



**YAPAY ZEKA TEKNİKLERİ İLE YÜKSEK  
FIRINDA TAHMİN VE ÖNERİ SİSTEMİ  
GELİŞTİRİLMESİ**

**Erdoğan BOZKURT**

**2022  
DOKTORA TEZİ  
BİLGİSAYAR MÜHENDİSLİĞİ**

**Tez Danışmanı  
Doç. Dr. İlhami Muharrem ORAK**

**YAPAY ZEKA TEKNİKLERİ İLE YÜKSEK FIRINDA TAHMİN VE ÖNERİ  
SİSTEMİ GELİŞTİRİLMESİ**

**Erdoğan BOZKURT**

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

**Tez Danışmanı  
Doç. Dr. İlhami Muharrem ORAK**

**KARABÜK  
Ağustos 2022**

Erdoğan BOZKURT tarafından hazırlanan “YAPAY ZEKA TEKNİKLERİ İLE YÜKSEK FIRINDA TAHMİN VE ÖNERİ SİSTEMİ GELİŞTİRİLMESİ” başlıklı bu tezin Doktora Tezi olarak uygun olduğunu onaylarım.

Doç. Dr. İlhami Muharrem ORAK .....  
Tez Danışmanı, Bilgisayar Mühendisliği Anabilim Dalı

Bu çalışma, jürimiz tarafından Oy Birliği ile Bilgisayar Mühendisliği Anabilim Dalında Doktora tezi olarak kabul edilmiştir. 19/08/2022

<u>Ünvanı, Adı SOYADI (Kurumu)</u>	<u>İmzası</u>
Başkan : Prof. Dr. Fatih V. ÇELEBİ	Online
Üye : Doç. Dr. İlker TÜRKER	Online
Üye : Doç. Dr. İlhami M. ORAK	.....
Üye : Dr. Öğr. Üyesi Mustafa YENİAD	Online
Üye : Dr. Öğr. Üyesi Oğuzhan MENEMENCİOĞLU	Online

KBÜ Lisansüstü Eğitim Enstitüsü Yönetim Kurulu, bu tez ile, Doktora 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.”*

Erdoğan BOZKURT

## ÖZET

**Doktora Tezi**

### **YAPAY ZEKA TEKNİKLERİ İLE YÜKSEK FIRINDA TAHMİN VE ÖNERİ SİSTEMİ GELİŞTİRİLMESİ**

**Erdoğan BOZKURT**

**Karabük Üniversitesi**

**Lisansüstü Eğitim Enstitüsü**

**Bilgisayar Mühendisliği Anabilim Dalı**

**Tez Danışmanı:**

**Doç. Dr. İlhami Muharrem ORAK**

**Ağustos 2022, 138 sayfa**

Yüksek Fırın (YF) üretim metodolojisi, çok değişkenli proses girdilerine ve uygun şekilde modellenmesi gereken değişkenliklere bağlı olduğundan, demir-çelik fabrikalarının en karmaşık proseslerinden biridir. Pahalı yatırım maliyetleri nedeniyle, genel yüksek fırın verimliliğini ve kararlılığını optimize etmek ve ayrıca kullanım ömrünü en üst düzeye çıkarmak için işletme giderlerini azaltarak, hammadde ve yakıt tüketim performansını artırarak yüksek fırını çalıştırmak çok önemlidir. Sıcak metalin kimyasal bileşimleri ve sıcaklığı, işlemi değerlendirirken önemli göstergeler olmasından dolayı, sonraki ölçümler yerine sıcak metal sıcaklığının gelecekteki değerleri önceden tahmin edilebilirse, yüksek fırın çalışanları yüksek fırını en iyi şekilde kontrol etmek için kok/cevher oranı, dağıtım matrisi, oksijen zenginleştirme oranı, yüksek nem oranı, geçirgenlik, alev sıcaklığı, soğuk hava sıcaklığı, soğuk hava akışı ve toz haline getirilmiş kömür enjeksiyon hızı gibi aşağıdakiler gibi çeşitli operasyonel parametreler üzerinde daha erken karşı önlemler alabilir. Bu çalışmada,

en uygun proses girdileri ve sıcak metal sıcaklıklarının gemiş gerek deęerleri kullanarak seilmesi ve fırın sıcak metal sıcaklığının izlenmesi ve tahmin edilmesi için NARX (Doęrusal olmayan otoregresif eksojen model) zaman serisi yaklaşımı ile birleştirilmiş Yapay Sinir Ağları (YSA) modeli önerilmiştir. 2 aylık operasyon sırasında Türkiye'de işletilen yüksek fırından toplanan veriler. Önceki makalelere kıyasla bu çalışmanın yeniliğini ve etkinliğini sağlayan şarj döngüsü ve fırının çalışma hızı gereksinimleri nedeniyle çeşitli veri madencilięi teknikleri uygulanmaktadır. ANN tahmin sonuçları, R2 (Belirleme Katsayısı), RMSE (Kök ortalama kare hatası) ve MAPE (Ortalama mutlak yüzde hatası) için sırasıyla 0,92, 8,59 ve 0,41 istatistiksel ölçümleriyle çok tatmin edici bulunmuştur. Ayrıca, fırının ısınma veya soęutma hareketlerinin durumuna orta vadede karar vermek ve operasyonel durumu sürdürmek için son tahmin edilen HMT deęeri ve son 5 HMT deęerlerinin ortalaması kullanılarak 5x5 olasılık matrisi tasarımı ile bulanık eęer-öyleyse kuralları kullanılarak bir uzman öneri sistemi önerilmiş ve eylemleri önceden etkileşimli olarak gerekleştirilmiştir.

**Anahtar Sözcükler :** Yapay Zeka; Yapay Sinir Ağları; Yüksek Fırın; Uzman Öneri Sistemi; Sıcak Maden Sıcaklığı; Tahminleme

**Bilim Kodu** : 92432

## **ABSTRACT**

**Ph. D. Thesis**

### **PROPOSAL OF A PREDICTION AND SUGGESTION SYSTEM FOR BLAST FURNACES BY USING ARTIFICIAL INTELLIGENCE TEQNIQUES**

**Erdoğan BOZKURT**

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

**Thesis Advisor:**

**Doç. Dr. İlhami Muharrem ORAK**

**August 2022, 138 pages**

Blast Furnace (BF) production methodology is one of the most complex process of iron & steel plants as it is dependent on multi-variable process inputs and disturbances to be modelled properly. Due to expensive investment costs, it is critical to operate a BF by reducing operational expenses, increasing the performance of raw material and fuel consumptions to optimize furnace stability and efficiency at overall, and also to maximize the lifetime. The chemical compositions and temperature of hot metal are important indicators while evaluating the operation, therefore, if the future values of hot metal temperature can be predicted in advance instead of subsequent measuring, then the BF staff can take earlier counteractions on several operational parameters such as coke to ore ratio, distribution matrix, oxygen enrichment rate, blast moisture rate, permeability, cold blast flow, flame temperature, cold blast temperature and pulverized coal injection rate, etc. to control the furnace optimally. In this study, Artificial Neural Networks (ANN) model is proposed combined with NARX (Nonlinear autoregressive

exogenous model) time series approach to track and predict furnace hot metal temperature by selecting the most suitable process inputs and past values of hot metal temperatures using the real data which is collected from the BF operated in Turkey during 2 months of operation. Various data mining techniques are applied due to requirements of charge cycling and operating speed of the furnace which secures novelty and effectiveness of this study comparing previous articles. ANN prediction results are found very satisfactory with statistical measures of 0.92, 8.59 and 0.41 for  $R^2$  (Coefficient of determination), RMSE (Root mean squared error) and MAPE (Mean absolute percentage error) respectively. Furthermore, an expert suggestion system is proposed using fuzzy if-then rules with 5x5 probability matrix design using the last predicted HMT value and the average of the last 5 HMT values to decide furnace's warming or cooling movements state in mid-term and maintain the operational actions interactively in advance.

**Key Word** : Artificial Neural Networks; Blast Furnace; Expert Suggestion System; Hot Metal Temperature; Prediction.

**Science Code** : 92432



## TEŐEKKÜR

Uzun süre emek verdiđim alıřmanın fikrinin oluřturulmasından bařlayıp planlama, arařtırma, yürütme ve tamamlanmasında yönlendirmelerini ve sürekli ve desteđini veren, tüm tecrübe ve bilgilerinden yararlandıđım, motivasyonu ve devamlılık kararlılıđı ile birlikte tavsiye, yönlendirme ve bilgilendirmeleriyle alıřmayı bilimsel temeller ışığında řekillendiren sayın hocam Do. Dr. İlhami Muharrem ORAK'a sonsuz teőekkürlerimi sunarım.

Tüm süreç boyunca tavsiye ve yönlendirmelerini ve tecrübe paylařımları ile desteklerini esirgemeyen Prof.Dr. Fatih V. elebi ve Do. Dr. İlker Türker Hocalarıma teőekkürü bir bor bilirim.

Sürete her daim desteđini esirgemeyen arkadařım Dr. Yasin TUNKAYA'ya da ayrıca teőekkür ederim.

## İÇİNDEKİLER

	<u>Sayfa</u>
KABUL .....	iii
ÖZET .....	iv
ABSTRACT .....	vi
TEŞEKKÜR .....	viii
İÇİNDEKİLER .....	ix
ŞEKİLLER DİZİNİ .....	xiii
ÇİZELGELER DİZİNİ .....	xv
SİMGELER VE KISALTMALAR DİZİNİ .....	xvi
BÖLÜM 1 .....	1
GİRİŞ .....	1
1.1. ÇALIŞMANIN AMACI .....	6
1.2. ÇALIŞMANIN LİTERATÜRDEKİ YERİ .....	10
1.3. ÇALIŞMANIN LİTERATÜRE KATKISI .....	15
BÖLÜM 2 .....	16
YÜKSEK FIRIN VE ÇEVRE BİRİMLERİ .....	16
2.1. DEMİR ÇELİK FABRİKALARI VE YÜKSEK FIRINLAR .....	16
2.2. YÜKSEK FIRINLARIN GENEL YAPISI .....	18
2.3. HAMMADDELER .....	21
2.4. ÜRÜNLER .....	22
2.5. YÜKSEK FIRIN YARDIMCI SİSTEMLERİ .....	24
2.5.1. Hammadde Besleme Sistemi .....	24
2.6.2. Fırın Tepe Şarj Sistemi .....	25
2.6.3. Sobalar .....	25
2.6.4. Hidrokarbon İlavesi Sağlayan Sistemler .....	26
2.6.5. Dökümhane .....	26
2.6.6. Soğutma Sistemleri .....	26

	<b><u>Sayfa</u></b>
2.6. ÜRETİM SÜRECİ .....	27
2.6.1. Demiroksitlerin İndirgenmesi.....	28
2.6.2. Alt Bölge Tepkimeleri .....	30
2.6.3. Orta Bölge Tepkimeleri .....	33
2.6.4. Üst Bölge Tepkimeleri.....	34
2.7. VERİMLİLİKTEKİ GELİŞMELER.....	34
BÖLÜM 3 .....	37
BULANIK MANTIK.....	37
3.1. GİRİŞ VE TARİHÇE.....	37
3.2. BULANIK KÜME TEORİSİ.....	39
3.2.1. Bazı Kavram ve Terimler .....	40
3.2.2. Bulanık Küme(Fuzzy Set) İşlemleri .....	43
3.2.2.1. Kapsama(Alt küme) .....	43
3.2.2.2. Birleşim(Union) .....	43
3.2.2.3. Kesişim(Intersection).....	44
3.2.2.4. Tümleyen(Complement) .....	45
3.2.3. Bazı Bulanık Küme Kuralları .....	45
3.2.4. Üyelik Fonksiyonları .....	46
3.2.4.1. Üçgen Üyelik Fonksiyonu .....	46
3.2.4.2. Yamuk Üyelik Fonksiyonu .....	47
3.2.4.3. Gaussian Üyelik Fonksiyonu .....	47
3.2.4.4. Genelleştirilmiş Çan Üyelik Fonksiyonu.....	48
3.2.4.5. Sigmoid Üyelik Fonksiyonu .....	48
3.3. BULANIK YARGILAMA.....	49
3.2.1. Bulanık Eğer-İse Kuralları.....	49
3.2.2. Bulanık Yargılama.....	51
3.4. BULANIK ÇIKARIM SİSTEMLERİ.....	53
3.4.1. Mamdani Bulanık Çıkarım Sistemi .....	55
3.4.1.1. Alanın Kitle Merkezi .....	55
3.4.1.2. Alanın Orta Noktası .....	56
3.4.1.3. Maksimumun Ortası.....	56

	<b><u>Sayfa</u></b>
3.4.1.4. Maksimumun En Küçüğü .....	56
3.4.1.5. Maksimumun En Büyüğü .....	57
3.4.2. Sugeno Bulanık Çıkarım Sistemi.....	57
3.4.3. Tsukamoto Bulanık Çıkarım Sistemi .....	59
3.4. BULANIK MODELLEME .....	60
3.4.1. Yaklaşımlar ve Teknikler .....	61
BÖLÜM 4 .....	62
YAPAY SİNİR AĞLARI .....	62
4.1. GİRİŞ.....	62
4.2. TARİHİ GELİŞİM .....	63
4.3. BİYOLOJİK SİNİR SİSTEMİ .....	66
4.4. YSA ÖZELLİKLERİ .....	68
4.4.1. Eğitilebilirlik.....	68
4.4.2. Genelleme .....	69
4.4.3. Doğrusal Olmama.....	69
4.4.4. Sağlamlık ve Hata Toleransı.....	69
4.4.5. Tekbiçimlilik.....	69
4.4.6. Paralellik .....	70
4.5. YSA ESASLARI.....	70
4.5.1. İşlem Birimleri.....	70
4.5.1.1. Tek Girişli Nöron.....	71
4.5.1.2. Çok Girişli Nöron .....	72
4.5.2. Bağlantılar.....	73
4.5.3. Hesaplama.....	74
4.5.3.1. Transfer Fonksiyonları.....	75
4.5.4. Öğrenme .....	79
4.6. YSA SINIFLANDIRILMASI .....	81
4.6.1. Denetimli Öğrenme .....	82
4.6.1.1. İleri Beslemeli Ağlar.....	82
4.6.1.2. Yinelene Ağlar .....	86

	<b><u>Sayfa</u></b>
4.6.2. Yarı Denetimli Öğrenme .....	87
4.6.3. Denetimsiz Öğrenme .....	88
4.5.2. Melez Ağlar .....	90
4.5.3. Dinamik Ağlar .....	90
4.7. GERİ YAYILIM ALGORİTMASI.....	91
4.7.1. Algoritma.....	93
4.7.1.1. Performans Göstergesi .....	93
4.7.1.2. Zincir Kuralı.....	94
4.7.1.3. Duyarlılıkların Geri Yayılımı .....	96
4.7.2. Geri yayılımdaki Değişiklikler .....	99
BÖLÜM 5 .....	100
ARIMA .....	100
BÖLÜM 6 .....	105
YÖNTEM, UYGULAMA VE BULGULAR .....	105
BÖLÜM 7 .....	125
SONUÇLARIN DEĞERLENDİRİLMESİ VE ÖNERİLER.....	125
KAYNAKLAR .....	130
ÖZGEÇMİŞ .....	138

## ŞEKİLLER DİZİNİ

	<u>Sayfa</u>
Şekil 1.1. Dünya Çelik Talebi.....	2
Şekil 1.2. Çelik Üretim Süreci .....	4
Şekil 2.1. 2021 yılı Türkiye çelik haritası .....	17
Şekil 2.2. Bir yüksek fırınının genel görünümü.....	18
Şekil 2.3. Bir yüksek fırının düşey ve yardımcı sistemleri .....	19
Şekil 2.4. Bir yüksek fırın tesisinin hammadde, şarj, dökümhane, gaz işleme ve sıcak hava sistemlerini gösteren kesiti .....	20
Şekil 2.5. Gaz ve katıların sıcaklık dağılımının fırın yüksekliği boyunca ki ideal dağılımı ve üç sıcaklık bölgesinde oluşan kimyasal tepkimeler .....	32
Şekil 2.6. Yüksek fırınlarda bazı verimlilik artırma yöntemleri.....	35
Şekil 3.1. Klasik bir kümede ve bir bulanık kümede temsil edilen dil değerleri .....	39
Şekil 3.2. Üyelik fonksiyonun bazı özellikleri.....	41
Şekil 3.3. Sık kullanılan birleşim (VEYA) operatörleri .....	43
Şekil 3.4. Sık kullanılan kesişim (VE) operatörleri .....	44
Şekil 3.5. Üyelik fonksiyonları .....	49
Şekil 3.6. Bulanık çıkarım sistemi .....	53
Şekil 3.7. Bir örnek üzerinden Mamdani bulanık çıkarım sisteminde adımlar.....	54
Şekil 3.8. Sayısal çıktı elde etmek için kullanılan farklı berraklaştırma yöntemleri .	55
Şekil 3.9. Sugeno bulanık modeli .....	58
Şekil 3.10. Tsukamoto bulanık modeli .....	59
Şekil 4.1. Bir sinir hücresinin yapısı ve modeli .....	67
Şekil 4.2. Tek girişli nöron .....	71
Şekil 4.3. Çok girişli nöron .....	72
Şekil 4.4 Yapay sinir ağı topolojileri .....	73
Şekil 4.5. Belirleyici yerel transfer fonksiyonları: (a) doğrusal; (b) eşik; (c) sigmoidal.....	76
Şekil 4.6. Diğer transfer fonksiyonları.....	77
Şekil 4.7. Belirleyici olmayan transfer fonksiyonları .....	78
Şekil 4.8. Tek katmanlı ağ .....	82

	<b><u>Sayfa</u></b>
Şekil 4.9. Çok katmanlı ağlara örnek olarak üç katmanlı bir ağ.....	84
Şekil 4.10. Katmanlı yinelenen ağlar. (a) Jordan ağı; (b) Elman ağı.....	86
Şekil 5.1. Box-Jenkins metodolojisinin gösterimi .....	101
Şekil 6.1. Seri-paralel (sp) veya paralel (p) tanımlama yöntemleri .....	110
Şekil 6.2. Hava akışı ham verisi (seri 1) ve 6.2. eşitliğinin uygulanmış hali (seri 2) .....	112
Şekil 6.3. Eğitilen ağ yapılarının sahip oldukları nöron sayılarına göre MSE'leri..	118
Şekil 6.4. Gerçek ve tahmin edilen pik maden sıcaklık değerleri.....	119
Şekil 6.5. Gerçek ve tahmin edilen pik maden sıcaklık değerleri arasındaki hata...	120
Şekil 6.6. Gerçek ve tahmin edilen pik maden sıcaklık değerleri arasındaki hata (Jimenez)[26] .....	120
Şekil 6.7. Sıcaklık ortalamalarının karşılaştırma grafiği .....	122
Şekil 6.8. Bulanık mantık modeli .....	123
Şekil 6.9. Öneri matrisi .....	123
Şekil 6.10. Sıcaklık durumunda bağlı öneri çıktıları .....	124

## ÇİZELGELER DİZİNİ

	<b><u>Sayfa</u></b>
Çizelge 1.1. Dekarbonizasyon Stratejileri.....	6
Çizelge 2.1. Pik Analizi .....	22
Çizelge 2.2. Curuf Analizi .....	23
Çizelge 2.3. Yüksek Fırın Gazı Analizi .....	24
Çizelge 6.1. Model Giriş Parametreleri .....	113
Çizelge 6.2. Önemli model giriş parametreleri ve veri çalışma örnekleri .....	114
Çizelge 6.3. NARX YSA Modeli Çıktıları .....	120
Çizelge 6.4. Model Çıktılarının Değerlendirilmesi.....	121



## SİMGELER VE KISALTMALAR DİZİNİ

### SİMGELER

$\forall$	: Her
$\wedge$	: Kesişim
$\vee$	: Birleşim
$\alpha$	: Sinirsel ağlarda öğrenme katsayısı
$\mu$	: Bulanık mantıkta üyelik fonksiyonu
$\eta_{CO}$	: 900 °C derecedeki CO verimlilik faktörü
°C	: Celcius
$\infty$	: Sonsuz
$a$	: Nöron çıkış
$\mathbf{a}$	: Nöron çıkışları matrisi
$Al_2O_3$	: Alüminyum Oksit
$b$	: Bias
$\mathbf{b}$	: Bias matrisi
$C$	: Karbon
$CaC_2$	: Karpit
cal	: Kalori
$CaO$	: Kalsiyum oksit
$CaCO_3$	: Kalsiyum karbonat
$CO$	: Karbon monoksit
$CO_2$	: Karbon dioksit
$e$	: Sinirsel ağdaki hata
$\mathbf{e}$	: Sinirsel ağdaki hata matrisi
$f$	: Transfer fonksiyonu
$FeO$	: Vüstit
$Fe_2O_3$	: Hematit

$Fe_3O_4$	: Magnetit
$H_2$	: Hidrojen
$H_2O$	: Su
$k$	: Yineleme sayısı
$K$	: Potasyum
$K_2O$	: Potasyum oksit
$MgCO_3$	: Magnezyum karbonat
$MgO$	: Magnezyum oksit
$Mn$	: Mangan
$n$	: Çok katmanlı ağlarda ara katman çıkışı
$N_2$	: Azot
$Na$	: Sodyum
$Na_2O$	: Sodyum oksit
$p$	: Nöron girişi
$\mathbf{p}$	: Nöron giriş matrisi
$P$	: Fosfor
$P$	: Paskal
$R$	: Bağlantı katsayısı
$s$	: Sinirsel ağlarda bir katmandaki nöron duyarlılığı
$\mathbf{s}$	: Sinirsel ağlarda bir katmandaki nöron duyarlılıklarının matrisi
$S$	: Kükürt
$Si$	: Silisyum
$SiO_2$	: Silisyum oksit
$t$	: Sinirsel ağlarda hedef çıkış değeri
$\mathbf{t}$	: Sinirsel ağlarda hedef çıkış değerleri matrisi
$w$	: Sinirsel ağlarda bağlantının ağırlığı
$\mathbf{W}$	: Sinirsel ağlarda bağlantıların ağırlık matrisi
$x_{\max}$	: En yüksek değerli dizi elemanı
$x_{\min}$	: En düşük değerli dizi elemanı
$x_i$	: Giriş nöronları dizisi
$x_i^{\text{scaled}}$	: Normalize edilmiş değerler dizisi

$\varphi_p$  : Otoregresif parametre terimleri dizisi  
 $\theta_q$  : Hareketli ortalama operatörü parametre terimleri deęerleri

## KISALTMALAR

ADALINE : Adaptive Linear Neuron  
ANN : Artificial Neural Network  
AR : Otoregresif  
ARIMA : Otoregresif entegre kayan ortalama  
ARMA : Otoregresif kayan ortalama  
ART : Adaptif rezonans teorisi  
ARX : Otoregresif ekzojen modeli  
ASIC : Application Specific Integrated Circuit  
ASO : Automatic Structure Optimization  
AT&T : American Telephone & Telegraph Company  
B2 : İekli curuf bazitesi  
B4 : Dörtlü curuf bazitesi  
BOA : Bisector of Area  
SKICAT : Sky Image Cataloging and Analysis Tool  
SOFM : Self-Organizing Feature Maps  
SNNS : Stuttgart Neural Network Simulator  
SOM : Smallest Of Maximum  
SQL : Structured Query Language  
TDNN : Time Delay Neural Network  
TSK : Takagi-Sugeno-Kang  
USD : Amerikan Doları  
VLBP : Variable Learning Rate Back Propagation  
YSA : Yapay Sinir Ağları  
yy : Yüzyıl  
COA : Centroid (Center) of Area  
DARPA : Defense Advanced Research Projects Agency  
EDA : Exploratory data analysis

Erdemir	: Eređli Demir ve elik Fabrikaları
IBM	: International Business Machines Corporation
IEEE	: Institute of Electrical and Electronics Engineers
İsdemir	: İskenderun Demir ve elik Fabrikaları
Kardemir	: Karabük Demir ve elik Fabrikaları
kcal	: Kilo kalori
kg	: Kilogram
lim	: Limit
LOM	: Largest Of Maximum
LMBP	: Levenberg-Marquardt Back Propagation
LMS	: Least mean square
LVQ	: Learning Vector Quantizers
m	: Metre
MA	: Kayan ortalama
max	: Maksimum
min	: Minimum
MOM	: Mean Of Maximum
MSE	: Mean Squared Error
NARMAX	: Nonlinear Auto Regressive Moving Average with Exogenous Input
NARX	: Nonlinear Auto Regressive with Exogenous Input
NBJ	: Nonlinear Box-Jenkins
NFIR	: Nonlinear Finite Impulse Response
NOE	: Nonlinear Output Error
nftool	: Neural fitting toolbox
nntool	: Neural network toolbox
QBIC	: Query by Image Content
Q1	: Birinci eyrek
Q3	: Üüncü eyrek
IQR	: eyrekler Arası Aralık
RBF	: Radial Basis Function

## BÖLÜM 1

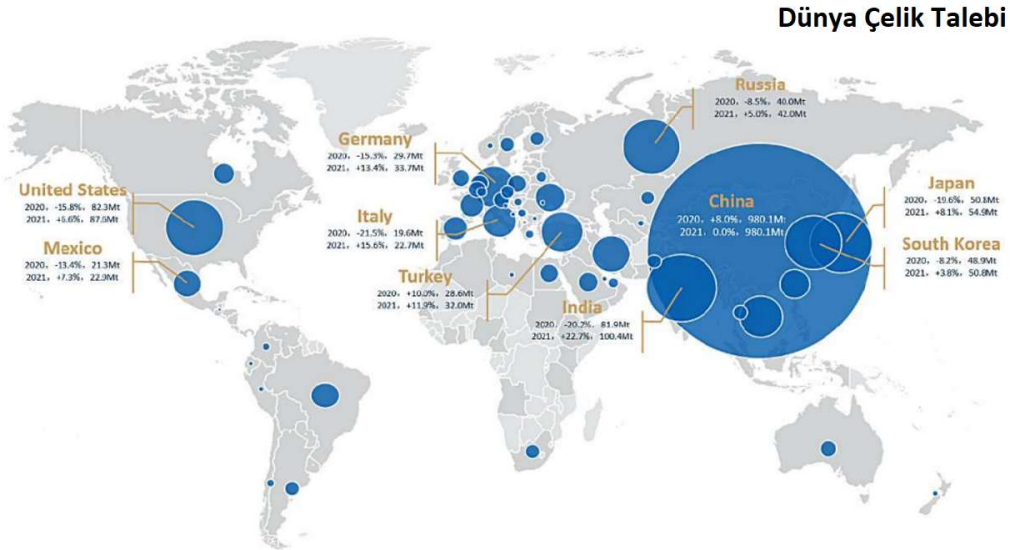
### GİRİŞ

Günümüzde ülkelerin çelik tüketim oranının yüksekliği bir kalkınmışlık göstergesidir. Çelik, demir elementinin ana birleşen olduğu, kalitesine göre içeriğinde %0,02 ile %1,7 arasında değişen oranda karbon olan bir metal alaşımıdır. Karbon, alaşımı sertleştirmeye ve demir atomlarının çeliğin yapısında kaymasını durdurmaya hizmet eder. Çelik, alaşımın karbon içeriğini değiştirerek sertliğini, esnekliğini ve çekme mukavemetini değiştirebilir. Bir demir-karbon alaşımının çelik olarak kabul edilebilmesi için, tipik olarak %2,1'den fazla karbon içermemesi gerekir [1].

