

**ANKARA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

YÜKSEK LİSANS TEZİ

**ERGİTME FIRINLARINDA OPTİMUM SİSTEM PARAMETRELERİNİN
PEKİŞTİRMELİ ÖĞRENME METODLARI İLE SAPTANMASI**

Mehmet Ulaş ÇAKIR

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

**ANKARA
2022**

Her hakkı saklıdır

ÖZET

Yüksek Lisans Tezi

ERGİTME FIRINLARINDA OPTİMUM SİSTEM PARAMETRELERİNİN PEKİŞTİRMELİ ÖĞRENME METODLARI İLE SAPTANMASI

Mehmet Ulaş ÇAKIR

Ankara Üniversitesi
Fen Bilimleri Enstitüsü
Elektrik-Elektronik Mühendisliği Anabilim Dalı

Danışman: Prof. Dr. Murat EFE

Dijitalleşen dünyada, elde edilen verinin boyutu ve çeşitliliği her geçen gün artmaktadır. Verinin boyutunun sürekli olarak arttığı her alanda, günlük problemlere yönelik etkili ve güvenli çözümler tasarlamak ve uygulamak için gelişen teknolojinin imkanlarından yararlanılmaya çalışılmaktadır. Endüstriyel amaçla kullanılan ısıtma fırınlarında, bir taraftan dijitalleşme süreçleri devam ederken, diğer tarafta verimliliği arttırabilmek üzere geliştirilen yenilikçi tekniklerin uygulanmaya çalışıldığı görülmektedir. Geliştirilmeye çalışılan çözümler, genellikle birden fazla özneliğe ve özelliğe sahip olan bileşenlerden oluşmakta; uzun, karmaşık ve zor bir çok parametrelili optimizasyon süreci olarak karşımıza çıkmaktadır. Optimizasyon süreçleri uzun ve karmaşık olduğu kadar ve parametre çeşitliliği nedeni ile zor bir süreçtir. Birden çok parametreye sahip optimizasyon ihtiyaçları doğrultusunda otomatik tanılama/parametre optimizasyonu için yeni yöntemlerin araştırılması büyük değer taşımaktadır. Veri analizi ile endüstriyel optimizasyon tekniklerinin bir arada kullanımı gittikçe yaygınlaşmaktadır. Endüstriyel ısıtma fırınlarında verimliliği arttırabilmek için, kullanılan enerji miktarını azaltmak gerekmektedir. Bu problemin çözülebilmesine yönelik olarak çalışma zamanına etki edebilecek parametrelerin optimum çalışma düzeylerinin elde edilmesi gerekmektedir. Enerji tüketiminin azaltılması için, kullanılan enerji miktarını girdi olarak alan, diğer parametrelerin optimum değerlere sahip parametre setlerini oluşturmaya çalışan, parametre ilişkilerinin pekiştirmeli öğrenme yaklaşımı ile modellenmesine yönelik tez çalışması gerçekleştirilmiştir. Değişkenlerin zamana bağımlı birer öznelilik olması nedeni ile pekiştirmeli öğrenme çevresinin elde edilmesinde, makine öğrenimi tekniklerinden Uzun Kısa Süreli Bellek modelleri kullanılarak, optimum parametre setine adım adım yaklaşılarak sonuç elde edilmeye çalışılmıştır. Deneyde kullanılan yenilikçi yaklaşımların sonuçları bazı varsayımlar ve kısıtlar doğrultusunda değerlendirildiğinde, %15 civarında enerji verimliliği sağlanabileceği gösterilmiştir.

Haziran 2022, 91 sayfa

Anahtar Kelimeler: Pekiştirmeli Öğrenme, Optimizasyon, Veri Analitiği, Enerji Verimliliği

ABSTRACT

Master Thesis

DETERMINATION OF OPTIMUM SYSTEM PARAMETERS WITH REINFORCEMENT LEARNING METHODS IN MELTING FURNACES

Mehmet Ulaş ÇAKIR

Ankara University
Graduate School of Natural ve Applied Sciences
Department of Electrical and Electronics Engineering

Supervisor: Prof. Dr. Murat EFE

In a digitized world, the size and variety of data obtained is increasing. Every field where the size of data is constantly increasing, it is tried to utilize the opportunities of developing technology to design and implement effective solutions. Melting furnaces used for industrial purposes, it is seen that while digitalization processes continue, innovative techniques developed to increase efficiency are tried to be applied. The solutions usually consist of more than one attribute and feature; long-term, complex and difficult multi-parameter optimization process. Optimization processes are long-term, complex and difficult due to the variety of parameters. Investigating new methods for automatic diagnostics/parameter optimization for multi-parameter optimization needs is a great value. The combination of data analysis and industrial optimization techniques is becoming increasingly common. Reducing the amount of energy used to increase efficiency in industrial melting furnaces is necessary. In order to solve this problem, it is necessary to obtain the optimum operating levels of the parameters that can affect the working time. This thesis study was carried out for modeling parameter relations with reinforcement learning approach, which takes the amount of energy used as input, tries to create parameter sets with optimum values. Since the variables are time-dependent attributes, Long Short Term Memory models and reinforcement learning techniques were used to obtain results by approaching the optimum parameter set. The results of the innovative approaches used in the experiment are evaluated in line with some assumptions and constraints, it has been shown that around 15% energy efficiency can be achieved.

June 2022, 91 pages

Key Words: Reinforcement Learning, Optimization, Data Analytics, Energy Efficiency

TEŞEKKÜR

Yüksek lisans eğitimime başlamam konusunda bana destek, cesaret ve ilham veren sevgili eşim Zeynep ÇAKIR'a, ders ve deney çalışmalarım sırasında değerli zamanından ödünç aldığım biricik kızım Ece Özge ÇAKIR'a, bilgisini ve tecrübelerini esirgemeyen, araştırmamdaki her aşamada yardımcı olan, daima anlayışlı yaklaşımıyla yol gösteren tez danışmanım Prof.Dr.Murat EFE'ye, yüksek lisans süresince akademik çalışmalarımı işimle birlikte yürütebilmem konusunda zaman esnekliği sağlayan Savunma Teknolojileri Mühendislik ve Ticaret A.Ş.'ye sonsuz teşekkürlerimi sunarım.

Mehmet Ulaş ÇAKIR
Ankara, Haziran 2022

İÇİNDEKİLER

TEZ ONAY SAYFASI

ETİK.....	i
ÖZET.....	ii
ABSTRACT	iii
TEŞEKKÜR	iv
KISALTMALAR DİZİNİ	vii
ŞEKİLLER DİZİNİ	viii
ÇİZELGELER DİZİNİ	x
1. GİRİŞ.....	1
2. KURAMSAL TEMELLER.....	4
2.1 Ergitme Fırınları	4
2.2 Veri Analitiği	7
2.3 Makine Öğrenmesi.....	8
2.3.1 Regresyon.....	11
2.3.2 Tekrarlayan sinir ağları	12
2.3.3 Uzun kısa süreli bellek ağları.....	14
2.3.4 Pekiştirmeli öğrenme	18
2.4 Yapay Zeka	24
2.4.1 Açıklanabilir yapay zekâ	26
2.4.2 Yapay zekâ önyargısı	27
2.4.2.1 Önyargılı veri seti	27
2.4.2.2 Yanlı algoritma geliştirme	28
2.4.3 Yapay zekâ etiği	28
2.5 Optimizasyon	30
3. MATERYAL ve YÖNTEM.....	32
3.1 Önerilen Sistem Mimarisi.....	32
3.2 Ergitme Fırını Veri Seti.....	32
3.3 Veri Seti Üzerinde Gerçekleştirilen Ön Çalışmalar.....	33
3.3.1 Veri analizi.....	34
3.3.2 UKSB modelleri.....	54
3.4 Pekiştirmeli Öğrenme Bileşenleri	59
3.4.1 Çevre bileşeni.....	59
3.4.1.1 Çevre bileşeni değişkenleri	60
3.4.2 Ajan	61
3.4.3 Optimizasyon algoritmaları	62
4. ARAŞTIRMA BULGULARI	64
4.1 Pekiştirmeli Öğrenme Modelinin Farklı Parametreler ile Eğitimi	64
4.1.1 50 birimlik doğalgaz değişimi	65

4.1.2 25 birimlik doğalgaz değişimi	67
4.1.3 10 birimlik doğalgaz değişimi	70
4.1.4 5 birimlik doğalgaz değişimi	73
4.1.5 0-50 aralığında değişken birimlik doğalgaz değişimi.....	76
4.1.6 Doğalgaz değerleri değişim sonuçları.....	79
5. SONUÇ	81
KAYNAKLAR	85
EKLER.....	89
EK 1 PYTHON YAZILIM DİLİ KÜTÜPHANE VE ÇERÇEVE VERSİYONLARI LİSTESİ	89
EK 2 KAYNAK KOD	89
EK 3 VERİ SETİNDEKİ VERİ ALANLARININ LİSTESİ	89
EK 4 VERİ İÇERMEYEN VERİ ALANLARININ LİSTESİ.....	89
EK 5 KATEGORİK VERİ İÇEREN VERİ ALANLARININ LİSTESİ	89
EK 6 VERİ SETİ İÇERİSİNDEKİ VERİ ALANLARININ TEMEL İSTATİSTİK DEĞERLERİ.....	89
EK 7 DENEY SONUÇLARI.....	89
EK 8 UKSB EĞİTİMİ SONUÇLARI	89
EK 9 DEĞİŞKENLERİN DAĞILIM GRAFİKLERİ	89
EK 10 HAM VE İNDİRGENMİŞ VERİ TEMEL İSTATİSTİKLERİ	89
EK 11 KORELASYON ÇALIŞMALARI.....	89
EK 12 KORELASYON TABLOSU	89
EK 13 EK ÇALIŞMALAR.....	89
ÖZGEÇMİŞ.....	90

KISALTMALAR DİZİNİ

AYZ	Açıklanabilir Yapay Zeka
DSA	Derin Sinir Ağları
DÖ	Derin Öğrenme
MKS	Markov Karar Süreci
OMH	Ortalama Mutlak Hata
PÖ	Pekiştirmeli Öğrenme
TSA	Tekrarlayan Sinir Ağları
UKSB	Uzun Kısa Süreli Bellek
YZ	Yapay Zeka
ReLU	Rectified Linear Activation

ŞEKİLLER DİZİNİ

Şekil 2.1 Doğalgaz ile çalışan modern ergitme fırını genel görünüm.....	5
Şekil 2.2 Doğalgaz ile çalışan ergitme fırını hava sirkülasyonu tasarımı	6
Şekil 2.3 Doğalgaz ile çalışan ergitme fırını işleyişindeki kaçaklar	7
Şekil 2.4 Denetimli öğrenme.....	9
Şekil 2.5 Denetimsiz öğrenme	10
Şekil 2.6 Yarı denetimli öğrenme	11
Şekil 2.7 Tekrarlayan yapay sinir ağı.....	12
Şekil 2.8 TSA zinciri.....	13
Şekil 2.9 UKSB zinciri.....	15
Şekil 2.10 UKSB hücresi	16
Şekil 2.11 Basit PÖ ajan diyagramı	18
Şekil 2.12 Q-Öğrenme algoritmasının temel adımları	20
Şekil 2.13 Derin PÖ ajan diyagramı	21
Şekil 2.14 Değer fonksiyonunun sonraki değer ile etkileşimi	23
Şekil 2.15 Karmaşıklığa göre optimizasyon problemi sınıfları	31
Şekil 3.1 Kutu grafiği	35
Şekil 3.2 Keman grafiği	36
Şekil 3.3 f_b ic değişkeninin kutu, keman ve veri dağılımı grafiği	37
Şekil 3.4 Normal dağılıma sahip Q-Q grafiği	38
Şekil 3.5 Q-Q grafiğinin çarpık durum örnekleri.....	39
Şekil 3.6 f_b ic değişkeninin normal dağılıma göre Q-Q grafiği.....	39
Şekil 3.7 f_b ic değişkeninin $f_{ak_dogalgaz_2}$ değişkenine göre aldığı değerler.....	40
Şekil 3.8 f_b ic değişkeninin $f_{ak_dogalgaz_2}$ değişkenine ile birlikte zamana göre değişimi	41
Şekil 3.9 Doğalgaz ($f_{ak_dogalgaz_2}$) değişkenin dağılım grafiği.....	42
Şekil 3.10 Doğalgaz ($f_{ak_dogalgaz_2}$) değişkenin Q-Q grafiği,.....	42
Şekil 3.11 teorik_hava_ihtiyacı değişkeninin dağılım grafiği	43
Şekil 3.12 ust_isil_deger değişkeninin dağılım grafiği.....	44
Şekil 3.13 alt_isil_deger değişkeninin dağılım grafiği	44
Şekil 3.14 $f_g_boost_zon1$ değişkeninin dağılım grafiği	45

Şekil 3.15 f_g_boost_zon2 değişkeninin dağılım grafiği	45
Şekil 3.16 f_y_baca_damperi_cetvel değişkeninin dağılım grafiği	46
Şekil 3.17 f_ag_bunker_sol değişkeninin dağılım grafiği	46
Şekil 3.18 Veri alanları korelasyon ısı haritası	48
Şekil 3.19 f_y_yakma_havasi_2_kontrolu - f_y_yakma_havasi_1_kontrolu_1 fic0201.pida.op değişkenlerinin zamana göre birlikte değişimleri	49
Şekil 3.20 f_s_rejenerator_dolgu_alti_sag - f_s_rejenerator_dolgu_alti_sol değişkenlerinin zamana göre birlikte değişimleri	50
Şekil 3.21 teorik_hava_ihtiyacı'nın diğer değişkenler ile korelasyon analizi grafiği	53
Şekil 3.22 UKSB pencere sırası ilerlemesi	55
Şekil 3.23 teorik_hava_ihtiyaci UKSB Eğitim ve Doğrulama Hata Sonuçları Grafiği ..	58
Şekil 3.24 f_ag_bunker_sol UKSB Eğitim Hata Sonuçları Grafiği	59
Şekil 3.25 MNIST veriseti üzerinde optimizasyon grafikleri	62
Şekil 4.1 Doğalgaz ve ödül değerleri grafiği (50 birim/adım–100 Tur)	65
Şekil 4.2 Doğalgaz ve ödül değerleri grafiği (50 birim/adım–250 Tur)	66
Şekil 4.3 Doğalgaz ve ödül değerleri grafiği (50 birim/adım–500 Tur)	67
Şekil 4.4 Doğalgaz ve ödül değerleri grafiği (25 birim/adım–100 Tur)	68
Şekil 4.5 Doğalgaz ve ödül değerleri grafiği (25 birim/adım–250 Tur)	69
Şekil 4.6 Doğalgaz ve ödül değerleri grafiği (25 birim/adım–500 Tur)	70
Şekil 4.7 Doğalgaz ve ödül değerleri grafiği (10 birim/adım–100 Tur)	71
Şekil 4.8 Doğalgaz ve ödül değerleri grafiği (10 birim/adım–250 Tur)	72
Şekil 4.9 Doğalgaz ve ödül değerleri grafiği (10 birim/adım–500 Tur)	73
Şekil 4.10 Doğalgaz ve ödül değerleri grafiği (5 birim/adım–100 Tur)	74
Şekil 4.11 Doğalgaz ve ödül değerleri grafiği (5 birim/adım–250 Tur)	75
Şekil 4.12 Doğalgaz ve ödül değerleri grafiği (5 birim/adım–500 Tur)	76
Şekil 4.13 Doğalgaz ve ödül değerleri grafiği (0-50 birim/adım–100 Tur)	77
Şekil 4.14 Doğalgaz ve ödül değerleri grafiği (0-50 birim/adım–250 Tur)	78
Şekil 4.15 Doğalgaz ve ödül değerleri grafiği (0-50 birim/adım–500 Tur)	79

ÇİZELGELER DİZİNİ

Çizelge 2.1 YZ etik konuları sınıflandırması	29
Çizelge 3.1 Orjinal veri alanları	33
Çizelge 3.2 İndirgenmiş veri alanları	34
Çizelge 3.3 En yüksek 10 pozitif korelasyon	51
Çizelge 3.4 En düşük 10 negatif korelasyon	52
Çizelge 4.1 Gözlem sonuçlarının doğalgaz miktarı özelinde özeti	80
Çizelge 5.1 Gözlem sonuçlarının özeti	82



1. GİRİŞ

Günümüz dünyasının en önemli ve ortak mücadele edilmesi gereken konularından biri olan iklim değişikliği, etkisini gün geçtikçe artırmaktadır. Ölçekten bağımsız olarak tüm şirketlere, önemli sorumluluklar düşmektedir. Bu kapsamda enerji tüketimi yüksek olan firmalar, iklim değişikliğinde çözüm ortağı olabilmek amacıyla, tüm sektörlerle yönelik yenilikçi, çevreci ve müşteri ihtiyaçlarını karşılayan yeni ürünler geliştirerek enerji tüketimini en aza indirmeyi hedeflemektedir.

Nüfus artışına bağlı artan talep ve endüstriyel faaliyetlerin otomasyonundaki gelişmelerden dolayı, son 50 yıl içerisinde, endüstriyel enerji tüketimi ikiye katlanmıştır (Mouzon vd. 2007). Günümüzde, dünya üzerindeki toplam enerji üretiminin yaklaşık %70'i endüstriyel faaliyetler esnasında tüketilmektedir (Ross 1992). Amerika Birleşik Devletleri'nde, yıllık toplam enerji tüketiminin %34'ü fabrikalar tarafından kullanılmaktadır ve üreticilerin yıllık masrafı 100 milyar doların üzerindedir. Enerjisinin %70'ini ithal eden Ülkemiz açısından bakıldığında, benzer şekilde enerji tüketiminin yaklaşık %30'u bireysel kullanımda, büyük enerji tüketimi ise sanayi alanlarında gerçekleşmektedir (Anonim 2018). Tüketilen enerjinin büyük bir kısmının kömür ve doğalgaz gibi geri dönüşümü olmayan kaynaklar cinsinden olması maliyetleri arttırmaktadır (Tacconi ve Rodwell 2000). Ekonomik etkilere ek olarak, küresel ısınma gibi oldukça tehlikeli çevresel sonuçlara da neden olmaktadır.

Bu durum, farklı amaçlarla üretim yapan fabrikalar için de geçerlidir. Enerji Piyasası Düzenleme Kurumu'nun Doğalgaz Piyasası 2020 yılı Sektör Raporu'na (Anonim 2021) göre, doğalgaz tüketiminin yoğun olduğu Sanayi Sektörü'nde, ergitme faaliyetini konu alan ametal mineraller (cam, seramik, çimento, vs.), demir-çelik ve demir dışı metal üretimi ve işleme (krom, bakır, vs.) sektörlerinde tüketilen toplam doğalgaz miktarı, Türkiye'de yıllık tüketilen toplam doğalgaz miktarının %6,71'ine, sanayi sektörü içerisinde ise %25,5'ine karşılık gelmektedir. Bu fabrikaların temel enerji tüketim kaynağı olan ergitme fırınlarının enerji tüketimi açısından düzenlenmesi, hem ekonomik hem de çevresel anlamda oldukça verimli sonuçlar doğuracaktır.

Bu tezin amacı, endüstriyel amaçla kullanılan ısıtma fırınlarından toplanan verilerin kullanılması ile, ısıtma fırınlarının optimum enerji tüketimi için gerekli operasyonel parametrelerin tespitini sağlamak için veri analitiği teknikleri kullanılarak, yenilikçi bir metodoloji oluşturmaktır. Çalışmada, bir adet ısıtma fırınının ürettiği verilerin analiz edilmesi ile enerji verimliliği sağlanmasına yönelik olarak, sensör verilerinin değerlendirilmesi ile optimum parametre setinin elde edilmesi sağlanmaya çalışılmıştır.

