



# **YAPAY SİNİR AĞLARI İLE SIVI HAM DEMİR TAHMİNİ VE 5. YÜKSEK FIRIN UYGULAMASI**

**Ertan Yavuz KÖPRÜ**

**2020  
YÜKSEK LİSANS TEZİ  
BİLGİSAYAR MÜHENDİSLİĞİ**

**Tez Danışmanı  
Dr. Öğr. Üyesi Caner ÖZCAN**

**YAPAY SINIR AĞLARI İLE SIVI HAM DEMİR TAHMİNİ VE 5. YÜKSEK  
FIRIN UYGULAMASI**

**Ertan Yavuz KÖPRÜ**

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

**Tez Danışmanı  
Dr. Öğr. Üyesi Caner ÖZCAN**

**KARABÜK  
Ekim 2020**

Ertan Yavuz KÖPRÜ tarafından hazırlanan “YAPAY SINIR AĞLARI İLE SIVI HAM DEMİR TAHMİNİ VE 5.YÜKSEK FIRIN UYGULAMASI” başlıklı bu tezin Yüksek Lisans Tezi olarak uygun olduğunu onaylarım.

Dr. Öğr. Üyesi Caner ÖZCAN

.....

Tez Danışmanı, Bilgisayar Mühendisliği Anabilim Dalı

Bu çalışma, jürimiz tarafından oy birliği ile Bilgisayar Mühendisliği Anabilim Dalında Yüksek Lisans tezi olarak kabul edilmiştir. 02.10.2020

Ünvanı, Adı SOYADI (Kurumu)

İmzası

Başkan : Doç. Dr. İlhami Muharrem ORAK (KBÜ)

.....

Üye : Doç. Dr. Salih GÖRGÜNOĞLU (KÜ)

.....

Üye : Dr. Öğr. Üyesi Caner ÖZCAN (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.”*

Ertan Yavuz KÖPRÜ

## **ÖZET**

**Yüksek Lisans Tezi**

### **YAPAY SİNİR AĞLARI İLE SIVI HAM DEMİR TAHMİNİ VE 5.YÜKSEK FIRIN UYGULAMASI**

**Ertan Yavuz KÖPRÜ**

**Karabük Üniversitesi**

**Lisansüstü Eğitim Enstitüsü**

**Bilgisayar Mühendisliği Anabilim Dalı**

**Tez Danışmanı:**

**Dr. Öğr. Üyesi Caner ÖZCAN**

**Ekim 2020, 54 sayfa**

Demir cevherinden çelik üretimi zor ve zahmetli bir süreçtir. Çelik üretiminin yanında ürün planlamanın da doğru bir şekilde yapılması demir-çelik sektöründe büyük önem arz etmektedir. Yüksek fırın işletmesi hem istenilen miktarda sıvı ham demir üretmeye hem de üretimde kullanılacak ham madde miktarını aşmamaya özen göstermektedir. Bu hammaddelerin takibi işletmelerin otomasyon birimleri tarafından dijital ortamda gerçekleştirilmekte ve kayıt altına alınmaktadır.

Bu çalışmada, yüksek fırın işletmesine ait aylık ham madde bilgileri kullanılarak yapay sinir ağı ile üretilen sıvı ham demir miktarının tahmin edilmesi amaçlanmıştır. Bu sayede hem üretim ve tüketim planlama süreci daha hızlı bir şekilde yapılırken hem de işletmeler arasındaki bilgi alışverişinin de kolaylaştırılması sağlanacaktır.

İşletme sahasından alınan üretim verilerinin normalizasyonu yapılarak yapay sinir ağı için anlamlı ve kullanılabilir hâle getirilmiştir. Bu kapsamda, 2016 ve 2019 yılları arasına ait 1000 adet aylık üretim verisi %70'lik kısmı eğitim, geri kalan %30'luk kısmı test için ayrılmıştır. Tahmin edilen sıvı ham demir miktarı, 5.yüksek fırın tarafından üretilen gerçek sıvı ham demir miktarı karşılaştırılarak değerlendirilmiştir.

**Anahtar Sözcükler :** Yapay Sinir Ağı, Tahmin, Yüksek Fırın, Sıvı Ham Demir, Demir Cevheri.

**Bilim Kodu** : 92431

## **ABSTRACT**

**M. Sc. Thesis**

### **ESTIMATION OF PIG RAW IRON WITH ARTIFICIAL NEURAL NETWORKS AND 5TH BLAST FURNACE APPLICATION**

**Ertan Yavuz KÖPRÜ**

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

**Thesis Advisor:**

**Assist. Prof. Dr. Caner ÖZCAN**

**October 2020, 54 pages**

Steel production from iron ore is a difficult and demanding process. Proper product planning as well as steel production is very important in the iron and steel industry. The blast furnace process pays attention not only to produce the desired amount of pig iron, but also to not exceed the amount of raw materials to be used in production. The tracking of these raw materials is monitored and recorded in digital environment by the automation units of the operations.

In this study, it is aimed to estimate the amount of pig iron produced by using the monthly raw material information of the blast furnace process with artificial neural network. In this way, it will be ensured that both the production and consumption planning process is carried out more quickly and the information exchange between the process is facilitated.

The production data received from the process site was first passed through the necessary normalization process and made meaningful and usable for the artificial neural network. 70% of the 1000 monthly production data between 2016 and 2019 are reserved for education and the remaining 30% for testing. The estimated amount of pig iron was evaluated by comparing the actual amount of pig iron produced by the 5th blast furnace.

**Key Word** : Artificial Neural Network, Prediction, Blast Furnace, Pig Iron, Iron Ore.

**Science Code** : 92431



## TEŐEKKÜR

Bu teze ait alıŐma planının oluŐturulmasında, literatur taramasında, iŐletilmesi ve uygulanmasında alaka ve yardımlarını esirgemeyen, üst düzey bilgi ve tecrübelerinden faydalandığım, tez alıŐmamı bilimsel kurallar dođrultusunda yönlendiren sayın hocam Dr. Öğr. Üyesi Caner ÖZCAN'a sonsuz teşekkürlerimi sunarım.

alıŐmaların yapılmasında yardımlarını esirgemeyen, KARDEMİR Yüksek Fırınlr Müdürü Fikret FURTUN'a, 5. Yüksek Fırın İŐletme Mühendisi Mert Orkun HEKİM'e ve alıŐma arkadaşım İsa YURDABAKAN'a teşekkür ederim.

Sevgili aileme her türlü yardımı esirgemedен destekçim oldukları için tüm kalbimle teşekkür ederim.

## İÇİNDEKİLER

	<u>Sayfa</u>
KABUL.....	ii
ÖZET.....	iv
ABSTRACT.....	vi
TEŞEKKÜR.....	viii
İÇİNDEKİLER .....	ix
ŞEKİLLER DİZİNİ.....	xi
ÇİZELGELER DİZİNİ .....	xii
SİMGELER VE KISALTMALAR DİZİNİ .....	xiii
BÖLÜM 1 .....	1
GİRİŞ .....	1
BÖLÜM 2 .....	3
YÜKSEK FIRINLARDA SIVI HAM DEMİR ÜRETİMİ.....	3
BÖLÜM 3 .....	11
YAPAY SİNİR AĞLARI MİMARİSİ .....	11
3.1. YAPAY SİNİR AĞINDAKİ HÜCRELERİN ELEMANLARI .....	14
3.2. YAPAY SİNİR AĞLARINDA EĞİTİM .....	15
3.3. YAPILARINA GÖRE YAPAY SİNİR AĞLARI .....	16
3.3.1. İleri Beslemeli Ağlar .....	16
3.3.2. Geri Beslemeli Ağlar .....	17
3.4. YAPAY SİNİR AĞININ TASARIMI .....	19
3.4.1. Nöron ve Katman Sayısının Belirlenmesi .....	20
3.4.2. Aktivasyon Fonksiyonu Seçimi .....	20
3.4.3. Normalizasyon .....	21
3.4.4. Momentum ve Öğrenme Katsayısı .....	22
3.5. YAPAY SİNİR AĞLARINDA ÖĞRENME ALGORİTMALARI.....	23

	<b><u>Sayfa</u></b>
3.5.1. Levenberg Marquardt Algoritması .....	23
3.5.2. Bayesian Algoritması.....	24
3.5.3. Broyden Fletcher Goldfarb Shanno Algoritması.....	24
<b>BÖLÜM 4 .....</b>	<b>26</b>
<b>YÜKSEK FIRINLARDAKİ SIVI HAM DEMİR ÜRETİMİNİN YAPAY SİNİR AĞLARI KULLANILARAK TAHMİN EDİLMESİ .....</b>	<b>26</b>
4.1. KULLANILAN MATERYALLER .....	26
4.2. GİRİŞ VE ÇIKIŞ PARAMETRELERİNİN BELİRLENMESİ.....	26
4.2.1. Cevher.....	28
4.2.2. Metalurjik Kok.....	28
4.2.3. Fluks .....	29
4.2.4. Sıcak Hava .....	29
4.2.5. Sıvı Ham Demir .....	29
4.3. YAPAY SİNİR AĞINDA KULLANILAN YÖNTEMLER .....	33
4.4. GERÇEKLEŞTİRİLEN DENEYSEL ÇALIŞMALAR.....	34
4.5. YSA MODELLERİNİN PERFORMANSININ DEĞERLENDİRİLMESİ ..	39
4.5.1. Levenberg Marquardt Geri Yayılım Algoritması Sonuçları.....	40
4.5.2. Bayesian Algoritması Sonuçları .....	41
4.5.3. Broyden Flechter Goldfarb Shanno Algoritması Sonuçları.....	42
4.6. VİSUAL STUDIO PLATFORMUNDA HAZIRLANAN YAPAY SİNİR AĞI UYGULAMASI.....	43
4.7. PLATFORM DEĞİŞİKLİĞİ ANALİZİ .....	47
<b>BÖLÜM 5 .....</b>	<b>49</b>
<b>SONUÇLAR VE TARTIŞMA .....</b>	<b>49</b>
<b>KAYNAKLAR .....</b>	<b>50</b>
<b>ÖZGEÇMİŞ .....</b>	<b>54</b>

## ŞEKİLLER DİZİNİ

### Sayfa

Şekil 2.1. Yüksek fırınlarda sıvı pik üretimi ve gerçekleşen reaksiyonlar .....	4
Şekil 2.2. Yüksek fırın takip ekranı .....	5
Şekil 2.3. Yüksek fırından döküm alan bir torpedo .....	7
Şekil 3.1. Sinir hücresinin yapısı .....	12
Şekil 3.2. Yapay sinir ağındaki nöron yapısı .....	13
Şekil 3.3. Üç katmanlı yapay sinir ağı .....	14
Şekil 3.4. İleri beslemeli YSA .....	17
Şekil 3.5. Geri beslemeli YSA .....	18
Şekil 4.1. Yüksek fırın giriş ve çıkış parametreleri .....	27
Şekil 4.2. Ara katmanında bir nöron bulunan YSA mimarisi.....	34
Şekil 4.3. Ara katmanında bir nöron bulunan YSA'nın eğitim ve test korelasyon sonuçları.....	34
Şekil 4.4. Ara katmanında iki nöron bulunan YSA'nın eğitim ve test korelasyon sonuçları.....	35
Şekil 4.5. Ara katmanında üç nöron bulunan YSA'nın eğitim ve test korelasyon sonuçları.....	36
Şekil 4.6. Ara katmanında dört nöron bulunan YSA'nın eğitim ve test korelasyon sonuçları.....	36
Şekil 4.7. Tasarlanan yapay sinir ağı mimarisi .....	38
Şekil 4.8. Levenberg Marquardt Algoritması ile yapılan eğitim ve test korelasyon sonuçları.....	40
Şekil 4.9. Bayesian Algoritması ile yapılan eğitim ve test korelasyon sonuçları ....	41
Şekil 4.10. BFGS Marquardt Algoritması ile yapılan eğitim ve test korelasyon sonuçları.....	42
Şekil 4.11. Visual Studio ile hazırlanan YSA tahmin programının arayüzü .....	44
Şekil 4.12. Visual Studio ile hazırlanan YSA'nın tahmin grafiği.....	45
Şekil 4.13. Visual Studio ile hazırlanan YSA'nın eğitim sürecinde zamana bağlı hata miktarının değişim grafiği.....	46

## ÇİZELGELER DİZİNİ

	<b><u>Sayfa</u></b>
Çizelge 4.1. Kullanılan giriş parametreleri .....	30
Çizelge 4.2. Kullanılan çıkış parametreleri .....	30
Çizelge 4.3. Giriş ve çıkış parametre örnekleri .....	31
Çizelge 4.4. Veri tablosunun normalizasyon değerleri .....	32
Çizelge 4.5. Veri setinin minimum ve maksimum değerleri .....	33
Çizelge 4.6. Modellerin karşılaştırılması ve test sonuçları .....	37
Çizelge 4.7. Kullanılan eğitim algoritmaları .....	39
Çizelge 4.8. LM algoritması ile gerçekleştirilen eğitim ve test sonuçları .....	40
Çizelge 4.9. BR algoritması ile gerçekleştirilen eğitim ve test sonuçları .....	41
Çizelge 4.10. BFGS algoritması ile gerçekleştirilen eğitim ve test sonuçları .....	42
Çizelge 4.11. LM, BR, BFGS algoritmalarının eğitim ve test sonuçları .....	43
Çizelge 4.12. İterasyon sayısına bağlı olarak hata miktarının değişimi .....	45
Çizelge 4.13. YSA'da platform değişikliği analizi .....	48

## SİMGELER VE KISALTMALAR DİZİNİ

### SİMGELER

- $\partial$  : Türev işlevi  
 $\eta$  : Öğrenme katsayısı  
 $\Delta$  : Fark miktarı  
 $\Sigma$  : Toplam  
 $\delta_j$  : Azalma miktarı

### KISALTMALAR

- YSA : Yapay Sinir Ağı  
°C : Celcius  
ANFIS : Adaptive Neuro Fuzzy Inference System(Sinirsel Bulanık Mantık Çıkarımı)  
NOE : Nonlinear Output Error(Doğrusal Olmayan Çıktı Hatası)  
NARX : Nonlinear Auto Regressive Exogenous (Doğrusal Olmayan Otoregresif Eksojen)  
Fe : Demir  
O<sub>2</sub> : Oksijen  
Si : Silisyum  
C : Karbon  
Fe<sub>2</sub>O<sub>3</sub> : Hemotit  
FeO : Wüstit  
CO : Karbon monoksit  
CO<sub>2</sub> : Karbon dioksit  
Fe<sub>3</sub>O<sub>4</sub> : Magnetit  
FeO : Demir (II) Oksit  
MnO<sub>2</sub> : Manganez Dioksit  
MnO : Mangan (II) Oksit

$\text{CaCO}_3$  : Kalsiyum Karbonat

$\text{CaO}$  : Kalsiyum Oksit

$\text{Fe}_3\text{O}_4$  : Demir (II, III) Oksit

VS : Visual Studio

Nntool : Neural fitting toolbox (Sinir ađları ara kutusu)

## BÖLÜM 1

### GİRİŞ

Yüksek fırın işletmeleri demir çelik endüstrisinde sıvı ham demirin elde edildiği ilk tesistir. Yüksek fırın tesisi, karışık ve kompleks bir yapıya sahiptir. Bu sebeple üretim aşamasında çeşitli sorunlarla karşılaşmaktadır. İlgili sorunlardan bir tanesi sıvı ham demir miktarının ton bazında ne kadar üretileceği bilgisidir. Yüksek fırının tepe noktasından şarj edilen demir cevherinin, taban kısmında bulunan havuzdan alınmasına bir dökümün tamamlanması adı verilir.