Hem Türkiye hem de dünya için önemli olan demir-çelik sektörü, uluslararası ekonomide önemli bir rol oynamaktadır. Antik çağlardan beri birçok endüstrinin büyümesinde ve toplumun gelişmesinde önemli rol oynayan demir-çelik endüstrisi, diğer alanlarda da öncülük etmiş ve halen devam etmektedir. Üretilen malların çeşitliliği göz önüne alındığında, demir-çelik endüstrisinin hem geleneksel hem de teknik endüstrilerde giderek daha önemli hale geldiği açıktır. Sanayi devrimi ve teknolojiadaki önemli gelişmeler, demir-çelik üretimindeki hızlı gelişmelerin bir sonucu olarak ortaya çıkmıştır. [8].

Çelik talebi dünya çapında her gün artmaktadır. Şekil 1.1, 2021'deki küresel çeliğe olan talebi göstermektedir. Üretim açısından, Brüksel'de bulunan Dünya Çelik Birliği (Worldsteel), küresel ham çelik üretiminin önceki yıla göre %3,7 artarak 1 milyar 950.5 milyon tona ulaştığını tahminlemiştir. 2021'de Çin'in üretimi bir önceki yıla göre %3 azalarak 1 milyar 32,8 milyon tona gerilerken, Asya'nın üretimi sadece yüzde 0,6 artarak 1 milyar 382 milyon tona ulaşmıştır. Ekonomisi Kovid-19 salgınından kurtulurken, dünyanın önde gelen çelik üreticilerinden Hindistan, söz konusu dönemde üretimde %17,8 artışla 118,1 milyon tona ulaşmıştır. Güney Kore'nin üretimi %5,2 artışla 70,6 milyon tona yükselirken, Japonya'nın üretimi %14,9 artışla 96.3 milyon

tona yükselmiştir. AB'de üretilen ham çelik miktarı önceki yıla göre %15,4 artarak 152,6 milyon tona ulaşmıştır. Almanya'nın üretimi AB ülkeleri arasında %12,3 artarak 40,1 milyon tona, İtalya'nın üretimi ise %19,7 artarak 24,4 milyon tona ulaşmıştır. Fransa'nın üretimi ise %20,3 artışla 13,9 milyon tona yükselmiştir. 2021, ABD'de ham çelik üretiminde %18,3 artışla 86 milyon tona ulaşmıştır. Bu dönemde Rusya'da üretilen ham çelik miktarı 2020 yılına göre yüzde 6,1 artarak 76 milyon tona ulaşırken, Ukrayna'da üretilen ham çelik miktarı yüzde 3,6 artarak 21,4 milyon tona ulaşmıştır. Tahminlere göre, İran'ın söz konusu malların üretimi yüzde 1.8 düşüşle 28,5 milyon tona gerilemiştir. Öte yandan, Türkiye'nin ham çelik üretimi 2021'de %12,7 artarak toplam 40,4 milyon tona ulaşmıştır. Türkiye, şimdiye kadarki en yüksek üretim seviyesine ulaşmasına rağmen, dünya ham çelik üretiminde yedinci sıradaki yerini korumuştur [2].



Şekil 1.1. Dünya çelik talebi[9].


Yüksek fırınlar, doğrudan madenlerden toplanan demir içeren hammaddeleri kok ve kireçtaşı ile eriten demir üreten tesislerdir (fırınlar). Bir yüksek fırının yüksekliği, ne kadar demir üretebileceğine bağlı olarak 30 ila 90 metre arasında değişir. Dünya çeliğinin yaklaşık %60'ı yüksek fırınlarda ve çelik fabrikalarında, geri kalan %40'ı ise ertirme atıkları (elektrik ark ocağı) ile üretilmektedir. Yüksek fırın birincil hurda

kaynağı olduğundan, yüksek fırınlar çelik üretiminin yüzde 99'unu sağladığı değerlendirilebilir [3].

Şekil 1.2'de, demir ve çelik üretme süreci gösterilmektedir. Madenlerden elde edilen demir cevheri, kok fabrikasından çıkan kok, sinter fabrikasından elde edilen sinter ve demir kullanılarak yüksek fırınlarda pik demire dönüştürülür. Bu maden daha sonra tipik olarak torpidolarla çelik fabrikasına taşınır ve önce oksijen fırınında oksijenle işlenir. Malzeme daha sonra ikincil metalürjik işlemler için uygun tesislerde işlendikten sonra sürekli döküm tesislerinde yassı ve çubuk ürünlere dönüştürülür [4].

Çeliğin ham maddelerini üreten iki sektör -demir ve çelik- topluca "demir ve çelik endüstrisi" olarak anılsa da, daha önceleri ayrı isimlerle anılmaktaydılar [1].

Avrupa'da demir üretiminin tarihi MÖ 1700'lere kadar uzanmaktadır. Hititler'den Orta Çağ'ın sonuna kadar demir aynı şekilde üretilmiştir: demir cevheri eriyene kadar odun veya odun kömürü ile ısıtılır, bu noktada sıcak bir ortamda dövülerek herhangi bir maddeyi uzaklaştırmak için dövülür, ek elementler ve ortaya çıkan ham cevher, dövmelede kullanılırdı. 1150-1350 yılları arasında Avrupa'da ve MÖ birinci yüzyılda İskandinavya'da (günümüzde İsveç) ilk ortaya çıkışının ilk doğrulanmış hesapları 14. yüzyıla kadar uzanmaktadır. Modern demir üretiminde yüksek fırınların kullanımı, İngiltere'de ilk kullanıldıkları zamandan bu yana pek değişmemiştir [6]. Rönesans'tan çok önce çelik, çeşitli verimsiz teknikler kullanılarak yapılmış, ancak 17. yüzyılda daha başarılı üretim tekniklerinin keşfinden sonra kullanımı daha yaygın hale gelmiştir [8]. Yüksek fırın teknolojisi, 1709'da kömür yerine kok ikamesi ve 1828'de İskoçya'da sıcak havanın üflenmesiyle oluşturulmuştur. Endüstri rekabeti nedeniyle, bugünün 60000 tonluk haftalık üretim seviyelerine ulaşmış olan üretim, 18. yüzyıldaki 400 tonluk yıllık üretim seviyelerindeydi [7]. Çelik, 19. yüzyılın ortalarında Bessemer Modifier'ın geliştirilmesiyle düşük maliyetli, seri üretilen bir malzeme haline gelmiştir. İyileştirmeler, ilerleme adımı boyunca çelik üretim sürecine bazik oksijenin eklenmesini içerirken, metal kalitesini artırırken üretim maliyetlerini düşürmüştür [8].



Şekil 1.2. Çelik üretim süreci [5].

Günümüzde çelik, yıllık 1900 milyon tonluk üretimiyle dünyada en yaygın kullanılan yaygın malzemelerden biridir. Diğer malzemelerin yanı sıra yapılarda, altyapı oluşturmada, aletlerde, gemilerde, otomobillerde, makinelerde, aksesuarlarda ve silahlarda kullanılabilir. Birincil üretim bileşeni olarak hizmet etmektedir. Çeşitli standart organizasyonları, çağdaş çeliği çeşitli niteliklere göre sınıflandırır [8].

Günümüzde çelik, hurdanın (veya sünger demir veya sıcak briketlenmiş demir gibi hurda eşdeğeri malzemelerin) elektrik ark ocaklarında ergitilmesiyle veya entegre tesislerde (Kok tesisi - yüksek fırın - çelik tesisi (bazik oksijen ocağı) - haddehane demir cevheri ve kok kömürü ergitilerek) üretilmektedir. Buna ek olarak, eski SSCB ülkelerinin birçoğunda, bu tesisler hızla ortadan kalksa da, üretim için hala OH (openhearth) yöntemi gibi oldukça eski teknolojileri kullanmaktadır [8]. Entegre demir-çelik fabrikalarında pik üretimi için yüksek fırınlar, daha küçük tesislerde ise elektrik ark ocakları kullanılmaktadır.

Günümüzde insanoğlunun elindeki en faydalı araçlardan biri yüksek fırındır. Yüksek fırın, çelik üretiminin temelini oluşturur ve cevheri hızlı ve verimli bir şekilde demir



bazlı aralar iin ihtiya duyulan hammaddeye dnstrr. Bir ulusun ekonomisindeki kilit unsurlardan biri yksek fırındır [9].

Trkiye, savunma sektrnn elik ihtiyaını karřılamak iin 1928 yılında Kırkkale'de ilk elik retimine bařlamıřtır. Trkiye'nin ilk entegre demir-elik tesisi olan Karabk Demir elik Fabrikası (KARDEMİR), 1939 yılında kapılarını amıřtır. İkinci entegre fabrikası olan Ereli Demir elik Fabrikası (ERDEMİR), Trkiye'nin yassı elik ihtiyaını karřılamak zere 1965 yılında faaliyete bařlamıřtır. Trkiye'nin nc entegre tesisi olan İskenderun Demir elik Fabrikaları (İSDEMİR), uzun elik ve yarı mamul talebini karřılamak zere 1977 yılında kurulmuřtur [8].

İklim deęiřiklięi tehdidine verilen kresel tepki ile 190 lke 2015 yılında Paris Anlařması'nı kabul etti. Yine 2019'da Birleřmiř Milletler'in aıklamasına gre; Ana  emisyon kaynak lkelerinin (in, Hindistan ve Amerika Birleřik Devletleri) dahil olmadığı 60 lke - Birleřik Krallık ve Avrupa Birlięi dahil (Polonya hari) 2050 yılına kadar karbon ntrlę saęlamayı taahht etmiřtir. Ayrıca, bazı lkeler daha erken tarihler iin alıřma sz verdiler. Bu anlařmalar tm endstriyel sektrlerde karbonsuzlařtırmayı srdrme baskısında bymeye yol atı.

2018'de retilen her ton elik, ortalama 1,85-ton karbondioksit salınımına sebep oldu. Bu rakam kresel karbondioksit emisyonlarının yaklařık 8 %'ine denk gelmektedir. Sonu olarak, dnya ve zellikle Avrupa elik oyuncularını giderek artan bir řekilde karbonsuzlařtırma sorunuyla karřı karřıya kaldılar.

Bu durum Paris Anlařması'nın tesine geen; deęiřen mřteri gereksinimleri ve karbon dostu elik iin artan talep, karbon emisyonu dzenlemelerinin daha da sıkılařtırılması ve srdrlebilirlięe artan yatırımcı ve kamu ilgisi bařlıęındaki  nemli geliřme tarafından ynlendirilmiřtir. Deęerlendirildięinde; elik reticileri karbon ayak izlerini azaltmak iin teknolojik ve ekonomik olarak uygun yollarını arařtırmak, deęerlendirme ve karar vermek ihtiyaındadır [11].

Demir cevherinden koka ihtiya duymadan pik demir retimi iin COREX ve FINEX gibi teknolojilerin yanı sıra, doęal gazla alıřan fırınlarda demir cevheri ve peletleri

işledikten sonra doğrudan indirgenmiş demir oluşturabilen MIDREX gibi teknolojiler de bulunmaktadır [10].

Çizelge 1.1. Dekarbonizasyon stratejileri[11].

	CO2 indirgeme			Tam karbonsuzlaştırma		
	 Yüksek Fırın Verimliliği(BOF)	 Biyokütle indirgeyiciler	 Karbon tutma ve kullanımı	 Elektrik ark ocağı(EAO)	 DRI ve doğal gazlı EAO	 DRI ve hidrojenli EAO
<b>Strateji</b>	YF/BOF operasyonlarını optimize etmek için verimlilik iyileştirmelerinin	Alternatif indirgeyici veya yakıt olarak biyokütle kullanımı	Fosil yakıt ve emisyonları tutmak ve yeni ürünler üretilmesi	EAO'da daha fazla hurda eriterek ikincil akışların ve geri dönüşümün en üst düzeye çıkarılması	EAO'da DRI kullanımını arttırmak	DRI prosesinde kullanılan yakıtların yenilebilir enerji veya hidrojen ile değiştirilmesi
<b>Örnekler</b>	İyileştirilmiş BOF girdileri(DRI, hurda), YF'da yakıt enjeksiyonunun artırılması(hidrojen, PCI)	Teknik Süreç	CO2 emisyonundan Bioetanol üretimi	EAO- hurdayı eritmek için kullanılması	Doğal gaz kullanan EAO'da mevcut DRI kullanımı	Hidrojen ile işletilen MIDREX DRI prosesi Hidrojen ile işletilen HYL DRI prosesi
<b>Mevcut durum</b>	Rekabetçi maliyetle kolayca temin edilebilen teknoloji	Biyokütle bulunabilirliği kaynaklı olarak Güney Amerika ve Rusya'da mümkün	Endüstriyel ölçekte mevcut değil	Rekabetçi maliyetle kolayca temin edilebilen teknoloji	Temin edilebilen teknoloji	Yüksek maliyetle temin edilebilen teknoloji

## 1.1. ÇALIŞMANIN AMACI

Alternatif bulma çabalarına rağmen, bir ülkenin ekonomik ilerlemesinin kabul edilen bir ölçüsü, modern dünyanın en önemli sanayi tesislerinden biri olan demir çelik fabrikalarında üretilen çelik miktarı, nüfusuna göre dir. Endüstriyel tesisler, kendi ayakları üzerinde durabilen ve sürekli kâr sağlayan güçlü kurumlara dönüşmek için mümkün olan en düşük maliyet, en yüksek hacim ve verimlilikle üretim yapmak için küresel ölçekte rekabet etmektedir.

Endüstriyel tesisler için önemli maliyet kalemleri olarak ortaya çıkan unsurlar arasında çevresel etkilerin en aza indirilmesi, iş güvenliği ve çalışma koşullarının sürekli iyileştirilmesi, toplam kalite yönetimi gibi hem ulusal hem de uluslararası standartlar ile insani ve vicdani değerler açısından empoze edilen hedefler yer almaktadır. Bu nedenle, bu tesislerde kullanılan tüm sıvı, katı veya gaz giriş yakıtlarının yanı sıra su, buhar ve diğer kimyasalların sıcaklık, basınç, akış ve seviye bilgilerini düzenlemek için çağdaş sensörler ve gelişmiş otomasyon sistemlerinin kullanılması, bu tesislerde önemli bir etkiye sahiptir. Bu süreç üretim verimliliği ve optimizasyonunu da tetiklemektedir.

Entegre demir-çelik fabrikalarında, yüksek fırınlar (YF) büyük, silindirik, çelik sacların birbirine kaynaklanmasıyla inşa edilmiş, çok yüksek sıcaklıklardaki reaksiyonlara dayanıklı refrakter tuğlalarla yalıtılmış, boru hatlarıyla birbirine bağlanmış ve nispeten yüksek endüstriyel binalardır. Pik demir, çelik yapmak için kullanılan hammaddedir. Fırın prosesinin arkasındaki ana fikir, kok ve demir hammaddelerinin üst kısımdan düzenli aralıklarla askıda tutulup doldurulması, basınçlı havanın sobalarda ısıtılması ve ve bu ısıtılmış havanın sobalardan tüyer bölgesi ile fırına üflenmesiyle gerçekleşen reaksiyonlarla sıcak pik demir üretmektir.

İşletme maliyetlerinin, hammadde ve yakıt tüketiminin düşürülmesi, fırının istikrarlı, verimli ve dengeli çalıştırılabilmesi için bazı proses parametrelerinin kontrol altında tutulması gerekmektedir. Bununla birlikte, birçok parametredeki hızlı değişimlerden olumsuz etkilenen bu doğrusal olmayan süreci matematiksel olarak modellemek imkansız değilse de oldukça zordur.

Bu çalışmanın ilk bölümünde, fırın içi ısı dağılımı ve çalışma performansı hakkında bilgi vermesi açısından kritik bir öneme sahip olan pik demir değerinin kestirimi ve bu yolla kontrolü konusunda farklı modelleme denemelerinin yapılması hedeflenmektedir. Eğer pik demir sıcaklığını etkileyen faktörler düzgün olarak seçilebilirse, geçmişe dönük değerlerin temini ve kullanımı ile gerçekleştirilecek bir modelleme çalışması, bu sıcaklık değişimlerinin kestirimini mümkün kılacaktır. Bu nedenle yeni bir veri madenciliği, veri tasnif ve sınıflandırma metodolojisi kullanarak yüksek fırınların dinamik olarak modellenmesi amacıyla çeşitli kurallar dizini oluşturulacaktır. Modelin çıktıları, fırının çalışma ve kontrol yönüne gösterge olacak, ayrıca sıcaklık değişikliklerinin ne kadar hızlı değerlendirileceğine önceden karar verdikleri için fırın işletme grubu için bir kılavuz görevi göreceklerdir.

Yüksek fırınların birincil ürünü olan pik demirin verimini iyileştirmek ve sıcak maden kalite koşullarını sağlamak için çelik üretiminde çok önemli bir gereklilik; üst düzey kontrol ve tahmin yaklaşımlarıdır. Üretilen sıcak metaldeki silikon konsantrasyonundaki değişim kontrol edilerek üretilen pik demirin kalitesinin iyileştirilmesinde temel adım sağlanır. Fırının ısı seviyelerinin kontrolü ve düzenlenmesi, bu dengenin korunması ile birinci dereceden ilişkilidir. Fırının sıcaklığı

yüksekse, sıcak madenin silikon içeriği yükselir; tersine, fırının sıcaklığı düşükse, pik demirin silikon içeriği bu bilgiyle tam orantılı olarak düşer. Bununla birlikte, fırının çalışmasına ışık tutan diğer önemli faktörler arasında pik demirdeki karbon miktarı ve yüksek fırın cürufunun bazitesi yer alır. Pik demir sıcaklık parametresinin önemi ve düzenlenmesinin fırın sürecine katkısı, fırın ısı dengesinin fırın çıktısı üzerinde doğrudan bir etkisi olduğu düşünüldüğünde ortaya çıkmaktadır.

Fırın işletmesi sırasında oluşan anormallikler, duvar oluşumuna karşı fırına giren sıcak hava miktarını azaltmak veya tam tersi şekilde, cevher/kok oranını azaltarak geçirgenlik değerini artırmak, oksijen zenginleştirme oranını azaltmak veya nemi yükselterek geçirgenlik değerini artırmak gibi örneklenebilecek müdahaleler ile düzenlenmeye çalışılır. Ancak, bu anormallikler veya olası sorunlar matematiksel modelleme ve simülasyon çalışmaları kullanılarak tahmin edilebiliyorsa, sürecin daha sorunsuz ilerlemesine yardımcı olacak düzeltici önlemler almak yine de mümkündür. Örneğin, ilave kok enjeksiyonunun fırın sıcaklığı üzerindeki etkisini gözlemlemek minimum 6 ila 8 saat sürmektedir.

Endüstriyel tesislerin günlük olarak nasıl çalıştığının anlaşılması için, önemli parametreleri hesaba katarak fiziksel süreçleri tanımlayan matematiksel modeller tarafından büyük ölçüde geliştirilmiştir. Ancak karmaşık bir yapıya sahip olan bu fiziksel modellerin kullanılması, çok sayıda süreç değişkeni ve uzun iterasyonlar gerektirdiğinden büyük ölçekli işletmelerde çok zaman almaktadır [12]. Bu nedenle, bilgisayar tabanlı simülasyon, tahmin ve tahmin çalışmaları, son zamanlarda yukarıda belirtilen matematiksel modellere uygulanabilir bir alternatif haline gelmiştir.

Özellikle, AI modellerini kullanan deneysel araştırmalar, beklenen matematiksel tekniklerin ve sayısal çözümlerin performansını karşılaştırarak ve değerlendirerek literatüre katkıda bulunur. Sinir ağları, daha karmaşık ilişkileri bulma ve eşleştirme kapasiteleri nedeniyle öne çıkarken, geleneksel teknikler tipik olarak doğrusal girdi-çıkı eşleştirmede başarılı sonuçlar üretir. Bununla birlikte, sinir ağlarının kullanımı model oluşturmayı hızlandırır ve çalışma koşullarındaki değişikliklere yanıt olarak onları yeniden kalibre etmeyi kolaylaştırdığı için özellikle faydalıdır.

Yapay Sinir Ağları (YSA) olarak bilinen önemli veri madenciliği tekniği, kısmen zamanla değişen, karmaşık ve doğrusal olmayan eşleştirme uygulamalarındaki yüksek performansı nedeniyle bu çalışma için seçilmiştir. Bu yöntemin tipik olarak geleneksel regresyona dayalı modellerden daha iyi sonuçlar ürettiği de iyi bilinmektedir [13]. Modellemenin regresyon performanslarını değerlendirmek ve sonuçları karşılaştırmak için tez çalışmasında sunulan diğer istatistiksel modellerden biri olan Otoregresif Entegre Hareketli Ortalama (ARIMA) algoritması da tercih edilmiştir.

Söz konusu modeller arasındaki karşılaştırmaya ek olarak, sinir ağı modelinin eğitim algoritmasının değiştirilmesi suretiyle, öğrenme işleminin model performansına olan etkileri de araştırılmıştır. Model sonuçlarının karşılaştırılabilmesi için, literatürde kabul gören performans kriterleri olan Belirlilik Katsayısı ( $R^2$ ), Ortalama Mutlak Yüzde Hata (MAPE) ve Karekök Ortalama Hatası (RMSE) ifadeleri kullanılmıştır.

Birbirinden bağımsız olarak yürütülen iki ayrı tahminleme modeli araştırma çıktılarından, kullanılan girdi değişkenlerinin çıktı değerini karşılamada yüksek bir başarı oranına sahip olduğu açıktır. Model çıktılarının birbirleriyle karşılaştırılması için seçilen kriterler olan belirleme katsayısı ve ortalama karekök hata değerleri dikkate alındığında, modellerin genellikle hesaplamalar ve analizler sonucunda yüksek bir memnuniyet oranı sağladığı kaydedilmiştir. Her iki araştırma da Levenberg-Marquardt eğitim tekniğini kullanan yapay sinir ağı modelinin en iyi simülasyon performansını ürettiğini göstermiştir. Bu deneysel çalışmanın bir başka sonucu da YSA modelinin ARIMA modelinden daha iyi tahminler gerçekleştirdiğinin kanıtıdır.

Çalışmanın ikinci aşamasında bir önceki modelden elde edilen tahminleme değeri baz alınarak bir bulanık mantık modeli oluşturulmuştur. En önemli değişkenlerden biri olan sıcak metal sıcaklığı fırın ısıtma veya soğutma değişimlerinin modellenmesinde uzman modelci olarak bulanık öneri modeli oluşturulmuştur. Son tahmin edilen sıcak metal sıcaklığı ve tahmin edilen son 5 sıcak metal sıcaklığının ortalaması girdi değişkenleri olarak seçilmiştir. Ve bu sayede geçmiş sıcaklık verilerine göre son sıcaklık ve çalışma yönü bulunacak ve hareket boyutlandırmasına göre yapılacak işlem belirlenmeye çalışılmıştır.

## 1.2. ÇALIŞMANIN LİTERATÜRDEKİ YERİ

Çelik üretmek için çok sayıda tesiste çok sayıda süreç kullanılmaktadır. Bu süreçlerden ilki, hammadde olarak kullanılan kok ve sinter imalatı göz ardı edilirse, çelik işlerinde hammadde olarak kullanılan pik demir üretimidir. Modern teknolojiler geliştiriliyor olsa da, madenlerden pik demir üretmenin en verimli ve hızlı yöntemi hala yüksek fırınlardır. Tez içeriğinde, yüksek fırının genel tasarımını ve işlevselliğini kapsayacak bir bölüm mevcuttur.

