİ (t/h)	SICAKLIK (°c)	BASINÇ (bar)
GİREN BRİNE	823,7	144,2	11
ÇIKAN BRİNE	823,7	70	8,5
YÜKSEK BASINÇ İKİNCİL AKIŞKAN	540	125	24,6
ALÇAK BASINÇ İKİNCİL AKIŞKAN	169	100	15,7
BUHAR GİRİŞ	25,6	152	5
BUHAR ÇIKIŞI	0,5	139	4,9
KONDENS ÇIKIŞI	25,1	139	4,9
BRÜT GÜÇ ÜRETİMİ (kWe)	12.240		
İÇ TÜKETİM (kWe)	1.920		
NET GÜÇ ÜRETİMİ (kWe)	10.320		

4. METOT

Santrallerin verimli tasarlanması için optimum işletme koşullarının belirlenmesi işletmelerin maliyet analizleri açısından önem arz etmektedir. Tasarımı yapılan jeotermal santraller genellikle türbin firmasının işletme algoritması ile santralleri çalıştırmaktadırlar. Ancak jeotermal sahalar doğası gereği zaman içerisinde tasarım şartlarından farklılık oluşacak şekilde termofiziksel özellikleri değişebilmektedir. Bu sebeple santrallerin işletme koşulları göz önüne alınarak optimum şartlar sürekli hesaplanabilmelidir. Santrallerin dinamik olarak sürekli izlenebilir olmasını ve işletme şartlarının optimize edilebilmesine imkan tanıyacak, parametrik çalışmalardan çok daha kısa sürede sonuç veren bir hesaplama yöntemine ihtiyaç duyulmaktadır.

Yapay sinir ağları ve genetik algoritma ile literatürde yapılan çalışmalar bu yöntemlerin jeotermal enerji santrallerine uygulanabileceğini göstermektedir. İlerleyen zamanlarda bu çalışmalar geliştirilerek tam zamanlı kullanıcıya yönelik santral simülasyonları oluşturulabilir. Yapılan çalışmalarda yapay sinir ağları ve genetik algoritma ayrı ayrı hesaplama yöntemi olarak değerlendirilmiş ve karşılaştırmalı analizler yapılmıştır. Aynı zamanda iki yöntemin birlikte uygulandığı çalışmalar da yapılabilir. Bu bağlamda genetik algoritmanın (GA) içerisindeki en etkili fonksiyon olan uygunluk fonksiyonunun derin yapay sinir ağları (DSA) ile modellenmesi özgün bir fikir olarak karşımıza çıkmaktadır. Her iki yöntem de bu şekilde kullanılarak birbirlerini tamamlayan ve hesaplama yönteminin tutarlılığını arttıran bir geliştirme sağlanabileceği hedeflenmektedir.


Bu çalışmada geliştirilen yöntemde genetik algoritmanın tercih edilmesinin en önemli sebebi veri üretebilme ve bu verileri santral doğasının uygunluğuna göre test ederek farklı senaryoları oluşturabilme yeteneğidir. Santralin çalışma şartlarının uygunluğu genetik algoritma içerisindeki bireylerin başka bir ifade ile üretilen jeotermal saha verilerinin uygunluk fonksiyonunda değerlendirilmesi ile belirlenmektedir. Bu sebeple uygunluk fonksiyonu jeotermal sahaya uygun bir fonksiyon seçilerek daha tutarlı sonuçlar elde edilebilir. Ancak literatürde ve uygulamalarda kullanılan genetik algoritmalar, verilerin doğruluğunu hesaplayan uygunluk fonksiyonu için genelde mevcut veya termodinamik fonksiyonları

kullanılmaktadırlar. Bu fonksiyonlar ile başarılı sonuçlar elde edilmiştir. Bunun yanı sıra jeotermal enerji santralleri gibi karmaşık fiziksel ilişkilerin tamamını tanımlayabilecek tek bir fonksiyon yoktur. Regresyon analizleri ile bu bağlantılar bulunabilir. Fakat jeotermal enerji santrallerindeki veriler göz önüne alındığında böyle bir regresyon analizinin çok zor ve uzun zaman alacağı anlaşılabilir.

Yapay sinir ağları girdi ve çıktılar arasındaki bağıntıları bularak geniş kapsamlı bir fonksiyon üretebilmektedirler. Bu özellikleri sayesinde genetik algoritmada derin yapay sinir ağlarını uygunluk fonksiyonu olarak kullanan optimizasyon yöntemi geliştirilmiştir. Yapay sinir ağları, veriler arasındaki bağıntıları bulabilmek için girdi ve çıktılarının farklı zamanlardaki değerlerine ihtiyaç duymaktadır. Başka bir ifade ile çalışma şartlarındaki mevsim, ay, gece ve gündüz farklılıkları gibi çeşitli şartlardaki santral verileri kullanılarak daha tutarlı bir bağıntı oluşturulabilir. Yapay sinir ağları fiziksel şartların tamamını analiz edebilecek şekilde eğitilmiştir. Jeotermal enerji santrallerinin bir yıllık çalışma süreleri içerisinde üretilen saatlik veriler ile mevsimsel döngülerin oluşturduğu farklılıklar sayesinde yapay sinir ağı modeli santral verileri arasındaki bağıntıları çözebilmektedir. Sonraki bölümlerde bu tez kapsamında geliştirilen yöntemin modellenmesi açıklanarak, mühendislik bakış açısı ve termodinamik hesaplamalar ile karşılaştırmalı analizleri detaylı olarak anlatılacaktır.

4.1 Derin Yapay Sinir Ağlarının Modellenmesi

Derin yapay sinir ağları insan beyninin çalışma prensiplerini matematiksel olarak modelleyen ve buna bağlı olarak iki veri arasındaki bağlantıları ortaya koyan özelleştirilmiş analiz yöntemlerinden bir tanesidir. İnsanın sinir hücrelerindeki işleyiş matematiksel olarak modellenmiştir. Modelin matematiksel işlemleri yapabilmesi bilgisayar donanım ve yazılımlarıyla mümkün olmaktadır. Son yıllarda geliştirilen bilgisayar işlemci teknolojileri ve bu alandaki yazılımlar sayesinde DSA akademik çalışmalardan sahadaki çalışmalara kadar kullanılabilir. Veriler ile kendi kendine öğrenebilen ve analiz yapabilen yapay sinir ağları geliştirilmiştir. Şekil 4.1’de sinir hücresinin matematiksel modeli gösterilmiştir.



Şekil 4 1: Sinir hücresinin matematiksel gösterimi (URL 4)

Bu modeldeki en küçük tahminleme biriminin tanımı 1957 yılında Frank Rosenblatt tarafından yapılmıştır. Buna göre (4.1) eşitliğinde verilen doğrusal denklem ile yapay sinir ağının en küçük birimi matematiksel olarak ifade edilmiştir (URL 4).

$$y = w \times x + b \quad (4.1)$$


Denklemdaki y bağımlı değişken olup girdiye ait skoru üretmektedir. Bağımsız değişken ise x 'tir. Ağırlık (weight) parametresi ve önyargı (bias) değeri sırasıyla w ve b 'dir. Yapay sinir ağları modelinin yapmış olduğu temel işlem en iyi skoru üretecek olan ağırlık (w) ve önyargı (b) parametrelerinin hesaplanmasıdır. Bir başka ifade ile sinir hücrelerinin diğer katmanlar ve kendi katmanına etkilerini ve genel mimariye etkisi hesaplanmış olur. Ağırlık ve bias değerleri sürekli olarak model tarafından güncellenmektedir. Bu aşamada çıkış performansını belirleyen kayıp fonksiyonu (loss function) değerinin sıfıra yaklaşması ile modeldeki değerler hesaplanarak en uygun fonksiyon belirlenebilir (Kızrak 2021).

Yapay sinir ağı modelinin performansına, seçilen sinir hücresi sayısı, katman sayısı ve aktivasyon fonksiyonu gibi bir çok parametre etki etmektedir. Bu parametrelere hiperparametre adı verilmektedir. Hiperparametreler veri setinin büyüklüğüne göre değişkenlik gösterebilir. Örnek verecek olursak katman sayısının artması hesaplama sonuçlarının hassasiyetini arttırmaktadır ancak gereğinden fazla

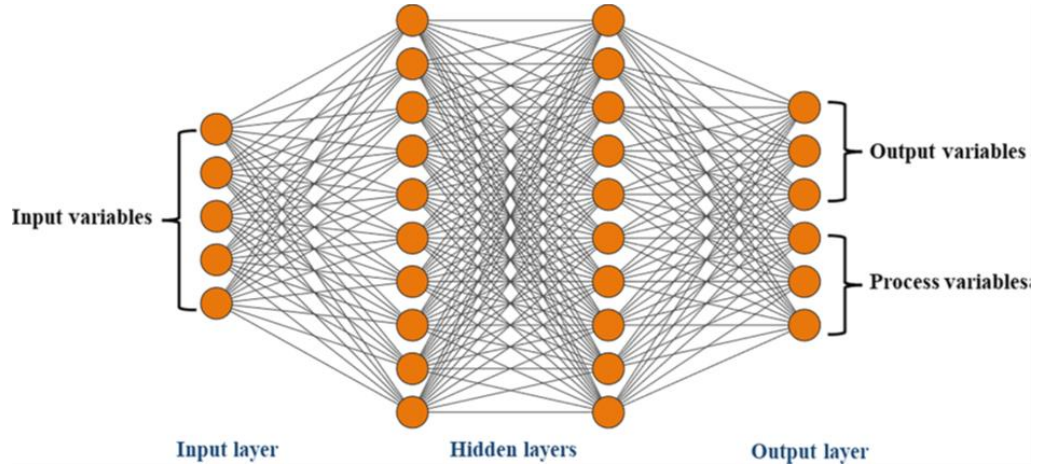
katman sayısının olması sonucu anlamlı olarak değiştirmeyebilir. Bu nedenle santralden elde edilen veri setine göre modelin mimarisi ve parametrelerin seçimi en iyi performans için genellikle deneme yanılma yoluyla bulunmaktadır (URL 5). Literatürde parametre optimizasyonu için diğer disiplinler tarafından farklı çalışmalar yapılmaktadır.

Modeldeki ağırlıkların düzenlenmesi ve hassasiyetinin optimize edilmesi için ileri-geri yayılım işlemi yapılmaktadır. Modelin başarısı elde edilen çıktı ile beklenen arasındaki farkın minimuma indirilmesine göre ölçülmektedir. Bu yöntem geriye doğru tüm fonksiyonların türevini alarak işlemleri tekrar ileri yönde başlatmaktadır. İteratif olarak tekrarlanan işlemler beklenen ile elde edilen değer arasındaki fark minimum olana kadar devam etmektedir. Burada da belirli bir iterasyon sonrasında aradaki fark değişmiyorsa işlem durdurulur. Daha sonra seçilen fonksiyon genetik algoritma içerisinde uygunluk fonksiyonu olarak kullanılabilir.

Yapay sinir ağı ve derin yapay sinir ağı arasındaki fark ise katman sayısının artmasıdır. Tek katman ile hızlı öğrenme oluşacağı ve hesaplamının istenilen hassasiyette olamayacağı anlaşılmaktadır. Bu nedenle daha fazla sayıda katman ve nöron ile modeli daha hassas ve güvenilir hale getirebilmek için derin öğrenme yöntemi kullanılmıştır. Şekil 4.2’de tek ve çok katmanlı sinir ağı yapısına örnek görülmektedir. Ayrıca Şekil 4.3’te daha kapsamlı bir yapay sinir ağı gösterilmiştir.



Şekil 4 2: Tek ve çok katmanlı sinir ağları (URL 4)



Şekil 4 3: Çok katmanlı sinir ağının yapısı (Ling ve diğ. 2024)

Modellenen Şekil 4.2’de görüleceği üzere 3 adet katman vardır. Bunlar; giriş, gizli ve çıkış katmanıdır. Tek veya çok katmanlı olmasını gizli katman sayısı belirlemektedir. Şekildeki tek katmanlı modelde giriş katmanı hariç 4 adet gizli ve 2 adet çıkış olmak üzere toplamda 6 adet nöron bulunmaktadır.

Çok katmanlıda ise 4 adet birinci gizli katmanda, 4 adet ikinci gizli katmanda ve 1 adet çıkış katmanında olmak üzere toplamda 9 nöron bulunmaktadır. Giriş ve çıkış katmanlarındaki ağırlık ve önyargı adetleri, gizli ve çıkış katmanlarındaki nöron sayısına göre belirlenir. Tek katmanlıda 3 giriş ile 4 adet gizli katman ve 4 adet gizli katman ile 2 çıkış katmanı sayısal olarak ayrı ayrı çarpılır ve her ikisi de toplanır. Sonuç olarak 20 adet öğrenilmesi gereken ağırlığa ihtiyaç vardır. Ayrıca 4 adet gizli ve 2 adet çıkış katmanındaki nöronların toplamı ile 6 adet öğrenilmesi gereken önyargı bulunur. Tek katmanlı örnekte toplamda 26 adet öğrenilmesi gereken parametre vardır. Aynı işlem Şekil 4.2’deki çok katmanlı model için de yapıldığında öğrenilmesi gereken 32 adet ağırlık ve 9 adet önyargı bulunur. Çok katmanlı örnekte de toplamda 41 adet öğrenilmesi gereken parametre ortaya çıkmaktadır (URL 4).

Derin yapay sinir ağlarındaki katman ve nöron sayısına bağlı olarak öğrenilmesi gereken ağırlık ve önyargıların sayısı artacaktır. Ancak hesaplamaların hassasiyeti ve güvenilirliği için gerekli olan bu işlemlerin ne kadar sayıda olacağını bulunması jeotermal santral verileri ile deneme yanılma yoluyla anlaşılabilir. Bir başka ifade ile belirli bir katman ve nöron sayısından sonra hata ve kayıp fonksiyonunda anlamlı değişiklik olmuyorsa adetleri arttırmaya gerek yoktur.

Arařtırmacı bu bağlamda gizli katman ve nöron sayısını araştırma sürecinde yapmış olduđu çalışmaları sonucuna göre belirlemiştir. Yapay sinir ağlarının modellenmesindeki optimum noktaların bulunması arařtırmacının aşması gereken bir başka problemdir. Optimum modelin bulunması ile ilgili literatürde çalışmalar yapılsa da kısıtlı alanda kalmakta ve farklı disiplinlerin araştırma konuları arasında yer almaktadır. Konu hakkında genel bir metodoloji geliştirilene kadar arařtırmacılar kendi optimum noktalarını deneme yanılma ile bularak problemlerine özgü yaklaşımlar geliştirebilirler.

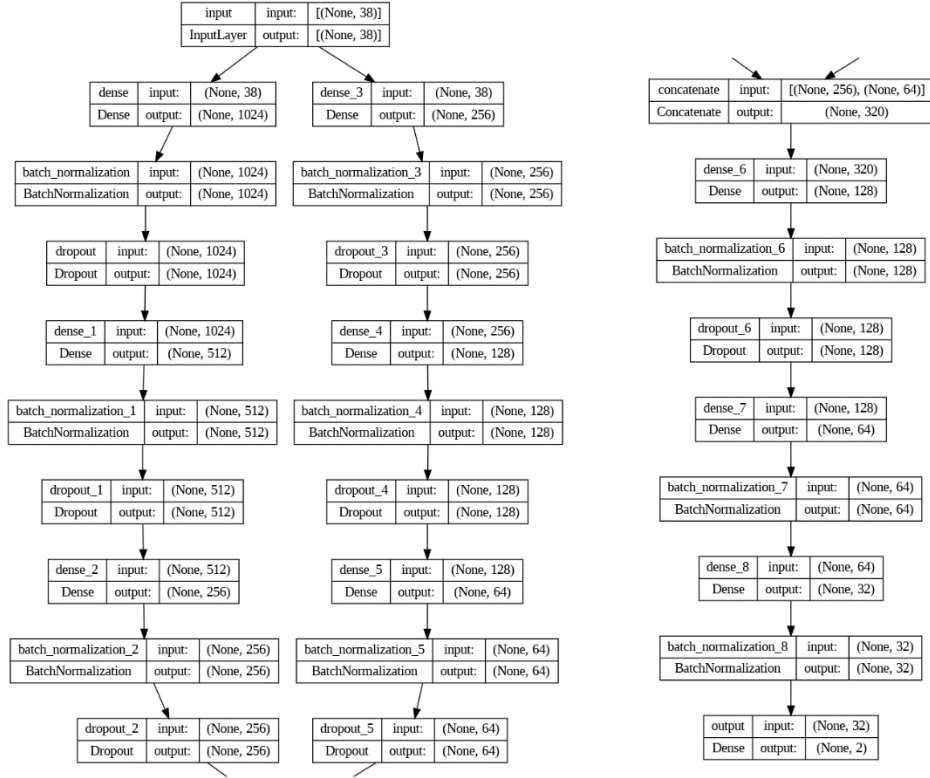
Model mimarisi, yapay sinir ağlarının temel yapısını oluşturan matematiksel fonksiyonlara diđer hiperparametreler eklenerek oluşturulur. Veri adetinin fazla olması ile çok katmanlı başka bir ifade ile derin yapay sinir ağlarını oluşturmak gerekir. Bu aşamada DSA modelinin doğru çalışabilmesi için hiperparametrelerin yanı sıra modelin mimarisi uygulanabilir ve sorunları ortadan kaldıracak şekilde probleme özgün olarak seçilmelidir. Literatürde aşırı uyumlanma (overfitting) olarak geçen, veriler arasındaki bağıntının sadece o verileri tanımlayacak şekilde oluşması istenmeyen bir durumdur. Bu durum modelin farklı girdi değerleri verildiğinde anlamsız sonuçlar üretmesine sebep olmaktadır. Modelin verimli ve güvenilir çalışmasını engelleyen bu durumu ortadan kaldırmak için modelin mimarisinin yanında regularization ve dropout gibi özellikler kodlar ile eklenmektedir. Bu kodlar sayesinde modele karmaşıklık ve doğrusal olmayan ilişkiler verilerek aşırı uyumlanmanın önüne geçilebilir (Bishop 2006). Tüm bu işlemler detaylı olarak yapay sinir ağının öğrenmesi için gerekli yapının oluşturulması içindir. Bu sayede öğrenme işlemi tamamlanan yapay sinir ağı ile girdi ve çıktılar arasındaki fiziksel etkileşimleri temsil eden ve matematiksel bağıntıyı oluşturabilen karmaşık bir fonksiyon üretilmiş olur. Bu fonksiyon genetik algoritmada literatürden farklı bir şekilde santral verileri arasındaki bağıntıları öğrenmiş bir DSA uygunluk fonksiyonu olarak kullanılacaktır.

Sonraki bölümde derin yapay sinir ağlarının temelde çalışma ilkelerinden bahsedilerek modelin işleyiş süreci anlatılmıştır. Modelin mimarisinin nasıl seçildiği, hangi kodlar, kütüphaneler, ve modüllerin kullanıldığı detaylı olarak anlatılacaktır.

4.1.1 DSA Modelinin Yapılandırılması

Hesaplama yönteminde kullanılan yapay sinir ağının modeli çok katmanlı derin yapay sinir ağıdır. Modelin mimarisinde 1 adet giriş, 6 adet gizli ve 1 adet çıkış katmanı olmak üzere toplamda 8 katmanlı yapı kullanılmıştır. Giriş katmanında 38 adet nöron bulunmaktadır. Bu nöronlar giriş verilerinin adeti kadardır. Aynı şekilde çıkış katmanında ise derin yapay sinir ağının amaç fonksiyonu olan brüt güç üretimi ve net güç tüketimini temsil eden toplamda 2 adet nöron vardır. Gizli katmanlarda ise toplamda 2464 adet nöron bulunmaktadır. Giriş ve çıkış katmanlarındaki nöronlar jeotermal enerji santralının hesaplanmasında kullanılan fiziksel özellikler olduğu için sabittir. Ancak gizli katmanlarda kullanılan nöronların sayısı hassasiyeti arttırmak için fazla sayıda seçilebilir. Bu tercih işlem kapasitesine ve süresine göre ampirik olarak belirlenmiştir. Gizli katmanlardaki nöron sayılarının ikinin katları olması ise literatürde genellikle uygulanan bilgisayar hesaplamalarını kolaylaştırmak adına yapılmış keyfi bir seçimdir. Gizli katmanlar ilk 3 katman ayrı daha sonraki 3 adeti ise birleşik olarak modellenmiştir. Bunun sebebi ise daha detaylı analiz yapabilen bir model oluşturabilmektir. Önceki bölümlerde de bahsedildiği üzere katman sayısını arttırarak aynı etkiye ulaşılabilir ancak işlem sırasına göre analizleri gerçekleştirecek olan bilgisayarın kapasitesini ve işlem süresi göz önüne alındığında tercih edilen yöntem daha verimlidir.

Burada felsefi olarak yüzlerce yıldır kullanılan Occam'ın usturası veya başka bir ifade ile yalınlılık yasasını kullanmamız gerekmektedir. Bir olgunun açıklanması, mümkün olan en az varsayıma dayanmalıdır. Gereksiz olan ayrıntılar elimine edilirse doğru yaklaşımı bulmak mümkün olur. Bir diğer ifade ise zorunlu olmadıkça varlıkları çoğaltmamak gerekir. Bu ilke gereği araştırmacı farklı modeller üzerinde çalışmalar yaptıktan sonra süre ve analizin doğruluğu ile de modeli son haline getirmiştir. Çok fazla sayıda katman ve nöron ihtiyacı olan araştırmalar genellikle çok fazla veri bulunması durumunda ortaya çıkmaktadır (Goodfellow ve diğ., 2016). Bu araştırmada yapılan geliştirmeler sonucunda iki kola ayrılan ve daha sonra birleşip tek bir çıktı alınan 8 katmanlı ve farklı nöron sayılarına sahip katmanlardan oluşan model tercih edilmiştir. Derin yapay sinir ağının modeli şematik olarak Şekil 4.4'te gösterilmiştir.