Üretim Planlama Müdürlüğü tarafından belirlenen aylık üretim planı Yüksek Fırınlar Müdürlüğüne bildirilmektedir. Yüksek Fırın işletmesi bu plan çerçevesinde üretim hedeflerini yakalamaya çalışmaktadır. Diğer taraftan çelikhane tesisi ile Yüksek fırın ünitesi arasında önemli bir üretim ilişkisi mevcuttur. Eğer yüksek fırın işletmesi çelikhane tesisinin işleyebileceği kapasiteden fazla sıvı hamdemir gönderdiği takdirde, üretilen fazla sıvı ham demir beklemeye alınacak ve torpedonun içerisinde sıcaklığını zamanla kaybederek donacaktır. Bu duruma istinaden Üretim Planlama Müdürlüğünün belirtmiş olduğu üretim hedefleri de yakalanamayacaktır. Teorik sıvı hamdemir tahmini sayesinde tesisler arası haberleşme sağlanarak üretim sürecinin kesintisiz olarak devam etmesine katkı sağlamaktadır.

Bu çalışmanın amacı yapay sinir ağları ile yüksek fırınlarda üretilen sıvı ham demir miktarını ton bazında önceden tahmin ederek ileride oluşabilecek karmaşıklıkların önüne geçip, işletmenin ham demir üretiminde kar sağlamasına katkıda bulunmaktır. Yapay sinir ağı modelleri öncelikle MATLAB ortamında tasarlanan modellerle test edilerek başarımlar kayıt altına alınmıştır. Elde edilen sonuçların tahminleme için başarılı sonuçlar verdiği değerlendirildiği için daha sonra Visual Studio ortamında model tasarımı gerçekleştirilmiştir. Hazırlanan yapay sinir ağına ait tahminler hem bu iki platform arasında hem de gerçek üretim verileri ile karşılaştırılarak en başarılı



sonuların gerek ortamda alıřacak olan Visual Studio ortamında geliřtirilen modele ait olduėu grlmřtr.

Gerekleřtirilen bu alıřmada, ilk blmde “Giriř” kısmı yer almıř olup uygulamanın bir zetinden bahsedilmiřtir. İkinci kısımda, alıřmada kullanılacak olan tesisin sıvı ham demir retimi zerinde durulmuřtur. nc kısımda literatur alıřmaları, kurulan yapay sinir aėının mimarisi ve kullanılan ėrenme yntemleri detaylı bir řekilde anlatılmıřtır. Drdnc kısımla uygulama kısmında, yapay sinir aėında kullanılan teknoloji ve programlar hakkında bilgilere yer verilmiřtir. Belirlenen parametrelerin ve uygulamanın tahminleri verilmiřtir. İlgili tahminler grafik olarak sunulmuř ve gerekleřtirilen tahminler ile gerek veriler bir tabloda karřılařtırılmıřtır. Son blmde ise yapılan karřılařtırmaların sonuları yorumlanmıř ve neriler sıralanmıřtır.

## BÖLÜM 2


### YÜKSEK FIRINLARDA SIVI HAM DEMİR ÜRETİMİ

Gelişmişliğin bir göstergesi olan demir-çelik sektörü ülkelere ait milli gelir seviyesinde önemli yer tutmaktadır. Küresel çelik sektöründe önemli paya sahip ülkelerde birey başına düşen çelik tüketim miktarı 400-600 kg/kişi/yıl iken, ülkemizde bu oran 200 kg/kişi/yıl civarındadır. Demir-çelik sektörünün en önemli işlenmiş hammaddesi, sıvı hamdemirdir. Sıvı hamdemir üretimi birden fazla yöntemle elde edilebilmektedir. Birinci yöntem de sıvı çelik, demir cevherinin yüksek fırınlara şarj edilmesi ile sağlanırken, diğer yöntemde ise ark ocaklarında hurda şarjı uygulamasının tercih edildiği görülmektedir.

Demir cevheri içeriğinde birden fazla bileşen bulunmaktadır. Bu kimyasal bileşen oranları ithal ve yerli demir cevherinde farklılıklar göstermektedir [1]. Demir cevheri, kok, sinter, sıcak hava gibi birden fazla parametrenin bulunduğu yüksek fırın prosesi kompleks bir üretim sistemine sahiptir. Bu sebepten dolayı yüksek fırınlar birden fazla değişkenin, doğrudan veya dolaylı olarak üretimi etkilediği bir işletme ünitesidir [2].


Demir cevherinden sıvı ham demir üretimi yüksek fırınlar işletmesinde gerçekleşmektedir. Kok bataryalarında hazırlanan kok ve sinter tesislerinde üretime hazırlanan sinter ham maddeleri, demir cevheri ile birlikte yüksek fırınlarda sıvı demir haline getirilmektedir. Üretimin diğer adımı olan çelikhaneye torpido veya pota vasıtasıyla gönderilmektedirler. Burada gerekli metalürjik işlemlerin ardından sürekli dökümler tesisinde son fiziksel şeklini alarak yarı mamul haline getirilmektedir [3].

Büyük miktarda sıvı ham demir üretimi entegre demir çelik fabrikalarında üretilirken düşük miktarda yapılan üretimler hurda malzemelerinin kullanıldığı elektrikli ark ocaklarında gerçekleştirilmektedir [4]. 2018 yılında Türkiye’de 12 milyon tonu yüksek fırınlarda, 25 milyon tonu elektrikli ark ocaklarında olmak üzere 37 milyon sıvı ham demir üretilmiştir [5].



Şekil 2.1. Yüksek fırınlarda sıvı pik üretimi ve gerçekleşen reaksiyonlar [4].

Şekil 2.1’de bir yüksek fırının genel yapısı gösterilmektedir. Fırının işleyişinin daha iyi anlaşılabilmesi için baca, gövde, karın ve hazne bölümlerine ayrılmıştır. Baca kısmından sıvı hamdemir üretimi sırasında meydana gelen gazların toplandığı bölümdür. Çan kısımlarından yüksek fırına malzemelerin şarjı gerçekleştirilmektedir. Refrakter malzemesi, yüksek sıcaklıklara dayanabilen tuğlalardır. Baca kısmından gövde bölmesine doğru ilerledikçe fırın içi sıcaklık artmaya devam edecektir. Yüksek fırınlar bombeli bir fiziksel yapıya sahip oldukları için genişlik olarak en geniş kısım karındır. Ana hava simidi olarak adlandırılan, diğer adı ile tüyer, kanallardan yüksek fırınlara düzenli olarak oksijen zenginleştirilmiş sıcak hava gönderilmektedir. Fırının son ve zemin kısmı olan haznede, üretim sonucunda iki farklı fiziksel ürün toplanır. Cüruf, yoğunluğu sıvı ham demirden düşük olması sebebi ile sıvı ham demirin üzerinde bir katman gibi toplanmakta ve cüruf akıtma kanalları vasıtasıyla yüksek fırınların içinden tahliye edilmektedir. Geriye kalan sıvı ham demir ise ham demir(pik) akıtma kanalından torpedo veya potalara taşınmaktadır.



Şekil 2.2. Yüksek fırın takip ekranı.

Yüksek fırınlarda üretim ortamı yer çekimine ters olacak şekilde tasarlanmıştır. Fırının üst bölümünden düzenli olarak şarj edilen katı hammaddeler fırının alt bölümlerine doğru ilerlerken fırının alt bölümünde açığa çıkan gazlar tam tersi yönde hareketlilik gösterirler. Birden fazla demir oksit bileşenlerinin (Magnetit ( $Fe_3O_4$ ), Wüstit ( $FeO$ ), Hematit ( $Fe_2O_3$ )) kimyasal tepkimeler neticesinde demirden oksijenin uzaklaştırılarak yalnız bırakılmasına demir üretimi denilebilir. Yüksek fırına düzenli olarak şarj edilerek alt kısma doğru ilerleyen kok, alt kısımda bulunan tüyerlerden üflenen sıcak hava ile karşılaşır ve bu karşılaşma sonucunda meydana gelen kimyasal tepkime sonucunda karbon monoksit gazı ( $CO$ ) oluşur. Demirli malzemenin redüklenmesinde  $CO$  önemli bir rol oynamaktadır.



Gerçekleşen bu reaksiyonun ardından reaksiyonlar zincirleme olarak gerçekleşmeye başlamakta ve fırın içi sıcaklıkta değişiklikler gözlemlenir. Sıcaklık  $455^\circ C$  civarına yaklaştığında Eşitlik 2.2’de gösterilen reaksiyoda karbon dioksit oluşur.



Gövde bölümüne doğru ilerlemeye devam eden demir cevherinde Hematit ile karbon monoksit ile yaklaşık 594 °C’de tepkimeye girmekte ve Eşitlik 2.3’de görülen.



reaksiyonu fırının üst bölgesinde gerçekleştirmektedir. Yükselen sıcaklık 705°C ‘ye yaklaştığında Eşitlik 2.4’teki tepkime ile demir oksijenden ayrılır.




Yüksek fırının üst kısmından bulunduğu ortamı terk etmeye başlayan gazın yüksek sıcaklığı ile birlikte ilk adımda fırına şarj edilen demir oksitin rutubeti giderilir.

Dolomit ve kireçtaşı fırına cüruf yapıcı malzeme olarak verilmektedir. Yüksek fırına Eşitlik 2.5’de kireçtaşı ve Eşitlik 2.6’da manganez kullanılarak Eşitlik 2.7’deki gibi cüruf elde edilir.



Ardından orta bölmeye doğru inmeye devam eden malzeme bu bölmede FeO ile karşılaştığında gerçekleşen tepkime sonucu meydana gelen CO<sub>2</sub>, Eşitlik 2.8 ve Eşitlik 2.9’da gösterilen reaksiyonlarla, karbon tarafından hızla indirgenmeye başlanarak demir (Fe) elde edilir.



Gerçekleşen bu reaksiyonların ardından şarj edilen malzemeler sertliğini kaybetmeye başlarken, yüksek fırının orta kısmında sıvı pik ve cüruf maddeleri oluşmaya başlar. Oluşan bu cüruf ve sıvı demir fırının alt kısımlarına doğru ilerlerken sıvı forma geçmiş olan sıvı pik yoğunluğu sebebi ile cürufun içinden ayrılmaya başlar. Bu ayrılma süreci fırının en alt katmanında oluşturulan haznede biriktirilmesiyle son bulur. Haznenin alt kısmında kalan sıvı ham demir yüksek fırının yanlarından özel olarak açılan delikler yardımıyla alınırken, bir üst katmanda oluşan cüruf fırının içinden dışarıya alınır [6].

Demir cevherinin sıvı ham demire dönüştürülme süreci bu şekilde tamamlanmış olur. Ardından sıvı ham demir torpedolar ile şekil verilmek üzere çelikhane işletmesine gönderilir.



Şekil 2.3. Yüksek fırından döküm alan bir torpedo.

Sıvı ham demir; pelet, sinter ve demir cevheri gibi demir oranı yüksek malzemelerin cüruf yapıcı malzemeler ile karıştırılarak kok vasıtasıyla reaksiyona girmesi sonucu elde edilmiştir. Bu işlemde gerçekleşen kimyasal reaksiyonlar ile demir cevherinin içeriğindeki oksitler sıvı ham demir haline getirilmektedir. Bu işlem sonunda oluşan sıvı ham demir, çelik üretimi için çelikhane tesislerine gönderilirken meydana gelen ve atık madde olarak sınıflandırılan cüruf ise çimento üretim tesislerine gönderilmektedir. Yüksek fırın içinde gerçekleşen kimyasal reaksiyonlar sırasında oluşan gaz ise Gaz Temizleme Tesislerine gönderilerek yeniden kullanım için temizlenmektedir.

Yüksek fırın gibi endüstriyel işletmelerin günümüzdeki en büyük sorunu gelişen teknoloji ile senkronize olamamasıdır. Teknolojik gelişmelerle birlikte yapay sinir ağları birçok üretim alanında kullanılmaya başlanmıştır. Demir-çelik üretiminde sıvı ham demirin ilk oluştuğu ünite olan yüksek fırın işletmesinde, bu alanla ilgili çeşitli çalışmalar ele alınmıştır. Erdemir yüksek fırınlarında yapılan çalışmada erimiş demirin kimyasal analizi, alınan numuneler yardımıyla yapay sinir ağı ile tahmin edilmeye çalışılmıştır [7].

Diğer taraftan yüksek fırın işletmesinde kullanılmak üzere kütle ve ısı oranlarının dengede olduğu matematiksel bir model oluşturulmuştur [8]. İlgili modellemelerde sıvı ham demir üretimine ait oranı yakalayabilmek için ihtiyaç duyulan hammadde miktarlarının hesaplanmasında yapay sinir ağları kullanılabilir. Bu çerçevede, kullanılan hammaddeler arasında bağlantı kurularak kütle miktarında değişikliklere gidilebilir. Kütle ve ısı dengesinin yanında sıvı ham demir-cüruf dengesini izleyebilmek için kinetik veri de ilave edilerek yapılan modellemede, yüksek fırın kendi içinde dört farklı kısma ayrılmıştır. Yapılan çalışmada sıvı ham demir içindeki kükürt ve silisyum yoğunlukları hesaplanmıştır. Bunun yanında sıvı ham demirin sıcaklık ve silisyum değişkenlerinin doğru bir şekilde tahmininin modeller vasıtasıyla gerçekleştirilmesinin çok zor olduğu belirtilmiştir.

Yapay sinir ağı demir-çelik sektöründe birçok farklı tesiste çeşitli üretim aşamalarında aktif olarak kullanılmıştır. Yapay sinir ağlarından önce kullanılan tekniklerde sadece giriş ve sonuç işlemlerinde başarı sağlanırken yapay sinir ağları kullanılarak daha karmaşık hesaplamalar ve tahminler gerçekleştirilebilmiştir. Ayrıca yapay sinir ağları daha esnek ve kullanışlı olduğu için üretim tesisi farketmeksizin kullanılabilir [9]. Yapay sinir ağından hava ayırıştırma işleminin kimyasal modellemesi yapılmak için faydalanılmıştır [10]. Üç giriş parametresi, tek gizli katmana sahip ve değişik durumlarda meydana gelen oksijenin durumunu tahmin edebilmek için kullanılmıştır. Finlandiya, Koverbar'da çalışan yüksek fırın işletmesinde, fırının sıcaklık durumunu tahmin etmek için yapay sinir ağlarından faydalanılmıştır [11].