Isıtma fırınları, sadece mekanik endüstriyel cihazlar değil, aynı zamanda, yoğun veri üreten makinelerdir. Elde edilen verinin büyüklüğü, günümüzde her alanda önemli başarılar gösteren büyük veri yaklaşımlarının uygulanabilmelerine olanak sağlamaktadır. Isıtma fırınlarından elde edilen büyük boyutlu veri, farklı sistem (fırın işletme, vb.) parametrelerine karşılık gelen enerji tüketim değerlerini de içermektedir. Büyük hacimli veriler kullanılarak eğitilecek yapay sinir ağları, veriyi öğrenmenin en ideal yolu olarak ön plana çıkmaktadır. Geliştirilen yapay sinir ağı, sistem parametreleri ile enerji tüketimi arasında kompleks ilişkiyi modelleyerek, daha önce karşılaşılmamış parametrelerin de neden olabileceği enerji tüketimini tahmin ederek optimum parametre setine adım adım yaklaşılmasını sağlamıştır.

Çalışmanın ekonomiye, çevreye ve verimliliğe etkisini en üst düzeye çıkarabilmek için enerji verimliliğine katkı sağlayacak çalışmalar gerçekleştirilmiştir. Bu amaca yönelik olarak yeni gelişen teknolojilerden veri analitiğinin sunduklarından yararlanılmış, tanımlayıcı veri analitiği ve tahminleyici veri analitiği teknikleri kullanılarak elde edilen analizler zenginleştirilmiştir.

Tez kapsamında yapılan çalışmalarda, tanımlayıcı veri analitiğinin, temel istatistikî analizler ile verinin temel özellikleri ve veri ile hangi tekniklerin kullanılabileceğini ortaya çıkaran analizleri içerdiği; tahminleyici veri analitiği tekniklerinin ise, verinin karakteristiğinin etkilerinin öğrenme metodolojileri (makine öğrenmesi, Derin Öğrenme - DÖ (*Deep Learning*) vb.) ile öğrenilerek, zamana göre kestirebilmesini sağlayan analizleri içerdiği tecrübe edilmiştir. Veri analitiği yöntemleri ile sistem parametrelerinin karakteristiği tespit edilmiş, enerji verimliliğine olan etkileri incelenmiş, Pekiştirmeli Öğrenme - PÖ (*Reinforcement Learning*) teknikleri ile

optimum sistem parametrelerinin ortaya çıkarılması sağlanmıştır. Çalışma sayesinde enerji tasarrufu için öngörülen optimum sistem parametreleri tespit edilerek önerilmiştir.

Optimum parametrelerin belirlenmesinde izlenen yöntem, PÖ algoritmalarından Q-Öğrenme'nin (*Q-Learning*) uygulanmasını içermektedir. Çalışma içerisinde PÖ'nin uygulanabilmesi için Çevre (*Environment*) tanımı yapılmış, bu Çevre ile etkileşime girecek olan Ajan (*Agent*) özellikleri detaylandırılmaya çalışılmıştır.

Tez içerisinde kullanılan teknikler, kuramsal temeller başlığında açıklanmış, gerçekleştirilen çalışmalara yönelik analiz sonuçları materyal ve yöntem başlığında irdelenmiştir. Araştırma bulgularının sonuçları sunularak tez çalışması tamamlanmıştır.

2. KURAMSAL TEMELLER

Tez çalışması kapsamında kullanılan metodolojilere yönelik olarak kuramsal temeller hakkında bilgi sağlanmıştır. Tezin amacı veri bilimleri teknikleri kullanılarak ergitme fırınının enerji verimliliğini sağlamak için en uygun çalışma parametrelerini bulmaya çalışan yenilikçi bir yöntem geliştirmektir. Bu nedenle bütünsel olarak kuramsal kavramlar ele alınmış ancak ileri konular olarak nitelendirilebilecek detaylar açıklanmamıştır.

Çalışma içerisinde geçen kavramlardan; ergitme fırınları, veri analitiği, makine öğrenmesi, Yapay Zeka – YZ (*Artificial Intelligence*) ve optimizasyon kavramlarına yönelik bilgi sağlanmıştır. Teknolojik çalışma konusu olan PÖ metodolojisi daha detaylı aktarılmaya özen gösterilmiştir.

2.1 Ergitme Fırınları


Fırın, ısınma ihtiyacını karşılayan bir kullanım amacı olmasının yanı sıra, ısıyı kullanarak farklı malzemelerin işlenmesini sağlayan bir cihazdır. Fırınlar sadece evlerde kullanmak için değil, endüstride de malzemelerin moleküler yapılarını değiştirmek için ısı işlem uygulamak gibi çeşitli amaçlarla kullanılmaktadır.

Fırınlı merkezi ısıtma, asırlık bir fikirdir. Bu fikrin en eski biçimlerinden biri Romalılar tarafından icat edilmiş ve *hipokaust* olarak adlandırılmıştır (Başaran 1997). Duvarlardaki baca bağlantıları ile havalandırılan bir bodrum katının bir köşesinde ateş kullanılarak gerçekleştirilen bir tür yerden ısıtma düzeneği olarak uygulanmıştır. Bu ısıtma şekli sadece taş veya tuğla evlerde kullanılacak şekilde tasarlanmıştır.

Fırınlar yakıt (odun, kömür, petrol türevleri, elektrik vb.) yakarak ısı üretir. İlk fırınlarda yakıt olarak odun kullanılmakla beraber on yedinci yüzyılda kömür, ihtiva ettiği yüksek kalori nedeniyle birincil yakıt olarak odunun yerini almaya başlamıştır. Kömür, birincil yakıt olarak 1940'ların başına kadar kullanılmıştır.


Odun ve kömür yakan fırınlar, ürettikleri ısıyı korumak için sürekli besleme gerektirmektedir. Kullanım süresi boyunca fırına yakıt konulması gerekmektedir. Yanmanın katı yakıtlar ile gerçekleşmesi, ısının sabit tutulmasını da zorlaştırmaktadır. Ayrıca yanmış odun veya kömürün küllerinden çıkan atıkların uzaklaştırılması ve bertaraf edilmesi sorun teşkil etmektedir.

Endüstriyel ergitme fırınları, ısınma amaçlı kullanılan fırınlar ile benzer tasarıma sahiptirler. Gereksinim duydukları kalori ihtiyacının sabit bir şekilde karşılanabilmesi için gaz ile çalışan çözümler üretilmiştir. Modern ergitme fırınlarının genel görünümü şekil 2.1’de gösterilmektedir. Ergitme fırınlarında sürekli gaz girişleri, gaz deliklerinden sağlanırken, hammadde olarak beslenen içerik ergitme bölgesinde ilerleyerek çıkışa kadar ısıl işleme tabi tutulmaktadır. Nihai ürün çıkış boğazından alınarak soğutulur, depolanmak üzere depolara taşınmaktadır.




Şekil 2.1 Doğalgaz ile çalışan modern ergitme fırını genel görünüm

Modern, gazla çalışan ergitme fırınlarında, havayı büyük ısıtma kanallarından dolaştırmak ve ergitme fırını içerisinde taze hava döngüleri sağlamak için, hava akışına uygun olarak şekil 2.2’deki (Zhao vd. 2021) tasarımlara benzer tasarımlar kullanılmıştır.



Şekil 2.2 Doğalgaz ile çalışan ertitme fırını hava sirkülasyonu tasarımı

Bu tasarımlar sayesinde, ertitme fırınları oldukça verimli olmalarına rağmen, farklı nedenler ile ısıtın/enerjinin kaybına neden olmaktadır. Winnipeg, Kanada'daki bir çelik fabrikasının termal verimliliği çeşitli araştırma araçları ile analiz edilmiş ve % 40 civarında enerji kaybının olduğu tespit edilmiştir. Ertitme fırının enerji kayıplarının miktarı ve nedenleri şekil 2.3'te belirtilmiştir. En büyük kayıp olan baca gazı kayıplarının kullanılan enerjinin yaklaşık % 30'u oranında olduğu belirtilmiştir (Zhao vd. 2021). Tez çalışmasında bu tür kayıplar göz ardı edilmiştir.



Şekil 2.3 Doğalgaz ile çalışan ergitme fırını işleyişindeki kaçaklar

2.2 Veri Analitiği

Veri analitiği, yararlı bilgileri keşfetmek için verilerin temizlenmesi, dönüştürülmesi, modellenmesi ve analizi süreci olarak tanımlanabilir. Veri analitiğinin amacı, verilerden faydalı bilgiler çıkarmak ve veri analizine dayalı sonuçlar elde ederek karar almaya yardımcı olacak bilgileri sağlamaktır.

Veriler ile gerçekleştirilen analitik çalışmalarında üç baskın analitik türü – Tanımlayıcı, Tahminleyici ve Reçete Yazıcı Analitik – ön plana çıkmaktadır. Bu analitik türlerin her biri farklı yöntemler sunmaktadır.

1-Tanımlayıcı Analitik (*Descriptive analytics*) ile "Ne oldu?" sorusuna yanıt aranmaktadır. Geçmişte ne olduğunu anlamak için ham verilerin istatistiksel olarak tanımlamaya çalışılması veya özetlenmesi ile yorumlanabilir hale getirilmesidir. Sıklıkla kullanılan istatistik yöntemlerinin büyük çoğunluğu bu kategoriye girmektedir (temel aritmetik işlemleri, toplamalar, ortalamalar, yüzde değişiklikleri v.b.). Tanımlayıcı analitik, bilgilerin geçmişe dair yorumlamasına yardımcı olmak için veri toplama ve veri madenciliğini teknikleri kullanılarak girdilerin anlamlandırılmasına yardımcı

olmaktadır. Bu analitik türü istatistik temelli grafikler, çizelgeler, raporlar ve gösterge tabloları gibi veri görselleştirmeleri biçiminde olabilmektedir.

2-Tahminleyici Analitik (*Predictive analytics*) ile "Ne olabilir?" sorusuna yanıt aranmaktadır. Geçmiş verileri temel alarak, geleceği anlamak için istatistiksel modelleri ve tahmin tekniklerini kullanan, makine öğrenmesi yöntemleri ile eğilimleri, kalıpları ve veri kümeleri arasındaki ilişkileri dikkate alarak modellerin üretildiği yöntemidir. Tahminleyici analitik yöntemlerinde elde edilen modeller, mevcut verilere uygulanarak, gelecekteki bir sonucun (tahminin) olasılığı hakkında bilgi sağlamayı amaçlamaktadırlar.


3-Reçete Yazıcı Analitik (*Prescriptive analytics*) ile " Ne yapmalıyız?" sorusuna yanıt aranmaktadır. Tahminleyici analitik sonuçlarını bir sonraki düzeye taşımaya çalışmakta, gelecekte ne olacağına dair fikir edinebilmek üzerine analizlerin gerçekleştirilmesini sağlamaktadır. Reçete yazıcı analitik, kararlar fiilen alınmadan önce olası sonuçlar hakkında tavsiyede bulunmak için gelecekteki kararların etkisini ölçmeye çalışarak, yalnızca ne olacağını değil, aynı zamanda neden olacağını da tahmin ederek, tahminlerden yararlanacak eylemlerle ilgili öneriler sunmaktadır. Optimizasyon ve simülasyon algoritmalarını kullanarak olası sonuçlar hakkında tavsiyelerde bulunmaya çalışmaktadır. Reçete yazıcı analitik, iş kuralları, algoritmalar, makine öğrenimi ve hesaplamalı modelleme prosedürleri gibi tekniklerin ve araçların bir kombinasyonunu kullanmaktadır. Bu teknikler, geçmiş ve işlemsel veriler, gerçek zamanlı veri akışları ve büyük veriler dâhil olmak üzere birçok farklı veri kümesinden gelen girdiler doğrultusunda uygulanmaktadır. Analiz sonucu, amaca yönelik olarak çeşitli yollar önermekte ve her biri için olası sonuçların ne olacağını ana hatlarıyla belirtmeyi amaçlamaktadır.

2.3 Makine Öğrenmesi

Makine öğrenimi, geniş anlamda bir makinenin akıllı insan davranışını taklit etme yeteneği olarak tanımlanan YZ'nin bir alt alanıdır. YZ sistemleri, karmaşık görevleri, insanların sorunları çözme şekline benzer şekilde gerçekleştirmek için kullanılır.


Makine öğrenimi yaklaşımları, öğrenme sistemi için mevcut olan "veri" veya "geri bildirimin" doğasına bağlı olarak üç geniş kategoriye ayrılır:

1-Denetimli öğrenme: Bilgisayara, bir "öğretmen" tarafından verilen örnek girdiler ve istenen çıktılar sunulur ve amaç, girdileri çıktılara eşleyen genel bir kuralı öğrenmektir. Denetimli makine öğrenimi modelleri, modellerin zaman içinde daha doğru bir şekilde öğrenmesini ve büyümesini sağlayan etiketli veri kümeleriyle eğitilir. Algoritmanın etiketlenmiş eğitim veri seti ile eğitilerek, girdi veri seti ile çıktı arasında ilişki kurulmasını sağlayan ve bu sayede sınıfları ayıran bilgi modele girdi oluşturmaya çalışır (Şekil 2.4). Bir algoritmanın, tümü insanlar tarafından etiketlenen köpek resimleri ve diğer nesneler ile eğitilmesi sonrasında, verilecek herhangi bir resim içerisinde köpek şekillerini kendi başına tanımlamanın yollarını öğrenmesi, denetimli öğrenmeye bir örnektir. Denetimli makine öğrenimi, günümüzde kullanılan en yaygın makine öğrenimi türüdür.




Şekil 2.4 Denetimli öğrenme

2-Denetimsiz öğrenme: Öğrenme algoritmasına hiçbir etiket verilmez, verilen girdiler içerisinde yapıyı bulmak/tanımlamak için algoritma kendi başına bırakılır. Denetimsiz makine öğreniminde kullanılan algoritma etiketlenmemiş veriler içerisindeki/arasındaki kalıpları arar. Girdi verilerinin etiketleme yapılmadan algoritmaya verilmesi ile otomatik olarak keşif yapan, ilişki ağını ortaya koymaya çalışan model, sınıfları birbirinden ayıran bilgileri elde etmeye çalışır (Şekil 2.5). Denetimsiz makine öğrenimi, insanların açıkça aramadığı kalıpları veya eğilimleri bulmaya yardımcı olur. Örneğin, denetimsiz bir makine öğrenimi algoritması, satın alma yapan farklı müşteri türlerini belirleyerek, müşteri özelliklerine göre sınıflara ayırabilir.



Şekil 2.5 Denetimsiz öğrenme

3-Pekiştirmeli (Takviyeli) öğrenme: PÖ, bir ödül/ceza sistemi kurarak en iyi eylemi gerçekleştirmeleri için algoritmaların deneme yanılma yoluyla öğrenmesini sağlayan tekniktir. Yarı denetimli öğrenme olarak da sınıflandırılmaktadır. Sınıfları ayıran bilginin bir kısmı verilirken, daha uygun sonucu bulmak üzere model sınıfları ayıran bilgiyi bulmaya çalışır (Şekil 2.6). PÖ, algoritmaya doğru kararları verdiğinde ödül veren, yanlış veya istenmeyen kararları verdiğinde ceza vererek zaman içinde hangi eylemleri yapması gerektiğini öğrenmesine yardımcı olan, deneme yanılma süreçleri sonrasında öğrenmenin gerçekleştiği bir yöntemdir. Günümüzde özellikle oyun dünyasında oyuncuların karşısındaki yapay oyuncu hareketlerini sağlamak için ve otonom araçların çevre koşullarına göre karar vermesini sağlayacak algoritmaların geliştirilmesinde kullanılmaktadır.



Şekil 2.6 Yarı denetimli öğrenme

Veri türlerinin ve boyutlarının sürekli artması, veri analizinin farklı türlerinin kullanımının ve farklı aşamaların/süreçlerin probleme yönelik olarak ele alınması sonucunu doğurmuştur. Veri analitiğinin başarılı bir şekilde kullanılması, doğru bilginin elde edilmesinin en önemli aşamasıdır. Veri analitiğinin temel amacı, daha iyi sonuçları elde edebilmek için uygun tekniklerin kullanılmasıdır.

Makine öğrenmesi teknikleri; denetimli öğrenme, denetimsiz öğrenme ve pekiştirmeli öğrenme alt alanlarında pek çok alternatif sunmaktadır. Tez çalışması içerisinde, makine öğrenmesi tekniklerinden regresyon, tekrarlayan sinir ağları, uzun kısa süreli hafıza ağları ve pekiştirmeli öğrenme algoritmalarının kullanılmış olmasından dolayı, kuramsal temeller içerisinde anlatılmışlardır.

2.3.1 Regresyon


Regresyon analizi, iki veya daha fazla nümerik değişken arasındaki ilişkinin incelemesine yardımcı olan istatistiksel yöntemdir. Pek çok regresyon analizi türü olsa da, temelde hepsi bir veya daha fazla bağımsız değişkenin bir bağımlı değişken üzerindeki etkisini inceler.

Makine öğrenimi çalışmalarında, değişken ilişkilerini matematiksel ifadeler cinsinden elde etmek üzere, temel araçlardan biri olarak regresyon algoritmaları kullanılmaktadır. Birbirleri ile güçlü korelasyonu bulunan değişkenlerin değişimlerinin tahminlenmesinde

yüksek başarılı sonuçlar elde edilmesini sağlar. Girdi verileri ile hedef değişkenin ileri değeri tahmin etmek için kullanılır. Regresyon, tahmine dayalı bir ilişkinin elde edilmesine yardımcı olan bir tür denetimli öğrenme tekniğidir.

2.3.2 Tekrarlayan sinir ağları

Tekrarlayan Sinir Ağı - TSA (*Recurrent Neural Networks*), bir veri dizisindeki kalıpları tespit etmek için kullanılan (Schmidt 2019), bilginin kalıcı olmasını sağlayan, zaman serisi olarak düzenlenmiş metin, ses, video vb. şeklinde sıralı verilerle çalışmak üzere uyarlanmış, çıktıyı üretmek için sıralı verideki önceki bilgileri kullanan, özel bir yapay sinir ağı türüdür (Che vd. 2018). Bir yapay sinir ağını temsil eden A ağı, X_t girdilerini alır ve bir h_t değeri elde eder (Şekil 2.7). Tekrarlanan döngü, bilgilerin ağın bir adımından diğerine geçmesine izin verir. Standart bir TSA'daki yinelenen modül, tek bir katman içermektedir.



Şekil 2.7 Tekrarlayan yapay sinir ağı


X_t : girdi vektörü

h_t : gizli katman vektörü

TSA (Pineda 1988), döngüsel olmayan ileri beslemeli ağların aksine, düğümler arasında döngüsel bağlantılara sahiptir. Bu, TSA'ya bir dizideki önceki adımlardan gelen bilgileri (X_t ve h_t), $\tanh^{-1}$ etkinleştirme (aktivasyon) işlevi ile şekil 2.8'deki gibi

¹ ReLU - (*Rectified Linear Activation*) veya Sigmoid benzeri diğer etkinleştirme işlevleri de kullanılabilir.

hatırlama yeteneği verir, bu da sıralı verilerin analizi için TSA'ların kullanılmasını avantajlı hale getirir.



