



**KÜKÜRT GİDERME İŞLEMİ İÇİN KULLANILAN
MALZEME MİKTARININ MAKİNE ÖĞRENME
YÖNTEMLERİ İLE TAHMİNİ**

Esra ÖZCAN

**2021
YÜKSEK LİSANS TEZİ
BİLGİSAYAR MÜHENDİSLİĞİ**

**Tez Danışmanı
Dr. Öğr. Üyesi Emrullah SONUÇ**

**KÜKÜRT GİDERME İŞLEMİ İÇİN KULLANILAN MALZEME
MİKTARININ MAKİNE ÖĞRENME YÖNTEMLERİ İLE TAHMİNİ**

Esra ÖZCAN

**T.C.
Karabük Üniversitesi
Lisansüstü Eğitim Enstitüsü
Bilgisayar Mühendisliği Anabilim Dalında
Yüksek Lisans Tezi
Olarak Hazırlanmıştır**

**Tez Danışmanı
Dr. Öğr. Üyesi Emrullah SONUÇ**

**KARABÜK
Haziran 2021**

Esra ÖZCAN tarafından hazırlanan “KÜKÜRT GİDERME İŞLEMİ İÇİN KULLANILAN MALZEME MİKTARININ MAKİNE ÖĞRENME YÖNTEMLERİ İLE TAHMİNİ” başlıklı bu tezin Yüksek Lisans Tezi olarak uygun olduğunu onaylarım.

Dr. Öğr. Üyesi Emrullah SONUÇ

.....

Tez Danışmanı, Bilgisayar Mühendisliği Anabilim Dalı

Bu çalışma, jürimiz tarafından Oy Birliği ile Bilgisayar Mühendisliği Anabilim Dalında Yüksek Lisans tezi olarak kabul edilmiştir. 30/06/2021

Ünvanı, Adı SOYADI (Kurumu)

İmzası

Başkan : Doç. Dr. Ümit ATILA (GÜ)

.....

Üye : Dr. Öğr. Üyesi Kasım ÖZACAR (KBÜ)

.....

Üye : Dr. Öğr. Üyesi Emrullah SONUÇ (KBÜ)

.....

KBÜ Lisansüstü Eğitim Enstitüsü Yönetim Kurulu, bu tez ile, Yüksek Lisans derecesini onamıştır.

Prof. Dr. Hasan SOLMAZ

.....

Lisansüstü Eğitim Enstitüsü Müdürü

“Bu tezdeki tüm bilgilerin akademik kurallara ve etik ilkelere uygun olarak elde edildiğini ve sunulduğunu; ayrıca bu kuralların ve ilkelerin gerektirdiği şekilde, bu çalışmadan kaynaklanmayan bütün atıfları yaptığımı beyan ederim.”

Esra ÖZCAN

ÖZET

Yüksek Lisans Tezi

KÜKÜRT GİDERME İŞLEMİ İÇİN KULLANILAN MALZEME MİKTARININ MAKİNE ÖĞRENME YÖNTEMLERİ İLE TAHMİNİ

Esra ÖZCAN

Karabük Üniversitesi

Lisansüstü Eğitim Enstitüsü

Bilgisayar Mühendisliği Anabilim Dalı

Tez Danışmanı:

Dr. Öğr. Üyesi Emrullah SONUÇ

Haziran 2021, 45 sayfa

Sıvı ham demir üretimi, yüksek fırın tesislerinde kok, sinter ve diğer demir cevheri malzemelerinin kullanılmasıyla gerçekleşmektedir. Sıvı ham demirin çeliğe dönüştürülmesinden önce kükürt giderme işlemi uygulanmaktadır. Buradaki amaç, içerisinde mevcut olan kükürt miktarının belirli bir miktar düşürülmesidir. Bu işlemde, sıvı ham demirin hedef kükürt değerine ulaşması için bazı kükürt gidericiler enjekte edilmektedir. Enjekte edilecek malzeme miktarları ise bir modele göre kurgulanmalıdır.

Literatürde kükürt giderme işlemi için temel ve veriye dayalı modeller önerilmektedir. Bu çalışmada ise makine öğrenme teknikleri kullanılmıştır. Yöntemlerin sonuçları analiz edilerek diğerlerine göre daha başarılı olduğu değerlendirilen yapay sinir ağı modelinin kullanılmasına karar verilmiştir.

Çalıřmada; kükürt giderme tesisinin 2020 yılına ait veriler kullanılarak malzeme miktarlarını tahmin etmek için bir model tasarlanmıřtır. Verilerin %80'i eğitim seti, %20'si de test seti olacak řekilde ayrılmıřtır. Tahmin edilen deęerler ile tesisten alınan gerçek veriler karşılařtırılarak deęerlendirilmiřtir. Buna göre; tesiste kullanılan kükürt gidericilerden magnezyum, kireç ve florit için sırasıyla %85, %95.4 ve %80.14 doęruluk elde edilmiřtir. Tesis için kullanılmak üzere model girdilerini parametre olarak alan ve tahmin edilen deęerleri gösteren bir arayüz hazırlanmıřtır.

Anahtar Sözcükler : Makine öğrenmesi, yapay sinir aęları, tahmin, sıvı ham demir, kükürt giderme

Bilim Kodu : 92431

ABSTRACT

M. Sc. Thesis

PREDICTION WITH MACHINE LEARNING METHODS THE AMOUNT OF MATERIAL USED FOR DESULPHURIZATION PROCESS

Esra ÖZCAN

**Karabük University
Institute of Graduate Programs
Department of Computer Engineering**

Thesis Advisor:

Assist. Prof. Dr. Emrullah SONUÇ

June 2021, 45 pages

Liquid raw iron is produced by using coke, sinter and iron ore materials in the blast furnace facilities. Before the conversion of liquid raw iron to steel, the desulfurization process is performed. The aim here is to reduce the amount of sulphur present in it by a certain amount. In this process, some desulfurizers are injected so that the liquid raw iron reaches the target sulphur value. The amount of material to be injected should be designed according to a model.

Basic and data-based models are suggested for the desulfurization process in the literature. In this study, machine learning techniques are used. The results of the methods are analyzed and it was decided to use the artificial neural network model which is considered to be more successful than the others.

In this study, a model is designed to predict material quantities using data of the desulfurization facility for 2020. 80% of the data is divided into a training set and 20% as a test set. It is evaluated by comparing the estimated values with the real data taken from the facility. According to the results, 85%, 95.4% and 80.14% accuracies are obtained for magnesium, lime and fluorite, which are desulphurizers used in the facility, respectively. An interface is prepared for the facility, which takes the model inputs as parameters and displays the estimated values.

Key Word : Machine learning, artificial neural network, prediction, pig iron, desulfurization.

Science Code : 92431

TEŐEKKÜR

Bu tez alıőmasının planlanmasında, araőtırılmasında, yürütülmesinde ve oluşumunda ilgi ve desteęini esirgemeyen, engin bilgi ve tecrübelerinden yararlandıęım, yönlendirme ve bilgilendirmeleriyle alıőmamı bilimsel temeller ışığında őekillendiren sayın hocam Dr. Öğr. Üyesi Emrullah SONUÇ'a teşekkürlerimi sunarım.

Sevgili aileme maddi, manevi hiçbir yardımı esirgemedен yanımda oldukları için tüm kalbimle teşekkür ederim.

İÇİNDEKİLER

	<u>Sayfa</u>
KABUL.....	ii
ÖZET.....	iv
ABSTRACT.....	vi
TEŞEKKÜR.....	viii
İÇİNDEKİLER	ix
ŞEKİLLER DİZİNİ.....	xii
ÇİZELGELER DİZİNİ	xiii
SİMGELER VE KISALTMALAR DİZİNİ	xiv
BÖLÜM 1	1
GİRİŞ	1
1.1. PROBLEMİN TANIMI	1
1.2. ÇALIŞMANIN KAPSAMI.....	2
BÖLÜM 2	3
SIVI HAM DEMİRDE KÜKÜRT GİDERME İŞLEMİ	3
2.1. LİTERATÜR TARAMASI.....	7
BÖLÜM 3	11
MAKİNE ÖĞRENME METODOLOJİSİ	11
3.1. YAPAY SİNİR AĞLARI.....	12
3.1.1. Yapay Sinir Ağının Yapısı.....	12
3.1.2. Aktivasyon Fonksiyonları.....	13
3.1.2.1. Doğrusal (Lineer) Fonksiyon	13
3.1.2.2. Step (Basamak) Fonksiyonu	14
3.1.2.3. Sigmoid Fonksiyonu	14
3.1.2.4. Tanjant Hiperbolik Fonksiyonu	15
3.1.2.5. ReLU Fonksiyonu	15

	<u>Sayfa</u>
3.1.2.6. Leaky ReLU Fonksiyonu	16
3.1.2.7. Softmax Fonksiyonu	17
3.1.3. Optimizasyon Yöntemleri.....	17
3.1.3.1. Stokastik Gradyan İnişi (SGD)	17
3.1.3.2. Momentum	17
3.1.3.3. Adagrad	18
3.1.3.4. RMSProp.....	18
3.1.3.5. Adadelata	18
3.1.3.6. Adam.....	18
3.2. DOĞRUSAL REGRESYON	18
3.3. KARAR AĞACI	18
3.4. K-EN YAKIN KOMŞU	18
3.5. RASTGELE ORMAN.....	19
3.6. XGBOOST (AŞIRI GRADYAN YÜKSELTME).....	20
3.7. MODEL PERFORMANS METRİKLERİ.....	20
3.7.1. Hata Kareler Ortalaması (MSE)	21
3.7.2. Hata Kareler Ortalamasının Karekökü (RMSE).....	21
3.7.3. Ortalama Mutlak Hata Yüzdesi (MAPE)	22
3.7.4. Ortalama Mutlak Hata (MAE).....	22
BÖLÜM 4	23
DENEYSEL ÇALIŞMALAR	23
4.1. KULLANILAN MATERYAL VE METODLAR	23
4.1.1. Veri Seti	24
4.1.2. Python	25
4.1.3. Spyder Programı	26
4.1.4. Keras Kütüphanesi.....	27
4.1.5. Tkinter Kütüphanesi	28
4.2. DENEYSEL SONUÇLAR.....	28

	<u>Sayfa</u>
BÖLÜM 5	39
SONUÇLAR VE TARTIŞMA	39
KAYNAKLAR	41
ÖZGEÇMİŞ	45

ŞEKİLLER DİZİNİ

Sayfa

Şekil 2.1.	Entegre tesislerde çelik üretim süreci	4
Şekil 2.2.	Sıvı ham demirde kükürt giderme akışı	4
Şekil 2.3.	Sıvı ham demirde önişlemler	5
Şekil 2.4.	Temel ve veriye dayalı modeller.....	7
Şekil 3.1.	Makine öğrenme metodolojisi	11
Şekil 3.2.	Biyolojik sinir hücresi	12
Şekil 3.3.	YSA örneği	13
Şekil 3.4.	Doğrusal fonksiyon	14
Şekil 3.5.	Basamak fonksiyonu	14
Şekil 3.6.	Sigmoid fonksiyonu	15
Şekil 3.7.	Tanjant Hiperbolik fonksiyon	15
Şekil 3.8.	ReLU fonksiyonu	16
Şekil 3.9.	Leak ReLU fonksiyonu	16
Şekil 4.1.	Python kod örneği.	25
Şekil 4.2.	Spyder kod editörü.	26
Şekil 4.3.	Spyder konsol ekranı.....	26
Şekil 4.4.	Spyder değişken görüntüleme ekranı	27
Şekil 4.5.	Keras ile model oluşturma örneği.	27
Şekil 4.6.	Tkinter ile form oluşturma	28
Şekil 4.7.	XGBoost modeli için kullanılan parametreler	29
Şekil 4.8.	Tasarlanan ağ modeli	31
Şekil 4.9.	Mg loss grafiği	32
Şekil 4.10.	Mg gerçek ve tahmin değerlerinin dağılımı	33
Şekil 4.11.	CaO loss grafiği	34
Şekil 4.12.	CaO gerçek ve tahmin değerlerinin dağılımı	35
Şekil 4.13.	CaF ₂ loss grafiği.....	36
Şekil 4.14.	CaF ₂ gerçek ve tahmin değerlerinin dağılımı	37
Şekil 4.15.	Hazırlanan arayüz ekranı	38