Yapay sinir ağlarının tasarımında farklı metotlar kullanılmıştır. Bu çalışmalardan biri olan sıvı ham demir içindeki silisyum miktarının tahmin edilmesinde çok

katmanlı ileri yönlü beslemeli ağ kullanılarak başarılı sonuçlara ulaşılmıştır. Eğitimi yapılan ileri beslemeli ağlarda türev işlemi kullanılmıştır. Bu metod Levenberg Marquardt olarak adlandırılmaktadır [12].

Sıvı ham demir sıcaklığının tahmini için değişik modellemelerden de faydalanılmıştır. Yapılan çalışmada, tasarlanan sinir ağı NARX modeli olarak tasarlanmış ve ilerleyen aşamalarda kurulan yapıyı NOE modeli için de kullanmışlardır. Ortaya çıkan sonuçlarda sıvı ham demire ait sıcaklık ölçümüne uygun, NARX modelinin ise kontrol sistemlerinde başarılı ve NOE modelinin de simülasyon çalışmalarında daha etkin olduğu tespit edilmiştir [13].

Sıvı ham demir üretim sürecinde oluşan cürufun yüksek fırın duvarlarına yaptığı basınç dayanımı tahmini için iki farklı yöntem kullanılmıştır. İlk yöntem çoklu regresyon, ikinci yöntem ise yapay sinir ağlarıdır. Bu sayede yüksek fırın işletmelerinde planlı ve plansız duruşlara yardımcı olması hedeflenmiştir [14]. Yüksek fırının bir diğer çıktı ürünü olan yüksek fırın gazı enerji kaynağı olarak kullanılabilir. Diğer taraftan üretim sürecinde yaşanan ani değişiklikler ve dalgalanmalar elde edilecek yüksek fırın gazı miktarının tahminini zorlaştırmaktadır. Bu sorunun önüne geçebilmek adına yapılan çalışmada analiz edilen veriler kullanılarak bir tahmin modeli sunulmuştur [15].

Sıvı ham demirin sahip olduğu kimyasal oranlar, üretilecek çeliğin kalitesini belirlemektedir. Ayrıca kalite çeliğin hem kullanım ömrünü hem de kimliğini belirlemektedir. Bu duruma istinaden, sıvı ham demirin içerisindeki sülfür oranının tahmin edilebilmesi için gerçekleştirilen çalışmada yapay sinir ağları kullanılmıştır [16]. Diğer taraftan yüksek fırınlardan elde edilen veri setleri üzerinde yapılan çalışmada evrimsel algoritmalar kullanılarak gürültülü verilerin optimizasyonu gerçekleştirilmiştir [17].

Sıvı ham demirin kontrollü bir biçimde taşınabilmesi yüksek fırın işletmelerinin bir diğer önemli problemidir. Bu işlem sırasında yaşanacak herhangi bir olumsuzluk istenmeyen işkazalarına neden olabilmektedir. Bu problemin ortadan kaldırılması için yapay sinir ağları yardımıyla hazırlanan bir simülasyon tasarlanmıştır. Çok katmanlı



yapay sinir ađının tercih edildiđi alıřmada, iřletme operatrne tavsiye veren simlatrn kullanıřlı olduđu tespit edilmiřtir [18]. Yksek kaliteli sıvı ham demir retimini kolaylařtırmak iin yksek fırında istikrarlı bir operasyon srdrmek byk nem tařıtmaktadır. Yksek fırının retim srecindeki durumunu takip edebilmek iin gerekleřtirilen alıřmada yapay sinir ađı tabanlı bir arıza tespit ve tanımlama yntemi nerilmiřtir [19].

Granl bazlı materyallerin partikl kalıntıları endstriyel iřletmelerde istenmeyen bir durumdur. zellikle yksek fırın iřletmelerinde bu durum gaz ve katı fazlar arasındaki ısı transferini dođrudan etkilemektedir. Bu nedenle partikl davranıřlarının anlaşılması ve ngrlebilmesi iin gerekleřtirilen alıřmada partikl yođunluđunu tespit edebilmesi iin yapay sinir ađı kullanılmıřtır [20]. Sıcak hava sobaları, yksek fırınlarda sıvı ham demir retim srecinde gerekli sıcaklıđın sađlanmasında rol alan nemli bir nitedir. Iřletme srecini kontrol etmek iin sıcaklıđın iyi analiz edilmesi gerekmektedir. Bu duruma istinaden yapay sinir ađları kullanılarak oluřturulan simlasyonda gerek sıcaklık deđerlerine yakın sonular alınmıř ve sıvı ham demir retim srecine byk katkı sađlayacađı belirtilmiřtir [21].

## BÖLÜM 3

### YAPAY SİNİR AĞLARI MİMARİSİ

Yapay sinir ağları (YSA); insan beynine ait olan düşünme, öğrenme, bağlantı kurabilme, karar verebilme gibi yetenekleri kendi kendine gerçekleştirebilen bilgisayar sistemleridir. Gelişen teknolojiye paralel olarak bu işlem hızına karar destek mekanizması da eklenmiştir. Ortaya çıkan yapıya, insan beynini taklit ettiği için yapay sinir ağı adı verilmiştir [22,23].

Hem akademik hem de sektör bazında incelendiğinde yapay sinir ağlarının, birçok alanda yaygın olarak kullanıldığı görülmektedir. Otomotiv, savunma, uzay ve havacılık, haberleşme sistemleri, sağlık, AR-GE, bilişim gibi geniş bir kullanım yelpazesine sahiptir [24-25]. Çalışma alanlarının geniş olması, ortaya birbirlerinden farklı yapay sinir ağı mimarilerinin çıkmasına da zemin hazırlamıştır. Yapay sinir ağlarının en iyi performansını gösterebilmesi için mimarisindeki bileşenlerin sonuçlara etkileri araştırılmıştır. Çalışmada ara nöron, aktivasyon fonksiyonları değiştirilerek en iyi sonucu tahmin eden mimarinin tespit edilmesi sağlanmıştır [26].

Yapay sinir ağları, insan beyninin çalışma yapısını baz alarak çeşitli algoritma ve matematiksel modellemelerin neticesinde ortaya çıkmıştır. Bu sebeple, yapay sinir ağları üzerindeki çalışmaların başlangıç noktası insan beynini oluşturulan ve nöron adı verilen biyolojik yapıların analiz edilerek bilgisayar sistemlerinde kullanılmaya başlanmış ve zaman içerisinde çeşitli alanlarda da aktif olarak kullanılabilir duruma gelmiştir [27].

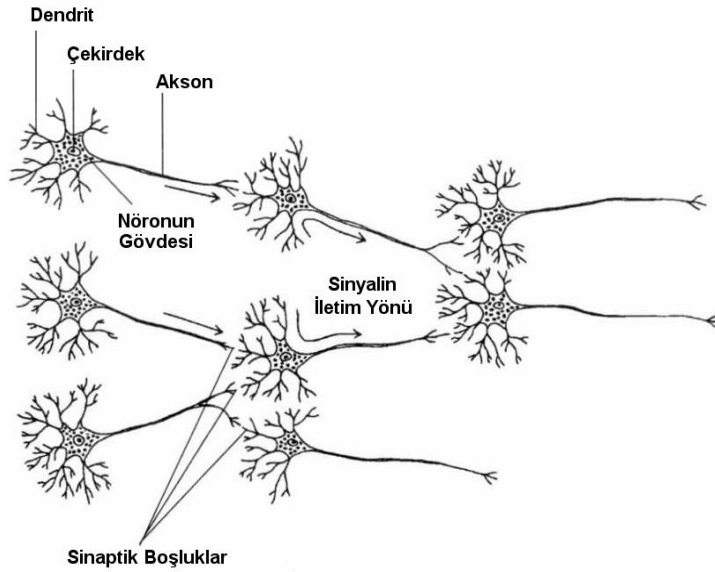
Yapay sinir ağlarının en güçlü olduğu yanlarından biri doğrusal olmayan matematiksel sistemlerin modellenmesindeki zorlukları ortadan kaldırmasıdır [28]. Geliştirilen bu modeller farklı amaçlar doğrultusunda kullanılarak verdikleri sonuçların ne kadarefektif olduğu araştırılmıştır. Pi-Sigma yapay sinir ağı, sahip olduğu çarpım ve

toplam fonksiyonu ile öngörü konusunda kullanmıştır. Kurulan mimaride diferansiyel gelişim algoritması tercih edilerek yapay sinir ağına eğitim yaptırılmış ve çıkan sonuçlar çeşitli algoritma sonuçları ile karşılaştırılmıştır [29].

Diğer taraftan çalışmalar gösteriyor ki bir problem üzerinde sadece yapay sinir ağının kullanılması istenilen kriterlerin hepsini karşılamaya yetmemektedir. Yapay sinir ağının eğitim süreçleri, farklı öğrenme metodları ile gerçekleştirildiğinde verdiği sonuçların nasıl değiştiği gözlemlenmiştir. Sonuçların yanında geçen süre ve performans değerlendirmeye alınmıştır [30].

Beyin, duyu organlarından gelen elektriksel tetiklemeleri yorumlayarak uygun kararlar veren organdır. Üç katmanı bulunan beyinde çeşitli birimler görev almaktadır. Bu katmanlar; girdi, ara ve çıktı katmanı olarak isimlendirilirler. Bu katmanlar arasında haberleşme gelen elektriksel sinyallerin kimyasal olarak diğer sinir hücrelerine iletilmesiyle gerçekleştirilmektedir.

Nöron ismi verilen sinir hücresi, biyolojik sinir sisteminin en temel elemanıdır. Bu temel yapı dentrit, soma, akson, sinaps adı verilen kısımlardan oluşur ve her birinin farklı görevleri vardır. Şekil 3.1’de nöronun yapısı gösterilmektedir.




Şekil 3.1. Sinir hücresinin yapısı [32].

Bir nöron dentrit veya akson ile diğer sinir hücresine bağlanır. Sinir hücrelerinin bağlandığı bu noktaya sinaps adı verilir. Sinaps bir nöronun akson kısmından aldığı elektriksel akımı bağlı olduğu diğer sinir hücresinin dentritine iletmekle görevlidir.


Elektrik akımını alan dentrit bu akımı hücre gövdesine yani somaya gönderir. Somanın içerisinde hücre çekirdeği bulunur ve yaşamsal faaliyetlerin devam etmesini sağlar. Hücreye gelen bütün sinyaller bu noktada toplanır. Bu toplama işleminin sonucunda ilgili hücrenin eşik değeri aşılsa, o hücrenin akson kısmında elektrik akımı oluşur ve bağlı olduğu hücrenin dentritine sinapslar üzerinden gönderilir. Bu sayede hücrede oluşturulan elektrik akımı diğer hücreye iletilmiş olur. Nöronlar arasında bu haberleşme sistemi ile biyolojik olarak öğrenme gerçekleşmiş olur. Bu süreç doğumdan ölüme kadar devam eder. Zaman içerisinde beyin kendini geliştirmekte, yeni bağlantılar oluşturmakta, mevcut bağlantılarını ve aynı zamanda nöronların eşik değerlerini güncellemektedir. Bu duruma ise zaman içinde öğrenme adı verilmektedir [33].

Yapay sinir ağlarında beyinde bulunan nöronlar ve işleyişleri simüle edilmiştir. Tasarlanan bu nöronlar, bir düzlem içerisinde aralarında bağlantı kurarak ve katmanlar biçiminde bir araya gelerek yapay sinir ağını oluştururlar. Şekil 3.2’de beyindeki sinir hücresinin matematiksel tasarımı verilmektedir.



Şekil 3.2. Yapay sinir ağındaki nöron yapısı [34].

Bir yapay sinir ađında girdi katmanı, gizli katman ve çıktı katmanı olmak üzere üç farklı katman bulunur. Belirli bir sıra ve düzen içerisinde bir araya gelen bu katmanlar ise ađ yapısını oluştururlar. İşte yapay sinir ađı ismini bu düzenden almaktadır. Şekil 3.3'te tüm katmanların bulunduğu bir ađ örneđi gösterilmektedir.



Şekil 3.3. Üç katmanlı yapay sinir ađı [34].

### 3.1. YAPAY SİNİR AĐINDAKİ HÜCRELERİN ELEMANLARI

Yapay sinir ađının çalışma yapısını anlayabilmek için yapay sinir ađında görev alan bileşenlerin bilinmesi ve tanımlamaların yapılması gerekmektedir. Başlangıç olarak, öğretilmek istenen veri setlerine ait her bir bilgi aynı zamanda gizli katmana doğru yönlendirilir. Ağırlık değerleri aynı katmanda bulunmayan nöronlar arasında oluşmaya başlar.

Başlangıç değerleri genellikle rastgele olarak belirlendikten sonra, girdi katmanındaki hücrelerin gönderdiği bilgiler ( $x_i$ ) ulaştığı nörondaki tüm bağlantıların ağırlık değeri ( $w_i$ ) ile çarpılarak toplama fonksiyonu vasıtasıyla net girdisi bulunur. Nörondaki *net* değerin hesaplanmasında rol oynayan fonksiyon, tasarlanan yapay sinir ađında gerçekleştirilen matematiksel işleme göre çeşitlilik gösterebilir. Bu noktada toplama fonksiyonunun kesin bir formülü bulunmamaktadır ve bu durum için deneme yanılma

yöntemi kullanılarak en iyi sonuca gidilmesi hedeflenir. Toplama fonksiyonu Eşitlik 3.1’de gösterilmiştir

$$\sum_{i=1}^n x_i w_i + b \quad (3.1)$$

Çeşitli matematiksel işlemler  $x_i$  sonucunda toplam fonksiyonunu kullanarak net değere ulaşan nöron, üreteceği çıktıya aktivasyon fonksiyonu ile ulaşır. Diğer bir adı da transfer fonksiyonudur. Genel olarak aktivasyon fonksiyonu doğrusal olmayan bir fonksiyondur. Yapay sinir ağlarının güçlü olduğu doğrusal olmayan sonuçlar bulması buradan gelmektedir. Bu fonksiyon uygulanırken dikkat edilmesi gereken nokta, geri beslemeli algoritmaların türev alma yöntemlerini aktif olarak kullanması sebebiyle gerçekleşen işlemler sırasında zaman kaybının olmaması için daha kolay hesaplanabilen bir fonksiyon seçilmesidir [35].