Şekil 2.8 TSA zinciri

tanh : etkinleştirme işlevi

TSA'lar sıralı bir şekilde çalışır ve bir seferde bir dizideki bir adımı işler. Standart TSA bu nedenle yalnızca analiz edilen sıradaki adımlara dayalı kararlar alabilir. TSA'ların tekrarlayan katmanda geri besleme döngüleri vardır. Bu, zaman içinde bilgileri/bağımlılıkları bellekte tutmalarını sağlar. Ancak, uzun süreli bağımlılıkların öğrenilmesini gerektiren sorunları çözmek için standart TSA'ları eğitmek, kaybolan gradyan problemi olarak adlandırılan problem nedeni ile zor olabilir (Bengio vd. 1994).


TSA'da ağı eğitmek için zaman içinde geri yayılan her adımda gradyan hesaplanır. Gradyan, ağıdaki ağırlıkları güncellemek için kullanılır. Önceki katmanın mevcut katman üzerindeki etkisi küçükse, gradyan değeri küçük olacaktır ve bunun tersi de geçerlidir. Önceki katmanın gradyanı daha küçükse, mevcut katmanın gradyanı daha da küçük olacaktır. Bu, geri yayılım yapılırken gradyanların katlanarak küçülmesine neden olur. Daha küçük gradyan, ağırlık güncellemesini etkilemeyeceği anlamına gelir. Etkinleştirme fonksiyonları sayesinde girdileri belirli bir aralığa indirgenebilmektedir. Bu aralık genel olarak (-1,1) veya (0,1) aralıklarıdır. Değerlerin dar bir alana indirgenmesinden dolayı girdideki büyük bir değişim etkinleştirme işlevinde o kadar

büyük bir değişime yol açmayabilir. Bu nedenle, türevi de küçük olur. Eğer türev çok küçükse, o katman önceki girdilerin etkisini yeteri kadar öğrenemez. Böylece kısa süreli hafıza sorununa neden olur. Bu oluşan probleme de kaybolan gradyan problemi denir.

TSA'nın dezavantajı gradyan probleminde bahsedildiği üzere önceki zaman adımlarından sonraki adımlara bilgi taşımakta zorlanmalarıdır (Pascanu vd. 2013). Bu sorunun üstesinden gelmek için TSA'nın birimlerine ek olarak özel birimler kullanan bir versiyon olarak Schmidhuber and Hochreiter tarafından Uzun Kısa Süreli Bellek - UKSB (*Long Short Term Memory*) (Hochreiter ve Schmidhuber 1997) geliştirilmiştir. UKSB birimleri, bilgileri uzun süre bellekte tutabilen bir bellek hücresi içerir. Bu bellek hücresi, daha uzun süreli bilgileri/bağımlılıkları öğrenmelerini sağlar.

2.3.3 Uzun kısa süreli bellek ağları

UKSB'ler de TSA zinciri benzeri yapıya sahiptir. Normal bir TSA hücresinde, zaman damgasındaki giriş ve önceki zaman adımından gelen gizli katman, yeni bir durum elde etmek için etkinleştirme işlevinden geçirilir. UKSB hücresinde yer alan kapı mekanizmasında, TSA'dan farklı olarak yinelenen modül içerisinde tek bir sinir ağı katmanı yerine, birim boyunca bilgi akışını daha iyi düzenlediği varsayılan şekil 2.9'da gösterildiği gibi dört adet sinir ağı yer almakta, mevcut giriş durumu, önceki hücreden kısa süreli bellek ve son olarak uzun süreli bellek olarak üç farklı hücreden girdi almaktadır. UKSB kullanılan ağlar, daha kararlıdır ve analiz edilen sırada daha fazla sayıda adımla ayrılan bağımlılıkları yakalayabilir.




Şekil 2.9 UKSB zinciri

UKSB'lerin temel konsepti hücre durumu ve kapılardır. UKSB'ler, kapılar² adı verilen, isteğe bağlı olarak bilgileri saklanmasına (bilgi ekleme) veya unutulmasına (çıkarma) yardımcı olan mekanizmalara sahiptirler. Kapılar, ağdaki bilgi akışını kontrol etmek için kullanılır ve hangi girdilerin önemli olduğunu öğrenme ve bilgileri saklama yeteneğine sahiptirler. Hücre durumu, bilgiyi zincirin sonuna kadar aktarma görevi görür. Bu, ağın hafızasını oluşturmaktadır. Bu hücreler, uzun süreli ve kısa süreli bilgileri bir sonraki hücreye aktarmadan önce, döngü işleminde tutulacak veya atılacak bilgileri düzenlemek için kapıları kullanır. Daha önceki zaman adımlarından alınan bilgiler bile, kısa süreli belleğin etkilerini azaltarak sonraki zaman adımlarına geçiş yapabilir. Bilgi, kapılar aracılığıyla hücre durumuna eklenir veya çıkarılır. Bu kapılar, istenmeyen ve alakasız bilgileri filtrelemeyi sağlayan, istenilen bilgilerin saklanmasını sağlayan yapılardır. Kapılar, eğitim sırasında hangi bilgilerin saklanması veya unutulması gerektiğini öğrenebilir.

Kapılarda (ağda) kullanılan sigmoid (σ) fonksiyonu 0 ile 1 arasındaki değerleri değerlendirerek, her bir girdinin ne kadarının geçmesine izin verilmesi gerektiğini belirler. Sıfır (0) değeri "hiçbir şeyin geçmesine izin verme" anlamına gelirken, bir (1) değeri "her şeyin geçmesine izin ver" anlamına gelir. Bu, ağın, hangi verilerin önemli

² Kapı olarak ifade edilen mekanizmalar da birer sinir ağıdır.

olduğunu öğrenerek, hangi verilerin tutulması/güncellenmesi veya unutulması/silinmesini sağlamak için kullanılır.



Şekil 2.10 UKSB hücresi

Şekil 2.10’da verilen UKSB hücresinde (Vijayaprabakaran ve Sathiyamurthy 2020), bilgi akışını düzenleyen üç farklı kapı bulunur: unutma kapısı, giriş kapısı ve çıkış kapısı.

Unutma kapısı - *forget gate* (f_t), hangi bilgilerin unutulacağına veya saklanacağına karar verir. Önceki durumdan gelen bilgiler ve mevcut girişten gelen bilgiler sigmoid fonksiyonundan geçirilir.

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

Burada;

W_f : giriş kapısı (f_t) ve hücre durumu (C_{t-1}) arasındaki ağırlığı (*weight*),

b : vektör cinsinden yanlılığı (*bias*)³

h_t : çıktı vektörünü

σ : sigmoid etkinleştirme fonksiyonunu temsil eder (Hu vd. 2022).

Giriş kapısı – *input gate* (i_t) hücre durumunu güncellemeyi sağlar. Önceki durumu ve mevcut girişten gelen bilgiler sigmoid fonksiyonundan geçirildikten sonra tanh fonksiyonuna iletilir. tanh çıktısı ile sigmoid çıktısı çarpılır. Sigmoid çıktısı, *tanh* çıktısından hangi bilgilerin saklanması gerektiğine karar vermek için kullanılır.

$$i_t = \sigma(W_i[h_{t-1}, X_t] + b_i) \quad (2)$$

Çıkış kapısı – *output gate* (o_t), hücre durumuna bağlı olarak, filtrelenmiş bir sürüm olarak, hücre durumunun hangi bölümlerinin saklanacağına karar vermek için sigmoid fonksiyonundan geçirilir. Hücre durumunu daha sonra tanh fonksiyonuna iletilir ve sigmoid fonksiyonunun çıktısı ile çarpılır, böylece sadece karar verilen kısımları çıkartılmış olur.

$$o_t = \sigma(W_o[h_{t-1}, X_t] + b_o) \quad (3)$$

³ UKSB'lerin çoğu uygulamasında UKSB'ler birçok problemde işe yarayan küçük rastgele ağırlıklarla başlatılır. Ancak bu tür bir başlatma, kapı yanlılıklarını 0.5 değerine yakınsaması ile sonuçlanır. Bu değer, zaman adımı başına 0.5 faktörü ile kaybolan bir gradyan sunar; bu, uzun süreli bellek ihtiyacı olduğunda sorunlara neden olmaktadır (Zhao vd. 2021). Bu sorun, geçitlerin yanlılık değerlerine 1 veya 2 gibi büyük bir değer ile atanması ile çözülür. Bu şekilde, kapılar, gradyan akışını mümkün kılacak şekilde 1'e yakın bir değere yakınsamasını sağlayacaktır. Kapıların yanlılığı uygun şekilde başlatılmazsa, UKSB'nin uzun süreli bağımlılıklarda sorunları çözme yeteneğini öğrenemediği sonucu ortaya çıkabilir (Jozefowicz vd. 2015).

Aday hücre durumu C_{t+1} , giriş verileri X_t ve önceki gizli katman h_{t-1} kullanılarak hesaplanır. Hücre belleği veya mevcut hücre durumu C_t , unutma kapısı f_t , önceki hücre durumu C_{t-1} , giriş kapısı i_t ve aday hücre durumu C_{t+1} kullanılarak hesaplanır. Eşitlik 5 ve 6'daki çarpımlar, ilgili matrislerin basitçe element bazında çarpımıdır.


$$C_{t+1} = \tanh(W_c[h_{t-1}, X_t] + b_c) \quad (4)$$

$$C_t = f_t * C_{t-1} + i_t * C_{t+1} \quad (5)$$

$$h_t = o_t * \tanh(C_t) \quad (6)$$

2.3.4 Pekiştirmeli öğrenme

PÖ, ödül-ceza temeline dayanan, ajanların bir çevrede nasıl eylemlerde bulunması gerektiğini öğrenmelerine yönelik bir makine öğrenimi alt alanıdır. Öğrenme kabiliyetine sahip ajanların, kontrollü bir çevre ile etkileşime girdiği standart PÖ çerçevesi (Sutton ve Barto 1998) ile başlayan geliştirme süreci, sınırlı sayıda eylem ve durum ile sınırlı ödüller içeren ayrık zamanlı bir Markov Karar Süreci - MKS (*Markov Decision Processes*) ile tanımlanır.




Şekil 2.11 Basit PÖ ajan diyagramı

Şekil 2.11’de, basit PÖ çalışma mekanizması özetlenmiştir. Burada bahsi geçen terminolojide;

- ajan: bir ortamda eylemler gerçekleştiren varsayımsal varlık/algoritmayı (bir oyunu oynayan ana karakter – tez çalışmasındaki ajan, değerleri analiz eden operatörü) ifade etmektedir
- çevre: ajanın yüzleşmesi gereken ortam/senaryoyu (ana karakterin etkileşime girdiği oyun alanı – tez çalışmasındaki çevre ergitme fırınıdır) ifade etmektedir
- aksiyon (a): ajanın gerçekleştirebileceği tüm olası hareketleri (bir oyundaki ana karakterin hareketleri – örneğin yukarı zıplama, sağa ve sola hareket vb. – tez çalışmasındaki aksiyon, doğalgaz miktarının artırılıp azaltılması işlemidir) ifade etmektedir
- durum (s): aksiyon sonrası elde edilen mevcut durumu (ana karakterin zıplayarak tepesindeki parayı alması, sağa hareket ederek önündeki engelden kaçması – tez çalışmasında durum, doğalgaz miktarının değişimi sonrası parametrelerin aldığı değerdir) ifade etmektedir
- ödül/ceza (r): son eylemin çevre tarafından değerlendirildikten sonra aksiyon karşılığında aldığı dönüşü/ödülü/cezayı (ana karakterin bölüm sonuna başarı ile gelmesi, engele çarparak oyunu sonlandırması – tez çalışmasında ödül, doğalgaz miktarının azaltılması (enerji tasarrufu), ceza ise doğalgaz miktarının arttırılmasıdır (enerji sarfıyatı)) ifade etmektedir.


Ajan için temel amaç bir sonraki hareketleri inceleyerek, sonraki hareket olasılıklarına göre kazanacağı ödülü en çoklayıp (*maximize*) buna göre hareket etmektir. Bu amaca, PÖ’de en çok kullanılan algoritmalarından birisi olan Q-Öğrenme (*Q-Learning*) (Chrisman 1992, Lin ve Mitchell 1993) algoritmasının şekil 2.12’de gösterilen basit

adımlarının uygulanması ile gerçekleştirilir. Q-Tablosu, ilgili durum ve aksiyonların değerlerini tutan tablodur. İlk olarak Q-Tablosuna'a 0 değerleri atanarak, tablo oluşturulur. En yüksek ödülü veren aksiyon adımı Q-Tablosundan seçilir. Seçilen aksiyon çevre içerisinde uygulanır. Çevrenin aksiyon karşılığında vereceği ödül/ceza miktarı alınarak, toplanır. Tüm aşamalardan sonra Q-Tablosu güncellenir. Bu adımlar Q-Tablosu verileri istenilen düzeye gelene kadar devam ettirilir. Öğrenme Q-Tablosu vasıtası ile gerçekleştirilmiş olur.



Şekil 2.12 Q-Öğrenme algoritmasının temel adımları

PÖ ajanı, şekil 2.13’de gösterilen sistem hakkındaki bilgisi yetersiz olduğu için neden sonuç arasında bağ kurmak amacıyla gözlem yapar (ilk hareketler rasgele seçilerek yapılır). Gözlemin ardından ajan, önündeki seçenekler arasında bir tercihte bulunmaya zorlanır. En yüksek ödüle odaklı olduğu için, en uygun kararı vererek aksiyona geçer. İlk adımından sonra ajan tekrar gözlemde bulunarak önüne çıkan yeni seçeneklere bakar. Burada önemli olan nokta, ajanın ilk adımdan sonra hedefine ulaşabilmek için nasıl doğru kararı alabileceğini birikimli olarak öğrenecek olmasıdır. Bu döngü sürekli öğrenme ile devam eder. Kullanılan YSA sayesinde öğrenme gerçekleşir.



Şekil 2.13 Derin PÖ ajan diyagramı

PÖ algoritmaları, ajanın belirli bir durumda bulunma olasılığının ne kadar iyi olduğunu (veya belirli bir eylemi gerçekleştirmenin ne kadar iyi olacağını) tahmin eden durum-eylem çiftlerini tahmin etmeye dayanır. Buradaki "ne kadar iyi" kavramı, sonraki adımlarda beklenebilecek ödüller açısından tanımlanır. Ajanın gelecekte almayı bekleyebileceği ödüller, hangi eylemlerin gerçekleştirileceğine bağlıdır. Buna göre, değer işlevleri belirli politikalara göre tanımlanır. Bu işlevleri belirten fonksiyonlara değer fonksiyonları adı verilir (Sutton ve Barto 2018).

PÖ algoritmasının temel unsurlarından biri, beklenen değer ve ödül değerlerinin değişimine göre hangi eylemin seçileceğine karar verilmesini sağlamak üzere oluşturulan değer fonksiyonlarının (V ve Q) hesaplanması için gerekli olan Bellman Denklemidir (Yang ve Whinston 2020). Bellman Denklemleri, alt problemlerin özyinelemeli olarak, genel problem ile iç içe geçmesi ile problem ile alt problemlerin değerleri arasında bir ilişki olduğu durumlarda kullanılan tekniğin adıdır (Guan vd. 2021).

PÖ'de ajanın amacı, ödülü en üst düzeye çıkaracak bir dizi aksiyon adımı bulmaktır. Bellman denklemi değer fonksiyonunu iki kısma ayırır: anlık ödül ve gelecek değerler. Dinamik programlamanın, bir kararın daha küçük alt kararlar dizisine bölünerek basitleştirilmesi ilkesi doğrultusunda; değer fonksiyonları dizisi V , sistemin t anında, s durumunda ve a aksiyonunda aldığı ödül ile bir sonraki durumda s_{t+1} ($t+1$ anında) alacağı değer maksimumu olarak Eşitlik 7'deki gibi tanımlanır.

$$V(s_t) = \max_{a_t} (R(a_t, s_t) + \gamma V(s_{t+1})) \quad (7)$$

$V(s_t)$: varolan durumdaki beklenen değeri

$R(a_t, s_t)$: alınan aksiyondaki durumun ödül değerini

$\gamma V(s_{t+1})$: γ indirim faktörü (*discount factor - gamma*) ile bir sonraki durumdaki beklenen değer çarpımı (γ değeri öğrenime etki eden önemli bir değişkendir, başlangıç değeri olarak 0.95 gibi bir değer seçilerek, ileriki adımlar önemli hale getirilir)

$\max_{a_t} (R(a_t, s_t) + \gamma V(s_{t+1}))$: t anındaki a aksiyonu gerçekleştirildiğinde alınabilecek maksimum değeri ifade eder.

Bellman denklemi, t anındaki bir s durumundaki optimal durum değeri fonksiyonunun a eylemine bağlı olduğunu söyler, bu da olası maksimum beklenen anlık ödül ve bir sonraki (s_{t+1}) durumu için uzun süreli ödül Eşitlik 8'deki gibi verir:

$$V(s_t) = \max_{a_t} \sum_{s_{t+1}} p_{ss_{t+1}}^{a_t} (R(s_t, a_t) + \gamma V(s_{t+1})) \quad (8)$$


$p_{ss_{t+1}}^{a_t}$: p , s durumunda başlayan ve s_{t+1} durumunda biten a eyleminin olasılık değeridir (geçiş olasılığı)

Bellman denklemi, ayrıca s durumunda optimal durum-eylem değeri fonksiyonunun (*optimal state-action value function*) ve a eylemi gerçekleştirmenin denklemi olarak

yazılabilir. Eşitlik 9’da verilen değer fonksiyonu, şekil 2.14’te görselleştirildiği üzere, sonraki a_{t+1} eyleminin s_{t+1} durumu ile elde ettiği değer γ (indirim faktörü) ile çarpımının, o anki s durumu ve a eyleminin ödül olasılıkları ile toplanması ile Q -fonksiyonu elde edilmiş olur.

$$Q(s_t, a_t) = \sum_{s_{t+1}} p_{ss_{t+1}}^{a_t} (R(s_t, a_t) + \gamma \max_{a_{t+1}} Q(s_{t+1}, a_{t+1})) \quad (9)$$

$Q(s_t, a_t)$: a eyleminin s durumundaki ödül değeri değeridir.



Şekil 2.14 Değer fonksiyonunun sonraki değer ile etkileşimi

PÖ, geçiş olasılıkları açık bir şekilde belirtilmeden MKS’lerini çözebilir. Geçiş olasılıklarının değerlerine, değer ve politika (adımlara karar verilmesi) yinelenmesi sürecinde ihtiyaç vardır. PÖ’de, geçiş olasılıklarının açık ifadesi yerine, geçiş olasılıkları, birçok kez yeniden başlatılan uygulama/simülatör aracılığıyla elde edilir, yani çevre ile etkileşime giren ajan sürekli bir döngüde olasılıkları oluşturarak öğrenme fonksiyonunu oluşturur. Bu da sürecin sürekli olarak tekrar edilerek öğrenmenin pekiştirilmesini sağlar.

$p_{ss_{t+1}}^{a_t}$ parametresinden de anlaşılacağı üzere süreç stokastik bir süreçtir. Bellman Denklemi, bir sonraki duruma ileriye doğru bir adımlık bakış yaparak durum değerlerinin hesaplanmasına olanak tanır. Algoritma bu değerleri kullanarak hangi durumların iyi olduğunu ve hangi durumlardan kaçınılması gerektiğini öğrenmeye başlar.