ÇİZELGELER DİZİNİ

	<u>Sayfa</u>
Çizelge 4.1. Veri seti örneği.....	24
Çizelge 4.2. Tahmin edilecek parametreler.....	25
Çizelge 4.3. Linear Regression metodunun sonuçları.....	29
Çizelge 4.4. Kneighbors Regressor metodunun sonuçları	30
Çizelge 4.5. Decision Tree Regressor metodunun sonuçları	30
Çizelge 4.6. Random Forest Regressor metodunun sonuçları	30
Çizelge 4.7. XGBoost metodunun sonuçları.....	30
Çizelge 4.8. Mg parametresi için uygunluk ve performans değerleri	32
Çizelge 4.9. Mg parametresi için değerlerin karşılaştırılması.....	33
Çizelge 4.10. CaO parametresi için uygunluk ve performans değerleri	34
Çizelge 4.11. CaO parametresi için değerlerin karşılaştırılması.....	35
Çizelge 4.12. CaF ₂ parametresi için uygunluk ve performans değerleri	36
Çizelge 4.13. CaF ₂ parametresi için değerlerin karşılaştırılması	37
Çizelge 4.14. Modellerin karşılaştırılması	38

SİMGELER VE KISALTMALAR DİZİNİ

SİMGELER

S	: kükürt
P	: fosfor
Si	: silisyum
Mn	: mangan
Mg	: magnezyum
CaO	: kalsiyum oksit, kireç
CaF ₂	: kalsiyum florür, florit
CaC ₂	: kalsiyum karbür, karpit
CaS	: kalsiyum sülfür
CaSiO ₄	: kalsiyum silikat
CaO ₂	: kalsiyum dioksit
O	: oksijen
C	: karbon
MgS	: magnezyum sülfür

KISALTMALAR

BOF : Bazik Oksijen Fırını

CBR : Case Based Reasoning (Vaka Bazlı Muhakeme)

YSA : Yapay Sinir Ağı

ReLU : Rectified Linear Unit (Doğrultulmuş Lineer Birim)

SGD : Stochastic Gradient Descent (Stokastik Gradyan İniş)

MAE : Mean Absolute Error (Ortalama Mutlak Hata)

MAPE: Mean Absolute Percentage Error (Ortalama Mutlak Yüzde Hata)

MSE : Mean Squared Error (Ortalama Kare Hata)

RMSE : Root Mean Square Error (Kök Ortalama Kare Hata)

HKO : Hata Kareler Ortalaması

HKOK: Hata Kareler Ortalamasının Karekökü

OMHY: Ortalama Mutlak Hata Yüzdesi

OMH : Ortalama Mutlak Hata

CPU : Central Process Unit (Merkezi İşlem Birimi)

GPU : Graphics Process Unit (Grafik İşlem Birimi)

GUI : Graphical User Interface (Grafiksel Kullanıcı Arayüzü)

R^2 : R-kare (R-squared)

BÖLÜM 1

GİRİŞ

Ülkelerin gelişmişlikleri ve ekonomileri üzerinde çelik sektörünün büyük bir rolü bulunmaktadır. Pek çok alanda yaygın olarak kullanılmasından ötürü yüksek miktarda çelik üretimi teşvik edilmektedir. Bu kapsamda farklı üretim yöntemleri ortaya çıkmış olup bu yöntemlere göre parametre ve süreçler değişiklik göstermektedir [1]. En yaygın olarak kullanılan bazik oksijen fırınlı (BOF) üretim prosesine göre işlenmiş olan en önemli hammadde sıvı ham demirdir [2].

Sıvı ham demir, yüksek fırın tesislerinde kok, sinter ve diğer demir cevheri malzemelerinin kullanılmasıyla üretilmektedir. Ardından sıvı çeliğe dönüştürülmektedir. Çeliğe dönüşüm gerçekleşmeden hemen önce, sıvı ham demir içerisinde bulunan kükürt (S), fosfor (P) ve silisyum (Si) değerlerinin düşürülmesi için ön işlemlerden geçirilmektedir [1]. Bu ön işlem desülfürizasyon olarak adlandırılmakta ve kükürt giderme tesislerinde uygulanmaktadır.

1.1. PROBLEMİN TANIMI

Kükürt, çeliğin mekanik özelliklerini olumsuz yönde etkileyen zararlı bir element olup çelik üretimi öncesinde belirli bir miktara düşürülmesi gerekmektedir. Bu uygulama için kükürt giderici reaktif malzemeler enjekte edilmektedir [3]. Kullanılan malzemelerin miktarları, üretilmesi hedeflenen kalitenin kükürt analizine göre de değişiklik göstermektedir [4]. Dolayısıyla enjekte edilecek malzemelerin miktarlarının belirlenmesi bir modele göre kurgulanmalıdır.

Kükürt giderme işlemi için uygulanan mevcut yöntemlerin yeterli olmaması sebebiyle güncel makine öğrenme yaklaşımları uygulanmıştır.

1.2. ÇALIŞMANIN KAPSAMI

Kükürt giderme tesisinden alınan veriler kullanılarak makine öğrenme metodlarıyla uygulamalar gerçekleştirilmiş olup yapay sinir ağları ile bir tahminleme modeli oluşturulmuştur. Enjekte edilecek malzemelerin miktarlarının girdi değerlerine göre tahmin edilmesi hedeflenmiştir. Kurgulanan yapay sinir ağı modeli ve uygulanan diğer yöntemlere ait çıktılar değerlendirilmiş ve başarılı sonuçlar elde edilmiştir. Modelin tahmin sonuçları ile tesisin gerçek verileri karşılaştırılmıştır.

Hazırlanan bu çalışmanın ilk bölümü olan “Giriş” kısmında amaç ve uygulama kapsamından bahsedilmiştir. İkinci bölümde çelik üretim sürecinin bir parçası olan sıvı ham demirin kükürt giderme prosesine ve bu işlemle ilgili literatürde yer alan uygulamalara değinilmiştir. Bir sonraki kısımda makine öğrenme metodolojisi ve yöntemleri anlatılmıştır. Dördüncü bölümde uygulama aşamasına geçilmiştir. Kullanılan programlar ve yöntemler hakkında bilgiler verilerek bu yöntemlerden elde edilen veriler karşılaştırılmıştır. Geliştirilen uygulamanın tahmin sonuçları ile gerçek değerlerin analizleri değerlendirilerek uygulamaya dair çıktılar görselleştirilmiştir. Sonuç bölümünde ise uygulamanın sonuçları yorumlanmıştır. İlerideki çalışmalara kaynaklık etmesi adına önerilerde bulunulmuştur.

BÖLÜM 2

SIVI HAM DEMİRDE KÜKÜRT GİDERME İŞLEMİ

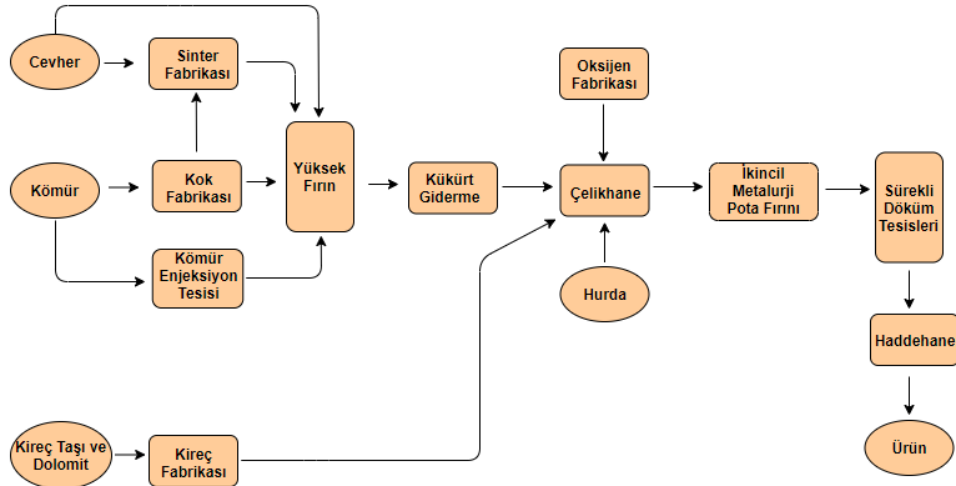
Çelik, demir ile birlikte %0.2-%2.1 arasında deęişkenlik gösteren karbon elementinin alaşımından oluşmaktadır. Kullanım alanı çok geniş olup; bina, otomobil, uçak, makine, köprü, aksesuar gibi pek çok sektörde kullanılan ana maddedir [5]. Dolayısıyla ülkelerin ekonomik alanda gelişmesinde demir-çelik üretiminin payı büyüktür [5]. Hatta ülkelerin gelişmişlik düzeylerini gösteren bir kriter olan kişi başına düşen gayrisafi milli hasılanın yanı sıra kişi başına düşen demir-çelik tüketimi de belirleyici bir ölçüt haline gelmiştir [6].

Farklı yöntemlerle çelik üretilebilmektedir. En yaygın olarak; demir cevherinden elde edilen sıvı ham demire oksijen üflenerek yapılan bazik oksijen fırınlı entegre tesislerde ya da hurdanın eritilmesiyle elektrik ark ocaklarında gerçekleştirilmektedir [3].

Dünyada, entegre tesislerde bazik oksijen fırın ile yapılan üretim şekli daha yaygındır. Bazik oksijen fırını ile üretim ilk olarak 1952-1953 yıllarında Avusturya'da Linz ve Donawitz işletmelerinde kullanılmıştır. Bu yöntemle kütle çelik üretimi; tekno-ekonomik açıdan en iyisi olup uygulama alanı da yaygın hale gelmiştir. Dolayısıyla çelik üretiminin büyük bir kısmı bu yöntem kullanılarak gerçekleştirilmektedir [1].

Şekil 2.1'de olduğu gibi bazik oksijen fırını ile ham çelik üreten bir demir çelik fabrikasında iki temel malzeme olan kömür ve cevherin girişiyle süreç başlamaktadır. Kömür, kok bataryalarında kok üretimi için kullanılmaktadır. Demir cevheri ise sinter tesislerinde sinterleme işlemine tabii olmaktadır. Kok, sinter ve diğer demir cevheri malzemeleri sıvı ham demir üretimi için yüksek fırınlarda işlem görmektedir [7].


Yüksek fırınlarda üretilen sıvı ham demir; hurda, kireç ve oksijen kullanılarak bazik oksijen fırınlarında sıvı çeliğe dönüştürülmektedir. Sıvı çeliğin istenilen kalite değerlerine ulaşabilmesi için pota fırınında alaşım eklemesi yapılmaktadır [7]. Ardından sürekli döküm tesislerinde slab, kütük formlarına getirilmektedir. Bu yarı mamüller de haddehanelerde işlenerek nihai ürün haline gelmektedir.



Şekil 2.1. Entegre tesislerde çelik üretim süreci [8].


Bu süreçte sıvı ham demir en önemli işlenmiş hammadde durumundadır [2]. Sıvı ham demir, yüksek fırınlarda kok, sinter ve diğer demir cevheri malzemeleri ile elde edilmektedir. Sonrasında pota, torpido vb. aracılığıyla çelikhaneye taşınmaktadır [3].

Çelik üretim aşamasına geçmeden önce ilk durak olarak kükürt giderme tesisinde üretilen sıvı ham demirde desülfürizasyon işlemi uygulanmaktadır (Şekil 2.2).



Şekil 2.2. Sıvı ham demirde kükürt giderme akışı [9].

Burada sıvı ham demir içerisinde bulunan kükürt, fosfor ve silisyum değerlerinin düşürülmesi için ön işlemlerden geçirilmektedir. Bu işlem Şekil 2.3'te gösterildiği gibi kükürt giderme istasyonlarında gerekli flaks malzemeler beslenerek, termodinamik reaksiyonlar sonucu cürufa geçirilmekte ve belli seviyelere indirilmektedir [10].



Şekil 2.3. Sıvı ham demirde ön işlemler [3].

Silisyum değerini azaltmak için demir oksit/cevher eklemesi yapılırken; fosfor düşürmede kireçli flakslar kullanılmaktadır. Bu şekilde silisyum ve fosfor cürufa geçirilmektedir [3].