Yüksek fırından elde edilen pik demirin üretiminin artması, kalitesinin sonraki tesisler için önemi ve kontrol edilebilmesi sonucu, fırında belirli proseslerin uygulanması ihtiyacı gelişmiştir. Üretilen pik demirdeki silikon içeriği değişkenliğini ayarlamak, pik demirin kalitesini yükseltmenin anahtarıdır. Fırının ısı ayarları bunu düzenleyen süreçtir. Pik demirin yapısındaki silikon miktarı yüksek fırın sıcaklıklarında artarken düşük fırın sıcaklıklarında azalır. Bu nedenle, birçok çalışma, fırının durumunu ve [r]n olan pik demir içindeki silikon konsantrasyonunu belirlemek için bir gösterge olarak pik demirin sıcaklığını kullanmıştır [23, 24]. İşletme mühendislerine fırının çalışması hakkında bilgi veren ek faktörler arasında pik demir bileşimindeki karbon miktarı ve bir yan ürün olan yüksek fırın cürufunun bazitesi yer alır.

Bu kontrol teknikleri tipik olarak uzman sistemleri içerir. Fırında meydana gelen kayma ve askı gibi dengesizliklerin tahmininde yardımcı bir araç olarak kullanılmalarının yanı sıra daha çok fırın iç sıcaklığını ve pik demirin sıcaklığını kontrol etmek için kullanılırlar.

Pik sıcaklık, yüksek fırının günlük çalışması sırasında operatörlerin sürekli olarak izlediği önemli değişkenlerden biridir. Literatürde, mevcut fırın verilerini ve özellikle bir yapay sinir ağı modelini kullananlar da dahil olmak üzere, bu hedef parametrenin modellenmesi ve tahmin edilmesi hakkında birkaç araştırma vardır, ancak bu çalışmaların gerçek çalışma koşullarını dikkate alması nadirdir. Ayrıca kesim sonrası bu kestirilmiş değeri kullanmak ve operatörlere tavsiyede bulunmak için herhangi bir araştırma yapılmamıştır. Yayınlanmış çalışmalara bakıldığında, araştırmacıların çoğu

zaman pik demir sıcaklık deęerini anlamak ve tahmin etmek için matematiksel ve sayısal modeller kullandığını görebiliriz.

Örneęin, hidrokarbon yakıtların kullanıldığı yanma ortamında alev sıcaklığı simüle edilerek alev sıcaklığı deęerinin tahmin edildięi bir çalışmada yakıt dağılımı, reaksiyon basıncı ve sıcaklığı, hava-yakıt oranı ve yakıt buharlaşma indeksi gibi girdi parametreleri seçilmiştir [14]. Çeşitli çalışma ayarları için denemelerin yapıldığı bu araştırma ile en yüksek sıcaklık deęerinin doğru bir şekilde tahmin edilebileceęi belirlenmiştir. Başka bir çalışma, çeşitli yakıt, oksijen ve nitrojen konsantrasyonları için yanma hattını ve alev bölgesini tahmin edilmiştir. Çalışmada, literatüre pik demir sıcaklık deęerinin hesaplanmasına yönelik bir yöntem sunulmakta ve sonuçlar geçmiş verilerle karşılaştırıldığında modelin başarılı bir şekilde hesaplama yaptığı görülmektedir [15].

Tek bir yanma lansından iki gazın enjeksiyonu, kok gazı miktarının yanma üzerindeki etkisi, tek veya çift bir lans kullanmanın etkileri ve fırın enjeksiyonu için lans açılarının performansı, esas olarak etkileri araştıran 2005 yılındaki çalışmada tartışılmıştır. Kok ve yüksek fırın gazları için farklı yakıt lansı açılarının yanma üzerine etkileri de tartışılmıştır [16].

Kok gazı, yüksek fırın gazından daha verimli yandığı için tüyere bölgesinde daha yüksek bir alev sıcaklığı oluştuęu ortaya konmuştur. Brezilya'da kurulan CSN III yüksek fırını için yapılan bir çalışmada fırının kimyasal ve termal özelliklerini modellemek için hibrit bir yapay sinir ağı kullanılmıştır [17]. Bu araştırma ayrıca malzeme sistemi, şarj sistemi ve şişirme sistemindeki dalgalanmaları da dikkate alarak daha etkin operasyon, daha kaliteli ürün ve hedef maliyetlere ulaşma hedeflerine yaklaşıldığı kaydedilmiştir.

Matlab'da oluşturulan ve alev sıcaklığını belirleyen FTC adlı bir model, gaz halindeki yakıtlardan gelen ısı enerjisini ve alev sıcaklığını etkileyen faktörleri tartışan başka bir makalede anlatılmaktadır [18]. Program sonuçlarından oksijen zenginleştirmenin alev sıcaklığını biraz yükselttięi açıkça görülmüştür. FTC modelinin karbon dioksit, buhar, oksijen, azot, karbon monoksit ve azot oksit konsantrasyonlarını hesaplayabildięi de

gösterilmiştir. Ek olarak, FTC tarafından elde edilen proses parametrelerini modellemek için yapay sinir ağı modeli kullanılmış ve alev sıcaklığı değerinin yüzde 1,3'lük güvenilir bir doğrulukla tahmin edilebileceği gösterilmiştir.

2010 yılında yapılan başka bir çalışmada Masmod olarak bilinen bir yüksek fırın optimizasyon modeli uygulaması oluşturulmuştur [19]. Yazılım, soba sistemi, yanma düzenleri, tepe gazı emisyonları ve CO2 emisyonları dahil olmak üzere bir yüksek fırının temel işlevlerini simüle etmiştir. Alev sıcaklığı için çalışmanın hesaplamaları tüyere bölgesi civarında yanma sonrası entalpi, kimyasal reaksiyonların ürünleri, yanma ile üretilen ısı enerjisi, özellikle kok malzemesininki ve fırın gövdesinin ısı kapasitesi dikkate alınmıştır. Hesaplama sonuçları referans değerlerle karşılaştırıldığında, modelin yinelemeli olarak çözülüp optimize edildikten sonra sağlanan denklem için başarılı bir çözüm ürettiği gösterilebilir.

Yüksek fırındaki tepe kok şarj miktarının alev sıcaklığı üzerindeki etkisi, yüksek fırınların verimliliğinin temel teknolojik parametrelerin hesaplanmasıyla gösterildiği bir çalışmada da değerlendirilmiştir [20]. Ton başına kok miktarının yüksek olduğu bir yüksek fırında yapılan çalışmada alev sıcaklığını optimize etmek için yapılan hesaplamada tuyre alanından fırına yüklenecek demir tozu oranının %10 arttırılması tavsiye edilmektedir. pik demirde 250 kg/t, kömür miktarı ise 367 kg/t civarındadır.

Fırınlarda meydana gelen muazzam ısı ve kütle transferleri, birçok kütle hareketleri, yanma süreçleri ve katı-katı, katı-sıvı ve gaz-katı reaksiyonları nedeniyle çok zorlu bir problemler ortaya çıkmaktadır. Bileşenler arasındaki etkileşimler nedeniyle, yüksek fırın süreci çok değişkenli girdi parametrelerine göre sürekli değişir ve koşullar aynı olsa bile farklı sonuçlar üretir. Sonuç olarak, fırınları matematiksel olarak simüle etmek ve modellemek zordur. Ancak alev sıcaklığı tahmini ve yönetimine ek olarak literatürde çok önemli bir verimlilik parametresi olan pik maden sıcaklığının yapay sinir ağları ile hesaplanması üzerine bazı çalışmalar yapılmıştır.

Örneğin, bir Hint yüksek fırınında oluşturulan pik demirin sıcaklığı gibi bazı kalite parametrelerini modellemek için ileri beslemeli bir sinir ağı kullanılmıştır [21]. Bu çalışmada, maden sıcaklığı üzerinde en büyük etkiye sahip olan parametre sayısı 24'ten



15'e düşürülmüş ve geri yayılım öğrenmeli bu tek gizli katman ağının günlük en yüksek maden sıcaklığını tahmin edebileceği gösterilmiştir.

Pik demirin silikon konsantrasyonunu tahmin etmek için farklı bir araştırmada çok katmanlı ileri beslemeli sinir ağları kullanılmıştır [22]. İleri beslemeli ağlar, bu makalenin Levenberg-Marquardt öğrenme yöntemi uygulamasında doğrusal zaman serilerinden daha iyi performans göstermiştir. Literatürde son zamanlarda yüksek fırın pik demir sıcaklığı ve silikon konsantrasyonu hakkında çok sayıda modelleme ve tahmin araştırması görülmüştür.

Finlandiya'daki Koverhar yüksek fırınındaki fırının sıcaklık durumunu tahmin etmek için Nikus ve arkadaşları sinir ağları kullanmışlardır [25]. Dakikalık toplanan veriler kullanılarak önceden bir ile yirmi dakika arasında değişen bir tahmin yapılmıştır. Yedi girişli ve beş gizli nöronlu ağ düzeni, tek bir gizli katman ağı için seçilmiş ve en iyi sonuçları vermiştir. Tahmin edilen değerler de gecikmeli ve ek giriş olarak ağ girişine gönderilmiştir [43].

İsveç'te yapılan bir çalışmada, yüksek fırınların üretimini simüle etmek için sinir ağları kullanılmıştır. Bu çalışma, pik demirin silikon konsantrasyonunu iki saat önceden tahmin etmek için kendi kendini organize eden ağlar ve çok katmanlı algılayıcıların bir kombinasyonunu kullanır. Takip eden birkaç saat içinde silikon içeriğini tahmin etmek için, yüksek fırında sık sık değişen çalışma koşulları nedeniyle ayrı bir statik ağ gerekli olacaktır. Sonuç olarak, kendi kendini düzenleyen ağlar kullanılarak yapılan fırının her bir operasyonel durumu için farklı çok katmanlı algılayıcılar eğitilmiştir. fırının çalışma koşulları. Sıcak madenin pik demir sıcaklığı ve silikon içeriğinin ilişkili olduğu göz önüne alındığında, bu çalışmanın silikon içeriğini tahmin etmek için yapay sinir ağlarının kullanılmasının başarılı sonuçları, bu ağların pik demir sıcaklığını tahmin etmek için de kullanılabileceğini göstermektedir. [43, 44].

Beş farklı yüksek fırın, Birleşik Krallık'ta bir demir ve çelik üreticisi olan British Steel'den araştırmacılar tarafından yönetilmek için sinir ağları denendi. Birkaç fırına uygulanan bu yapay sinir ağları, özellikle hammadde dağıtımını düzenlemek için bir araç olarak kullanıldı. Pik demirin üretim kalitesini tahmin etmek için sinir ağı

modelleri de oluşturuldu. Önemli ölçüde, silikon konsantrasyonu ve pik demir sıcaklığının hesaplanması için modeller oluşturulmuştur ve bunlar yakından bağlantılıdır. Modeller geliştirilmeden önce ilk olarak diferansiyel girdilerin zamana bağımlılığının ayrı bir istatistiksel incelemesi yapılmıştır [43, 45].

Yüksek fırında üretilen pik demirin silikon konsantrasyonunu tahmin etmek için çok katmanlı ileri beslemeli sinir ağlarını kullanarak Bulsari ve arkadaşları son derece iyi sonuçlar elde etmişlerdir. Bir ve iki gizli katmanlı ileri beslemeli ağların ağırlıklarını eğitmek ve güncellemek için geleneksel geri yayılım öğrenme algoritmasının doğrusal olmayan bir varyasyonu kullanmışlardır. Burada kullanılan Levenberg-Marquardt eğitim yöntemidir [46]. Bu çalışma, ileri beslemeli yapay sinir ağlarının geleneksel doğrusal zaman serileri kullanılarak yapılan tahminden daha iyi performans gösterdiğini göstermiştir [43].

Sonda sıcaklıklarını sınıflandırmak için Bulsari ve Saen sinir ağlarını yeniden kullanmışlardır. Yüksek fırın işletmecileri, fırın gövdesi içindeki gaz dağılımı hakkında bilgiye ihtiyaç duyar. Bu bilgi, ergime bölgesinin durumu ile fırına gönderilen malzemenin akışı ve dağılımı ile ilgili verilen kararlarda kullanılır. Geleneksel olarak operatörler bu tür kararları, fırın içerisine yatay biçimde yerleştirilmiş sondalardan elde edilen sıcaklık ölçümlerine ve geçmiş tecrübelerine dayanarak vermektedir. Fırın gaz dağılımını sınıflandırmak için Bulsari ve Saxen, bu ölçümleri kullanan bir uzman sistem kurmuşlardır. Bu sınıflandırma için çıktı ve gizli katmanda sigmoid transfer fonksiyonunu kullanan ileri beslemeli ağlar kullanılır. En iyi performansı gösteren tek ağ yapısını kullanarak elde etmişlerdir. Ayrıca Bulsary ve Saxen, çok az gizli nöronlu ağların gerekli ilişkileri doğru olarak yakalayamazken büyük ağların ise aşırı öğrenme (overtraining-overfitting) sorunu olduğunu bulmuşlardır. Bu sistem yüksek fırında uygulanmış ve sınıflandırılan bilginin anlamlı bir şekilde operatörlere gösterilmesi için bir ara yüz tasarlanmıştır [43, 47]

Zuo ve ark. yüksek fırın bozulmalarını tahmin etmek için ileri beslemeli sinir ağlarını kullandı. Farklı ağlar, çeşitli fırın pik gaz dağıtım profillerini tanımak, çeşitli ısı akışı dağılımlarını belirlemek ve kaymaları veya anormallikleri tahmin etmek için eğitilmiştir. Söz konusu sınıflandırma ve tahmin fonksiyonlarını gerçekleştiren sinir

ağı tabanlı bir kontrol sistemi makalede sunulmaktadır. Fırında tehlikeli bir senaryo oluştuğunda operatöre alarm verir. Kayma tahminleri için ileri beslemeli ağlar kullanılır ve sınıflandırma için öğrenme vektör niceleyicileri (LVQ) ve kendi kendini organize eden özellik haritaları (SOFM) kullanılır. Sonuçlar, sinir ağlarının yüksek fırınlar için tahminler yapabildiğini bir kez daha göstermiştir [43, 48].

Jimenez ve arkadaşları pik demir sıcaklığını belirlemek için yaptıkları çalışmada benzer şekilde mükemmel bulgular elde etmişlerdir. NARX modeline dayalı araştırmaları için bir sinir ağı modeli oluşturmuşlar, sonrasında aynı topoloji ile NOE modelini de kullanmışlardır. Üretilen modellerin pik demirin sıcaklığını algılamada etkili olduğunu, NARX modelinin yüksek fırın kontrol sistemleri için daha uygun olduğunu ve modeli önceki çıktılarından bağımsız olan NOE modelinin simülasyona izin verdiğini vurgulamışlardır [26].

### **1.3. ÇALIŞMANIN LİTERATÜRE KATKISI**

Bu çalışması sonucunda yazılan makale “Performance analysis of hot metal temperature prediction 5 in a blast furnace and expert suggestion system proposal 6 using neural, statistical and fuzzy models” başlığında literature sunulmuş, makale SCI-Expanded kapsamındaki Metallurgical Research Technology dergisinde hakemli bir dergide yayınlanmıştır.

Makale; 21 Mayıs 2021'de online olarak erişime açılmıştır. Erdoğan Bozkurt, İlhami M. Orak and Yasin Tunçkaya., " Performance analysis of hot metal temperature prediction in a blast furnace and expert suggestion system proposal using neural, statistical and fuzzy models", Metall. Res. Technol. 118, 321 (2021).

DOI Numarası: <https://doi.org/10.1051/metal/2021043>

## BÖLÜM 2

### YÜKSEK FIRIN VE ÇEVRE BİRİMLERİ

#### 2.1. DEMİR ÇELİK ÜRETİM SÜRECİ VE YÜKSEK FIRINLAR

Modern sanayide kullanılan temel hammaddelerden biri de ekonomi literatüründe o toplumun gelişmişliğinin bir göstergesi olarak kişi başına tüketim oranı olarak tanımlanan demir çeliktir. Demir ve çelik, insanlık tarihi boyunca savaş aletleri, süs eşyaları, kaplamalar ve barınak gibi ihtiyaçları karşılamak için yaygın olarak kullanılmıştır. Resmi kayıtlar, bugünkü fırınların atası olan ilk tesisin 14. yüzyılda İngiltere'de üretim yaptığını gösterse de, demir çelik üretiminin ilk olarak MÖ 1. yüzyılda Çin'de ve 1150 ve 1350 tarihleri adresleyen kanıtlara rastlanmaktadır [49].

1800'lü yılların başlarında günümüzde kullanılan yöntemlerden farklı yöntemlerle 1 milyon ton civarında demir çelik malzeme üretimine ulaşıldığı düşünülürken, seri üretim tekniklerinin ortaya çıkmasıyla birlikte dünya çelik üretimi 1870 yılında 10 milyon tona yükselmiş, 1900 yılından bu yana yıllık yüzde 4,5 artışla milyon tona ulaştığı tespit edilmiştir [28]. Özellikle 20. yüzyılın başlarında yeni haddeleme ve alaşımlama tekniklerinin gelişmesi ve dünya savaşlarından bu yana süregelen talep ve teknolojik gelişmelerle birlikte, 2021 yılı sonuna kadar küresel olarak 1.911,9[31] milyon ton ham çelik üretildi. Demir ve çelik üretimi sanayileşmenin motoru haline gelmiştir.

Ülkemizde son dönemde sektöre yapılan yatırımlar sonucunda yılda elli milyon tonun üzerinde çelik üretilmektedir. Varlıklı ülkelerde çelik tüketimi yılda kişi başı 400 ila 600 kg arasında değişirken, ülkemizde kişi başı yılda sadece 200 kg civarındadır. Şekil 2.1, 2021 itibariyle halihazırda kullanımda olan Türk demir-çelik üretim tesislerinin bölgesel dağılımını ve ortalama kapasitesini detaylandırmaktadır. Türkiye, 2021'de 40,4 [31] milyon ton çelik üretmiştir.



Şekil 2.1. 2021 yılı Türkiye çelik haritası [30].

Çelik hammaddesi imalatında kullanılan endüstriyel tesisler ve sıcak madenler, entegre demir-çelik tesislerinin merkezi olan yüksek fırınlardır. Elektrik enerjisi kullanılarak hurda levhaların ergitilmesi ile bu tesislere alternatif olarak oluşturulan daha küçük çaplı ark ocaklarında sıcak metal üretimi gerçekleştirilmektedir. Çelik levhalar silindirik yapıların birbirine kaynak yapılarak birleştirilmesi ile yüksek fırın olarak bilinen nispeten büyük, yüksek, temel zeminde oturmuş ve üzerinde çok fazla destekleyici platform ve yapı olan bir sistemler bütünü olarak ortaya çıkarır [29].

Ateşe dayanıklı tuğlalar, gövdeyi özellikle yüksek sıcaklıklarda meydana gelen reaksiyonlardan korumak ve fırının iç sıcaklık dengesini korumak için fırının iç yüzeyini inşa etmek için kullanılır [49]. Fırın gövde sacı, fırına yüklenen malzemeler yukarıdan aşağıya inerken ısı nedeniyle genişlediğinden, aşağı doğru genleşmeyi kolaylaştıracak şekilde yapılır ve uygulanır. Şekil 2.2, Türkiye'nin güneyinde bulunan İskenderun Demir ve Çelik Fabrikası için üçüncü yüksek fırın tesisinin dışını göstermektedir.




Şekil 2.2. Bir yüksek fırınının genel görünümü [32].

Bir yüksek fırının beş temel bileşeni genellikle yukarıdan aşağıya şöyle sıralanır: boğaz(throat), gövde(stack), bel(belly), karın(bosh) ve hazne(hearth). Entegre demir-çelik fabrikalarında kullanılan fırınların birincil işlevi, mümkün olduğu kadar sabit bir kimyasal bileşim ile, mümkün olan en etkin ve kaliteli şekilde sıcak metal üretimi olarak özetlenebilir [49].

## 2.2. YÜKSEK FIRININ GENEL YAPISI

Fırın oldukça büyük, dikey ve silindirik bir şekle sahiptir ve tipik olarak kok yapısında bulunan karbonu kullanarak cevherdeki demiri indirger [29]. Pik demir (yüzde 4-5 karbon ( $C$ ), yüzde 0,5-1 Silisyum ( $Si$ )) nihai üründür ve çelik yapmak için kullanılabilir. Şekil 2.4 tipik bir yüksek fırın kurulum tasarımını gösterirken, Şekil 2.3 kapsamlı bir yüksek fırın profilini göstermektedir.




Şekil 2.3. Bir yüksek fırının düşey ve yardımcı sistemleri [50].

Dış gövdesi, kalınlığı bölgesel olarak değişen çelik sac kaplama (gövde sacı) ile kaplanmıştır. Gövde sacının iç yüzeyine, reaksiyonlar sonucunda oluşacak ısı miktarına bağlı olarak değişen derecelerde ısıya dayanıklı karbon tuğlalar yerleştirilir.

Bu sayede fırın içinde oluşan muazzam ısının dışarı kaçması, fırın içinde meydana gelen iç reaksiyonlar sonucu oluşan ısının ise gövde sacını tahrip etmesi engellenir.

Boğaz (throat), gövde (stack), bel (belly), karın (bosh) ve hazne (hearth) bölümleri yüksek fırını oluşturur.

Bir yüksek fırının birincil amacı, önceden belirlenmiş ve sabit bir bileşime sahip erimiş demiri verimli bir şekilde oluşturmaktır. Fırın döküm deliğinden demir ve cürufun erimesi için 1700 Kelvin'den yüksek olması gereken demir ve cürufun sıcaklığı en önemli çalışma parametresidir. Üretilen pik demirin bileşimi, yüksek fırın işleminde çok önemli bir faktör değildir, çünkü pik demir sıklıkla tekrar işlenip çeliğe dönüştürülür. Ancak çelik fabrikası gereksinimlerine uygun olarak uygun cüruf bileşimi ve fırın sıcaklığı ile bu bileşim yönetilir [29].



Şekil 2.4. Bir yüksek fırın tesisinin hammadde, şarj, dökümhane, gaz işleme ve sıcak hava sistemlerini gösteren kesiti [27].



### 2.3. HAMMADDELER

Fırının tepesinden yüklenen katı maddeler (cevher, kok, akışkanlaştırıcı maddeler) ve fırın tabanına yakın tüyerlerden üflenen hava, bir yüksek fırın için hammadde olarak kabul edilebilir. Ayrıca tüyerlerden oksijen ve hidrokarbon katkı maddeleri (gaz, sıvı veya katı) gönderilir.

Demir oksitler, hematit ( $Fe_2O_3$ ) ve/veya manyetit ( $Fe_3O_4$ ); Modern işletmelerde sinter üretmek için kullanılmayan, demir oksitler, 0,05 milimetreden küçük cevher tozları işlenerek, kalan kısmın %5-10'u  $SiO_2$  ve  $Al_2O_3$  yaklaşık %100'ü  $Fe_2O_3$  olan 1-2 santimetre çapında pelet, cevher parçacıklarının işlenmesiyle üretilen 1-3 cm sinter ve 1-5 cm cevher yapılarında kullanılır. Mütevazı miktarlarda bile, çelik hurda ve cüruf bazen demir bileşenleri yapmak için kullanılır.

Metalürjik kok; yüzde 10 ila 12 arasında bir kül içeriğine sahiptir, yapısında yüzde 90 karbon, yüzde 0,5-1 kükürt ve yüzde 5-10 nem içerir. Cevherin indirgenmesi ve ergitilmesi için gereken gaz ve ısının büyük bir kısmı ondan sağlanır. Farklı kalitedeki kömür karışımlarının havasız bir atmosferde yakılmasıyla metalik kok üretilir. Bu, kömürün uçucu bileşenlerini damıtarak fırının alt bölgelerinden parçalanmadan geçebilen ve yüksek sıcaklıklarda reaksiyona girebilen gözenekli kok oluşturmak için mümkün kılar. Kok parçacıklarının fırının dibine inmesi çok önemlidir. Çünkü bu özellik, fırının alt kısımlarında yumuşayan ve eriyen malzemelerden sabit bir gaz akışını sürdürmek için gereklidir. Kok, 2 ila 8 santimetre genişliğinde parçalar halinde fırına şarj edilir.

Cüruf yapıcılar; kok ve cevher akışkanlığının silikon oksit ( $SiO_2$ ) ve alüminyum oksit ( $Al_2O_3$ ) bileşenlerine vererek 1600 Kelvin civarında düşük bir erime noktasına sahip akışkan cüruf oluştururlar. Öncelikli olarak kok ile fırına yüklenen kükürt,  $CaO$  ile artık fırından pik demir yerine cüruf şeklinde çıkabilmektedir, bu da ikinci bir avantajdır. Bu malzemelerin büyük bir kısmını oluşturan kalker ( $CaCO_3$ ) ve dolomit ( $CaCO_3$  ve  $MgCO_3$ ) sinterin yanında 3-5 cm büyüklüğünde olacak şekilde fırına şarj edilirken; çelikhane cürufu da zaman zaman bu parçalarla fırına verilir.

Sıcak hava; 1200 ile 1600 Kelvin arasında ısıtılmış ve oksijen içeriği tipik olarak yüzde 25 düzeyine artmış olan havadır. Tüyerlerin önünde, sıcak hava akkor kokla (yaklaşık 1800 Kelvin) yanar, indirgeme işlemleri, yüklü malzemenin ısıtılması ve eritilmesi için gereken ısıyı sağlar ve erimiş pikin sıcaklığını korur. Sıcak havanın yüksek sıcaklığı, pik demir ve cürufun sıcaklıklarının erime noktalarından uygun şekilde yüksek olmasını sağlar.

İndirgeme işlemi için gereken indirgeyici gazların ( $CO$  ve  $H_2$ ) miktarı, diğer gaz, sıvı ve katı hidrokarbonların varlığından dolayı artar. Kullanılan maddeler arasında toz haline getirilmiş kömür, doğal gaz, katran, akaryakıt ve katran bulunmaktadır [29, 34].