MKS bir durum uzayını ve bu durumlar arasında hareket etmenin geçiş olasılıklarını tanımlar. Hangi durumların iyi durumda olduğunu veya bir durumdan diğerine geçmenin iyi olup olmadığını belirtmez. Bunun için sisteme Eşitlik 10'da gösterilen ödül mekanizması eklenmektedir.

$$V^{\pi}(s_t) = \max_{a_t} \left(R(s_t, a_t) + \gamma \sum_{s_{t+1}} p_{ss_{t+1}}^{a_t} V(s_{t+1}) \right) \quad (10)$$

$\sum_{s_{t+1}} p_{ss_{t+1}}^{a_t} V(s_{t+1})$: sonraki durumun beklenen değeridir

PÖ probleminde, maksimum ödülü kazanmak için, her durumda maksimum beklenen getiriyi veren eylemin seçilmesi beklenmektedir. Algoritmanın her durum için hangi eylemleri seçmesi gerektiğine karar vermek için Eşitlik 12'de verilen optimum durum-değer fonksiyonunu (*Q-Learning Function*) uygulaması gerekir.

$$Q^{\pi}(s_t, a_t) = R(s_t, a_t) + \gamma \sum_{s_{t+1}} p_{ss_{t+1}}^{a_t} \max_{a_{t+1}} Q(s_{t+1}, a_{t+1}) \quad (11)$$

2.4 Yapay Zeka

YZ, bilgisayar biliminin bir dalıdır. Öğrenme, akıl yürütme ve kendini düzeltme gibi insan benzeri düşünce süreçlerinin geliştirilmesi ile ilgilidir ve insan zekâsı gerektiren görevleri tamamlamak için algoritmalar geliştirmeyi tarifler. YZ algoritmaları öğrenme, algılama, problem çözme, dil anlama ve/veya mantıksal akıl yürütme ile ilgili alanlarda kullanılmaktadır.

YZ algoritmalarının geliştirilmesi, insan beyninin nasıl çalıştığını, insanların bir sorunu çözmeye çalışırken nasıl öğrendiğini ve karar verdiğini inceleyerek, bu çalışmanın sonuçlarını yazılım ve sistemler geliştirerek gerçekleştirilmesidir (Turing 1948).

Günümüzde YZ üç seviyeli olarak tanımlanmaktadır: Dar YZ, Genel YZ ve Süper YZ (Gottfredson 1997):

Dar YZ, bir alandaki basit bir görevi gerçekleştirmek için tasarlanmış, duyarlı olmayan makine zekâsına sahip olan ilk seviye zekâ türüdür. Hâlihazırda geliştirilen YZ algoritmaları genel olarak bu tanıma girmektedir.

Genel YZ, bir insanın zekâ düzeyine yakın; akıl yürütme, planlama, problem çözme, soyut düşünme, karmaşık fikirleri kavrama, hızlı öğrenme ve deneyimlerden öğrenme yeteneğine sahip YZ türüdür (Gottfredson 1997).

Süper YZ, bilimsel yaratıcılık, genel bilgelik ve sosyal beceriler dâhil olmak üzere hemen hemen her alanda en iyi insan beyninden çok daha akıllı bir YZ türüdür (Bostrom 2006).

YZ'nin farklı alanlarındaki geniş uygulama yelpazesine rağmen, YZ'yi tanımlamak üzere ortak bir zemin bulunamamıştır. Bununla birlikte, YZ'nin geniş çapta benimsenmesi, açıklanabilirliği, önyargısı ve etikle ilgili konularda tartışmaları beraberinde getirmiştir. Örneğin, DÖ modellerinin algoritmalarının girdi ve sonuç arasında net bir matematiksel haritalama sağlayamaması veya çıktılarından orijinal verilerin elde edilemesi problemleri, YZ modellerinin nasıl çalıştığına dair bu tür bir anlayış eksikliği, elde edilen sonuçlarla ilgili güven sorunlarına yol açmaktadır (Carvalho vd. 2019). YZ sistemlerinin tasarımları ve algoritmaları, yeni teknikler ile daha karmaşık hale gelmiştir. YZ gelişiminin/geliştirmenin bakış açılarını anlamak için 3 kavrama daha yakından bakmakta fayda vardır: Açıklanabilir YZ, YZ Önyargıları ve YZ Etiği (Marshan 2021).

2.4.1 Açıklanabilir yapay zekâ

YZ, çok çeşitli uygulama alanlarında kullanılması ile önemli bir ivme kazanmıştır. Uzman sistemler ve kural tabanlı modeller ile sunulan yeni strateji sistemleri kolayca yorumlanabilir olsa da, yüzlerce katman ve milyonlarca parametre içeren, karmaşık kara kutu modelleri olarak adlandırılan (Castelvecchi 2016) Derin Sinir Ağları - DSA (*Deep Neural Networks*) gibi karmaşık karar verme sistemlerinin ortaya çıkması ile DÖ modellerinin deneysel performansı, güçlü öğrenme algoritmalarının birleşiminden oluşması, algoritmaların açıklanmasını güçleştirmektedir.

İnsanlar, artan etik YZ ihtiyacına rağmen, açıkça yorumlanamayan, izlenebilir veya güvenilir olmayan stratejileri benimsemeye genellikle isteksizdir (Zhu vd. 2018). Bununla birlikte, bir yöntemi açıkça yorumlayabilmek, eksikliklerinin artmasıyla sonuçlanacaktır. Yorumlanabilirlik, eğitim veri setindeki önyargıların tespit edilmesine ve düzeltilmesine izin verirken, karar verme tarafsızlığına katkıda bulunur (Arrieta vd. 2020).

Açıklanabilir Yapay Zeka - AYZ (*Explainable Artificial Intelligence*) (Gunning 2017), günümüzün YZ sistemlerinin etkinliğini bozmaktan kaçınmak için, bir dizi özelliklere sahip makine öğrenimi tekniği geliştirmeyi önerir:

- Yüksek derecede öğrenme verimliliği ve tahmin doğruluğu sağlarken daha açıklanabilir algoritmalar oluşturmak,

- İnsanların, akıllı sistemlerin gelişmekte olan algoritmalarını anlamalarına, uygun şekilde güvenmelerine ve yönetmelerine izin vermek.

YZ geliştiricileri, YZ algoritmalarının karar verme döngülerine girebilerek, algoritmalarının izlemelerini zamanında sağlayabilecek (durdurabilecek, tekrar çalıştırabilecek, değişkenleri takip edebilecek vb.) yapılarda geliştirme yapabilmelidirler. Bir YZ algoritması geliştirilirken kullanılan çerçevenin (*framework*), (kapalı bir çerçeve olsa dahi) yalnızca bir işi yürütmesi veya bir yargıda bulunması

(sonuç üretmesi) değil, aynı zamanda bu sonuçlara neden ulaştığına dair şeffaf bir açıklama sağlayabilecek bir model sağlaması da beklenir. Açıklanabilir bir model, çalışma zamanında kararlı sonuçlar üretebilmeli, algoritmaya ilişkin gerçekleri sağlamalıdır. Bu nedenle, algoritmaların açıklamalarında kullanılan nedenlerin “yeterince makul” olmasını sağlamak gereklidir.

2.4.2 Yapay zekâ önyargısı

Önyargı, bir kimseyle ya da şeyle ilgili olarak, belirli bir olaya, duruma ya da görmeye dayanan, önceden edinilmiş olumlu ya da olumsuz yargı, kanı olarak nitelendirilmektedir.

YZ yanlılığı, makine öğrenimi algoritmalarının çıktısında bir anormallik olarak tanımlanabilir. Bunlar, algoritma geliştirme sürecinde yapılan önyargılı varsayımlardan veya eğitim verilerinden kaynaklanabilir.

YZ önyargılarının iki ana kaynağı olabileceği varsayılabilir: (1) makine öğrenimi algoritmalarında, modelleri eğitmek için kullanılan veriler ile oluşan önyargılar ve (2) geliştirici tarafından algoritmaların yapısına eklenen önyargılar.

2.4.2.1 Önyargılı veri seti

YZ algoritmaları, modellerini oluşturmak ve eğitmek için, veri kümeleri kullanır. Çoğu durumda, bu veriler insan kararlarını içerir veya tarihsel veya toplumsal eşitsizliklerin etkilerini yansıtır. Bunu yaparak, veri setleri etik olmayan bir sonuca veya karara karşı önyargılı olabilir. Sorunun ana kaynağı genellikle algoritmanın kendisinden ziyade bu temel veri kaynaklarıdır.

Cathy O'Neil'in “*Weapons of Math Destruction*” (2017) adlı kitabında tasvir edildiği gibi, hatalı veya yanlış temsil edilen veri girdileri, yanlış, aldatıcı veya adaletsiz karar vermeye yol açar. Gerçekten de, algoritmaların rolü, verilere gömülü gizli davranışları

optimize etmek ve güçlendirmektir. Algoritmaları eğitmek için kullanılan veriler önyargılı olduğunda, algoritma bu davranışı öğrenir.

2.4.2.2 Yanlı algoritma geliştirme

YZ uzmanları, geliştiriciler ve araştırmacılar; sorunları soyut ve karmaşıklığı azaltan yollarla analiz etmeye çalışırlar. Bu nedenle, insanın akıl yürütmede kısayolları kullanma eğilimi, YZ'nin tasarlanma ve inşa edilme şekline yansır.

Chattopadhyay ve ark. (2020), bilişsel önyargılar ve yazılım geliştirme konulu çalışmalarında, bilişsel önyargıların çok sayıda faktörün bir sonucu olduğu ve yazılım geliştiriciler de dâhil olmak üzere bireylerin nasıl düşündüklerine bağlı olduğunu ifade etmişlerdir. Ayrıca bazı önyargıların, sınırlı bilişsel kapasitemiz nedeniyle ortaya çıktığını, bazılarının ise bireyin gelişim sürecinin bir yan ürünü olduğundan bahsetmişlerdir. Kaçınılmaz olarak, bu önyargıların, YZ'nin nasıl oluşturulduğu ve geliştirildiği üzerinde etkileri vardır.

2.4.3 Yapay zekâ etiği

Etik, bir kişinin davranışını veya bir faaliyetin yürütülmesini yöneten ahlaki ilkelerdir. Pratik bir örnek olarak, etik ilkelerden biri herkese saygılı davranmaktır. İnsanlar için etik ilkeler yüzyıllardır filozoflar tarafından tartışılırken, günümüzde etik tartışmalarının merkezinde YZ ile ilgili etik görüşleri de yer almaktadır.

YZ etiği, zayıf tasarım, uygunsuz uygulama veya suistimalden kaynaklanan YZ'nin zararlarını en aza indirmek için geliştiricilerin, üreticilerin ve operatörlerin toplumda nasıl davranması gerektiğine dair kritik sorular ile ilgilenmektedir. Mevcut YZ sistemlerinde veri gizliliği ve önyargı gibi YZ etiğinin kapsamı ve YZ sistemlerinin insan eşdeğeri yeteneklere (süper zekâ olarak adlandırılan) erişme veya bunları aşma olasılığı hakkında uzun vadeli endişeler mevcuttur.

Önde gelen etik tartışmaların yanı sıra Jobin ve ark. (2019) YZ ile ilişkilendirmeye çalıştıkları etik ilkeleri, belirli prensip başlıkları altında sınıflandırabilmek için alt kategoriler oluşturarak çizelge 2.1’de önermişlerdir:

Çizelge 2.1 YZ etik konuları sınıflandırması

Prensip	Etik konular
Şeffaflık	Açıklanabilirlik, anlaşılabilirlik, yorumlanabilirlik, iletişim, gösterim
Adil olma	Tutarlılık, eşitlik, hakkaniyet, önyargısızlık, ayrımcılık yapmama, çeşitlilik, çoğulluk, erişilebilirlik, erişim ve dağıtım
Zarar vermeme	Güvenlik, emniyet, zarar verme, koruma, önlem, önleme, yıkıcı olmama
Sorumluluk	Hesap verebilirlik, dürüstlikle hareket etme
Mahremiyet	Gizlilik, kişisel veya özel bilgiler
İyilik	Menfaat, barış, sosyal iyilik, ortak yarar
Özgürlük ve özerklik	Seçim, kendi kaderini tayin etme, yetkilendirme
Güven	Güvenirlik
Sürdürülebilirlik	Çevre (doğa), enerji, kaynaklar (enerji)
İtibar	İtibar
Dayanışma	Sosyal güvenlik, uyum

YZ’nin sosyal etkileri ve etiğiyle ilgili küresel bir endişenin önemi, endüstride ve akademik tartışmalarda ortaya çıkmaktadır ve yeni yeni dikkat çekmeye başlamaktadır. Kültürlerarası YZ etiğinin değişmesine neden olacak temel değerler ile bölgesel farklılıklar, büyük ölçüde keşfedilmemiş kritik bir kör nokta oluşturmaktadır ve YZ etiği konusundaki tartışmaları ilerletmesi beklenmektedir (Morgan vd. 2020).


2.5 Optimizasyon

Optimizasyon, bir sistemde varolan kaynakların (iřgücü, zaman, kapital, süreçler, hammaddeler, kapasite, ekipman gibi) en verimli şekilde kullanılarak belirli amaçlara (maliyet en azaltılması, kâr ençoklanması, kapasite kullanımının enyükseltilmesi ve verimliliğin ençoklanması gibi) ulaşmayı sağlayan bir teknoloji olarak tanımlanmaktadır (Gass ve Assad 2004).

Optimizasyon teknolojisi, karar verme süreçlerini hızlandırmakta ve karar kalitesini arttırmakta kullanılarak gerçek hayatta karşılaşılan problemlerin etkin, doğru ve gerçek zamanlı çözümünde fayda sağlamaktadır (Winston 2003).

Optimizasyon çalışmalarında modelleme ve çözümleme iki önemli bileşen olarak nitelendirilmektedir. Modelleme gerçek yaşamda karşılaşılan problemin matematiksel olarak ifade edilmesi; çözümleme ise bu modeli sağlayan en iyi çözümün elde edilmesini kapsamaktadır. Optimizasyon problemleri karmaşıklık durumlarına göre şekil 2.15’de verildiği üzere kolaydan çok zor olan sınıflara ayrılır (Al-Jilawi 2019, Hochba 1997). Burada;

- P (*Polynomial Time*), polinomsal zamanda çözülebilen karar problemlerini,
- NP (*Non-deterministic Polynomial Time*), polinomsal zamanda doğrulanabilen karar problemlerini,
- NP Tam, başka bir NP probleminin polinom zamanında deterministik bir Turing makinesi tarafından NP Tam probleme indirgenebildiği karar problemlerini (Du ve Ruzsçzyński 2017),
- NP Zor, polinomsal zamanda bir çözümü olduğu ispatlanamayan karar problemlerini ifade eder.



Şekil 2.15 Karmaşıklığa göre optimizasyon problemi sınıfları

Optimizasyon probleminin karmaşılaşması, modelleme için elde edilmesi gereken matematiksel ifadenin de karmaşılaşması ve çözümlemede zorluklar ile karşılaşılmasına neden olmaktadır. Yapılan araştırmalarda, YZ'den ilham alan çözüm yöntemlerinin, karmaşık optimizasyon problemlerinin çözümünde yer aldığı veya optimizasyon ve YZ tekniklerinin hibrit olarak kullanıldığını göstermektedir (Said vd. 2020).

3. MATERYAL VE YÖNTEM

3.1 Önerilen Sistem Mimarisi

Tez çalışması için aşağıda özellikleri belirtilen araç seti kullanılmıştır. EK-2’de verilen kaynak kodların çalıştırılabilmesi için, EK-1’de listelenen kütüphane ve çerçeve versiyonlarının kurularak kullanılabilmesi için gereken Python dili konfigürasyon öğeleri aşağıda belirtilmiştir.

- Anaconda (v4.10.3): Python programlama diline yönelik olarak bilimsel çalışmalar gerçekleştirmekte kullanılan kütüphanelerin ve araçların kolayca yönetmesini sağlayan ücretsiz ve açık kaynaklı geliştirme çerçevesidir.
- Python (v3.7): 1991 yılında Guido van Rossum tarafından geliştirmeye başlanan, nesne tabanlı, yorumlamalı, modüler, etkileşimli yüksek seviyeli, desteklediği kütüphane zenginliği nedeni ile veri analitiği çalışmalarında sıklıkla kullanılan bir programlama dilidir.
- Jupyter Notebook (v6.3.0): Bir web tarayıcısı üzerinden Python kodlarını istenilen bloklara bölerek düzenlemeyi ve çalıştırmayı sağlayan bir sunucu-istemci uygulamasıdır.
- Spyder IDE (v5.0.0): Python dilinde bilimsel programlama yapabilmek için, programlamayı hızlandıran hazır bileşenler içeren, açık kaynak kodlu yazılım geliştirme arayüz aracıdır.

3.2 Ergitme Fırını Veri Seti

Veri seti, ergitme fırınlarından toplanan sensör verilerinden oluşmaktadır. Sensör verileri, 1’er dakikalık aralıklı olmak üzere 2020/03/06 00:00:07 tarihi ile 2020/06/04 10:31:28 tarihi arasında geçen yaklaşık 3 aylık olarak toplanmaya çalışılan zaman serisi olarak tanımlanan veri setidir. Verinin orjinal boyutu ve içeriği çizelge 3.1’de verilmiştir.

Çizelge 3.1 Orjinal veri alanları

Veri Alanı Sayısı	148
Veri Boyutu (satır sayısı)	59987

3.3 Veri Seti Üzerinde Gerçekleştirilen Ön Çalışmalar

Orjinal veri seti göz ile incelendiğinde, anlamsız veri barındıran (veri satırının içerisinde bozulmuş karakter bulunan), hiçbir değere sahip olmayan satırlar ve sütunlar bulunduğu gözlemlenmiş, ilk veri temizliği bu alanlar üzerinde gerçekleştirilmiştir.

Veri setinde, satırlar içerisinde anlamsız karakterler bulunan (ve manuel olarak düzeltilemeyen) 16 satır veri setinden çıkarılmıştır.

Veri seti içerisinde 2 farklı tipte veri alanı yer almaktadır; nicel (*quantitative*) ve kategorik (*categorical*). Tez çalışmasında nicel verilerin birbirleri ile olan ilişkileri incelenmiştir.

Hiçbir veri içermeyen 79 adet kolon (EK-4) veri setinden çıkarılmıştır. 15 adet kategorik veri içeren kolon (EK-5) veri setinden çıkarılmıştır. Satır bilgisinde herhangi bir bilgi içermeyen (tüm kolonları boş olan satırlar) 10.977 satır, veri setinden çıkarılmıştır.

Veri seti zaman serisi olmasına rağmen, veri seti içerisinde zaman bilgisinin tutulduğu alan katar (*string*) veri türü olarak saklanmıştır. Bu alan veri setinden çıkarılarak, zaman türünde veri alanı veri setine eklenmiştir.

İlk veri temizliği sonrasında elde edilen veri setinin yeni boyutu çizelge 3.2’de yer almaktadır.

Çizelge 3.2 İndirgenmiş veri alanları

Veri Alanı Sayısı	50
Veri Boyutu (satır sayısı)	48994

Veri setinde kalan 50 adet veri alanının hangilerinin çalışma için anlamlı olduğunu öğrenmek için Tanımlayıcı Analitik tekniklerinden yararlanılmıştır.

Bu alanlar içerisinde yer alan veri kolonlarının veri sayısı, alt-üst limit değerleri, ortalama değerleri ve standart sapma değerleri Ek-10'da verilmiştir. Alt-üst limit değerleri çevre bileşeninin kısıt değerleri olarak kullanılmaktadır. Doğalgaz miktarı için üst limit bir kısıt olarak kullanılırken, alt limit belirtilmeyerek, PÖ çevresi ve ajanın iletişime geçmesi ile en düşük seviyelere gelmesi hedeflenmiştir.