Sıvı ham demir içerisinde bulunan kükürt ise, çeliğin darbe mukavemeti gibi mekanik özelliklerinde olumsuz etki bırakan çelik için zararlı bir elementtir [3]. Süneklik ve tokluk gibi özelliklerinin azalmasına sebep olmaktadır [11]. Örneğin, mangan (Mn) ile dengeli bir tepkime olmadığı zaman demir sülfür bileşiğinin oluşmasından ötürü yüksek sıcaklıkta çeliğin kırılma mukavemeti düşer [11]. Ayrıca ürünün sertleşebilirliğini ve kaynaklanabilirliğini de olumsuz yönde etkilemektedir [11]. Dolayısıyla çelik içinde istenen bir element değildir ve miktarının sınırlı olması gerekmektedir [3]. Bu nedenle sıvı çelik üretim süreci öncesinde kükürt giderme işlemi uygulanmaktadır [4].

Kükürt oranını düşürmek amacıyla kireç, magnezyum, florit, karpit gibi ilave malzemeler (kükürt giderici reaktifler) kullanılmaktadır. En yaygın olarak kullanılan bu kükürt gidericilerden kireç daha düşük maliyetli ve kolay ulaşılabilir. Kükürt giderme işlemi sırasında kireç parçacıklarının, kalsiyum karbür (CaC_2) ve kalsiyum silikat ($CaSiO_4$) ile sürekli kaplanma durumu oluşmaktadır. Bu da kirecin sıcak metale temasındaki kükürt giderme reaksiyonunu engellemektedir. Bu durumu önleyebilmek için; kirecin tane boyutunun en fazla 45 mikrometre ile olması gerekmektedir. Kükürt giderme işleminde kireç, Eşitlik 2.1'deki denkleme göre reaksiyon göstermektedir [12].



Bir diğer reaktif; kalsiyum karbür yani karpit genellikle birkaç bileşenle birlikte kullanılmaktadır. Kireç gibi katman oluşumuna maruz kalarak kükürt giderme reaksiyonunun engellenmesine yol açabilmektedir. Kalsiyum karbür, kükürt gidermek için Eşitlik 2.2'de yer alan denkleme göre reaksiyona girmektedir [12].



En çok kullanılan bir diğer reaktif olan magnezyum enjeksiyonunda ise kireç enjeksiyonundan farklı olarak oksijen yer almamaktadır. Böylece magnezyum sülfür oluşturmak amacıyla kükürt ile tepkimeye girmektedir. Magnezyumun kükürt giderme işlemi için tepkime denklemi Eşitlik 2.3'te gösterildiği gibidir [12].



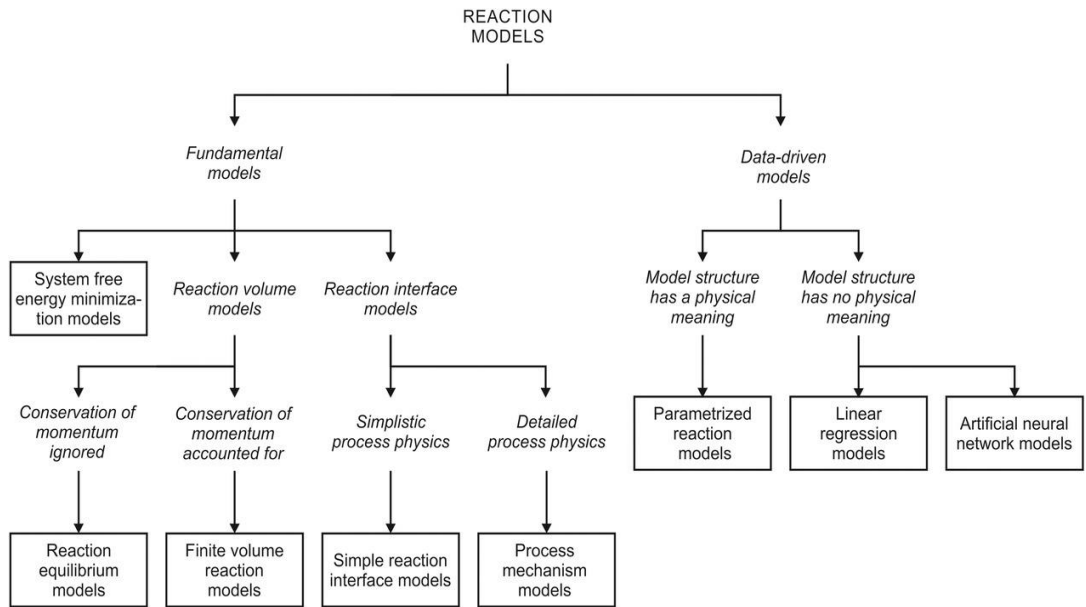
Desülfürizasyon işleminde öncelikle; torpido ve pota içine refrakter kaplı bir lans borusu indirilmektedir. Ardından bu lans ucunun iki tarafında bulunan nozullardan kireç, magnezyum gibi malzemeler püskürtülmektedir. Lans borusundaki işlem kontrolü ile desülfürizasyon tesisinde üretimin ihtiyaçlarına uyum için enjeksiyon hızı, miktarı gibi parametrelerin kontrolü işletme maliyetlerine yön verebilecektir. Bu durumu etkileyen bir başka faktör de farklı reaktiflerin eklenmesidir. Bu reaktifler tek

başına mono enjeksiyon, birlikte enjeksiyon veya çoklu enjeksiyon şeklinde uygulanmaktadır. Bu lans borusu yöntemi ile sıvı ham demirde kükürt miktarını %0,001'lere kadar düşürmek mümkündür [12].

Kullanılan flaks malzemeler ve miktarları, üretilecek kalitenin kükürt analizine göre de değişkenlik göstermektedir [4]. Bu nedenle istenilen kükürt değerine ulaşmak için kullanılan malzemelerin miktarlarının belirlenmesi bir modele göre kurgulanmalıdır.

2.1. LİTERATÜR TARAMASI

Sıvı ham demirde kükürt giderme işleminin modellenmesi ve kontrolü için genel olarak Şekil 2.4'te yer alan temel ve veriye dayalı yaklaşımlar mevcuttur [13].



Şekil 2.4. Temel ve veriye dayalı modeller [13].

Temel modeller, fizikokimyasal özelliklerin, parametrelerin kullanılmasıyla oluşturulmuştur. Veriye dayalı modellerde ise süreç verilerine odaklı işlemler gerçekleştirilmektedir [13].

Sıcak metalde yani sıvı ham demirde kükürt gidermenin modellenmesine ilişkin pek çok çalışma mevcuttur. Deo vd.'nin (1994) yaptıkları çalışmaya göre; bir torpido

arabasında sıcak metalde kükürt gidermeyi modellemek için yapay sinir ağı kullanılmıştır. Sıcak metalin nihai kükürt içeriği beş girdi değişkenine dayalı olarak tahmin edilmiştir. Bu değişkenler; işlem süresi, sıcak metal ağırlığı, ilk kükürt içeriği, taşıyıcı gaz akış hızı ve reaktif enjeksiyon hızıdır. Bu değişkenler dizisi ile nihai kükürt içeriğine göre yeterli tahmin doğruluğu elde etmişlerdir [14].

Rong vd. (2005) yapmış oldukları çalışmada kükürt giderme işlemi için işlem parametrelerini tahmin etmede geri yayımlı yapay sinir ağı modeli geliştirmişlerdir. Bu sinir ağı tahmin modelinin temel amacı; operatörlerin deneyimi yerine akıllı algoritma temelindeki operasyon parametrelerini atamaktır. Kükürt gidericinin tüketimini optimize etmek için matematiksel bir model sunulmuştur. Ayrıca, tahmin modeline dayalı bir yazılım paketi de geliştirilmiştir [15].

Jin vd. (2006) tarafından ise kireç bazlı toz enjeksiyonu kullanılarak kükürt giderme için kinetik model önerilmiştir. Model için, kireç bazlı ve magnezyum bazlı enjeksiyon arasında bir karşılaştırma yapılmış ve magnezyum enjeksiyonunun kükürt giderme oranının kirece göre çok daha fazla olduğu sonucuna ulaşılmıştır [16].

Bir diğer çalışmada; Vinoo vd. (2007) regresyon yaklaşımını kullanarak proses sonuçlarını tahmin etmişlerdir. Sıcaklık baz alınarak birden çok regresyon modeli kurulmuş ve tahminler ilgili sıcaklığa ait model üzerinden yapılmıştır. Operatöre desülfürizasyon reaktifinin optimum tüketimini sağlamak için kılavuzluk etmek üzere çoklu doğrusal regresyon teknikleri kullanan bir model geliştirilmiştir [17].

Zhan vd. (2010) ise geri yayımlı 4-12-1 nöronlu ağ yapılandırmasına sahip magnezyum tozunun tahmin modelini kurgulamıştır. Girdi parametreleri olarak sıcak metalin ağırlığı, sıcaklığı, sıcak metalde başlangıç ve son kükürt içeriği seçilmiştir. Eğitim için 210, test için 46 örnek veri kullanılarak; ortalama 5,12 kg'lık magnezyum tüketiminde hata tahminine yer vermişlerdir. Modelin, gerçek üretim prosesiyle büyük ölçüde örtüşüğünü belirtmişlerdir [18].

Bir diğer örnek olarak; Liang vd. (2011) tesisin sıcal metal ön işlem kükürt giderme prosesi için geri yayımlı sinir ağında moment terimi eklenmesine dayalı bir kükürt

giderici ekleme miktarı tahmin modeli oluşturmuşlardır. Üretim sahasında sıcak metal ön kükürt giderme verileri ile test edildikten sonra tahmin modeli üretim sürecine uygulanmıştır. Sonuçlar modelin kükürt giderme başarı oranının %96,8 olduğunu ve modelden sonra kükürt giderme tüketiminin de azaltılabileceğini göstermiştir [19].

Wang vd. (2011) temel bileşen analizi – radyal tabanlı sinir ağı kullanarak çalıştıkları veri setinde model çıktılarının gerçek sonuçlara göre küçük bir farkla yaklaştığını tespit etmişlerdir. Radyal tabanlı sinir ağlarında, girdi katmanından gizli katmana geçişte radyal tabanlı aktivasyon fonksiyonları ve doğrusal olmayan kümeleme analizi kullanılmaktadır [20].

Özmen vd. (2018) tarafından demir çelik üretim sektöründe yer alan İskenderun Demir ve Çelik A.Ş. (İSDEMİR)'de; kükürt giderme tesisinin yapımçı firması tarafından hazırlanmış olan seviye-2 programının önerdiği magnezyum miktarı ile işlem yapıldığında hedef kükürt değerini tutturma oranı düşük olmasından ötürü operatöre bağlı değişkenlik gösteren magnezyum kullanıldığı saptanmış olup hedef kükürt değerine göre kullanılması gerekli magnezyum miktarını tahminleyen en iyi alt küme regresyon analizi yapılmıştır. Yapılan çalışmada operatör kaynaklı değişkenliğin azaltılması ve kullanılan magnezyum miktarının optimize edilmesi amaçlanmıştır [4].

Bir diğer çalışmada, Vuolio vd. (2019) endüstriyel ölçekli bir veri setini kullanarak sıcak metalde kükürt giderme tahmini için otomatik değişken seçim prosedürü yürütmeyi denemişlerdir. Değişken seçim sorunu için ikili kodlu genetik algoritma kullanılmıştır. Bu şekilde ana üretim değişkenlerinin kükürt gidermede hız ve verimliliği üzerindeki etkisine odaklanılmıştır ve değişkenlerin büyük önem taşıdığı sonucuna ulaşılmıştır [20].

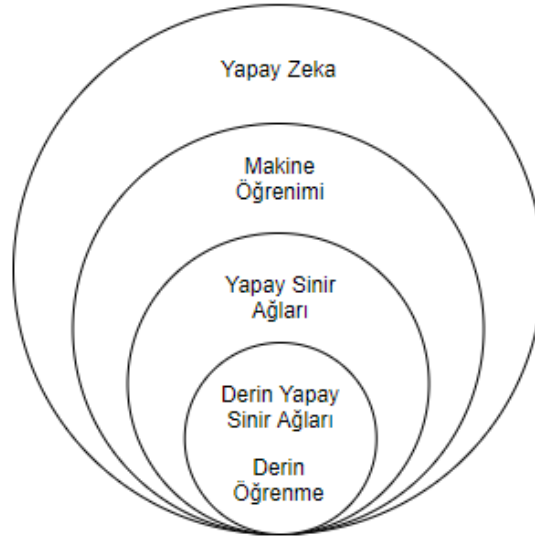
Feng vd. (2019) ise Kanbara Reaktörü desülfürizasyon işleminde sıvı demirin son noktadaki kükürt değerini tahmin etmek amacıyla, mekanik model düzeltmeye dayalı vaka bazlı muhakeme (CBR) yöntemini kullanmışlardır. Kanbara reaktörü; sıcak metaldeki kükürdü geleneksel tesislere göre daha düşük seviyelere ve daha uygun maliyetlere imkan tanıyan sıcak metal ön işlemidir. Çalışmada öncelikle mekanik modelin belirlenmesi için analiz yapılmış ve bu analizlere göre özelliklerin seçimi,

ağırlıkların belirlenmesi ve hesaplama sonuçlarının ayarlanması işlemleri gerçekleştirilmiştir. Ardından CBR yöntemi geri yayımlı sinir ağı ve düzeltilen model ile kullanılmıştır. Düzeltilen modelin tahmin doğruluğunun geri yayımlı sinir ağından daha yüksek olduğu sonucuna varılmıştır [22].