Şekil 4 4: Derin Yapay Sinir Ağının Modeli

Bu model phyton programı içerisinde aşağıdaki kodlama kullanılarak oluşturulmuştur.

```

reg_const = 0.001
input = tf.keras.Input(shape=(38), name="input")
x = layers.Dense(1024, activation='relu',
kernel_regularizer=regularizers.l2(reg_const))(input)

x = layers.BatchNormalization()(x)
x = layers.Dropout(0.9)(x)
x = layers.Dense(512, activation='relu',
kernel_regularizer=regularizers.l2(reg_const))(x)
x = layers.BatchNormalization()(x)
x = layers.Dropout(0.7)(x)

x = layers.Dense(256, activation='relu',
kernel_regularizer=regularizers.l2(reg_const))(x)
x = layers.BatchNormalization()(x)
xx = layers.Dropout(0.5)(x)
y = layers.Dense(256, activation='relu',
kernel_regularizer=regularizers.l2(reg_const))(input)
x = layers.BatchNormalization()(y)

```

```

x = layers.Dropout(0.9)(x)
x = layers.Dense(128, activation='relu',
kernel_regularizer=regularizers.l2(reg_const))(x)
x = layers.BatchNormalization()(x)
x = layers.Dropout(0.7)(x)
x = layers.Dense(64, activation='relu',
kernel_regularizer=regularizers.l2(reg_const))(x)
x = layers.BatchNormalization()(x)
yy = layers.Dropout(0.5)(x)
x = layers.concatenate([xx,yy])
x = layers.Dense(128, activation='relu',
kernel_regularizer=regularizers.l2(reg_const))(x)
x = layers.BatchNormalization()(x)
x = layers.Dropout(0.5)(x)
x = layers.Dense(64, activation='relu',
kernel_regularizer=regularizers.l2(reg_const))(x)
x = layers.BatchNormalization()(x)
yy = layers.Dropout(0.5)(x)
x = layers.Dense(32, activation='relu',
kernel_regularizer=regularizers.l2(reg_const))(x)
x = layers.BatchNormalization()(x)
x = layers.Dense(2, activation='sigmoid', name="output")(x)


model = Model(inputs=input, outputs = x )

```

Yapay sinir ağlarının modellenmesinde kullanılan her katman içerisinde tanımlanmış fonksiyonlar ve özellikler bulunmaktadır. Bunlar; aktivasyon fonksiyonu, regularizer ve dropout kodlarıdır. Nöronların arasındaki bağıntılar ağırlık ve önyargılar ile doğrusal olarak kurulmaktadır. Ancak fiziksel olayların doğrusal olmayan doğasını da kapsayacak şekilde bu fonksiyonları genişletmek için aktivasyon fonksiyonları kullanılmaktadır. Bu sayede eğer iki veri arasında doğrusal veya doğrusal olmayan bir bağıntı varsa hepsini tespit edebilecek şekilde bir derin yapay sinir hücresinin üretilmesi sağlanacaktır. Aktivasyon fonksiyonu kullanılmazsa yapay sinir ağları sınırlı öğrenmeye sahip doğrusal sonuçlar (lineer regresyon) veren bir fonksiyon gibi davranmaya başlayacaktır. Ancak burada yapay sinir ağının birbiri ile doğrusal olmayan şekilde bağlı olan değişkenler arasındaki ilişkileri de gerekmektedir. Aktivasyon fonksiyonu sayesinde çok katmanlı derin yapay sinir ağları verilerden anlamlı bağıntılar oluşturarak istenilen fonksiyonu üretebilmektedir. Bu çalışmada ReLU (rectified linear unit) fonksiyonu kullanılmıştır. Literatürde farklı fonksiyonlar mevcuttur. Bunlar sigmoid, hiperbolik tanjant, softmax fonksiyonları sayılabilir. Özellikle sigmoid fonksiyonu fazlaca kullanılmaktadır. Bu çalışmada derin yapay sinir

ağı modelinin çıkış katmanında sigmoid fonksiyonu kullanılmaktadır. ReLU aktivasyon fonksiyonu doğası gereği diğer fonksiyonlara göre hızlı işlem yapabilme, iyi bir tahmin edici olması, herhangi bir başka fonksiyona yakınsamak için kullanılması gibi öne çıkan özellikleri sebebiyle araştırmacı tarafından tercih edilmiştir. Çok katmanlı derin yapay sinir ağlarında sigmoid ve hiperbolik tanjant gibi fonksiyonlar neredeyse tüm nöronların aynı anda aktive olmasına sebep olmaktadır. Bu da işlem hızını büyük ölçüde uzatan verimsiz bir yöntemdir. Bu sebeple diğer alternatifleri yerine ReLU kullanarak negatif değerlerin sıfır olduğu bir aktivasyon fonksiyonu ile çok daha etkili ve hızlı bir hesaplama yöntemi ortaya çıkmaktadır. Ancak sonuçta negatif değerler (dış hava sıcaklığı) de üretilebileceği için nöron sayısı, dolayısıyla işlem süresi azalan son katmanda farklı bir aktivasyon fonksiyonu kullanarak bu problemi ortadan kaldırabiliyoruz. Bu sebeple sonuç katmanında sigmoid kullanarak negatif değerleri de çıktı olarak alabiliyoruz (URL 6). ReLU aktivasyon fonksiyonu (4. 2) eşitliği ile gösterilmiştir. Ayrıca Şekil 4.5'te ReLU fonksiyonunun grafiği verilmiştir.

$$f(x) = x^+ = \max(0, x) = \frac{x+|x|}{2} = \begin{cases} x & \text{if } x > 0, \\ 0 & \text{otherwise.} \end{cases} \quad f' = \begin{cases} 1 & \text{if } x > 0, \\ 0 & \text{if } x < 0. \end{cases} \quad (4.2)$$



Şekil 4 5: ReLU fonksiyonu grafik gösterimi

Bu fonksiyonlar phyton programlama dili kütüphanesindeki komutlar ile otomatik olarak kullanılmaktadır. Yukarıdaki yapay sinir ağı modelinde “activation=relu” kodu ile aktivasyon fonksiyonu o katmandaki görevini yerine getirmektedir.

Aktivasyon fonksiyonu dışında özellikle önemli olan bir başka özellik “dropout” kodu ile karşımıza çıkmaktadır. Dropout kodu ile nöronların işlevselliğinin arttırılması amaçlanmıştır. Dropout analiz sırasında girilen orana göre %90, %70, %50 kadar nöronu rastgele seçip kapatarak yapılan işlemleri tekrar ediyor. Bu sayede modelin sonuçlara ulaşmada ezberleme ve kısa yollar kullanmasının önüne geçilmiş oluyor. Daha önce de belirtildiği üzere overfitting yani aşırı uyum göstermeden kaçınacak şekilde yöntem modellenabiliyor. Bu çalışmada phyton programı içerisinde rastgele bir şekilde seçim yaparak çalışan dropout kodu için 0.9, 0.7 ve 0.5 yüzdeleri kullanılmıştır. Bunlar yukarıda bahsedildiği gibi sırasıyla nöronların %90, %70 ve %50 oranında kapatarak tekrar analiz edilmesini sağlamaktadır. Overfitting, ezberleme, aşırı uyum gibi sorunların oluşmaması için model mimarisinde kullanılan matematiksel işlemler ilerideki aşamalarda genetik algoritmanın farklı bir olası değer için anlamsız sonuçlar üretmesinin önüne geçmek için yapılmaktadır.

Bir diğer matematiksel algoritma ise regülerizasyondur. Literatürde farklı yöntemler mevcuttur. Bilgisayar bilimleri ve yapay sinir ağlarının araştırma sahası içerisinde regülerizasyon fonksiyon ve algoritmaları önemli bir çalışma konusudur. Optimizasyon çalışmalarında çoğunlukla kullanılan L2 regülerizasyon bir diğer ifade ile Ridge Regularization bu çalışma kapsamında da kullanılmaktadır. Modelin karmaşıklığını kontrol ederek, gereksiz büyük ağırlıkları küçültmeyi ve daha genelleştirilebilir bir model elde etmeyi sağlar. Yukarıda açıklanan yapay sinir ağlarının matematiksel analojisindeki x değerlerinde oluşan küçük değişiklikler ağırlıklarda önemli değişikliklere sebep olmaktadır. Anlamsız sonuçlar ve aşırı öğrenme (overfitting) olayının önüne geçilmesi için kullanılan fazladan matematiksel parametreler içermektedir. Bu parametreleri ise ağırlıkların karesinin toplamının karekökünü loss function olarak tanımladığımız kayıp fonksiyonuna ekleyerek buluyoruz. Burada kayıp fonksiyonu olarak kullandığımız mean square erroru tanımlamamız gerekiyor. Her satırdaki üretilen veriler gerçek verilerden çıkarılarak toplanıyor ve satır sayısına bölünüyor. Buradan elde edilen değer hata fonksiyonu

olarak modelde tanımlanmaktadır. Model analiz sonuçlarında bu hata fonksiyonunu minimum değerde tutacak şekilde hesaplamaları yapmaya çalışıyor. Bu hata fonksiyonunu optimize edebilmek için daha önce tanımladığımız gradient decent benzeri bir yöntem olan ancak işlem hızı daha fazla ve çok boyutlu hesaplamalar yapabilen Adam yöntemini kullanıyoruz. L2 regülerizasyon ve hata fonksiyonu (loss function) denklem (4. 3) ve (4. 4)'te gösterilmiştir.

$$L2Reg = \left(\sqrt{w_1^2 + \dots + w_n^2} \right) + f_{mse} \quad (4.3)$$

$$f_{mse} = \frac{\left((Veri_{Gerçek} - Veri_{Üretilen})^2 + \dots \right)}{\left(+ (Veri_{Gerçek} - Veri_{Hesaplanan})^2 \right)} \Bigg/ Satır Sayısı \quad (4.4)$$

Regülerizasyon ile yukarıdaki formüllerin yanı sıra ağırlıklar ile yine aşırı öğrenme probleminin önüne geçmeye çalışıyoruz. Bu hesaplamaların tamamı modelin veriler arasındaki bağlantıları doğru ve ezberden uzak olacak şekilde oluşturması için yapılmaktadır. Son olarak mean absolute error yani ortalama mutlak hata fonksiyonu ile aşırı öğrenme (overfitt) olasılığı en düşük olan en iyi modeli seçerek oluşturulan fonksiyonu genetik algoritma içerisinde uygunluk fonksiyonu olarak kullanıyoruz. Ortalama mutlak hata fonksiyonu (f_{mae}) (4. 5) eşitliği ile gösterilmiştir.

$$f_{mae} = \frac{\left((Veri_{Gerçek} - Veri_{Üretilen}) + \dots \right)}{\left(+ (Veri_{Gerçek} - Veri_{Hesaplanan}) \right)} \Bigg/ Satır Sayısı \quad (4.5)$$

Buradan hareketle modelin ürettiği en iyi fonksiyon genetik algoritma içerisinde uygunluk fonksiyonu olarak kullanılmaktadır. Literatürde araştırmacılar farklı fonksiyonlar, regresyon yöntemleri ya da santral verimini temel alan uygunluk fonksiyonları kullanmaktadır. Burada tezin en önemli ve özgün farklılığı gerçek santral verileri ile oluşturulan derin yapay sinir ağı modeli ile ortaya çıkarılan optimum fonksiyonun genetik algoritmada uygunluk fonksiyonu yerine kullanılmasıdır. Modelin doğru çalışabilmesi için santral verilerinden elde edilen değerleri tutarlı bir şekilde öğrenebilmesi ve işlemleri bu öğrenme sürecine göre tekrar etmesi

gerekmektedir. Hiperparametre ayarları ve öğrenme algoritmasının belirlenmesi ile derin yapay sinir ağı modelinin mimarisi oluşturulmaktadır.

4.1.2 Hiperparametre Ayarları

Yapay sinir ağlarının modellenmesinde kullanılan temel denklemler ve kodların nasıl kullanılacağı hakkında verilen bilgilerin dışında belirlenmesi gereken parametreler vardır. Önceki bölümlerde bahsedildiği gibi hiperparametreler olarak bilinen bu değerler rastgelelilik ve istatistiksel yöntemlerin uyumlu bir şekilde çalışabilmesi için belirlenmektedir. Literatürde farklı yöntemler mevcut olsa da parametrelerin değerleri genellikle 2 ve katları tercih edilmektedir. Yine bu parametrelerin optimum olarak belirlenmesi için farklı disiplinlerde araştırmalar devam etmektedir. Araştırmacı bu parametreleri modelin tutarlılığına, işlem süresine ve tekrar edilebilir sonuçların elde edilmesine bağlı olarak ampirik yollar ile belirlemiştir. Bu bölümde modelin hiperparametrelerinin nasıl belirlendiği ve sebepleri anlatılacaktır.

Modelde ağırlık olarak geçen sinir hücresinin en küçük birimindeki katsayılar belirli bir hesaplama döngüsü sonrasında yeniden düzenlenerek modelin çıktıları en iyi şekilde tahmin etmesini sağlamaya yönelik çalışır. Buradaki belirli hesaplama döngüsünde yeniden kontrol etme mekanizması modelde tanımlanması gereken “batch_size” komutudur. Bu komuta girilecek sayı o modelin kaç hesaplama döngüsü sonunda ağırlıkları yeniden hesaplaması gerektiğini belirler. Buna literatürde backpropagation veya geri yayılım algoritması denir. Bu sayede model kendisini sürekli kontrol ederek çıktıları en iyi şekilde tahmin edebilecek fonksiyonlara ulaşmaya çalışır. Ancak buradaki önemli ayrıntılardan bir tanesi backpropagation için seçilecek döngü miktarıdır. Literatürde bu sayıyı belirlemek için özel bir yöntem olmamak ile birlikte genellikle iki ve katları tercih edilmektedir. Araştırmacı ampirik yollar ile bu sayıyı belirleyebilir. Bu çalışmada ise otuz iki olarak belirlenmiştir. Bunun anlamı her otuz iki veri işlemi sonucunda tüm fonksiyon kontrol edilerek ağırlıklar (katsayılar) yeniden düzenlenmektedir. Araştırmacı farklı denemeler sonunda optimum olarak bu sayıyı ampirik yollarla belirlemiştir. Eğer bu sayı bir veya düşük olursa model backpropagation işlemini tek tek her veri için yapacaktır. Ancak mantıklı

görünen bu durum modelin doğru çalışması için engel oluşturmaktadır. Çünkü her nöron diğer veriler ile etkileşimde bulunmaktadır. Bu sebeple sonuçlar anlamlı çıkmamaktadır. Tüm verileri birbiri ile bağlantılı olarak temsil etmede sorun yaşanmaktadır. Aynı zamanda bu değerlerin yüksek olması da modeldeki rastgeleliği ortadan kaldırmaktadır. Ayrıca hafızanın işlem kapasitesine sığmaması gibi problemler ortaya çıkmaktadır. Burada yapılan analizlerin kapasitesinin bilgisayarın fiziksel sınırları ile de doğrudan ilgili olduğunu vurgulamak gerekmektedir. Bu sebeplerden ve yapılan hesaplamalar sonrasında backpropagation (geri yayılım) için yapay sinir ağı içerisinde belirlenen optimum batch_size değeri “32” olarak belirlenmiştir.

Backpropagation için literatürde farklı yöntemler kullanılsada en sık kullanılan yöntem gradient decent yöntemidir. Bu araştırmada da aynı yöntem kullanılmıştır. Yöntem genel anlamda fonksiyonun türevi ile elde edilecek yerel maksimum ve minimumların bulunarak çok küçük farklılıklar ile bu noktalardan uzaklaşarak yine yerel maksimum ve minimumları bulmasını amaçlamaktadır. Bu sayede optimum noktaları ortaya çıkararak ağırlıkları düzenleyebilmektedir. Literatürde çok boyutlu problemlerde özellikle optimizasyon problemlerinde kullanılmaktadır. Bu fonksiyon ile küçük adımlar atarak yapay sinir ağındaki ağırlıkları düzenler ve optimum noktalarda çalışmasına yardımcı olur. Yapay sinir ağının öğrenme aşamasındaki bu yöntem ile backpropagation yapılmaktadır (Goodfellow ve diğ., 2016).

Derin yapay sinir ağlarının modellenmesinde en önemli konu modelin öğrenmesidir. Öğrenmiş ve test edilmiş model ile oluşturulan fonksiyon diğer bölümlerde anlatılacak olan genetik algoritma içerisinde uygunluk fonksiyonu olarak kullanılacaktır. Analiz sonuçlarına göre araştırmacı yapay sinir ağlarının öğrenmesinin ne kadar iyi olup olmadığına karar verilebilir ancak burada en önemli ayrıntı veri sayısının öğrenmeyi tüm modeli etkilediğidir. Seçilen değer ve yöntemlerden sonra verilerin overfitt ya da aşırı uyum göstermesini engellemek için belirlenmesi gereken bir diğer değer ise shuffle_buffer_size olarak belirlenmiştir. Bu araç ile derin yapay sinir ağının öğrenmesinde kullanılan verileri kendi içerisinde karıştırarak yeniden hesaplamaya dahil etmektedir. Bu karıştırma işlemi daha sonra bireyler olarak anılacak olan satırları birbirinden bağımsız olarak değerlendirip satırları yer değiştirerek tekrar model içerisinde analizini yapmaktadır. Bu sayede rastgelelik ekleyerek genel datayı

daha iyi temsil eden bir fonksiyon elde etmeyi kolaylaştırmaktadır. Literatürde yine bu sayıyı belirlemek için herhangi bir yöntem olmamakla beraber araştırmacı ampirik olarak deneme yanılma ile değer belirlenmiştir. Genelde araştırmacılar 64 ve 512 arası değerleri kullanmıştır. Yapılan analizlerde model içerisinde optimum olarak 256 değeri uygun görülmüştür. Bu değeri daha yüksek veya düşük yapmak öğrenmede hızlı öğrenme ya da çok uzun sürede öğrenme gibi sorunlar çıkardığı için 256 değeri bu veriler doğrultusunda seçilmiştir. Bu değerde yapılacak 2-4-6-10 gibi küçük değişiklikte ise anlamlı farklılıklar olmaması sebebi ile deneme yapılmamıştır. Bir başka ifade ile değer daha düşük veya yüksek olması istenilen etkiyi yapamamıştır. Bu sebeple kodlamada “Shuffle_Buffer_Size” olarak geçen parametre 256 olarak belirlenmiştir.

Genel olarak öğrenmenin temeli belirlenmiş olan sayılar ve formüller ile bir algoritma sayesinde yapılmaktadır. Derin yapay sinir ağı modeli python programlama dili içerisinde bulunan hazır kütüphane içerisindeki tensorflow kodlaması kullanılarak otomatik bir şekilde yapılmaktadır. Yukarıda belirlenen değer ve algoritmalar ile öğrenme ve öğrenilen değerlerin test edilmesi için santral verilerinin ne kadar bir bölümü öğrenme ve test için ayrı ayrı kullanılacak belirlenmesi gerekmektedir. Bu oran literatürde genellikle verilerin %80’i öğrenme ve %20’si test için kullanılmaktadır. Araştırmacılar kendi çalışmaları özelinde farklı oranlar belirleyebilir. Problemin tanımı, yapılacak olan analiz ve eldeki veri sayısı bu oranı etkileyebilmektedir. Yapılan analizlerde farklı oranlarda model denenmiş ancak önemli bir farklılık elde edilemediği için araştırmacı öğrenme ve test için sırasıyla santral verilerinin %80’i ve %20’sini kullanmayı tercih etmiştir. Elde edilen sonuçlar oranların seçiminin doğruluğunu kanıtlar niteliktedir. Farklı araştırmalarda farklı değerler ile doğru sonuçlara ulaşılabileceği unutulmamalıdır.

4.1.3 Eğitim ve Test Süreçleri

Python programlama dili içerisinde yapay sinir ağının öğrenme ve test algoritması aşağıdaki gibi kodlanmıştır. Burada sadece öğrenme ve test oranları araştırmacı tarafından belirlenmektedir. Diğer kodların çalışması içerisinde bulunan kütüphaneler tarafından yapıldığı bilinmelidir.


```

training_count = np.ceil(DATASET_SIZE - (DATASET_SIZE/5))
validation_count = np.ceil(DATASET_SIZE - training_count)
STEPS_PER_EPOCH = math.ceil(training_count / BATCH_SIZE)
VALIDATION_STEPS_PER_EPOCH = math.ceil(validation_count / BATCH_SIZE)

AUTOTUNE = tf.data.experimental.AUTOTUNE

init_ds = tf.data.Dataset.from_tensor_slices(dataset)
train_ds = init_ds.take(training_count).shuffle(SHUFFLE_BUFFER_SIZE,
reshuffle_each_iteration=False)
val_ds = init_ds.skip(training_count).take(validation_count)

train_ds = train_ds.map(process_path, num_parallel_calls=AUTOTUNE)
val_ds = val_ds.map(process_path, num_parallel_calls=AUTOTUNE)

train_ds =
train_ds.batch(BATCH_SIZE).repeat().prefetch(buffer_size=AUTOTUNE)
val_ds = val_ds.batch(BATCH_SIZE).repeat().prefetch(buffer_size=AUTOTUNE)

```

Yukarıda anlatılan seçimler bu kod içerisinde tanımlanmıştır. Son olarak öğrenme algoritması içerisinde autotune modülü sayesinde aynı anda paralel işlemler yapılarak analiz süresini en verimli şekilde kullanmasını sağlıyoruz. Bu modül senkron işlemlere kendisi karar vermektedir. Karar verme mekanizması rastgele arama algoritması ile yapılmaktadır. Bu sayede modellenen öğrenme metodolojisindeki işlemler belirli bir paralellikte seçilerek tekrar edilmesini sonrasında ise en verimli hiperparametre çalışma sürecinin belirlenmesini sağlar.