## 3.2. YAPAY SİNİR AĞLARINDA EĞİTİM

Bilgisayar sistemlerinin, gerçekleşen bir olay karşısında öğrendiği tecrübe ve deneyimleri kullanarak gelecekte yaşanacak benzer olaylar için çözümler üretmesi, karar verebilmesi ve tahminlerde bulunabilmesi makine öğrenmesinin temelini oluşturmaktadır. Uygulama amacı ve problem analizi yapıldıktan sonra uygun bir ağ yapısı belirlenerek ağ eğitimi aşamasına geçilir. Bu aşamada çözülecek problemin türü ve kullanılacak ağın yapısı daha önce planlanan öğrenme kuralları çerçevesinde nöronlar arasındaki bağlantılara ait ağırlıkların değiştirilmesiyle gerçekleştirilir. Bu işlemdeki amaç sinir ağına sunulan örneklemeler için doğru çıktı parametrelerini üretebilmesidir.

İlk adım olarak sinir ağındaki ağırlıklar rastgele verilir. Eğitimde kullanılacak olan veri seti uygun formatta olmalıdır. Eğitim sürecinde ise eğitim seti defalarca sinir ağına gösterilerek tüm ağırlıkların güncellenmesi istenir. Eğitim süresinin ölçümü iterasyon sayıları ve bu iterasyon sayılarının tamamlanma zamanı olarak kaydedilir.

Yapay sinir ağı eğitim sürecinin sonunda birtakım testlerden geçer. Tıpkı veri setinde olduğu gibi bu süreç için de bir test seti hazırlanır. Elbette test veri seti de yapay sinir ağının yapısına uygun olmalıdır. Test sürecinin öğrenme sürecinden farkı ise mevcut ağırlıkların artık güncellenmemesidir. Bu süreçte sinir ağının ürettiği çıktılar ve test veri setinin sonuçları sürekli olarak karşılaştırılarak eğitim durumu analiz edilir. Karşılaştırma işleminin sonucunda istenilen çıktılar elde ediliyorsa eğitim başarılı olarak sonlandırılır [35].


### **3.3. YAPILARINA GÖRE YAPAY SİNİR AĞLARI**

Yapılarına göre YSA, İleri Beslemeli ve Geri Beslemeli Ağlar olmak üzere ikiye ayrılmaktadır [36].

#### **3.3.1. İleri Beslemeli Ağlar**

Yapay sinir ağlarında kullanılacak olan ilk değerler genellikle rastgele seçilir. Bu durumun sebebi YSA'nın öğrenme yapabilmesi için elinde henüz veri olmamasıdır. İlk verinin sinir ağına gösterilmesinin ardından eğitim süreci başlar. Giriş katmanından alınan veriler bir sonraki katmana (gizli katman) iletilir. Bu katmanda işlenmeye başlayan bilgiler aktivasyon fonksiyonu ile birlikte çıkış katmanına gönderilir. Tasarlanan bu yapı ile girdi katmanından çıkış katmanına doğru bir çeşit veri akışı sağlanır. Bu sayede ileri beslemeli yapay sinir ağı eğitim sürecini devam ettirir ve doğrusal olmayan, değişken işlevleri gerçekleştirir.

Gizli katmana sahip ileri beslemeli yapay sinir ağının sürekliliğe sahip bir fonksiyonu istenilen doğruluk noktasına yakınlaştırabileceği ispatlanmıştır. Bu işlemi kendisine gösterilen verileri kullanarak ve her bir iterasyonda sahip olduğu ağırlıkları güncelleyerek yapar. Eğitim süresince yapay sinir ağı, gerçekleştirdiği ağırlık güncellemeleri ile giriş ve çıkış parametreleri arasındaki ilişkiyi öğrenmeye başlar. Veri işleme yönü ise sürekli olarak çıkışa yani ileriye doğrudur. Son katman olan çıkış katmanında bulunan nöronların kendilerine ait ağırlıkları toplanır ve aktivasyon fonksiyonu ile hata miktarı ortaya çıkmış olur. Hata miktarı önceden belirlenen düzey yakalanıncaya kadar döngü devam eder [37].



Şekil 3.4. İleri beslemeli YSA [37].


Şekil 3.4'te ileri yönlü beslemeli çok katmanlı yapay sinir ağı mimarisi gösterilmektedir. İleri yönlü beslemeli ağda bilgi akışı ok yönünde gösterildiği gibi sadece girdi katmanından çıkış katmanına doğru gerçekleşirken sinir ağı üzerinde herhangi bir geri bildirim bulunmamaktadır. Numaralandırılmış hücreler sinir ağındaki bulunan nöronları temsil etmektedir.

### 3.3.2. Geri Beslemeli Ağlar

YSA da diğer bir sınıf olan geri beslemeli ağlar ileri beslemeli ağların tersi yönünde hareket eder. İlk çıkış iterasyonu hariç, her bir iterasyon sonucunda gerçek değer ile sinir ağının üretmiş olduğu değer arasındaki fark hata miktarı olarak kabul edilir ve hafızaya alınır. Bir sonraki iterasyonda nöronlara ait ağırlıklar hata miktarı kadar güncellenir. Bu döngü; belirlenen iterasyon sayısına ulaşılmasıyla veya hata miktarının istenilen düzeye indirgenmesi ile son bulur. Geri beslemeli ağlarda da tıpkı ileri beslemeli ağlarda olduğu gibi sahip oldukları nöronların çıkış değeri, kendilerinden önceki nöronların giriş değerlerine bağlıdır. Bu ağ mimarisi genel olarak tahmin amaçlı işlemlerde kullanılır [38].



Geri beslemeli ađlar giriř katmanına geri dđnerek ađrılıkların gđncellemesinin yapıldığı bir ađ yapısıdır. Bu çeřit sinir ađları bir nceki ađrılık deđerini gđncelleyecek olması sebebiyle hafızaları vardır. Bu algoritmadaki nronların ıkıřı deđerı nceki giriř deđerlerine de bađlıdır. Bundan dolayı, bu ađ yapısı genellikle tahmin iřlemleri iin kullanılır. [36]. Őekil 3.5'te hata miktarının geri ynl ilerlemesi gsterilmiřtir.



Őekil 3.5. Geri beslemeli YSA [35].

Geri beslemeli ađlar, yapay sinir ađlarının đrenimli sınıfına giren bir algoritmadır. ıkıř katmanında bulunan nron iin n. iterasyondaki Eřitlik 3.2'deki forml ile hesaplanır.

$$e_j(n) = d_j(n) - y_j(n) \quad (3.2)$$

Sinir ađının đrenme sresince her iterasyonda elde ettiđi hata geriye dođru yayılım algoritması ile en kuk deđere ulařana kadar devam eder. Eđitim sırasında elde edilen ıkıřlardaki hata Eřitlik 3.3'te gsterilmiřtir.

$$E(n) = \frac{1}{2} \sum_{j \in C}^N e_j^2(n) \quad (3.3)$$

n. iterasyon sonundaki tüm hataların ortalaması Eşitlik 3.3'te gösterilmiştir. İlgili eşitlikte C ağı'n çıkış katmanında bulunan nöron sayısını temsil etmektedir. Mevcut ağırlıkların güncellenmesi adım adım aşağıdaki gibi yapılır.

$$\Delta w_{ij} = -\eta \frac{\partial E(w)}{\partial w_{ij}} \quad (3.4)$$

İleri yayılım kısmında girdi parametrelerinin oluşturduğu bilgilere karşılık bir çıkış elde edilmektedir. Bu çıkışlar ile gerçek değerler arasındaki fark kadar güncellenmesi gerekmektedir. Bu güncelleme işlemi;

$$\Delta w_{ij} = \eta \delta_j y_i \quad (3.5)$$

$$w_{n+1} = w_n + \Delta w_n \quad (3.6)$$

formülü ile gerçekleştirilmektedir.

Gizli katmanda bulunan ağırlıkların güncellenmesi için Eşitlik 3.4'te gösterildiği üzere, toplam ağırlıkların gizli katmandaki ağırlıklara göre  $\partial$  türevi alınır. Aradaki hata değişim ise Eşitlik 3.5'te gösterilen  $\Delta$  kadar olacaktır. Eşitlik 3.6'da gösterildiği gibi bir sonraki iterasyonda mevcut ağırlık,  $\Delta$  ile toplanarak güncellenir. Bu eşitlikte  $\eta$  öğrenme katsayısını temsil etmektedir. Geriye yayılım algoritmasında yaşanan en büyük problem veri setine ve öğrenme yüzdesine bağlı kalarak, eğitim süresinin giderek artmasıdır. Bu problemi çözmek için mevcut ağırlıkların değişim miktarının önceden belirtildiği öğrenme katsayısı üzerinde değişiklikler yapmaktır [39].

### 3.4. YAPAY SİNİR AĞININ TASARIMI

Yapay sinir ağı modelini ortaya koyabilmek için nöron sayısı, aktivasyon fonksiyonunu, öğrenme yöntemleri önceden belirlenmelidir. Veri setinde kullanılacak

verilerin ve ađın amacına uygun hareket edebilmesi YSA tasarımı adına temel adımlardır. Bu noktada ařađıdaki adımlar izlenerek mimari tasarlanmaya bařlar;

- YSA nın en temel birimi olan nronun tasarımından bařlanarak katman sayısı, đrenme katsayısı gibi zellikler netleřtirilir,
- Nronların kullandıđı aktivasyon fonksiyonları incelenerek hangi amaca hizmet edecek ise o amaca uygun seeneklerin belirlenmesi,
- Eđitimde kullanılacak olan verilerin tespit edilmesi,
- Tespit edilen verilere gre hem eđitim hem de test veri setlerinin oluřturulması

Yukarıdaki adımlar tutarlı bir řekilde gerekleřtirilmediđi takdirde oluřturulan mimari istenilen sonulara ulařamayacaktır. Ayrıca sistem karmařıklıđı ve eđitim sresi de artacaktır [34].

#### **3.4.1. Nron ve Katman Sayısının Belirlenmesi**

Yapay sinir ađının karmařıklıđı, kullanılan katman ve bu katmanda oluřturulan nronların sayısı tarafından belirlenir. Ara katman ve nron sayısı arttıka ađırlık hesaplamaları artacađından eđitim sresi de paralel olarak artacak ve ađın performansı dşecektir. İhtiya duyulandan az kullanılması sonucunda sinir ađı istenen sonuları vermeyecektir. İki ya da ç katmanlı olarak tasarlanan yapay sinir ađları birok problem iin istenilen sonuları vermektedir.

Yapay sinir ađında kullanılacak olan katman sayısı ve nron sayısını belirlemenin en iyi yolu, deneme–yanılma yntemiyle belirlemektedir. Ara katman ve bu katmanda bulunan nron sayıları zerinde deđiřiklikler yapılarak sinir ađının performansı llmektedir [40].

#### **3.4.2. Aktivasyon Fonksiyonu Seimi**

Sinir ađında grevli nronların dođru sonuları retebilmesi iin aktivasyon fonksiyonunun dođru seilmesi ok nemlidir. Aktivasyon fonksiyonlarının seiminde girdi olarak kullanılacak verilerin trne ve sinir ađının hizmet edeceđi amaca uygun

olacak şekilde belirlenmesi gerekmektedir. Örnek olarak, doğrusal olmayan bir problemin çözümünde doğrusal olmayan aktivasyon fonksiyonlarının kullanılması daha iyi sonuçlar verecektir [41].

### 3.4.3. Normalizasyon

Normalizasyon, kısaca YSA da kullanılacak verilerin sinir ağına gösterilmeden önce verilen uygun hale getirme işlemi olarak isimlendirilebilir. Bu işlemlerdeki ana amaç ise veriler arasındaki aşırı fark değerlerini veya salınımların önüne geçerek sinir ağının gereksiz zaman ve performans kaybetmesini engellemektir. Genelde yapılan çalışmalarda veriler [0,1] veya [-1,1] değer aralıklarında ölçeklendirilirler. Veriler üzerinde yapılan bu çalışma hem veri kalitesini arttırmakta hem de veriler arasındaki salınımların önüne geçerek sinir ağının daha sağlıklı sonuçlar vermesine yardımcı olmaktadır. Tıpkı aktivasyon fonksiyonlarında olduğu gibi normalizasyon işleminin de çeşitleri mevcuttur [42].

#### 3.4.3.1. Min-Max Normalizasyonu

Bu yöntem, normalize işlemini doğrusal olacak şekilde gerçekleştirir. İlgili verinin en küçük değere minimum değer, olabilecek en büyük değer için ise maksimum isimlendirmesi yapılır. Min-Max normalizasyonunda bir veriyi 0 ve 1 aralığında indirgeyebilmek için Eşitlik 3.7 ile hesaplanır.

$$x'_i = \frac{x_i - x_{min}}{x_{max} - x_{min}} \quad (3.7)$$

Bu eşitlikte;

- $x'$  = Normalizasyonu yapılmış veri
- $x_i$  = Giriş parametre değeri,
- $x_{min}$  = En küçük girdi parametresi,
- $x_{max}$  = En büyük girdi parametresi

olarak ifade etmektedir [42].

### 3.4.3.2. D\_Min\_Max Normalizasyonu

Bu normalizasyon yönteminde diğerlerinden farklı olarak [0,1 – 0,9] değer aralığında normalize edilerek veriler boyutsuz hale getirilmektedir. Bu normalizasyonun yöntemi için Eşitlik 3.8 kullanılmaktadır.

$$x' = 0.8 * \frac{x_i - x_{min}}{x_{max} - x_{min}} + 0.1 \quad (3.8)$$

$x^i$  = Normalizasyonu yapılmış veri,

$x_i$  = Giriş parametre değeri,

$x_{min}$  = En küçük girdi parametresi,

$x_{max}$  = En büyük girdi parametresi

olarak ifade edilmektedir.

Sonuç olarak kurulacak yapay sinir ağında kullanılmak üzere birden fazla normalizasyon türü bulunmaktadır. Normalizasyon tekniklerinin yapay sinir performansı üzerinde yapılan çalışmalar gösteriyor ki D\_Min\_Max normalizasyon yönteminin daha sağlıklı sonuçlar verdiği gözlemlenmiştir [42].

### 3.4.4. Momentum ve Öğrenme Katsayısı

Eğitim sürecindeki yapay sinir ağında nöronlar arasındaki ağırlıkların hangi miktarda değişeceğini belirleyen değişkene öğrenme katsayısı denilmektedir. Bu değişkenin sinir ağı öğreniminde önemli etkisi vardır. Öğrenme katsayısı uygulanacak probleme göre değişken olabilir fakat çok büyük bir değer olarak belirlenirse ağ üzerinde bulunan minimum hata değerini bulması zorlaşacaktır. Çok küçük bir değer seçilirse yerel minimum değerlerini bulacak fakat bu değerlere takılı kalacak ve eğitim süresi uzamaktadır.

İlgili problemin çözümünde en az hataya sahip olan noktanın bulunabilmesi yerel çözüm olarak adlandırılmaktadır. Çünkü bu nokta sinir ağının en iyi çözüm noktasıdır. Diğer adı mutlak minimum olarak bilinmektedir. Bu durumda yerel minimumdan global minimum noktalarına ilerleyebilmek için momentum değişkeni kullanılır. Yapay sinir ağının eğitim adı verilen süreci de bu noktada başlamaktadır. Sinir ağının amacı bu noktayı yakalayabilmektir [43].