## 2.4. ÜRÜNLER

Yüksek fırının birincil çıktısı olan erimiş pik demir, fırın hazne bölümünün altında bulunan bir veya daha fazla döküm deliğinden periyodik olarak (veya çok büyük fırınlarda sürekli olarak) çekilir. Çizelge 2.1, erimiş pik demirin tipik bir analizinin bir örneğini vermiştir.

Çizelge 2.1. Pik analizi [51].

ISO Sınıfı	100	150	200	250	300	350
%C	3,5-3,8	3,4-3,7	3,2-3,5	3,1-3,4	3,0-3,2	2,9-3,1
%Si	2,3-2,8	2,1-2,6	1,8-2,3	1,6-2,1	1,3-1,9	1,1-1,5
%Mn	0,4-0,8	0,5-0,8	0,6-0,8	0,6-0,8	0,7-0,9	0,8-1,0
%P	Max.0,20	Max.0,20	Max.0,20	Max.0,15	Max.0,10	Max.0,10
%S	0,06-0,15	0,06-0,15	0,06-0,15	0,06-0,12	0,06-0,12	0,06-0,12
Ceqv	4,2-4,6	4,0-4,3	3,8-4,1	3,6-3,9	3,4-3,7	3,2-3,5

Bir yüksek fırında pik demir bileşimi, üretilen demirin sevk edileceği çelik fabrikalarının ihtiyaçlarını karşılayacak şekilde seçilir. Pik demir bileşimi, cürufun bileşimi ve genellikle fırının alt yarısında fırın sıcaklığının değiştirilmesiyle kontrol edilir.

Pik demir tipik olarak, çelikteki istenmeyen bileşenleri çok düşük seviyelere indirmek için oksijenle temizlendiği çelik atölyesine torpidolarla erimiş halde taşınır. Erimiş pik demir, çelik fabrikalarında kalsiyum karbür veya magnezyum koku ile işlenmeden önce bazen kükürttten arındırılabilir.

Cüruf ve yüksek fırın gazı diğer iki yüksek fırın ürünüdür. Çizelge 2.2, cürufun genel kimyasal yapısı hakkında bilgi vermektedir.

Çizelge 2.2. Cüruf analizi [52].

Oksitler									Kızdırma
CaO	SiO <sub>2</sub>	Al <sub>2</sub> O <sub>3</sub>	MgO	SO <sub>3</sub>	K <sub>2</sub> O	Na <sub>2</sub> O	TiO <sub>2</sub>	Mn <sub>2</sub> O <sub>3</sub>	Kayıbı
(%)	(%)	(%)	(%)	(%)	(%)	(%)	(%)	(%)	(%)
35,57	41,90	10,79	6,36	1,70	0,70	0,32	0,66	2,16	0,51

Cüruftaki nispeten küçük bir demir oksit yüzdesi, fırının iyi indirgeme verimliliğinin bir işareti olarak değerlendirilebilir. Cüruf kimyasal kompozisyonu:

- SiO<sub>2</sub> ve Al<sub>2</sub>O<sub>3</sub> 'ün akışkan cüruf içerisinde atılmasını,
- olmaması halinde fırın duvarlarına yapışarak fırın hacmini düşüren ve gaz akışı düzenine bozarak çalışmasını zorlaştıran alkalilerin (Na<sub>2</sub>O ve K<sub>2</sub>O) soğurulmasını,
- Kükürtün demirde çözünmesi yerine kükürt emilimi,
- metalin silikon içeriğinin yönetimi

sağlayacak biçimde seçilir. Cüruf bazitesi, cürufun kimyasal özelliklerini ifade etmek için kullanılır. 2.1 ile verilen denklem cüruf baziklik oranını temsil etmektedir.

$$B4 = \frac{\%CaO + \%MgO}{\%SiO_2 + \%Al_2O_3} \quad (2.1)$$

Fırın üzerindeki gaz toplama sistemi, yüksek fırın gazının fırından çıkmasını sağlar. Çizelge 2.3, yüksek fırın gazının bileşiminin bir özetini sunmaktadır. Bu gazın (4000 kJ/Nm<sup>3</sup>) yanma enerjisi, doğal gazınkinin yaklaşık onda biridir. Gaz temizleme

sisteminden geçirilerek tozu alınan gaz, fırına gönderilecek havayı ısıtmak için fırın yardımcı sistemlerinden sobalarda yakılır.

Çizelge 2.3. Yüksek fırın gazı analizi [53].

<b>Yüksek Fırın Gazı Bileşenleri</b>	
<b>Bileşen</b>	<b>Oran</b>
H <sub>2</sub>	1,74%
N <sub>2</sub>	57,06%
CH <sub>4</sub>	0,3%
CO	24,10%
CO <sub>2</sub>	16,80%
Alt Isıl Değeri	690 kcal/m <sup>3</sup>

Sinterleme süreci yardımıyla, ayrılan toz birleştirilir veya fırına geri yüklenir ya da daha sonra kullanılmak üzere saklanır [29, 34].

## **2.5. YARDIMCI SİSTEMLER**

Yüksek fırınlar için yardımcı sistemler, havayı ısıtmak, fırını çalıştırmak için gerekli malzemeleri doldurmak ve cüruf ve pik demiri çıkarmak gibi görevleri yerine getirir.

### **2.5.1. Hammadde Taşıma Sistemi**

Yukarıdan yüklenen malzemelerin yüksek fırına sevkini kolaylaştıran bir sistemdir. Siloları, konveyör bantları, tartım için hazneleri ve hammadde depolamak için kovaları vardır. Tutulacak malzemeye ve fırının boyutuna bağlı olarak farklı tipte silolar kullanılabilir. Hammaddeler, önceki tesislerden gelen bantlarla silolara taşınır ve orada da elek görevi gören besleyiciler ile tartım odalarına taşınır. Fırına taşınacak malzeme miktarı fırının çalışması için çok önemli olduğundan hassasiyeti sürekli kontrol altında olan tartım odalarında tartılır ve gerekli oranlarda bantlı kovalara aktarılır. Fırının tepesine malzeme taşıyan ekipmanlara kova denir. Kovalar, fırının üzerinde bulunan diğerinden malzemeyi boşaltırken, birinin altındaki bantlardan malzeme alarak paralel

olarak çalışır. Bazı büyük fırınlarda, kova sistemleri yerine tartım odalarından fırının tepesine kadar konveyör sistemleri çalışır.

### **2.5.2. Fırın Tepe Şarj Sistemi**

Hammadde besleme sisteminin fırına konulan malzemeyi şarj etmek için kullandığı sistemdir. Büyük çan ve küçük çan ve bunların senkronize işleyişinden oluşan "Çan Sistemi", daha önce malzemeyi fırına doldurmak için kullanılmıştır. Şimdi, çansız havai ekipman olarak bilinen bir yöntemle süreç işletilmektedir. Bu sistemde fırının üstüne iki adet malzeme silosu kurulur ve gerekli işlemlerden sonra malzemeler bu silolardan siloların altına yerleştirilen kapak ile (basınç eşitleme gibi) fırın içinde açısı ayarlanabilir bir eğirme şutuna taşınır. Döner oluk açısı malzemenin şarj edileceği yerlere göre değiştirilerek malzeme fırına doldurulur.

### **2.5.3. Sobalar**

Sobalar, kok kömürünün yanabilmesi için fırına yönlendirilen sıcak havayı ısıtan sistemlerdir. Çalışma teorisi, bir fırında üç veya dört tane olduğunu belirtir. Bir yanma odası ve bir ısıtma odası, her sobanın iki bölümünü oluşturur. Bir sobanın ısıtma devresi ve fırın devresi olmak üzere iki durumu vardır. Kok gazı, doğal gaz veya çelik fabrikası gazlarından oluşan gaz karışımı, ısıtma devresinde yüksek fırın gazı gerekiyorsa, yeterli hava belirli bir sıcaklığa kadar ısıtılarak yanma odasında yakılır. Üretilen ısı, fırını tamamen çevreleyen ısıtma hücrelerindeki delikli tuğlaları ısıtır. Baca atık gazın dışarı atılması için kullanılır. Fırına taşınacak hava, tuğlalarda tutulan ısıyı emmesini sağlamak için fırın devresindeki ısıtma hücresi vasıtasıyla dolaştırılır. Soba, fırın devresinden çıktıktan sonra soğuduktan sonra tekrar ısıtma devresine girer. Sobalardan biri genellikle fırın devresinde, diğerleri ise ısıtma devresindedir. Fırının çalışmasının iki yolu vardır: fırın devresine aynı anda yalnızca bir brülörün bağlı olduğu seri olarak ve aynı anda iki sobanın fırın devresine bağlı olduğu paralel.

#### **2.5.4. Hidrokarbon Saęlayan Sistemler**

Geçmişte yüksek kok tüketimi maliyetini düşüren ve fırının çalışma parametrelerini kontrol eden fuel oil, katran gibi sıvı halde üretilirdi. Ancak 1979 petrol krizinin getirdiğı maliyet artışları nedeniyle terk edilmiştir. Ancak bu fırının işletimi ve maliyeti önemli ölçüde olumsuz etkilenmiştir. Bu nedenle işletmeler pulverize kömür enjeksiyonu kullanmaya başlamış ve bu teknolojiyi kullanan fırınların sayısı artmıştır. Günümüzde akaryakıt oluşturmak için toz haline getirilmiş kömür ve doğal gaz kullanılmaktadır. Kömür enjeksiyonu için, kömür enjeksiyon için 75 mikron ve daha küçük partiküller haline getirilmeden önce yüksek fırın gazı, yüksek fırın baca gazı, kok gazı ve/veya doğal gaz ile kurutulur. Daha sonra kömür tüyere ile sıcak havanın bir enjeksiyon sistemi ile saęlandığı fırına taşınır.

#### **2.5.5. Dökümhane**

Yüksek fırının ürettiğı pik demir ve cürufun alındığı yerlerdir. Yüksek fırın üretebileceklerine baęlı olarak en az bir ve en fazla dört taneye sahiptirler. Fırın haznesinin altında cüruf ve cüruf çıkışı için döküm ve cüruf delikleri bulunur. Pik delikler sık sık açılırken cüruf delikleri gerektiğı gibi açılır. Cüruf ve pik, pik deliklerinden tahliye için verildiğinden, bu delikler genel olarak döküm delikleri olarak da bilinir. Döküm kapama çamurluk topu ile bu deliğe özel bir çamur enjekte edilir ve tahliye mümkün hale getirildikten sonra döküm deliğı kapatılır. Bir döküm matkabı ile döküm deliğinin açılır. Pik demir, tahliye sırasında çelikhane taşınması için gerekli olan torpidolara korozyona dayanıklı bir kanal vasıtasıyla taşınır. Cüruf kanalı, cüruf alanındaki cürufu toplar. Cüruf, bazı fırınlarda potalar kullanılarak kullanım amacına göre işlenebilir.

#### **2.5.6. Soęutma Sistemleri**

Yüksek fırında yapılan işlemler fırın içindeki sıcaklığın artmasına, bazen 2200 °C dereceye ulaşmasına neden olur. Fırın üstü şarj sistemi 150 °C ile 200 °C derece arasındaki sıcaklıklara maruz bırakılır. Sonuç olarak, fırın bir soęutma sistemine ihtiyaç duyar. Fırının iç duvarı, gövde sacının fırında oluşan ısıdan zarar görmemesi

için karbon,  $SiC$  (silisyum karbür), grafit  $Al_2O_3$  gibi çeşitli kalitedeki refrakter tuğlalardan yapılmıştır. Bu tuğlaların ömrünü uzatmak ve soğutmak için bakır plakalı soğutucular ve/veya tepe panel kullanılmaktadır ve bu sayede fırının ömrü de uzamaktadır. Bu soğutucular, soğutma suyunun girdiği, tüm soğutucu boyunca dolaştığı ve ardından çıktığı kanal yapısına sahip bir alana sahiptir. Fırın gövdesindeki tüyerler veya sıcak hava girişleri bakırdan yapılmıştır ve ısı hasarını önlemek için su ile soğuk tutulur.

## 2.6. ÜRETİM SÜRECİ

Hammaddelerin fırının tepesinden düzenli aralıklarla doldurulması, üretilen erimiş ürünlerin dökümhaneden sürekli veya düzenli olarak çıkarılması, sürekli sıcak hava ve yardımcı hidrokarbonların üflenmesi, gaz ve tozun sürekli olarak uzaklaştırılması süreçleri yüksek fırın üretim sürecinin birer parçasıdır

Hammaddelerin doldurulması, sıcak hava üflenmesi ve hidrokarbonların enjekte edilmesi gibi işlemlerin çoğu mekanik ve otomatik olarak gerçekleştirilir. Sürekli izleme sistemleri, günümüzün yüksek fırınlarında yaygın olarak kullanılmaktadır. Sürekli olarak gözlemlenen süreç değişkenleri;

- Sıcaklıklar: duvar ve taban sıcaklıkları, soğutma suları, sıcak hava, tepe sistemi ve gaz sıcaklıkları,
- Basınç: Fırın iç, sıcak hava, tepe, duvar,
- Akış miktarları: oksijen zenginleştirme, sıcak hava, soğutma suları, hidrokarbon ilavesi,

olarak sayılabilir. Döküm sırasında pik demir ve cürufun sıcaklıkları ve kimyasal bileşimleri de periyodik olarak ölçülür. Teknolojik ilerlemeler, hem bu noktaların miktarını hem de geçmiş tutma oranlarını büyük ölçüde artırmıştır

Fırının çalışma parametreleri ve bilgisayar hesaplamaları sonucunda elde edilen ölçüm verilerine göre fırına beslenecek hammadde miktarı belirlenir. Dökümü açmak ve pik demiri ve cürufu fırın içerisinden tahliye etmek en önemli manuel işlemdir [29].

Kok, fırına üstten beslenen ve tüyere seviyesine inen tek hammaddedir. Kok, hammaddelerin pik demir ve cürufa dönüştürülmesi için gereken ısıyı sağlamanın ve indirgeyici bir rol oynamanın yanı sıra, tipik olarak metal ve cürufun sıvı olduğu göbekte malzemeye mekanik destek sağlar. Kok parçacıkları arasındaki boşluklardan bu erimiş elementler odaya girer. Yüksek fırında en büyük harcamalardan biri, ton pik demir başına 450-500 kg ağırlığındaki koktur. Uygun malzeme kullanımı, yüksek sıcak hava sıcaklığı, yüksek hidrokarbon takviyesi ve düzenli gaz dağıtımı ile maliyetleri nedeniyle daha az kok tüketimi mümkün olmaktadır.

Tüyerin hemen önünde, fırına giren tüyerlerden gelen sıcak hava kok kömürünü yakar. Kuvvetli yanma kullanılarak 2000 °C ile 2200 °C derece arasında bir alev üretilir (tüyer gazı sıcaklığı). 1000 °C derecenin üzerindeki karbon ortamlarında CO<sub>2</sub> kararlı bir yapıya sahip olmadığı için eşitliğinde CO<sub>2</sub> + C = 2CO eşitliğinde CO oluşur. Tüyer gazı, kuru hava kullanıldığında %35 CO ile %65 N<sub>2</sub> arasında dağılımına sahiptir. Kok tüyere bölgesine sürekli yukarıdan değil, aralıklı olarak gelir. Demir oksitler, karın, bel ve gövdeye doğru yükselirken bu sıcak indirgeyici gaz tarafından indirgenir [34].



### 2.6.1. Demir Oksitlerin İndirgenmesi

Demir oksitler Hematit (Fe<sub>2</sub>O<sub>3</sub>), magnetit (Fe<sub>3</sub>O<sub>4</sub>) ve vüstit (FeO) olmak üzere üç farklı biçimde gelir. Bahse konu oksitler kademeli olarak indirgenir. CO ile demir oksitlerin reaksiyonları, CO/CO<sub>2</sub> denge oranı ve 900 °C derecedeki CO verimlilik faktörleri (η<sub>CO</sub>) aşağıda verilmiştir. Verimliliğin boyutu, CO<sub>2</sub>'ye dönüşen CO'nun oranı veya yüzdesi formül 2.2'deki gibi gösterilir.

$$\% \eta_{CO} = 100 \cdot \frac{\%CO_2}{\%CO + \%CO_2} \quad (2.2)$$

Tepkime	900 °C derecedeki denge
	CO/CO <sub>2</sub> η <sub>CO</sub> ,%





Bir ters akım prosesi olan yüksek fırın, yüksek  $CO$  içeriğine sahip tüyer gazının temas etmesine ve  $Fe$ 'ye dönüşmesi için yüksek bir indirgeme potansiyeline ihtiyaç duyan  $FeO$  ile reaksiyona girmesine neden olur ve yükselir. Bu mineraller önemli ölçüde daha düşük  $CO/CO_2$  denge oranlarında daha düşük oksitlere indirgenebilir. Bu nedenle, indirgeme reaksiyonları arasında, vüstit indirgemesi en üst sırada yer almaktadır. 2.3 ila 2.5 arasındaki reaksiyonlarda daha fazla oksijen parçalandıkça karbonun kimyasal ve termal enerjisinin verimliliği azalır, çünkü  $CO_2$  karbonun sonradan yanmasının nihai sonucunu belirler. Bir miktar ısı saldıkları için dolaylı veya gazlı reaksiyonlar olarak bilinen bu reaksiyonlar,  $CO$ 'nin açığa çıkmasına neden olur.

Eğer sıcaklığın  $1000\text{ }^{\circ}C$  dereceyi aştığı bölgelerde indirgenmemiş vüstit kalmış ise, kalan vüstit 2.4 numaralı tepkime sonucunda ortaya çıkan  $CO_2$ 'de bulunan karbon indirgemeyi sağlar.



2.5 ve 2.6 numaralı eşitliklerden 2.7 numaralı eşitlik elde edilir.



Yüksek oranda ısı alan ve  $CO$  kullanımını bozan 2.6 tepkimesi Boudouard veya çözümlü kaybı veya karbon gazlaşma tepkimesi olarak bilinir. 2.7 tepkimesine doğrudan indirgeme denir. Dolaylı indirgemeye nazaran ısı alan bu tepkime, oksitlerden ayrılan her bir oksijen molü için daha az karbon tüketir ve bu sayede  $CO$  daha ileriki indirgemelerde kullanılabilir.

Çözünürlük kaybı reaksiyonu veya karbon gazlaştırma reaksiyonu olarak da bilinen Boudouard reaksiyonu,  $CO$ 'in kullanımını engelleyen yüksek ısı içeren bir

reaksiyondur. Doğrudan indirgeme, reaksiyon 2.7'ye verilen addır. Oksitlerden çıkan her bir oksijen molü için, dolaylı indirgemededen daha fazla ısı üreten bu reaksiyon, daha az karbon tüketerek  $CO$ 'in diğer indirgemelerde kullanılmasına izin verir.

Şarj edilen hammaddeler alçaldıkça 1400–1450 °C dereceye kadar ısınırken, 2000–2200 °C derece yüksek alev sıcaklığına sahip tüyere gazı, fırından çıkarken yükselir ve 100–250 °C derece sıcaklığa kadar soğur. Fırında Şekil 2.4'te gösterildiği gibi üç ayrı sıcaklık bölgesi vardır: fırının tüm ısı ihtiyacını yükselen gazlar yoluyla sağlayan alt ve üst ve geneld sabit sıcaklıkta (800–1000 °C) olduğu orta. Orta sıcaklıkta neredeyse tüm alan boyunca ve çok az ısı transferi yaşar [35].

### 2.6.2. Alt Bölge Tepkimeleri

Tüyer bölgesini alt eritme veya işleme bölgesinden 3-5 metre ayırır yukarıya doğrudur. Bu bölgede erimiş maddeler 1400-1450 °C derece sıcaklıklara ulaşabilirken, gaz 800-1000 °C dereceye kadar soğur.

Kokun tüyerlerin önünde yanması sonucu, odanın üst sınırında tüyerlerin önünde sürekli bir boş alan oluşması, yüklü malzemelerin aşağı doğru akışına neden olur. Düzenli bir gaz dağılımı ve yüklü malzemenin alçalması, büyük ölçüde bu yanma alanının boyutuna ve biçimine bağlıdır. Bu yanma alanının derinliği, sıcak havanın kinetik enerjisine bağlı olarak bir ile iki metre arasında değişmektedir. Bu nedenle, haznenin üst sınırını çevreleyen bu 1-2 m'lik alan asıl aktif alandır. Hazne halkası, aktif çevre veya raceway, derinliği olan halkadır. “dead man's zone”, bu halkanın ötesinde yer alan, sıkıca doldurulmuş bir merkez kok sütunudur. Bu kok kolonu ya bölmedeki sıvı tepe noktasında yüzer ya da mümkün olduğu kadar bölmenin dibine iner. Döküm açıldığında, kok parçacıkları arasındaki yarıklardan bir miktar cüruf ve demir süzülür.


1200 °C dereceyi geçen sıcaklıklarda fırına giren akışkanlaştırıcı maddeler ve demir dışı oksit bileşenleri erir ve fırının bel bölgesinde iki ayrı faz oluşmaya başlar. Bu iki sıvı faz birbirinden ayrıldıktan sonra kanal üzerindeki kok alanından sızar ve haznede

toplanır. Tüyer gazı, kok yatağındaki çatlaklardan yükselirken, hazne halkası veya raceway, kok mekanik destek sağlarken, karşı akımlı bir sıvıdan gaza dönüştürücü gibi davranır. Taşma riski açısından bu alandaki malzeme hareketi çok önemlidir.

Çalışmakta iken söndürülmüş ve sıcak su verilmiş yüksek fırın çalışmalarında, alt gövdeye doğru uzanan zayıf doldurulmuş bir kok kolonu da görülmüştür. Geçirimsiz, yapışkan, yarı erimiş bir cüruf ve alternatif kok katmanları içeren ve yükselen gazların geçmesini önleyen bir demir yumuşatma-erime veya yapışkan bölge, bu zayıf doldurulmuş sütunu çevreler. Gazın yatay olarak içinden geçmesini sağlayarak gaz difüzörü işlevi gören geçirgen kok katmanlarına kok yarıkları denir.

Yukarı doğru uzanan geçirgen katı yatakta gaz yükselir. Özellikle büyük fırınlarda, gazın çoğunluğunun bu boşluklardan geçmesi gerektiğinden, kok yarıkları geçirgen olmalıdır. Bu özellik, kokunun kırılma direnci ile yakından ilgilidir.

Karın bölgesindeki cüruf, fazladan kireç ilk cürufa dahil edildiğinde oluşur. Hazne cürufu daha sonra kok külünün tüyere önünde yakılmasıyla oluşturulur ve döküm açıldığında serbestçe akmasına izin verecek bir bileşime sahip olmalıdır. Cüruf içerisindeki malzemeler 1400 ile 1450 °C derece arasındaki sıcaklıklarda tamamı sıvı olacak şekilde, 1500 °C derecede ise akışkanlıkları 10 P olacak şekilde seçilmiştir. Bazitesi 0,9 ile 1,2 arasında değişmektedir. Cürufun içinde  $FeO$  yoktur. Çünkü indirgenmemiş  $FeO$ , ya eritme bölgesindeki kok ızgaralarından geçtiğinde ya da odadaki yüzen kok kolonu ile temas ettiğinde tamamen indirgenir.



Şekil 2.5. Gaz ve katıların sıcaklık dağılımının fırın yüksekliği boyunca ki ideal dağılımı ve üç sıcaklık bölgesinde oluşan kimyasal tepkimeler [35].

Demir ve cürufu tüm çalışma koşullarında sıvı halde tutmak için 1500 ile 1550 °C arasında olması gereken kritik hazne sıcaklığı, basit cüruf tahliyesi için gerekli olan en düşük sıcaklıktır.

Şekil 2.5’de bölgesel oluşan tepkimelerden öne çıkanlar verilmiştir.

Cüruf nihai sıcaklığı, yaklaşık 1350–1450 °C olan demirin nihai sıcaklığından 50–100 °C (yaklaşık) daha yüksektir. Fırının alt kısmında ihtiyaç duyulan ısı, ısı yayılımı ve soğutma kayıpları ile birlikte, kullanılan hammaddelere ve üretilen ürünlere bağlı olmakla birlikte, bir ton pik demir için 0,7 ile 1 milyon kcal. arasında değişmektedir. Bu noktadan sonra gaz ve şarj malzemelerinin sıcaklıkları artık birbirine yaklaşmaktadır [35].

### 2.6.3. Orta Bölge Tepkimeleri

Orta izotermal veya termal rezerv, gazlar ve katılar için 800 ila 1000 santigrat derece arasındaki sıcaklık aralığı olarak tanımlanır. Genellikle indirgeme bölgesi olarak bilinen bu alan, ana indirgemenin, özellikle vustitin ( $FeO$ ) indirgenmesinin önemli bir bölümüne sahiptir. Bu alan iyi çalışan bir fırın için fırın hacminin yarısı veya biraz daha fazlasıdır (%50-60).

Vustitin dolaylı olarak indirgenme şansının en yüksek olması gerektiğinden, bu alanın genişliği çok önemlidir. Bu bölgenin başlangıç noktası, fırının yüksek ısı (endotermik) reaksiyon eşiği, ısı iletim etkinliği ve çeşitli fırın bölümleri boyunca homojen gaz dağılımı ile tanımlanır.