Bu tez kapsamında çalışan bir santralin daha sonra bahsedileceği üzere genetik algoritmanın doğası gereği rastgele üretilen veriler ile optimize edilerek çalışma koşullarının belirlenmesi aynı zamanda verilere en yakın modellemeyi yaparak santralin şu anki çalışma koşullarını hesaplayabileceği bir yöntem oluşturulması hedeflenmiştir. Genetik algoritma ile rastgelelik ve farklı çalışma koşullarının değerleri üretilerek model içerisinde analiz edilebilmektedir. Genetik algoritmanın en önemli fonksiyonu olan uygunluk fonksiyonu üretilen verilerin uygunluğuna karar veren mekanizmasıdır. Geliştirilen genetik algoritma modelin tamamını kapsayacak şekilde anlatılacaktır.

4.2 Genetik Algoritma Modeli

Genetik algoritma, evrimsel süreçlerdeki genetik varyasyonları oluşturan mutasyon ve çaprazlama gibi araçların matematiksel modellerini kullanır. Gerçek verilere yakın değerler üreterek analizler yapabilen önemli bir araçtır. Bu sayede farklı koşullar altında santral değerlerini kullanarak uygunluk fonksiyonunu belirlemede daha sonra ise olası santral işletme senaryosunu oluşturarak örnek çözüm kümesi ile optimizasyon yapmaktadır. Aynı zamanda çalışan santralin çalışma koşullarını çok az hata ile tahmin edebilmektedir. Genetik algortmada verilerin her birisi birer gen ve satırlar da birey olarak adlandırılmaktadır. Bu bireyler yani veri satırları işletme şartlarını göstermektedir. Bu sayede oluşturulan veriler ile santralin çalışma koşulları ile optimum çalışma şartları tahmin edilmesi için matematiksel algoritma modeli oluşturulmaktadır. Genetik algoritmanın modellenmesinde öncelikle popülasyon sayısı ve jenerasyon sayısı belirlenmektedir. Popülasyon sayısı birey sayısını ifade etmektedir. Bu bireyler çalışma koşullarını oluşturan debi, sıcaklık, basınç ve brüt güç üretimi gibi santral verilerinin oluşturduğu satırları ifade etmektedir. Her satır santralden alınan verilerin o tarih ve saatinde alınmış verilerdir.

Hesaplama modelinin temel çalışma yöntemi olan genetik algortmada üretilen bireyler uygunluk fonksiyonundan geçirilerek uygunluk değeri almaktadır. Bu uygunluk değerleri daha önce bahsedildiği üzere gerçek veriler ile eğitilen derin yapay sinir ağı ile oluşturulmuş fonksiyon sayesinde belirlenmektedir. Uygunluk fonksiyonu bireylerin tutarlı bir şekilde oluşturulması için kritik öneme sahiptir. Bireyin elde ettiği uygunluk değeri ne kadar yüksekse yaşama ve sonraki jenerasyonlara aktarılma şansı artacaktır. Bu sayede optimize edilmek istenen veriler en iyi sonuca ulaşana kadar işlemler tekrarlanmış olur. Bu tekrar sayısı popülasyon ve jenerasyon sayısı ile ölçülmektedir. Bu sayılar iterasyon sayısı olarak düşünülebilir. Literatürde optimum bir sayı olmamak ile beraber genellikle 100-250 arası popülasyon ve 50-100 arası jenerasyon değerleri kullanılmaktadır. Bu sayılar hesaplamanın hızına, sonuçların tutarlılığına ve bilgisayarın işlem kapasitesine göre belirlenebilir. Ayrıca belirli bir jenerasyon sonrasında sonuçlar çok az değişiyor ya da anlamsız oluyorsa işleme devam etmemek için jenerasyon ve popülasyon sayıları düşürülebilir. Bu çalışmada 200 popülasyon ve 100 jenerasyon sayısı ile tutarlı ve optimum sonuçlara ulaşıldığı için burada sınırlandırılması uygun görülmüştür. Farklı veriler ve hesaplanacak santraller

için bu sayıların değişebileceği unutulmamalıdır. Ayrıca araştırmacı tarafından belirlenen hesaplama yönteminin modellenmesine göre değişiklik gösterebilmektedir. Aynı zamanda bilgisayarın fiziksel işlem kapasitesi de göz önüne alınması gereken bir diğer konudur. Belirlenmesi gereken bir başka konu ise genetik algoritma doğası gereği kullanılan yaşam eşiği (survival threshold), mutasyon olasılığı eşiği (mutation probability threshold) ve çaprazlama (crossing over) araçlarının matematiksel modellemeleridir. Her bir araç içerisinde rastgeleliği arttırmak için gauss dağılımı ile çarpanlar eklenerek model oluşturulmuştur. Burada amaç farklı koşulları oluşturabilecek verilere ulaşmak ve en iyi sonucu analiz edebilecek modeli oluşturmaktır. Literatürde bu araçlar için farklı değerler bulunmaktadır. Optimum bir değer olmamak ile beraber çaprazlama için phyton programı içerisindeki kodlama dili kullanılmaktadır. Bu kodlama aşağıdaki gibidir:

```
#crossing over  
  
crossing_over_point = np.random.randint(1,38)  
  
offspring =  
np.concatenate([p1[:crossing_over_point],p2[crossing_over_point:]])
```

Çaprazlama bir veri satırındaki tüm değerler içerisinde belirli bir bölümü ile başka bir satırdaki uygun verileri birleştirerek yeniden analiz etmeye yarayan bir araçtır. Eğer bu şekilde oluşturulan bireyler uygunluk fonksiyonunda yüksek değer alırsa yaşayabileceklerdir. Bu sayede uygun değerler birbiri içerisinde birleştirilerek rastgele bir şekilde de oluşturulmaktadır. Çaprazlama örnek olarak bir satırda 38 veri arasından rastgele ilk 1-12 veriler ile sonraki 13-38 aralığındaki verileri birbirinden ayırarak, farklı bir satırda benzer şekilde uyum sağlayacak ayrılmış veriler ile birleştirilebilir. Bu sayede başlangıçtaki yaşayan bireylerden farklı olarak çaprazlamadan elde edilen veriler yaşamsal döngü içerisinde eğer uygunluk değerleri yüksek olursa gelecek nesillere aktarılarak çeşitlilik arttırılmış olmaktadır. Bu sayede santralin farklı çalışma koşulları da model içerisinde yeniden değerlendirilerek analiz edilebilmektedir.

Daha sonra elde edilen bireyler yani satırların içerisindeki tüm değerlere tek tek bakarak rastgele bir çarpan atanmaktadır. Bu rastgelelik gauss dağılımı yöntemi ile

bulunmaktadır. Bu yöntemden daha sonra bahsedilecektir. Atanan bu çarpan ile elde edilen yeni değer mutasyon olasılığından büyük ise yine gauss dağılımı ile belirlenen bir mutasyon çarpanı ve veri çarpılarak değiştirilir başka bir şekilde ifade edersek genler mutasyona uğratılıyor. Mutasyon olasılığını belirlemek için literatürde optimum bir değer yoktur. Bu sebeple ampirik yollar ile bu çalışmada en iyi sonuçlara 0.95 ile ulaşılmıştır. Başka bir ifade ile yukarıdaki işlemde elde edilen sayı 0.95'ten büyükse mutasyona uğrayacaktır. Burada son bir kontrol yapılarak elde edilen değer bir önceki değer %75'inden az veya fazla değilse mutasyona uğrayan değiştirilen değer korunarak aktarılmaktadır ancak tam tersi durumda önceki veri kullanılmaktadır. Genetik algoritmada mutasyon ve yaşamsal eşige fiziksel sınır koyarak uygulaması imkansız ancak termodinamik olarak mümkün olan sonuçların önüne geçilmeye çalışılmaktadır. Kodlama içerisinde de ingilizce olarak bu yöntemin matematiksel ifadesi verilmiş olup aşağıdaki gibidir:

```
#mutation
for i in range(offspring.size):
    mut_prob = random()
    if mut_prob > MUTATION_PROBABILITY_THRESHOLD:
        percentage_of_mutation = gauss(1, 0.6) #TODO
        offspring[i] = offspring[i] * percentage_of_mutation
        limit_of_change = 1.75
        if offspring[i] > limit_of_change * columnFeatures[i][1]:
            offspring[i] = columnFeatures[i][1]
        if offspring[i] < limit_of_change * columnFeatures[i][0]:
            offspring[i] = columnFeatures[i][0]
```

Burada rastgele sayıları üreten gauss dağılımını açıklamak gerekmektedir. Gauss dağılımı ile rastgele olarak elde edilen sayılar verilerde çarpan olarak kullanılır. Bu sayede farklı çalışma koşullarını temsil edecek verilere ulaşılmıştır. Gauss veya literatürde normal dağılım olarak geçen bu yöntem sayesinde python programında hazır bulunan gauss dağılım fonksiyonu kullanılmıştır. Yöntem sayesinde istatistiksel olarak rastgele sayı üretebilmekteyiz. Gauss dağılımı yöntemi yeni veri üretiminde özellikle doğada karşılaşılan fiziksel olguların tanımlanmasında sıklıkla kullanılmaktadır. Sürekli olasılık dağılımları içerisinde sınıflanan gauss dağılımı merkezi limit teoremi gereğince, büyük bir sayıda bağımsız ve aynı dağılım gösteren rassal (sonlu varyans) değişkenlerin aritmetik ortalamasının yaklaşık olarak gauss

dağılımı (normal dağılım) göstereceğini ifade eden bir teoremdir. Bu nedenle hesaplamalarda rastgele sayı üretiminde gauss dağılımı kullanılmıştır. Gauss dağılımının matematiksel ifadesi aşağıdaki denklem (4. 7) de gösterildiği gibidir.

$$f(x) = \frac{1}{\sigma\sqrt{2\pi}} \times e^{-\frac{(x-\mu)^2}{2\sigma^2}} \quad (4.6)$$

Tüm bu işlem basamaklarından sonra her bir birey (sıra) için uygunluk değeri belirlenir. Uygunluk değeri aşağıdaki kodlama ile python programında otomatik olarak çalıştırılan daha önceden belirlenmiş olan derin yapa sinir ağı ile analiz edilerek belirlenmektedir.

```
#populasyondaki her bir birey için fitness score belirlenir
for j in range(POPULATION_SIZE):
    pred = model.predict(np.expand_dims(population[j], axis=0), verbose=0)
```

Daha sonra bireyler uygunluk değerine göre sıralanır ve maksimum/minimum değerleri hesaplanır. Genetik algoritmanın amaç fonksiyonu net güç üretimini maksimum hale getirmektir. Belirlenen uygunluk değerleri bu aşamada maksimum ve minimum net güç üretimi olarak tanımlanır. Jenerasyondaki bireylerin hangilerinin bir sonraki jenerasyonda yer alacağına uygunluk değerine ek olarak gauss dağılımı sayesinde oluşturulan rastgelelik eklenerek belirlenmektedir. Bu bireyler ayrıca yeni bireyleri oluşturacak ebeveynler olacaktır. Bu aşamada uygunluk değerleri aşağıda bulunan ilk formül ile normalize edilmektedir. Ayrıca yukarıda bahsedilen yaşamsal eşik değeri burada kullanılarak bireylerin yaşayıp yaşamayacağına karar verilmektedir.

```
fit_normalized = (fitness_scores[j][1] - min_fitness)/(max_fitness-min_fitness) + 0.1
rnd = gauss(1.5,0.5)
if rnd * fit_normalized > SURVIVAL_THRESHOLD:
    survivors.append(fitness_scores[j,0])
```

Yaşamsal eşik değeri için literatürde farklı değerler kullanılmaktadır. Optimum bir değer olmadığı için araştırmacı ampirik yollar ile bu değeri belirlemiştir. Bu çalışmada 0.85 değeri optimum olarak bulunmuştur. Yaşamsal eşik değerinin çok yüksek olması bireylerin büyük çoğunluğunun ölmesine ve yeni varyasyonların oluşmasına engel olmaktadır. Çok küçük olması ise önceki bireylere çok benzer bireyler üretilmesine ve çeşitliliğinin azalarak optimizasyonun yapılamamasına sebep

olmaktadır. Santralden elde edilen veriler ve araştırma süresi içerisinde tüm değerler ampirik olarak belirlenmiştir. Belirlenen bu değerler araştırmacıların elde ettiği veriler ve saha çalışmalarına göre değişkenlik gösterebileceği bilinmelidir.

Tüm bu işlemlerin sonunda en iyi bireyler başka bir ifade ile satılardaki veriler çıktı alınarak düzenlenir ve araştırmacı tarafından seçilen satırlardaki optimum sonuçlar değerlendirilir. Burada model tarafından analiz edilen sonuçların tamamı excel dosyası ile program dışarısına aktarılmaktadır. Daha sonra araştırmacı en iyi net güç çıktılarının olduğu verileri inceleyerek optimum sonucu bulmaya ve termodinamik hesaplama yöntemleri ile sonuçların doğruluğunu teyit etmeye çalışacaktır. Geliştirilen model sayesinde birbiri ile etkileşim halinde olan değerlerin santral çalışma koşullarına uygunluğu araştırılarak çalışma sonlandırılmıştır. Literatürde derin yapay sinir ağlarını uygunluk fonksiyonu olarak kullanan genetik algoritma ile jeotermal enerji santrallerinin işletme şartlarını ve optimum işletme koşullarını belirlemeye yönelik yenilikçi ve tutarlı sonuçlar elde eden bir model geliştirilmiştir.

4.2.1 Uygulama Süreci

Genetik algoritmanın farklı varyasyonları ile literatürde çalışmalar mevcuttur. Buradan hareketle genetik algoritma kullanarak jeotermal enerji santrallerinin modellenebileceği anlaşılabilmektedir. Bu çalışmada genetik algoritmanın optimum şartlarını belirleyebilmek için tüm özellikleri kullanılmıştır. Özgün bir yaklaşım olarak uygunluk fonksiyonu jeotermal sahadaki bir işletmeden santral verileri ile oluşturulan yapay sinir ağının üretmiş olduğu bir fonksiyon atanmıştır. Bu sayede genetik algortmada fiziksel olarak anlamlı olan sayısal sınırlar verilerek girdilere benzer veriler üretmesi istenmiştir. Olası santral işletme verileri sırasıyla defalarca uygunluk fonksiyonundan geçirilerek santral verilerinin en optimum olanları belirlenmiştir. Geliştirilebilir olan hesaplama yönteminin bu aşamada yüzlerce sayıda işletme parametresi belirlediği görülebilmektedir. Bu aşamada araştırmacı veriler arasından optimum olan veya santral işletme şartlarına uygun olan sonuçları seçerek karşılaştırmalı analiz yapması gerekmektedir.

Genetik algoritma belirli sayı aralıkları içerisinde önemli miktarda veri üretebilmektedir. Üretilen bu verilerin tamamı önceki bölümlerde bahsedilen

aşamalardan geçerek sonuç üretmektedir. Üretilen sonuçlar uygunluk fonksiyonu yardımı ile santral verilerine uyumlu olup olmadığı incelenerek verilerin anlamlı veya anlamsız olduğuna karar verilmektedir. Bu sayede çok fazla sayıda senaryo aynı anda defalarca model içerisinde denenebilmektedir. Başka bir ifade ile kendi içerisinde jeotermal santralin farklı çalışma koşullarını simüle etmektedir. Ancak üretilen her verinin uygulanabilir olabileceği düşünülmemelidir. Araştırmacı tecrübe ve termodinamik analizler ile uygulanabilir olan işletme şartlarını belirlemektedir. Sonraki çalışmalarda araştırma konusu olarak bu analizlerin de model içerisinde yapılabileceği yeni yaklaşımlar geliştirilebilir.

4.3 Modelin Değerlendirilmesi

Hesaplama modelinin literatüre yenilikçi bir katkı olarak yapılan çalışma ile kazandırılması hedeflenmiştir. Bu bağlamda oluşturulan modelden elde edilen sonuçların analiz edilerek tutarlı ve güvenilir olup olmadığı araştırılmalıdır. Termodinamik analizler ile öncelikle santralin verilerdeki örneklere benzer işletme şartları üretilip üretilmediği grafik ve tablolar ile desteklenmiştir.

Aynı zamanda optimum işletme şartlarının uygulanabilirliği de bir diğer problemdir. Bu problemin çözülmesi seçilen optimum işletme şartları ile santralin çalışma ve tasarım koşulları ile jeotermal sahadaki üretim kuyularının verileri arasındaki termodinamik analizler sayesinde gösterilmektedir. Bu sayede uygulanabilirliği fiziksel olarak ispat edilen optimum koşullar ve bu koşulları üreten hesaplama modelinin tutarlılığı, geçerliliği ve güvenilirliği ispat edilebilmiştir. Sonraki bölümlerde elde edilen bulguların açıklanan yöntem ve materyaller kullanılarak bahsedilen analizlerin tamamını kapsayacak şekilde tablo, grafik ve termodinamik sonuçlar ile karşılaştırmalı olarak sunulacaktır.


4.4 Termodinamik Analiz Yöntemi ve ORÇ Verileri

Geliştirilen model ile üretilen değerler ve optimum çalışma koşulları termodinamik analizler ile doğrulanmıştır. İş akışkanına ait ORÇ verileri ise İzmir bölgesinde çalışmakta olan santralde yapılan keşifte bulunan basınç ve sıcaklık göstergelerinden elde edilmiştir. Bu bağlamda reküperatör pompa basma hattı ve ön

ısıtıcılara giden hatlardaki deęerler okunabilmektedir. Aynı zamanda AB buharlařtırıcısı ile YB buharlařtırıcı ve ön ısıtıcısının giriř deęerleri okunabilmektedir. Burada en önemli verilerden olan ORÇ tarafındaki debi ölçerler bulunmamaktadır. Toplam debi, AB ve YB debileri her iki kademedeki buharlařtırıcıların giriř çıkıř sıcaklık ve basınçlarının bilinmesi ile bulunabilmektedir. Santralin kontrol odasında kayıt edilmeyen bu veriler alındığı sırada SCADA sisteminden ORÇ ve üretim kuyularındaki tüm deęerleri gösteren ekran görüntüleri kayıt edilerek termodinamik analizler yapılmıřtır. Veriler 11.06.2024 tarihinde yapılan santral ziyaretinde alınmıřtır. Őekil 4.6, Őekil 4.7, Őekil 4.8 ve Őekil 4.9’da sırasıyla pompa basma hattı, reküperatörden ön ısıtıcıya basma hattı, AB buharlařtırıcı giriři ve YB buharlařtırıcı giriřindeki sıcaklık göstergeleri verilmiřtir.



Őekil 4 6: ORÇ Pompa basma hattı sıcaklık göstergesi



Şekil 4 7: ORÇ Reküperatör basma hattı sıcaklık göstergesi



Şekil 4 8: ORÇ AB buharlaştırıcı girişi sıcaklık göstergesi



Şekil 4 9: ORÇ AB buharlaştırıcı girişi sıcaklık göstergesi

Santraldeki tüm süreçler termodinamik hesaplamaların daha kolay analiz edilebilmesi için bazı kabuller yapılmıştır. Bu kabuller;

- Tüm süreçler termodinamik dengededir.
- Kinetik ve potansiyel enerji farkları ihmal edilebilir.
- Tüm ekipmanlarda çevreye ısı geçişi ihmal edilebilir düzeydedir.
- Borulardaki ve ekipmanlardaki basınç düşüşleri tasarımdaki ısı ve kütle transferinde verilen değerlere benzer şekilde alınmıştır. İşletmede göstergelerdeki değerler kullanılmıştır.
- Hava ideal gaz olarak kabul edilmiştir.
- Çevrimler dengeli ve kararlı akışıdır.
- ORÇ debisi AB ve YB buharlaştırıcılarındaki ısı transferi sonucu bulunmuştur.
- NCG miktarı az olması sebebiyle ihmal edilmiştir.
- Santrale giren buharın tamamı yoğuşarak çıktığı kabul edilmiştir. Tasarım parametrelerinde ise yoğuşan buhar debisi hesaplamalarda kullanılmıştır.
- Ekserji analizlerinde bölgenin bir yıllık ortalama sıcaklığı ölü hal olarak alınmıştır. Bu değer meteoroloji verilerine göre 17 °C alınmıştır. Ayrıca ölü hal basıncı çevre basıncı olan 1 bar alınmıştır.
- Brine termofiziksel değerleri su değerleri ile aynı kabul edilmiştir.
- Santral yetkilileri ile görüşme sonucu reenjeksiyon sıcaklığı optimum hesaplamalar için en düşük 65 °C aralığı olarak belirlenmiştir.
- Türbinin mekanik verimi %99 alınmıştır.
- Pompa ve Fan mekanik verimleri %95 alınmıştır.
- Değerlendirmelerde santralin tasarım parametreleri ile ısı ve kütle dengesi referans alınmıştır.