### **3.5. YAPAY SİNİR AĞLARINDA ÖĞRENME ALGORİTMALARI**

Kurulan mimarinin ardından yapay sinir ağı, öğrenme süreci belirli birtakım kurallara ihtiyaç duymaktadır. Tıpkı yapay sinir ağlarının sınıflandırmasında olduğu gibi öğrenme kurallarının da birden fazla yolu vardır. Bu noktada yapay sinir ağının topolojisi ve mimarisi öğrenme kuralları ile yakından ilişkilidir.

Yapay sinir ağlarında öğrenme kuralları yine insanın öğrenme yapısına benzeyen yöntemler temel alınarak ortaya koyulmaktadır. Diğer taraftan bilgisayarların öğrenme biçimi insan beyninin öğrenme şekli ile kıyaslandığında çok kısıtlı olmaktadır. Bu kurallar yardımıyla öğrenme işlemi daha anlaşılabilir ve kullanışlı hale gelmektedir [38].

Bu tez çalışmasında yapay sinir ağı öğrenme sürecinde çeşitli öğrenme algoritmaları kullanılmış ve çıkan sonuçlar birbirleri ile karşılaştırılmıştır.

#### **3.5.1. Levenberg Marquardt Algoritması**

Levenberg Marquardt algoritması, adım azaltmalı ve Gauss Newton algoritmalarının birleşiminden oluşturulan melez bir algoritmadır. Bu algoritmanın popüler olmasının sebebi, birinci dereceden türev yaklaşımlarında yüksek başarı oranı sağlamasıdır. Geri yayımlı mimarinin kullanıldığı yapay sinir ağlarında yoğun olarak tercih edilmektedir.

LM, ağırlıkların güncellemesi Eşitlik 3.9'da gösterilmiştir.

$$X_{k+1} = X_k - [J^T - \mu I]^{-1} J^T e \quad (3.9)$$

Bu eşitlikte;  $\mu$  Marquardt parametresi,  $I$  birim matrisi,  $e$  hata vektörünü,  $T$  matris transpozisini ve son olarak  $J$  ağıdaki ağırlıklara ait hataların türevlerini tutan Jacobian matrisidir [44].

### 3.5.2. Bayesian Algoritması

Bayesian algoritması, Levenberg Marquardt algoritmasını kullanıp ağıın mevcut durumdaki ağırlıklarını ve kutuplama özelliklerini analiz ederek güncelleyen bir algoritmadır. Ağırlıkların ve karesel hataların arasındaki doğru birleşime karar verir. Eşitlik 3.10'da algoritmanın kullandığı formüller gösterilmiştir.

$$\begin{aligned} J_j &= J_x * J_x \\ J_E &= J_x * E \\ dX &= -\frac{(J_j + I * \mu)}{J_E} \end{aligned} \quad (3.10)$$

Bu eşitliklerde  $X$  ağırlık ve kutuplama değerlerini,  $E$  hata miktarını,  $I$  birim matrisi ifade etmektedir [45].

### 3.5.3. Broyden Fletcher Goldfarb Shanno Algoritması

Doğrusal olmayan problemlerin çözümünde kullanılan Broyden Fletcher Goldfarb Shanno algoritması, yineleme yöntemini kullanmaktadır. Genellikle optimizasyon problemlerinde kullanılan BFGS, LM algoritmasından farklı olarak çözümlerinde ikinci türevi de kullanmaktadır.

Bu tür matematiksel işlemlerin fazla olması sebebi ile BFGS algoritması daha fazla hafızaya gereksinim duymaktadır. Eşitlik 3.11'de BFGS algoritmasını kullandığı yöntem gösterilmektedir.

$$X = X + a * dX \quad (3.11)$$

$X$ , ağırlık ve kutuplama değerlerini ifade ederken  $dX$ ,  $X$ 'in türevi olarak tanımlanmaktadır.  $a$  parametresi performansı en küçük değerde tutmak için kullanılmıştır [45].



## **BÖLÜM 4**

### **YÜKSEK FIRINLARDAKİ SIVI HAM DEMİR ÜRETİMİNİN YAPAY SİNİR AĞLARI KULLANILARAK TAHMİN EDİLMESİ**

Bu bölümde, farklı makine öğrenmesi yöntemlerinin yüksek fırınlardan alınan veri setleri üzerine uygulanarak elde edilen sonuçların analizleri ele alınmıştır. MATLAB platformunda yapay sinir ağı tasarlanmış ve denemeler gerçekleştirilmiştir. Bu denemeler sonucunda hem en iyi performansı sağlayan yapay sinir ağı mimarisi hem de bu mimari de kullanılacak öğrenme metodunun tespiti yapılmıştır. Bir sonraki adımda, aynı yapay sinir ağı mimarisi ve veriler Visual Studio ortamında kurulan yapay sinir ağında denenmiş ve sonuçlar analiz edilmiştir.

#### **4.1. KULLANILAN MATERYALLER**

İlgili çalışmada kullanılan veriler, bir demir-çelik fabrikasının 2016 ve 2019 yılları arasında yapmış olduğu aylık üretimleridir. Bu veriler, hem yüksek fırın ile ilgili yapılan benzer akademik çalışmaların hem de uzun yıllar işletmede çalışmış tecrübeli personellerin deneyimleri doğrultusunda tespit edilmiştir. Fiziksel olarak bir yüksek fırına düzenli olarak şarj edilen demir cevheri, kok, fluks malzemeleri ve sıcak hava tesisin giriş parametreleri olarak nitelendirilirken, üretim süreci sonunda elde edilen sıvı ham demir ise işletmenin nihai çıktı parametresi olarak kabul edilmiştir.

#### **4.2. GİRİŞ VE ÇIKIŞ PARAMETRELERİNİN BELİRLENMESİ**

Yapılan çalışmada yüksek fırın üretiminin teorik üretimi báz alınmıştır. Diğer taraftan sıcak maden üretimi, demir-çelik sektöründe üretim prosesleri içinde en başta gelmektedir. Bu durumun asıl sebepleri arasında sadece çok yüksek miktarlara ulaşan üretim miktarı değil, aynı zamanda işletmenin sağladığı yüksek ısıdır.


Yüksek fırın işletmesinin, üretim planlama çerçevesinde gerçekleştirmiş olduğu sıvı ham demir üretimini analiz edebilmek için literatur taraması yapılmıştır [1-7, 46]. Bu kapsamda aşağıdaki giriş ve çıktı parametreleri dikkate alınmıştır.

- Cevher
- Metalurjik Kok
- Dolomit ve kireç taşı karışımları (fluks)
- Sıcak hava

Çıktı parametresi olarak;

- Sıvı ham demir

Bununla beraber, demir (Fe) üretimi için cevher, dolomit ve kireç taşı karışımı, kok kullanılır. Çıktı olarak sıvı ham demirin yanında cüruf, baca tozu ve yüksek fırın gazı elde edilmektedir [46].



Şekil 4.1. Yüksek fırın giriş ve çıkış parametreleri [46].

Yapay sinir ağıının üretilecek olan sıvı ham demir miktarını tahmin işlemlerini gerçekleştirirken reaksiyon sonucunda oluşan cüruf, baca gazı ve yüksek fırın gazları miktarları ihmal edilmiştir. 5 nolu Yüksek Fırın işletmesinde 1 ton sıvı ham demir için yaklaşık 0.3 ton cüruf meydana gelmektedir. Bu sebeple sıvı ham demirin miktarının bilinmesi, cüruf miktarının hesaplanmasına imkân sağlamaktadır.

#### **4.2.1. Cevher**

Günümüzden birkaç çeyrek yüzyıl öncesinde demir cevheri tozları yüksek fırın işletmelerinde tercih edilmiyordu. Bu durumun sebebi ise yer altından çıkarılan demir cevherinin direkt olarak kullanılamamasıdır. Kullanılabilir hale gelmesi için birtakım işlemlerden geçmesi gerekir ve bu işleme cevher hazırlama adı verilir. Kırma, yıkama, harmanlama gibi süreçlerden geçen demir filizi ön hazırlık aşamasını tamamlamış olarak kabul edilir. Bu işlemlerin amacı, cevherin yüksek fırında gireceği tepkimeler için en uygun fiziksel halini almasını sağlamaktır. İdeal bir demir cevherinin çapı 6-8 mm arasında olmalıdır. Bu aralık değerlerine sahip demir cevheri girdiği kimyasal reaksiyonlarda çok iyi katı-gaz etkileşimine girmektedir. Aksi takdirde fiziksel özellikleri sebebi ile tepkime akış yönünü tıkayarak süreci olumsuz yönde etkileyecektir. Bu olumsuz duruma ek olarak kimyasal reaksiyonun ihtiyaç duyduğu sıcaklığı arttıracaktır.

#### **4.2.2. Metalurjik Kok**

Yüksek fırınlarda gerekli sıcaklığın sağlanması için kullanılan yakıttır. Yüksek fırınların kullanılabilmesi için kok bataryalarında üretime hazır hale getirilir. Bunun yanında kok kömürünün en çok kullanıldığı tesis yüksek fırınlardır. Kok, kimyasal reaksiyonların gerçekleşebilmesi için ısı verici ve indirgeyici görevlerini üstlenir. Demir cevherinin erime noktasını düşürerek verimi artırır. Kok cevher gibi yüksek fırınların tepe noktasından şarj edilemez. Bunun yerine tüyer adı verilen hava kanallarından verilir. Giriş parametrelerinin yaklaşık %50-%60'ını kok oluşturmaktadır. Tıpkı demir cevherinde olduğu gibi ideal çapı 6-8 mm arasındadır.

### **4.2.3. Fluks**

Fluks, demir cevherinden sıvı ham demir üretiminde kullanılan ve sıvı ham demir içerisinde Alumina ve Silika gibi istenmeyen materyallerin ayrışmasını sağlayan karışımdır. Fluks karışımı içerisinde dolomit, kireçtaşı, kuvarsit gibi malzemeler bulunmakta ve bu karışımın kullanımı sırasında gerçekleşen kimyasal reaksiyonlar sonunda hem cüruf hem de sıvı ham demir elde edilir. Yüksek fırında gerçekleşen reaksiyonda fluks materyalleri istenmeyen bu maddelere yapışmaktadır. Tepkime sonrası yüksek fırının taban bölgesinde bulunan ve havuz adı verilen kısımda, toplanan sıvı ham demirin üstünde cüruf katmanını oluşturur. Yoğunluğu düşük olması sebebi ile cüruf her zaman sıvı ham demirin üstünde toplanmaktadır. Bu metalürjik ayrışma işlemine izabe adı verilir. Cürufun ayrıştırılması üretilen yarı mamülün kalitesi açısından büyük önem arz etmektedir. Çünkü içinde yoğun miktarda cüruf bileşeni olan sıvı ham demir ile yapılan bir dökümde çatlak, kanama gibi istenmeyen durumların ortaya çıkması muhtemeldir. Diğer taraftan sıvı ham demirin kimyasal analiz sonuçları önemli olduğu gibi cüruf analizleri de üretimin ne kadar verimli olduğu hakkında işletmeye önemli bilgiler verir.

### **4.2.4. Sıcak Hava**

Yüksek fırının alt bölmesinde bulunan ve fırını çevreleyen tüyerlerden üflenen oksijence zenginleştirilmiş sıcak hava %25 oranında oksijen içerirken 1200 – 1600 °C sıcaklığa sahiptir. Yüksek fırın içinde gerçekleşen indirgenme reaksiyonları, malzemelerin ihtiyaç duyduğu ısının sağlanması için sıcak hava kullanılmaktadır. Bunun için giriş parametrelerinden biri olan kokun yanması sağlanarak fırın içi sıcaklığın yüksek seviyelere çıkması sağlanır.

### **4.2.5. Sıvı Ham Demir**

Yüksek fırının çıkış parametresi olarak nitelendirilmektedir. Ayrıca demir çelik sektörünün ana üretim maddesidir. Terimsel olarak, yüksek fırınlarda demir filizinin karbon monoksit veya karbon ile indirgenmesi sonucu oluşan mamuldür. Demir cevherinin yüksek sıcaklık altında kimyasal reaksiyonlar vasıtasıyla ergiyik durumuna

geçmesi sonucunda sıvı ham demir oluşmaktadır. Üretilen bu sıvı pik torpido veya potalar vasıtasıyla çelikhane işletmesine gönderilerek kütük, blum gibi yarı mamül haline getirilmektedir. Yapay sinir ağında giriş parametreleri olarak kullanılacak girdi değişkenleri, Çizelge 4.1’de gösterilmiştir.

Çizelge 4.1. Kullanılan giriş parametreleri.

<b>Parametre Adı</b>	<b>Ölçü Birimi</b>	<b>Açıklama</b>
Kok	ton	Yakıt
Cevher	ton	Demir Cevheri
Fluks	ton	Cüruf Yapıcı Malzeme
Sıcak Hava	°C	Tüyerden Üflenen Sıcak Hava

Bu çerçevede, YSA’nın giriş katmanında kok, cevher, fluks ve sıcak havayı temsil edecek dört adet nöron bulunacaktır. Çizelge 4.2’de yapay sinir ağında çıktı parametresi gösterilmiştir.

Çizelge 4.2. Kullanılan çıkış parametreleri.

<b>Parametre Adı</b>	<b>Ölçü Birimi</b>	<b>Açıklama</b>
Sıvı Ham Demir	ton	Yüksek fırından alınan sıvı ham demir

Yapay sinir ağının son katmanında, bir adet çıktı olacağı için, bir nöron bulunacaktır. Bu nöron sıvı ham demir miktarının tahmininde görev alacaktır. Çizelge 4.3’te beş numaralı yüksek fırında 2019 yılının şubat ayına ait günlük üretim ve tüketim verileri örnek olarak verilmiştir.

Çizelge 4.3. Giriş ve çıkış parametre örnekleri.

<b>Kok</b>	<b>Cevher</b>	<b>Fluks</b>	<b>Hava</b>	<b>Sıvı Ham Demir</b>
1744	5543	14	1317	3224
1855	5947	6	1304	3447
1699	5504	0	1285	3211
1731	5585	0	1278	3257
1607	5163	0	1303	3022
1883	6074	0	1279	3547
1450	4719	0	1323	2758
1726	5570	0	1326	3210
1629	5303	0	1307	3056
1556	5056	0	1313	2932
1749	5344	0	1326	3075
269	714	0	1531	417
973	3197	0	1476	1851
1758	5735	0	1340	3307
1734	5766	0	1302	3326
1900	6170	0	1277	3579
1860	6041	0	1299	3453
1755	5775	0	1323	3255
1812	5992	0	1306	3391
1913	6300	0	1280	3564
1820	5950	0	1308	3421
1886	6152	0	1273	3553
1901	6119	0	1274	3566
1847	5942	0	1284	3464
1821	5904	0	1272	3469
1912	6156	0	1273	3630
1862	6077	0	1248	3582

İlk aşamada yüksek fırın işletmelerinden temin edilen veri seti üzerinde ön işlemler gerçekleştirilmiştir. Yüksek fırında yakıt olarak kullanılan toplam kok kömürü ve PCI malzemelerinin günlük tonajı, cevher değişkeni için sinter, pelet ve parça cevher malzemelerinin günlük toplam tonajı toplamı, fluks değişkeni için kireçtaşı ve dolomit malzemelerinin toplam tonajı, sıcak hava değişkeni için tüyerlerden üflenen havanın °C cinsinden değeri ve son olarak sıvı ham demir değişkeni için teorik sıvı ham

demirin tonaj miktarı verilmiştir. Çizelge 4.3'te gösterilen giriş ve çıkış parametreler örneklerinin normalizasyonlu hâli Çizelge 4.4'te verilmiştir.