3.3.1 Veri analizi

Enerji tüketimine yönelik yapılan tez çalışmasında, özneliliklerden doğalgaz miktarı ($f_{ak_dogalgaz_2}$), enerji tüketimini doğrudan etkileyen değişkendir. Doğalgaz miktarının diğer değişkenler ile etkileşimi araştırılmıştır.

Enerji değişimlerinin gözlemleri veri temizliği sonrası elde edilen 50 adet değişken üzerinden incelenmiştir. Deney çalışması için en önemli olduğu değerlendirilen parametrelerin değişimleri göz önüne alınarak, bu parametrelere göre PÖ çalışmaları yapılmıştır.


PÖ geliştirmesi yapılmadan önce, veri setinde yer alan değişkenlerin temel istatistiki verilerinin görselleştirilmesi ile veri alanlarına yönelik olarak ilk değerlendirmeler gerçekleştirilmiştir. EK-6'da yer alan görseller içerisinde alt-üst değerler ile veri alanlarının değer aralıklarının hangi değerlerde yoğunlaştığı kutu grafiği (*box plot*),

keman grafiđi (*violin plot*) ve sütun grafiđi (*histogram*) kullanılarak belirlenmeye çalışılmıştır.




Şekil 3.1 Kutu grafiđi

Kutu grafiđi (Şekil 3.1), bir veri alanının, minimum, ilk çeyrek (tüm verilerin dörtte birini), medyan, üçüncü çeyrek (tüm verilerin dörtte üçünü) ve maksimum değerlerini özetlemeyi sağlar. Kutu grafiđinde, ilk çeyrekten üçüncü çeyređe bir kutu oluşur, kutunun ortasından geçen dikey çizgi orta değeri ifade eder. Kutunun çıkıntısı olan sağ ve soldaki çizgiler minimum ve maksimum değeri ifade ederken, bazı değeri ise aykırı değeri (*anomaly*) olarak işaretlenir.



Kutu grafiği, temel dağılımları görselleştirmek ve özet istatistikleri (minimum-maksimum değer aralıkları ve çeyrekler gibi) karşılaştırmak için uygundur, ancak verilerdeki varyasyonları görmenize izin vermez. Birden çok tepe noktası olan veri sayısal veri setlerinin dağılımını görselleştirmek için keman grafiği kullanılır. Yalnızca özet istatistikleri gösterebilen bir kutu grafiğinden farklı olarak, keman grafikleri özet istatistikleri ve her bir değişkenin yoğunluğunu gösterir. Şekil 3.2’de gösterilen keman grafiği örneğinde, beyaz nokta medyanı, merkezdeki kalın gri çubuk, çeyrekler arası değer aralığını, ince gri çizgi, çeyrekler arası değer aralığında yer alan aykırı değerler olarak belirlenen noktalar hariç, dağılımın geri kalanını temsil eder. Keman grafiği, çeyrek aralık kuralının (aykırı değerlerin varlığını tespit etmek için) uygulanabilmesi nedeni ile hızlı bir gösterim sunmak üzere tercih edilebilir.




Şekil 3.3 f_b_ic değişkeninin kutu, keman ve veri dağılımı grafiği

Şekil 3.3’de f_b_ic veri alanına yönelik olarak farklı gösterim yöntemleri kullanılarak veri alanının değer kümesi incelenmeye çalışılmıştır. Bu amaçla kutu grafiği, keman grafiği ve veri değerlerinin dağılımlarının görselleştirildiği sütun grafiği kullanılmıştır. Verinin yoğunlukla -0.5 ile 0.5 değerleri arasında yer aldığını, bir adet tepesinin olduğunu, ortalamasının 0 olduğunu, en küçük değerinin -2, en büyük değerinin 2 olduğunu, bu değerler dışında kalan değerlerin aykırı değer olarak değerlendirilebileceğini ifade etmektedir.

Pratikte birçok veri seti, analizleri kolaylaştırabilmek için farklı dağılımlar ile karşılaştırılır. Bilinen dağılımlara yönelik matematiksel eşitlikler elde etmek ve yorumlamak daha kolaydır. Bu amaçla kullanılan istatistiki veri görselleştirme araçlarından biri Q-Q (kantil-kantil) grafikleridir ⁴. Bir veri setindeki değerlerin teorik bir dağılımdan ne ölçüde ve nasıl saptığını keşfetmek ve oluşan bu farkı analiz etmek

⁴ Kantil ile ifade edilen, verinin yer aldığı yüzdelik dilimlerdir.

amacı ile görsel olarak değerlendirmek için bir araçtır. Veri setinin teorik kantillere göre kıyaslamasında elde edilen noktaların belirli bir çizgi üzerinde uzanması değerlendirilir.




Şekil 3.4 Normal dağılıma sahip Q-Q grafiği

Q-Q grafiğini oluşturabilmek için, veriler küçükten büyüğe doğru sıralanır. Sıralanmış veriler ile standart normal dağılımın tablo değerleri Şekil 3.4'te gösterildiği şekilde koordinat olarak grafikte gösterilir. Q-Q grafiğinde, sıralanmış veriler ile standart normal dağılımın tablo değerleri doğrusal bir çizgi üzerinde düzgün bir şekilde yer alıyorsa, verilerin Normal dağılıma sahip olduğu söylenebilmektedir. Benzer şekilde verilerin başka bir dağılımdan gelip gelmediğini test etmek için de kullanılır.


Q-Q grafikleri ayrıca bir dağılımın asimetrisini (çarpıklığını) bulmak için kullanılır. Q-Q grafiğinin alt ucu düz çizgiden sapıyor ama üst ucu sapmıyorsa, dağılımın solunda daha uzun bir kuyruğu olduğunu veya basitçe sola çarpık (veya negatif çarpık) olduğunu açıkça söyleyebiliriz, ancak düz çizgiden sapsak için Q-Q grafiğinin üst ucunu ve düz bir çizgiyi izleyen alt çizgiyi gördüğümüzde, o zaman eğri sağa doğru daha uzundur ve sağa çarpıktır (veya pozitif çarpıktır) olarak yorumlanabilir. Şekil 3.5'de normal

dağılıma sahip veri setlerine ait Q-Q grafiklerinin çarpıklık durumlarına yönelik örnekler gösterilmiştir.




Şekil 3.5 Q-Q grafiğinin çarpık durum örnekleri

Örneğin şekil 3.6’da f_b_ic veri alanının Q-Q grafiği incelendiğinde, normal dağılıma yakınsadığı (normal dağılmadığını), veri değerlerinin ortalamaya yaklaştıkça tepe noktası oluşturduğu söylenebilir. Bu özellikteki veri setleri ile bir model oluşturmadan önce ölçeklendirmenin ve aykırı değer içeren verileri temizlemenin daha iyi bir sonuç üretebileceği sonucuna varabiliriz.




Şekil 3.6 f_b_ic değişkeninin normal dağılıma göre Q-Q grafiği

Girdi değişkeni olan $f_ak_dogalgaz$ değişkeninin değerinin, diğer değişkenler ile birlikte görsel olarak nasıl değiştiğini anlayabilmek için, değerlerin birbirine ve zamana göre değişimleri incelenmiştir. Örneğin f_b_ic veri alanının $f_ak_dogalgaz$ değişkeninin değerinin değişimine göre görselleştirilmesi şekil 3.7’de ve şekil 3.8’de sunulmuştur. $f_ak_dogalgaz$ değerinin 0 ve 2500 değerlerine karşılık, f_b_ic değerinin -5 ve 5 değerleri aldığı görülmektedir. Buna göre ve şekil 3.3’de de belirtildiği üzere, f_b_ic değerinin $f_ak_dogalgaz$ değerinin yoğunlukla 2000 ve 2500 değer aralığı aldığı bölgede, f_b_ic veri alanının -2 ve 2 değer aralığında ölçüldüğü görülmektedir.




Şekil 3.7 f_b_ic değişkeninin $f_ak_dogalgaz_2$ değişkenine göre aldığı değerler




Şekil 3.8 f_b_ic değişkeninin f_ak_dogalgaz_2 değişkenine ile birlikte zamana göre değişimi

Veri setindeki veri alanlarının dağılımları incelenmiş, dağılımlarına yönelik görseller EK-9'da sunulmuştur. Girdi değişkeni olan doğalgaz değişkeninin şekil 3.9'da yer alan dağılım grafiği incelendiğinde, değişkenin değerinin büyük oranda 2000 ile 2500 değer aralığında yer aldığı, 0 ile 500 değer aralığında ise yeterli miktarda ısı üretemeyeceği gerçeğinden, aykırı değer olarak nitelendirilebileceği görülmektedir. 0 ile 2000 değer aralığında, üretimin yavaşlatıldığı (veya durdurulduğu), bakım ve temizleme faaliyetlerinin gerçekleştirildiği, bu değer aralığındaki doğalgaz miktarı ayarlamasının, ısıtma fırınının durmasına sebep olmadan gerçekleştirildiği bilinmektedir. Alan uzmanlarının ilettiği bilgi doğrultusunda doğalgaz değerinin 1500 ile 2500 aralığında gerçekleşen ve ısıtma fırını içerisinde üretime engel olmayacak ısı değişimlerine sebep olabilecek değişimlerin zaman zaman tasarruf amaçlı olarak gerçekleştirildiği belirtilmiştir.




Şekil 3.9 Doğalgaz (f_ak_dogalgaz_2) değişkenin dağılım grafiği

Girdi değişkeni olan f_ak_dogalgaz değişkeninin şekil 3.10’da verilen normal dağılıma göre Q-Q grafiği incelendiğinde, normal dağılıma yakınsamadığı ve veri değerleri içerisinde sağa dayalı bir dağılıma sahip olduğu söylenebilir.




Şekil 3.10 Doğalgaz (f_ak_dogalgaz_2) değişkenin Q-Q grafiği,


Şekil 3.11 ve şekil 3.17 arasında verilen dağılım grafikleri incelendiğinde, teorik_hava_ihtiyacı, ust_isil_deger, alt_isil_deger, f_g_boost_zon1, f_g_boost_zon2 ve f_y_baca_damperi_cetvel değişkenlerinin normal dağılıma sahip olmadıkları, ilgili değişkenler üzerinde çalışırken dikkat edilmesi gerektiği ortaya çıkmaktadır.




Şekil 3.11 teorik_hava_ihtiyacı değişkeninin dağılım grafiği




Şekil 3.12 ust_isil_deger değişkeninin dağılım grafiği




Şekil 3.13 alt_isil_deger değişkeninin dağılım grafiği




Şekil 3.14 f_g_boost_zon1 değişkeninin dağılım grafiği



Şekil 3.15 f_g_boost_zon2 değişkeninin dağılım grafiği




Şekil 3.16 f_y_baca_damperi_cetvel değişkeninin dağılım grafiği



Şekil 3.17 f_ag_bunker_sol değişkeninin dağılım grafiği


Nicel verilerin korelasyon analizi gerçekleştirildiğinde, çoklu değişkenler arasındaki korelasyon katsayılarının görselleştirildiği şekil 3.18’de gösterilen korelasyon ısı haritası matrisi elde edilmektedir. Korelasyon matrisi, değişkenler arasındaki

korelasyon katsayılarını gösteren bir tablodur. Tablodaki her hücre, iki değişken arasındaki korelasyonu gösterir. Veriler arasındaki ilişkiyi özetlemek için, gelişmiş bir analizlere girdi olarak korelasyon matrisi kullanılır. Korelasyon matrisi mantığı gereği kare şeklindedir ve değişkenler satırlarda ve sütunlarda gösterilir. Korelasyon matrisinde sol üst köşeden sağ alt köşeye olan tüm diagonal elemanlar eşit ve 1 değeri ile temsil edilmektedir, bu değer de her değişkenin her zaman kendisiyle en güçlü derecede ilişkili olduğunu gösterir. Korelasyon ısı haritası ise, belirli bir ölçekteki ilişkileri temsil etmek için renkli hücreler kullanılarak iki değişken arasındaki korelasyon bağlantısını görselleştiren bir ısı haritasıdır. Her bir hücrenin rengi, korelasyon değerine uyan değer ile orantılıdır. Normal bir ısı haritası gibi korelasyon ısı haritası, verileri kolayca okunabilir ve anlaşılabilir hale getiren bir renk çubuğu tarafından desteklenir. -1 ile 1 değeri arasında yer alan matris katsayıları, korelasyon ilişkisinin gücünü ve yönünü belirler. Açık sarı-yeşil tonları arasındaki renk skalası 0 ve 1 değerleri arasındaki pozitif korelasyonu, koyu mavi-yeşil tonları arasındaki renk skalası -1 ile 0 değerleri arasındaki negatif korelasyonu temsil eder. 1 değeri pozitif korelasyonun en güçlü olduğu değeri, -1 değeri ise negatif korelasyonun en güçlü olduğu değeri ifade etmektedir.




Şekil 3.18 Veri alanları korelasyon ısı haritası

Örneğin en yüksek pozitif korelasyon değeri 0.999989'a sahip f_y_yakma_havasi_2_kontrolu ve f_y_yakma_havasi_1_kontrolu_1fic0201.pida.op değişkenlerinin zamana göre değişimleri üst üste gelecek şekilde çizilerek şekil 3.19'da görselleştirilmiştir. İki değişkenin değişiminin aynı şekilde ve yönde gerçekleşmesi, korelasyon ısı haritasında açık sarı ile gösterildiği şekilde güçlü pozitif yönde birlikte hareket ettiklerini göstermektedir. Tüm değişkenlerin birbirleri ile olan korelasyon değerleri EK-12'de verilmiştir.



Şekil 3.19 f_y_yakma_havasi_2_kontrolu - f_y_yakma_havasi_1_kontrolu_1fic0201.pida.op değişkenlerinin zamana göre birlikte değişimleri

Benzer şekilde en düşük negatif korelasyon değeri -0.985832'a sahip f_s_rejenerator_dolgu_alti_sag ve f_s_rejenerator_dolgu_alti_sol değişkenlerinin zamana göre değişimleri üst üste gelecek şekilde çizilerek şekil 3.20'de görselleştirilmiştir. İki değişkenin değişiminin aynı şekilde ve tam zıt yönde gerçekleşmesi, korelasyon ısı haritasında koyu mavi ile gösterildiği şekilde güçlü negatif yönde birlikte hareket ettiklerini göstermektedir.



Şekil 3.20 f_s_rejenerator_dolgu_alti_sag - f_s_rejenerator_dolgu_alti_sol
değişkenlerinin zamana göre birlikte değişimleri

En yüksek 10 pozitif korelasyonların değerini içeren ikili dizisi ve değerleri Pandas kütüphanesinin veri yapısı olan veri çerçeveleri (*DataFrame*) için hazır olarak sunduğu korelasyon fonksiyonuna göre çizelge 3.3’de gösterilmiştir:

Çizelge 3.3 En yüksek 10 pozitif korelasyon

Veri Alanı-1	Veri Alanı-2	Korelasyon Değeri
f_y_yakma_havasi_1_kontrolu_1 fic0201.pida.op	f_y_yakma_havasi_2_kontrolu	0.999989
teorik_hava_ihtiyaci	ust_isil_deger	0.999969
ust_isil_deger	alt_isil_deger	0.999940
teorik_hava_ihtiyaci	alt_isil_deger	0.999870
f_y_harman_verici_sag_1lic0501. pida.op	f_y_harman_verici_sol	0.999536
f_ak_dogalgaz_2	f_y_vana_dogalgaz_akis_kontr ol_1fic0601.pida.pv	0.998691
f_y_yakma_havasi_1_kontrolu_1 fic0201.pida.pv	f_y_yakma_havasi_1_kontrolu _1fic0201.pida.sp	0.998381
f_ak_yakma_havasi	f_y_yakma_havasi_1_kontrolu _1fic0201.pida.pv	0.997125
f_ak_yakma_havasi	f_y_yakma_havasi_1_kontrolu _1fic0201.pida.sp	0.994914
f_s_rejeneratör_dolgu_alti_sag	f_s_rejeneratör_dolgu_alti_sol	0.985832


En düşük 10 negatif korelasyonların değerini içeren ikili dizisi ve değerleri çizelge 3.4'te gösterilmiştir:

Çizelge 3.4 En düşük 10 negatif korelasyon

Veri Alanı-1	Veri Alanı-2	Korelasyon Değeri
f_s_rejenerator_dolgu_alti_sag	f_s_rejenerator_dolgu_alti_sol	-0.985832
f_ak_dogalgaz_1	f_s_dogalgaz	-0.834138
f_b_dogalgaz	f_b_ic	-0.685728
f_s_rejenerator_dolgu_alti_sol	f_y_oksijen	-0.644124
f_s_rejenerator_sag	f_y_ic_basinc_damperi_cetvel	-0.634610
f_s_rejenerator_dolgu_ustu_sag	f_s_rejenerator_sag	-0.616867
f_s_rejenerator_dolgu_ustu_sag	f_y_oksijen	-0.612601
f_s_rejenerator_dolgu_alti_sol	f_s_rejenerator_dolgu_ustu_sol	-0.608547
f_s_rejenerator_sag	f_y_baca_damperi_cetvel	-0.605564
f_s_taban_245mm	f_y_vana_dogalgaz_akis_kontr	-0.604379

Çalışmanın temel amacı enerji tüketiminin azaltılması durumunda parametrelerin alacağı değerleri belirlemeye yöneliktir. Bu amaçla hedef (tahminlenecek) veri alanları belirlenerek, öncelikle regresyon analizleri gerçekleştirilmiş, regresyona uyumlu olmayan veri alanları için ise makine öğrenmesi yöntemleri ile modeller geliştirilmeye çalışılmıştır. Regresyon modellerinin istenilen sonuçları üretebilmeleri için, değişkenlerin birbirleri ile olan korelasyon durumları incelenmiştir.

EK-11’de gerçekleştirilen korelasyon çalışmalarında her değişken özelinde Ki-kare ve regresyon modellemeleri ile korelasyon katsayıları incelenmiştir. Örnek olarak teorik_hava_ihtiyacı değişkenine göre yapılan korelasyon analizlerinde şekil 3.21’de gösterildiği üzere iki değişkenin teorik_hava_ihtiyacı ile yüksek korelasyona sahip olduğu, bu değişkenlerin ust_isil_deger ve alt_isil_deger değişkenleri olduğu belirlenmiştir. Diğer değişkenler için gerçekleştirilen analizler EK-11’de yer almaktadır.



Şekil 3.21 teorik_hava_ihtiyacı'nın diğer değişkenler ile korelasyon analizi grafiği

Temel değişken olan 'f_ak_dogalgaz_2' değişkeninin değerinin değişiminin diğer değişkenler üzerindeki etkileri EK-6'da incelenmiştir. Gerçekleştirilen korelasyon çalışmaları sonucunda, girdi değişkeni olan 'f_ak_dogalgaz_2' değişkeninin doğrudan veya dolaylı olarak, diğer değişkenler ile ilişkisini, $f(x)$ şeklinde doğrusal veya doğrusal olmayan eşitlikler cinsinden ifade edilebilecek güçlü bir korelasyon bulunamadığı için, veri setinin zaman serisi özelliği taşıması nedeni ile UKSB ile modellenmeleri üzerine çalışma devam etmiştir.