Çağdaş fırınlardaki çeşitli seviyelerdeki sondalara ve gaz numunelerinin analizlerine göre, burada cevher ve gaz arasında çok az oksijen değişimi ve gaz bileşiminde çok az değişiklik olan kimyasal olarak aktif olmayan bir bölge vardır. Bu aktif olmayan bölgede kabaca 2,3'lük bir  $CO/CO_2$  gaz oranına sahiptir, bu da 2.5 ile gösterilen denklemdeki  $Fe - FeO$  dengesini gösterir.

Su-gaz deęişim reaksiyonu, bu alandaki bir dięer önemli reaksiyondur.



Bu reaksiyon,  $CO$  'a göre daha aktif bir indirgeyici gaz olan hidrojen emisyonu ile sonuçlanır. Nem, demir oksitlerin indirgenmesinde hidrojen tüketimi veya fırına üflenen havaya ilave edilen buhar ve/veya şarj edilen hammaddeler yoluyla fırına girer [35].

#### 2.6.4. Üst Bölge Tepkimeleri

Şarj malzemelerinin sıcaklıkları oda sıcaklığından  $800 \text{ }^\circ C$  dereceye yükselirken, ön ısıtma veya hazırlama bölgesinde merkez bölgeden yükselen gazın sıcaklığı  $800-1000 \text{ }^\circ C$  dereceden  $100-250 \text{ }^\circ C$  dereceye hızla düşer. Bu alanda:

- $2CO = CO_2 + C$  reaksiyonu ile karbon birikimi,
- nem ve hidrat buharlaşması,
- kalsiyum dışındaki karbonatların ayrışması,
- hematit ve manyetit kısmen veya tamamen düşük oksitlere indirgenmesi

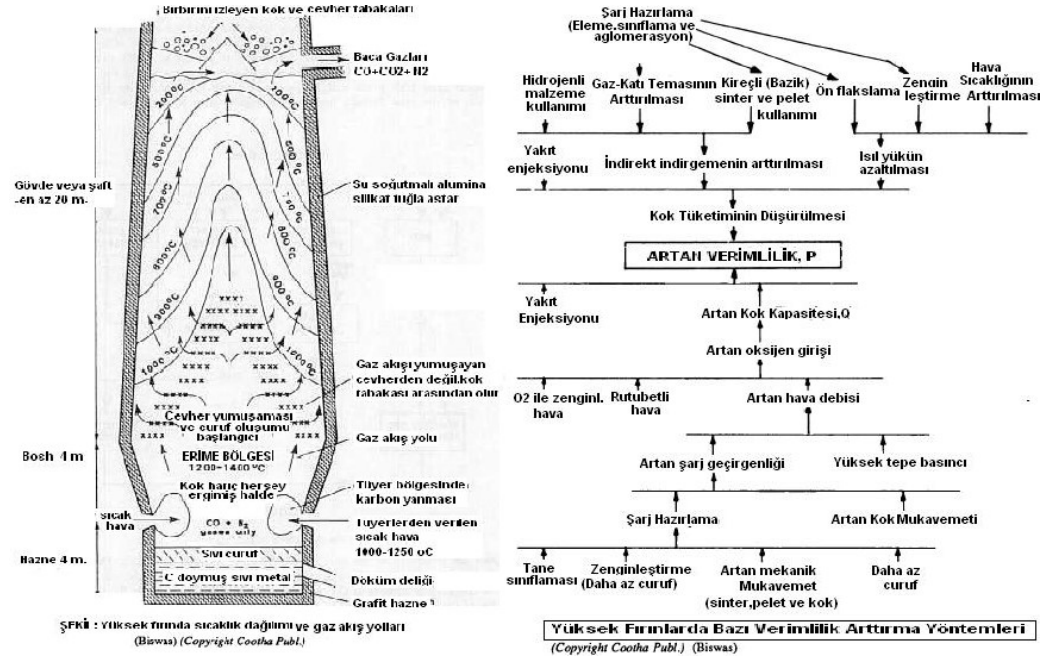
not edilebilir.

Üretim hızına baęlı olarak, şarj edilen malzemelerin üstten tüyere seviyesine gelmesi 5-8 saat arasında sürebilir. Bu malzemelerin uç alanın her birinde ne kadar süre aldıkları bilinmemektedir. Gazın fırında kalma süresi ise 1 ile 10 saniye arasında deęişmektedir [35].

#### 2.7. VERİMLİLİKTEKİ GELİŞMELER

Günde 13000-ton üretim kapasiteli fırınların inşa edilebildięi günlere geline süreçte ilk fırınların kurulduęu günden bu yana yüksek fırınların verimlilięi istikrarlı bir şekilde artmıştır. Daha iyi yük dağıtım sistemleri, daha iyi soęutma sistemleri ve daha dayanıklı refrakter malzeme gibi üstün tasarımlara sahip daha büyük fırınlar, bu büyümenin başlıca itici gücüdür. Performans, fırın koşulları altında şarj

malzemelerinin fiziksel ve kimyasal özelliklerindeki değişikliklerle de önemli ölçüde iyileştirilmiştir.



Boyutsuz cevherden boyutlandırılmış cevhere geçiş ve istenilen sinter ve pelet dağılımı, verimlilik artışına en önemli katkıyı sağlayan unsurlardır. Fırın, yüksek hava oranlarında çalıştırılabilir, çünkü pürüzsüz malzeme, fırın gazlarının kanallaşma olmadan şarjla hızlı bir şekilde tırmanmasına izin verir. Aslında, daha küçük sinter ve peletler kullanmak, eski fırınların üretimini neredeyse iki katına çıkarmıştır. Ek olarak, fırın gazı ile toz olarak kaybedilen cevher miktarında önemli bir azalma vardır.

Hidrokarbon sıvılarının, gazların ve katıların tüyerlerden enjeksiyonu sonucunda katı şarjdaki kok gereksinimi azalmış ve fırın üretkenliğinin iyileştirilmesine olanak sağlanmıştır. Gövdede daha fazla demir oksit için alan açılması, mümkün kılınan artan indirgeme kapasitesini arttırmıştır. Ek olarak, bu katkı maddelerinin maliyetlerini kok maliyetleriyle karşılaştığımızda, doğrudan üretim maliyetlerini önemli ölçüde düşürmüştür.

Bununla birlikte, daha sıcak havanın kullanımı, hidrokarbon takviyesi yoluyla keşfedilmiştir. Tüyere bölgesindeki fırına soğuk olduğu için verilen hidrokarbonlar daha fazla ısı gerektiriyordu. Modern fırınlara üflenen sıcak hava  $1350^{\circ}C$  dereceye kadar çıkabilmektedir.

Yüksek fırının performansı, havaya saf oksijen eklenmesiyle arttırılmıştır. İlave oksijen gerekli hava oranını düşüreceğinden, fırından geçen nitrojen miktarı azalacaktır. Azotu kısmen ortadan kaldırarak, soğuk hidrokarbon enjeksiyonunu iyileştirmek için tüyerlerin önündeki alevin sıcaklığını artırılması ve üretim hızını artırarak, fırından geçen toplam gaz hacmini arttırmadan daha fazla demir oksit indirgenmesi elde edilmiştir. Bu yakşalımda da kanallama veya taşma olmadan çıktıyı artırma yeteneği kazandırmıştır.

Şu anda bir çok fırının işletildiği üç atmosfere kadar fırın tepesini basınçlandırma kapasitesi, bir diğer önemli gelişmedir. Gaz hızını arttırmadan, yüksek basınçlı işlem, yüksek fırın şarjı boyunca gazın ağırlık akış hızını arttırır. Sonuç olarak, demirin üretilme hızı artar, ancak üretilen indirgeme gazı miktarı değişmeden kalır. Fırından çıkan gaz akışını damper ile sıkıştırarak yüksek fırının basıncı korunur. Bu tür bir faaliyet için fırın yapısının güçlendirilmesi gerekmektedir [29].



## BÖLÜM 3

### BULANIK MANTIK

#### 3.1. GİRİŞ VE TARİHÇE

Plato, "Doğru" ve "Yanlış"ın birbirine karıştığı üçüncü bir örnek tanımlayarak bulanık mantık için temel kavramı ortaya atmıştır. Bu fikir, Hegel ve Marx gibi çağdaş entelektüeller tarafından pekiştirildi, ancak Lukasiewicz, Aristoteles'in iki değerli mantığına ilk sistematik meydan okumayı oluşturmuştur [55].

Önermelerin yalnızca bir veya sıfır doğruluk değerine sahip olmasına izin veren klasik mantığın aksine, önermelerin bir ile sıfır arasında kesirli doğruluk değerleri almasına izin veren "çok değerli" mantık kavramları 1920'lerde Polonyalı mantıkçı Jan Lukasiewicz tarafından geliştirildi. İlk bulanık küme eğrileri, bir kuantum filozofu olan Max Black tarafından 1937 tarihli bir makalede, liste veya nesne koleksiyonlarına "çok değerli mantık" uygulanarak oluşturulmuştur [54]. Sonsuz değerli mantık ancak 1965'ten sonra başarılı bir şekilde uygulanmış olsa da, Lotfi A. Zadeh bu değerleri  $[0.0, 1.0]$  aralığında sayılarla ifade etme teorisini "Bulanık Mantık" adlı çalışmasında tanımladığında, bu değerleri sayısal olarak ifade etmiştir. [55]. Zadeh'in bu ufuk açıcı çalışması, Lukasiewicz'in mantığını tüm küme bileşenlerine uygulayarak bulanık kümeler için kapsamlı bir cebir geliştirir. Ancak Ebrahim H. Mamdani, 1974'te İngiltere'de bir buhar motoru için bir bulanık mantık kontrol sistemi yaratana kadar bu çalışmalar pratikte kullanım alanı bulamamıştır [54]. Bulanık mantık daha sonra Hans Zimmermann tarafından karar destek sistemleri oluşturmak için kullanıldı. Bulanık mantık, "çok değerli mantık" veya "süreklili mantık" olarak da adlandırılabilir, bu alanda yaygın olarak kullanılmamaktadır [56].

1980'lerde, karar destek ve veri analizi için bulanık mantık uygulamalarının önemi Avrupa'da arttı ve uygulama ve araştırma girişimlerinde son teknoloji bulanık mantık teknolojileri oluşturulmuştur.

Japon işletmeleri, 1980'lerde Avrupa bulanık mantık uygulamalarından ilham aldıktan sonra kontrol mühendisliğinde bulanık mantığı kullanmaya başlamışlardır. Hitachi tarafından 1987'de piyasaya sürülen metro sisteminde ve 1983'te başlatılan bir su arıtma tesisinde Fuji Electric tarafından kullanılmıştır. Geleneksel donanımdaki ilk bulanık mantık algoritmaları sayısal olarak yetersiz performans gösterdiğinden, uygulamaların çoğu bulanık mantık donanımını bulundurmıştır.

Artımlı optimizasyon ve hızlı prototipleme bulanık mantık tarafından mümkün kılınsa da, sistemi yine de açıkça basittir. Sonuç olarak, pratikte tüm veri işleme ve akıllı kontrol sistemleri artık bulanık mantık kullanmaktadır. Mitsubishi duyurusuna göre, fotoğraf ve video ekipmanından şimdiye kadar yapılmış ilk bulanık sistem tabanlı arabaya kadar çok sayıda endüstriye yayılmıştır. Bulanık mantık, birçok kimyasal ve biyolojik sürece yardımcı olmuş ve Omron şirketine fabrika otomasyonu için 350'den fazla patent verilmiştir.

Avrupalı işletmeler çok önemli bir teknolojiyi Japonya'ya kaptırdıklarını fark ettikten sonra bulanık mantığı uygulamalarına dahil etme çabalarını artırdı. Günümüzde bulanık mantık, çok çeşitli endüstriyel otomasyon ve proses kontrol uygulamalarında ve ayrıca piyasadaki birçok üründe başarıyla kullanılmaktadır. Bu uygulamaların ticari başarısının ardından, bulanık mantık mühendislik camiasında yaygın bir destek kazanmış ve standart bir tasarım tekniği olarak benimsenmiştir [56].


Belirsizliklerin ifade edilmesi ve belirsizliklerle başa çıkmak için oluşturulan katı bir matematiksel düzen, o zamandan beri önemi giderek artan bulanık mantıktır. İyi bilindiği gibi, istatistik ve olasılık teorisinin temeli belirsizlikten ziyade kesinliktir. Ancak bireylerin yaşadığı bölgede pek çok bilinmeyen vardır. Bu nedenle, insanın sonuç oluşturma yeteneğini anlamak için belirsizliklerle çalışmak hayati önem taşımaktadır.

Bulanık mantık ilk olarak Amerika'da keşfedilmesine rağmen, teknoloji Amerika ve Avrupa'ya dönmeden önce Japonya'dan hızla ilerlemiştir. Japonya hala bulanık mantıkta büyük adımlar atmaktadır. "Fuzzy" terimi, basit bulanık kontrol ilkelerinin uygulandığı bağlamlarda bir pazarlama modası haline de gelmiştir [54].

### 3.2. BULANIK (FUZZY) KÜME TEORİSİ

Bulanık kümeler ve alt kümeler, bulanık mantığın temelidir. Geleneksel yönteme göre bir varlık kümenin ya üyesidir ya da değildir. Küme ile üyelik ilişkisi açısından varlık kümenin üyesi olduğunda (1), matematiksel olarak ifade edildiğinde kümenin üyesi olmadığında (0) değerini alır. Örneğin, 23 derecenin ortalama oda sıcaklığı olduğuna inanırsak, klasik küme teorisi 23 derecenin üzerindeki her şeyin sıcak olduğunu belirtir. Bu derecelerin sıcak kümesindeki üyelik dereceleri (1)'dir. 23 derecenin altındaki bir sıcaklık soğuk olarak kabul edilirken, sıcak kümenin bir üyesi (0)'dır. Soğuk kümeyi temel aldığımızda, bu değerler ters çevrilir.

Geleneksel küme gösteriminin bir gelişimi bulanık mantıktır. Bulanık varlıklar kümesindeki her varlığın bir üyelik derecesi vardır. Varlıklar, [0,1] arasında herhangi bir değerde üyelik derecesine sahip olabilir. Yukarıda verilen örneğe göre üyelik değeri, 14 derecelik bir sıcaklık için (0) ve 23 derecelik bir sıcaklık için (0,25) olabilir.



Klasik kümelerin aksine, bulanık kümeler, öğelerin  $[0, 1]$  arasındaki üyelik derecelerinde sınırsız değişikliklere izin verir. Bunlar, kesintisiz ve kesintisiz olarak çalışan eksiksiz bir üyelik dereceleri setidir. Keskin kümelerde soğuk-sıcak, hızlı-yavaş, aydınlık-karanlık gibi ikili değişkenler, bulanık mantıkta gerçek dünyayı taklit etmek için biraz soğuk, biraz ılık ve biraz karanlık gibi esnek niteleyicilerle yumuşatılır. En önemli ayırım, bilgi kaynağında küme üyeliği için kesin olarak tanımlanmış önkoşullar olmadığı için böyle bir çerçevede daha fazla probleme ve rastgele değişkene kolayca erişilebilir olmamasıdır [58].

### 3.2.1 Bazı Kavram Ve Terimler

Matematiksel olarak belirsiz olan "parlak yeşil", "soğuk hava" veya "yükse hız" gibi değer yargıları içeren "bulanık(fuzzy) dil niteleyicileri" kullanarak, insan beyni sağduyulu yargılar oluşturabilir ve sonuçlar çıkarabilir. Bulanık mantık, esasen, mutlak doğru veya mutlak yanlış tanımlarından ziyade, insan zihninde ve doğasında bulunan yaklaşıklık ve kesinsizliğin yanı sıra, doğal doğruluk veya yanlışlık derecelerinin tanımlarını kullanır. Sonuç olarak, bulanık mantık, günlük konuşmada kullanılan belirsiz terimlerin tanımlanmasına ve bu dilsel niteleyicilerin insan benzeri çıkarım prosedürlerini gerçekleştirmek için kullanılmasına izin verir. Bu yaklaşımda, bulanık mantık, insan muhakeme ve karar verme yeteneklerini bilgisayarlara ve dolayısıyla kontrol sistemlerine aktarmak için pratik bir yol sunar.

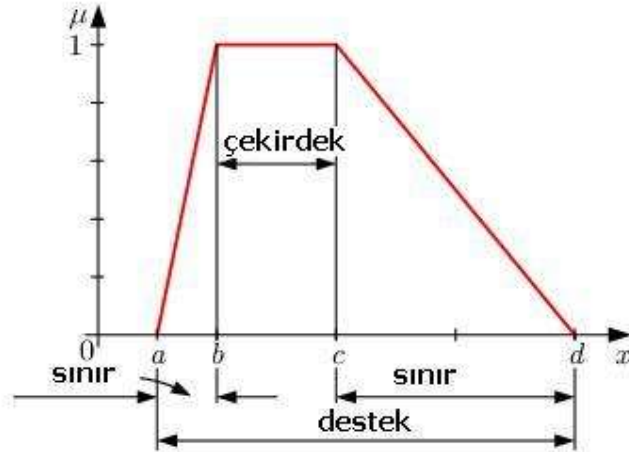
Bulanık küme teorisine göre bir eleman kısmi olarak bir kümeye ait olabilir. Üyelik derecesi olarak bilinen üyelik fonksiyonunun değeri bire eşitse,  $X$  elemanı tamamen bulanık kümeye aittir. Bu değer 0 ise, bulanık küme  $X$ 'i içermez. Üyelik derecesi sıfır ile bir arasında ise  $X$ , bulanık kümenin kısmi bir üyesidir. Kesin terimi bulanık kümelerle ilgili literatürde bulanık olmayan nicelikler için kullanılan yaygın bir terimdir. Örnek olarak, kesin sayı, kesin küme verilebilir [59].

Bulanık küme; X uzayından birim aralığına bir dönüşümü olarak ifade edilebilen  $\mu_A(x)$  üyelik fonksiyonları ile X evrensel tanım kümesinde A bulanık kümesini tanımlar:

$$\mu_A(x) : X \rightarrow [0,1] \quad (3.1)$$

F(X), X uzayına dahil bütün bulanık kümeleri ifade eder. Eşitlikteki  $\mu_A(x)$  üyelik fonksiyonudur.

Üyelik derecesi, belirli bir girdi değerinin dilsel bir değişkenin belirli bir terimine ne kadar karşılık geldiğini belirler. Üyelik fonksiyonu veya bulanık sayı, bir fonksiyon olarak tüm dilsel değişken için bu değerleri tanımlamak için kullanılan terimdir [59]. Başka bir deyişle, üyelik fonksiyonu, X'in her elemanına 0 ile 1 arasında bir üyelik derecesi atar.



Şekil 3.2. Üyelik fonksiyonun bazı özellikleri [61].

Bir bulanık kümenin desteği (support), X'deki bütün x noktalarının  $(\mu_A(x)) > 0$  olduğu kümedir [62].

$$\text{destek}(A) = \{x \mid \mu_A(x) > 0\} \quad (3.2)$$

Bir bulanık kümenin çekirdeği (core),  $X$ 'deki bütün  $x$  noktalarının  $(\mu_A(x)) = 1$  olduğu kümedir [62].

$$\text{çekirdek}(A) = \{x \mid \mu_A(x) = 1\} \quad (3.3)$$

Bu bulanık küme, 1 değerine sahip en az bir üyeye sahipse normal (olağan) bir bulanık kümedir [63].  $X$ 'de  $\mu_A(x) = 1$  ile sadece bir noktayı destekleyen  $A$  bulanık kümesi bulanık tekil (fuzzy singleton) olarak adlandırılır [62]. Bunlar dışında kalan bulanık kümeler ise normal dışı (subnormal) bulanık kümeler denir [63].

Bir  $A$  bulanık kümesinin çapraz geçiş noktaları (crossover points),  $\mu_A(x) = 0.5$  olduğu  $x \in X$  noktalarıdır [62].

$$\text{çaprazgeçiş}(A) = \{x \mid \mu_A(x) = 0.5\} \quad (3.4)$$

Dışbükey bulanık kümeler (convex fuzzy sets), üyelik değerleri monoton olarak artan, monoton olarak azalan veya belirli üyelik değerlerinde 1'e ulaştıktan sonra monoton olarak azalan kümelerdir [63]. Normal ve dışbükey bir bulanık kümenin bant genişliği veya genişlik, geçiş noktaları arasındaki mesafe ile belirlenir [60].

$$\text{bantgen}(A) = |x_2 - x_1|; \mu_A(x_1) = \mu_A(x_2) = 0.5 \quad (3.5)$$

Bir  $A$  bulanık (fuzzy) kümesinde eğer (if) üyelik fonksiyonu belirli bir  $x = c$  noktasına göre sağda ve solda eşit dağılımlı ise bu küme simetriktir [60].

$$\mu_A(c+x) = \mu_A(c-x) \quad ; \quad \text{bütün } x \in X \quad \text{için} \quad (3.6)$$

Bir A bulanık kümesi; eğer  $\lim_{x \rightarrow -\infty} \mu_A(x) = 1$  ve  $\lim_{x \rightarrow +\infty} \mu_A(x) = 0$  ise soldan açık; eğer  $\lim_{x \rightarrow -\infty} \mu_A(x) = 0$  ve  $\lim_{x \rightarrow +\infty} \mu_A(x) = 1$  ise sağdan açık; eğer  $\lim_{x \rightarrow -\infty} \mu_A(x) = 0$  ve  $\lim_{x \rightarrow +\infty} \mu_A(x) = 0$  ise kapalı olarak adlandırılır [60].

### 3.2.2. Bulanık Küme (Fuzzy Set) İşlemleri

#### 3.2.2.1. Kapsama (Alt Küme)

Küme A, küme B'nin alt kümesidir; sadece bütün x'ler için  $\mu_A(x) \leq \mu_B(x)$  ise küme A, küme B tarafından içerilmektedir [62].


$$A \subseteq B \Leftrightarrow \mu_A(x) \leq \mu_B(x) \quad (3.7)$$

#### 3.2.2.2. Birleşim (Union)

A ve B bulanık kümelerinin birleşimi olan C bulanık kümesi  $C = A \cup B$  ya da  $C = A \text{ VEYA } B$  olarak yazılır ve 3.8'deki denklem üyelik fonksiyonları arasındaki bağlantıyı sağlar [62]. Aynı şekilde T-conorm işlemleri olarak da anılır [64].

$$\mu_C(x) = \max(\mu_A(x), \mu_B(x)) = \mu_A(x) \vee \mu_B(x) \quad (3.8)$$

- (a) maksimum :  $\max(\mu_A(x), \mu_B(x))$   
(b) olasılıklı toplam :  $\mu_A(x) + \mu_B(x) - \mu_A(x) \cdot \mu_B(x)$   
(c) sınırlı toplam :  $\min(1, \mu_A(x) + \mu_B(x))$




Şekil 3.3. Sık kullanılan birleşim (VEYA) operatörleri [64].

### 3.2.2.3. Kesişim (Intersection)

A ve B bulanık kümelerinin birleşimi olan C bulanık kümesi  $C = A \cap B$  ya da  $C = A \text{ VE } B$  olarak yazılır ve 3.9'daki denklem üyelik fonksiyonları arasındaki bağlantıyı ifade eder [62]. Aynı şekilde T-norm işlemleri olarak da anılır [64].

$$\mu_C(x) = \min(\mu_A(x), \mu_B(x)) = \mu_A(x) \wedge \mu_B(x) \quad (3.9)$$

- (a) minimum :  $\min(\mu_A(x), \mu_B(x))$   
(b) çarpım :  $\mu_A(x) \cdot \mu_B(x)$   
(c) sınırlı çarpım :  $\max(0, \mu_A(x) + \mu_B(x) - 1)$



Şekil 3.4. Sık kullanılan kesişim (VE) operatörleri [64].



### 3.2.2.4. Tmleyen (Complement)

AŖağıdaki denklem,  $\bar{A}$  sembol ile temsil edilen bir bulanık A kmesinin tmleyenini temsil eder.

$$\mu_{\bar{A}}(x) = 1 - \mu_A(x) \quad (3.10)$$

### 3.2.3 Bazı Bulanık Kme Kuralları

Bulanık kmelerdeki bazı kurallar aŖağıda verilmiŖtir.

- Eęer  $\forall x \in X$  iin  $\mu_A(x) = \mu_B(x)$  ise  $A = B$  'dir.
- Eęer  $\forall x \in X$  iin  $\mu(x) = 0$  ise A kmesi boŖ kmedir.
- Evrensel kme; eęer  $\forall x \in X$  iin  $\mu_A(x) = 1$  ise A kmesi X uzayına eŖittir.
- Bir A bulanık(fuzzy) kmesinin, boŖ bir bulanık kme ile birleŖimi kendisine eŖittir ( $A \cup 0 = A$ ).
- Bir A bulanık(fuzzy) kmesinin evrensel kme ile birleŖimi evrensel kmeye eŖittir ( $A \cup X = X$ ).
- Bir A bulanık kmesinin boŖ kme ile keŖiŖimi boŖ kmedir( $A \cap 0 = 0$ ).
- Bir A bulanık kmesinin evrensel kme ile keŖiŖimi A bulanık kmesine eŖittir ( $A \cap X = A$ ).
- İki kme keŖiŖimi kmelerin altkmesi ve kmeler de iki kme birleŖiminin alt kmesidir ( $A \cap B \subseteq A \subseteq A \cup B$ ).
- Bulanık kme iŖlemlerinde birleŖebilirlik vardır ( $A \cap (B \cup C) = (A \cap B) \cup (A \cap C)$  ve  $A \cup (B \cap C) = (A \cup B) \cap (A \cup C)$ ).
- $(A \cup B)' = A' \cap B'$  ve  $(A \cap B)' = A' \cup B'$  (De Morgan kuralı)
- Bir A bulanık kmesi ve tmleyeninin keŖiŖimi boŖ kme deęildir ( $A' \cap A \neq 0$ ).
- Bir A bulanık kmesi ve tmleyeninin birleŖimi evrensel kme deęildir ( $A' \cup A \neq X$ ).