Çizelge 4.4. Veri tablosunun normalizasyonlu değerleri.

0.721470	0.719936	0.198246	0.698977	0.720896
0.761024	0.765120	0.142105	0.693064	0.763842
0.705434	0.715574	0.100000	0.684423	0.718392
0.716837	0.724633	0.100000	0.681239	0.727251
0.672650	0.677436	0.100000	0.692609	0.681993
0.771002	0.779323	0.100000	0.681694	0.783101
0.616704	0.627779	0.100000	0.701706	0.631151
0.715056	0.722955	0.100000	0.703070	0.718199
0.680490	0.693094	0.100000	0.694429	0.688541
0.654477	0.665469	0.100000	0.697157	0.664661
0.723252	0.697679	0.100000	0.703070	0.692200
0.195857	0.179855	0.100000	0.796305	0.180308
0.446726	0.457556	0.100000	0.767197	0.456476
0.726459	0.741409	0.100000	0.709437	0.736880
0.717906	0.744876	0.100000	0.692155	0.740539
0.777060	0.790060	0.100000	0.680785	0.789263
0.762806	0.775633	0.100000	0.690790	0.764998
0.725390	0.745883	0.100000	0.701706	0.726866
0.745702	0.770152	0.100000	0.693974	0.753057
0.781693	0.804599	0.100000	0.682149	0.786375
0.748552	0.765455	0.100000	0.694883	0.758835
0.772071	0.788047	0.100000	0.678965	0.784256
0.777416	0.784356	0.100000	0.679420	0.786760
0.758174	0.764560	0.100000	0.683968	0.767116
0.748909	0.760310	0.100000	0.678511	0.768079
0.781336	0.788494	0.100000	0.678965	0.799085
0.763519	0.779659	0.100000	0.667595	0.789841

İkinci aşamada veriler, normalizasyonuna tabii tutularak yapay sinir ağı için kullanışlı hâle getirilmiştir. Çizelge 4.5'te yapay sinir ağlarında kullanılan materyallerin normalizasyonunda tespit edilen minimum ve maksimum değerleri verilmiştir.

Çizelge 4.5. Veri setinin minimum ve maksimum değerleri

<b>Değer\Materyal</b>	<b>Kok</b>	<b>Cevher</b>	<b>Fluks</b>	<b>Sıcak Hava</b>	<b>Sıvı Ham Demir</b>
Maksimum	2254	7153	114	2257	4154
Minimum	232	699	0	598	321

Veri setinde ön işlemler gerçekleştirildikten sonra kok için maksimum değer 2254 ton, cevher için 7153 ton, fluks malzemeleri için 114 ton, sıcak hava için 2257 °C ve sıvı ham demir için 4154 ton olarak belirlenmiştir. Diğer taraftan kok için minimum değer 232, cevher için 699, fluks için 0, sıcak hava için 598 °C ve sıvı ham demir için 321 ton olarak belirlenmiştir.

### **4.3. YAPAY SİNİR AĞINDA KULLANILAN YÖNTEMLER**

Tez çalışmasında İleri Beslemeli Geri Yayımlı Yapay Sinir Ağı kullanılmış olup bu mimaride çeşitli öğrenme algoritmaları test edilmiştir. Girdi parametreleri olarak kok, cevher, fluks ve sıcak hava miktarı seçilirken çıktı parametresi ise sıvı ham demir miktarı olarak belirlenmiştir.

Yapay sinir ağının eğitimi için literatürde sıklıkla tercih edilen üç farklı algoritma kullanılmıştır. Bu algoritmalar Levenberg Marquardt (LM), Bayesian (BR), Fletcher - Golgfarb – Shanno (BFGS) algoritmalarıdır.


Projede yazılımın geliştirildiği platform Visual Studio 2019 Community versiyonu, programlama dili olarak C# kullanılmıştır. Framework olarak .NET Core 4.5. paketi seçilmiştir. Bu platform seçilmesinde açık kaynaklı olmasının yanısıra esnek ve modern olması da etkili olmuştur. Diğer taraftan tıpkı Python programlama dilinde olduğu gibi C# dilinde de artık makine öğrenmesi ve yapay zekâ gibi uygulamalar geliştirilebilmektedir. Bu kapsamda çeşitli kütüphaneler sayesinde Visual Studio da açık kaynaklı kodlamalar yapan programcılar tarafından tercih edilmektedir. Elde edilen verilerin çıktılarının görselleştirilmesi için Chart kütüphanesinden faydalanılmıştır.



#### 4.4. GERÇEKLEŞTİRİLEN DENEYSEL ÇALIŞMALAR


Yapay sinir ağının yüksek test performansına ulaşabilmesi için ara katmandaki nöron sayısının önemi büyüktür. Bu kapsamda, ara katmandaki nöron sayısı değiştirilerek sonuçlar analiz edilmiş ve en uygun mimarinin tespit edilmesi amaçlanmıştır. 1000 adet üretim verisi %70 eğitim, %30 test olmak üzere ayrılmıştır.

Deneysel çalışmalarda, ilk olarak şekil 4.2’de verilen 1 nöronlu ara katmana sahip bir YSA mimarisi kullanılmıştır.



Şekil 4.2. Ara katmanında bir nöron bulunan YSA mimarisi.

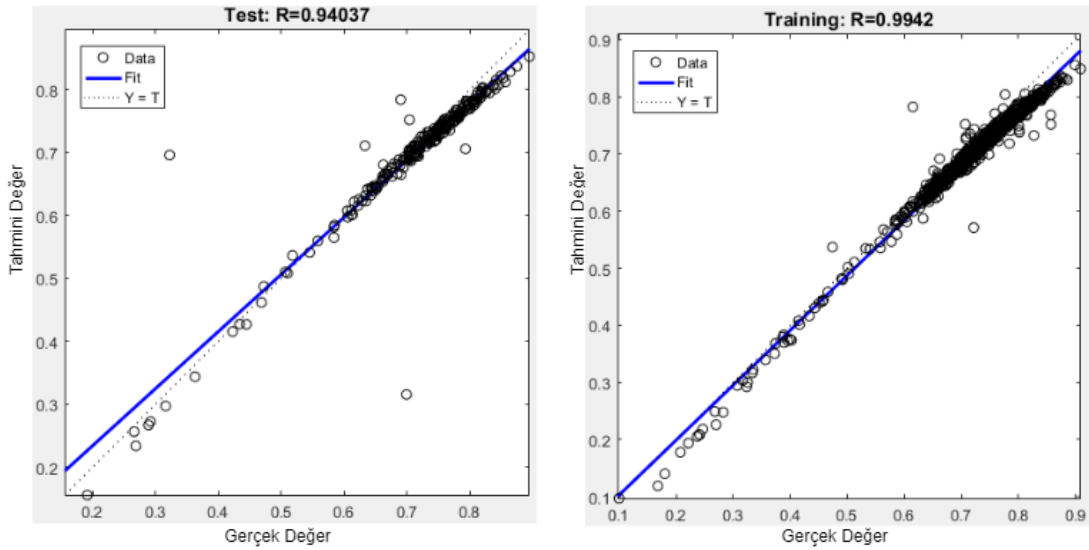
Yapılan eğitim ve test aşamalarında Şekil 4.3’teki sonuçları elde edilmiştir.



Şekil 4.3. Ara katmanında bir nöron bulunan YSA’nın eğitim ve test korelasyon sonuçları.


Grafiklerdeki fit doğrusu, YSA'nın eğitim ve test süreci boyunca gerçekleştirdiği yönelimleri ifade etmektedir.  $Y=T$  doğrusunda ise Y, YSA'nın vermiş olduğu çıktıları temsil ederken T test çıktıları göstermektedir. Bir YSA'nın fit ile  $Y=T$  doğrusu birbirine ne kadar yakın ise sonuç (R) o kadar yüksek olacak ve ilgili süreç o kadar başarılı sayılacaktır. Grafiklerdeki yuvarlak noktalar, eğitim ve test için ayrılan verilerdir. Daha önce eğitim ve test için ayrılan veriler, YSA'ya normalize edilerek gösterildiği için değer aralıkları 0.1-0.9 arasındadır.

Şekil 4.3'te bu mimari ile elde edilen korelasyon grafikleri verilmektedir. Eğitim ve test sonuçları incelendiğinde verilerin  $Y=T$  eksenine yakın olarak konumlandığı görülmektedir. Eğitim seti için %98.94, test için %94.20 oranında bir tahmin başarısı elde edilmiştir. Bu YSA mimarisine, diğer mimarilerle daha kolay karşılaştırılabilmesi için, Model 1 ismi verilmiştir.




Şekil 4.4. Ara katmanında iki nöron bulunan YSA'nın eğitim ve test korelasyon sonuçları.

Ara katmanda iki nöron bulunan YSA mimarisi incelendiğinde fit doğrusunun  $Y=T$  doğrusundan biraz uzaklaştığı görülmektedir. Eğitim oranında yaklaşık %99.42'lik bir başarı oranı elde edilmiştir. Test verileri üzerinde yapılan çalışmada %94.03'lük bir başarı oranı ile sonuçlanmıştır. Bu YSA mimarisine, diğer mimarilerle daha kolay karşılaştırılabilmesi için, Model 2 ismi verilmiştir.



Şekil 4.5. Ara katmanında üç nöron bulunan YSA'nın eğitim ve test korelasyon sonuçları.

Giriş katmanında 4, ara katmanda 3, çıkış katmanında 1 nöron bulunan YSA mimarisi oluşturularak veri seti ile öğrenme ve test süreci incelenmeye devam edilmiştir. Ara katmanda 3 nöronu bulunan YSA mimarisi, eğitim aşamasını yaklaşık %99.56 gibi çok yüksek bir başarı oranı, test aşamasını %94.45'lik bir başarı oranı ile tamamlamıştır. Yapılan ilk 2 denemelerden farklı olarak  $Y=T$  doğrusuna en yakın oranı bu mimari yakalamıştır. Bu YSA mimarisine, Model 3 ismi verilmiştir.



Şekil 4.6. Ara katmanında dört nöron bulunan YSA'nın eğitim ve test korelasyon sonuçları.


Eđitim ve test ařamalarını tamamlayan dđrt nđronlu YSA'da, eđitim iin her ne kadar %99'luk bir bařarı elde etse de ara katmanda u nđrona sahip YSA mimarisinde performans olarak geride kalmıř ve  $Y=T$  dođrusundan uzaklařarak %93'lük bir test bařarı oranı yakalamıřtır. Bu YSA mimarisine, diđer mimarilerle daha kolay karřılařtırılabilmesi iin, Model 4 ismi verilmiřtir.

Model karřılařtırılmasında transfer fonksiyonu olarak logsig fonksiyonu, eđitim fonksiyonu olarak trainlm fonksiyonu kullanılmıřtır. izelge 4.6'da modellerin karřılařtırılması ve test sonuları gđsterilmiřtir.

izelge 4.6. Modellerin karřılařtırılması ve test sonuları.

<b>Model</b>	<b>Ara Nđron</b>	<b>Eđitim</b>	<b>Test</b>
Model 1	1	%98.94	%94.20
Model 2	2	%99.42	%94.03
Model 3	3	%99.56	%94.45
Model 4	4	%99.50	%93.88

Her YSA mimarisi, eđitim ařaması %98'in uřtünde bir bařarı oranı ile tamamlamıřtır. Bu yksek bařarının ana sebebi, iřletme sahasından alınan veriler arasında salınım olmamasıdır. Yapılan analizlerin ardından ara katmanında 3 nđron bulunan YSA'nın uygun olduđuna karar verilmiřtir. Tahmin iřlemi iin kullanılan yapay sinir ađının tasarımı Őekil 4.7'de gđsterilmiřtir.



Şekil 4.7. Tasarlanan yapay sinir ağı mimarisi.

Verilerin tespit edilmesi ve yapay sinir ağına uygun hale getirildikten sonra sinir ağı kurulumuna geçilmiştir. Geri yayılım algoritması kullanılarak eğitilen ileri beslemeli sinir ağı kullanılmıştır. Bu mimarinin kullanılmasında, yapılan çalışmalarda da genel olarak bu mimarinin tercih edilmesi etkili olmuştur.

Giriş katmanı, giriş parametreleri sayısı kadar nöron kullanması gerektiği için 4 adet nörona sahiptir. Toplama fonksiyonunun kullanıldığı ara katmanda kullanılan 3 nöron ise tamamen deneme/yanılma yöntemi ile belirlenmiştir. Diğer taraftan incelenen çalışmalarda da ara katmanda kullanılacak nöron sayısının herhangi bir formülle belirlenemediği ve deneme-yanılma ile nöron sayısına karar verildiği gözlemlenmiştir. Çıkış katmanında sıvı ham demir tahminini yapması için bir adet nöron kullanılmıştır.

Performans analizi için Ortalama Mutlak Yüzde Hata (MAPE) kriteri kullanılmıştır. Literatür çalışmalarında MAPE değeri %10'un altında olan modellerin "çok iyi", %10- %20 arasında olanların "iyi", %20- %50 arasındakilerin "kabul edilebilir" olduğunu ve %50'den yüksek olan modelleri "hatalı ve yanlış" olarak derecelendirmektedir [47]. MAPE oranı Eşitlik 4.1'deki gibi hesaplanmaktadır.

$$MAPE = \frac{100}{n} \sum_{n=1}^n \frac{|y_g - y_t|}{y_g} \quad (4.1)$$

$n$  = Tahmin yapılan iterasyon,  
 $y_g$  = İterasyondaki gerçek değer,  
 $y_t$  = İterasyondaki tahmini değer

olarak ifade edilmektedir.

#### 4.5. YSA MODELLERİNİN PERFORMANSININ DEĞERLENDİRİLMESİ

Bu bölümde yüksek fırınlardan alınan veriler üzerinde yapay sinir ağlarının eğitiminde en iyi sonuçları veren üç farklı eğitim algoritması denenmiştir [48]. Bu algoritmalar; Levenberg Marquardt algoritması, Broyden–Fletcher – Golgfarb – Shanno algoritması ve Bayesian algoritmasıdır. Her eğitim sonucu çizelge ile kayıt altına alınmıştır. Çizelge 4.7’de kullanılan eğitim algoritmaları ile ilgili bir çizelge sunulmuştur.