Ayrıca termodinamik analizlerde kullanılan jeotermal akışkan ve iş akışkanı olan bütanın termofiziksel özellikleri Refprop programı ile belirlenmiştir. Hesaplamalarda kullanılan termodinamik formüller aşağıda verilmiştir.

$$\dot{Q} - \dot{W} = \sum(\dot{m}_c - h_c) - \sum(\dot{m}_g - h_g) \quad (4.7)$$

$$\sum \dot{m}_g = \sum \dot{m}_c \quad (4.8)$$

$$\eta_{net,isl} = \dot{W}_{net} / \sum \dot{Q}_g \quad (4.9)$$

$$\dot{Q}_{brine} = \dot{m}_{brine} \times (h_{brine,giriş} - h_{reenjeksiyon}) \quad (4.10)$$

$$\dot{Q}_{buhar} = \dot{m}_{buhar} \times (h_{buhar,giriş} - h_{yoğuşan,çıkış}) \quad (4.11)$$

$$\dot{Q}_g = \dot{Q}_{brine} + \dot{Q}_{buhar} \quad (4.12)$$

$$\dot{W}_{net} = \dot{W}_{brüt} - \dot{W}_{iç,tüketim} \quad (4.13)$$

$$\begin{aligned} \dot{m}_{toplam} \times h_{toplam} = & (\dot{m}_{kuyu1} \times h_{kuyu1}) + (\dot{m}_{kuyu2} \times h_{kuyu2}) + \\ & (\dot{m}_{kuyu3} \times h_{kuyu3}) \end{aligned} \quad (4.14)$$

$$\psi_i = ((h_i - h_0) - T_0 \times (s_i - s_0)) \quad (4.15)$$

$$\dot{E}_i = \dot{m}_i \times \psi_i \quad (4.16)$$

$$\eta_{ikinciyasa} = \dot{W}_{net} / \sum \dot{E}_g \quad (4.17)$$

Geliştirilen hesaplama yöntemi ile elde edilen sonuçlar sonraki bölümde karşılaştırmalı olarak değerlendirilecektir.


5. BULGULAR

Derin yapay sinir ağlarını uygunluk fonksiyonu olarak kullanan genetik algoritma ile işletmede olan bir jeotermal enerji santralının modellenmesi ve optimum çalışma şartlarının bulunması için analizler yapılmıştır. Tezin amacı jeotermal enerji santrallerinin derin yapay sinir ağlarını uygunluk fonksiyonu olarak kullanan genetik algoritma ile modellenbildiğini ve aynı zamanda optimum işletme şartlarını tahmin edebildiğini araştırmaktır.

Analiz sonuçlarına göre santral verilerine çok yakın üretilen veriler tekrar tekrar elde edilmiştir. Aynı zamanda daha verimli çalışan işletme şartları da bulunarak sunulmuştur. Öncelikle bu veriler tablo ve grafiklerle karşılaştırılacaktır. Daha sonra ise termodinamik hesaplamalar ile analiz edilecektir. Son olarak geliştirilen hesaplama modelinin tutarlılığı, istenilen amaca hizmet etmesi ve hedeflenen beklentileri karşılaması tartışılacaktır.

Jeotermal enerji santralinden elde edilen veriler için karşılaştırmalı tablolar sunulacaktır. Aynı zamanda korelasyon matrisi ile bu veriler arasındaki bağıntılar ikili olarak gösterilmektedir. Çalışmanın ilerleyen bölümlerinde korelasyon matrisinde brüt güç üretimi ve net güç tüketimine etkisi çok ve az olan veriler hesaplamalardan çıkarılmıştır. Bu sayede hesaplamaların süresi kısaltılarak araştırma daha verimli hale getirilmiştir. Veriler arasındaki etkileşim Şekil 5.1'deki korelasyon matrisi ile gösterilmiştir.

Korelasyon matrisi ile santral verilerinin birbirleri arasındaki matematiksel etkileşimler gösterilmiştir. Buradan yola çıkarak kuyulardan alınan debi, sıcaklık ve basınç verilerinin brüt güç üretimi ile iç tüketimi doğru orantılı olarak etkilediği görülmektedir. Tablo 5.1'de verilen tabloda kuyulardaki verilerin brüt güç ve iç tüketim ile etkileşim oranları gösterilmiştir. Üretim kuyusu 2'nin santral değerleri ile etkileşiminin diğer kuyulardan daha fazla olmasının sebebi bu kuyuda diğer kuyulara göre daha düşük sıcaklık ve debide akışkanın santrale gönderilmesidir. Aynı zamanda bu kuyudaki yaşanan bazı problemler sebebiyle santral işletme döneminde kuyu kapatılıp açılmaktadır. Bu durum santralin brüt güç üretimi ve iç tüketimi ile daha fazla bir etkileşime girmesine sebep olmaktadır.



Şekil 5.1: Korelasyon matrisi

Tablo 5.1: Üretim kuyularının debi, sıcaklık, basınç değerleri ile brüt güç ve iç tüketim değerleri arasındaki korelasyonu

ÜRETİM KUYULARI		BRÜT GÜÇ	İÇ TÜKETİM
KUYU 1	DEBİ	0,26	0,46
	SICAKLIK	0,33	0,55
	BASINÇ	0,33	0,55
KUYU 2	DEBİ	0,47	0,74
	SICAKLIK	0,68	0,68
	BASINÇ	0,41	0,62
KUYU 3	DEBİ	0,3	0,04
	SICAKLIK	0,21	-0,04
	BASINÇ	0	-0,35

İlerleyen bölümlerde analizleri açıklanacak olan hesaplama modeli ise üretim kuyusu 3'ün santral üzerindeki etkisinin daha fazla olduğunu tespit ederek hesaplamalar yapmaktadır. Özellikle güç artışı için bu kuyudan elde edilen buharın önemini öne çıkarmaktadır. Bu anlamda korelasyon matrisleri eldeki veriler ile ikili matematiksel ilişkileri açıl原因an faydalı bir araç olsa da gelişmiş bir yorumlama yapamamaktadır. Geliştirilen modelin bu anlamda basit matematiksel ilişkiler ile değil santral verilerinin gerçeğe yakın karmaşık matematiksel ilişkilerini ortaya çıkarabildiği vurgulanmalıdır. Bir başka çıkarılabilecek sonuç toplam üretim debisinin santralin güç üretimi ve iç tüketimi ile doğrudan etkileşimde olmasıdır. Bu etkileşim sırasıyla 0,62 ve 0,91 olmak üzere önemli miktarda yüksektir. Santrale giren toplam brine debisinin artması ile brüt güç üretiminin artacağı ve iç tüketimin de buna bağlı olarak artması beklenen bir sonuçtur. Burada özellikle dikkat edilmesi gereken konunun toplam debinin iç tüketim ile olan ilişkisi brüt güç üretimiyle olan ilişkisinden oldukça fazladır. Ancak bu sonuçtan toplam debinin artması ile elde edilecek brüt güçten daha fazla iç tüketim olacağı sonucu çıkarılmamalıdır. Santralin türbin giriş basıncı ise doğal olarak üretim kuyularının debi ve sıcaklıkları ile doğru orantılıdır. Bu ilişki santralin ısı enerjisi aldığını ve aynı enerjiyi mekanik işe dönüştürdüğü iki nokta arasındaki güçlü etkileşimi göstermektedir. Ayrıca beklenen bir diğer sonuç türbin giriş basıncının brüt güç üretimi ve iç tüketim arasında sırasıyla 0,58 ve 0,81 gibi yüksek değerlerde doğru orantılı olduğudur. Aynı şekilde türbin çıkış basıncının brüt gücü -0,56 oranında ters orantılı etkilediği anlaşılmaktadır. Bu durum özellikle dış ortam sıcaklığının artması ya da santralin işletme parametrelerinin değişmesi ile gözlenebilmektedir.

Dış ortam sıcaklığının türbin çıkış basıncıyla 0,96 ile neredeyse birebir ilişkili olduğu korelasyon matrisinden elde edilen bir diğer bulgudur. Bu bağlamda dış ortam sıcaklığı reenjeksiyon sıcaklığı ile de önemli ölçüde ilişkilidir. Türbin çıkış basıncının artması ve santral veriminin düşmesi sebebiyle santralden çıkan brine reenjeksiyona gönderilen brine sıcaklığı artabilmektedir. Bir diğer bulgu ise düşük ekserjiye sahip ikinci üretim kuyusunun brine giriş sıcaklığına olan negatif etkisi toplam brine giriş debisine olan pozitif etkisinden yaklaşık olarak %39,47 daha azdır. Buradan hareketle santralin belirli bir miktar debiden elde edeceği ısı enerjisi kazanımının sıcaklıktan kaybettiğinden daha fazla olabileceği anlaşılmaktadır. Ancak debi ve sıcaklıkların değiştirilebildiği özellikle artezyen kuyularda bu durum için optimizasyon

çalışmasının yapılması gerekmektedir. Bu yaklaşımdan her sıcaklık azalmasının daha fazla debi kazandırarak santralin güç üretimini arttıracığı genellemesi yapılmamalıdır. Kuyulardan elde edilecek debi miktarının eğer o kuyu için düşük sıcaklıkla üretimi zorunlu ise toplam giriş sıcaklık ve debilerine etkisi araştırıldıktan sonra santral üretim hattına bağlantısı yapılabilir.

Korelasyon matrisinde görüldüğü üzere, santral optimizasyonları için elde edilen verilerin basit matematiksel ilişkilerini ortaya koyarak, incelenen santralin anlaşılmasında önemli bir kaynak olmaktadır. Santralin tasarım ve işletme parametrelerinin optimizasyonu için korelasyon matrisindeki anlamlı fiziksel sonuçlar incelenerek açıklanmıştır. Elde edilen bilgiler ile oluşturulan santral optimizasyonu hesaplamalarında kullanılacak veriler Tablo 5.2’de gösterilmiştir.

Tablo 5.2: Santralden alınan ve hesaplama modelinde kullanılacak veriler

Kuyu 1			Kuyu 2			Kuyu 3			
Debi	Basınç	Sıcaklık	Debi	Basınç	Sıcaklık	Debi	Kuyubası Basıncı	Seperasyon Basıncı	Seperasyon Sıcaklığı
m ³ /h	bar	°C	m ³ /h	bar	°C	m ³ /h	bar	bar	°C

ORÇ Türbin Giriş	ORÇ Türbin Çıkış	Brine Reenjeksiyon	Brine Giriş	Brine Çıkış	Giren Brine	Giren Brine	Dış Ortam	Buhar ve NCG	Brüt Güç	İç Tüketim	Net Güç
Basınç	Basınç	Sıcaklık	Basınç	Basınç	Sıcaklık	Debi	Sıcaklık	Debi	Güç	Güç	Güç
bar	bar	°C	bar	bar	°C	t/h	°C	m ³ /sa	MW	MW	MW

İzmir bölgesindeki bir jeotermal enerji santralinden belirli bir sürede kaydedilen işletme parametreleri bu tezin araştırma konusu olan hesaplama modelinde kullanılmıştır. Ayrıca organik rankin çevrimine göre çalışan jeotermal enerji santralinin tasarım parametrelerini içeren ısı ve kütle diyagramı santral yetkilileri tarafından araştırmacıya iletilmiştir. Bu veriler sayesinde santralin tasarımındaki ekipmanların giriş ve çıkış parametreleri ile verimleri hesaplanabilmektedir. Ancak işletmede ekipmanlar üzerinde bulunmayan elektronik debi, sıcaklık basınç göstergeleri gibi tasarım parametrelerinin hepsi açıkça belirtilmemiştir. Bundan dolayı önceki bölümlerde bahsedilen kabullerin yardımıyla santral tasarım ısı ve kütle diyagramı termodinamik hesaplamalar ile oluşturulmuştur.

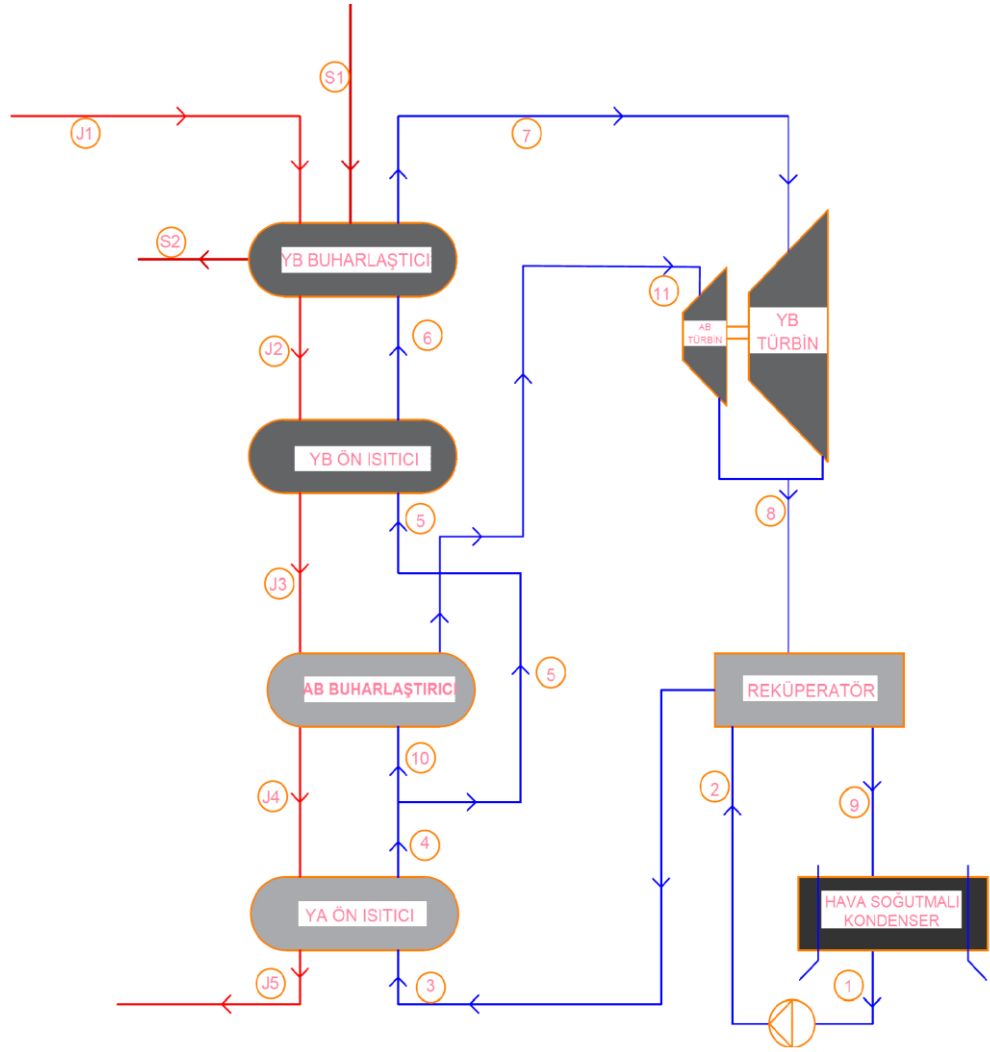
Tasarım parametrelerinde belirtilmeyen bazı ısı deęiřtiricilerinin giriş veya çıkışındaki sıcaklık ve basınçlar yapılan termodinamik hesaplamalar yoluyla bulunmuş ve sistem dengelenmiştir. Ayrıca besleme pompalarından basılan iş akışkanı bütün reküperatörden sonra iki adet ön ısıtıcıya girmektedir. Bu ön ısıtıcılar tek bir ön ısıtıcı olarak kabul edilmiştir. Her iki ısı deęiřtiriciyi birbirine bağlayan boru ekipmanları üzerinde hiçbir ölçü aleti bulunmamaktadır. Yapılan termodinamik analizleri önemli ölçüde etkilemeyeceęi için bu iki ısı deęiřtiriciyi tek bir ön ısıtıcı olarak kabul etmek yanlış olmayacaktır. Bu bilgiler ve yapılan kabuller ile birlikte santralin tasarım ısı ve kütle diyagramında bulunan tüm ekipmanların enerji ve ekserji analizleri sırasıyla yapılmıştır. Ayrıca santralin genel enerji ve ekserji verimleri bulunarak analizler mühendislik bakış açısı ile yorumlanmıştır. Yapılan termodinamik analizler tablo ve grafikler yardımıyla açıklanmıştır. Santralin tasarım parametreleri ile termodinamik analiz yapılması daha sonra incelenecek işletme şartları ve hesaplama modelinden elde edilen optimum verilerin kıyaslanmasında kullanılacak en önemli kaynaklardan birisidir.

ORÇ ile çalışan jeotermal enerji santrali YB buharlaştırıcısı, YB ön ısıtıcısı, AB buharlaştırıcısı, iki kademeye ayrılmadan önce kullanılan birleşik YA ön ısıtıcı, reküperatör, türbin, pompa ve hava soğutmalı yoęuşturucu ekipmanlarından oluşmaktadır. Organik rankin çevrimine göre çalışan santralde n-bütan iş akışkanı olarak kullanılmıştır. Jeotermal akışkan ve bütanın termofiziksel özellikleri refprop programında alınmıştır. Isı transferi hesaplamalarında karışıklık ve yanlış sonuçlar olmaması için sadece entalpi farkları ile termofiziksel özellikler için tek kaynak kullanılmıştır. Sadece hava soğutmalı santralde havanın özellikleri için termodinamik tablolardan faydalanılmıştır.

Santralin akış şeması. Şekil 5.2’de numaralandırılarak gösterilmiştir. Santral firması tarafından sağlanan ısı ve kütle diyagramı sadeleştirilerek analizler için kolay anlaşılır hale getirilmiştir.

Jeotermal üretim kuyularından elde edilen brine ve buhar boru hatları ile ORÇ içerisine getirilmektedir. Buhar sadece YB buharlaştırıcısında yoęuşturulduktan sonra reenjeksiyona basılmaktadır. Brine ise dięer buharlaştırıcı ve ön ısıtıcılardan geçerek reenjeksiyon kuyularına gönderilmektedir. Santral tasarımına göre 144,2 °C sıcaklıkta ve 228, 8 kg/s debide YB buharlaştırıcısına giren brine 127,64 °C sıcaklıkta çıkacağı

hesaplanmıştır. Burada çıkış sıcaklığı tasarım akış diyagramında verilmemiştir. Ancak brine kütle debisi, basıncı ile ORÇ iş akışkanının buharlaştırıcıya giriş çıkış debi, sıcaklık ve basıncı bilinmektedir. Daha sonra adyabatik ısı transferi kabulü ile çıkış sıcaklığı hesaplanmıştır. Buhar fazındaki jeotermal akışkan ise 152 °C ve 6,97 kg/s debide buharlaştırıcıya girerek 139 °C sıcaklıkta yoğunlaşarak ısıl enerjisini bütana aktarmıştır. Bütan 123 °C sıcaklıkta ve 150 kg/s debide buharlaştırıcıya girerek 125 °C’ de kızgın buhar halinde çıkmıştır. Bu tasarım parametrelerine göre YB buharlaştırıcının analiz tablosu Tablo 5.3’te verilmiştir.



Şekil 5 2: Santral ısı ve kütle diyagramı

Yapılan hesaplamalar sonucunda buhardan 15078,48 kW ve brinedan 16190,52 kW ısı aktarılmıştır. Ayrıca ısı değiştiricide toplamda 1049,62 kW ekserji yıkımı gerçekleşmiştir. Buharlaştırıcının ekserji verimi % 88,95 olarak bulunmuştur.

Daha sonra YB ön ısıtıcısının enerji ve ekserji analizleri yapılmıştır. Tablo 5.4'te YB ön ısıtıcısının analiz bulguları gösterilmiştir. Ön ısıtıcıda yapılan analiz sonucunda 12041,7 kW ısı transferi gerçekleşmiştir. Toplam ekserji yıkımı ise 215,34 kW ve toplam ekserji verimi %93,24 olarak bulunmuştur.

Tablo 5.2: YB Buharlaştırıcısının analiz tablosu

YÜKSEK BASINÇ BUHARLAŞTIRICI									
Hal	Akışkan Fazı	Debi (kg/s)	Sıcaklık (°C)	Basınç (bara)	Entalpi (kJ/kg)	Entropi (kJ/kg.K)	Ekserji (kW)	Toplam Ekserji Yıkımı (kW)	Ekserji Net Verimi (%)
0 _{jeo}	-	-	17	1	71,45	0,2534	-	-	-
0 _{orc}	-	-	17	1	239,9	1,1412	-	-	-
J1	Sıvı	228,8	144,2	11	607,64	1,7818	21236,01	1049,62	88,95
J2	Sıvı	228,8	127,64	10,5	536,88	1,6089	16524,32		
S1	Buhar	6,97	152	5	2748,3	6,8192	5379,96		
S2	Buhar	6,97	139	4,9	584,96	1,7287	596,23		
6	Sıvı	150	123	24,6	536,92	1,9929	7484,89		
7	Gaz	150	125	24	745,38	2,5173	15930,69		

Tablo 5.5'te ise AB buharlaştırıcısının termodinamik analiz sonuçları gösterilmiştir.

AB buharlaştırıcı ekipmanında jeotermal brinedan 11897,6 kW ısı transferi yapılarak iş akışkanına aktarılmıştır. Toplam ekserji yıkımı ve verimleri ise sırasıyla 118,18 kW ve %95,89 olarak bulunmuştur. Tablo 5.6'da yüksek ve alçak (YA) basınç kademeleri öncesindeki YA ön ısıtıcısının termodinamik analiz sonuçları gösterilmiştir.

Termodinamik hesaplamalarda YA ön ısıtıcıda 31688,8 kW ısı transferi gerçekleştiği bulunmuştur. Burada iki adet ön ısıtıcı tek bir ön ısıtıcı olarak değerlendirildiği ve yapılan ısı transferi miktarının bu sebeple diğer ısı değiştiricilerden fazla çıktığı unutulmamalıdır. Aynı zamanda toplam ekserji yıkımı

ve ekserji verimleri sırasıyla 1474,35 kW ve %75,95 olarak bulunmuştur. Verimin düşmesinin ve ekserji yıkımının artmasındaki en büyük sebep sonlu sıcaklık farkında ve düşük sıcaklıklarda ısı transferi yapılmasıdır.