- Bulanık küme işlemlerinde değişebilirlik vardır ( $A \cap B = B \cap A$  ve  $A \cup B = B \cup A$ ).
- Bir bulanık A kümesinin kendisi ile kesişim ve birleşiminin A bulanık kümesidir ( $A \cup A = A$  ve  $A \cap A = A$ ).
- Bulanık küme işlemlerinde dağıtılabirlik vardır ( $A \cap (B \cup C) = (A \cap B) \cup (A \cap C)$  ve  $A \cup (B \cap C) = (A \cup B) \cap (A \cup C)$ ) [59].

### 3.2.4. Üyelik Fonksiyonları

#### 3.2.4.1. Üçgen Üyelik Fonksiyonu

Denklem 3.11, şekil 3.5a'da gösterilen  $\{a,b,c\}$  parametreleriyle bir üçgen üyelik fonksiyonunu tanımlar [62].

$$y = \text{üçgen}(x; a, b, c) = \begin{cases} 0, & x \leq a \\ (x - a)/(b - a), & a \leq x \leq b \\ (c - x)/(c - b), & b \leq x \leq c \\ 0, & c \leq x \end{cases}$$

(3.11)

Min-maks işlemleri kullanılarak, denklem 3.11'deki ifade aşağıdaki denklemle de ifade edilebilir [60].

$$y = \text{üçgen}(x; a, b, c) = \max\left(\min\left(\frac{x - a}{b - a}, \frac{c - x}{c - b}\right), 0\right) \quad (3.12)$$

Üçgen üyelik fonksiyonunun üç köşesinin üç x koordinatı,  $a < b < c$  olmak üzere  $\{a, b, c\}$  parametreleri tarafından belirlenir [62].

### 3.2.4.2. Yamuk Üyelik Fonksiyonu

Denklem 3.13, şekil 3.5b'da gösterilen  $\{a,b,c,d\}$  parametreleriyle bir yamuk üyelik fonksiyonunu tanımlar [62].

$$y = \text{yamuk}(x; a, b, c, d) = \begin{cases} 0, & x \leq a \\ (x-a)/(b-a), & a \leq x \leq b \\ 1, & b \leq x \leq c \\ (d-x)/(d-c), & c \leq x \leq d \\ 0, & d \leq x \end{cases} \quad (3.13)$$

3.13 numaralı eşitlikteki ifade min-max işlemleri kullanılarak aşağıdaki eşitlik ile de gösterilebilir [60].

$$y = \text{yamuk}(x; a, b, c, d) = \max\left(\min\left(\frac{x-a}{b-a}, 1, \frac{d-x}{d-c}\right), 0\right) \quad (3.14)$$

Yamuk üyelik fonksiyonunun dört köşesinin x koordinatı,  $a < b < c < d$  olmak üzere  $\{a,b,c,d\}$  parametreleri tarafından belirlenir.

Üçgen ve yamuk üyelik fonksiyonları, basit formülasyonları ve yüksek hesaplama verimliliği nedeniyle, özellikle gerçek zamanlı uygulamalarda yaygın olarak kullanılmaktadır. Bu fonksiyonlar, düz doğru parçalarından oluştuğu için parametrelerle gösterilen köşelerde düzgün değildir [62].

### 3.2.4.3. Gaussian Üyelik Fonksiyonu

Denklem 3.15, şekil 3.5c'da gösterilen  $\{c, \sigma\}$  parametreleriyle bir gaussian üyelik fonksiyonunu tanımlar [62].

$$\text{gaussian}(x; c, \sigma) = e^{-\frac{(x-c)^2}{2\sigma}} \quad (3.15)$$

Üyelik fonksiyonunun genişliğine  $\sigma$  ve merkezine  $c$  tarafından karar verilirken, tam gauss fonksiyonu  $\{c, \sigma\}$  parametreleri tarafından yönetilir.

#### 3.2.4.4. Genelleştirilmiş Çan Üyelik Fonksiyonu

Denklem 3.16,  $b$ 'nin genellikle pozitif bir sayı olduğu  $a$ ,  $b$  ve  $c$  parametreleriyle genelleştirilmiş bir çan üyelik fonksiyonunu tanımlar. Bu fonksiyon şekil 3.5'de gösterilmiştir [62].

$$\text{çan}(x; a, b, c) = \frac{1}{1 + \left| \frac{(x - c)}{a} \right|^{2b}} \quad (3.16)$$

Cauchy üyelik fonksiyonu, olasılık teorisinde Cauchy dağılımının doğrudan bir genellemesi olan bu fonksiyon için başka bir isimdir [62].

Bulanık kümeler tipik olarak yumuşak geçiş ve basit denklem parametreleri ile Gaussian ve çan üyelik fonksiyonları kullanılarak tanımlanır. Gaussian üyelik fonksiyonu ile karşılaştırıldığında, çan üyelik fonksiyonunun daha fazla parametresi vardır. Gaussian üyelik fonksiyonu, çekirdeğin genişliğinin değiştirilebilmesi ve çapraz noktaların eğimlerini değiştirmek için ek bir parametre kullanılabilmesi ile hassas ayarlama yetenekleri fonksiyona üstünlük sağlamıştır [60].

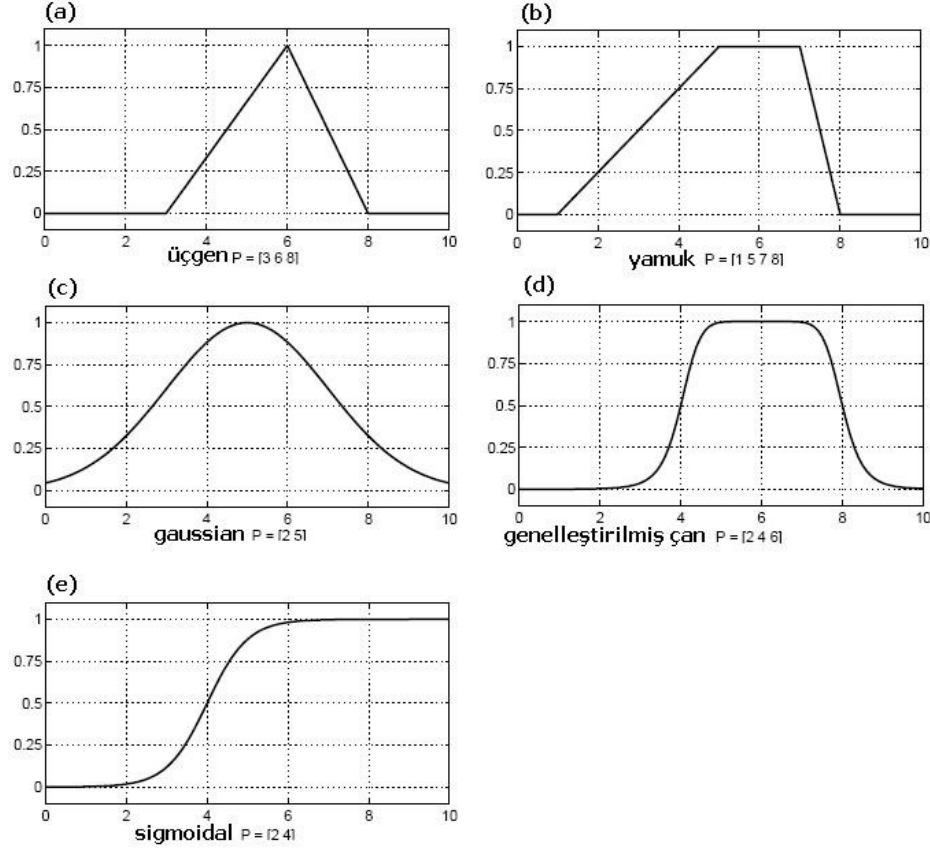
#### 3.2.4.5. Sigmoid Üyelik Fonksiyonları

Çan ve Gaussian üyelik fonksiyonları yumuşak geçişli fonksiyonlardır. Ancak simetrikler ve simetrik olmayan üyelik fonksiyonlarını tanımlamak için kullanılamazlar. Bu durumlarda sigmoid üyelik fonksiyonu veya çok sayıda sigmoid üyelik fonksiyonunun birleştirilmesiyle üretilen üyelik fonksiyonu kullanılır.

Denklem 3.17, şekil 3.5'e'de gösterilen  $\{a, c\}$  parametreleriyle bir sigmoid üyelik fonksiyonunu tanımlar [62].

$$\text{sig}(x;a,c) = \frac{1}{1 + e^{-a(x-c)}} \quad (3.17)$$

$x=c$ 'deki çapraz geçiş noktasının eğimi burada  $a$  tarafından kontrol edilir. Üyelik fonksiyonu, bu değişkenin işaretine bağlı olarak sağa veya sola açık olabilir.



Şekil 3.5. Üyelik fonksiyonları [57].

### 3.3. BULANIK YARGILAMA

#### 3.3.1 Bulanık Eğer-İse Kuralları

Bulanık kural, bulanık içerik veya bulanık koşullu ifadeler olarak da bilinen bulanık eğer-ise kuralına göre “eğer  $x$  A ise, o zaman  $y$  B’dir”; burada A ve B, sırasıyla X ve Y uzaylarında bulanık kümeler olarak belirtilen dilsel değişkenlerdir. ve. Tipik olarak,

"x A" ifadesi koşul (antecedent) olarak anılırken, "y B'dir" ifadesi sonuç (consequence) olarak anılır.

Günlük dilsel ifadelerimizden bulanık eğer-ise kurallarına bazı örnekler aşağıda verilmiştir [62].

- Eğer hacim yüksek ise, basınç küçüktür.
- Eğer hava sisli ise, görüş mesafesi kısadır.
- Eğer yok kaygan ise, freni yavaş yap.

Hacmin yüksek ve basıncın düşük olduğu örnekleme, durumda hacmin 0 ile 1 arasında bir sayı olduğu ve koşulun 0 ile 1 arasında tek bir sayı veren bir temsil olduğu belirtilmelidir. Basınç da bulanık küme ile ifade edilir. Bu nedenle bulanık küme B'nin çıkış değişkeni y'ye atanması sonuçtur [57].

Bir sistemin analiz ve modellenmesinde bulanık eğer-ise kurallarını kullanmadan önce bazen  $A \rightarrow B$  şeklinde kısaltılan "eğer x A ise, y B'dir" ifadesi ile ne anlatılmak istendiği biçimlendirilmelidir. Aslında bu, "x" ve "y" değişkenleri arasındaki ifadeyi gösterir ki bu bulanık eğer-ise kuralını  $X \times Y$  çarpım uzayında R ikili bulanık ilişkisi olarak tanımlar. Genel olarak  $A \rightarrow B$  kuralını yorumlamak için iki yol vardır. Eğer  $A \rightarrow B$ 'yi A, B ile ortak şekilde değerlendirirsek:

$$R = A \rightarrow B = A \times B = \int_{X \times Y} \mu_A(x) \tilde{*} \mu_B(y) / (x, y) \quad (3.18)$$

$\tilde{*}$  operatörünün kesişimi gösterdiği ifadeye ulaşılır. Diğer yandan  $A \rightarrow B$ , A B'yi gerektir şeklinde yorumlarsak, ifade aşağıdaki iki formülden biri şeklinde yazılabilir.

$$R = A \rightarrow B = \bar{A} \cup B \quad (3.19)$$

$$R = A \rightarrow B = \bar{A} \cup (A \cap B) \quad (3.20)$$

Bu denklemler farklı görünseler de, A ve B iki değerli mantık önermeleri olduğunda, her ikisinde bilinen  $A \rightarrow B \equiv \overline{A} \cup B$  özdeşliğine indirgenir [62].

### 3.3.2. Bulanık Yargılama

Olgular olarak bilinen bir dizi bulanık eğer-ise kuralından çıkarımlar yapılırken, genellikle yaklaşık yargı olarak da adlandırılan bulanık yargı adı verilen bir çıkarım yaklaşımı kullanılır. Geleneksel iki değerli mantığın temel çıkarsama kuralı,  $A \rightarrow B$  sembolüyle gösterilen ve A önermesinin doğruluğundan B önermesinin doğruluğunu çıkarmamıza olanak veren doğrulamadır (modus ponens). Örnek olarak:

Terim 1 (olgu):	$x \text{ A' } \text{dir,}$
Terim 2 (kural):	Eğer $x \text{ A ise, } y \text{ B' } \text{dir,}$
Sonuç:	$y \text{ B' } \text{dir.}$

Şekil 3.6. Örnek 1

Ancak insanlar olarak bizim çoğu yargılamamızda durum doğrulama bir yaklaşım biçimi ile uygulanır.  $A'$  'nün A'ya yakın ve  $B'$  'nün B'ye yakın iken değerlendirmeyi yapacak olursak:

Terim 1 (olgu):	$x \text{ A' } \text{dür,}$
Terim 2 (kural):	Eğer $x \text{ A ise, } y \text{ B' } \text{dir,}$
Sonuç:	$y \text{ B' } \text{dür.}$

Şekil 3.7. Örnek 2

$A, A', B$  ve  $B'$  uygun uzayların bulanık kümeleri iken, yapılan bu çıkarım “yaklaşık yargılama” veya “bulanık yargılama” olarak adlandırılır. Durum doğrulamasını belirli bir örnek olarak ele aldığı için "genelleştirilmiş durum doğrulaması" olarak da bilinir.

$A$  ve  $A'$   $X$ 'in,  $B$ 'de  $Y$ 'nin bulanık kümeleri olsun.  $A \rightarrow B$  bulanık çıkarımının  $X \times Y$ 'deki  $R$  bulanık ilişkisi olarak gösterildiğini varsayalım. Buradan yola çıkarak,  $B$  bulanık kümesi, “ $x \in A'$ ” olgusu ve “eğer  $x \in A$  ise,  $y \in B$ ’dir” kuralı ile oluşturulur ve aşağıdaki eşitlik ile tanımlanır.

$$\mu_{B'}(y) = \max_x \min[\mu_{A'}(x), \mu_R(x, y)] = V_X[\mu_{A'}(x) \wedge \mu_R(x, y)] \quad (3.21)$$

Bu aşamadan sonra uygun ikili bulanık ilişkiler olarak tanımlanmış  $A \rightarrow B$  bulanık içeriği ile sağlanan sonuçları hesaplamak için bulanık yargılamanın çıkarım yöntemi kullanılabilir.

Formül, en basit durum olan "tek koşullu bir kural" için denklem 3.21'dekiyle aynıdır. Bu denklem, daha fazla sadeleştirmeden sonra aşağıdaki durum haline gelir.

$$\mu_{B'}(y) = V_X[\mu_{A'}(x) \wedge \mu_A(y)] \wedge \mu_B(y) = \omega \wedge \mu_B(y) \quad (3.22)$$

Başka bir deyişle, uyum derecesi öncelikli olan  $\omega$ ,  $\mu_{A'}(x) \wedge \mu_A(y)$  işleminin maksimum değeri olarak bulunur. Sonuç olan  $B'$ 'nin üyelik fonksiyonu  $B$ 'nin  $\omega$  ile örtüştürülmüş üyelik fonksiyonuna eşittir. Sezgisel değerlendirerek,  $\omega$ , kuralın koşuluna ne kadar inanıldığını ölçüm olarak gösterir. Ölçüm, eğer-ise kuralları ile dağıtılarak sonuçta oluşacak inanç derecesinin veya sonucun üyelik fonksiyonunun  $\omega$ 'yi aşmamasını sağlar.

"Çok-koşullu-çok-kurallar" için, bulanık yargı veya yaklaşık yargı, genelleme yapılarak dört aşamaya ayrılır.

Uygunluk derecesi: Her koşulun üyelik derecesine göre uygunluk derecesini belirlemek için bulanık kuralların koşulları bilinen gerçeklerle karşılaştırılır.

Tetikleme Gücü: Kuraldaki koşulun hangi bölümünün karşılandığını gösteren bir derece olan tetikleme gücü, bulanık AND veya OR operatörleri kullanılarak bir



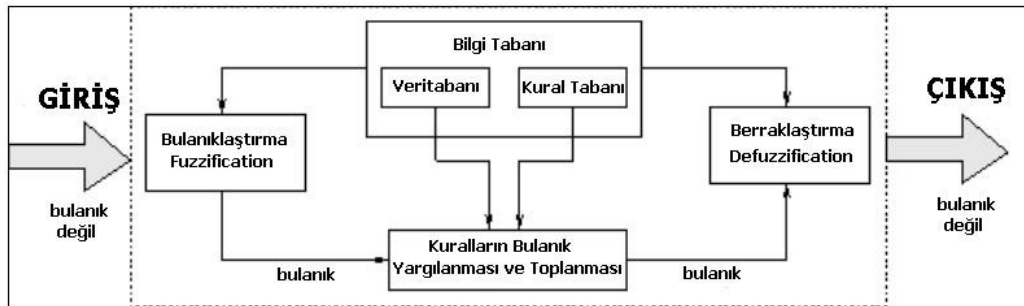
kuraldaki koşulların üyelik derecelerine göre uygunluk derecelerinin birleştirilmesiyle oluşturulur.

Nitelikli sonuç üyelik fonksiyonları: Nitelikli sonuç üyelik fonksiyonu, sonuç üyelik fonksiyonunda kuralın tetikleme kuvveti uygulanarak üretilir.

Genel çıktı üyelik fonksiyonu: genel çıktı üyelik fonksiyonu, tüm niteleyen sonuç üyelik fonksiyonlarının birleştirilmesiyle oluşturulur.

### 3.4. BULANIK ÇIKARIM SİSTEMLERİ

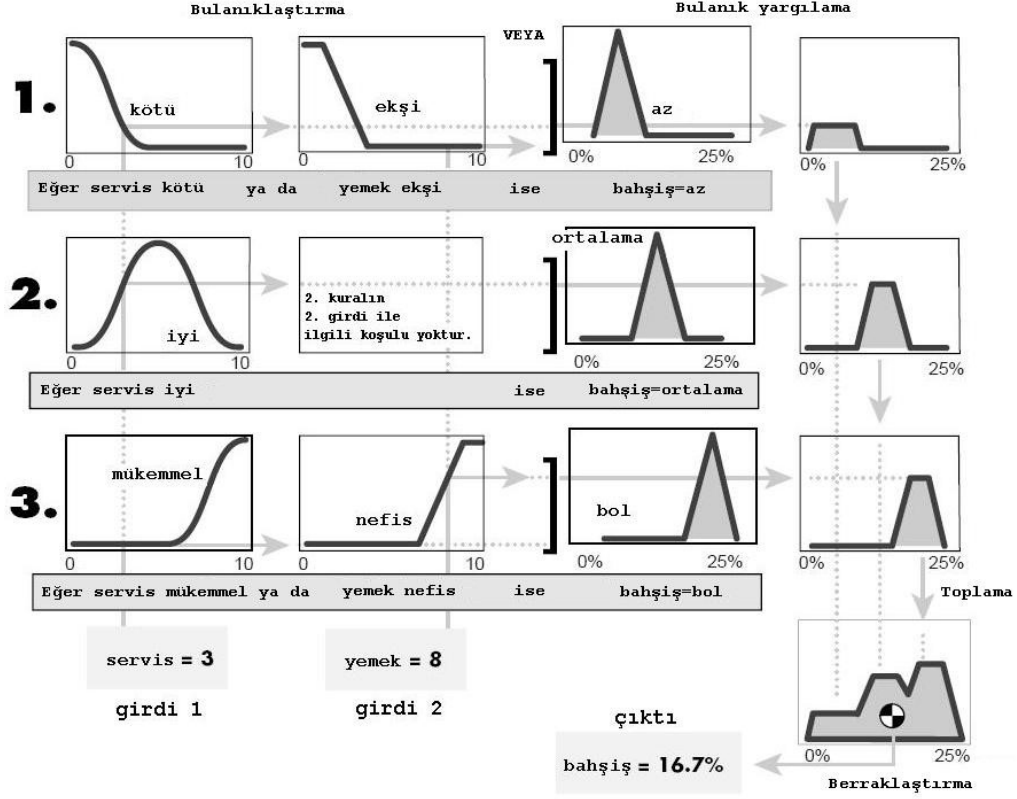
Verilen girdiler ve çıktılar arasındaki eşleştirmeyi kesin ve açık bir şekilde açıklamak için bulanık mantığı kullanma uygulaması, bulanık çıkarım olarak bilinir. Eşleme, daha sonra kararların alınabileceği veya modellerin bulunabileceği bir temel sunar. Üyelik fonksiyonları, bulanık mantık işlemleri ve eğer-ise kuralları dahil olmak üzere yukarıda tartışılan her şey, bulanık çıkarım sürecinin bir parçasıdır. Bulanık çıkarım sistemleri üç farklı şekilde gelir. Mamdani, Takagi-Sugeno ve Tsukamoto bulanık modelleri bunlardır.



Şekil 3.6. Bulanık çıkarım sistemi [65].

Otomatik kontrol, veri kategorizasyonu, karar analizi, uzman sistemler ve bilgisayarlı görme alanlarının tümü, bulanık çıkarım sistemlerinin kullanımıyla başarıya ulaşmıştır. Bulanık çıkarım sistemleri, disiplinler arası yapıları nedeniyle bulanık kural tabanlı sistemler, bulanık uzman sistemler, bulanık modelleme, bulanık ilişkisel

bellek, bulanık mantık denetleyicileri ve sadece düz bulanık sistemler gibi çeşitli isimlerle bilinir.




Şekil 3.7. Bir örnek üzerinden Mamdani bulanık çıkarım sisteminde adımlar [57].

Şekil 3.9'a göre, bulanıklaştırma, bir bulanık çıkarım sisteminde gerçek değişkenleri dilsel değişkenlere dönüştürmek için üyelik fonksiyonlarının ve bulanık kümelerin kullanıldığı süreçtir. Bilgi tabanından türetilen eğer-ise kurallarındaki her bir kural için her bir koşul bileşeninin ne kadarının girdileri bulanıklaştırarak karşılandığını belirlemek mümkündür. Belirli bir kuralın koşulunun birden fazla ögesi varsa, kuralın koşul sonucu olarak işlev gören tek bir tamsayı üretmek için bulanık işlemlere (VE, VEYA) tabi tutulur. Çıktı işlevi, elde edilen sayı kullanılarak ayarlanır. Bulanık küme toplama, her bir kuralın çıktısını temsil eden bulanık kümeleri birleştirme işlemidir. Netleştirme olarak bilinen bulanık kümeden temsili sayısal değer çıkarma işlemi daha sonra tamamlanır [57].

### 3.4.1. Mamdani Bulanık Çıkarım Sistemi

İlk olarak uzman operatörlerin ürettiği bir dizi dilsel kontrol kuralı kullanılarak bir buhar motoru ve kazan kombinasyonunun Mamdani bulanık çıkarım sistemi ile kontrol edilmesinde önerilmiştir. Şekil 3.10, 3 kurallı Mamdani bulanık çıkarım sisteminin toplam çıktı üretmek için iki sayısal girdiyi nasıl kullandığını göstermektedir. Aşağıdaki beş berraklaştırma tekniği değerlendirilmiştir [62].



Şekil 3.8. Sayısal çıktı elde etmek için kullanılan farklı berraklaştırma yöntemleri [62].

#### 3.4.1.1. Alanın kitle merkezi

Alan ağırlık merkezi (COA) [62] yaklaşımı, Z uzayında birleştirilmiş çıktı üyelik fonksiyonunu temsil eden A kümesinin ağırlık merkezini belirler. Berraklaştırma işleminin sonucu, Z uzayında bulunan ağırlık merkezi değeri tarafından belirlenir [60].

$$Z_{COA} = \frac{\int \mu_A(z)zdz}{\int \mu_A(z)dz} \quad (3.23)$$

Üyelik fonksiyonu  $\mu_A(z)$ , denklem 3.23'teki toplam sonuçtur. Yaygın olarak kullanılan bir berraklaştırma aracı olan bu teknik, olasılık dağılımındaki tahmin edilen değerlerin nasıl hesaplandığına benzer [62].

### 3.4.1.2. Alanın Orta Noktası

Alanın orta noktası (Bisector of Area-BOA)  $Z_{BOA}$  olarak gösterilir.  $\alpha = \min\{z \mid z \in Z\}$  ve  $\beta = \max\{z \mid z \in Z\}$  ise,  $Z_{BOA}$  3.24'deki matematiksel ifadeyi sağlar.

$$\int_{\alpha}^{Z_{BOA}} \mu_A(z) dz = \int_{Z_{BOA}}^{\beta} \mu_A(z) dz \quad (3.24)$$

### 3.4.1.3. Maksimumun Ortası

Maksimumun ortası yöntemi (Mean of Maximum-MOM)  $Z_{MOM}$  ile gösterilir. Üyelik fonksiyonun maksimum  $\mu^*$  değerine ulaştığı  $z$  noktalarının ortalamasıdır. Matematiksel olarak:

$$Z_{MOM} = \frac{\int_{z'} dz}{\int_{z'} dz}, \quad z' = \{z \mid \mu_A(z) = \mu^*\} \quad (3.25)$$

şeklinde verilebilir. Özel olarak  $\mu_A(z)$ 'nin  $z = z^*$ 'de tek maksimumda değeri varsa  $Z_{MOM} = z^*$ 'dir. Ayrıca eğer  $\mu_A(z)$  maksimuma  $z \in [z_{sol}, z_{sağ}]$  olduğunda ulaşıyorsa  $Z_{MOM} = (z_{sol} + z_{sağ})/2$  olarak ifade edilebilir.