BÖLÜM 3

MAKİNE ÖĞRENME METODOLOJİSİ

Yapay zekanın bir alt kümesi olan makine öğrenmesi, problemlere ait verilerden yararlanarak model kurgusunun gerçekleştirildiği algoritmalarıdır. (Şekil 3.1). Bu algoritmalar ile veriler üzerinde kuralların oluşturulması böylece makinelerin deneyimlerinin, öğrenmelerinin ve başarısının artması amaçlanmıştır [23]. Bilgisayarların bir problemle ilgili deneyimlerini öğrenerek benzer durumlara çözüm sunmasını sağlamaktadır [24].



Şekil 3.1. Makine öğrenme metodolojisi.

Makine öğrenmesinin kökenleri 1950'li tarihlere Alan Turing'in turing testi çalışmalarına uzanmaktadır. Bu çalışma ile makinenin zekasının belirlenmesi amaçlanmıştır. 1959 yılında ise Arthur Samuel tarafından hazırlanan dama programında ilk kez makine öğrenmesi kavramı doğmuştur [25].

Makine öğrenme; yüz tanımda, nesne tanımda, otonom sistemlerde, sağlık sektörü, bankacılık, savunma ve güvenlik gibi alanlarda, gelecek ile ilgili tahminlerde yaygın olarak kullanılmaktadır [23].

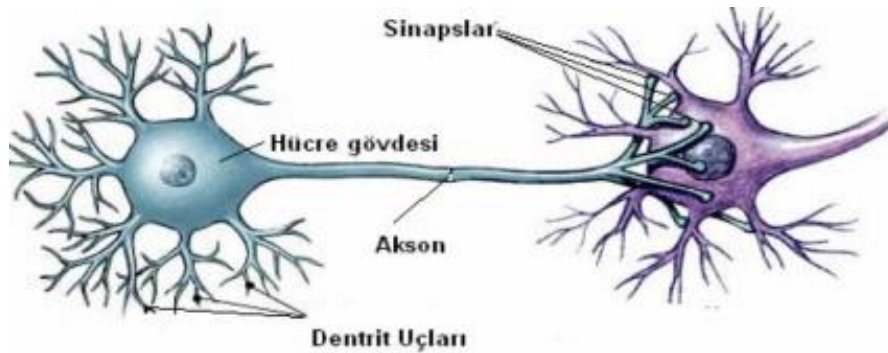
Makine öğrenmesinde kullanılan yöntemler probleme ait veri setine göre şekillenmektedir. Veri setinde yer alan parametrelere göre çıktı değerlerinin mevcut olması halinde denetimli öğrenme, yoksa denetimsiz öğrenme algoritmaları kullanılmaktadır [23].

3.1. YAPAY SİNİR AĞLARI

Yapay sinir ağları, insan beyninin öğrenme fonksiyonundan esinlenerek geliştirilen yöntemdir. Tahminleme, sınıflandırma, kümeleme gibi problemlerde çözümler üretmektedir. Karmaşık problemlerde geçmiş verilerden, bilgilerden yararlanıp öğrenme metodu ile çıkarımda bulunarak çözüme ulaştırmaktadır [26].

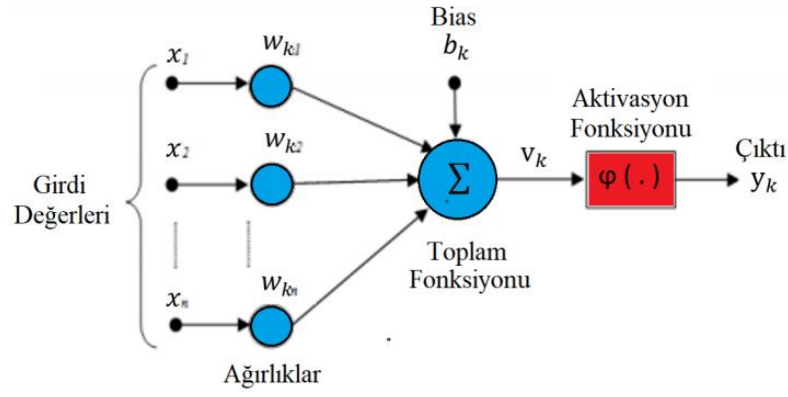
3.1.1. Yapay Sinir Ağının Yapısı

Yapay sinir ağları, biyolojik sinir sisteminden esinlenerek oluşturulmuştur. Şekil 3.2'de sunulan biyolojik sinir sisteminde sinir hücreleri sinapslar aracılığıyla elektrik sinyalleri ile iletişim sağlamaktadır. Bu sinyaller dentrite kadar iletdikten sonra dentritler de sinyalleri sinapslara göndererek sinir hücreleriyle bağlantı kurulmaktadır [27].



Şekil 3.2. Biyolojik sinir hücresi [28].

Sinir ağlarında da biyolojik sinir sistemine benzer bir modelleme kurgulanmıştır. Paralel olarak bağlı elemanlardan oluşmaktadır. Girdi, ara (gizli) ve çıktı şeklinde üç katmandan oluşan bu yapıda ağın fonksiyonu elemanlar arasındaki bağlantıyı sağlamaktadır. Elemanların birbirine bağlı oldukları ağırlık değerlerinin ayarlanmasıyla da ağın eğitimi gerçekleşmektedir [26]. Girdi katmanının aldığı bilgiler ara katmana iletilmekte, ara katmanda işlenen bilgiler ise çıktı katmanına aktarılmaktadır [26]. Çıktı katmanı, giriş verilerinin eğitilmesi sonucunda hedeflenen sonucu üretmektedir. Bu yapının tasarımına Şekil 3.3'te yer verilmiştir.



Şekil 3.3. YSA örneği [29].


3.1.2. Aktivasyon Fonksiyonları

Sinir ağına doğrusal olmayan özellikleri tanıtmak amacıyla aktivasyon fonksiyonu kullanılmaktadır [30]. Amaç; ağırlık ve eşik değerlerinin ayarlanmasıdır [31].

3.1.2.1. Doğrusal (Linear) Fonksiyon

Türevi sabit bir değer olduğundan öğrenme işlemi yeterli düzeyde gerçekleşmemektedir. Ağdaki tüm katmanlarda lineer fonksiyon kullanıldığında giriş ile çıkış katmanında aynı sonuca ulaşılması kaçınılmazdır (Şekil 3.4). Bu durum ara katmanları pasif hale getirmektedir [30]. Eşitlik 3.1'deki gibi giriş değerine karşılık aynı çıkış değerinin üretildiği görülmektedir.

$$f(x) = x \quad (3.1)$$




Şekil 3.4. Doğrusal fonksiyon [30].

3.1.2.2. Step (Basamak) Fonksiyonu

Eşitlik 3.2’de yer aldığı gibi ikili değer alan fonksiyon olup, çıkış katmanlarında kullanılmaktadır. Türevi anlamlı bir öğrenme değeri temsil etmediğinden gizli katmanlarda tercih edilmemektedir [30]. Şekil 3.5’de basamak fonksiyonuna yer verilmiştir.

$$f(x) = \begin{cases} 0, & \text{if } x < 0 \\ 1, & \text{if } x \geq 0 \end{cases} \quad (3.2)$$




Şekil 3.5. Basamak fonksiyonu [30].

3.1.2.3. Sigmoid Fonksiyonu

0-1 aralığında değer üreten fonksiyondur (Şekil 3.6). Sınıflayıcı olarak kullanılmaktadır. Eşitlik 3.3’te denklemi yer alan bu fonksiyonda türev değerlerinin küçük ve/veya 0’a yaklaştığı durumlarda gradyanların ölmesi söz konusu olup öğrenme yavaş gerçekleşmektedir. Bu da sinir ağı performansını olumsuz etkileyebilmektedir [30].

$$f(x) = \frac{1}{1 + e^{-x}} \quad (3.3)$$




Şekil 3.6. Sigmoid fonksiyonu [30].

3.1.2.4. Tanjant Hiperbolik Fonksiyonu

-1 ile +1 aralığında tanımlı bir fonksiyon olup sigmoid fonksiyona göre daha çok değer alabilmektedir (Şekil 3.7). Bu durum ağıın daha hızlı öğrenmesini ve daha verimli çalışmasını öngörmektedir. Eşitlik 3.4'teki denkleme sahip bu fonksiyonun uç noktalarında gradyanların ölmesi problemi mevcuttur [30].

$$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (3.4)$$




Şekil 3.7. Tanjant Hiperbolik fonksiyon [30].

3.1.2.5. ReLU Fonksiyonu

Şekil 3.8'de belirtildiği gibi 0 ile $+\infty$ aralığında değer alan fonksiyondur. Negatif bölgede 0 değerleri alması ağıın hızlı çalışmasını sağlamaktadır. Sigmoid ve tanjant

hiperbolik fonksiyonlarına göre hesap yükü daha azdır ve bu durum yaygın olarak kullanılmasına sebep olmaktadır. Tek dezavantajı ise; Eşitlik 3.5’de gösterildiği gibi 0 değer alan bölgede türevinin de 0 değerini alması ve o alanda öğrenmenin gerçekleşmesini engellemesidir [30].

$$f(x) = \begin{cases} 0, & \text{if } x < 0 \\ x, & \text{if } x \geq 0 \end{cases} \quad (3.5)$$




Şekil 3.8. ReLU fonksiyonu [30].

3.1.2.6. Leaky ReLU Fonksiyonu

ReLU fonksiyonundan farkı $-\infty$ ile $+\infty$ aralığında tanımlı olmasıdır (Şekil 3.9). Eşitlik 3.6’ya göre; 0 olmayan değerler sayesinde öğrenme, negatif bölgede de gerçekleşmektedir [30].

$$f(x) = \begin{cases} 0.01x, & \text{if } x < 0 \\ x, & \text{if } x \geq 0 \end{cases} \quad (3.6)$$



Şekil 3.9. Leak ReLU fonksiyonu [30].

3.1.2.7. Softmax Fonksiyonu

Sigmoid fonksiyonu gibi sınıflayıcı olarak kullanılan Eşitlik 3.7'deki denkleme sahip bu fonksiyon 0-1 aralığında değerler üretmek için girdinin hangi sınıfa ait olduğunu belirlemektedir [30].

$$f(x)_j = \frac{e^{z_j}}{\sum_{k=1}^K e^{z_k}} \text{ for } j = 1, \dots, K. \quad (3.7)$$

3.1.3. Optimizasyon Yöntemleri

Regresyon modellerinde öğrenme işleminden sağlıklı sonuçlar elde edebilmek için hata fonksiyonlarında veya performans fonksiyonlarında minimum değere ulaşmak önemlidir. Bu noktada devreye optimizasyon girmektedir. Optimizasyon ile çıktı değerleri ve gerçek değerler arasındaki fark minimize edilmeye çalışılmaktadır [32].

Optimizasyon yöntemlerinden başlıca; SGD, Momentum, Adagrad, RMSProp, Adadelta ve Adam en sık kullanılanlardandır [31].

3.1.3.1. Stokastik Gradyan İnişi (SGD)

SGD yöntemiyle, eğitim verisinin tamamı yerine bir örnek üzerinden hesaplama gerçekleştirilmektedir. Bu şekilde hafıza yetersizliğini önlemek mümkündür [32].

3.1.3.2. Momentum

SGD yönteminde optimum nokta bulunurken fazla salınım gerçekleşmektedir. Dolayısıyla bu salınımları azaltmak için tercih edilen yöntemdir. Mevcuttaki gradient (düşüm)'ler yerine momentumlu yani kontrollü gradient kullanılarak daha az salınım elde edilebilmektedir [31].