Çizelge 4.7. Kullanılan eğitim algoritmaları.

Matlab Algoritması	Algoritmanın Kısaltması	Açıklama
trainlm	BFGS	Levenberg Marquardt Geri Yayılım Algoritması
trainbr	BR	Bayesyen Algoritması
trainbfg	BFGS	Broyden, Fletcher, Goldfarb, Shanno Algoritması

Veriler, ilk olarak [0,1] aralığında normalize edilerek Matlab programının çalışma formatına uygun hâle getirilmiştir. YSA’nın tahminlerini gerçekleştirmesinin ardından elde edilen sonuçlar denormalize edilmiştir.

#### 4.5.1. Levenberg Marquardt Geri Yayılım Algoritması Sonuçları

Bu bölümde Levenber Marquardt(trainlm) geri yayılım algoritması, veri seti üzerinde uygulanmıştır.



Şekil 4.8. Levenberg Marquardt algoritması ile yapılan eğitim ve test korelasyon sonuçları.


Levenberg Marquardt (LM) algoritması ile yapılan eğitim sürecinde  $Y=T$  doğrusu ile veri noktaları arasında uzaklıklar tespit edilmiştir. Özellikle 0.2 ve 0.5 aralığında göze çarpan bu uzaklık test sonuçlarına da yansımıştır. Eğitim aşamasında %99.56 oranında başarı sağlarken test sürecini %94.45'lik oranla tamamlamıştır. Algoritma en iyi sonucu 53.iterasyonda bulmuştur. Bu algoritma ile ilgili sonuçlar Çizelge 4.8'de gösterilmiştir.

Çizelge 4.8. LM algoritması ile gerçekleştirilen eğitim ve test sonuçları.

Levenberg Marquardt Algoritması	
Eğitim	%99.56
Test	%94.45
İterasyon Sayısı	53

#### 4.5.2. Bayesian Algoritması Sonuçları

İkinci öğrenme algoritması olan Bayesian algoritması(trainbr), aynı veri seti üzerinde denenmiştir.



Şekil 4.9. Bayesian algoritması ile yapılan eğitim ve test korelasyon sonuçları.

Bayesian algoritması ile yapılan eğitimde veri ve test örneklerinin paralel olarak iki grafikte de 0.6-0.8 bandında sıklaştığı tespit edilmiştir. Her ne kadar test sürecinin 0.2-0.5 aralığında fit doğrusu  $Y=T$  doğrusundan uzakta olsa da 0.6-0.8 değer aralığında başarılı bir süreç yakalayarak başarı oranını yükseltmiştir. Algoritma %99.47 başarı oranı ile eğitimini tamamlarken test aşamasını %94.21'lik başarı oranı ile sonuçlandırmıştır. Algoritma en iyi sonuca 78. iterasyonda ulaşmıştır.


Çizelge 4.9. BR algoritması ile gerçekleştirilen eğitim ve test sonuçları.

Bayesian Algoritması	
Eğitim	%99.47
Test	%94.21
İterasyon Sayısı	78



### 4.5.3. Broyden Fletcher Goldfarb Shanno Algoritması Sonuçları

Son eğitim algoritması olan BFGS eğitim algoritması da aynı veri seti üzerinde denenmiştir.



Şekil 4.10. BFGS algoritması ile yapılan eğitim ve test korelasyon sonuçları.

BFGS algoritması ile yapılan denemede her ne kadar eğitim sürecini %99'luk başarı oranı ile tamamlasa da test aşamasını %90'lık bir oran ile tamamlamıştır. Grafikler incelendiğinde, test aşamasındaki veriler eğitim aşamasındaki verilerden farklı noktalarda bulunup  $Y=T$  doğrusundan uzaklaştığı görülmektedir. Bu durumda test başarı oranı %90.29'da kalırken algoritma en iyi sonucu 71. iterasyonda bulmuştur.

Çizelge 4.10. BFGS Algoritması ile gerçekleştirilen eğitim ve test sonuçları.

<b>BFGS Algoritması</b>	
<b>Eğitim</b>	%99.39
<b>Test</b>	%90.29
<b>İterasyon Sayısı</b>	71

Yapılan eğitim ve test aşamalarına ait sonuçlar tek çizelgede toplanmıştır. Bu sayede üç farklı öğrenme yöntemine ait test sonuçlarının analizi daha kolay olacaktır.

Çizelge 4.11. LM, BR, BFGS algoritmalarının eğitim ve test sonuçları.


<b>Algoritma/Kriter</b>	<b>LM</b>	<b>BR</b>	<b>BFGS</b>
<b>Eğitim</b>	%99.56	%99.47	%99.39
<b>Test</b>	%94.45	%94.21	%90.29
<b>İterasyon Sayısı</b>	53	78	71

Algoritmaların ürettiği sonuçlar analiz edildiğinde, hepsinin birbirine yakın ve eğitimlerini %97'nin üzerinde başarı oranları ile tamamlamışlardır. Eğitim sonuçları arasındaki bu yakınlık, veri setinde dalgalanmanın olmamasının bir göstergesidir. Diğer taraftan kullanılan verilerin sağlıklı olduğunu da işaret etmektedir. Test aşamasında en başarılı sonucu %94.45'lik başarı oranı ile LM algoritması gerçekleştirmiştir. İkinci sırada BR %94.21'lik test başarısına sahip olurken, son sırada %90.29'lük test başarı oranı ile BFGS algoritması yer almıştır.

Bu analizlerin ardından, tezin ikinci adımı olan Visual Studio platformunda tahminler yapılmıştır. Yine aynı mimariye sahip olan ağda, aynı eğitim ve test veri seti kullanılmıştır. Visual Studio ortamında yapılan tahminler en yüksek test başarısına sahip olan BR algoritması ile karşılaştırılmıştır.

#### **4.6. VISUAL STUDIO PLATFORMUNDA HAZIRLANAN YAPAY SİNİR AĞI UYGULAMASI**

Matlab ortamında gerçekleştirilen denemelerin ardından uygulamanın geliştirildiği platform değiştirilmiştir. Visual Studio platformunun seçildiği bu bölümde programlama dili olarak C# kullanılmıştır. Matlab ortamında tasarlanan ve en yüksek test sonuçlarına ulaşan yapay sinir ağı mimarisi ile kullanılan veri seti burada da kullanılmıştır.



Şekil 4.11. Visual Studio ortamında hazırlanan YSA tahmin programının arayüzü.

Şekil 4.11’de, yapay sinir ağının eğitimi “Veri Çek” butonu ile başlatılır. Geçen zaman içerisinde yapay sinir ağı eğitim sürecini tamamlar ve tahmin işlemini gerçekleştirmeye hazır hale gelir. Eğer eğitim süreci istenilen oranda başarı elde edilemez ise “Ağı Eğit” butonu ile tekrar eğitim süreci başlatılır. Kullanıcı, “Tolerans Miktarı” kısmına, genel olarak %10 olarak öngörülmüştür, hata payı girmektedir. Tolerans miktarı, yüksek fırın işletmelerinin çeşitli sebeplerden dolayı üretim miktarında kayıp yaşaması sebebi ile kabul edebildiği oranı temsil etmektedir. Eğer gerçek değer ile yapay sinir ağının gerçekleştirdiği tahmin arasındaki fark tolerans miktarından düşük ise iterasyon başarılı sayılmaktadır. Bu sayede, programın eğitimini ne kadar başarılı tamamladığı tespit edilebilecektir.


Kullanıcı, elindeki giriş parametrelerini sırasıyla kok, cevher, fluks ve sıcak hava kutularına girdikten sonra “Tahmin Et” butonuna basarak tahmin sonucunu elde etmektedir. Bu sayede üretim süreci daha başlamadan üretilcek sıvı ham demir miktarını öngörerek gerekli önlemleri alabilecektir.

İlk olarak iterasyon sayısına bağlı olarak yapay sinir ağının tahmini ile gerçek değerler arasında karşılaştırması gerçekleştirilmiştir. Bunun için sinir ağında iterasyon sayısı adım adım artırılmış ve çıkan sonuçlar Çizelge 4.11’de gösterilmiştir. Bu sayede en iyi iterasyonun tespit edilmesi sağlanmaktadır.

Çizelge 4.12. İterasyon sayısına bağlı olarak hata miktarının değişimi.

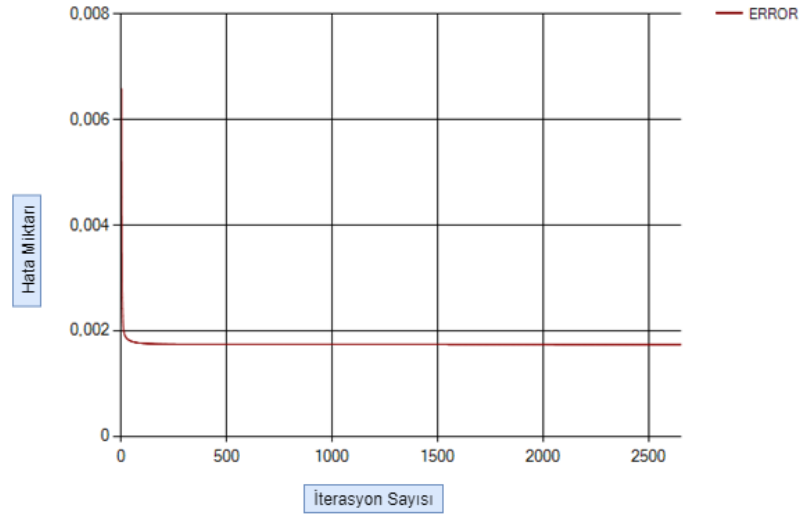
İterasyon Sayısı	Yüksek Fırında üretilen sıvı ham demir miktarı	Visual Studio platformunda hazırlanan YSA'nın tahmini	Hata Oranı (%)
10	3146 ton	2939 ton	6,55
20	3146 ton	2943 ton	6,45
50	3146 ton	2969 ton	5,60
100	3146 ton	3042 ton	3,30
200	3146 ton	3129 ton	0,17
500	3146 ton	3129 ton	0,17

Çizelge 4.12'de görüldüğü üzere iterasyon sayısındaki hata oranlarının azalmasında ve gerçek değerlere yakın tahminlerin yapılabilmesinde önemli rol oynamaktadır. Hata oranının en düşük seviyeye geldiği 153. iterasyonda olduğu saptanmıştır.



Şekil 4.12. Visual Studio ile hazırlanan YSA'nın tahmin grafiği.

Şekil 4.12'deki grafikte, YSA'nın gerçekleştirmiş olduğu tahmine ait grafik gösterilmiştir. Bu grafikte yeşil renkteki çizim yüksek fırında gerçek değerlerin oluşturduğu değerler iken kırmızı renkteki çizim yapay sinir ağının gerçekleştirmiş olduğu tahminlere aittir. y düzleminde bulunan değerler tonaj bazında sıvı ham demir miktarı iken x düzlemindeki değerler iterasyona örneklelidir.



Şekil 4.13. Visual Studio platformunda hazırlanan YSA'nın eğitim sürecinde zamana bağlı hata miktarının değişim grafiği.

Şekil 4.13'te zamana bağlı hata değişiminin grafiği verilmiştir. Şekil ve çizelgelerden anlaşıldığı üzere iterasyon sayısındaki artış, her zaman olmamakla birlikte, gerçeğe yakın tahminlerin yapılmasını olumlu etkilemektedir. Belirli bir iterasyondan sonra hata oranı hep aynı miktarda kalarak 0.0017 değerinin altına düşmemiştir.

Üretilen sıvı ham demirin çelikhane işletmesine gönderilmesinde kullanılan torpedo hacmine bağlı olarak kaç adet gerektiği hesabı da gösterilmiştir. Dikkat edilmesi gereken kısım, her torpedonun aynı debiye sahip olmamasıdır. Bir torpedonun içerisinde kalan sıvı ham demir zaman içerisinde soğuyarak katılaşmakta ve bunun sonucunda da torpedonun debisi azalmaya başlamaktadır.

Genel bir hesap yapılabilmesi için kullanılan torpedoların sahip oldukları debi ortalaması alınarak yapılan tahminlere oranlar kaç adet torpedonun gerekli olduğu hesaplanmaya çalışılmıştır. Şekil 4.14'te örnek bir hesaplama görülmektedir.

Sonuç: 3053,24207705753 Topedo sayısı:122,129683082301  
Hata: 4,43686769772985

Ağı Eğit

Kok	Cevher	Flux	Hava	Elde Edilen Sıvı Demir
1758	5523	15	1293	3195

Tahmin Et

Veri Çek

Dogruluk Oranı

75/1002 olarak seçilen 10

0,0149928

Şekil 4.14. Visual Studio platformunda hazırlanan YSA programının torpedo tahmini.

Yapay sinir ağı ile gerçekleştirilen tahmin sonucuna istinaden ihtiyaç duyulacak torpedo sayısı aşağıdaki formül yardımıyla bulunmaktadır;

$$\text{Torpedo sayısı} = \text{Tahmini Sıvı Ham Demir Miktarı} / \text{Debi} \quad (4.2)$$

Eşitlik 4.2.'de debi miktarı sabit olarak 25 ton alınmıştır. Tahmini sıvı ham demir miktarı, YSA'nın gerçekleştirmiş olduğu tonaj miktarıdır. Bu hesaplama ile yüksek fırında üretilen sıvı ham demirin çelikhane işletmesine taşınabilmesi için kaç adet torpedoya ihtiyaç olacağı öngörülebilmektedir.

#### 4.7. PLATFORM DEĞİŞİKLİĞİ ANALİZİ

İki farklı programlama ortamında yapılan denemelere ait sonuçlar analiz edilmiştir. Çizelge 4.10'da aynı mimari ve veri setinine sahip YSA'nın farklı platformlarda karşılaştırılması yapılmıştır.

Çizelge 4.13. YSA’da platform değişikliği analizi.

<b>Kriter / Platform</b>	<b>MATLAB platformu</b>	<b>Visual Studio platformu</b>
<b>Eğitim</b>	%99.56	%96
<b>Test</b>	%94.45	%92
<b>MAPE</b>	%5.89	%7.83
<b>İterasyon</b>	53	153

Eğitim aşaması, her iki platformda da eğitim kısmını yüksek bir başarı yüzdesi ile tamamlanmıştır. Kullanılan verilerin sağlıklı ve güvenilir olduğu böylece bir kez daha teyit edilmiştir.