EK-6'da yer alan çalışmalardaki görsellerde dikkat çeken 2 husus daha bulunmaktadır:

- Zaman serileri incelendiğinde 2020-04-01 tarihi ile 2020-04-12 tarihleri arasında ciddi veri kayıpları olduğu gözlemlenmiştir. Bu nedenle ilgili tarih aralığındaki veriler veri setinden çıkarılmıştır.
- Aşağıda listelenen veri alanlarının zaman serileri görselleri incelendiğinde ise, zaman serisi özelliği oluşturmak için yeterli olmadıkları (veri sayısı çok az, zaman içerisinde değişimleri çok değişken vb.), ve PÖ çevresinin, ajanı yanıltma olasılığı yüksek olan veri alanları olduğu gözlemlenmiştir. Bu alanlara yönelik yine de

UKSB modelleri geliştirilmiş, sonuçlar elde edilmiş, ancak aşağıda listelenen değişkenlere yönelik elde edilen tahmin sonuçları, çevre bileşeninin alt-üst değer kontrollerinden çıkarılmıştır.

- f_g_boost_zon1
- f_g_boost_zon2
- f_s_rejenerator_dolgu_alti_sag
- f_s_rejenerator_dolgu_alti_sol
- f_s_rejenerator_sag
- f_s_rejenerator_sol
- f_y_baca_damperi_cetvel
- f_y_harman_verici_sag_1lic0501_pida_op
- f_y_harman_verici_sol
- f_y_oksijen
- f_y_vana_dogalgaz_akis_kontrol_1fic0601_pida_pv
- f_y_vana_dogalgaz_akis_kontrol_1fic0601_pida_sp
- f_y_yakma_havasi_1_kontrolu_1fic0201_pida_sp

3.3.2 UKSB modelleri

‘f_ak_dogalgaz_2’ değişkeni ile güçlü korelasyona sahip olmayan veri alanlarının doğalgaz değişkeni ile ilişkisini öğrenebilmek için, veri seti zaman serisi olarak düzenlenerek (zaman türünde veri alanı eklenmesi ve zamana göre sıralanması), veri setinin %75’i ile öğrenme, %25’i ile doğrulama yapılacak şekilde, her bir değişkene yönelik 100 döngülük (turluk) UKSB eğitimi uygulanmış ve tüm UKSB modelleri kaydedilebilir model dosyası formatında kaydedilerek, PÖ çevresinin geliştirildiği Python uygulamasına yüklenerek kullanılmıştır.

Veri setlerindeki öğrenme süreçlerinin kayıpları EK-8’de yer alan grafikler ile görselleştirilmiştir. Örnek bir değişkene ait UKSB grafikleri sonraki paragraflarda yorumlanmış, diğer değişkenlere yönelik değerlendirmeler okuyucuya bırakılmıştır.

Model ile eğitilecek verinin ölçeklendirilmesi (*scaling*), hem algoritmanın hızlı çalışmasını sağladığı hem de başarımı arttırdığı için önerilmektedir. Aykırı değer (*outlier*) olarak isimlendirilen verilerin fazla olmadığı durumlarda kullanılmaktadır. UKSB modeli ile eğitilecek veri seti, ilgili verinin Eşitlik 13’te belirtildiği metod sayesinde (ölçekleme işlemi farklı yöntemler ile de gerçekleştirilebilmektedir) 0 ile 1 arasında değerler almasının sağlanması ile ölçeklendirilmiştir. Bu yöntem verinin dağılımını değiştirmemektedir.

$$(X_{ölçeklenmiş}) = \frac{X - \text{minimum}(X)}{\text{maksimum}(X) - \text{minimum}(X)} \quad (13)$$

Şekil 3.22’de örneklendiği üzere “Girdi verisi” ile bir pencere sırası UKSB modeli tarafından öğrenilerek, bu tür bir veri serisinden sonra elde edilecek “Çıktı”nın arasındaki bağlantı öğrenilmeye çalışılmaktadır.



Şekil 3.22 UKSB pencere sırası ilerlemesi

Eğitime firmanın veri setindeki değişkenlerinin verileri ile gerçekleştirilen UKSB eğitiminde 5 dakikalık verinin içerildiği kayan bir zaman penceresi üzerinden

ilerletilerek öğrenme gerçekleştirilmektedir (Pencere boyunun 5 dakika seçilmesinin nedeni, iki sensör arasındaki fiziksel mesafenin birbirini etkileme süresinin yaklaşık 5 dakika olduğunun alan uzmanları tarafından belirtilmiş olmasıdır).

UKSB modelleri girdi olarak 9 parametre ile eğitilmektedir: tahmin edilecek veri alanı için 4 adet 'f_ak_dogalgaz_2' girdisi, 4 adet girdiye karşılık 4 adet ilgili değişken değeri bilgisi ve son parametre olarak, bir sonraki 'f_ak_dogalgaz_2' değeri (doğalgaz miktarı) bilgisidir. Bu girdiler ile çıktı olan, ilgili parametrenin bir sonraki durumunun tahminlemesi yapılması amaçlanmaktadır.

Örnek girdi olarak, 4 adet 'f_ak_dogalgaz_2' (fad) değeri, 4 adet 'teorik_hava_ihtiyaci' (thi) ikilileri girdileri ile 1 adet 'f_ak_dogalgaz_2' (fad) ölçeklendirilmiş olarak aşağıdaki şekilde yer almaktadır. ⁵

1.fad – thi	2.fad – thi	3.fad – thi	4.fad – thi	5.fad – thi (?)
0.8797-0.3989	0.8929-0.3989	0.8890-0.3989	0.8764-0.3978	0.8824 - ?

UKSB modeli, 9'lu kayan pencere girdilerinin örüntülerini öğrenerek, çıktı olan 'teorik_hava_ihtiyaci' (thi) miktarını tahminlemeye çalışmaktadır. UKSB modelinin eğitiminde, 9'lu blokların öğrenimi, veri setinin %75 olarak ayrılan kısmında gerçekleşmektedir. %75'lik öğrenim veri seti üzerinde gerçekleştirilen tahminler ile gerçek değerler kıyaslanmakta, modelin eğitim başarısı regresyon ve zaman serisi problemlerinde sıkça kullanılan Ortalama Mutlak Hata - OMH (*Mean Absolute Error*) ile ölçülmektedir.

OMH iki sürekli değişken arasındaki farkın yönlerini dikkate almadan hataların ortalama büyüklüğünü ölçer. Eşitlik 14'de belirtildiği üzere tahmin değeri ile karşılık gelen gözlem (gerçek değer) arasındaki farkların mutlak değerlerinin ortalamasıdır. Bu değer in sıfıra yakın olması, modelin tahmin yeteneğinin iyi olduğu anlamına gelir.


⁵ fad kısaltması doğalgaz miktarı bilgisini içeren f_ak_dogalgaz_2 değişkeni için, thi kısaltması teorik_hava_ihtiyaci için kullanılmıştır.

$$OMH = \frac{1}{n} \sum_{k=1}^n |e_k| \quad \#(14)$$

EK-8’de, değişkenlerin, UKSB eğitim süreçlerinin başarımlarına ve her bir değişkenin model eğitimi ve doğrulaması için kullanılan veri miktarlarına erişilebilir.

Örnek olarak 38.674 veri satırı içeren teorik_hava_ihtiyaci değişkeninin veri seti, rastgele 29.006 (%75) veri satırı eğitim için, 9.668 (%25) veri satırı doğrulama için kullanılmak üzere ayrılmıştır. Gerçek veri setinden ilk 9 değer (4 adet f_ak_dogalgaz_2 değeri, 4 adet teorik_hava_ihtiyaci değeri, 1 adet f_ak_dogalgaz_2 değeri) alınarak normalize edilmesi sağlanmış ve [0,87971854 0,39892006 0,89294964 0,39892006 0,8890023 0,39892006 0,87642235 0,3978901 0,8824729] değerleri elde edilerek, başlangıç veri seti oluşturulmuştur. 9 adet veri içeren pencere her bir adımda ilerletilerek UKSB modelinin eğitimi sağlanmış, yine her bir adımda bir sonraki değer UKSB modeli ile tahmin edilmesi ile tahmin değeri elde edilmiştir. Gerçek değer ile tahmin değeri arasındaki fark ile OMH değerleri elde edilerek şekil 3.23’de görselleştirilen her bir tur için “Eğitim Hatası” olarak gösterilmiştir.


Her bir tur sonunda elde edilen modelin başarımlarını ölçmek için modelin eğitiminde kullanılmayan (modelin tecrübe etmediği) doğrulama veri seti üzerinden, tahmin yapması sağlanmış, bir sonraki değer UKSB modeli ile tahmin edilmesi ile tahmin değeri elde edilmiştir. Doğrulama veri setindeki gerçek değer ile tahmin değeri arasındaki fark ile OMH değerleri elde edilerek şekil 3.23’de her tur için “Doğrulama Hatası” olarak gösterilmiştir.



Şekil 3.23 teorik_hava_ihtiyaci UKSB Eğitim ve Doğrulama Hata Sonuçları Grafiği

Eğitim, 100 tur tamamlandığında bitirilmektedir. Bu nedenle her bir değişken ait modelin 100 tur eğitimi sonucunda elde edilen OMH değerleri EK-8’de belirtilmiştir. Örneğin teorik_hava_ihtiyaci değişkeninin UKSB modelinin 100 tur sonucunda Eğitim Hatası 0.0049 ve Doğrulama Hatası 0.0069 olarak gerçekleşmiştir. Bu sonuçların 0’a yakın olması modelin eğitiminin başarılı olduğunu, tahmin edilmek istenen sonucun gerçek değere yakınsayacağını göstermektedir.

Bir diğer örnek olarak f_ag_bunker_sol değişkeninin, 17737 satır eğitim verisi ve 5912 satır doğrulama verisi ile gerçekleştirilen eğitiminden elde edilen model başarımı, şekil 3.24’te verilen hata sonuçlarının yorumlanmasını gerektirmektedir. f_ag_bunker_sol değişkeninin UKSB modelinin 100 tur sonucunda Eğitim Hatası 0.0523 ve Doğrulama Hatası 0.3037 olarak gerçekleşmiştir. Grafik değerleri modelin başarılı olamadığını, model ile yapılacak tahminlerin aykırı değer tabir edilebilecek değerlere ulaşabileceğini göstermektedir. Bu nedenlerle f_ag_bunker_sol değişkeni çevre bileşeninden çıkarılmalıdır (tahmin değerleri ajan ile paylaşılmamalıdır), aksi durumda gerçekçi bir tahmin verisi üretemeyeceği için ajanı yanıltacaktır.



Şekil 3.24 f_ag_bunker_sol UKSB Eğitim Hata Sonuçları Grafiği

3.4 Pekiştirmeli Öğrenme Bileşenleri

PÖ metodolojisinin eğitime fırınından elde edilen veri seti üzerinde uygulanabilmesi için, çevre ve ajan bileşenleri ile durum ve ödül-ceza bilgilerinin tanımlanmaları gerekmektedir.

3.4.1 Çevre bileşeni

Çevre bileşeni içerisinde, eğitime fırınından elde edilen veri setinin oluşmasında, temel değişken (girdi) olan doğalgaz miktarının artırılıp azaltılması sırasında hangi aksiyonlara nasıl tepki vereceği tanımlanmaktadır. Çevre bileşenin tepkileri ise önceki analizlerde elde edilen karakteristiklerin (modellemelerin) eklenmesi sonucu oluşmaktadır.

PÖ'nün genel yaklaşım olarak enerji tüketiminin azaltılmasını destekleyecek şekilde kurgulanması sağlanmıştır. Bu amaçla enerji tüketimdeki düşüşü ödüllendiren,

tüketimdeki artışı cezalandıran bir mekanizma üzerinde ajanın öğrenim sürecinin gerçekleştirilmesi sağlanmıştır.

PÖ süreçleri içerisinde, çevre ajan ile ilişkisinde, ödül/ceza mekanizmasının ajan tarafından öğrenilmesini sağlamak için, doğru adımlar ödüllendirilirken, yanlış adımlar cezalandırılacak şekilde puanlama yapılır. Ajanın amacı, süreç boyunca en fazla ödülü kazanmaktır (ya da en fazla ödülü kazanacak aksiyonları öğrenmektir). Enerji değişimini simüle eden her bir değer değişimi düşüşü (doğalgaz miktarının azaltılması) için ajana +3 puan ödül verilmekte, her bir değer değişimi artışı için ajana -2 puan ceza verilmektedir. Verilen ödül/ceza bilgileri ile şekil 2.12’de belirtilen Q-Öğrenme algoritmasına girdi oluşturan Q-Tablosunun güncellenmesini sağlayarak, ajanın doğru değişimi seçmesine yardımcı olur. Adımların ödül/ceza değerleri seçilirken, ajanın döngü içerisinde toplayacağı ödül/ceza değerinin, döngünün sonunda elde edeceği değere etkisinin/oranının en az olması hedeflenir (Pandey vd. 2010, Matignon vd. 2006). Bu sayede döngü içerisinde yanlış karar vererek ceza alsa bile, doğru sonuca ulaştığında alacağı ödül miktarına etkisi az olacaktır. Ajana en büyük ceza (-1000 puan ceza) Ek-6’da belirtilen veri alanlarının en yüksek-en düşük değerlere ulaşması sonucunda verilmektedir. Bu değerler aynı zamanda çevrenin kısıtları olarak da değerlendirilebilir. Ajan, doğalgaz miktarını 1900 değerinin altında tuttuğu müddetçe, her adımda ajana +250 ödül puanı ek olarak verilmektedir.

3.4.1.1 Çevre bileşeni değişkenleri

Enerji tüketiminde tek girdi doğalgaz miktarıdır. Doğalgaz miktarı $f_{ak_dogalgaz_2}$ değişkeni içerisinde yer almaktadır. Çevre değişkenleri, doğalgaz miktarının değişiminden etkilenen diğer değişkenlerdir. Bu değişkenlerin davranışları, doğalgaz miktarındaki değişim sonucunda elde edilen değerler ile karakterize edilmekte ve çevre bileşeni tarafından ajana iletilmektedir.

Doğalgaz miktarı parametresinin ($f_{ak_dogalgaz_2}$) her bir adımında (değerin arttırılıp azaltılmasında), diğer parametrelerin değişimleri korelasyon analizleri sonucunda elde edilebilen denklemler veya herhangi kuvvetli bir korelasyon bulunmayan değişkenler

için UKSB makine öğrenmesi eğitimleri sonucunda zamana bağlı olarak değişimlerinin modellenmesi ile formüllenmiştir.

Ödül-ceza sistemi, ajanın, doğalgaz girdi miktarının düşük değerlere doğru hareket etmesini motive edici şekilde tasarlanmıştır. Beklenti, doğalgaz girdi miktarının olabildiğince düşük değerlerde sonuca ulaşmasını sağlayarak enerji tasarrufu sağlayabilmektir.

3.4.2 Ajan

Ajanın temel görevi, doğalgaz miktarını değiştirerek (arttırarak veya azaltarak) bu değişimden etkilenen diğer parametrelerin değerlerinin, kısıt olarak nitelendirilebilecek alt-üst değerlere erişmeden hareket etmeyi öğrenmektir. Buradaki öğrenme sürecinde, doğalgaz değerlerinin mümkün olduğunca düşük değerlerde kalması sağlanarak enerji tasarrufuna yönelik ajan öğrenimi ön plana çıkarılmaya çalışılmıştır.

Ajanın amacı en fazla puanı toplamayı öğrenmesidir. Ajan bu amaca yönelik olarak temel değişken olan doğalgaz değerini artırıp azaltmaktadır.

Ajan başlangıç seviyesi olarak, doğalgaz değerinin en yüksek değeri ile en küçük değerinin ortalaması olan 2200.00 değeri ile başlamaktadır. Bu değeri ilk döngülerde rastgele arttırıp azaltırken, bellekte biriken ödül ve cezalar doğrultusunda doğalgaz değerini azaltmayı öğrenmeye başlamaktadır.


Rastgele atılan ilk 500 adım (adım, doğalgaz değerinin her bir değişimidir) kaydedilerek, ajanın öğrenmesini sağlayacak yapay sinir ağının veri kümesi oluşturulmaya başlanmaktadır. Atılan adım ile ilgili verilerin yanı sıra, atılan adımın ödül/ceza değeri de yapay sinir ağının öğrenmesi için saklanmaktadır.

Bellekte kaydedilen adım sayısının, 500 adıma ulaşmasından sonra, yapay sinir ağı öğrenmesi başlamaktadır. Sürekli öğrenme sağlamak ve öğrenmeyi iyileştirmek için

toplamda 2000 adımlık bellek oluşturularak, 2000 adımdan rastgele 500 adım seçilerek yapay sinir ağının sürekli güncellenmesi sağlanmaktadır. Bu sayede yapay sinir ağının (ajanın) sonradan elde edilmiş olunan veriler ile de öğrenme sürecinin devamı sağlanmaktadır.

3.4.3 Optimizasyon algoritmaları

Makine öğrenmesi uygulamalarında, öğrenme işlemi temelde bir optimizasyon problemidir. Doğrusal olmayan problemlerin çözümünde optimum değeri bulmak için optimizasyon yöntemleri kullanılmaktadır. DÖ uygulamalarında yaygın olarak Stochastic Gradient Descent, Adagrad, Adadelat, Adam, Adamax gibi optimizasyon algoritmaları kullanılmaktadır. Bu algoritmalar arasında başarımlı ve hız bakımından farklılıklar bulunmaktadır. Şekil 3.25’de farklı optimizasyon algoritmalarının MNIST veri seti (el yazısıyla yazılmış rakamların resimlerinden oluşan veri seti) üzerindeki çalışma zamanı grafiği verilmiştir (Anonymous 2017). Adam optimizasyonu en çok kullanılan optimizasyon algoritmalarından biridir ve tez çalışmasında Adam optimizasyonu tercih edilmiştir.



Şekil 3.25 MNIST veriseti üzerinde optimizasyon grafikleri

Adam (*Adaptive Moment*) optimizasyon algoritması, düşük dereceli momentlerin uyarlanabilir tahminlerine dayanan, stokastik amaç fonksiyonlarının birinci dereceden gradyan tabanlı bir algoritmasıdır. Son zamanlarda DÖ uygulamaları için daha geniş bir şekilde benimsenen stokastik gradyan değerinin bir uzantısıdır ve eğitim verilerine dayalı yinelemeli ağ ağırlıklarını daha verimli bir şekilde güncellemek için klasik stokastik gradyan inişinin yerine kullanılabilmektedir.

Stokastik gradyan inişi, tüm ağırlık güncellemeleri için tek bir öğrenme oranını (alfa olarak adlandırılır) korur ve eğitim sırasında öğrenme oranı değişmez. Adam, daha hızlı yakınsamak için Momentum (yerel minimuma doğru ilerlemenin ilgili yönde stokastik gradyan inişinin hızlanması) ve Adaptive Learning Rate kullanır.

DÖ uygulamalarında parametrelerin güncellenmesi geriye yayılım (*backpropagation*) işlemi ile yapılmaktadır (Jozefowicz vd. 2015). Geriye yayılım işleminde bu güncelleme işi zincir kuralı (*chain rule*) olarak adlandırılan geriye doğru türev olarak farkın bulunması ve bulunan fark değerinin öğrenme oranı (*learning rate*) parametresiyle çarpılması, çıkan sonucun ağırlık değerlerinden çıkarılarak yeni ağırlık değerinin hesaplanmasıyla yapılmaktadır. Bu işlem esnasında kullanılan öğrenme oranı parametresi sabit değer olarak belirlenebilir, ya da adım adım artan bir değer olarak da belirlenebilir (örneğin belli bir öğrenme adımına kadar 0.001 o adımdan sonra 0.01 gibi) ya da adaptif olarak momentum değerine bağlı olarak belirlenebilir. Momentuma bağlı olarak belirlenen öğrenme hızı adaptif öğrenme oranı (*Adaptive Learning Rate*) olarak adlandırılır.