### 3.4.1.4. Maksimumun En Küçüğü

$Z_{SOM}$  ile gösterilen maksimumun en küçüğü yöntemi (Smallest of Maximum-SOM), üyelik fonksiyonunun en büyük olduğu en küçük  $z$ -noktasını veren yaklaşımdır.

### 3.4.1.5. Maksimumun En Büyüğü

$Z_{LOM}$  ile gösterilen maksimumun en büyüğü yöntemi (Largest of Maximum-LOM), üyelik fonksiyonunun en büyük olduğu en büyük z-noktasını veren yaklaşımdır.

SOM ve LOM yaklaşımları, elde edilmesi en önemli olan değerde sapmalar oluşturabildikleri için diğer üç berraklaştırma yöntemi kadar sık kullanılmazlar [60].

Uzmanlaşmış bilgi toplamak için Mamdani tekniği çok yaygın olarak kullanılmaktadır. İnsan düşünce mantığını kullanarak daha anlaşılır bir uzmanlık tanımı sağlar [66]. Özel donanım desteği olmadığında, buradaki beş berraklaştırma işlemini tamamlamak için gerekli hesaplama uzun zaman almaktadır. Ayrıca, çalışmalar öncelikle deneysel bulgulara dayanmaktadır çünkü kolaylıkla sıkı matematiksel analizlerle ilişkilendirilemez. Bu hiç berraklaştırma ihtiyacı istemeyen başka tipteki bulanık çıkarım sistemlerinin önerilmesine neden olmaktadır. Burada bunlardan ikisi tartışılacaktır. Buna ek olarak, Yager&Filer ve Rukler&Glesner gibi daha uyarlanabilir netleştirme teknikleri bulunabilir [62].

### 3.4.2. Sugeno Bulanık Çıkarım Sistemi


Takagi, Sugeno ve Kang, giriş ve çıkış veri kümelerinden bulanık kurallar oluşturmak için metodik bir yöntem sağlamak amacıyla Sugeno bulanık modelini (bazen TSK bulanık modeli olarak adlandırılır) önermiştir. A ve B'nin koşullu bulanık kümeler olduğu ve  $z = f(x, y)$ 'nin sonuç bölümünde standart bir fonksiyon olduğu tipik bir Sugeno bulanık model bulanık kural yapısı;

eğer(if) x, A VE y, B ise(then),  $z = f(x, y)$  'dir,

şeklindedir.

Tipik olarak,  $f(x, y)$ , x ve y girdi değişkenlerinden oluşan bir polinomdur, ancak modelin çıktısını kuralın bulanık sınırı içinde doğru bir şekilde yakaladığı sürece

herhangi bir fonksiyon olabilir.  $f(x,y)$  birinci dereceden bir polinom ise, bulanık çıkarım sistemi "birinci dereceden Sugeno bulanık modeli" olarak bilinir. F fonksiyonu sabit ise "sıfır dereceli Sugeno bulanık modeli" olarak adlandırılır. Bu, her bir kural koşulunun sabit merkezindeki bir adım fonksiyonu ile tanımlandığı bir Tsukamoto bulanık çıkarım sisteminin veya her bir kural koşulunun bir bulanık tekil üyelik fonksiyonu ile belirlendiği bir Mamdani bulanık çıkarım sisteminin özel bir örneği olarak görülebilir.




Şekil 3.9. Sugeno bulanık modeli [67].

Birinci derece Sugeno bulanık modelinin bulanık yargı prosedürü Şekil 3.11'de gösterilmiştir. Mamdani modeli zaman alıcı bir berraklaştırma süreci gerektirir, ancak her kural sayısal bir çıktı verdiği için, bunun yerine "ağırlıklı ortalama" kullanılarak tam çıktı elde edilebilir [62].

Sugeno yaklaşımı, hesaplama verimliliği ve optimizasyon ve uyarlamalı tekniklerle uyumluluğu nedeniyle, doğrusal olmayan dinamik sistemlerin kontrol sorunları için özellikle çekicidir. [61].

### 3.4.3. Tsukamoto Bulanık Çıkarım Sistemi

Her eğer-ise (if-then) kuralının sonucu, kural yapısının Mamdani bulanık sistemiyle aynı olduğu Tsukamoto bulanık modellerinde tek yönlü büyüyen veya azalan (monotonik) üyelik fonksiyonuna sahip bir bulanık küme ile temsil edilir [59, 62]. Sonuç olarak, her kuralın çıktısı, kuralın tetikleme gücü tarafından sağlanan sayısal bir değerdir. Nihai çıktıyı belirlemek için her kuralın sonuçlarının ağırlıklı ortalaması kullanılabilir. Şekil 3.12 iki giriş, iki kuralın bulanık(fuzzy) yargısına bir örnek teşkil eder.



Şekil 3.10. Tsukamoto bulanık modeli [67].

Her kuralın çıktısı sayısal olduğu için, Tsukamoto bulanık modelinde zaman alıcı netleştirme süreçleri yerine ağırlıklı ortalama yaklaşımı kullanılır. Ancak Mamdani ve Sugeno daha belirgin ve net olduğu için bu model o kadar sık kullanılmamıştır [62].

### 3.5. BULANIK MODELLEME

Bulanık modelleme, bir bulanık çıkarım sisteminde beklenen davranışa ulaşmayı sağlayacak parametrelerin tanımlanması işidir [64]. Yani, genel olarak bulanık çıkarım sistemleri hedef sistemin bilinen geçmiş davranışları esas alınarak tasarlanır. Bu sayede bulanık sistemden hedef sisteminin davranışlarını taklit etmesi beklenir [62].

Bulanık modelleme süreci, dilsel ve sayısal gereksinimlerden dolayı modelin doğruluğu ve yorumlanabilirliği arasındaki ters ilişki ile başa çıkmak zorundadır. Başka bir deyişle, model mümkün olduğu kadar çok sözel betimleme gücünü korurken yüksek hassasiyetle sayısal bir çıktı üretmelidir. Bulanık modelleme, bu süreç tarafından otomatik yöntemler kullanmaya teşvik edilir, ancak eldeki bilgi eksik olduğunda veya sorun alanı çok büyük olduğunda bu zordur. Bulanık modelleme ile ilgili temel sorunlardan biri, değişken sayısı arttıkça gerekli hesaplama miktarının da artmasıdır.

Bir bulanık çıkarım sisteminin parametreleri dört kategoride sınıflandırılabilir.

- 1. Mantıksal Parametreler.** Çıkarım işlemi sırasında ikili ve bulanık büyüklüklerin geçirdiği dönüşüm tiplerini tanımlayan operatör ve fonksiyonlardır. Üyelik fonksiyonlarının şekli, VE, VEYA, karıştırma ve toplama işlemleri için uygulanan bulanık mantık operatörlerini ve berraklaştırma yöntemini içerir.
- 2. Yapısal Parametreler.** Daha çok bulanık sistemin büyüklüğü ile ilgilidir. Çıkarımda kullanılacak değişken sayısı, her bir dilsel değişkeni tanımlayacak üyelik fonksiyonu sayısı ve çıkarım için kullanılacak kural sayısını içerir.
- 3. Bağlayıcı Parametreler.** Sistemin topolojisi hakkındadır. Çeşitli dil illüstrasyonları arasındaki ilişkileri açıklar. Koşullar, sonuçlar ve kural ağırlıklarından oluşurlar.
- 4. İşlevsel Parametreler.** Bu değişkenler, değişkenlerin dil ve sayısal temsillerinin nasıl eşlendiğini belirtir. Dilsel değişkenlerin üyelik fonksiyonlarını niteler.



Bulanık modellemede, tasarımcı genellikle mantıksal parametreleri önceki bilgilere ve problemin özelliklerine dayalı olarak kurar. Mandani ve Sugeno türleri yargı prosedürü olarak sıklıkla kullanılmaktadır. Minimum, maksimum, çarpım, sonlu çarpım, sonlu toplam ve olasılıklı toplam, yaygın bulanık operatörlerin örnekleridir. Çan tipi, üçgen ve yamuk üyelik fonksiyonları en popüler olanlarıdır. COA ve MOM prosedürleri en sık kullanılan açıklama teknikleri olmakla birlikte başka teknikler de vardır.

Bir sentez ve araştırma daha fazla parametre verebilir veya önceden tanımlanabilir. Arama uzayı, işleme yükü gibi parametre sayısı arttıkça tipik olarak üstel olarak büyür. Sonuç olarak, arama yaklaşımına daha fazla kaynak ayrılabilir ve sistemin önceki uzman bilgisi artırılarak arama uzayı kısıtlanabilir. Daha önce açıklanan doğruluk ve yorumlanabilirlik arasındaki ilişki, sıklıkla, arama sürecini daha zorlu hale getiren parametre değerleri üzerindeki bir dizi kısıtlama olarak ifade edilir [64].

### **3.5.1. Yaklaşımlar Ve Teknikler**

Uzman sistemlerde kullanılan bilgi mühendisliği teknikleri, ilk bulanık modelleme için ilham kaynağı ve büyük bir etki olarak hizmet etmiştir. Mamdani, doğrudan uzman bilgisini kullanarak - doğrudan yaklaşım olarak adlandırdığımız - bulanık bir model oluşturarak Zadeh'in teorilerini kullanmıştır. Bulanık modelin yapısını veya parametrelerini belirlemek için belirli bir şekilde kullanılmayan daha fazla girdi ve çıktı verisi mevcut olduğundan, modellenen sistemde doğrudan yaklaşımı kullanırken uzman bilgisi toplamak daha zor hale gelmiştir. Bu, bulanık modelin yalnızca bir kısmının ön bilgiler kullanılarak oluşturulduğu otomatik bulanık modelleme yaklaşımlarının kullanılmasına yol açmıştır.

Arama metodolojilerine sahip çok fazla bulanık modelleme tekniği var. Bunlardan önemli olanları aşağıdakiler gibidir:

- Klasik tanımlama algoritmaları temelindeki yaklaşımlar,
- Doğrudan yaklaşım,
- Yapıcı öğrenme yaklaşımları,
- Sinirsel-bulanık ve evrimsel-bulanık gibi hayattan esinlenen yaklaşımlar.

## BÖLÜM 4

### YAPAY SİNİR AĞLARI

#### 4.1. GİRİŞ

İnsanların günlük hayatlarındaki her türlü aktiviteyi gerçekleştirmesini mümkün kılan yapı, karmaşık bir şekilde birbirine bağlı 100 milyar sinir hücrelerinden (nöronlar) oluşan gelişmiş bir biyolojik sinir sistemidir. Her biyolojik nöron, mikroişlemciler kadar hızlı olmasa da karmaşıktır ve doku ile kimyanın karmaşık bir bileşimidir. Nöronun yapısının bir kısmı doğuştan varken, diğer yönler öğrenilerek geliştirilir.

Araştırmacılar, biyolojik sinir sisteminin nasıl çalıştığını yeni yeni anlamaya başlamışlardır. Hafıza dahil tüm biyolojik beyin süreçlerinin nöronlarda ve onları birbirine bağlayan bağlantılarda depolandığına inanılmaktadır. Nöronal değişiklikler veya yeni bağlantılar, öğrenmenin sonucu olarak tanımlanmıştır. Biyolojik sinir sistemi hakkındaki temel bilgimiz çok önemli olmasına rağmen, insanın doğayı kopyalama içgüdüsünden kaynaklı basit yapay nöronlar üretilebilir ve bu yapay nöronlar yararlı işlevleri yerine getirmek üzere eğitilebilir mi sorusu gündeme gelmiştir.

Biyolojik nöronların çok temel kopyaları olan yapay nöronlar, silikon devre bileşenleri veya program parçaları olarak düşünülebilir. Bu yapay nöronlardan inşa edilen sistemler (ağlar), insan beyin gücüyle eşleşemeyecek olsalar bile, bazı değerli görevleri yerine getirmek için eğitilebilirler [68].

İnsanlığın doğayı inceleme ve taklit etme çabalarının en yeni sonuçlarından biri olan yapay sinir ağları (YSA) çeşitli sınıflandırmalara sahiptir [69]. "Yapay sinir ağları, birçok farklı işleme parçasıyla oluşturulmuş, dağıtılmış, uyarlanabilir, genellikle

doğrusal olmayan öğrenme makineleridir" tanımı, bu teknolojinin göze çarpan özelliklerini vurgulamak için kullanılabilir [70].

Başlangıçta nörobiyoloji, bağlantıcılık veya yapay sinir ağları çalışmasından etkilenmesine rağmen, bilgisayar bilimi, elektrik ve elektronik mühendisliği, matematik, fizik, psikoloji ve dilbilimi içeren oldukça disiplinler arası bir alana dönüşmüştür [71].

## 4.2. TARİHİ GELİŞİM

19. yüzyılda nörobiyologlar tarafından insan sinir sistemi üzerinde yapılan önemli araştırmalar, yapay sinir ağlarının çağdaş çalışmalarının temeli olarak hizmet etmiştir. Bir anatomi uzmanı olan Cajal (1892), sinir sisteminin, aksonları aracılığıyla elektrik sinyalleri göndererek birbirleriyle iletişim kuran ve sonunda binlerce başka nöronun dendritlerine (alıcı alanlara) dokunmak üzere dallanan ve elektrik sinyalinin sinapslar (değişken direnç bağlantı noktaları) yoluyla ileten bireysel nöronlardan oluştuğunu keşfetti. Takip eden on yıllar boyunca, bu temel görüntü, farklı nöronal tipleri sınıflandırarak, elektriksel tepkilerini inceleyerek, bağlantı modellerini ortaya çıkararak ve beynin başlıca işlevsel alanlarını tanımlayarak daha da geliştirildi. Nörobiyologlar için tek bir nöronun performansını incelemek basit olsa da, nöronların algı ve biliş gibi daha yüksek dereceli süreçleri yürütmek için nasıl işbirliği yaptığını tespit etmek zor olmuştur. Yüksek hızlı bilgisayarların geliştirilmesiyle, araştırmacıların bu sistemlerle daha kolay deneyler yapmalarına ve özellikleri hakkında daha iyi bilgi edinmelerine olanak tanıyan, nörolojik sistemlerin çalışan modellerini oluşturmak mümkün hale gelmiştir [71].

19yy. sonu 20yy. yüzyıl başlarında fizik, psikoloji ve nörofizyolojinin multidisipliner çalışmalarıyla başlayarak, Hermann von Helmholtz, Ernst Mach ve Ivan Pavlov gibi bilim adamlarının sinir ağları ile ilgili arka plan çalışmaları vardı. İlk araştırmalar, nöronların nasıl işlediğine dair ayrıntılı bir matematiksel model içermiyordu; bunun yerine öğrenme, algı ve koşullandırma gibi geniş teorilere odaklanılmıştı.

1940'larda McCulloch ve Pitts'in alıřmaları ve 1943'te yayınlanan, yapay nronlardan oluřan ađların herhangi bir matematiksel veya mantıksal iřlemi gerekleřtirebileceđini gsteren makaleleriyle, sinir ađlarının ađdař bakıř aısının temellerini oluřturdular [68]. Bu alıřma ile; sinir ađı alanının kkenin, net girdinin belirli bir eřik deđerini ařıp ařmamasına bađlı olarak 0 veya 1 ıktısı veren bir nronun sayısal bir temsili olan ikili eřik biriminden kaynaklandıđı sıklıkla kabul edilir [71]. Bu modelde, nronları arasındaki ađırlık katsayıları iin dođru deđerler verildiđinde, bu nronlardan yapılmıř ve sonlu durumlu bir otomat olarak inřa edilmiř bir sistemin herhangi bir sıralı iřlevi hesaplayabildiđini gstermek byleyiciydi. Daha sonra bilim adamları, herhangi bir iřlevi yerine getirebilecek ađların ađırlık katsayılarını belirlemeyi mmkn kılacak đrenme teknikleri aramaya bařlamıřlardır [71].

Sre 1949'da Donald Hebb'in eseri ile devam etmiřtir. Biyolojik nronlarda đrenme iin bir yntem varsayımında bulunmuř ve Pavlov tarafından kurulan klasik kořullandırmanın nronların benzersiz zelliklerinden kaynaklandıđını iddia etmiřtir. Sonunda 20 yıllık arařtırmasını 1949'da, daha sonra Hebbian đrenimi ile iliřkilendirilecek olan "The Organization of Behavior - Davranıř Organizasyonu" bařlıđı altında yayınlamıřtır.

Rosenblatt'ın 1950'lerin sonlarında perseptron ađı ve ilgili đrenme kuralı oluřturması ile, yapay sinir ađları ilk gerek dnya uygulamalarına kavuřtu. Rosenblatt ve ekibi, bir perseptron ađı oluřturarak, rnt tanıma kapasitesini gstermiřlerdir. Bununla birlikte, temel perseptron ađının, nihayetinde sorunları ele alma yeteneđinin sınırlı olduđu grlmřtr [68]. Bu alıřmadan nce, Nathaniel Rochester'ın IBM arařtırma laboratuvarlarında bir sinir ađı simlasyonu (bařlangıta bařarısız oldu ama sonunda bařarılı oldu), yapay zeka ve sinir ađları zerindeki alıřmaları hızlandıran 1956'daki yapay zeka Dartmouth Yaz Arařtırma Projesi ve John von Neumann'ın aynı yıllarda ki vakum tpleri ve telgraf rleleri kullanarak temel nronların hareketlerini kopyalamaya ynelik arařtırması da ok nemlidir [66].

Benzer dnemlerde, Widrow ve Hoff, mevcut zamanda da Widrow-Hoff đrenme kuralı olarak biline, bir đrenme algoritması (LMS-En Kk Kareler - Least Mean Square) geliřtirmiř ve yapısal ve yeteneksel olarak Rosenblatt'ın perseptronuna yakın

olan uyarlamalı (adaptif) lineer sinir ađının (ADALINE-ADaptive LInear NEuron) eđitiminde kullanmıřlardır.

Minsky ve Papert'in 1969'daki kitapları Rosenblatt ve Widrow ađları iin sorunlara neden olan aynı ayrılmaz sınırlamaları kapsamlı bir řekilde tartıřıp duyururken, bu sınırlamaların farkında olan iki arařtırmacı, eđitim iin algoritmalar daha karmařık olsa da bu kısıtlamaları ařmak iin yeni ađlar nermiř olsalar da bařarılı bir řekilde geliřtirilmemiřtir. Bu kitaptan etkilenen birok okuyucu, sinir ađı arařtırmasının henüz emekleme ařamasında olduđunu dřünmüřtür. Bununla birlikte, deney yapmak iin gl hesaplama makinelerinin eksikliđi nedeniyle arařtırmacıların alanı terk etmesi sonucu sinir ađlarındaki geliřmeler on yıllık bir beklemeye srecine girmiřtir.

Ancak Kohonen ve Anderson, 1970'lerde yapılan bazı nemli deneyler sonucunda kendi arařtırmalarında bellek grevi gren sinir ađları oluřturdular. Grossberg, 1976'da kendi kendini organize eden ađların keřfine aktif olarak katkıda bulunmuřtur.

Kapasitesi hızla geliřen yeni kiřisel bilgisayarların ve iř istasyonlarının yaygınlařması ve bu engellerin nemli yeni yaklařımlarla ařılabilmesi nedeniyle, 1960'ların sonlarında yetersizlik nedeniyle durmuř olan sinir ađlarına ilgi ve arařtırmalar, bilgisayarların yeni fikirler ve deneyler yrtmesi dođrultusunda artmıř ve 1980'lerde dramatik bir dnř yapmıřtır. Sinir ađlarının yeniden canlanması, iki yeni stratejiden byk lde etkilenmiřtir. Birincisi, fiziki John Hopfield tarafından bir seminerde sunulan, istatistiksel mekanik kullanılarak kolektif bellek olarak kullanılabilir belirlenmeli bir zyinelemeli ađ sınıfının aıklamasıdır [68]. İstenilen herhangi bir davranıř iin eđitilebilen olasılıksal bir ađ olan Boltzman makinesi, Hopfield'in bir ađın bir enerji fonksiyonu aısından alıřılabileceđi nerisini yapan alıřmasının bir sonucu olarak geliřtirilmiřtir [71]. Buna paralel olarak, Kyoto, Japonya, Ortak/Rekabeti Sinir Ađları zerine Amerika-Japonya Bađlantı Konferansına ev sahipliđi yapmıřtır. 1800'den fazla kiři 1987'de ilk IEEE Uluslararası Sinir Ađları Konferansına katılmıřtır [73].

ok katmanlı perseptron ađlarını eđitmek iin ok sayıda ayrı arařtırmacı tarafından yapılan geri yayılım algoritmasının oluřturulması, 1980'lerdeki ikinci nemli


gelişmesi olmuştur. Geri yayılım algoritmasının en önemli yayını 1986 yılında Rumelhart ve McClelland tarafından yapılmıştır.

Bu yeni keşiflerin bir sonucu olarak sinir ağları çalışması yeniden canlanmıştır. O zamandan beri binlerce sayfa makale yazılmış, sinir ağları çok çeşitli bağlamlarda kullanılmıştır ve bu konu yeni teorik ve uygulamalı araştırmalar sayesinde hala büyümektedir. Sinir ağlarının gelecekte her derde deva bir çözüm olarak değil, gerektiğinde uygulanabilecek bir araç olarak ve mevcut anlayışımız göz önüne alındığında, modern uygulamalar ile ilişkili kalacağı söylenebilir. Yapılan çalışmalar ile her türlü uygulamaya dahil edilebilmesi ve karmaşık sorunların çözümüne katkı sağlaması ile gelişme muhtemelen devam edecektir [68]. Günümüzde dilden sanata kadar soyut kavramlarda da yapay zeka etkileri görülebilmektedir. Ancak donanım geliştirme, tüm bu teknolojide çok önemli bir rol oynar. Şirketler şu anda üç farklı türde beyin çipi geliştirmektedir: dijital, analog ve optik. Diğerleri hala bir silikon derleyici kullanarak bir Uygulamaya Özel Entegre Devre (ASIC) sinir ağı inşa etmektedir. ASIC'ler ve nöronlara benzeyen dijital çipler, yaklaşan trendler gibi görünmektedir [73].

### **4.3. BİYOLOJİK SİNİR SİSTEMİ**

Beyindeki sinir hücrelerinin sayısı yüz milyar ile ifade edilecek kadar çok fazladır ve hepsi birbirine yaklaşık on biner bağlantı ile yüksek şekilde bağlı element(nöron) içerir. Bu nöronlar amaçlarımız için üç temel bölüme ayrılabilir: dendrit, hücre gövdesi ve akson. Dendritler olarak bilinen sinir lifi ağları, alıcı ağlar olarak hareket eder ve elektrik sinyallerini hücre gövdesine taşır. Dendritik sinyaller hücre gövdesi tarafından verimli bir şekilde toplanır ve bu da onların eşiği geçmelerine izin verir. Sinyal, hücre gövdesinden komşu hücrelere tek bir uzun lif olan akson aracılığıyla gönderilir. Şekil 4.1'de bir sinir hücresi gösterilmiştir. Sinapslar, bir hücrenin aksonunun başka bir hücrenin dendritine bağlandığı noktalardır. Zor bir kimyasal reaksiyonla kontrol edilen nöronların konfigürasyonu ve her sinapsın gücü, sinir ağının ne kadar iyi performans gösterdiğini etkiler.

Akson, akson ve dendritin birleştiği noktada "ön sinaptik terminal" olarak bilinen bir düğüm oluşturur. Diğer hücre dendrit yüzeyi boyunca bu uç uzanır. Ön sinaptik terminal, akson aktive olduğunda "sinir taşıyıcısı" olarak bilinen bir maddeyi serbest bırakır ve komşu dendrit yönünde hareket eder. İkinci nöron, dendriti aktive ettiği için bu madde tarafından uyarılır. Bu olayı Na-K pompası sağlar. Sinir tepkileri, hücreler arasındaki boşluklar boyunca kimyasal nörotransmitterler aracılığıyla iletilse bile, esas olarak elektrikseldir [74].



Şekil 4.1. Bir sinir hücresinin yapısı ve modeli [37].

Bazı beyin yapılarının doğuştan olmasına rağmen, yeni bağlantılar kurulduğunda veya eski bağlantılar öğrenilerek değiştirildiğinde diğerleri büyür. Yaşam boyunca, sinirsel yapılar sürekli olarak gelişmektedir. Sinaptik bağlantılar daha sonraki bu değişiklikler sonucunda ya güçlenir ya da zayıflar. Örneğin, bu sinaptik güçlerdeki değişikliklerin yeni anıların oluşumuna yol açtığı düşünülmektedir. Böylece yeni bir kişinin yüzünü öğrenme sürecinde farklı sinapslar değiş tokuş edilir.

Beynin karmaşıklığı, yapay sinir ağlarınıninkiyle karşılaştırılmaz. Ancak biyolojik ve sentetik sinir ağları arasında iki önemli paralellik vardır. İlk olarak, her iki ağın da temel öğeleri yüksek oranda birbirine bağlı, temel hesaplama makineleridir (yapay nöronlar biyolojik nöronlardan çok daha basit olsa da). İkincisi, ağın işlevselliği nöronlar arasındaki bağlantılarla belirlenir.

Organik nöronların elektrik devrelerine göre biraz daha yavaş hareket etmesine rağmen, beyin birçok görevi herhangi bir geleneksel bilgisayardan çok daha hızlı

gerçekleştirebilir. Bunun nedeni, biyolojik beyin ağlarının, tüm nöronların aynı anda çalışmasını sağlayan oldukça büyük bir paralel yapıya sahip olmasıdır [68].