Tablo 5.3: YB ön ısıtıcı analiz tablosu

YÜKSEK BASINÇ ÖN ISITICI									
Hal	Akışkan Fazı	Debi (kg/s)	Sıcaklık (°C)	Basınç (bara)	Entalpi (kJ/kg)	Entropi (kJ/kg.K)	Ekserji (kW)	Toplam Ekserji Yıkımı (kW)	Ekserji Net Verimi (%)
0 _{jeo}	-	-	17	1	71,45	0,2534	-	-	-
0 _{orc}	-	-	17	1	239,9	1,1412	-	-	-
J2	SIVI	228,8	127,64	10,5	536,88	1,6089	16524,32	215,34	93,24
J3	SIVI	228,8	115,24	10	484,23	1,4755	13313,34		
5	SIVI	150	98	25	455,46	1,7804	4514,42		
6	SIVI	150	123	24,6	536,88	1,9927	7484,89		

Tablo 5.4: AB Buharlaştırıcı analiz sonuçları

ALÇAK BASINÇ BUHARLAŞTIRICI									
Hal	Akışkan Fazı	Debi (kg/s)	Sıcaklık (°C)	Basınç (bara)	Entalpi (kJ/kg)	Entropi (kJ/kg.K)	Ekserji (kW)	Toplam Ekserji Yıkımı (kW)	Ekserji Net Verimi (%)
0 _{jeo}	-	-	17	1	71,45	0,2534	-	-	-
0 _{orc}	-	-	17	1	239,9	1,1412	-	-	-
J3	SIVI	228,8	115,24	10	484,23	1,4755	13313,34	118,18	95,89
J4	SIVI	228,8	102,94	9,5	432,23	1,3396	10437,64		
10	SIVI	46,94	98	15,7	456,37	1,7881	1350,56		
11	GAZ	46,94	100	15	720,89	2,4973	4108,08		

Termodinamik hesaplamalarda YA ön ısıtıcıda 31688,8 kW ısı transferi gerçekleştiği bulunmuştur. Burada iki adet ön ısıtıcı tek bir ön ısıtıcı olarak değerlendirildiği ve yapılan ısı transferi miktarının bu sebeple diğer ısı değiştiricilerden fazla çıktığı unutulmamalıdır. Aynı zamanda toplam ekserji yıkımı ve ekserji verimleri sırasıyla 1474,35 kW ve %75,95 olarak bulunmuştur. Verimin düşmesinin ve ekserji yıkımının artmasındaki en büyük sebep sonlu sıcaklık farkında ve düşük sıcaklıklarda ısı transferi yapılmasıdır.

Tablo 5.5: YA ön ısıtıcı analiz sonuçları

YA ÖN ISITICI									
Hal	Akışkan Fazı	Debi (kg/s)	Sıcaklık (°C)	Basınç (bara)	Entalpi (kJ/kg)	Entropi (kJ/kg.K)	Ekserji (kW)	Toplam Ekserji Yıkımı (kW)	Ekserji Net Verimi (%)
0 _{jeo}	-	-	17	1	71,45	0,2534	-	-	-
0 _{orc}	-	-	17	1	239,9	1,1412	-	-	-
J4	SIVI	228,8	102,94	9,5	432,23	1,3396	10437,64	1474,35	75,95
J5	SIVI	228,8	70	8,5	293,73	0,9546	4307,58		
3	SIVI	196,94	41,11	27,6	300,57	1,327	1331,34		
4	SIVI	196,94	98	27	455,3	1,7788	5987,05		

Bu sebeple tersinmezlikler artmıştır. Aynı zamanda tersinmezliklerin artması ısı değiştiricilerin tasarımına da bağlı olduğu hatırlanmalıdır. Tablo 5.7’de reküperatör ekipmanının termodinamik analiz sonuçları gösterilmiştir.

Reküperatördeki analizler sonucu türbin çıkışındaki kızgın buhar fazında bulunan bütan akışkanından 1538,1 kW ısı transferi pompa basma hattındaki bütana aktarıldığı hesaplanmıştır. Toplam ekserji yıkımı ve verimi sırasıyla 456,2 kW ve %17,91 olarak bulunmuştur. Reküperatördeki ısı transferi düşük sıcaklıkta ve sıcaklık farkının az olması sebebiyle verimsiz bir uygulama olarak görülebilir. Ancak atık ısının bir kısmından faydalanılarak jeotermal akışkandan daha fazla ısı transferi yapabilmek için ORÇ işletme parametreleri düzenlenebilir. Bu sayede santralden daha fazla elektrik enerjisi elde edilebilir. Reküperatörden kazanılan ısının elektrik enerjisi

üretimini ne kadar arttırdığı hesaplanmalı ve sisteme reküperatör eklenmesi ile oluşacak ek yatırım maliyetini ne kadar sürede geri ödediği analiz edilmelidir.

Tablo 5.7: Reküperatör analiz sonuçları

REKÜPERATÖR									
Hal	Akışkan Fazı	Debi (kg/s)	Sıcaklık (°C)	Basınç (bara)	Entalpi (kJ/kg)	Entropi (kJ/kg.K)	Ekserji (kW)	Toplam Ekserji Yıkımı (kW)	Ekserji Net Verimi (%)
0 _{jeo}	-	-	17	1	71,45	0,2534	-	-	-
0 _{orc}	-	-	17	1	239,9	1,1412	-	-	-
8	GAZ	196,94	58,21	4	675,93	2,5293	6552,74	465,2	17,91
9	GAZ	196,94	53,81	3,8	668,12	2,5123	5986,06		
2	SIVI	196,94	38	27,8	292,83	1,3021	1229,86		
3	SIVI	196,94	41,11	27,6	300,57	1,327	1331,34		

Reküperatördeki analizler sonucu türbin çıkışındaki kızgın buhar fazında bulunan bütan akışkanından 1538,1 kW ısı transferi pompa basma hattındaki bütana aktarıldığı hesaplanmıştır. Toplam ekserji yıkımı ve verimi sırasıyla 456,2 kW ve %17,91 olarak bulunmuştur. Reküperatördeki ısı transferi düşük sıcaklıkta ve sıcaklık farkının az olması sebebiyle verimsiz bir uygulama olarak görülebilir. Ancak atık ısının bir kısmından faydalanılarak jeotermal akışkandan daha fazla ısı transferi yapabilmek için ORÇ işletme parametreleri düzenlenebilir. Bu sayede santralden daha fazla elektrik enerjisi elde edilebilir. Reküperatörden kazanılan ısının elektrik enerjisi üretimini ne kadar arttırdığı hesaplanmalı ve sisteme reküperatör eklenmesi ile oluşacak ek yatırım maliyetini ne kadar sürede geri ödediği analiz edilmelidir. Tablo 5.8'de YB türbini termodinamik analizleri yapılmıştır.

Yapılan analizlerde türbinden 10254 kW mekanik iş elde edildiği bulunmuştur. Burada kullanılan türbinin tek bir gövdede iki kademeli olarak tasarlandığı ve türbin çıkışında her iki basınç kademesinin de karışarak aynı sıcaklık ve basınçta türbini terk ederek güç ürettiği hatırlanmalıdır. Hesaplamalar iki basınç kademesi için ayrı ayrı yapılmıştır. Toplam ekserji yıkımı ve verim değerleri sırasıyla 661,26 kW ve %93,86 olarak bulunmuştur. Tablo 5.9'da ise AB türbin analiz sonuçları gösterilmiştir.

Tablo 5.8: YB Türbin analiz sonuçları

YB TÜRBİN									
Hal	Akışkan Fazı	Debi (kg/s)	Sıcaklık (°C)	Basınç (bara)	Entalpi (kJ/kg)	Entropi (kJ/kg.K)	Ekserji (kW)	Toplam Ekserji Yıkımı (kW)	Ekserji Net Verimi (%)
0 _{jeo}	-	-	17	1	71,45	0,2534	-	-	-
0 _{orc}	-	-	17	1	239,9	1,1412	-	-	-
7	GAZ	150	125	24	744,29	2,5139	15915,16	661,26	93,86
8	GAZ	150	58,1	4	675,93	2,5293	4990,92		

Alçak basınç türbininde 2110 kW mekanik güç elde edildiği hesaplanmıştır. Toplam ekserji yıkımı ve verimi ise sırasıyla 1561,82 kW ve %82,86 olarak bulunmuştur. Düşük sıcaklıklarda çalışmanın zorluklarından birisi de tersinmezliklerin yüksek sıcaklıklara göre daha fazla olmasıdır. Alçak basınç türbinindeki sıcaklıklar YB türbine göre önemli ölçüde düşüktür. Bu sebeple ekserji yıkımı ve verimi daha düşük çıkmaktadır. Ancak AB türbini ile santral 2110 kW fazladan güç üretebildiği ve bu sayede santralin daha fazla gelir elde edeceği anlaşılmaktadır. Tablo 5.10'da bütan basma hatlarında kullanılan pompanın termodinamik analiz sonuçları gösterilmiştir.

Bu sonuçlara göre pompa 915,77 kW mekanik güç aktarmaktadır. Pompaların verimlerinin %90 değerlerinde olması sebebiyle iş akışkanına aktarılan mekanik güçten daha fazla elektrik enerjisi tüketeceği bilinmelidir. Pompadaki toplam ekserji yıkımı ve verimi sırasıyla 62,86 kW ve % 93,14 olarak bulunmuştur. Tablo 5.11'de hava soğutmalı kondenser ekipmanının termodinamik analiz sonuçları gösterilmiştir.

Hava soğutmalı kondenser ekipmanında yapılan analizler 74636,32 kW ısı transferi yapılarak bütanın yoğunlaştırıldığı hesaplanmıştır. Toplam ekserji yıkımı ve verimi ise sırasıyla 3928 kW ve %29,75 olarak bulunmuştur. Diğer ısı değiştiricilere göre hava soğutmalı kondenserin ekserji yıkımı ve verimi çok düşüktür. Bu durumun sebebi hava soğutmalı santrallerin dış hava sıcaklığına ve atmosfer koşullarına bağlı olmasıdır. Aynı zamanda düşük sıcaklık farklarında çalışmalarını sebebiyle

tersinmezlikleri fazladır. Su soğutmalı santrallerde bu durum daha farklı olabilir. Tablo 5.12’de tüm ekipmanların ve santralin genel analiz sonuçları gösterilmiştir.

Tablo 5.9: AB Türbin analiz sonuçları

AB TÜRBİN									
Hal	Akışkan Fazı	Debi (kg/s)	Sıcaklık (°C)	Basınç (bara)	Entalpi (kJ/kg)	Entropi (kJ/kg.K)	Ekserji (kW)	Toplam Ekserji Yıkımı (kW)	Ekserji Net Verimi (%)
0 _{jeo}	-	-	17	1	71,45	0,2534	-	-	-
0 _{orc}	-	-	17	1	239,9	1,1412	-	-	-
11	GAZ	46,94	100	15	720,89	2,4973	4108,08	1561,82	82,86
8	GAZ	46,94	58,21	4	675,93	2,5293	1561,82		

Tablo 5.6: ORÇ pompası analiz sonuçları

ORC BESLEME POMPASI									
Hal	Akışkan Fazı	Debi (kg/s)	Sıcaklık (°C)	Basınç (bara)	Entalpi (kJ/kg)	Entropi (kJ/kg.K)	Ekserji (kW)	Toplam Ekserji Yıkımı (kW)	Ekserji Net Verimi (%)
0 _{jeo}	-	-	17	1	71,45	0,2534	-	-	-
0 _{orc}	-	-	17	1	239,9	1,1412	-	-	-
1	SIVI	196,94	36,7	3,8	288,17	1,3010	374,98	62,86	93,14
2	SIVI	196,94	38	27,8	292,82	1,3021	1227,89		

Santralin tasarım parametrelerine bağlı olarak yapılan termodinamik analiz sonuçlarına göre toplamda jeotermal brine ve buhardan 86901,09 kW ısı enerjisi organik rankine çevrimine aktarılmıştır. Santralin brüt güç üretimi ve iç tüketimi miktarları santral tasarım ısı ve kütle diyagramında verilmiştir. Bu değerler ile termodinamik hesaplamalar sonucunda elde edilen değerler yapılan kabuller

doğrultusunda örtüşmektedir. Bu sebeple yapılan verim analizleri net güç çıktısı santral tasarım parametrelerinde verilen değer alınarak hesaplanmıştır.

Tablo 5.11: Hava soğutmalı kondenser analiz sonuçları

HAVA SOĞUTMALI KONDENSER									
Hal	Akışkan Fazı	Debi (kg/s)	Sıcaklık (°C)	Basınç (bara)	Entalpi (kJ/kg)	Entropi (kJ/kg.K)	Ekserji (kW)	Toplam Ekserji Yıkımı (kW)	Ekserji Net Verimi (%)
0 _{hava}	-	-	17	1	290,31	1,66853	-	-	-
0 _{orc}	-	-	17	1	239,9	1,1412	-	-	-
9	GAZ	196,94	53,31	3,8	667,15	2,5093	5966,45	3928	29,75
1	SIVI	196,94	36,7	3,8	288,17	1,3010	374,98		
A1	GAZ	7324,47	19	1	292,31	1,67538	91,56		
A2	GAZ	732,47	29	1,001	302,35	1,7092	302,35		

Santralde toplam çevrim sonucu oluşan ekserji yıkımı 5801,27 kW olarak hesaplanmıştır. Ayrıca santralin ısı ve ekserji verimleri sırasıyla %11,88 ve %47,53 olarak bulunmuştur. Ekserji yıkımının ne kadarı santrale kazandırılarak elektrik enerjisi elde edilebilir araştırılmalıdır. Piyasada yapılan jeotermal enerji santrallerinin bir çoğunda net ısı verimi %10-12 aralığında tasarlanmıştır. Bu bağlamda santralin ısı verimi geliştirilebilir olmasının yanında yatırım açısından uygulanabilir olduğu da vurgulanmalıdır. Ancak hesaplanan 5801,27 kW ekserji yıkımının nereden kaynaklandığı önemli bir araştırma konusudur.

Tablo 5.12: Santralin tasarım parametrelerine göre ekipman ve genel analiz sonuçları

TASARIM EKİPMAN VE SANTRAL ANALİZ SONUÇLARI				
SANTRAL / EKİPMAN	Toplam Isı Transferi / İş (kW)	Toplam Ekserji Yıkımı (kW)	Toplam Net Ekserji Verimi (%)	Toplam Net Enerji Verimi (%)
YB Buharlaştırıcı	31269	1049,62	88	-
YB Ön Isıtıcı	12041,7	215,34	93,24	-
AB Buharlaştırıcı	11897,6	118,18	95,89	-
YA Ön Isıtıcı	31688,8	1474,35	75,95	-
Rekuperatör	1538,1	456,2	17,91	-
YB Türbin	10254	661,26	93,86	-
AB Türbin	2110	1561,82	82,86	-
ORC Pompa	915,77	62,86	93,14	-
Hava Soğutmalı Kondenser	74636	3928,09	29,75	-
Santral Brüt Güç Üretimi	12240	-	-	-
Santral İç Tüketim	1920	-	-	-
Samraş Net Güç Üretimi	10320	-	-	-
Genel Santral	86901,09	-	47,53	11,88

Ekipman tasarımı, iş akışkanının seçilmesi, işletme parametrelerinin seçimi ve sonlu sıcaklık farkı gibi sebeplerle tersinmezlikler oluşarak ekserji yıkımına sebep olmaktadır. Buradan hareketle santrallerin tasarlanmasındaki optimizasyon çalışmalarında harcanan emek ve süre ile ekserji yıkımının nasıl önüne geçileceği araştırılabilir. Bu sebeple santral tasarım ve işletmeleri için optimizasyon çalışmaları daha anlaşılır, tutarlı ve kolay hale getirilmelidir. Kurulumu yapılan santrallerde ise işletme parametrelerinin ve jeotermal kaynak kullanımı optimizasyonu önemli bir mühendislik problemi olarak karşımıza çıkmaktadır. Santrallerin işletme dönemlerinde jeotermal kaynaklardaki değişimler ve diğer sebeplerden dolayı

santraller tasarım parametrelerinde çalıştırılmayabilir. Jeotermal kaynaklardaki değişimlere de adapte olabilecek şekilde santral işletmecileri sürekli takibi yapılabilen bir hesaplama yöntemine ihtiyaç duymaktadırlar. Bu bağmla tezin konusu olan hesaplama modeli iyi bir çözüm olabilir. Tasarlanan hesaplama modeli istenilen her santral için ayrı ayrı hesaplar yapabilmektedir. Sadece santrallerden alınacak verilerin adetine göre veri tanımlaması yapılarak hesaplama modeli çalıştırılabilir.

İzmir bölgesindeki jeotermal santralden alınan veriler ile santral keşif ziyaretinde elde edilen ancak SCADA üzerinde bulunmayan veriler toplanarak işletme parametreleri üzerinde termodinamik analizler yapılmıştır. Bu analizlerin ne kadar uzun, zahmetli ve tecrübe gerektiren bir çalışma olduğu unutulmamalıdır. Aynı zamanda insanların hesap hataları sebebiyle bu hesaplamalar içerisinden çıkılamaz bir hale gelebilir. Bu bağlamda öncelikle işletme parametrelerinin analizleri yapılarak açıklanacak ve sonrasında hesaplama modelinin gelişimi ve sonuçları termodinamik analizler ile desteklenerek sunulacaktır.

Santralden 11.06.2024 tarihinde santral ziyareti gerçekleştirilmiştir. Santralden aynı tarih ve saat 16:31'de SCADA ekran görüntüleri ile santral içerisinden ORÇ iş akışkanı sıcaklık ve basınç verileri alınarak işletme parametreleri termodinamik analizlerde kullanılmıştır. Bu veriler ile yapılan analiz sonuçları Tablo 5.13'te gösterilmiştir. Ayrıca santralin ekipmanlarının enerji ile ekserji hesaplamaları yapılarak Tablo 5.14'te gösterilmiştir.

Yapılan analizlerde santral ekipmanlarından giren ve çıkan akışkanların debi, sıcaklık ve basınçları ile işletme akış tablosu oluşturulmuştur. Bu sonuçlar ile ekipmanların ve santralin genel enerji ve ekserji analizleri yapılmıştır.

Analiz sonuçlarına göre santralin işletme parametreleri tasarım parametrelerinden oldukça farklıdır. Ayrıca tasarım parametrelerinde hava sıcaklığı 19 °C alınması sebebiyle yaz aylarında santral veriminde düşüş olacağı bilinmelidir. Santral bu işletme şartlarında 4943 kW brüt ve 3748 kW net güçte çalışmaktadır. Burada santral besleme pompalarının iç tüketimi önemli ölçüde arttırdığı görülmektedir. Bunun sebebi ise santral daha düşük brine ve buhar debisinde çalışmasına rağmen pompaların belirli bir limitin altında çalışmaması olabilir.