4. ARAŞTIRMA BULGULARI

Çalışmaya Tanımlayıcı Veri Analitiği ile başlanarak, veri setinin özellikleri ortaya çıkarılmaya çalışılmış, öznitelikler incelenerek çalışmadan doğru sonuç alınabilmesi için incelemeler gerçekleştirilmiştir.

4.1 Pekiştirmeli Öğrenme Modelinin Farklı Parametreler ile Eğitimi

Projede özgün çalışmanın temeli, eldeki veri setinin analiz edilmesi ile elde edilen sonuçlar ve eğitilen modeller doğrultusunda PÖ'nün çevre bileşeninin oluşturulması ve YSA'na sahip ajan ile etkileşime girmesidir.

Çevre bileşeni, doğru sonuca ulaşabilmek için doğru şekilde düzenlenmelidir. Bu çalışmada veri setini temsil eden parametreler belirlenerek, çevrenin tepki vermesi gereken, durum, ödül, aksiyonlar belirlenmiştir.

Veri setini temsil kabiliyetine sahip veri alanları incelendiğinde, problemi modelleyebilmek için doğalgaz miktarı girdi değişkeni olmak üzere diğer veri alanları üzerinden çalışma gerçekleştirilmiştir.

PÖ ajanının, doğalgaz değerinin değişimi, çevre bileşeninde var olan diğer değişkenleri etkileyerek, etkileşime girmelerini sağlamaktadır.

Orjinal veri seti, 1'er dakikalık aralıkla elde edilmiştir. Doğalgaz miktarındaki değişim düzenli olmamış, ardışık doğalgaz miktarlarının yaklaşık 0-50 birim arasındaki değişimlerden oluştuğu belirlenmiştir. Bu nedenle doğalgaz değişkeninin adım değeri (değişim değeri) sıra ile 50, 25, 10 ve 5 birimlik sabit değişimler ile 0-50 birim arasında rastgele değişim değeri ile incelemek üzere ajan çalıştırılmış, 100, 250 ve 500 turluk denemelerinin sonuçları incelenmiştir.


UKSB öğrenme sürecinde 50, 25, 10 ve 5 birimlik sabit değişim olmadığı için, eğitilen modelin tahminlemesi sonuçlarında, hedef değerler üretilirken hata payının büyümesi

beklenmelidir. Bu nedenle girdi değişkeni olan doğalgaz değerindeki azalma/artış, hedef değerlerin (minimum-maksimum değerleri arasında) olması gereken aralıktaymış gibi veri üretmesine neden olmaktadır.

Ek-6'da yer alan sınır değerlerinde görüleceği gibi parametrelerin alabilecekleri değer aralıkları incelenmiştir. Ajan, elde ettiği değerlerden herhangi birinin Ek-6'da yer alan sınırların dışına çıkması durumunda turu tamamlayarak, yeni bir tura başlamaktadır.

4.1.1 50 birimlik doğalgaz değişimi

Şekil 4.1, 50 birimlik sabit doğalgaz miktarı değişimleri ile 100 tur (döngü) sonunda, sonuca ulaşmaya çalışan ajanın, turları tamamladığında elde edebildiği doğalgaz değerleri ve ödül miktarlarını göstermektedir. Ajan, girdi olan doğalgaz parametresini her bir adımda 50 birim değiştirmektedir (arttırmakta veya azaltmaktadır). Bu adım karşılığında çevre, diğer parametre değerlerini belirleyerek (tahmin ederek) ajana bilgi vermektedir. Bu döngü bir adım olarak değerlendirildiğinde, girdi değeri ve elde edilen sonuçlar adım bilgisi olarak saklanmakta ve YSA'nın eğitimine girdi olarak sunulmaktadır. Bu döngü tüm turlar boyunca devam etmektedir.




Şekil 4.1 Doğalgaz ve ödül değerleri grafiği (50 birim/adım–100 Tur)

İlk turlarda ajan, ön belleği doldurmaya çalıştığı için rastgele olarak değişkeni değiştirmiştir. Hem ödül kazanamamış, hem de YSA kullanımı olmadığı için öğrenme gerçekleşmemiştir.


Ön belleğe yeterince adım kaydedildikten sonra yapay sinir ağı eğitimi ile öğrenme aşamaları başlamış, elde edilen ödül değerlerinde değişim yaşanmıştır. Bu da ajanın hatırlamaya başladığı (YSA'nın devreye girmesinin) sonucunu bize göstermektedir. Ödül miktarındaki değişimler, bazı turlarda ajanın yanlış adımı seçmesinden kaynaklanmaktadır. Turların sonuna doğru hata yapma oranı azalmış, ödül değer aralığında çok fazla değişim olmadığı görülmüştür.

Şekil 4.2, 50 birimlik sabit doğalgaz miktarı değişimleri ile 250 tur (döngü) sonunda, sonuca ulaşmaya çalışan ajanın, turları tamamladığında elde edebildiği doğalgaz değerleri ve ödül miktarlarını göstermektedir. Turlar ilerledikçe öğrenme miktarı artmış, hatalı adım kararları azalmıştır, ödül değeri sabit hale gelmeye başlamıştır. Bu da ilerleyen turlar içerisinde benzer adım kararlarını alarak benzer ödüller aldığını göstermektedir.



Şekil 4.2 Doğalgaz ve ödül değerleri grafiği (50 birim/adım–250 Tur)


Şekil 4.3, 50 birimlik sabit doğalgaz miktarı değişimleri ile 500 tur (döngü) sonunda, sonuca ulaşmaya çalışan ajanın, turları tamamladığında elde edebildiği doğalgaz değerleri ve ödül miktarlarını göstermektedir. Yaklaşık olarak 300 turdan sonra öğrenme tamamlanmış, adım kararları ve ödül değeri sabit hale gelmiştir.



Şekil 4.3 Doğalgaz ve ödül değerleri grafiği (50 birim/adım-500 Tur)

4.1.2 25 birimlik doğalgaz değişimi

Şekil 4.4, 25 birimlik sabit doğalgaz miktarı değişimleri ile 100 tur (döngü) sonunda, sonuca ulaşmaya çalışan ajanın, turları tamamladığında elde edebildiği doğalgaz değerleri ve ödül miktarlarını göstermektedir. Ajan, girdi olan doğalgaz parametresini her bir adımda 25 birim değiştirmektedir (arttırmakta veya azaltmaktadır).




Şekil 4.4 Doğalgaz ve ödül değerleri grafiği (25 birim/adım–100 Tur)

İlk turlarda ajan, ön belleği doldurmaya çalıştığı için rastgele olarak değişkeni değiştirmiştir. Hem ödül kazanamamış, hem YSA kullanımı olmadığı için öğrenme gerçekleşmemiştir.


Ön belleğe yeterince adım kaydedildikten sonra yapay sinir ağı eğitimi ile öğrenme aşamaları başlamış, elde edilen ödül değerlerinde değişim yaşanmıştır. Bu da ajanın hatırlamaya başladığı (YSA'nın devreye girmesinin) sonucunu bize göstermektedir. Ödül miktarındaki değişimler, bazı turlarda ajanın yanlış adımı seçmesinden kaynaklanmaktadır. Turların sonuna doğru hata yapma oranı azalmış, ödül değer aralığında çok fazla değişim olmadığı görülmüştür.

Şekil 4.5, 25 birimlik sabit doğalgaz miktarı değişimleri ile 250 tur (döngü) sonunda, sonuca ulaşmaya çalışan ajanın, turları tamamladığında elde edebildiği doğalgaz değerleri ve ödül miktarlarını göstermektedir. Turlar ilerledikçe öğrenme miktarı artmış, hatalı adım kararları azalmıştır, ödül değeri sabit hale gelmeye başlamıştır. Bu da ilerleyen turlar içerisinde benzer adım kararlarını alarak benzer ödüller aldığını göstermektedir.



Şekil 4.5 Doğalgaz ve ödül değerleri grafiği (25 birim/adım–250 Tur)


Şekil 4.6, 25 birimlik sabit doğalgaz miktarı değişimleri ile 500 tur (döngü) sonunda, sonuca ulaşmaya çalışan ajanın, turları tamamladığında elde edebildiği doğalgaz değerleri ve ödül miktarlarını göstermektedir. Yaklaşık olarak 200 turdan sonra öğrenme tamamlanmış, adım kararları ve ödül değeri sabit hale gelmiştir.



Şekil 4.6 Doğalgaz ve ödül değerleri grafiği (25 birim/adım–500 Tur)

4.1.3 10 birimlik doğalgaz değişimi

Şekil 4.7, 10 birimlik sabit doğalgaz miktarı değişimleri ile 100 tur (döngü) sonunda, sonuca ulaşmaya çalışan ajanın, turları tamamladığında elde edebildiği doğalgaz değerleri ve ödül miktarlarını göstermektedir. Ajan, girdi olan doğalgaz parametresini her bir adımda 10 birim değiştirmektedir (arttırmakta veya azaltmaktadır).




Şekil 4.7 Doğalgaz ve ödül değerleri grafiği (10 birim/adım–100 Tur)

İlk turlarda ajan, ön belleği doldurmaya çalıştığı için rastgele olarak değişkeni değiştirmiştir. Hem ödül kazanamamış, hem YSA kullanımı olmadığı için öğrenme gerçekleşmemiştir.


Ön belleğe yeterince adım kaydedildikten sonra yapay sinir ağı eğitimi ile öğrenme aşamaları başlamış, elde edilen ödül değerlerinde değişim yaşanmıştır. Bu da ajanın hatırlamaya başladığı (YSA'nın devreye girmesinin) sonucunu bize göstermektedir. Ödül miktarındaki değişimler, bazı turlarda ajanın yanlış adımı seçmesinden kaynaklanmaktadır. Turların sonuna doğru hata yapma oranı azalmış, ödül değer aralığında çok fazla değişim olmadığı görülmüştür.

Şekil 4.8, 10 birimlik sabit doğalgaz miktarı değişimleri ile 250 tur (döngü) sonunda, sonuca ulaşmaya çalışan ajanın, turları tamamladığında elde edebildiği doğalgaz değerleri ve ödül miktarlarını göstermektedir. Turlar ilerledikçe öğrenme miktarı artmış, hatalı adım kararları azalmıştır, ödül değeri sabit hale gelmeye başlamıştır. Bu da ilerleyen turlar içerisinde benzer adım kararlarını alarak benzer ödüller aldığını göstermektedir.



Şekil 4.8 Doğalgaz ve ödül değerleri grafiği (10 birim/adım–250 Tur)


Şekil 4.9, 10 birimlik sabit doğalgaz miktarı değişimleri ile 500 tur (döngü) sonunda, sonuca ulaşmaya çalışan ajanın, turları tamamladığında elde edebildiği doğalgaz değerleri ve ödül miktarlarını göstermektedir. Yaklaşık olarak 200 turdan sonra öğrenme tamamlanmış, adım kararları ve ödül değeri sabit hale gelmiştir.



Şekil 4.9 Doğalgaz ve ödül değerleri grafiği (10 birim/adım–500 Tur)

4.1.4 5 birimlik doğalgaz değişimi

Şekil 4.10, 5 birimlik sabit doğalgaz miktarı değişimleri ile 100 tur (döngü) sonunda, sonuca ulaşmaya çalışan ajanın, turları tamamladığında elde edebildiği doğalgaz değerleri ve ödül miktarlarını göstermektedir. Ajan, girdi olan doğalgaz parametresini her bir adımda 5 birim değiştirmektedir (arttırmakta veya azaltmaktadır).




Şekil 4.10 Doğalgaz ve ödül değerleri grafiği (5 birim/adım–100 Tur)

İlk turlarda ajan, ön belleği doldurmaya çalıştığı için rastgele olarak değişkeni değiştirmiştir. Hem ödül kazanamamış, hem de YSA kullanımı olmadığı için öğrenme gerçekleşmemiştir.


Ön belleğe yeterince adım kaydedildikten sonra yapay sinir ağı eğitimi ile öğrenme aşamaları başlamış, elde edilen ödül değerlerinde değişim yaşanmıştır. Bu da ajanın hatırlamaya başladığı (YSA'nın devreye girmesinin) sonucunu bize göstermektedir. Ödül miktarındaki değişimler, bazı turlarda ajanın yanlış adımı seçmesinden kaynaklanmaktadır. Turların sonuna doğru hata yapma oranı azalmış, ödül değer aralığında çok fazla değişim olmadığı görülmüştür.

Şekil 4.11, 5 birimlik sabit doğalgaz miktarı değişimleri ile 250 tur (döngü) sonunda, sonuca ulaşmaya çalışan ajanın, turları tamamladığında elde edebildiği doğalgaz değerleri ve ödül miktarlarını göstermektedir. Turlar ilerledikçe öğrenme miktarı artmış, hatalı adım kararları azalmıştır, ödül değeri sabit hale gelmeye başlamıştır. Bu da ilerleyen turlar içerisinde benzer adım kararlarını alarak benzer ödüller aldığını göstermektedir.



Şekil 4.11 Doğalgaz ve ödül değerleri grafiği (5 birim/adım–250 Tur)


Şekil 4.12, 5 birimlik sabit doğalgaz miktarı değişimleri ile 500 tur (döngü) sonunda, sonuca ulaşmaya çalışan ajanın, turları tamamladığında elde edebildiği doğalgaz değerleri ve ödül miktarlarını göstermektedir. Öğrenme tamamlanamamış, 500 tur döngüsü sonucunda bile yanlış adım kararları almıştır.



Şekil 4.12 Doğalgaz ve ödül değerleri grafiği (5 birim/adım–500 Tur)

4.1.5 0-50 aralığında değişken birimlik doğalgaz değişimi

Şekil 4.13, 0-50 birim aralığında rastgele doğalgaz miktarı değişimleri ile 100 tur (döngü) sonunda, sonuca ulaşmaya çalışan ajanın, turları tamamladığında elde edebildiği doğalgaz değerleri ve ödül miktarlarını göstermektedir. Ajan, girdi olan doğalgaz parametresini her bir adımda 0-50 birim aralığında rastgele birim değiştirmektedir (arttırmakta veya azaltmaktadır).




Şekil 4.13 Doğalgaz ve ödül değerleri grafiği (0-50 birim/adım–100 Tur)

İlk turlarda ajan, ön belleği doldurmaya çalıştığı için rastgele olarak değişkeni değiştirmiştir. Hem ödül kazanamamış, hem de YSA kullanımı olmadığı için öğrenme gerçekleşmemiştir.


Ön belleğe yeterince adım kaydedildikten sonra yapay sinir ağı eğitimi ile öğrenme aşamaları başlamış, elde edilen ödül değerlerinde değişim yaşanmıştır. Bu da ajanın hatırlamaya başladığı (YSA'nın devreye girmesinin) sonucunu bize göstermektedir. Ödül miktarındaki değişimler, bazı turlarda ajanın yanlış adımı seçmesinden kaynaklanmaktadır. Turların sonuna doğru hata yapma oranı azalmış, ödül değer aralığında çok fazla değişim olmadığı görülmüştür.

Şekil 4.14, 0-50 birim aralığında değişken doğalgaz miktarı değişimleri ile 250 tur (döngü) sonunda, sonuca ulaşmaya çalışan ajanın, turları tamamladığında elde edebildiği doğalgaz değerleri ve ödül miktarlarını göstermektedir. Turlar ilerledikçe öğrenme miktarı artmış, hatalı adım kararları azalmıştır, ödül değeri sabit hale gelmeye başlamıştır. Bu da ilerleyen turlar içerisinde benzer adım kararlarını alarak benzer ödüller aldığını göstermektedir.



Şekil 4.14 Doğalgaz ve ödül değerleri grafiği (0-50 birim/adım–250 Tur)

Şekil 4.15, 0-50 birim aralığında değişken doğalgaz miktarı değişimleri ile 500 tur (döngü) sonunda, sonuca ulaşmaya çalışan ajanın, turları tamamladığında elde edebildiği doğalgaz değerleri ve ödül miktarlarını göstermektedir. Yaklaşık olarak 50 turdan sonra öğrenme tamamlanmış, adım kararları ve ödül değeri sabit hale gelmiştir.



Şekil 4.15 Doğalgaz ve ödül değerleri grafiği (0-50 birim/adım-500 Tur)

4.1.6 Doğalgaz değerleri değişim sonuçları

5, 10, 25, 50 sabit birimlik ve değişken birimlik değişimlerin, 100, 250 ve 500 tur ile yapılan deneylerin sonucunda elde edilen parametre setleri EK-7’de sunulmuştur.

Gözlem sonuçlarında sabit aralıklarla doğalgaz değişiminin, belirli parametre kısıtlarına takıldığı, değişken aralıklı deneyin ise optimum parametre sonuçlarına daha çok yakınsayarak, enerji verimini arttırdığı gözlemlenmiştir. Çizelge 4.1’de verilen gözlem sonuçlarına göre, en düşük doğalgaz değerleri değişken aralıklı deneyin sonucunda elde edilirken, sabit aralıklarla doğalgaz değişiminin sonuçlarının en düşük değerlerinin belirli kısıtları aşmadığı özetlenmiştir.

Çizelge 4.1 Gözlem sonuçlarının doğalgaz miktarı özelinde özeti

	f_ak_dogalgaz_2 değeri		f_ak_dogalgaz_2 değeri		f_ak_dogalgaz_2 değeri		f_ak_dogalgaz_2 değeri		f_ak_dogalgaz_2 değeri
Değişken Birim (100 tur)	1708.00	5 Birim (100 tur)	1820.00	10 Birim (100 tur)	1745.00	25 Birim (100 tur)	1725.00	50 Birim (100 tur)	1725.00
Değişken Birim (250 tur)	1701.00	5 Birim (250 tur)	1815.00	10 Birim (250 tur)	1745.00	25 Birim (250 tur)	1725.00	50 Birim (250 tur)	1725.00
Değişken Birim (500 tur)	1701.00	5 Birim (500 tur)	1815.00	10 Birim (500 tur)	1745.00	25 Birim (500 tur)	1725.00	50 Birim (500 tur)	1725.00

5. SONUÇ

Enerji ihtiyacının her geçen gün arttığı endüstri çağında, enerji tüketen her kullanıcının verimliliği arttırıcı, tüketimi azaltıcı faktörleri ortaya koyarak, doğal kaynakların doğru kullanımında yer almaları önemlidir.

Çalışmada doğalgaz miktarının değişiminin, diğer değişkenler üzerindeki etkisinin gözlemlenebilmesi için modeller geliştirilmiş, YZ teknikleri kullanılarak en uygun enerji tüketiminin, endüstriyel kullanım ortamını en iyileyecek parametre değerlerine ulaşması sağlanmaya çalışılmıştır.

Tez çalışması sırasında endüstriyel (geleneksel) optimizasyon tekniklerinin sonuçlarının elde edilerek, PÖ ile bulunan çözüm ile karşılaştırılmasının yapılması mümkün olmamıştır. Doğalgaz değeri ile pek çok değişken arasında matematiksel bir ilişki bulunamamıştır. Ayrıca zamanın etkisinin optimizasyon algoritmalarına yansıtılması, zaten karmaşık olacağı düşünülen matematik denklemlerinin içinden çıkılmaz bir hesaplama karmaşıklığına neden olacağı değerlendirilmiştir.