3.1.3.3. Adagrad

Öğrenme katsayısının geçmiş gradient karelerinin kümülatif toplamalarının kareköküne bölünmesiyle ilk iki yöntemde yer alan sabit öğrenme katsayısı sorunu giderilmiştir [31]. Böylece her parametre için farklı güncelleme işlemi gerçekleşmektedir [32].

3.1.3.4. RMSProp

Sabit öğrenme katsayısını önlemek için geliştirilen bir diğer yöntemdir. Adagrad yöntemindeki gradientlerin kareleri yerine momentumlu gradientlerin kareleri alınarak gerçekleştirilmektedir [31].

3.1.3.5. Adadelta

RMSProp yöntemindeki mantıkla oluşturulmuştur. Tek fark ise; öğrenme katsayısı seçme zorunluluğunu kullanmamasıdır. Bu kapsamda mevcut ağırlık ile güncellenen ağırlık arasındaki farkı simgeleyen delta değerlerinin karelerinin momentumlu toplamları kullanılmaktadır [31].

3.1.3.6. Adam

RMSProp ile momentum yöntemlerindeki avantajlı kısımlar birleştirilerek oluşturulmuştur [31]. Yani, geçmiş eğimlerin karelerinin üssel olarak ağırlıklandırılmış ortalamaları ile momentum değişiklikleri de işleme katılmaktadır [32].

3.2. DOĞRUSAL REGRESYON

Doğrusal regresyon, iki ya da daha fazla değişken arasından ilişkinin hesaplandığı bir modeldir. Bağımlı ve bağımsız değişkenlerden meydana gelen doğrusal regresyon modelinde; bağımlı değişkenin sürekli olması gerekirken, bağımsız değişkenler sürekli veya kategorik özelliğe sahip olabilir [33].

Eşitlik 3.8'deki denklemde de yer aldığı gibi x bağımsız değişkeni, w ağırlık değerlerini ve ϵ gerçek değerden uzaklaşma miktarını ifade etmektedir [34].

$$y = w_0 + w_1x_1 + w_2x_2 + \dots + w_nx_n + \epsilon \quad (3.8)$$

3.3. KARAR AĞACI

Denetimli öğrenme türlerinden biri olan karar ağaçları; bağımlı değişkenin türüne göre; yani kategorik bir yapıda ise sınıflandırma, sürekli ise regresyon ağaçları olarak kullanılmaktadır [35].

Kök düğüm, dal ve yapraklardan meydana gelen bu yapıda çıktı; yapraklarda elde edilen değeri ifade etmektedir [36]. Kök düğüm ile başlayan yöntemde veri kümeleri parçalara ayrılarak dalları ve düğümleri oluşturmaktadır. Kurgulanan kurallara göre seçilen kararlar ile sonraki düğüme geçiş gerçekleşmektedir.

3.4. K-EN YAKIN KOMŞU

Verilerin birbirine olan uzaklığını baz alarak uygulanan bir yöntemdir [23]. Çalışmanın sonunda tahmin işlemi için komşularında arama yaparak sonuç sunmaktadır [25]. Hem sınıflandırma hem de regresyon problemlerinde kullanılmaktadır [37].

Hedefe ulaşmak için daha önceki gözlemlerden yararlanarak k adedine olan yakınlığı dikkate alınmaktadır. Bu k değeri kadar olacak şekilde en yakın komşularının sonuçlarına göre işlem gerçekleştirilmektedir [36].

3.5. RASTGELE ORMAN

Birden fazla karar ağacı algoritmasının birlikte çalışmasıyla oluşan bir modeldir. Hem regresyon hem de sınıflandırma amacıyla kullanılmaktadır. İki adet parametresi mevcuttur. Bu parametreler; ağaç sayısının tanımlandığı N ve düğümlerdeki değişken sayısı olan m 'dir [25].

Bu yöntemle her düğümde rasgele değerlerden en iyisi seçilerek düğüm dallara ayrılmaktadır. [23] Ardından düşük hata oranına sahip ağaçlara yüksek; yüksek hata oranına sahip ağaçlara da düşük ağırlıklar verilmektedir. [25] Bu işlemlerin sonunda ağırlıklara göre ağaçların oylaması gerçekleştirilerek ağaç yapısı belirlenmektedir [25]. Girdi değişkeninin çok fazla olduğu verilerle yüksek performans göstermekte olup eksik verilerle de çalışarak tahminleme işlemi gerçekleştirilebilmektedir [36].

3.6. XGBOOST (AŞIRI GRADYAN YÜKSELTME)

Gradyanı artırılan karar ağaçlarının kullanıldığı bir algoritmadır ve gradyan yükseltme altyapısında geliştirilmiştir. [37] Aşırı öğrenmeyi engelleyen, veri setindeki kayıp verilerle çalışabilen, çapraz doğrulama ve ağaç budama özelliklerine sahip bir altyapısı mevcuttur [38]. Sınıflandırma ve regresyon işlemlerinde kullanılmaktadır [38].

Bu yöntemin çalışma mantığına göre; verideki her bir değeri analiz etmek yerine onları parçalara ayırma işlemi uygulanmaktadır. Bu şekilde küçük parçalar üzerinden daha iyi tahminleme yapması beklenmektedir [38].

Modelin performansının iyi olması için parametre ayarlarına dikkat edilerek en uygun değerleri seçmek önemlidir. Modelde; ağaç derinliği için max_depth, aşırı uyumu önlemek için gamma, öğrenme oranı için eta, eğitim için seçilen rastgele bölümü ifade eden subsample gibi parametreler kullanılmaktadır [38].

3.7. MODEL PERFORMANS METRİKLERİ

Tahmin sonucunun gerçek değerden ne ölçüde uzak olduğunu hesaplamak için kullanılan fonksiyonlardır [31]. Modellerin başarımları bu şekilde ölçülerek; ağın performansını ve öğrenme başarısını görmek mümkün olacaktır. En yaygın olarak tercih edilen performans metrikleri; ortalama mutlak hata (Mean Absolute Error - MAE), ortalama mutlak hata yüzdesi (Mean Absolute Percentage Error - MAPE), hata kareler ortalaması (Mean Squared Error - MSE), hata kareler ortalamasının karekökü (Root Mean Squared Error - RMSE) olarak gösterilmektedir [28].

Bu ölçütlerde amaç en küçük değere sahip sonuca ulaşmaktır [39]. Aşağıda başlıca kullanılan kayıp (loss) fonksiyonların matematiksel formüllerinde bulunan ifadelerin açıklamalarına yer verilmektedir.

Buna göre;

- t_i : i. birimin tahmin değerini
- g_i : i. birimin gerçek değerini
- e_j : tahmindeki hata değerini

ifade etmektedir [28].

3.7.1. Hata Kareler Ortalaması (MSE)

Eşitlik 3.9'da denklemleri verilen hata kareler ortalaması, hata değerlerinin büyüklükleri benzer olduğu durumlarda tercih edilmektedir. Sonuç pozitif değerli çıkmakta olup, sonucun 0'a yakın olması modelin performansının iyi olduğuna işaret etmektedir [40].

$$HKO = \frac{1}{n} \sum_{i=1}^n (t_i - g_i)^2 = \frac{1}{n} \sum_{i=1}^n e_j^2 \quad (3.9)$$

3.7.2. Hata Kareler Ortalamasının Karekökü (RMSE)

Tahmin hatalarındaki standart sapmadır. Yani tahmin hatalarının yayılma durumunu ölçmektedir. Sonucun 0 çıkması modelin hatasız olduğunu göstermektedir [40]. Eşitlik 3.10'da bu metrik için kullanılan denklem gösterilmiştir.

$$HKOK = \sqrt{\frac{1}{n} \sum_{i=1}^n (t_i - g_i)^2} = \sqrt{\frac{1}{n} \sum_{i=1}^n e_j^2} \quad (3.10)$$

3.7.3. Ortalama Mutlak Hata Yüzdesi (MAPE)

Hata değerlerinin birimlerinde farklılık söz konusu olduğunda kullanılabilir bir fonksiyondur. Yüzde olarak ifade edilen bu metrik fonksiyonu %10'un altında çıkması halinde yüksek doğruluğa sahip model; %10 ile %20 arasında ise doğru tahmin modeli olduğunu belirlemektedir [39]. Eşitlik 3.11'de fonksiyonun hesaplanma şekli gösterilmektedir.

$$OMHY = 100X \frac{\sum_{i=1}^n (t_i - g_i)^2 / t_i}{n} \quad (3.11)$$

3.7.4. Ortalama Mutlak Hata (MAE)

Eşitlik 3.12'de yer alan denkleme göre hesaplanan bu hata fonksiyonu; iki sürekli değişken olan tahmin ve gerçek değer arasındaki farkın ölçüsüdür. Regresyon ve zaman serisi problemlerde daha çok tercih edilmektedir [40].

$$OMH = \frac{\sum_{i=1}^n |t_i - g_i|}{n} = \frac{\sum_{i=1}^n e_j}{n} \quad (3.12)$$

BÖLÜM 4

DENEYSEL ÇALIŞMALAR

Kükürt giderme tesisine ait geçmiş veriler kullanılarak makine öğrenimi algoritmaları üzerinde durulmuştur. Uygulanan makine öğrenimi algoritmalarına ait parametreler belirlenerek işlem yapılmıştır. Yapay sinir ağı ile model geliştirmek hedeflenmiştir ve modelin oluşum aşamasında katman/nöron sayıları ve fonksiyonların seçimi için pek çok deneme gerçekleştirilmiştir. Kullanılan tüm yöntemler için performans açısından en iyi mimariye karar verilerek ağın eğitimi yapılmıştır. Tesisin gerçek verileri ile test tahmin sonuçları analiz edilmiştir.

4.1. KULLANILAN MATERYAL VE METODLAR

Tesisten temin edilen veriler analiz edilerek uygulama için kullanılacak kriterler belirlenmiştir. Çalışmada tahmin edilmesi gereken üç adet parametre mevcuttur. Bu parametreler bir sınıflandırmaya ait üç çıkış durumunu değil, farklı kriterlere ait değerleri temsil etmektedir. Dolayısıyla bir regresyon örneğini taşımaktadır.

Regresyon; bağımsız değişkenlerin bağımlı değişkendeki değişimini ifade etmektedir. Sayısal bir değeri tahmin etmeyi içeren tahmine dayalı bir modelleme problemidir [41]. Tahmine dayalı modelleme, yeni veriler üzerinde tahmin yapmak için geçmiş verilerden yararlanmayı gerektirir [41].

Regresyon problemlerinde makine öğrenimi algoritmaları ile tahmin işlemi gerçekleştirilebilmektedir. Çalışma kapsamında Linear Regression, Decision Tree Regressor, Kneighbors Regressor, Random Forest Regressor ve XGBoost makine öğrenimi algoritmaları ile yapay sinir ağı modeli kullanılmıştır.

Regresyon problemlerinde R-kare (R^2) ile uygunluk ölçülmektedir. 0 - 1 arasında bir değer alan R^2 , 1' ne kadar yakın ise modelin o denli anlamlı olduğuna işaret etmektedir [42]. Bu R^2 değerini açıklanabilen değişimin toplam değişime bölünmesiyle Eşitlik 4.1'deki gibi hesaplamak mümkündür [42]. Uygulanan modellerin uygunluğu R^2 kriteri ile değerlendirilmiştir.

$$R^2 = 1 - \frac{\sum (Y_i - \hat{Y})^2}{\sum (Y_i - \tilde{Y})^2} \quad (4.1)$$

Metodların performansını analiz edebilmek amacıyla hata fonksiyonları kullanılmaktadır. MAPE hata fonksiyonu ve doğruluk değerleri karşılaştırılarak yöntemlerin başarı durumları elde edilmiştir.

4.1.1. Veri Seti

Çalışmada entegre bir demir çelik tesisinin kükürt giderme prosesinde gerçekleşen 2020 yılına ait 3 aylık veri kullanılmıştır. Veri dosyası 4214 kayıttan oluşmaktadır. Dosyadaki bilgiler incelenerek uygulamada kullanılmak üzere baz alınması gereken özellikler tespit edilmiştir. Üretilen sıvı ham demir tonajı, mevcut kükürt ve silisyum içeriği, hedeflenen son kükürt içeriği, enjekte edilen magnezyum, kireç ve florit miktarlarının yer aldığı parametreler belirlenerek çalışma için uygun veri seti hazırlanmıştır. Hazırlanan veri setine ait küçük bir örneğe Çizelge 4.1'de yer verilmiştir.