Tablo 5.13: İşletme verilerinin analiz sonuçları

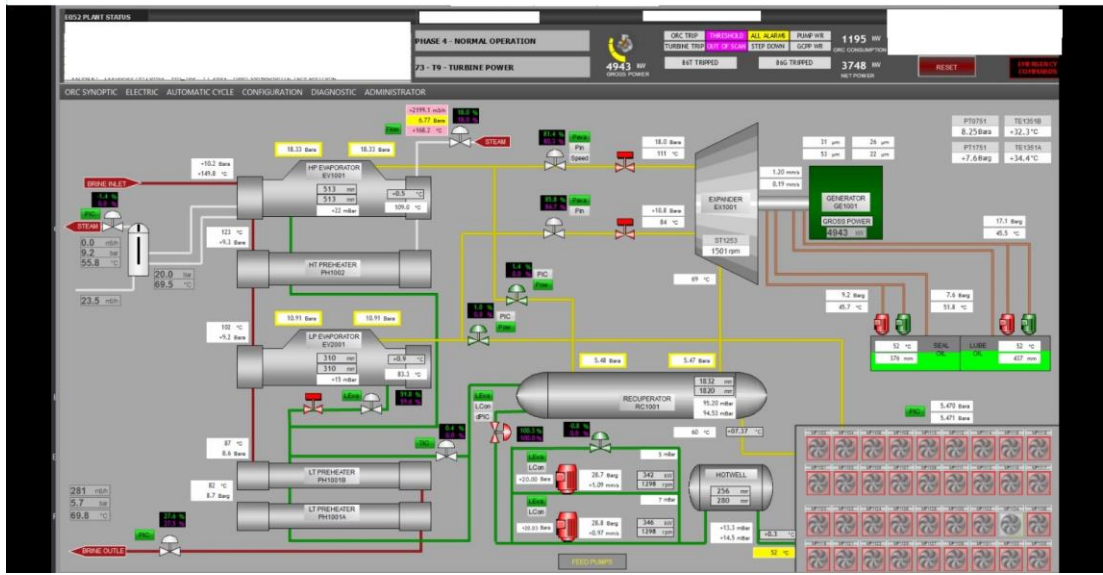
SANTRALİN İŞLETME PARAMETRELERİ							
Hal	Akışkan Fazı	Debi (kg/s)	Sıcaklık (°C)	Basınç (bar)	Entalpi (kJ/kg)	Entropi (kJ/kg.K)	Ekserji (kW)
0 _{hava}	-	-	17	1	290,31	1,66853	-
0 _{jeo}	-	-	17	1	71,45	0,2534	-
0 _{orc}	-	-	17	1	239,9	1,1412	-
J1	SIVI	160,75	149,6	10	630,45	1,8371	15992,9
J2	SIVI	160,75	124	9	521,29	1,5702	10894,1
S1	BUHAR	2,69	167,4	6,63	2771,9	6,7517	2192,26
S2	SIVI	2,69	66	6,2	276,8	0,90567	43,3
6	SIVI - GAZ	78,61 - 22,17	110,5	19,1	495,48 - 732,15	1,8898 - 2,5070	3016,56 - 952,49
7	GAZ	100,78	112	18,71	736,02	2,5166	9780,47
J3	SIVI	160,75	103	8,9	432,41	1,3404	7324,88
5	SIVI	100,78	81	19,2	406,21	1,6479	1924,88
J4	SIVI	160,75	88	8,36	369,2	1,1691	5153,59
10	SIVI	34,21	81	11,2	406,43	1,653	616,85
11	GAZ	34,21	85	11,12	703,41	2,4838	2529,99
J5	SIVI	160,75	72,6	8	304,59	0,9863	3293,62
3	SIVI	135	58	20	343,55	1,4645	1329
4	SIVI - GAZ	129,6 - 5,4	81	19,1	406,22 - 697,62	1,6479 - 2,4757	2882,19
8	GAZ	135	69	5,4	692,18	2,5388	6313,18
9	GAZ	135	60	5,38	673,89	2,4851	5947,75
2	SIVI	135	52,5	20,5	329,22	1,4206	1114,03
1	SIVI	135	52	5,35	327,33	1,4234	749,2
A1	MÜKEMMEL GAZ	4652	33	1	306,37	1,7224	1998,59
A2	MÜKEMMEL GAZ	4652	43	1,001	311,4	1,73868	3423,77

Tablo 5.14: İşletme parametrelerine göre Santral ekipmanları ve genel analiz sonuçları

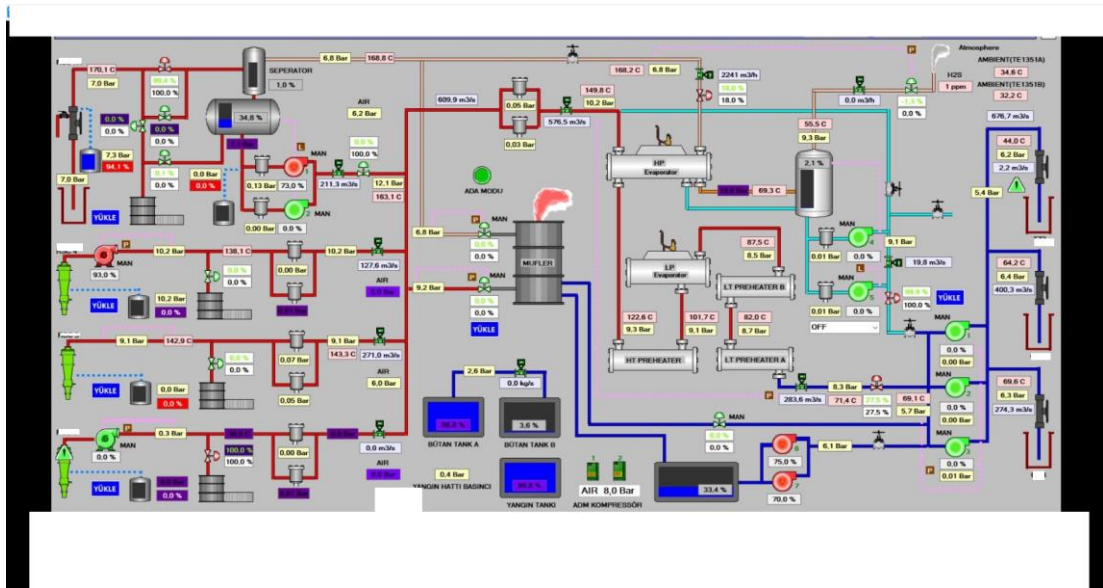
İŞLETME EKİPMAN VE SANTRAL ANALİZ SONUÇLARI				
SANTRAL / EKİPMAN	Toplam Isı Transferi / İş (kW)	Toplam Ekserji Yıkımı (kW)	Toplam Net Ekserji Verimi (%)	Toplam Net Enerji Verimi (%)
YB Buharlaştırıcı	24259,29	1436,37	80,18	-
YB Ön Isıtıcı	14287,46	1544,32	57,85	-
AB Buharlaştırıcı	10161	258,15	88,11	-
YA Ön Isıtıcı	10386,05	306,78	83,51	-
Rekuperatör	1937,25	150,74	58,78	-
YB Türbin	4418,2	649,15	87,19	-
AB Türbin	384,18	545,84	41,31	-
ORC Pompa	688	-	-	-
Hava Soğutmalı Kondenser	46785,6	3773,37	27,41	-
Santral Brüt Güç Üretimi	4943	-	-	-
Santral İç Tüketim	1195	-	-	-
Samraş Net Güç Üretimi	3748	-	-	-
Genel Santral	59093,82	-	25,24	6,34

İşletme şartlarına göre santralin termodinamik hesaplamaların yapılabilmesi için iş akışkanının debisi bilinmesi gerekmektedir. Ancak santralde böyle bir debimetre bulunmamaktadır. Kontrol odasındaki SCADA bilgisayarından alınan ekran görüntüleri ve sahadan elde edilen sıcaklık ve basınç göstergelerindeki verilere göre debi termodinamik olarak hesaplanmıştır. Yüksek ve alçak buharlaştırıcıların giriş çıkış sıcaklık ve basınç verileri mevcuttur. Aynı zamanda jeotermal akışkan tarafındaki debimetreler çalışmaktadır. Dış ortama ısıl enerjinin ihmal edilebilir ölçüde kaçabileceği kabulü ile termodinamik hesaplamalar sonucu YB tarafında 100,78 k/s ve AB tarafında 34,21kg/s toplam debi ise 135 kg/s olarak bulunmuştur. Bu veriler ile

ekipmanların giriş ve çıkış değerleri olmayan haller bulunarak santral termodinamik denge halinde hesaplanabilmiştir. Hesaplamaların sonuçları ile gerçekleşen arasındaki farklılıklar gösterge okuma hatası veya virgül sonrası anlamlı basamak hatalarından kaynaklanabilir. Dahası santralin elektronik olarak elde ettiği özelliklerde de küçük hatalar olabilir. Hesaplamadaki küçük hatalar sistem tasarımı ve işletme parametrelerini büyük ölçüde etkilemediği için ihmal edilebilir. Şekil 5.3 ve Şekil 5.4'te SCADA ekran görüntüleri verilmiştir.



Şekil 5.3: Santral ORÇ SCADA ekran görüntüsü



Şekil 5.4: Santral brine ve buhar SCADA ekran görüntüsü

Analizlere buharlaştırıcı ekipmanlarından başlanmıştır. YB ve AB ekipmanlarının ekserji yıkımları ve verimleri sırasıyla 1436,37 ve 1544,32 ile %80,18 ve %88,11 olarak bulunmuştur. Buharlaştırıcılar tasarım verilerine göre bir miktar düşük ekserji veriminde işletilmelerinin sebebi tasarım verilerinden daha düşük ısı enerji sisteme girdiği için beklenen bir durumdur. Ancak YB ön ısıtıcısı tasarım verilerinin çok altında bir ekserji verimi ile çalışmaktadır. Toplam ekserji yıkımı ve verimi santral tasarımı ile karşılaştırılacak olursa tasarımda 215,34 kW olan ekserji yıkımı işletmede 1544,32 kW olmaktadır. Aynı şekilde ekserji verimleri de tasarım ve işletmede sırasıyla %93,24 ve %57,85 olarak bulunmuştur. Termodinamik analizler esnasında ekipmanlardan özellikle YB ön ısıtıcısındaki ısı transferi dengesi önce kurulamamış daha sonra bunun sebebinin YB ön ısıtıcıdan YB buharlaştırıcısına giden çıkış kısmında çürük buhar oluşumu olduğu anlaşılmıştır. Yapılan hesaplamalarda %22 oranında bütan debisinin gaz fazına geçtiği bulunarak hesaplamalar tekrar edilmiştir. Ekserji yıkımının sebeplerinden birisi de bu durum olabilir. Ayrıca faz değişimi esnasında ısı transfer hızı artacaktır. Bu artış jeotermal akışkandan daha fazla ısı alınmasına sebep olmaktadır. Başlangıçta bu durum santral verimi açısından doğru olduğu düşünülebilir ancak diğer ekipmanlarda daha düşük sıcaklıklarda ısı transferi olmasına genel ekserji veriminin düşmesine sebep olabilir.

Bir başka problem de istenilen ısı transferi miktarının gerçekleştirilememesi sebebi ile reenjeksiyon sıcaklığının artmasıdır. Bu bağlamda santral yetkilileri ile yapılan görüşmelerde santralin 70 °C reenjeksiyon sıcaklığında tasarlanmasına rağmen suyun kimyasal özelliklerine vurgu yaparak 65 °C reenjeksiyon sıcaklığının da kullanılabilmesi bildirilmiştir. Bunun yanı sıra santral kış aylarında 60-65 °C reenjeksiyon sıcaklığında çalıştırılmaktadır. Daha düşük reenjeksiyon sıcaklıkları ile daha fazla ısı enerjisi alınarak santral güç üretimi arttırılabilir olmasına rağmen verimsiz işletme koşulları sebebiyle reenjeksiyon enerjisi artmış ve santral işletmesi açısından araştırmacıya fikir vermiştir. Analizler sonucunda ortaya çıkan bu problemi çözmek için bütan iş akışkanının basıncı ve debisi arttırılmalıdır. Bu sayede YB ön ısıtıcı çıkışındaki buharlaşmanın önüne geçilerek hal değişiminin olması gerektiği ekipman olan YB buharlaştırıcısında daha yüksek sıcaklıkta bütan elde edilebilir. Aynı zamanda reenjeksiyon sıcaklığı düşürülerek sıcak yaz aylarında verimi ve güç üretimi düşen santralin verimi arttırılabilir.

Organik rankine çevriminin hangi işletme parametreleri ile çalışması gerektiği bir optimizasyon problemidir. Santrallerin işletmelerde karşılaştıkları bu tip problemlerin hızlı bir şekilde inceleyerek hesaplamalar yapabileceği bir yöntem ihtiyacı vardır. Jeotermal Santrallerin işletmelerinde gözlem yapılsada parametrik analizlerin uzun ve zahmetli olması sebebiyle sürekli olarak analiz yapılması mümkün değildir. Bu bağlamda geliştirilecek olan hesaplama modeli önemli bir yenilik olarak gösterilebilir.

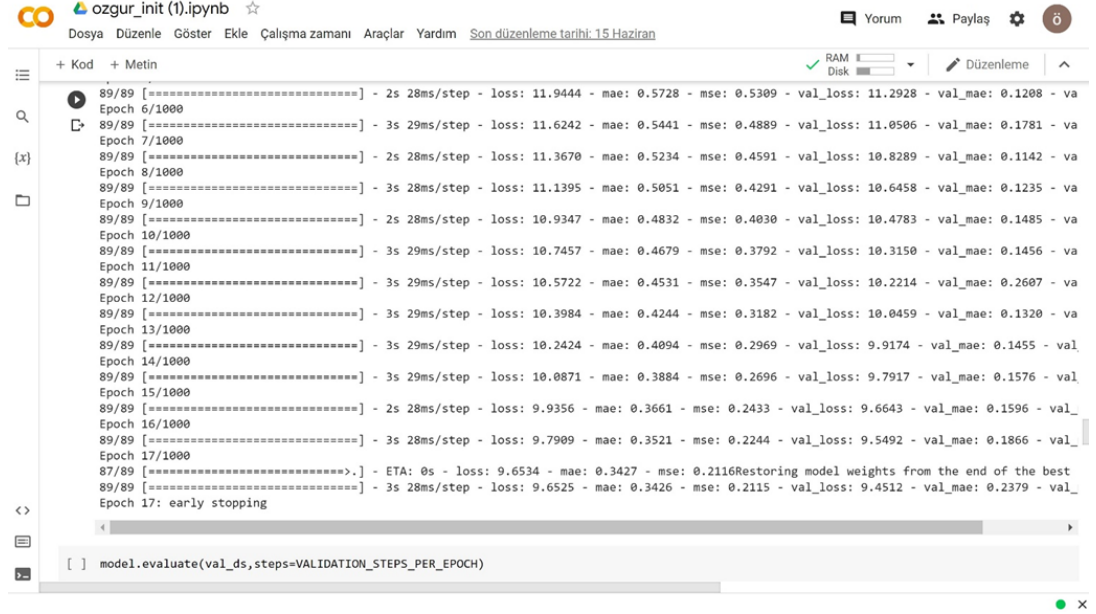
Genel santralin enerji ve ekserji verimleri incelendiğinde tasarım parametrelerinden oldukça düşük olduğu görülmektedir. Bunun en önemli iki sebebinden birisi hava soğutmalı santrallerde santral verimini doğrudan etkileyen dış ortam sıcaklığıdır. Ayrıca santralin işletme parametrelerinde optimizasyon yapılmaması sebebiyle oluşan yüksek ekserji yıkımları santralin verimini ve güç üretimini düşürebilmektedir. Burada dikkat edilmesi gereken konu dış ortam sıcaklığının kontrol edilememesine rağmen işletme şartlarının kontrol edilebilir olmasıdır.

Jeotermal enerji santrallerinin işletme parametreleri dış ortam sıcaklığı, jeotermal kaynakta yaşanan değişimler ve santralin işletme kontrol algoritması ile önemli ölçüde ilişkilidir. Bu sebeple geliştirilen model sayesinde elde edilen optimum olası çözümler termodinamik analizler ile desteklenerek santral için optimum işletme şartları önerilebilir.

Öncelikle derin yapay sinir ağları ve genetik algoritmadan elde edilen sonuçların optimum olup olmamasına bakılmadan nasıl veri üretimi gerçekleştirdiği grafikler yardımıyla açıklanacaktır. Sonrasında verileri kullanılan santralin işletme koşullarına benzer işletme parametreleri üretebildiği tablo ve grafikler ile doğrulanacaktır. Son olarak hesaplama modelinden elde edilen optimum işletme şartları termodinamik analizlerle desteklenerek çalışma tamamlanacaktır.

Derin yapay sinir ağlarını uygunluk fonksiyonu olarak kullanan genetik algoritma ile oluşturulan hesaplama modelinin nasıl çalıştığı önceki bölümlerde detaylı olarak anlatılmıştır. Bu bölümde ise derin yapay sinir ağının öğrenme sürecinin ekran görüntüsü alınara Şekil 5.5'te gösterilmiştir. Elde edilen verilere göre 0,3426 ortalama mutlak hata (mae) ve 0,2115 ortalama kare hata (mse) değeri ile en iyi öğrenme

modelini oluşturarak işlemi durdurmuştur. Buna karşılık modeldeki kötü değerler mae ve mse için sırasıyla 0,5728 ve 0,5309 olarak bulunmuştur. Elde edilen DYSA modeli genetik algorithmda uygunluk fonksiyonu olarak kullanılmıştır. Ayrıca genetik algoritmanın çalıştırılması sonrası elde edilen olası optimum noktaların nasıl bulunduğu Şekil 5.6'da gösterilmiştir.



```
89/89 [=====] - 2s 28ms/step - loss: 11.9444 - mae: 0.5728 - mse: 0.5309 - val_loss: 11.2928 - val_mae: 0.1208 - va
Epoch 6/1000
89/89 [=====] - 3s 29ms/step - loss: 11.6242 - mae: 0.5441 - mse: 0.4889 - val_loss: 11.0506 - val_mae: 0.1781 - va
Epoch 7/1000
89/89 [=====] - 2s 28ms/step - loss: 11.3670 - mae: 0.5234 - mse: 0.4591 - val_loss: 10.8289 - val_mae: 0.1142 - va
Epoch 8/1000
89/89 [=====] - 3s 28ms/step - loss: 11.1395 - mae: 0.5051 - mse: 0.4291 - val_loss: 10.6458 - val_mae: 0.1235 - va
Epoch 9/1000
89/89 [=====] - 2s 28ms/step - loss: 10.9347 - mae: 0.4832 - mse: 0.4030 - val_loss: 10.4783 - val_mae: 0.1485 - va
Epoch 10/1000
89/89 [=====] - 3s 29ms/step - loss: 10.7457 - mae: 0.4679 - mse: 0.3792 - val_loss: 10.3150 - val_mae: 0.1456 - va
Epoch 11/1000
89/89 [=====] - 3s 29ms/step - loss: 10.5722 - mae: 0.4531 - mse: 0.3547 - val_loss: 10.2214 - val_mae: 0.2607 - va
Epoch 12/1000
89/89 [=====] - 3s 29ms/step - loss: 10.3984 - mae: 0.4244 - mse: 0.3182 - val_loss: 10.0459 - val_mae: 0.1320 - va
Epoch 13/1000
89/89 [=====] - 3s 29ms/step - loss: 10.2424 - mae: 0.4094 - mse: 0.2969 - val_loss: 9.9174 - val_mae: 0.1455 - val
Epoch 14/1000
89/89 [=====] - 3s 29ms/step - loss: 10.0871 - mae: 0.3884 - mse: 0.2696 - val_loss: 9.7917 - val_mae: 0.1576 - val
Epoch 15/1000
89/89 [=====] - 2s 28ms/step - loss: 9.9356 - mae: 0.3661 - mse: 0.2433 - val_loss: 9.6643 - val_mae: 0.1596 - val
Epoch 16/1000
89/89 [=====] - 3s 28ms/step - loss: 9.7909 - mae: 0.3521 - mse: 0.2244 - val_loss: 9.5492 - val_mae: 0.1866 - val
Epoch 17/1000
87/89 [=====>.] - ETA: 0s - loss: 9.6534 - mae: 0.3427 - mse: 0.2116Restoring model weights from the end of the best
89/89 [=====] - 3s 28ms/step - loss: 9.6525 - mae: 0.3426 - mse: 0.2115 - val_loss: 9.4512 - val_mae: 0.2379 - val
Epoch 17: early stopping
```

Şekil 5 5: DYSA öğrenme süreci

Modelin üzerine çalıştığı jeotermal enerji santralinden alınan veriler ile yapılan analizlerde 20.000 adet satır bir başka ifade ile olası çözümler üretilmiştir. Bu bağlamda yöntem optimum çözümleri kesin olarak garanti edemeyebilir. Ancak araştırmacı deneyim ve analiz yöntemlerini kullanarak istenilen işletme şartlarına ulaşılabilmesi için ihtiyaç duyulan işletme parametrelerini seçebilir. Ayrıca hesaplama modeli ilerleyen dönemlerde geliştirilebilir ve çıktılarının yorumlanması için ek araçlar geliştirilebilir. Bu aşamada hesaplama yönteminin analizi yapılan santralin çalışma koşullarını modelleyebilmesi ve bu şartlara göre veya daha iyi çalışabileceği işletme şartlarını tespit etmesi hedeflenmektedir. Sonuçlardan yola çıkarak sadece belirli bir andaki değil farklı zamanlarda yapılabilecek senaryolar geliştirilebilir. Çalışmanın sonunda santral için farklı işletme parametreleri ve nasıl uygulanabileceği ile ilgili çözüm önerileri sunulacaktır.

```
ozgur_init (1).ipynb
Dosya Düzenle Göster Ekle Çalışma zamanı Araçlar Yardım Tarih değişiklikler kaydedildi
RAM Disk
+ Kod + Metin
for j in range(number_of_offspring):
    p1, p2 = np.random.choice(len(survivors), 2, replace=False)
    new_offspring = generate_offspring(next_population[p1], next_population[p2])
    next_population = np.append(next_population, [new_offspring], axis=0)

population = next_population
csvwriter.writerow("")

-----
GENERATION # 7
-----
MINIMUM Net Power: -13.999431610107422 MAXIMUM Net Power: 11.153631210327148
[1.86006655e+02 9.83697690e+00 1.44359006e+02 1.50000000e+03
 9.50000000e+01 3.47735989e+02 1.83974386e+02 1.11849575e+00
 9.90674863e+01 1.50000000e+03 9.00000000e+01 3.80194671e+02
 2.56525847e+02 7.38495149e+00 7.14795812e+00 1.65049243e+02
 2.0322236e+01 1.98387834e+02 1.80594293e+02 4.40374770e+00
 1.86626468e+02 8.87675851e+01 6.08512024e+02 1.58834726e+02
 1.76730020e+01 2.79286894e+00 7.33147823e+01 9.29937577e+00
 3.30847897e+00 1.55988134e+02 2.72078557e+02 2.58752166e+01
 3.51035668e+03 6.12791941e-01 3.49745680e+01 1.92822409e+00
 5.51744367e+01 1.23672850e-01]
# of survivors: 904

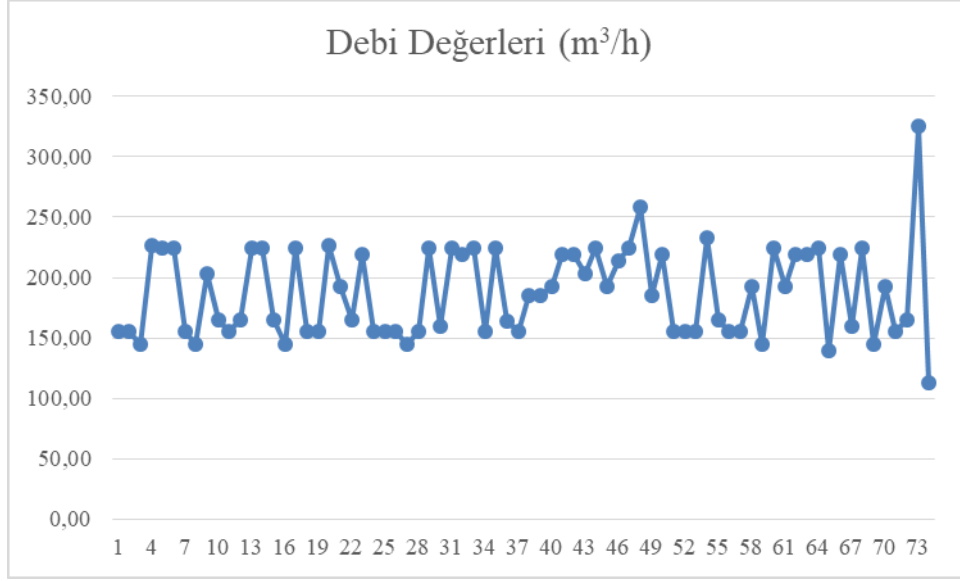
GENERATION # 8
-----
MINIMUM Net Power: -7.0633649826049805 MAXIMUM Net Power: 15.575496673583984
[1.54208991e+02 1.01828285e+01 1.43410792e+02 1.50000000e+03
 9.50000000e+01 3.75697810e+02 1.43229328e+02 2.63167482e+00
 1.21174823e+02 1.50000000e+03 9.00000000e+01 3.57924117e+02
 2.39200078e+02 8.69922981e+00 6.90422167e+00 1.62476794e+02
 1.79400695e+02 1.32841479e+02 5.12787079e+02 1.15825792e+00
 3.49264848e+01 6.92171615e+01 1.19074037e+02 1.39849400e+03
 1.71487803e+01 3.77117213e+00 5.09597974e+01 1.02783239e+01
 3.91769639e+00 1.53143106e+02 3.13406686e+02 2.03739804e+01
 4.25818864e+03 5.04981736e+00 2.80375321e+01 7.05083077e+00
 8.30206159e+00 2.87943713e-01]
# of survivors: 762

GENERATION # 9
```


Şekil 5 6: Genetik algoritma ile üretilen olası optimum verilerin ekran görüntüsü

Santral verileri ile öğrenmesi tamamlanan ve olası çözümleri hesaplayan yöntemden elde edilen sonuçlar grafikler ile gösterilecektir. Şekil 5.7 ve Şekil 5.8’de üretilen verilerin 1. Ve 50. Jenerasyonlarda nasıl optimum bir aralıkta kalacak şekilde hesapladığını göstermektedir.