Ajan, doğalgaz değişkenini değiştirme aralığını azalttığında, hedefe daha küçük adımlarda ilerleyeceği için daha iyi öğrenmeye başlayarak sonuca ulaşmakta, son değer kümesini elde etmede hassasiyeti artmaya başlamaktadır. Öğrenmenin ilerleyen turlarında, ajanın en düşük doğalgaz değerine yaklaşmak için öğrendiği adım serisi netleşmeye başladığı için ödül sabitlenmeye başlamıştır. Bu da sonuca giden yolu öğrendiğini göstermektedir.

Enerji tüketimine yönelik olarak düşük doğalgaz değerlerinin düşük enerji ihtiyacı olduğu varsayımından yola çıkılarak geliştirilen çevre ve bu çevrede belirlenen kurallar doğrultusunda hareket eden ajanın etkileşimi sonucunda; ajanın düşük doğalgaz miktarlarını elde etmeye yönelik olarak ilerlemeyi öğrendiği görülmektedir.

Orjinal veri seti ile elde edilen optimum parametre seti birlikte incelendiğinde, belirlenen alt/üst değer kısıtları içerisinde, ergitme fırınında %15 üzerinde enerji

tasarrufu sağlandığı görülmektedir. Bu değerlerin çalışma zamanında ertitme fırınında denenerek doğruluğunun/geçerliliğinin test edilmesi bir başka çalışmanın konusu olabilir. Ayrıca EK-7’de yer alan deney sonuçlarının özetlendiği çizelge 5.1 doğrultusunda, orjinal veri setindeki minimum ve maksimum değerleri içerisinde, deney sonucunda elde edilen parametreler incelendiğinde, yüksek sıcaklık kayıplarına neden olmadan kullanılan doğalgaz miktarının azaltılabileceği ortaya çıkarılmıştır. Çalışmanın sonuç odaklı gerçekleştirilmiş olması, süreç içerisinde gözlem yapılmasını bir miktar kısıtlamıştır. Elde edilen düşük doğalgaz miktarının sonucu kadar hangi adımların uygulanarak sonuca varıldığı da önemlidir. Her deneydeki tur sonuçları kaydedilmiş olmakla birlikte, her tur içerisindeki doğalgaz miktarının değişimleri uygulama çıktısı olarak bırakılmıştır. Çalışmanın avantajlarından birisi olarak, ileride yeni parametrelerin eklenmesi durumunda, yeni parametrelerin çalışmaya dâhil edilmesinin ve sonuçların elde edilmesinin kolay olacağı söylenebilir.

Çizelge 5.1 Gözlem sonuçlarının özeti

Parametre	Minimum Değer	Maksimum Değer	Değişken Birim (500 tur)
f_ak_dogalgaz_2	-	2600.00	1701.00
ust_isil_deger	9298.74	9812.37	9502.11
teorik_hava_ihtiyaci	9.81	10.35	10.02
alt_isil_deger	8383.54	8860.34	8575.56
f_ak_yakma_havasi	18364.33	25445.52	23066.40
f_ag_bunker_sag	0.18	35.92	27.09
f_ag_bunker_sol	0.00	32.93	2.00
f_ak_dogalgaz_1	0.02	0.74	0.29
f_b_dogalgaz	391.15	1134.79	645.70
f_b_enstruman_hava	4.51	5.60	4.91
f_b_ic	-1.00	5.25	-0.52
f_b_yakma_havasi	1.40	3.07	2.34
f_g_boost_zon2	0.00	1356.00	140.73
f_s_baca_kanali_alt	489.80	542.99	502.42
f_s_baca_kanali_orta	346.91	520.91	424.36
f_s_dogalgaz	7.97	38.10	33.88
f_s_firin_kemer_801	1437.90	1472.90	1461.07
f_s_firin_kemer_803	1526.50	1577.10	1555.76
f_s_firin_kemer_804	1502.20	1564.10	1528.99
f_s_rejenerator_dolgu_alti_sag	72.36	690.73	274.07

Çizelge 5.1 Gözlem sonuçlarının özeti (devam)

Parametre	Minimum Değer	Maksimum Değer	Değişken Birim (500 tur)
f_s_rejenerator_dolgu_alti_sol	58.09	682.45	165.42
f_s_rejenerator_dolgu_ustu_sag	976.50	1069.06	1001.66
f_s_rejenerator_dolgu_ustu_sol	1010.20	1079.23	1046.91
f_s_rejenerator_sag	100.85	1589.50	1037.73
f_s_rejenerator_sol	100.90	1599.91	1265.25
f_s_sag_onduvar	1384.50	1427.72	1402.93
f_s_sag_yanduvar_arka	1313.73	1340.30	1339.84
f_s_sag_yanduvar_orta	1354.90	1384.70	1359.29
f_s_sol_onduvar	1347.20	1391.50	1366.37
f_s_sol_yanduvar_arka	1367.20	1392.20	1387.72
f_s_sol_yanduvar_orta	1383.30	1411.80	1407.44
f_s_taban_245mm	1252.56	1266.80	1263.13
f_s_taban_25mm	1375.90	1401.20	1392.59
f_s_taban_cam_ici	1319.80	1400.80	1311.91
f_s_throat	1363.80	1406.50	1383.27
f_se_cam	-2.01	2.48	-0.13
f_y_baca_damperi_cetvel	5.68	63.81	5.88
f_y_harman_verici_sag_1lic0501_pida_op	2.00	100.00	11.61
f_y_harman_verici_sag_1lic0501_pida_pv	-2.12	2.29	-0.08
f_y_harman_verici_sol	2.00	100.00	14.55
f_y_ic_basinc_damperi_cetvel	13.11	98.19	35.65
f_y_oksijen	1.61	21.00	2.31
f_y_vana_dogalgaz_akis_kontrol_1fic0601_pida_op	51.65	63.30	54.68
f_y_vana_dogalgaz_akis_kontrol_1fic0601_pida_pv	105.56	2456.77	1748.97
f_y_vana_dogalgaz_akis_kontrol_1fic0601_pida_sp	2098.71	2443.10	2274.22
f_y_yakma_havasi_1_kontrolu_1fic0201_pida_op	59.28	79.79	72.16
f_y_yakma_havasi_1_kontrolu_1fic0201_pida_pv	18586.76	25106.67	23139.60
f_y_yakma_havasi_1_kontrolu_1fic0201_pida_sp	20987.08	24919.63	22319.43
f_y_yakma_havasi_2_kontrolu	59.28	79.79	74.26

Düşük enerji kullanımına (enerji tasarrufu) yönelik olarak doğalgaz değerine bağlı olarak diğer veri alanlarının optimum değer aralığının belirlenmesi çalışması, kısıtlı bir veri kümesi ile gerçekleştirilmiştir. İlerleyen çalışmalarda, yeni veri setleri ve daha uzun süre toplanmış olan veriler doğrultusunda çalışma tekrarlanabilir.

Ayrıca EK-13 içerisinde, veri setinin farklı oranlarda eğitim ve test amaçlı kullanılmasına yönelik çalışma gerçekleştirilmiştir. Deney aşağıdaki durumlar için tekrarlanmış ve sonuçları karşılaştırmalı olarak sunulmuştur:

- Veri setinin %80'i ile öğrenme, %20'si ile doğrulama yapılarak UKSB modelleri elde edilmiş, 0-50 birim aralığında rastgele doğalgaz miktarı değişimleri ile 100, 250 ve 500 tur (döngü) ile deney tekrar edilmiştir.
- Veri setinin %75'i ile öğrenme, %25'si ile doğrulama yapılmak üzere veri seti içerisinde rastgele örneklem alınarak UKSB modelleri elde edilmiş, 0-50 birim aralığında rastgele doğalgaz miktarı değişimleri ile 100, 250 ve 500 tur (döngü) ile deney tekrar edilmiştir.
- veri setinin %75'i ile öğrenme, %25'si ile doğrulama yapılmak üzere veri seti içerisinde 10 kayan pencere şeklinde eğitim gerçekleştirilerek UKSB modelleri elde edilmiş, en iyi sonucu veren model belirlenmiş, 0-50 birim aralığında rastgele doğalgaz miktarı değişimleri ile 100, 250 ve 500 tur (döngü) ile deney tekrar edilmiştir.

Deney sonuçları incelendiğinde, UKSB model eğitimlerinde benzer başarımlar elde edildiği ve deney sonuçlarında benzer enerji tüketim verimliliği ile sonuçlandığı gözlemlenmiştir.

KAYNAKLAR

- Al-Jilawi, A., 2019, Solving the Semidefinite Programming Relaxation of Max-cut Using an Augmented Lagrangian Method. Northern Illinois University.
- Anonim, Sürdürülebilirlik Raporu, 2018, Trakya Cam Sanayii A.Ş., Web Sitesi: https://www.sisecam.com.tr/tr/Documents/surdurulebilirlik/arsiv/duzcam/Duzcam_2018_Surdurulebilirlik_Raporu_TR.pdf , Erişim Tarihi: 10.03.2022.
- Anonim, Enerji Piyasası Düzenleme Kurumu, Strateji Geliştirme Dairesi Başkanlığı, Ankara 2021, Doğalgaz Piyasası 2020 yılı Sektör Raporu, Web Sitesi: <https://www.epdk.gov.tr/Detay/Icerik/3-0-94/dogal-gazyillik-sektor-raporu> Erişim Tarihi: 12.04.2022.
- Anonymous. 2017. Web Sitesi: <https://machinelearningmastery.com/adam-optimization-algorithm-for-deep-learning/> , Erişim tarihi: 17.01.2022
- Arrieta, A. B., Díaz-Rodríguez, N., Del Ser, J., Bennetot, A., Tabik S., Barbado, A., Garcia, S., Gil-Lopez, S., Molina, D., Benjamins, R., Chatila, R., Herrera, F., 2020, Explainable Artificial Intelligence (XAI): Concepts, taxonomies, opportunities and challenges toward responsible AI, Information Fusion, Volume 58, Pages 82-115.
- Başaran, T., 1997, Roma Dönemi Hypokaust Sisteminin, Isıl Analiz Yönünden, Günümüz Yerden Isıtma Sistemiyle Karşılaştırılması, Makine Mühendisleri Odası, 3. Ulusal Tesisat Mühendisliği Kongresi ve Sergisi
- Bengio, Y., Simard, P., & Frasconi, P., 1994, Learning long-term dependencies with gradient descent is difficult. IEEE Transactions on Neural Networks, 5(2), 157-166.
- Bostrom N., 2006, How long before superintelligence, Linguistic and Philosophical Investigations, pp. 11-30.
- Carvalho, D.V., Pereira, E.M., Cardoso, J.S., 2019, Machine learning interpretability: A survey on methods and metrics. Electronics, 8: 1–34, İsviçre.
- Castelvecchi D., 2016, Can we open the black box of AI?, Nature News, 538 (7623), p. 20.
- Chattopadhyay, S., Nelson, N., Au, A., Morales, N., Sanchez, C., Pandita, R., Sarma, A., 2020, A Tale from the Trenches: Cognitive Biases and Software Development. In 42nd International Conference on Software Engineering (ICSE '20), May 23–29, 2020, Seoul, Republic of Korea ACM, New York, NY, USA, 12 pages. <https://doi.org/10.1145/3377811.3380330>
- Che, Z., Purushotham, S., Cho, K., Sontag, D., & Liu, Y., 2018, Recurrent neural networks for multivariate time series with missing values. Scientific reports, 8(1), 1-12.

- Chrisman, L., 1992, Reinforcement learning with perceptual aliasing: The perceptual distinctions approach. In Proc. of the 10th National Conf. on AI AAAI Press.
- Du, Y., Ruszczyński, A., 2017, Rate of convergence of the bundle method. *Journal of Optimization Theory and Applications*, 173(3), 908-922.
- Gass, S.I., Assad, A.A., 2004, *Annotated Timeline of Operations Research: An Informal History*, Springer-Verlag New York, NY.
- Girasa, R., 2020, AI as a Disruptive Technology. In: *Artificial Intelligence as a Disruptive Technology*. Palgrave Macmillan, Cham. https://doi.org/10.1007/978-3-030-35975-1_1 , ISBN 978-3-030-35974-4
- Gottfredson L.S., 1997, *Mainstream Science on Intelligence : An Editorial With 52 Signatories, History and Bibliography* / Linda S. Gottfredson. - Ablex Publishing Corporation.
- Guan, Y., Li, S. E., Duan, J., Li, J., Ren, Y., Sun, Q., Cheng, B., 2021, Direct and indirect reinforcement learning. *International Journal of Intelligent Systems*, 36(8), 4439-4467.
- Gunning, D., 2017, *Explainable artificial intelligence (XAI)*, Technical Report, Defense Advanced Research Projects Agency (DARPA)
- Hochba, D. S. (Ed.), 1997, *Approximation algorithms for NP-hard problems*. ACM Sigact News, 28(2), 40-52.
- Hochreiter, S., Schmidhuber, J., 1997, Long short-term memory. *Neural Computation* 1997, Issue 8 Volume 9, 1735–1780. <https://doi.org/10.1162/neco.1997.9.8.1735>
- Hu, Y., Wei, R., Yang, Y., Li, X., Huang, Z., Liu, Y., He, C., Lu, H., 2022, Performance Degradation Prediction Using LSTM with Optimized Parameters. *Sensors*, 22, 2407. <https://doi.org/10.3390/s22062407>
- Jobin, A., Ienca, M. and Vayena, E., 2019, The global landscape of AI ethics guidelines, *Nature Machine Intelligence*, Vol. 1 No. 9, pp. 389-399, <https://doi.org/10.1038/s42256-019-0088-2>
- Jozefowicz, R., Zaremba, W., Sutskever, I., 2015, An Empirical Exploration of Recurrent Network Architectures, *Proceedings of the 32 nd International Conference on Machine Learning*, Lille, France, JMLR: W&CP volume 37.
- Lin, L.J, Mitchell, T., 1993, Reinforcement learning with hidden states. In Proc. of the 2nd Int. Conf. on Simulation of Adaptive Behavior. MIT Press.
- Marshan A., 2021, Artificial intelligence: Explainability, ethical issues and bias. *Ann Robot Automation* 5(1): 034-037. DOI: 10.17352/ara.000011

- Matignon, L., Laurent, G., Fort-Piat, N., 2006, Reward Function and Initial Values: Better Choices for Accelerated Goal-Directed Reinforcement Learning, Lecture Notes in Computer Science. 10.1007/11840817_87.
- Morgan, F.E, Boudreaux, B., Lohn, A.J., Ashby, M., Curriden, C., Klima, K., Grossman, D., 2020. Military Applications of Artificial Intelligence, Ethical Concerns in an Uncertain World, ISBN: 978-1-9774-0492-3
- Mouzon G. vd. 2007. Operational methods for minimization of energy consumption of manufacturing equipment. International Journal of Production Research 45(18-19): 4247-4271.
- O’Neil, C., 2017. Weapons of Math Destruction: How Big Data Increases Inequality and Threatens Democracy, Penguin Books.
- Pandey P., Kumar, S., Pandey D., 2010, Reinforcement Learning by Comparing Immediate Reward, (IJCSIS) International Journal of Computer Science and Information Security, Vol. 8, No. 5, August 2010.
- Pascanu, R., Mikolov, T., Bengio, Y., 2013, On the difficulty of training recurrent neural networks. International Conference Machine Learning Atlanta, Georgia, USA, 1310–1318.
- Pineda, F. J., 1988, Generalization of back-propagation to recurrent neural networks. American Institute of Physics., 602–611
- Ross, M. 1992. Efficient energy use in manufacturing. In Proc. Nat. Acad. Sci. USA 89: 827-831.
- Said, T., Saadia, B., Lmzouari Y., Jaafar, A., 2020, Artificial Intelligence for Improving the Optimization of NP-Hard Problems: A Review, International Journal of Advanced Trends in Computer Science and Engineering. Volume 9, No.5, pp 7411 – 7420, <https://doi.org/10.30534/ijatcse/2020/73952020>, ISSN 2278-3091
- Schmidhuber, J., 1991, Curious model-building control systems. In Proc. of IJCNN'91, volume 2, pages 1458-1463, Singapore.
- Schmidt, R.M, 2019, Recurrent Neural Networks (RNNs): A gentle Introduction and Overview, <https://doi.org/10.48550/arXiv.1912.05911>
- Sutton, R. S., Barto, A. G., 1998, Reinforcement Learning: An Introduction MIT press Cambridge, Vol. 135.
- Sutton, R. S., Barto, A. G., 2018, Reinforcement Learning: An Introduction, The MIT Press Cambridge, Massachusetts London, England, ISBN 978-0262039246.
- Tacconi, L., Rodwell, L. 2000. Biodiversity and ecological economics- participation, values and resource management. London: Earthscan Publications Ltd.

- Turing, A. M., 1948, Intelligent machinery, a heretical theory. The Turing Test: Verbal Behavior as the Hallmark of Intelligence, 105.
- Vijayaprabakaran, K., Sathiyamurthy, K., 2020, Towards activation function search for long short-term model network: A differential evolution based approach, Journal of King Saud University - Computer and Information Sciences, ISSN 1319-1578, <https://doi.org/10.1016/j.jksuci.2020.04.015>.
- Winston, W.L., 2003, Operations Research: Applications and Algorithms, 4. baskı, International Thomson Publishing, Belmont, CA.
- Yang, Y., Whinston, A.B., 2020, A survey on reinforcement learning for combinatorial optimization. CoRR, abs/2008.12248.
- Zhao, J., Ma L., Zayed, M.E., Elsheikh, A.H., Li, W., Yan, Q., Wang, J., 2021, Industrial reheating furnaces: A review of energy efficiency assessments, waste heat recovery potentials, heating process characteristics and perspectives for steel industry, Process Safety and Environmental Protection, Volume 147, Pages 1209-1228, ISSN 0957-5820, <https://doi.org/10.1016/j.psep.2021.01.045>.
- Zhu, J., Liapis, A., Risi, S., Bidarra, R., Youngblood, G.M., 2018, Explainable AI for designers: A humancentered perspective on mixed-initiative co-creation, 2018 IEEE Conference on Computational Intelligence and Games (CIG), pp. 1-8

EKLER

EK 1 PYTHON YAZILIM DİLİ KÜTÜPHANE VE ÇERÇEVE VERSİYONLARI LİSTESİ

EK 2 KAYNAK KOD

Kaynak kodlar ve çalışmada yer alan çıktılar, CD’de verilmiştir ve ek olarak https://github.com/mucakir/firin_PO_tez_calismalari linkinde yer almaktadır.

EK 3 VERİ SETİNDEKİ VERİ ALANLARININ LİSTESİ

EK 4 VERİ İÇERMİYEN VERİ ALANLARININ LİSTESİ

EK 5 KATEGORİK VERİ İÇEREN VERİ ALANLARININ LİSTESİ

EK 6 VERİ SETİ İÇERİSİNDEKİ VERİ ALANLARININ TEMEL İSTATİSTİK DEĞERLERİ

EK 7 DENEY SONUÇLARI

EK 8 UKSB EĞİTİMİ SONUÇLARI

EK 9 DEĞİŞKENLERİN DAĞILIM GRAFİKLERİ

EK 10 HAM VE İNDİRGENMİŞ VERİ TEMEL İSTATİSTİKLERİ

EK 11 KORELASYON ÇALIŞMALARI

EK 12 KORELASYON TABLOSU

EK 13 EK ÇALIŞMALAR