Çizelge 4.1. Veri seti örneği.

Uygulama İçin Seçilen Parametreler						
Tonaj	Mevcut Kükürt (S)	Mevcut Silisyum (Si)	Hedef Kükürt (S)	Magnezyum (Mg)	Kireç (CaO)	Florit (CaF ₂)
140	117	116	35	80	436	83
115	196	41	35	149	812	139
105	176	49	40	101	549	100
119	181	48	40	135	730	135
111	175	54	40	107	578	109

Bu parametrelerden sıvı ham demir tonajı, mevcut kükürt değeri, mevcut silisyum değeri ve hedef kükürt değeri giriş olarak; magnezyum, kireç ve florit ise tahmin edilecek çıktılar olarak Çizelge 4.2’de tanımlanmıştır.

Çizelge 4.2. Tahmin edilecek parametreler.

Tahmin Parametreleri
Magnezyum
Kireç
Florit

4.1.2. Python

Python; Şekil 4.1’de gösterildiği gibi basit söz dizimine sahip olmasının yanında, kolay öğrenilebilir, modüler, yorumlanabilir bir script dilidir. Nesneye dayalı programlamayı desteklemektedir. C veya C++ ortamında geliştirilme imkanı tanımaktadır. Farklı işletim sistemlerinde çalışabilmektedir. Okunabilirliği ve ulaşılabilirliği kolaydır [43].

Yapay zeka, makine öğrenmesi, derin öğrenme gibi son dönem teknolojide kullanımı yaygınlaşmıştır. Verileri kolaylıkla analiz edebilme imkanı sayesinde daha çok tercih edilmektedir. Çok fazla kütüphane desteği mevcuttur. Aynı python kodunun farklı platformlarda sorunsuz çalışabiliyor olması onu güvenilir ve etkili kılmaktadır [43].

```
>>> from math import sqrt
>>> x = 2
>>> sqrt(x)
1.4142135623730951
>>> x
2
>>> x = sqrt(x)
>>> x
1.4142135623730951
```

Şekil 4.1. Python kod örneği [43].

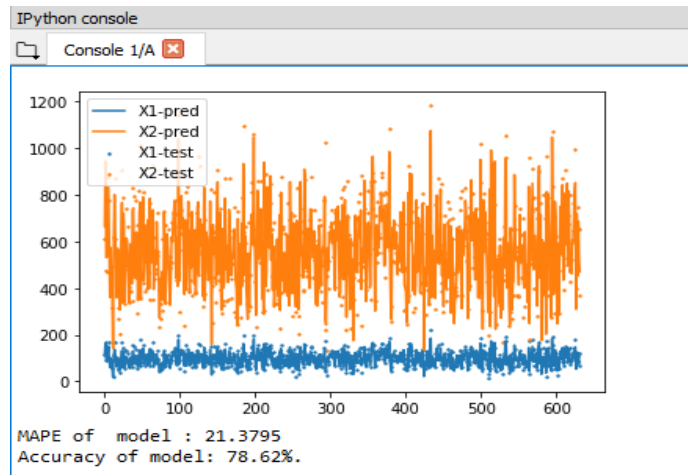
4.1.3. Spyder Programı

Python dili için kullanılan editörlerden bir tanesi de spyder programıdır. Ücretsiz ve açık kaynak bir yazılımdır. Konsol bölümünde kodlar çalıştırılmaktadır. Şekil 4.2’de olduğu gibi kod yazımında kod tamamlama özelliği mevcuttur [44].

```
1
2 import tensorflow as tf
3 from sklearn.model_selection import train_test_split
4 import numpy as np
5 import pandas as pd
6 from tensorflow import keras
7 import matplotlib.pyplot as plt
8 from tensorflow.keras.models import Model
9 from tensorflow.keras.layers import Dense, Input, Dropout, LSTM
10 from keras.models import Sequential
11 df=pd.read_csv('C:\\Users\\Desktop\\veri.csv', sep=';')
12
13 X_data = df.iloc[:, lambda df: [0, 1, 2, 4]].values
14 y_data = df.iloc[:, lambda df: [ 5]].values
15
16 X_train, X_test, y_train, y_test = train_test_split(X_data, y_data,
17
18
19 model = Sequential()
20 model.add(LSTM(units=128, dropout = 0.2, return_sequences=True))
21 model.add(LSTM(units=128, dropout = 0.2, return_sequences=False))
22 model.add(Dense(1))
23 model.compile(optimizer='adam',
24               loss='mae',
25               metrics=['mse'])
26
27
28
29 history = model.fit(X_train, y_train, epochs=100, batch_size=64, va.
30
31 ypred = model.predict(X_test)
```

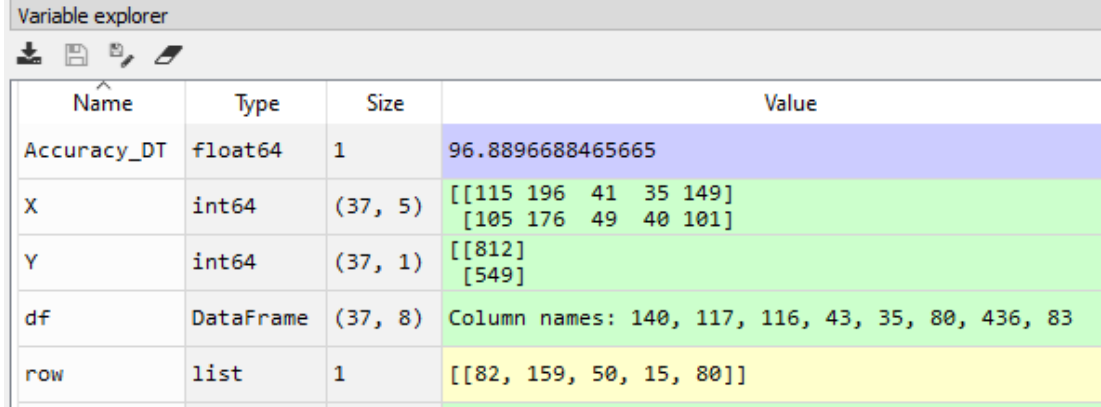
Şekil 4.2. Spyder kod editörü.

Çalıştırılan kodların sonuçlarına, verilerin grafiksel, görsel biçimlerine erişmek Şekil 4.3’te verilen örnek gibi mümkündür [44].



Şekil 4.3. Spyder konsol ekranı.

Değişkenlerin isim, tür, boyutları ve aldıkları değerlerine, Şekil 4.4'teki değişken görüntüleme ekranından ulaşılabilmektedir [44].



Name	Type	Size	Value
Accuracy_DT	float64	1	96.88966888465665
X	int64	(37, 5)	[[115 196 41 35 149] [105 176 49 40 101]]
Y	int64	(37, 1)	[[812] [549]]
df	DataFrame	(37, 8)	Column names: 140, 117, 116, 43, 35, 80, 436, 83
row	list	1	[[82, 159, 50, 15, 80]]

Şekil 4.4. Spyder değişken görüntüleme ekranı.

4.1.4. Keras Kütüphanesi

Keras, derin öğrenme ve yapay sinir ağı modellerini tanımlamak ve eğitmek amacıyla kullanılan python kütüphanesidir (Şekil 4.5). İşlevsel olması ile ağı modellerini tanımlamayı kolaylaştırmaktır. Kullanıcı dostu olup anlaşılması ve uygulanması da kolaydır [44].

Konvolüsyonel ağları, tekrar eden ağları ve bunların kombinasyonlarını da oluşturmayı desteklemektedir. CPU ve GPU üzerinde çalışmaktadır [44].

```
model = Sequential()
model.add(LSTM(units=128, dropout = 0.2, return_sequences=True))
model.add(LSTM(units=128, dropout = 0.2, return_sequences=False))
model.add(Dense(1))
model.compile(optimizer='adam',
              loss='mae',
              metrics=['mse'])
```

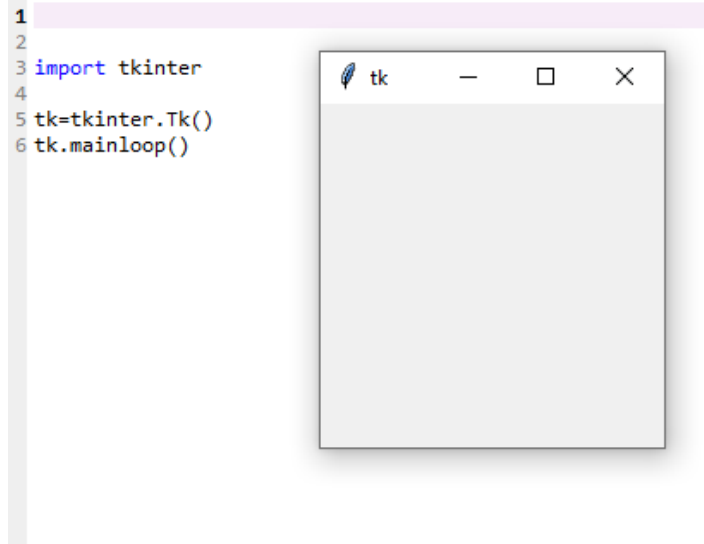
Şekil 4.5. Keras ile model oluşturma örneği.

4.1.5. Tkinter Kütüphanesi

Bir python kütüphanesi olup, arayüz geliştirme modülüdür. Form uygulamaları için olarak sağlamaktadır. Metin kutusu, buton, label gibi grafik kullanıcı arayüzü (GUI) öğelerini içermektedir [45].

Çalışmada; bir arayüz üzerinde tasarlanan formda ilgili bilgilerin girişi, sonuçların görüntülenmesi şeklinde kullanıcının işlemler yapması hedeflenmiştir. Bu nedenle projeye tkinter kütüphanesi dahil edilmiştir.

“Import tkinter” komutu ile modül aktif hale getirilmektedir. Şekil 4.6’da form oluşturma gerçekleştirilmektedir.



Şekil 4.6. Tkinter ile form oluşturma.

4.2. DENEYSEL SONUÇLAR

Çalışma için gerekli programların kurulumu gerçekleştirilmiş ve kullanılacak kütüphaneler projeye dahil edilmiştir. Hazırlanan veri seti de eklenerek %80’i eğitim, %20’si ise test amacıyla ayrılmıştır. Bu işlemlerin ardından model kurgulama aşamasına geçilmiştir.

Çalışmada, tesiste kullanılan kükürt giderici üç reaktif malzeme için tahmin işlemi uygulanmıştır. Bu tahminlerin her biri için ayrı model oluşturulmuştur. Öncelikli hedef; magnezyum miktarının elde edilmesidir. Mg tahmin işleminden sonra CaO parametresinin tahmini için giriş verilerine Mg parametresi ilave edilmiştir. Bir sonraki malzeme olan CaF₂ için de Mg ve CaO parametreleri girdiye eklenmiştir.

Bu kurgu dahilinde Linear Regression, KNeighborsRegressor, Decision Tree Regressor, Random Forest Regressor ve XGBoost metodları uygulanmıştır. Algoritmalar kütüphanelerde tanımlı olup; LinearRegression, KNeighborsRegressor, DecisionTreeRegressor, RandomForestRegressor ve XGBRegressor fonksiyonları ile uygulamaya dahil edilmiştir. RandomForestRegressor metodunda n_estimators parametresi 100 olarak seçilmiştir. XGBRegressor için aşağıdaki şekilde parametreler belirlenmiştir (Şekil 4.7). Diğer metodlar varsayılan hali ile kullanılmıştır.

```
XGBRegressor(base_score=0.5, booster='gbtree', colsample_bylevel=1,
              colsample_bynode=1, colsample_bytree=1, gamma=0,
              importance_type='gain', learning_rate=0.1, max_delta_step=0,
              max_depth=3, min_child_weight=1, n_estimators=100,
              n_jobs=1, nthread=None, random_state=0,
              reg_alpha=0, reg_lambda=1, scale_pos_weight=1, seed=None,
              silent=None, subsample=1, verbosity=1)
```

Şekil 4.7. XGBoost modeli için kullanılan parametreler.