Kuyu verilerinin modellenmesi literatürdeki çalışmalarda da yapılmaktadır. Burada kuyuların işletmedeki parametre değişimlerini öğrenerek nasıl bir işletme yapılması gerektiğini bulmak için ilk ve son jenerasyonlarda olası debi değerleri üretilmiştir. Bu sayede rastgele üretilen verilerden belirli bir aralıkta kümelenecek hale geçerek işletmeye yakın ve olası optimum koşulları bulmaya çalışmıştır. Şekil 5.9’da yöntemden elde edilen olası net güç üretimlerinin bir kısmı gösterilmiştir.




Şekil 5 7: 1. Jenerasyon kuyu verileri




Şekil 5 8: 50. Jenerasyon kuyu verileri

Yöntemde amaç fonksiyonu olan net gücün optimizasyonu için tüm veriler analiz edilmektedir. Şekil 5.10'de olası net güç değerlerinin 50. Jenerasyonunda önceki jenerasyonlara göre daha yatay ve optimum noktalarda hesaplandığı gösterilmiştir.



Şekil 5 9: 1. Jenerasyon olası net güç üretimleri



Şekil 5 10: 50. Jenerasyon olası net güç üretimleri


Yöntemden elde edilen verilerin tutarlılığı ve optimizasyon çalışmalarında yöntemin kullanılabilirliği bu grafikler ile vurgulanmaktadır. Tablo 5.15’de santral verilerini modelleyen hesaplama yönteminden elde edilen parametreler ile işletme parametreleri karşılaştırılmıştır. Hesaplama yöntemi ile öncelikle santralin çalışma verilerine benzer senaryolar üretilmesi hedeflenmiştir. Bu sayede yöntemin tutarlılığı tartışılabilir. Ayrıca DYSA modelinin öğrenme sonucunda santralin modelleme başarısını ölçebildiğimiz mae ve mse değerleri de kullanılmaktadır. Şekil 5.11’de santralin herhangi bir zamanında kayıt edilen veriler ile hesaplama yönteminden elde edilen veriler grafik üzerinden karşılaştırılarak santralin verilerine çok yakın işletme

koşullarının oluşturulabileceği gösterilmiştir. Bu sayede hesaplama yönteminin santral verilerine benzer işletme şartlarını hesaplayabildiği aynı zamanda farklı dönemlerdeki şartları da tahmin edebildiği grafiklerde gösterilerek ifade edilmiştir. Geliştirilen yöntemin öncelikli hedefi santralin işletme şartlarına benzer veriler üretebilmesidir. Bu sayede yöntemin tutarlılığı ve güvenilirliği vurgulanmaktadır. Farklı zamanlarda ve veri adetleri ile hesaplama yöntemi çalıştırılarak benzer sonuçlara ulaşılmış ve tekrar edilebilirliği araştırılmıştır.

Tablo 5.15: Yöntemden elde edilen ve işletme verilerinin karşılaştırılması

	Kuyu 1			Kuyu 2			Kuyu 3			
	Debi	Basınç	Sıcaklık	Debi	Basınç	Sıcaklık	Debi	Kuyubası Basıncı	Seperasyon Basıncı	Seperasyon Sıcaklığı
	m ³ /h	bar	°C	m ³ /h	bar	°C	m ³ /h	bar	bar	°C
Hesaplanan Veriler	221,82	9,59	135,11	158,26	6,5	129,7	272,54	6,57	5	161,26
İşletme Verileri	211,8	10	142,1	176,6	7	129	232	5,9	5,4	160,6

	ORÇ Türbin Giriş	ORÇ Türbin Çıkış	Brine Reenjeksiyon	Brine Giriş	Brine Çıkış	Giren Brine	Giren Brine	Dış Ortam	Buhar ve NCG	Brüt Güç	İç Tüketim	Net Güç
	Basınç	Basınç	Sıcaklık	Basınç	Basınç	Sıcaklık	Debi	Sıcaklık	Debi	Güç	Güç	Güç
	bar	bar	°C	bar	bar	°C	t/h	°C	m ³ /sa	MW	MW	MW
Hesaplanan Veriler	18,03	3,91	63,73	10,19	8,1	142,29	637,02	22,23	4832,86	8,55	1,81	6,74
İşletme Verileri	18,1	2,94	62,1	10	7,9	144,8	588,4	14	4287	8,57	1,89	6,68



Şekil 5.11: Santral verileri ve hesaplama yönteminden elde edilen veriler

Genetik algoritmanın elde ettiği olası çözüm senaryolarından birisinde buhar debisi olmadan santral işletme parametreleri belirlenmiştir. Burada türbin çıkış basıncı tasarımda verilen kondenser basıncı alınarak hesaplamalar yapılmıştır. Tablo 5.16’da santralin çalışmasına benzer işletme parametrelerinin hesaplama sonucu elde edilen değerleri gösterilmiştir. Buradaki en önemli belirlenmesi gereken parametre bütanın debisidir. Ancak daha öncesinde yöntemden elde edilen verilerin termodinamik olarak analizinin yapılması gerekmektedir. Kuyu verileri ile elde edilen ısı enerjisi ile brüt güç değeri kullanılarak enerji verimi hesaplanmıştır.

Tablo 5.16: Santralin çalışmasına benzer senaryonun olası parametreleri

	Kuyu 1			Kuyu 2			Kuyu 3			
	Debi	Basınç	Sıcaklık	Debi	Basınç	Sıcaklık	Debi	Kuyubası Basıncı	Seperasyon Basıncı	Seperasyon Sıcaklığı
	m ³ /h	bar	°C	m ³ /h	bar	°C	m ³ /h	bar	bar	°C
Hesaplanan Veriler	197,85	10,1	148,49	137,29	6,8	128,25	236,96	5,81	5,62	157,5

	ORÇ Türbin Giriş	ORÇ Türbin Çıkış	Brine Reenjeksiyon	Brine Giriş	Brine Çıkış	Giren Brine	Giren Brine	Dış Ortam	Buhar ve NCG	Brüt Güç	İç Tüketim	Net Güç
	Basınç	Basınç	Sıcaklık	Basınç	Basınç	Sıcaklık	Debi	Sıcaklık	Debi	Güç	Güç	Güç
	bar	bar	°C	bar	bar	°C	t/h	°C	m ³ /sa	MW	MW	MW
Hesaplanan Veriler	18	4,97	70,9	10,24	3,41	149,61	525,12	32,34	3957,61	7,81	1,76	6,05

Hesaplama sonucunda 53491,93 kW ısı transferi sağlanacağı bulunmuştur. Ayrıca ısı verim %14,6 olarak hesaplanmıştır. Santral tasarımının yapıldığı ısı verim değeriyle aynıdır. Bu sebeple işletilebilir parametreler olarak karşımıza çıkmaktadır. Santral 18 bara YB türbin giriş basıncında genelde 10,8 bara AB basınç türbin giriş basıncıyla çalışmaktadır. Verilen basınç değerlerindeki doyma sıcaklığının 0,5 °C üzerinde olacak şekilde bütanı kızgın buhar fazında kabul etmek hesaplamaları daha gerçekçi yapacaktır. Ayrıca türbin çıkış sıcaklığı genellikle yoğuşma basıncı sıcaklığının 15 °C üzerinde çalışmaktadır. Bu sebeple yine aynı kabulü yaparak yapılan hesaplamalarda türbin izantropik verimi YB ve AB için sırasıyla %93,35 ve %67,92 olarak bulunmuştur. Şekil 5.27’de veriler ve bulgular karşılaştırılmıştır. Santral tasarım verilerine benzer şekilde YB basınç türbininin ekserji verimi AB türbininin ve işletme verilerinde de görülen AB türbininin tasarlanandan daha düşüğe çalışıyor

olması AB türbin tasarımının ya da optimum parametrelerin gözden geçirilmesi gerekliliğini ortaya koymaktadır. Tablo 5.17’de sırasıyla YB ve AB türbin için birim kütle ekserji yıkımı ile birlikte hesaplanan özellikler verilmiştir.

Tablo 5.17: YB ve AB türbin analiz sonuçları

YB TÜRBİN									
Hal	Akışkan Fazı	Debi (kg/s)	Sıcaklık (°C)	Basınç (bar)	Entalpi (kJ/kg)	Entropi (kJ/kg.K)	Birim Kütle Ekserji (kW/kg)	Birim Kütle Ekserji Yıkımı (kW/kg)	İzantropik Verim (%)
0 _{jeo}	-	-	17	1	71,45	0,2534	-	-	-
0 _{orc}	-	-	17	1	239,9	1,1412	-	-	-
7	GAZ	-	109,15	18	731,7	2,5092	94,87	63,37	93,86
8	GAZ	-	56,95	4	673,46	2,5218	31,5		

AB TÜRBİN									
Hal	Akışkan Fazı	Debi (kg/s)	Sıcaklık (°C)	Basınç (bar)	Entalpi (kJ/kg)	Entropi (kJ/kg.K)	Birim Kütle Ekserji (kW/kg)	Birim Kütle Ekserji Yıkımı (kW/kg)	İzantropik Verim (%)
0 _{jeo}	-	-	17	1	71,45	0,2534	-	-	-
0 _{orc}	-	-	17	1	239,9	1,1412	-	-	-
11	GAZ	-	83,52	10,8	701,4	2,4814	131,52	100,02	67,92
8	GAZ	-	56,95	4	673,46	2,5218	31,5		

Analiz sonuçlarına göre AB türbin ekserji yıkımı önemli miktarda fazladır. Santral işletme koşullarında da aynı durum gözlemlenmektedir. Tasarım parametrelerinde %81 ekserji verimi ile tasarlanan AB türbini tasarım parametrelerinden daha düşük ısı transferi olan çalışma koşullarında önemli ölçüde verim kaybı yaşamaktadır. Santral için geliştirilmesi gereken optimum işletme parametresi AB türbini merkez alınarak yapılabilir. Türbinin giriş basıncının artırılması literatürde bilinen en yaygın verim artırma yöntemlerinden birisidir. Bu sayede farklı bir işletme parametreleri ile AB türbini iyileştirilerek daha fazla güç üretilebilir. Farklı bir çalışma ise Tablo 5.18’de santrale gelen buharın olmaması durumunda nasıl bir işletme parametresi ile verimin iyileştirilebileceği örneklenmiştir. Bu bağlamda YB türbin

giriş basıncı artırılarak jeotermal brinedan daha fazla ısı çekilmesi hedeflenmiştir. Reenjeksiyon sıcaklığının 60,31 °C çıkması da bu bulguyu desteklemektedir.

Tablo 5.18: Santral buhar olmaması durumunda olası optimum işletme parametreleri

	Kuyu 1			Kuyu 2			Kuyu 3			
	Debi	Basıncı	Sıcaklık	Debi	Basıncı	Sıcaklık	Debi	Kuyubası Basıncı	Seperasyon Basıncı	Seperasyon Sıcaklığı
	m ³ /h	bar	°C	m ³ /h	bar	°C	m ³ /h	bar	bar	°C
Hesaplanan Veriler	225,48	10,06	141,61	164,07	7,11	125,44	234,5	6,02	5,44	157,5

	ORÇ Türbin Giriş	ORÇ Türbin Çıkış	Brine Reenjeksiyon	Brine Giriş	Brine Çıkış	Giren Brine	Giren Brine	Dış Ortam	Buhar ve NCG	Brüt Güç	İç Tüketim	Net Güç
	Basıncı	Basıncı	Sıcaklık	Basıncı	Basıncı	Sıcaklık	Debi	Sıcaklık	Debi	Güç	Güç	Güç
	bar	bar	°C	bar	bar	°C	t/h	°C	m ³ /sa	MW	MW	MW
Hesaplanan Veriler	19,36	4	60,31	9,78	3,16	154,58	608,4	0,5	15	8,53	1,86	6,67

Sonuçta ise santralin işletme koşullarına benzer veriler ile santralin verimi artırılmıştır. Bu verimin nasıl artırılacağı detaylı termodinamik analiz sayesinde kurulacak santralin işletme ısı ve kütle diyagramı ile gösterilebilir. Tablo 5.19’da elde edilen iyileştirilmiş işletme koşulları gösterilmiştir.

Tablo 5.19: Santralin işletme şartlarına benzer verimi artırılmış işletme koşulları

	Kuyu 1			Kuyu 2			Kuyu 3			
	Debi	Basıncı	Sıcaklık	Debi	Basıncı	Sıcaklık	Debi	Kuyubası Basıncı	Seperasyon Basıncı	Seperasyon Sıcaklığı
	m ³ /h	bar	°C	m ³ /h	bar	°C	m ³ /h	bar	bar	°C
Hesaplanan Veriler	225,21	9,69	141,77	133,36	7,05	129,84	246,3	6,26	5,78	157,5

	ORÇ Türbin Giriş	ORÇ Türbin Çıkış	Brine Reenjeksiyon	Brine Giriş	Brine Çıkış	Giren Brine	Giren Brine	Dış Ortam	Buhar ve NCG	Brüt Güç	İç Tüketim	Net Güç
	Basıncı	Basıncı	Sıcaklık	Basıncı	Basıncı	Sıcaklık	Debi	Sıcaklık	Debi	Güç	Güç	Güç
	bar	bar	°C	bar	bar	°C	t/h	°C	m ³ /sa	MW	MW	MW
Hesaplanan Veriler	19,17	4,93	72,88	10,61	3,59	147,99	609,26	19,03	4582,3	8,2	1,81	6,39

Yapılan termodinamik analizler ile santralin işletilmesi için ORÇ bütan debi, sıcaklık ve basınçları hesaplanmalıdır. Yukarıdaki yapılan farklı analizler ile hesaplama yönteminden önemli bulgular elde edilmiştir. Özellikle santralin işletme koşullarının modellenmesi ve termodinamik analizler ile ekserji yıkımının fazla olduğu ekipmanlar belirlenmiştir. Bu sayede analiz yönteminden elde edilecek optimum şartlar araştırmacı tarafından seçilerek santralin termodinamik olarak analizi yapılabilir ve optimum işletme şartları belirlenebilir. Bu bağlamda hesaplama yöntemi bütan debisinin ve basıncının artırılarak çürük buhar oluşumunun gerçekleştiği YB ön ısıtıcısındaki sorunun giderilmesi ve ısı transferinin daha dengeli hale getirilmesini önermektedir. Bütanın buharlaştırıcı ekipmanlarındaki basıncın artması sayesinde doyma sıcaklığı da artarak daha iyi bir ısı transferi gerçekleştirilmiştir. Tablo 5.20’de hesaplama yönteminden elde edilen optimum işletme şartları gösterilmiştir. Ayrıca bu optimum parametreler ile tasarım ve işletme şartlarına bağlı olarak yapılan termodinamik analiz sonuçları karşılaştırmalı olarak Şekil 5.12’de gösterilmiştir. Optimizasyon sonuçlarına göre önemli miktarda net güç artışı sağlanarak ekserji ve enerji verimleri iyileştirilmiştir.

Analiz sonuçlarına göre YB ön ısıtıcısındaki ekserji verimi %57,85’ten %89,82 değerine çıkarılmıştır. YB ön ısıtıcısındaki bu artış miktarı yaklaşık %56 olmaktadır. Ekipman ekserji verimi açısından önemli ölçüde iyileştirilmiştir. Ayrıca AB türbininde yapılan iyileştirme sonucunda ekserji verimi %41,31 değerinden %59,22 değerine çıkmıştır. Bu artış miktarı ise yaklaşık olarak %43,35’tir. Optimizasyon sonucunda elde edilen işletme parametreleri santralin genel ekserji ve enerji verimlerini de önemli ölçüde arttırmıştır. Ekserji verimi %25,24’ten %34,62 değerine, enerji verimi ise %6,34’ten %8,62 değerine yükselmiştir.

Tablo 5.20: Santralin optimum çalışma koşulları

SANTRALİN OPTİMUM İŞLETME PARAMETRELERİ							
Hal	Akışkan Fazı	Debi (kg/s)	Sıcaklık (°C)	Basınç (bar)	Entalpi (kJ/kg)	Entropi (kJ/kg.K)	Ekserji (kW)
0 _{hava}	-	-	17	1	290,31	1,66853	-
0 _{jeo}	-	-	17	1	71,45	0,2534	-
0 _{orc}	-	-	17	1	239,9	1,1412	-
J1	SIVI	160,75	149,6	10	630,45	1,8387	15992,9
J2	SIVI	160,75	123	9,5	517,07	1,5595	10714,8
S1	BUHAR	2,69	167,4	6,63	2771,9	6,7517	2192,26
S2	SIVI	2,69	66	6,2	276,8	0,90567	43,3
6	SIVI	115	119,7	22,5	525,9	1,9661	5365,36
7	GAZ	115	120,4	22	742,79	2,5185	11875,6
J3	SIVI	160,75	102,76	9	431,39	1,3376	7291,52
5	SIVI	115	81	23	406,14	1,6455	2290,49
J4	SIVI	160,75	84,68	8,5	355,27	1,1302	4728,7
10	SIVI	40	81	13,5	406,37	1,6518	732,78
11	GAZ	40	92,3	13	712,28	2,4911	3228,26
J5	SIVI	160,75	70,33	8	295,05	0,95862	3051,1
3	SIVI	155	58	23,5	343,69	1,4627	1628,55
4	SIVI	155	81	23,1	406,14	1,6455	3087,19
8	GAZ	155	69	5,4	692,18	2,5388	6313,18
9	GAZ	155	60	5,38	673,89	2,4851	5947,75
2	SIVI	155	52,5	23,8	329,22	1,4206	1114,03
1	SIVI	155	52	5,35	327,33	1,4234	749,2

TASARIM EKİPMAN VE SANTRAL ANALİZ SONUÇLARI					İŞLETME EKİPMAN VE SANTRAL ANALİZ SONUÇLARI					OPTİMUM İŞLETME EKİPMAN VE SANTRAL ANALİZ SONUÇLARI				
SANTRAL / EKİPMAN	Toplam Isı Transferi / İş (kW)	Toplam Ekserji Yıkımı (kW)	Toplam Net Ekserji Verimi (%)	Toplam Net Enerji Verimi (%)	SANTRAL / EKİPMAN	Toplam Isı Transferi / İş (kW)	Toplam Ekserji Yıkımı (kW)	Toplam Net Ekserji Verimi (%)	Toplam Net Enerji Verimi (%)	SANTRAL / EKİPMAN	Toplam Isı Transferi / İş (kW)	Toplam Ekserji Yıkımı (kW)	Toplam Net Ekserji Verimi (%)	Toplam Net Enerji Verimi (%)
YB Buharlaştırıcı	31269	1049,62	88	-	YB Buharlaştırıcı	24259,29	1436,37	80,18	-	YB Buharlaştırıcı	24937,65	916,99	87,65	-
YB Ön Isıtıcı	12041,7	215,34	93,24	-	YB Ön Isıtıcı	14287,46	1544,32	57,85	-	YB Ön Isıtıcı	13773,06	348,42	89,82	-
AB Buharlaştırıcı	11897,6	118,18	95,89	-	AB Buharlaştırıcı	10161	258,15	88,11	-	AB Buharlaştırıcı	12236,29	67,34	97,37	-
YA Ön Isıtıcı	31688,8	1474,35	75,95	-	YA Ön Isıtıcı	10386,05	306,78	83,51	-	YA Ön Isıtıcı	9680,36	218,96	86,95	-
Rekuperatör	1538,1	456,2	17,91	-	Rekuperatör	1937,25	150,74	58,78	-	Rekuperatör	2224,25	150,74	58,78	-
YB Türbin	10254	661,26	93,86	-	YB Türbin	4418,2	649,15	87,19	-	YB Türbin	5820,15	677,36	89,58	-
AB Türbin	2110	1561,82	82,86	-	AB Türbin	384,18	545,84	41,31	-	AB Türbin	804	553,61	59,22	-
ORC Pompa	915,77	62,86	93,14	-	ORC Pompa	688	-	-	-	ORC Pompa	-	-	-	-
Hava Soğutmalı Kondenser	74636	3928,09	29,75	-	Hava Soğutmalı Kondenser	46785,6	3773,37	27,41	-	Hava Soğutmalı Kondenser	53716,8	4332,39	-	-
Santral Brüt Güç Üretimi	12240	-	-	-	Santral Brüt Güç Üretimi	4943	-	-	-	Santral Brüt Güç Üretimi	6624	-	-	-
Santral İç Tüketim	1920	-	-	-	Santral İç Tüketim	1195	-	-	-	Santral İç Tüketim	1399	-	-	-
Santraş Net Güç Üretimi	10320	-	-	-	Santraş Net Güç Üretimi	3748	-	-	-	Santraş Net Güç Üretimi	5225	-	-	-
Genel Santral	86901,09	-	47,53	11,88	Genel Santral	59093,82	-	25,24	6,34	Genel Santral	60627,37	-	34,62	8,62