Performans değerlendirme ölçüsü olarak her iki platform mutlak ortalama mutlak yüzde hata (MAPE) çerçevesinde değerlendirilmiştir. Her iki kodlama ortamı da %10’dan daha düşük bir hata payına sahip olmasından dolayı literatürde bahsi geçen, “çok iyi” kategorisine girmişlerdir. Bu performansın elde edilmesinde; Bölüm 3’te bahsedilen YSA mimarisi, aktivasyon fonksiyonu, normalizasyon çeşidi gibi ölçülerin doğru seçilmesi büyük önem arz ettiği görülmektedir. Visual Studio platformunun en yüksek başarı oranına 153. iterasyonda ulaşırken Matlab 53. iterasyonda bu başarıyı sağlamıştır. Diğer taraftan MAPE oranında da Matlab daha düşük hata oranına sahiptir.

## BÖLÜM 5

### SONUÇLAR VE TARTIŞMA

Bu tez çalışmasında sıvı ham demir üretiminin gerçekleştirildiği yüksek fırın işletmesi incelenerek üretilen sıvı pik miktarına dair tahmin için yapay sinir ağı kullanılmıştır. Yapılan çalışma sayesinde yüksek fırınların üreteceği sıvı ham demir miktarı, 8 saat beklemeden öngörülebilmektedir. Ayrıca çelikhane işletmesine gönderilecek olan sıvı ham demirin taşınmasında kullanılan torpedo sayısına ilişkin tahmin de bulunması programı işletme için kullanışlı hale getirmektedir.

Kullanılan yapay sinir ağının daha doğru tahminler yapabilmesi için girdi parametreleri artırılabilir. Giriş parametrelerinin kalitesi ve kimyasal analizlerin yanında elde edilen cürufun da analizi ilave edilerek gerçekleştirilecek tahminlerin daha başarılı olacağı düşünülmektedir.

Bu çalışma kullanılarak daha farklı alanlarda akademik çalışma gerçekleştirilebilir. Malzeme ve metalürji bölümünde maliyetlerin düşürülmesi adına kok, cevher, fluks için en uygun karışımın hazırlanmasında efektif olarak kullanılabilir.

Giriş parametreleri PLC, SCADA, DCS gibi canlı sistemlerden alınıp tahminler anlık olarak takip edilebilir. Böylece yapay sinir ağının yaptığı tahminler ve gerçek değerler arasındaki fark çok yüksek olduğu takdirde yüksek fırın işletmesinde çeşitli sebeplerden dolayı meydana gelebilecek arızalar tespit edilebilir. Bu sayede tesis duruşa geçmeden hemen önce detaylı bir planlama yapılarak bakım süre ve maliyetlerinin azaltılabileceği öngörülmektedir.



## KAYNAKLAR

1. Aydın, Ö., “Yüksek fırın işletmeciliğinde optimizasyon”, Yüksek Lisans Tezi, *Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü*, İstanbul (2005).
2. Ge, A. X., “A neural network approach to the modeling of blast furnace”, M.Sc. Thesis, *MIT Department of Electrical Engineering and Computer Science* (1999).
3. Aslan, B.H., “Demir-Çelik üretimindeki gelişmeler ve bir entegre tesis modernizasyon örneği”, Yüksek Lisans Tezi, *Mustafa Kemal Üniversitesi Fen Bilimleri Enstitüsü Makine Mühendisliği Anabilim Dalı*, Antakya (2008).
4. Savaşkan, T., “Malzeme Bilgisi ve Muayenesi”, *Karadeniz Teknik Üniversitesi Makine Mühendisliği Bölümü Malzeme Bilimleri Anabilim Dalı*, Trabzon (1999).
5. T.C. Sanayi ve Teknoloji Bakanlığı, “Demir Çelik Sektör Raporu”, *Sektörel Raporlar-Sanayi ve Verimlilik Genel Müdürlüğü*, 15-16 (2019).
6. Bulut, B., “Yüksek fırınlarda verim artırmak amacıyla koklaşabilir yerli ve ithal kömürlerin optimum harmanlama özelliklerinin belirlenmesi”, Yüksek Lisans Tezi, *Çukurova Üniversitesi Fen Bilimleri Enstitüsü Maden Mühendisliği Anabilim Dalı*, Adana (2010).
7. Bozkurt, E., “Yüksek fırın analizi ve yapay sinir ağı ile modellenmesi”, Yüksek Lisans Tezi, *Sakarya Üniversitesi Fen Bilimleri Enstitüsü*, Sakarya (2007).
8. Peacey, J. G. and Davenport, W.G. “The iron blast furnace theory and practice”, *Pergamon Press*, 1-29, Oxford (1979).
9. Radhakrishna, V. R. and Mohamed, A. R., “Neural networks for the identification and control of the blast furnace hot metal quality”, *Elsevier Journal of Process Control*, 10, 509-524 (2000).
10. Sadhukhan, A. K., Bag, S. K., Tapas A. M. and Ray, R. S., “Prediction of air separation column behavior based on static neural network”, *Tata Search* (1999).
11. Nikus, M. and Saxen, H., “Prediction of a blast furnace burden distribution variable”, *ISIJ International*, (9), 1142-1150 (1996).
12. Bulsarı, A., Saxen, H. and Saxen, B., “Time-series prediction of silicon in pig iron using neural networks”, *International Conference on Engineering Applications of Neural Networks (EANN .92)* (1992).

13. Jimenez, J., Mochon, J., Ayala, J. S. and Obeso, F., “Blast furnace hot metal temperature prediction through neural networks-based models”, *ISIJ International*, (3), 573-580 (2004).
14. Chiew, F. H., “Prediction of Blast Furnace Slag Concrete Compressive Strength Using Artificial Neural Networks and Multiple Regression Analysis”, *2019 International Conference on Computer and Drone Applications (IConDA)*, Kuching, Malaysia, 54-58 (2019).
15. Sun, W., Wang, Z. and Wang, Q., “Hybrid event-, mechanism- and data-driven prediction of blast furnace gas generation”, *Energy* (2020).
16. Assis, P. S., Carvalho, L. and Irgalyev, A., “Artificial neural network-based committee machine for predicting fuel rate and sulfur contents of a coke blast furnace”, *International Journal of Science and Research*, 1492-1495 (2019).
17. Bashista, K. M. and Nirupam C., “Tri-objective optimization of noisy dataset in blast furnace iron-making process using evolutionary algorithms”, *Journal Materials and Manufacturing Processes*, 677-686 (2020).
18. Zagoskina, E. V. and Barbasova, T. A., “Control of the blast furnace thermal state based on the neural network simulation”, *International Multi-Conference on Engineering, Computer and Information Sciences*, Novosibirsk, Russia, 714-718 (2019).
19. Shahmansouri, A. A., Akbarzadeh B. H. and Ghanbari, S., “Compressive strength prediction of eco-efficient GGBS-based geopolymers using GEP method”, *Journal of Building Engineering* (2020).
20. Liao Z., “Combining discrete element method and artificial neural network to predict the particle segregation behaviors at bell-less top blast furnace”, *11th International Symposium on High-Temperature Metallurgical Processing* (2020).
21. Yang, Y., Zhao, X. and Liu, X., “A Novel Exhaust Gas Temperature Prediction Method of Hot Blast Stove”, *39th Chinese Control Conference*, Shenyang, China, 5916-5921 (2020).
22. Şahin, M., “Karar ağaçları ve yapay sinir ağları kullanılarak kasko sigortalarında risk değerlendirme”, Yüksek Lisans Tezi, *Yıldız Teknik Üniversitesi İstatistik Bölümü Anabilim Dalı*, İstanbul (2018).
23. Uzunali, A., “Yapay sinir ağlarına dayalı yağış tahmin ve analizi”, Yüksek Lisans Tezi, *İstanbul Kültür Üniversitesi Lisansüstü Eğitim Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı*, İstanbul (2019).
24. Ömrüuzun, B., “Yapay sinir ağları ile kripto paraların fiyat modellenmesi”, Yüksek Lisans Tezi, *İstanbul Üniversitesi Sosyal Bilimler Enstitüsü İşletme Anabilim Dalı*, İstanbul (2019).

25. GÜNGÖR, S., “Meyve ağırlığı tahmininde farklı yapay sinir ağları yaklaşımı”, Yüksek Lisans Tezi, *Erciyes Üniversitesi Fen Bilimleri Enstitüsü Biyosistem Mühendisliği Anabilim Dalı*, Kayseri (2019).
26. KORKUT, D., “Yapay sinir ağları ile talep tahmini ve ayakkabı sektörüne uygulaması”, Yüksek Lisans Tezi, *Ankara Hacı Bayram Veli Üniversitesi Lisansüstü Eğitim Enstitüsü Ekonometri Anabilim Dalı*, Ankara (2019).
27. AKSU, Y., “İleri beslemeli geri yayımlı yapay sinir ağlarının incelenmesi”, *Van Yüzüncü Yıl Üniversitesi Sağlık Bilimleri Enstitüsü Biyoistatistik Anabilim Dalı*, Van (2019).
28. KOCATEPE, C. İ., “Ekonomik endeksler kullanılarak Türkiye’deki altın fiyatındaki değişim yönünün yapay sinir ağları ile tahmini”, Yüksek Lisans Tezi, *Gazi Üniversitesi Bilişim Enstitüsü*, Ankara (2017).
29. YUMUŞAK, N., “Güç sistemi devre elemanlarının elektriksel özelliklerinin elde edilmesinde yapay sinir ağı tabanlı algoritmaların kullanılması”, Doktora Tezi, *Sakarya Üniversitesi Fen Bilimleri Enstitüsü*, Sakarya (1998).
30. YILMAZ, O., “Pi-Sigma yapay sinir ağlarının diferansiyel gelişim algoritması ile eğitimi”, Yüksek Lisans Tezi, *Giresun Üniversitesi Fen Bilimleri Enstitüsü Matematik Anabilim Dalı*, Giresun (2019).
31. KIRANKAYA, C., “Çoklu popülasyon tabanlı metasezgisel algoritma ile yapay sinir ağlarının eğitilmesi”, Yüksek Lisans Tezi, *Erciyes Üniversitesi Fen Bilimleri Enstitüsü*, Kayseri (2019).
32. YILDIRIM, M., Z., “Makine öğrenmesi yöntemleri ile network saldırı tespiti”, Yüksek Lisans Tezi, *Karabük Üniversitesi Fen Bilimleri Enstitüsü*, Karabük (2017).
33. SARAÇ, T., “Yapay sinir ağları”, Seminer Projesi, *Gazi Üniversitesi Endüstri Mühendisliği Anabilim Dalı*, Ankara (2004).
34. BAYIR, F., “Yapay sinir ağları ve tahmin modellemesi üzerine bir uygulama, Yüksek Lisans Tezi”, *İstanbul Üniversitesi Sosyal Bilimler Enstitüsü*, İstanbul (2006).
35. ÖZTEMEL, E., “Yapay Sinir Ağları”, *Papatya Yayıncılık* (2003).
36. ÇAYIROĞLU, İ., “İleri Algoritma Analizi Ders Notları”, *Karabük Üniversitesi Mühendislik Fakültesi*, Karabük (2015).
37. ÇETİN, M., UĞUR A., ve BAYZAN Ş., “İleri beslemeli yapay sinir ağlarında geriye yayılım algoritmasının sezgisel yaklaşımı”, Yüksek Lisans Tezi, *Pamukkale Üniversitesi Fen Bilimleri Entüsü*, Denizli (2006).
38. AŞKIN, D., İSKENDER İ. ve MAMIZADEH A., “Farklı yapay sinir ağları yöntemlerini kullanarak kuru tip transformatör sargısının termal analizi”, *Gazi Üniv. Müh. Mim. Fak. Der.*, Ankara, 26(4): 905-913 (2011).

39. Keleşoğlu, Ö., “Yapay sinir ağları ile betonarme kiriş kesitlerin analizi”, *İMO Teknik Dergi*, 3935-3942 (2006).
40. Demirbay, B. ve Karakullukçu, A., “Artificial neural network (ANN) approach for dynamic viscosity of aqueous gelatin solutions: a soft computing study”, *Avrupa Bilim ve Teknoloji Dergisi*, (18), 465-475 (2020).
41. Eğrisöğüt, A., “Çimento hammadde karışımı prosesinin yapay sinir ağları ile matematiksel modellenmesi”, Yüksek Lisans Tezi, *Sakarya Üniversitesi Fen Bilimleri Enstitüsü*, Sakarya (2002).
42. Yavuz S. ve Deveci M., “İstatistiksel normalizasyon tekniklerinin yapay sinir ağı performansına etkisi”, *Erciyes Üniversitesi İktisadi ve İdari Bilimleri Fakültesi Dergisi*, (40), 167-187 (2012).
43. Hameed A. A. H., “Robust adaptive learning approach of artificial neural networks”, Doktora Tezi, *Selçuk Üniversitesi Fen Bilimleri Enstitüsü*, Konya (2017).
44. Sağiroğlu, Ş., Beşdok, E. ve Erler, M., “Mühendislikte Yapay Zekâ Uygulamaları-I: Yapay Sinir Ağları”, *Ufuk Kitap*, 426 (2003).
45. Ham, F. M. and Kostanic, I., “Principles of Neurocomputing for Science and Neurocomputing”, *Mcgraw-Hill Higher Education*, New York, 672 (2001).
46. Beşkardeş, A., Türkoğlu, S. and Acı, Ç., “Prediction of the hot metal silicon content in the Blast Furnace”, *24th Signal Processing and Communication Application Conference (SIU)*, 709-712, Zonguldak (2016).
47. Çuhadar M. ve Kervankıran, İ., “Nevşehir ili konaklama işletmelerine yönelik turizm talebinin analizi, modellemesi ve tahminleri, modellenmesi ve tahminleri”, *Ekonomi ve Yönetim Araştırmaları Dergisi*, 5(2) (2016).
48. Toraman, M., “Uçakların itki kuvvetinin yapay sinir ağları ile tahmini”, Yüksek Lisans Tezi, *Erciyes Üniversitesi Fen Bilimleri Enstitüsü*, Kayseri (2019).

## **ÖZGEÇMİŞ**

Ertan Yavuz KÖPRÜ 1993 yılında Karabük ilinde dünyaya gelmiştir. İlk ve orta öğrenimini Demir Çelik 50. Yıl İlköğretim Okulunda tamamlamıştır. 2011 yılında 75.Yıl Karabük Anadolu Lisesi'nden mezun olmuştur. 2017 yılında Karabük Üniversitesi Bilgisayar Mühendisliği Bölümü'nden mezun olmuş ve Kardemir Demir Çelik Fabrikalarında mühendis olarak göreve başlamıştır. 2018 yılında Karabük Üniversitesi Fen Bilimleri Enstitüsünde Bilgisayar Mühendisliği bölümünde Lisansüstü eğitime başlamıştır. 2019 yılında kurulan Elektrik Otomasyon Müdürlüğü bünyesinde Haddehaneler Seviye 2 Mühendisi ünvanı ile çalışmaya devam etmektedir.

### **ADRES BİLGİLERİ**

Adres : Kardemir Fabrika Sahası  
Elektrik Otomasyon Müdürlüğü  
Fabrika Sahası / KARABÜK  
Tel : 0 (370) 418 30 35  
E-posta : eykopru@gmail.com