Regresyon modellerinin uygunluk ölçüsü R² ile analiz edilebilmektedir. Bu doğrultuda R² değerleri hesaplanmıştır. Metodların performanslarını değerlendirebilmek için hata fonksiyonlarından faydalanılmıştır. Uygulama sonuçlarından elde edilen değerlere aşağıdaki çizelgelerde yer verilmiştir.

Çizelge 4.3. Linear Regression metodunun sonuçları.

Parametre	R ²	MAE	MSE	RMSE	MAPE	Doğruluk
Mg	0.71	14.27	349.54	18.695	17.15	%82.85
CaO	0.31	42.33	70426.28	265.379	6.03	%93.96
CaF ₂	-2.07	17.33	5226.85	72.296	25.05	%74.94

Çizelge 4.4. Kneighbors Regressor metodunun sonuçları.

Parametre	R ²	MAE	MSE	RMSE	MAPE	Doğruluk
Mg	0.68	14.97	390.76	19.767	18.28	%81.72
CaO	0.31	47.7	71127.19	266.696	7.81	%92.19
CaF ₂	0.64	17.2	609.84	24.694	25.48	%74.51

Çizelge 4.5. Decision Tree Regressor metodunun sonuçları.

Parametre	R ²	MAE	MSE	RMSE	MAPE	Doğruluk
Mg	0.50	36.69	2447.3	49.470	46.74	%53.26
CaO	0.30	238.42	143506.54	378.822	48.53	%51.47
CaF ₂	0.68	47.26	3448.7	58.725	65.86	%34.14

Çizelge 4.6. Random Forest Regressor metodunun sonuçları.

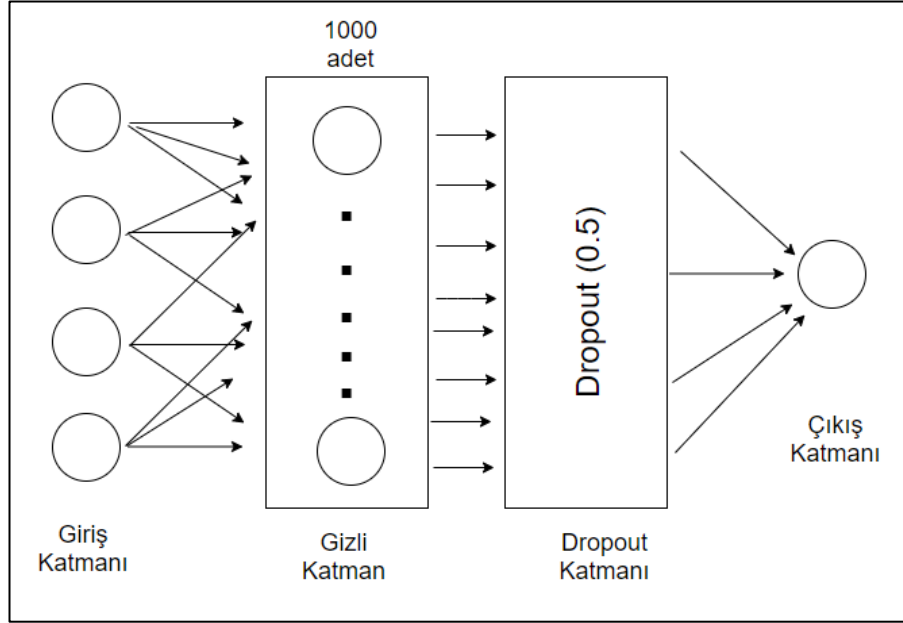
Parametre	R ²	MAE	MSE	RMSE	MAPE	Doğruluk
Mg	0.71	37.61	2193.21	46.831	44.70	%55.29
CaO	0.31	234.98	140987.77	375.483	47.82	%52.18
CaF ₂	0.81	44.67	3083.64	55.530	63.24	%36.76

Çizelge 4.7. XGBoost metodunun sonuçları.

Parametre	R ²	MAE	MSE	RMSE	MAPE	Doğruluk
Mg	0.75	37.35	2163.51	46.513	44.37	%55.63
CaO	0.32	233.96	140331.99	374.609	47.61	%52.39
CaF ₂	0.77	43.74	2974.62	54.540	62.18	%37.82

Aynı kurgudan hareket ederek bir yapay sinir ağı modeli geliştirilmeye çalışılmıştır. Modelde yer alan hiperparametrelerin seçimi için herhangi bir kural söz konusu değildir. Dolayısıyla modelin giriş, gizli ve çıkış katmanlarının ne kadar nöron içermesi gerektiği durumları deneme yanılma yöntemiyle gerçekleştirilebilmektedir. Bu nedenle katman ve nöron sayıları değiştirilerek denemeler yapılmıştır. Optimizasyon fonksiyonu olarak “Adam”, aktivasyon için “ReLU” fonksiyonu tercih edilmiştir. 100 iterasyon ile işlem yapılmıştır.

Modelin performansını analiz edebilmek amacıyla önceki yöntemlerde de olduğu gibi “MAE”, “MSE”, “RMSE” ve “MAPE” hata fonksiyonları kullanılmıştır. Oluşturulan modellerin yapısı Şekil 4.8’deki gibi gerçekleşmiştir.




Şekil 4.8. Tasarlanan ağ modeli.

Geliştirilen modelde; Mg tahmininde doğruluk değeri %85; MAPE 14.9 olarak sonuçlanmış olup detaylarına Çizelge 4.8’de yer verilmiştir.

Çizelge 4.8. Mg parametresi için uygunluk ve performans değerleri.


R ²	0.75
MAE	13.14
MSE	290.68
RMSE	17.049
MAPE	14.99
Doğruluk	%85

Modelin eğitim ve test aşamasında MSE loss fonksiyonu kullanılarak Şekil 4.9'daki gibi hata grafiği elde edilmiştir.



Şekil 4.9. Mg loss grafiği.

Test verileri kullanıldığında, gerçekleşen Mg tahmin değerleri ile gerçek değerlerin dağılımı Şekil 4.10'daki haliyle sonuçlanmıştır.



Şekil 4.10. Mg gerçek ve tahmin değerlerinin dağılımı.

Modelin eğitimi sonucunda test amaçlı veri girişleri yapılarak elde edilen tahmin sonuçlarına dair örnekler Çizelge 4.9’da sunulmuştur.

Çizelge 4.9. Mg parametresi için değerlerin karşılaştırılması.


Gerçek Değer	Tahmin Sonucu
177	176.26
169	144.52
122	115.73
169	144.52
111	118.26
75	68.64

CaO tahmini için giriş parametrelerine bağımlı değişken olarak Mg da ilave edilmiş ve model kurgulanmıştır. Tasarlanan bu modelin doğruluk oranı %95.41; MAPE değeri 4.59 şeklinde gerçekleşmiştir. CaO için performans ve uygunluk kriterlerine Çizelge 4.10’da yer verilmiştir.

Çizelge 4.10. CaO parametresi için uygunluk ve performans değerleri.


R ²	0.96
MAE	25.87
MSE	1390.29
RMSE	37.28
MAPE	4.59
Doğruluk	%95.41

CaO için eğitim ve test ile oluşan hata değerleri Şekil 4.11 ile grafik haline getirilmiştir.



Şekil 4.11. CaO loss grafiği.

Modelin test verilerine göre tahmin ettiği CaO değerleri ile gerçek değerlerin dağılımı Şekil 4.12’de ve karşılaştırılan örnekler Çizelge 4.11’deki gibi sonuçlanmıştır.



Şekil 4.12. CaO gerçek ve tahmin değerlerinin dağılımı.

Çizelge 4.11. CaO parametresi için değerlerin karşılaştırılması.


Gerçek Değer	Tahmin Sonucu
985	961.26
872	857.82
811	817.55
510	516.89
625	621.32
473	484.38

Son parametre olarak CaF_2 değerinin tahmini için Mg ve CaO kriterleri de girdiye dahil edildiğinde; hazırlanan modelin çalıştırılması sonucunda %80.14 oranında doğruluk; 19.85 oranında da MAPE elde edilmiştir. Sonuçlar Çizelge 4.12’de gösterilmiştir.

Çizelge 4.12. CaF₂ parametresi için uygunluk ve performans değerleri.


R ²	0.65
MAE	14.69
MSE	659.08
RMSE	25.67
MAPE	19.85
Doğruluk	%80.14

Eğitim ve test verileri ile Şekil 4.13'te olduğu gibi modelin hata grafiğine ulaşılmıştır.



Şekil 4.13. CaF₂ loss grafiği.

CaF₂ parametresi için gerçekleşen tahminler ve tesisin gerçek değerlerinin dağılımı grafik olarak sunulmuştur (Şekil 4.14).



Şekil 4.14. CaF₂ gerçek ve tahmin değerlerinin dağılımı.

Test örnekleri ile CaF₂ parametresinin tahmin sonuçları ve gerçek değerleri Çizelge 4.13 ile tablo haline getirilmiştir.

Çizelge 4.13. CaF₂ parametresi için değerlerin karşılaştırılması.

Gerçek Değer	Tahmin Sonucu
172	169.22
168	152.35
170	175.84
69	69.96
80	72.68
133	142.14

Uygulanan tüm modellerin karşılaştırılması Çizelge 4.14 ile yapılarak başarı oranı en yüksek yöntemin yapay sinir ağı ile olduğuna karar verilmiştir.

Çizelge 4.14. Modellerin karşılaştırılması.

Metodlar	Mg		CaO		CaF ₂	
	MAPE	Doğruluk	MAPE	Doğruluk	MAPE	Doğruluk
Linear Regression	17.15	%82.85	6.03	%93.96	25.05	%74.94
Kneighbors Regressor	18.28	%81.72	7.81	%92.19	25.48	%74.51
Decision Tree Regressor	46.74	%53.26	48.53	%51.47	65.86	%34.14
Random Forest Regressor	44.70	%55.29	47.82	%52.18	63.24	%36.76
XGBoost	44.37	%55.63	47.61	%52.39	62.18	%37.82
Yapay Sinir Ağı Modeli	14.99	%85	4.59	%95.41	19.85	%80.14

Tasarlanan modelin analizi tamamlandıktan sonra çalışmanın tesiste kullanımı için bir arayüz hazırlanmıştır. Python ile spyder ortamında geliştirilen form uygulamasında kullanıcının parametre değerlerini girip tahmin işlemini gerçekleştirmesi beklenmektedir. Şekil 4.15’de yer alan arayüz ekranından ağ eğitimi tamamlandıktan sonra girdiler eklenerek tahmin değerleri görüntülenebilmektedir.

Sıvı Ham Demir Desülfürizasyon Prosesi İçin Malzeme Enjeksiyon Tahmin Ekranı

AĞI EĞİT

Eğitim Tamamlandı..

Tahmin değerleri için aşağıdaki alanlara giriş yapınız!..

Tonaj Değerini Giriniz

Torpido S Değerini Giriniz

Torpido Si Değerini Giriniz

Hedef S Değerini Giriniz

TAHMİN ET

Mg Tahmini

CaO Tahmini

CaF₂ Tahmini

123.43121

686.36127

115.97762

Şekil 4.15. Hazırlanan arayüz ekranı.

BÖLÜM 5

SONUÇLAR VE TARTIŞMA

Bu çalışmada, üretilen sıvı ham demirde kükürt giderme işlemi için kullanılan malzeme miktarlarını tahminleyen makine öğrenme yöntemleri uygulanmıştır. Ayrıca yapay sinir ağı metodu ile bir model geliştirilmiş olup modelin çalıştırılması sonucunda doğruluk değeri Mg için %85, CaO için %95.4 ve CaF₂ için ise %80.14 oranında gerçekleşmiştir.

Test verileriyle sonuçlanan tahminler ve gerçek değerlerin karşılaştırılması neticesinde; modellerin MAPE hata fonksiyonları hesaplanarak yapay sinir ağı ile tasarlanan modelde Mg için 14.9, CaO için 4.59 ve CaF₂ için ise 19.85 değerlerine ulaşılmıştır. MAPE hata fonksiyonundan çıkan sonuçlara göre; literatürde yer aldığı gibi %20'den küçük oranların elde edilmesi geliştirilen modelin doğru tahmin modellerine örnek olduğunu göstermektedir.

Uygulanan Linear Regression, Kneighbors Regressor, Decision Tree Regressor, Random Forest Regressor ve XGBoost metodlarından elde edilen değerlere göre kurgulanan yapay sinir ağı modelinin sonuçlarının daha başarılı olduğu görülmüştür.