Şekil 5 12: Tasarım, işletme ve optimum koşullarda santralin karşılaştırmalı analiz sonuçları

Jeotermal akışkanın termofiziksel özelliklerinin aynı olduğu durumda optimum sonuçlar ile santralin işletmesinde önemli ölçüde iyileştirilmeler yapılmıştır. Bu sayede santralin net güç üretimi 3748 kW değerinden 5225 değerine çıkmıştır. Artış değeri yaklaşık olarak %39,41'dir. Elektrik enerjisi üretiminde net güç değerindeki artış elektrik üretim maliyetlerini de aynı koşullarda altında düşürülmesi anlamına gelmektedir. Bir başka ifade ile işletme giderlerinde bir değişiklik yapılmadan elde edilen gelir arttırılabilir. Analiz sonuçlarından elde edilen bulgulara göre işletme parametreleri optimize edilerek santral işletmesi önemli ölçüde verimli hale getirilebilir. Optimum işletme parametrelerinin santralde uygulanabilir olması başka bir araştırma konusudur. Santral üreticisi olan firmanın SCADA sistemindeki otomatik kontrol yazılımında yapacağı değişiklikler ile optimum işletme şartları uygulanabilir. ORÇ içerisindeki pompa frekansı ve vana açıklıklarının kontrolü ile optimum koşullar uygulanabilir. Bu uygulama dikkatli ve dengeli bir şekilde yapılmalıdır. Aynı zamanda gün içerisinde hava sıcaklığındaki değişiklikler ya da jeotermal akışkanın davranışında oluşabilecek değişiklikler göz önüne alınarak farklı senaryolar üretilebilir. Yukarıda geliştirilen bir senaryoda buhar debisinin olmaması ile santralin optimum şekilde işletilmesi için üç kritik parametrenin bütan basıncı, debisi ve reenjeksiyon sıcaklığında değişiklik yapılması hesaplama yöntemi tarafından önerilmiştir. Buna benzer binlerce senaryo oluşturularak santralde gerçekleşebilecek farklı çalışma koşulları modellenilebilir. Bu sayede otomatik yazılımda yapılacak değişiklikler ile santralde gerçekleşebilecek olası senaryolar için işletme kontrol algoritmaları oluşturulabilir.

Geliştirilen hesaplama yöntemi, tecrübe ile uzun yıllarda öğrenilebilecek senaryoları ortaya çıkararak santralde farklı bir otomasyon yazılımına zemin hazırlayabilir. Derin yapay sinir ağlarını uygunluk fonksiyonu olarak kullanan genetik algoritma ile yapılan optimizasyon çalışmaları sonucunda santralin modellenmesi, optimizasyonu ve farklı çalışma koşullarının simülasyonu oluşturularak bulguları sunulmuştur. Ayrıca santral işletme firmasına elde edilen bulgular raporlanarak sahada uygulanmasını ve sonuçların analiz edilmesi önerilmiştir.

6. SONUÇ VE ÖNERİLER

Geliştirilen modelin literatürde yenilikçi ve özgün bir yaklaşım ile optimizasyon problemleri için kullanılabilir bir yöntem olması amaçlanmaktadır. Santral verileri ile eğitilen derin yapay sinir ağından elde edilen uygunluk fonksiyonu sayesinde hesaplama modeli farklı santrallerin verileri ile ayrıca eğitilerek test edilebilir. Bu sayede aynı modeli farklı jeotermal saha ve santraller için kullanılabilir. Yöntemin içeriğini değiştirmeden sadece verilerin adet ve çeşidine göre veri tanımlama kodlaması değiştirilerek tüm santraller ile aynı amaç için kullanılabilir.

Bu tez kapsamında İzmir bölgesindeki jeotermal enerji santralinden işletme parametreleri alınarak analizler yapılmıştır. Öncelikle santral tasarım parametrelerinin termodinamik analizleri yapılarak santralin verimleri ve tasarıma özgü parametreleri belirlenmiştir. İşletme ve optimum parametrelerinin kıyaslanması için önemli bir kaynak oluşturulmuştur.

İşletme parametreleri için SCADA ekran görüntülerinden ulaşılamayan YB buharlaştırıcısı bütan giriş sıcaklığı ve basıncı, reküperatör pompa tarafı giriş ve çıkışlarının özellikleri sahadaki manuel ölçüm göstergelerinden okunarak ısı ve kütle dengesi kurulmuştur. Sonrasında işletme parametrelerinin termodinamik analizleri yapılarak işletme şartları ve ekipmanların verimleri hesaplanmıştır. Ayrıca karşılaştırmalı analizlerle işletmede olası problemlere yol açan ve işletme parametrelerinin optimizasyonunu gerektiren tespitler yapılmıştır. Bu optimizasyon problemlerinin parametrik hesaplamalar gerektirdiği ve bu hesaplamaların sürekli yapılmasının zorluklarından bahsedilmiştir. Sonrasında derin yapay sinir ağını uygunluk fonksiyonu olarak kullanan genetik algoritma hesaplama yönteminin çalışması ve tutarlılığı açıklanmaya çalışılmıştır.

Bu bağlamda santralin işletme koşullarına benzer veriler üretilerek grafik ve termodinamik analizler ile karşılaştırmalı olarak gösterilmiştir. Hesaplama yöntemi santralin işletme koşullarını çok az bir hatayla modelleyebilmektedir. Aynı zamanda bu modelden elde edilen farklı sonuçlar ile santralin çalışma koşulları ve parametreleri için optimum işletme senaryoları oluşturulmuştur. Tüm bulgular termodinamik analizlerle incelenerek sonuçlar tablo ve grafikler anlatılmıştır. Hesaplama yönteminin

jeotermal enerji santrallerinde kullanılabilceđi ve hesaplaması çok uzun zaman alacak binlerce iřletme senaryosunu test edebileceđi kanıtlanmıřtır.

Geliřtirilen yöntem genetik algoritmanın en önemli fonksiyonu olan uygunluk fonksiyonu literatürde kullanılan doğrusal ya da karesel fonksiyonlar yerine gerçek santral verileri kullanılarak derin yapay sinir ađlarından elde edilen fonksiyon kullanılmıřtır. Bu sayede optimizasyon çalıřmasında önemli bir araç olan ve optimum verilere ulařmak için genetik algoritmadaki evrimsel süreci doğal seğılime benzer bir şekilde yönlendirme iřlevi olan uygunluk fonksiyonu probleme uygun olarak seğılmıřtır. Sabit fonksiyonlar yerine dinamik olarak santral verileri arasındaki iliřkileri öđrenerek oluřturduđu fonksiyon ile parametreleri test ederek optimum sonuçlar üretilmesine olanak tanımıřtır. Geliřtirilen yöntemin öđrenme yetisini mae ve mse deđerleri ile görebilmekteyiz ayrıca santral verilerini çok az bir hata payı ile modelleyebilmektedir. Elde edilen mae ve mse deđerleri sırasıyla 0,3426 ve 0,2115 olarak bulunmuřtur. Bu deđerler ulařabildiđi en iyi deđerler olup durdurulan öđrenme sonrası elde edilen DYSA genetik algoritmada uygunluk fonksiyonu olarak kullanılmıřtır. Sonrasında genetik algoritmadan elde edilen veriler hesaplama yönteminde optimum iřletme řartlarının bulunması için analiz edilmiřtir.

Santral iřletme řartları aynı jeotermal kořullar altında optimize edilmiřtir. Hesaplama yöntemi bütan basıncının arttırılması ve reenjeksiyon sıcaklıđının düşürülmesi ile santraldeki verimin arttırılabileceđini göstermiřtir. Ayrıca termodinamik analizlerle bulunan bütan debisi ile kurulan termodinamik analizler ile santral ekipmanlarının ekserji verimlerinin önemli ölçüde düşük olduđu görölmüřtür. Hesaplama yönteminden elde edilen verilerde de özellikle YB ön ısıtıcının olduđu iřletme parametrelerinin iyileřtirilerek net güç üretimi ve verimde artış sađlanmıřtır. Bu sonuçlara göre YB ön ısıtıcısındaki çürük buhar önlenerek ekipmanın ekserji verimi %56 oranında arttırılmıřtır. Ayrıca AB türbininde yapılan iyileřtirmeler ile %43,35 ekserji verimi arttırılarak santralin ekserji ve enerji verimi sırasıyla %37,16 ve %35,96 oranlarında arttırılarak önemli bir gelişme sađlanmıřtır.

Santralin brüt güç üretimi 4.943 kW deđerinden 6.624 deđerine yükseltilmiřtir. Net güç üretimi ise teorik olarak 5.225 kW deđerinden 1.477 kW deđerine çıkmıřtır. Net güçteki artış hesaplama sonucunda elde edilen optimum iřletme řartları ile elde edilmiřtir. Ayrıca farklı çalıřma kořulları ile yapılan çalıřmalarda buharın santralde

olmaması sonucunda jeotermal akışkanın özelliklerinin aynı kalması ile işletmeye göre YB türbin giriş basıncı 18 bara değerinden 19,36 bara değerine çıkarılarak ve özellikle reenjeksiyon sıcaklığı 72,6 C değerinden 60,31 değerine düşürülmesi ile işletilebilecek bir senaryo oluşturmuştur. Farklı senaryolar oluşturularak uzun süreler gerektiren ve tecrübe ile öğrenilen santral işletme bilgisi oluşturularak santrallerin işletilmesi için otomatik kontrol senaryolarının oluşturulabileceği açıklanmıştır.

Araştırmacı tarafından bulunan sonuçlar değerlendirilerek santralin işletmedeki parametreleri, farklı senaryolardaki işletme parametreleri ve optimum işletme şartlarındaki parametreleri belirlenmiştir. Ancak yöntemin hala geliştirilebilir ve daha da iyi hale getirilebilir olduğu unutulmamalıdır.

Geliştirilen yöntem farklı hesaplama yöntemleri ve veri programları ile birlikte çalışacak şekilde adapte edilerek jeotermal enerji santrallerinin dinamik olarak izlenebilmesine ve işletmelerde sorunları ortaya çıkarabilmesi sağlanabilir. Aynı zamanda farklı hesaplama modelleri kullanılarak bu tez kapsamında geliştirilen model ile karşılaştırmalı analizler yapılabilir. Daha sonra yapılacak araştırma konuları açısından bu sonuçlar önemlidir. Bu sayede literatüre yenilikçi ve özgün bir fikir ile jeotermal enerji santrallerinin optimizasyonu için yeni bir yöntem kazandırılmıştır. Hesaplama yöntemi uzun, yorucu ve önemli ölçüde tecrübe gerektiren analizleri gerçekleştirerek optimizasyon çalışmaları yapılmıştır. Sonuçlar detaylı ve karşılaştırmalı olarak sunulmuştur. Elde edilen bulgular sayesinde anlaşılmaktadır ki geliştirilen hesaplama yöntemi ile önemli bir otomatik kontrol, santral işletme yönetimi ve optimizasyon yöntemi geliştirilebilir.

7. KAYNAKLAR

Ayan S., “Sezgisel Optimizasyon Algoritması Kullanılarak Hibrit (Fotovoltaik-Rüzgar) Enerji Sistemi İçin Boyut Optimizasyonu”, Yüksek Lisans, *Kırklareli Üniversitesi*, Kırklareli (2019).

Bandean, D. C., Smolen, S. and Cieslinski, J. T., “Working fluid selection for Organic Rankine Cycle applied to heat recovery systems”, *World Renewable Energy Kongresi*, 772-779, (2011).

Behzadi, A., Gholamian, E., Ahmadi, P., Habibollahzade, A., Ashjaee, M., “Energy, exergy and exergoeconomic (3E) analyses and multi-objective optimization of a solar and geothermal based integrated energy system”, *Applied Thermal Engineering*, 143, 1011-1022, (2018).

Bishop, C., M., *Pattern recognition and machine learning*, Singapore, SpringerScience+BusinessMedia, (2006).

Chauhan, A. ve Saini, R. P., “A review on Integrated Renewable Energy System based power generation for stand-alone applications: Configurations, storage options, sizing methodologies and control”, *Renewable and Sustainable Energy Reviews*, 38, 99-120, (2014).

Clarke, J., McLay, L., McLeskey, J. T., “Comparison of genetic algorithm to particle swarm for constrained simulation-based optimization of a geothermal power plant”, *Advanced Engineering Informatics*, 28, 1, 81-90, (2014).

Coşkun, A., “Türkiye’deki Jeotermal Kaynaklar İçin Güç Santrallerinin Termodinamik Analizi ve Optimizasyonu”, Doktora, *Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü*, Isparta, (2011).

Çengel, Y. A. and Boles, M. A., “Mühendislik Yaklaşımıyla Termodinamik”, Literatür Yayıncılık, İstanbul, (2002).

DiPippo, R., *Geothermal Power Plants: Principles, Applications, Case Studies and Environmental Impact*, Third Edition, Butterworth-Heinemann, (2012).

Erdođmus, P. ve Toz, M., “Heuristic optimization algorithms in robotics. Serial and Parallel Robot Manipulators-Kinematics, Dynamics”, Control and Optimization, InTechOpen, 311–338, (2012).

Ertürk, F., Akkoyunlu, A. ve Varınca, K. B., Enerji Üretimi ve Çevresel etkileri, Tasam Yayınları, (2016).

Fannou, J.L.C., Rousseau, C., Lamarche, L., Kajl, S., “Modeling of a direct expansion geothermal heat pump using artificial neural networks”, Energy and Buildings, 81, 381-390, (2014).

Goldberg, D.E.,” Genetic Algorithms in Search, Optimization and Machine Learning”, Addison Wesley, (1989).

He, Z., Xi, H., Ding, T., Wang, J., Li, Z., “Energy efficiency optimization of an integrated heat pipe cooling system in data center based on genetic algorithm”, Applied Thermal Engineering, 182, 115800, (2021).

Hettiarachchi, H.D.M., Golubovic, M., Worek, W. M. and Ikegami, Y., “Optimum design criteria for an Organic Rankine cycle using lowtemperature geothermal heat sources” , *Energy*, 32, 1698-1706, (2007).

Huster, W. R., Schweidtmann, A. M., Mitsos, A., “Globally optimal working fluid mixture composition for geothermal power cycles”, *Energy*, 212, 118731, (2020).

Imran, M., Usman, M., Park, B., S., Kim, H., J., Lee, D., H., “Multi-objective optimization of evaporator of organic Rankine cycle (ORC) for low temperature geothermal heat source”, *Applied Thermal Engineering*, 80, 1-9, (2015).

Kanođlu, M. “Jeotermal Elektrik Üretim Sistemleri Ve Kojenerasyon”, *7.Ulusal Tesisat Mühendisliđi Kongresi*, 289-299, (2005).

Karagöl, E.T. ve Kavaz, İ., “Dünyada Ve Türkiyede Yenilenebilir Enerji”, *Siyaset, Analiz*, 197, 1-32, (2017).

Keçebaş, A., Yabanova, İ., “Thermal monitoring and optimization of geothermal district heating systems using artificial neural network: A case study”, *Energy and Buildings*, 50, 339-346, (2012).

Khalil, A.J., Barhoom, A.M., Abu-Nasser, B.S., Musleh, M.M., Abu-Naser, S.S., “Energy Efficiency Predicting using Artificial Neural Network”, *International Journal of Academic Pedagogical Research*, 3, 9, 1-1, (2019).

Khosravi, A., Syri, S., Zhao, X., Assad, M. E.H., “An artificial intelligence approach for thermodynamic modeling of geothermal based-organic Rankine cycle equipped with solar system”, *Geothermics*, 80, 138-154, (2019).

Kızrak, M., A., “Akut lenfosit lösemisinin çekirdek sağrı regresyonu yöntemiyle tanınması”, M.Sc. Thesis, Haliç University, (2011).

Kızrak, M., A., “ Video Görüntülerinde Kalabalık Analizi”, Ph.D Thesis, Yıldız Teknik Üniversitesi, İstanbul, 2021.

Ling, W., Y. Liu, R. Young, T. T. Cladouhos, B. Jafarpour, Efficient data-driven models for prediction and optimization of geothermal power plant operations, *Geothermics* 119 (2024) 102924.

Lund, J. W., Boyd, T. L., “Direct utilization of geothermal energy 2015 worldwide review”, *Geothermics*, 60, 66-93, (2015).

Mokarram, N. H., Mosaffa, A. H., “A comparative study and optimization of enhanced integrated geothermal flash and Kalina cycles: A thermoeconomic”, *Energy*, 162, 111-125, (2018).

Müller, A. C., Guido, S., *Introduction to Machine Learning with Python*, First Edition, O'Reilly Media, (2012).

Nasruddin, N., Dwi Saputra, I., Mentari, T., Bardow, A., Marcelina, O., Berlin, S., “Exergy, exergoeconomic, and exergoenvironmental optimization of the geothermal binary cycle power plant at Ampallas, West Sulawesi, Indonesia”, *Energy*, 19, 100625, (2020).

Ongun, M., F., Gdkbay, U., Aksoy, S., “Recognition of occupational therapy exercises and detection of compensation mistakes for Cerebral Palsy”, *Journal of Visual Communication and Image Representation*, 73, 102970, (2020).

zer, ., “Jeotermal Elektrik Santrallerinde Optimum Performans Ve Verim İin Sistem Tasarımı Ve İletme Őartlarının İncelenmesi”, Yksek Lisans Tezi, Pamukkale niversitesi Fen Bilimleri Enstits, Makine Mhendislięi Anabilimdalı, Denizli, (2018).

ztrk, H.K., Canyurt, O.E., Hepbaslı, A., Utl, Z., “Residential-commercial energy input estimation based on genetic algorithm (GA) approaches: An application of Turkey”, *Energy and Buildings*, 36, 2, 175-183, (2004).

zkaraca, O., KeebaŖ, A., “Performance analysis and optimization for maximum exergy efficiency of a geothermal power plant using gravitational search algorithm”, *Energy Conversion and Management*, 185, 155-168, (2019).

zkaraca, O., KeebaŖ, A., Demircan, C., “Comparative thermodynamic evaluation of a geothermal power plant by using the advanced exergy and artificial bee colony methods”, *Energy*, 156, 169-180, (2018).

B. Rudyanto, M. S. Birri, Widjonarko, C. Avian, D. M. Kamal, M. Hijriawan,” A Genetic Algorithm approach for optimization of geothermal power plant production: Case studies of direct steam cycle in Kamojang”, *South African Journal of Chemical Engineering*, 45, 164, 1-9, (2023).

Sun, S., “CSC411 Tutorial #5 Neural Networks”, (22 Kasım 2021), https://www.cs.toronto.edu/~jluca/teaching/csc411/lectures/tut5_handout.pdf, (2017).

Ŗahin, C., “DŖk Sıcaklıklı Jeotermal Sahalarda Organik Rankine evrimi (ORC) İle Elektrik Enerjisi retiminde Afyon Jeotermal Elektrik retim A.Ŗ. Modellemesi”, Yksek Lisans Tezi, *Dmlpınar niversitesi Fen Bilimleri Enstits*, Elektrik-Elektronik Mhendislięi Anabilim Dalı, Ktahya, 28, (2016).

Weck, O., “A Basic Introduction to Genetic Algorithms”, (23 Kasım 2021), https://ocw.mit.edu/courses/institute-for-data-systems-and-society/ids-338j-multidisciplinary-system-design-optimization-spring-2010/lecture-notes/MITESD_77S10_lec11.pdf, (2010).

Yılmaz, C. Ve Koyuncu, İ. “Thermoeconomic modeling and artificial neural network optimization of Afyon geothermal power plant ”, Renewable Energy, 163, 1166-1181, (2021)

Yu, Z., Su, R., Feng, C., “ Thermodynamic analysis and multi-objective optimization of a novel power generation system driven by geothermal energy”, Energy, 199, 117381, (2020).

URL 1 <http://www.jeotermalvakfi.org.tr/jeoenerji.html>

URL 2 <https://www.irena.org/>

URL 3 <https://www.knowledgehut.com/blog/programming/best-python-ides-code-editors-guide>

URL 4 <http://cs231n.stanford.edu/>

URL 5 <https://learn.microsoft.com/tr-tr/azure/machine-learning/how-to-tune-hyperparameters?view=azureml-api-2>

URL 6 <https://iamtrask.github.io/2015/07/12/basic-python-network/>