Başarı oranının daha da artırılabilmesi ve hata değerlerinin düşürülmesi için sinir ağının mimarisinde değişiklikler yapılabilir ve katman ile nöron sayıları farklı tercih edilebilir. Modelin yapısını belirleyen herhangi bir standart yapı bulunmamaktadır. Katman ve nöron gibi parametre seçimleri deneme yanılma metodu ile gerçekleşmekte ve uygulanmaktadır. Ayrıca seçilen diğer hiperparametreler de model performansını etkileyen faktörlerdir. Çalışma, bu kriterler göz önünde bulundurularak geliştirmeye açıktır.

Tez kapsamında ařađıda belirtilen akademik alıřma gerekleřtirilmiřtir:

Uluslararası bildiri: “Predicting the amount of materials used for desulphurization process using machine learning”, 1st International Conference on Electrical-Electronics and Computer Engineering (ICEECE), 2021.

KAYNAKLAR

1. Çetin, Z., “Sürekli döküm prosesinde pota nozulu tıkanma probleminin analizi ve azaltılması”, Yüksek Lisans Tezi, *İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü*, İstanbul, 1-6 (2016).
2. Köprü, E.Y., “Yapay sinir ağları ile sıvı ham demir tahmini ve 5. yüksek fırın uygulaması”, Yüksek Lisans Tezi, *Karabük Üniversitesi Lisansüstü Eğitim Enstitüsü*, Karabük, 3 (2020).
3. Yıldız, K., “Demir Çelik Metalurjisi”, *Sakarya*, 53-54, 64-65, 68 (2017).
4. Özmen, K., Eskiuyurt, T.G., Şahin, H., Erkal, H., Kocabaş, T., Çakır, A.M. and Soysal Atan, B., “Sıvı ham demir kükürt giderme prosesinde kullanılan granule magnezyum tüketiminin seviye-2 yazılımı ile optimizasyonu”, *19. Uluslararası Metalurji ve Malzeme Kongresi*, İstanbul, 1-4 (2018).
5. Ersöz, F., Ersöz, T. and Erkmen, İ.N., “Dünyada ve Türkiye’de ham çelik üretimine bakış”, *Erciyes Üniversitesi Fen Bilimleri Enstitüsü Fen Bilimleri Dergisi*, Kayseri, 1-2 (2016).
6. Yamanoglu, R., “Metalurji Mühendisliğine Giriş Ders 7”, *Kocaeli Üniversitesi Metalurji ve Malzeme Mühendisliği Bölümü*, Kocaeli (2020).
7. Türkoğlu, S., “Developing oxygen amount prediction model of basic oxygen furnace steelmaking process with machine learning algorithms”, Yüksek Lisans Tezi, *Çukurova Üniversitesi Fen Bilimleri Enstitüsü*, Adana, III-VI (2017).
8. Çevre ve Şehircilik Bakanlığı, “Entegre Demir Çelik Üretimi”, Sanayiden Kaynaklanan Hava Kirliliğinin Belirlenmesi ve Azaltılmasına Yönelik Uygulamanın Kolaylaştırılmasının Sağlanması Projesi, *Dokuz Eylül Üniversitesi*, 2, (2020).
9. Köksel Kara, M., “Sürekli tavlama yöntemi ile yeni kalite bir emaye çeliği üretimi”, Yüksek Lisans Tezi, *İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü*, İstanbul, 58 (2014).
10. Tetik, Y., “Alüminyum tüketimini azaltmak için kok ile ön deoksidasyon işlemi ve prensibi”, Yüksek Lisans Tezi, *İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü*, İstanbul, 7-8 (2015).
11. İnternet: Çetin, A., “Çeliklerde alaşım elementlerinin etkileri”, <https://dokumhane.net/kutuphane/celiklerde-alasim-elementlerinin-etkileri/> (2019).

12. İnternet: Sarna, K. S., “Desulphurization of Hot Metal”, <https://ispatguru.com/desulphurization-of-hot-metal/> (2013).
13. Visuri, V.V., Vuolio, T., Haas, T. and Fabritius, T., “A review of modeling hot metal desulfurization”, *Steel Research International*, 91 (4): 2-3 (2020).
14. Deo, B., Datta, A., Haresh, M., Kalra, P.K. and Boom, R., “Adaptive neural net (ANN) models for desulphurization of hot metal and steel”, *Steel Research International*, 65 (11): 466-471 (1994).
15. Rong Z., Dan, B. and Yi, J., “A bp neural network predictor model for desulfurizing molten iron”, *International Conference on Advanced Data Mining and Applications*, 728-735 (2005).
16. Jin, Y., Bi, X.G. and Yu, S.R., “Kinetic model for powder injection desulfurization”, *Acta Metallurgica Sinica*, 19 (4): 258-264 (2006).
17. Vinoo, D.S., Mazumdar, D. and Gupta, S.S., “Optimization and prediction model of hot metal desulphurisation”, *Ironmaking & Steelmaking*, 34 (6): 471- 476 (2007).
18. Zhan, D.P., Zhang, H. and Jiang, Z., “Prediction model of magnesium powder consumption during hot metal pre-desulfurization”, *China Metallurgy*, (2010).
19. Liang, X.P., Ban, S.X., Wang, Y., Ge, W.S. and Huang Z.H., “Research and application of desulfurizer addition amount prediction model based on neural network”, *Metallurgical Industry*, (2011).
20. Wang, Y. and Zhang, Y., “Hot metal desulphurization control model based on PCA-RBFNN”, *Chinese Control and Decision Conference (CCDC)*, (2011).
21. Vuolio, T., Visuri, V.V, Sorsa, A. and Paananen, T., “Genetic algorithm-based variable selection in prediction of hot metal desulfurization kinetics”, *Steel Research International*, 90 (8): 1-20 (2019).
22. Feng, K., Xu, A.J., He, D.F. and Yang, L., “Case-based reasoning method based on mechanistic model correction for predicting endpoint Sulphur content of molten iron in KR desulphurization”, *Ironmaking & Steelmaking*, 47 (7): 799-806 (2019).
23. Alan, A., “Makine öğrenmesi sınıflandırma yöntemlerinde performans metrikleri ile test tekniklerinin farklı veri setleri üzerinde değerlendirilmesi”, Yüksek Lisans Tezi, *Fırat Üniversitesi Fen Bilimleri Enstitüsü*, Elazığ, 6-12 (2020).
24. Kutlugün, M.A., “Gözetimli makine öğrenmesi yoluyla türe göre metinden ses sentezleme”, Yüksek Lisans Tezi, *İstanbul Sabahattin Zaim Üniversitesi Fen Bilimleri Enstitüsü*, İstanbul, 30-32 (2017).

25. Görgün, M., “Makine öğrenmesi yöntemleri ile kalp hastalığının teşhis edilmesi”, Yüksek Lisans Tezi, *İstanbul Aydın Üniversitesi Lisansüstü Eğitim Enstitüsü*, İstanbul, 11-30 (2020).
26. Karaatlı, M., Helvacıoğlu, Ö.C., Ömürbek, N. and Tokgöz, G., “Yapay sinir ağları yöntemi ile otomobil satış tahmini”, *Uluslararası Yönetim İktisat ve İşletme Dergisi*, 8 (17): 87-100 (2012).
27. Adıyaman, F., “Talep tahmininde yapay sinir ağlarının kullanılması”, Yüksek Lisans Tezi, *İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü*, İstanbul, 6 (2007).
28. Küçükönder, H., “Yapay sinir ağları ve tarımda bir uygulama”, Doktora Tezi, *Kahramanmaraş Sütçü İmam Üniversitesi Fen Bilimleri Enstitüsü*, Kahramanmaraş, 4, 86-87 (2011).
29. Calp, M. H., “İşletmeler için personel yemek talep miktarının yapay sinir ağları kullanılarak tahmin edilmesi”, *Politeknik Dergisi*, 22 (3): 678 (2019).
30. İnternet: Ayyüce Kızrak, “Derin öğrenme için aktivasyon fonksiyonlarının karşılaştırılması”, <https://ayyucekizrak.medium.com/derin-ogrenme-icin-aktivasyon-fonksiyonlarının-karşılaştırılması-ccc17fd1d9cd> (2019).
31. Seyyarer, E., Ayata, F., Uçkan, T. and Karcı, A., “Derin öğrenmede kullanılan optimizasyon algoritmalarının uygulanması ve kıyaslanması”, *Anatolian Journal of Computer Sciences*, 5 (2): 92-95 (2020).
32. Ser, G. and Bati, C.T., “Derin sinir ağları ile en iyi modelin belirlenmesi: Mantar verileri üzerine keras uygulaması”, *Yüzüncü Yıl Üniversitesi Tarım bilimleri Dergisi*, 29 (3): 410-411 (2019).
33. Gök, B., “Makine öğrenmesi yöntemleri ile akademik başarının tahmin edilmesi”, *Gazi Üniversitesi Fen Bilimleri Dergisi*, 5 (3): 139-148 (2017).
34. Uğuz, S., Oral, O. and Çağlayan, N., “PV güç santrallerinden elde edilecek enerjinin makine öğrenme metotları kullanılarak tahmin edilmesi”, *Uluslararası Mühendislik Araştırma ve Geliştirme Dergisi*, 11 (3): 769-779 (2019).
35. Özgür, E.G. and Erdoğan, B.D., “Bilgisayar uyarlamalı test (BUT) uygulamalarında regresyon ağacı yaklaşımı: Regresyon karar ağaçları ile psikometrik model kullanan standart BUT algoritmasının yapay bir veri üzerinde değerlendirilmesi”, *Ankara Sağlık Bilimleri Dergisi*, 9 (1): 161-167 (2020).
36. Başer, B.Ö., Yangın, M. and Sarıdaş, E.S., “Makine öğrenmesi teknikleriyle diyabet hastalığının sınıflandırılması”, *Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 25 (1): 112-120 (2021).

37. Dilwani, A.A.R., “Makine öğrenmesi ile acil triyaj ve hastane yatış tahmini”, Yüksek Lisans Tezi, *Ankara Üniversitesi Fen Bilimleri Enstitüsü*, Ankara, 24-28 (2019).
38. Yangın, G., “Xgboost ve karar ağacı tabanlı algoritmaların diyabet veri setleri üzerine uygulaması”, Yüksek Lisans Tezi, *Mimar Sinan Güzel Sanatlar Üniversitesi Fen Bilimleri Enstitüsü*, İstanbul, 31-38 (2019).
39. Karabıçak, Ç., Avcı, S., Akman, G. and Aladağ, Z., “Determination of demand estimation methods by values and variability measures for stock items in a cleaning paper company”, *Journal of Current Researches on Engineering Science and Technology*, 4 (1): 58-59 (2018).
40. İnternet: Veri Bilimcisi, “MSE, RMSE, MAE, MAPE ve Diğer Metrikler”, <https://veribilimcisi.com/2017/07/14/mse-rmse-mae-mape-metrikleri-nedir/> (2017).
41. İnternet: Brownlee, J., “How to Develop Multi-Output Regression Models with Python”, Machine Learning Mastery, <https://machinelearningmastery.com/multi-output-regression-models-with-python/>, (2020).
42. Özkan, M., “GDM206 Reaksiyon Kinetiği 4. Hafta”, *Ankara Üniversitesi Gıda Mühendisliği Bölümü*, Ankara (2018).
43. Ürün, S., “Python ile Programlamanın Temelleri”, 3-4, 7, 57 (2019).
44. Alkan, O., “Parkinson hastalığının teşhisinde derin öğrenme yöntemi ile spect görüntü analizi”, Yüksek Lisans Tezi, *Ağrı İbrahim Çeçen Üniversitesi Fen Bilimleri Enstitüsü*, Ağrı, 25-29, 31-32 (2019).
45. İnternet: Yazılım Bilişim, “Python Tkinter Örnekleri”, <https://yazilimbilisim.net/python/python-tkinter-orneklere/>, (2019).

ÖZGEÇMİŞ

Esra ÖZCAN, 2015 yılında Karabük Üniversitesi Bilgisayar Mühendisliği bölümünden mezun oldu. 2020 yılına kadar Karabük Demir Çelik Sanayi ve Ticaret A.Ş.'de Yazılım Mühendisi olarak görev yaptı. Bu tarihten itibaren aynı yerde İç Denetçi unvanı ile çalışmaya devam etmektedir.