#### **4.4. YSA ÖZELLİKLERİ**

Yapay sinir ağlarının temeli, yargıların öğrenme yoluyla yapıldığı fikridir. Öğrenme, sistemlerin benzer süreçleri daha önce olduğundan daha etkin ve verimli bir şekilde yürüterek gerçekleştirdiğinde değişiklikler meydana getirme sürecidir. İnsan beynini simüle etme fikrine dayanan yapay sinir ağları adı verilen bir bilgi işleme tekniği, hiyerarşik olarak düzenlenmiş paralel işlem birimlerinden oluşur.

Doğrusal olmayan sistemlerin kontrolü ve modellenmesi yapay sinir ağları ile büyük ölçüde kolaylaştırılmıştır. Mühendislik zorlukları ve sayısız pratik uygulamalarda etkin kullanım için yapay sinir ağlarının bazı özelliklerinin anlaşılması gerekmektedir [75].

##### **4.4.1. Eğitilebilirlik**

Bilgi işleme tekniklerinin çoğu programlanabilir hesaplama dayandır. Bu yaklaşımlar ispatlanamayan sorunları çözmek için kullanılamaz ve uygun algoritmaların geliştirilmesini gerektirir [75]. Herhangi bir girdi ve çıktı modeli arasındaki bağlantıların geliştirilmesi, yapay sinir ağlarının yaptığı süreç olarak değerlendirilebilir [71]. Bunu başarmak için, yapay sinir ağları, çalışılan sistemin kayıtlı verileri kullanılarak eğitilir, bu da yapay sinir ağının sistemin işlevselliğini almasını sağlar. Eğitilmiş ağ artık sistemde depolanmayan giriş değerleri için çıkış değerleri üretme yeteneğine sahiptir. Eğitimli bir ağda verimlilik, nöronlar arasında uygun bağlantıların kurulması ve uygun ağırlıkların seçilmesini sağlayan eğitim süreci, istenilen sonuca ulaşmak için rastgele seçilen ağırlıklar ve kayıtlı veriler kullanılarak seçilen bir öğrenme algoritması kullanılarak önceden belirlenmiş bir hata kriterinin karşılanması sonucunda gerçekleşir.



#### **4.4.2. Genelleme**

Ağlar, eğitim verilerini basitçe ezberlemek yerine temel sırayı öğrenerek, eğitim verilerinden farklılık gösteren yeni girdi verileri için eğitim verilerinden genelleme yapmalarına olanak tanır. Başka bir deyişle, eğitim sırasında kullanılan sayısal verilerden eşleşmeyi tanımlayan anahtar özellikleri çıkararak, eğitim sırasında kullanılan girdi değerleri dışındaki değerler için anlamlı çıktı değerleri sağlamasını sağlayan ağ yapısının bir özelliğidir.

#### **4.4.3. Doğrusal Olmama**

Yapay sinir ağları, doğrusal olmayan özellikleri ve doğrusal olmayan yönleri ile önem kazanmıştır. Bir ağın ya da nöronal temel işlem birimi nöronun lineerliği transfer(aktarım) fonksiyonu ile tespit edilir [76]. Ağlar, verileri rastgele karmaşık yollarla değiştirmelerine izin veren doğrusal ve parametrik olmayan işlevleri hesaplama yeteneğine sahiptir [71].

#### **4.4.4. Sağlamlık Ve Hata Toleransı**

Yapay sinir ağlarının nöronlarının birbirine bağlanmasının sayısız farklı yolu sonucunda paralel dağıtılmış bir yapıya sahiptirler. Veriler, tek bir yerde tutulmak yerine ağ boyunca yerel belleğe dağıtılır. Bu nedenle, bir veya daha fazla nöron veya bağlantı fiziksel olarak hasar gördüğünde sistem daha az verimli olsa da, tamamen başarısız sonuçlardan kaçınılır. Öte yandan seri bilgisayarlarda herhangi bir işlem birimi devre dışı bırakılırsa sistem bir bütün olarak kullanılamaz hale gelir. Yapay sinir ağları bu nedenle geleneksel yöntemlerden çok daha fazla hataya dayanıklıdır. Aynı hata toleransı seviyesi gürültülü veriler için de geçerlidir. Gerçekte, gürültülü veriler ağların daha etkili bir şekilde geliştirilmesini sağlar [71].

#### **4.4.5. Tekbiçimlilik**

Birçok türdeki girdilerdeki sınırlamaları kolaylıkla birleştiren tutarlı tek biçimli bir sayısal örnek, sinir ağları tarafından sağlanır.

#### **4.4.6. Paralellik**

Bilgisayar tekniklerinin çoğu, hız sınırlamaları olan sıralı seri işlemleri kullanır. İnsan beyni bir bilgisayardan önemli ölçüde daha yavaş olmasına rağmen, genel olarak çok daha hızlıdır ve bir bilgisayardan çok daha büyük bir işleme kapasitesine sahiptir çünkü nöronlar birbirinden bağımsız olarak paralel olarak çalışır ve aynı anda birden fazla görevi yerine getirir. Aynı katmandaki nöronlar arasında zamansal bir bağımlılık yoktur çünkü yapay sinir ağları, her bir nörona aynı anda girdi uygulayan paralel bir yapıya sahiptir. Birçok nöronun aynı anda aktif olduğundan ve birkaç nöronal aktivitenin karmaşık eylemler oluşturmak için birleştiğinden emin olunmaktadır. Geleneksel yaklaşımlarla karşılaştırıldığında, geliştirilmiş işlem hızı nedeniyle sonuca daha hızlı ulaşılabilir.

### **4.5. SİNİR AĞLARININ ESASLARI**

Sinir ağları çok çeşitli şekillerde olmasına rağmen, sürekli olarak dört temel özelliğe sahiptirler: işlem birimleri, bağlantılar, hesaplama yöntemi ve öğrenme tekniği [71].

#### **4.5.1. İşlem Birimleri**


Genellikle beyin nöronlarıyla karşılaştırılabilir olan yapay nöronlar (yapay nöronlar), bir yapay sinir ağında çok sayıda bulunabilen basit işlem birimleridir. Yapay nöron, biyolojik sinirin bazı temel özelliklerini sergilemek için oluşturulmuştur [68]. Etkileyici paralellik, tüm yapay nöronların aynı anda çalışmasıyla desteklenir. Bu nöronlar, sistemdeki tek işlemciler olarak çalışır, tüm hesaplamaları yapmanın yanı sıra nöronların eylemlerini kontrol eder ve düzenler. Her nöron, her an kendi yerel girdilerinin değerlerini belirlemek için yalnızca bir matematiksel fonksiyon kullanır ve ardından aktivasyon değeri olarak bilinen sonucu yakındaki nöronlara dağıtır.

Bir ağın bileşenlerini, ortamdan ham veri alan "giriş birimleri - giriş nöronları", verilerin temsilini dahili olarak değiştirebilen "gizli birimler - gizli nöronlar" ve/veya yargı veya kontrol sinyallerini gösteren "çıkış birimleri - çıkış nöronları" olarak ayırmak mümkündür.

Herhangi bir zamanda bir ağdaki tüm nöronlardaki aktivasyon değerleri kümesi, ağın mevcut durumunu temsil eder. Sistemdeki girdiler değiştiğinden ve/veya geri bildirimler ağın durum uzayı boyunca dinamik bir yörünge izlemesine yol açabileceğinden, ağın durumu genellikle her an değişir [71].

#### 4.5.1.1 Tek Girişli Nöron

Şekil 4.2 tek girişli nöronun gösterimi mevcuttur. Toplayıcıya sağlanan terimlerden birisi olan  $wp$ , sayısal girdi  $p$  ile sayısal ağırlık  $w$  çarpılarak oluşturulur. Toplayıcı, 1 olan diğer girdi hatası eğilim vektörü [77] toplayıcıya gönderilmeden önce (bias)  $b$  ile çarpılır. Dijital nöron çıkışı  $a$ , net giriş olarak da bilinen toplayıcı çıkışının  $n$ , bir transfer fonksiyonu  $f$ 'e girdiğinde oluşturulur.



Şekil 4.2. Tek girişli nöron [78].

Biyolojik nöron ile eşlendiğinde; şekil 4.2'deki basit modelin ağırlığı  $w$ , sinapsların gücüne karşılık gelir, toplama ve transfer fonksiyonu hücre gövdesini temsil etmek için kullanılabilir ve nöron çıktısı  $a$ , aksondaki sinyali temsil etmek için kullanılabilir. 4.1'deki denklem nöron çıktısını belirlemek için kullanılabilir.

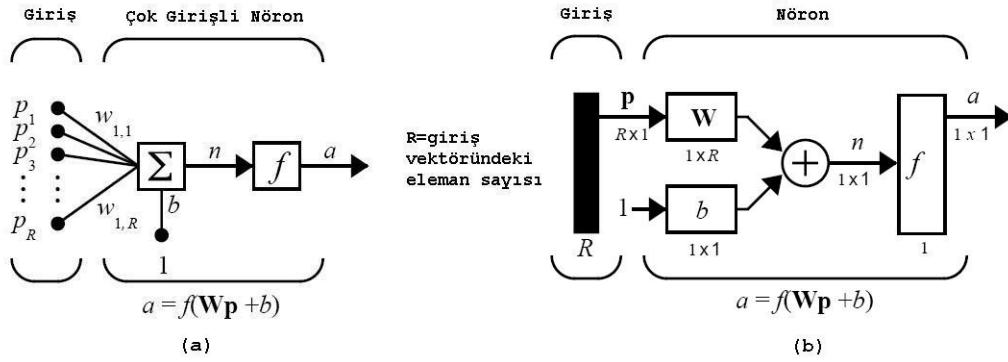
$$a = f(wp + b) \quad (4.1)$$

Denklemden de anlaşılacağı gibi, seçilen transfer fonksiyonu gerçek çıktıyı belirler.

Herhangi bir nöronun tercih edilirse göz ardı edilebilecek hata eğilim vektörü, girdisi sabit 1 olan bir ağırlıkla karşılaştırılabilir; burada  $w$  ve  $b$ , nöronun programlanabilir sayısal parametreleridir. Nöron girişi ve çıkışı arasında uygun bağlantıyı kurmak için, transfer fonksiyonu tipik olarak tasarımcı tarafından tanımlanır ve  $w$  ve  $b$  parametreleri bir öğrenme kuralının sonucu olarak belirlenir.

#### 4.5.1.2. Çok Girişli Nöron

Bir nöron tipik olarak birden fazla girdi alır. Şekil 4.3a,  $R$  girişli bir nöron yapısını gösterir ve Şekil 4.3b, genel kısaltılmış gösterimini gösterir.



Şekil 4.3. Çok girişli nöron [78].

$W$  ağırlık matrisinde  $w_{1,1}, w_{1,2}, \dots, w_{1,R}$  ağırlık değerleri ile eşleşen birbirinden ayrı  $p_1, p_2, \dots, p_R$  girişleri, ağırlıklandırılır. Denklem 4.2 ve denklem 4.3, hata eğilim vektörü  $b$  olan bir nöron için net girdiyi tanımlamak için kullanılabilir.

$$n = w_{1,1}p_1 + w_{1,2}p_2 + \dots + w_{1,R}p_R + b \quad (4.2)$$

$$n = \mathbf{W} \mathbf{p} + b \quad (4.3)$$

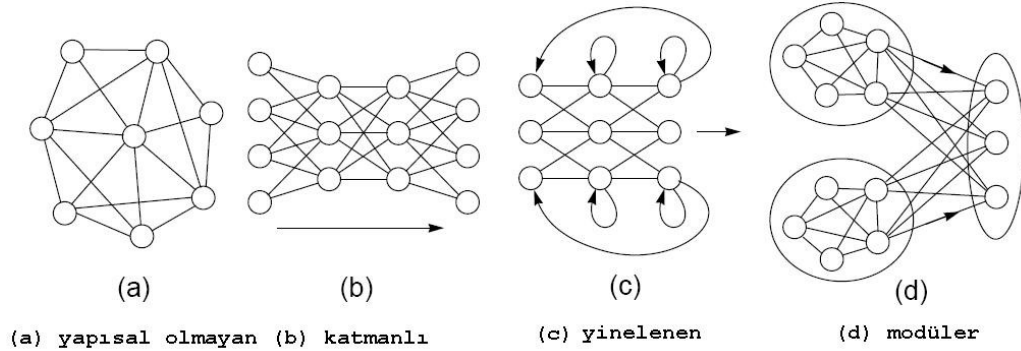
Tek bir nöron için  $\mathbf{W}$ , tek satırlı bir matris olacaktır. 4.4'teki denklem daha sonra nöron çıktısını ifade etmek için kullanılabilir.

$$a = f(\mathbf{W}p + b) \quad (4.4)$$

#### 4.5.2. Bağlantılar

Bir ağın topolojisi, bağlantılar veya çizgilerle temsil edilen ağırlıklar topluluğu tarafından belirlenir ve nöronların nasıl organize edildiğini belirler. Her nöron ağırlığının gerçek değeri normalde  $-\infty, +\infty$  arasındadır ancak aralık bazen kısıtlıdır. Bir birimin komşu birimde ne kadar etkisi olacağı, o ağırlığın değerine (veya gücüne) bağlıdır. Pozitif bir değer, bir nöronun diğerini uyarmasına neden olurken, negatif bir değer başka bir hücreyi engellemesine neden eder.

Her ağırlığın değerleri, ağın her rastgele girdi örneğine sayısal olarak nasıl yanıt vereceğine önceden karar verir. Sonuç olarak, ağın uzun süreli belleği veya bilgileri ağırlıklarla kodlanır. Ağırlıklar, kademeli bilgi birikimi nedeniyle nispeten yavaş değişme eğiliminde olmalarına rağmen, bir öğrenme sonucunun sonucu olarak değişebilir. Bu mevcut girişin geçici fonksiyonları olması nedeniyle kısa vadeli bellekler olan etkinleştirme modellerinin aksinedir.



Şekil 4.4 Yapay sinir ağı topolojileri.

Herhangi bir topoloji bir ağa bağlanabilir. Şekil 4.4, yapılandırılmamış, katmanlı, özyinelemeli ve modüler ağlar gibi ortak topolojileri göstermektedir. Her mimari, belirli bir uygulama türü için idealdir. Yapılandırılmamış ağlar, kalıp tamamlama, arama ve bir kalıp veritabanından bir kalıbın bir kısmını çıkarma gibi görevler için mükemmeldir. Girdi vektörlerini çıktı vektörlerine eşlerken olduğu gibi kalıpları

eşleştirirken, katmanlı ağlar yararlıdır. Modüler ağlar, basit sistemlerden karmaşık sistemler oluşturmak için mükemmeldir, yinelemeli ağlar ise kalıpları düzenlemek için kullanışlıdır.

Yapılandırılmamış ağların döngüleri olduğu için yinlenen oldukları vurgulanmalıdır. Katmanlı ağlar yinlenen olabilecekleri gibi olmayabilirler. Modüler ağlarda farklı ağ türleri birleştirilebilir. Yapılandırılmamış ağlar tipik olarak iki yönlü bağlantılar kullanırken, diğer ağlar sıklıkla tek yönlü bağlantılar kullanır.

İki katman gibi iki birim grubu, hepsini bir araya getirerek "tamamen", bazılarını birbirine bağlayarak "rastgele" veya bir bölgeyi diğerine bağlayarak "yerel olarak" bağlanabilir. En yüksek serbestlik dereceleri, tamamen bağlı ağlarda bulunur. Bu ağlar, geleneksel ağlara kıyasla teorik olarak daha fazla fonksiyon öğrenebilirler. Yine de bu her zaman beklenen bir durum değildir. Bir ağ, öğrenme sırasında çok fazla serbestlik derecesine sahipse ve bunun yerine sorunun kaynağını anlamak yerine eğitim setini ezberliyorsa, yeni verilere iyi genelleme yapamayabilir. Bağlantıyı sınırlamak, ağı daha uygun fiyatlı seçenekleri keşfetmeye zorlarken genellemeyi iyileştirebilir. Yerel bağlantı, bir görsel işleme sistemindeki katmanlara yerleştirilen geometrik kısıtlamalar gibi problemin topolojik sınırlamalarını yakaladığında özellikle yardımcı olabilir [71].

### **4.5.3. Hesaplama**

Hesaplama her zaman aktivasyon örneğini girişlere kenetleyerek veya ağ girişine bir giriş örneği uygulayarak başlar. Ardından, duruma bağlı olarak, kalan tüm diğer birimlerin aktivasyonu ya senkron (paralel sistemlerde hepsi aynı anda) ya da asenkron olarak (bire birer, rastgele veya doğal bir sırayla) hesaplanır. Giriş katmanından çıkışa hareket eden bu süreç katmanlı ağlarda "ileri yayılım" olarak bilinir ve yapılandırılmamış ağlarda "yayılan aktivasyon" olarak bilinir. Aktivasyonlar, hesaplama çıktı katmanına ulaşır ulaşmaz, ileri beslemeli ağlarda (geri beslemesiz ağlar) dengelenir. Öte yandan, yinelemeli ağlar (geri bildirim ağları), birimler sürekli olarak güncellendiğinden, durum uzayı boyunca dinamik bir yörüngeyi takip eden ve bunun yerine asla stabilize olmayabilecek aktivasyonlara sahip olabilirler.

Bir birim tipik olarak iki adımda güncellenir; ilk olarak birimin net girişi hesaplanır ve sonra çıkış aktivasyonu net girişin bir fonksiyonu olarak hesaplanır [71]. Net girişin hesaplanması 4.2 ve 4.3 eşitliklerinde verilmiştir. Bir birimin net girişinin hesaplanmasında sonra, 4.4 eşitliği ile verilen şekilde çıkış aktivasyonu net girişin bir fonksiyonu olarak hesaplanır. Bu fonksiyona aktivasyon fonksiyonu ya da transfer fonksiyonu denir.


Bir birimi güncellemeyi iki adımda yapmak gelenekseldir: ilk olarak, birimin net girdisini hesaplanır ve ardından bu girdinin bir fonksiyonu olarak çıktı aktivasyonunu hesaplanır [71]. Denklem 4.2 ve 4.3, net girdiyi hesaplamak için kullanılır. Bir birimin net girdisini belirledikten sonra, denklem 4.4'ün çıktı aktivasyonu için ifadesi net girdinin bir fonksiyonu olarak türetilir. Bu işlem aktivasyon fonksiyonu veya transfer fonksiyonu olarak isimlendirilir.

#### **4.5.3.1. Transfer Fonksiyonları**

Diğer bir deyişle transfer fonksiyonu, net girdiyi nöron çıktısına dönüştüren mekanizmadır. Eşik, işaret veya etkinleştirme işlevi bunun diğer adlarıdır [79]. Nöronun çözmeye çalıştığı sorunun bazı gereksinimlerini karşılayan benzersiz bir transfer işlevi seçilir [68].

Aktivasyon fonksiyonu, analog elektrik sistemlerine benzer şekilde yapay bir nöronun doğrusal olmayan kazancı olarak kavramsallaştırılabilir. Bu kazanç, çıktındaki değişikliğin net girdideki ihmal edilebilir bir değişikliğe bölünmesiyle belirlenir. Kazanç daha sonra belirli bir uyarma noktasında eğrinin eğimi olarak tanımlanır. Grossberg, transfer fonksiyonunun bu doğrusal olmayan özelliğinin, aynı ağın hem küçük hem de büyük sinyalleri işleme kapasitesini açıklayabileceğini önermiştir. Bu fonksiyonun uçlarındaki kazanç-düşürücü kısımlar büyük sinyalleri işlerken, fonksiyonun ortasındaki yüksek kazançlı bölge küçük sinyalleri işler. Sonuç olarak, kazanç eşleştirme, yapay bir nöronun çeşitli girdilerden gelen sinyalleri işlemesine izin verir [75].

Transfer fonksiyonları yerel veya yerel olmayan, deterministic(belirleyici) veya stokastik(olasılıklı) olabilir [71].



Şekil 4.5. Belirleyici yerel transfer fonksiyonları: (a) doğrusal; (b) eşik; (c) sigmoidal.

Tipik olarak, lokal aktivasyon fonksiyonlarını belirlemek için şekil 4.5'da gösterilen doğrusal, eşik veya sigmoidal yapılardan biri kullanılır. Tek bir katmanda eşlenebilen aynı işlevselliğe sahip çok katmanlı doğrusal birimlerin zayıflığı, denklemi Şekil 4.5a'da gösterilen doğrusal transfer fonksiyonunun çok sık kullanılmasını engellemektedir. Ağ, doğrusal olmayan işlevler oluşturmak için doğrusal olmayan birimler gerektirir. Şekil 5.6b'de gösterilen eşik fonksiyonu, bu doğrusal olmayanlığı oluşturmanın en kolay yoludur. Bu işlev, çok katmanlı bir ağdaki doğrusal işlevden önemli ölçüde daha etkilidir. Teoride, çok katmanlı bir eşik birimleri ağında herhangi bir ikili mantık işlemini gerçekleştirebilir. Bununla birlikte, fonksiyonun süreksizliği ideal ağırlık setini bulmanın üstel bir aramayı gerektireceğini gösterdiğinden, böyle bir ağın eğitilmesi zordur. Bu birimlerden oluşan tek katmanlı ağlar için kullanılabilir bir öğrenme kuralı vardır. Ayrıca, birçok uygulamada sürekli çıkışlar ikili çıkışlara tercih edilir. Sonuç olarak, şekil 5.6c'de gösterilen sigmoidal fonksiyon şu anda en popüler fonksiyondur.

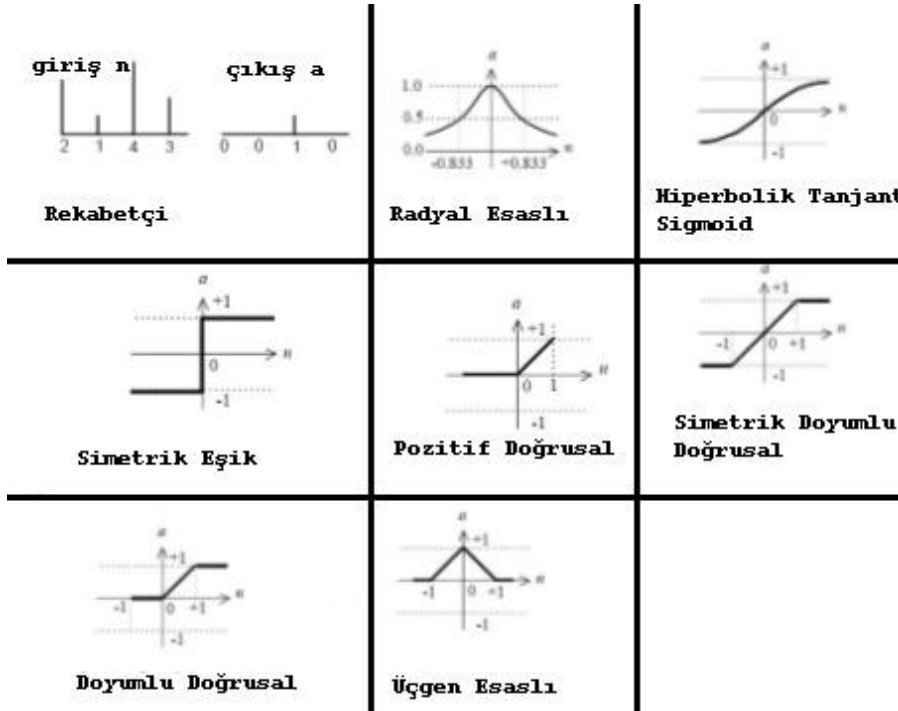
Sigmoidal fonksiyonların doğrusal olmama, süreklilik ve türevi alınabilirlik üstünlükleri vardır. Bunlar, çok katmanlı bir ağın herhangi bir rastgele gerçek değerli



fonksiyonu hesaplayabilmesini sağlarken pratik bir öğrenme algoritması olan gradient descent temelindeki geri yayılımı destekler.

Sigmoidal fonksiyonların türevlenebilirlik, süreklilik ve doğrusal olmama özellikleri avantajlıdır. Bunlar, herhangi bir gerçek değerli işlevin çok katmanlı bir ağ tarafından hesaplanmasına izin verir ve yararlı bir öğrenme yaklaşımı olan gradyan descent temelli geri yayılım sağlar.

Ağ bir bütün olarak yerel olmayan aktarım işlevleri kullanılarak kısıtlanabilir. Örneğin, olasılıklara benzer şekilde, ağı çıkış aktivasyonlarının toplam 1 olması bazen avantajlı olabilir. Bunu çıkışları lineer olarak normalize ederek elde etmek mümkündür, ancak doğrudan net girdiler üzerinde çalışan softmax fonksiyonlarını kullanmak daha popüler bir stratejidir. Ekstra yüke ve/veya donanım ihtiyacı duydukları için biyolojik olarak imkansız olsa da, genel kısıtlamalar gerekli olduğunda yerel olmayan işlevler yardımcı olabilir. Şekil 4.6 belirleyici ve yerel olmayan yerel transfer fonksiyonlarını listeler.




Şekil 4.6. Diğer transfer fonksiyonları [78].

Belirleyici olmayan transfer fonksiyonları belirleyici olanların aksine olasılıklıdır. Çıkışa 1 vermenin olasılığı 4.5'deki eşitlik ile verildiğinde, tipik olarak ikili aktivasyon değerleri (0 ya da 1) üretirler.

Deterministik transfer fonksiyonlarının aksine, deterministik olmayan transfer fonksiyonları olasılıksaldır. Tipik olarak, denklem 4.5, 1 çıktı olasılığını belirttiğinde, ikili aktivasyon değerleri (0 veya 1) verir.

$$P(y=1) = \frac{1}{1 + e^{-\frac{n}{T}}} \quad (4.5)$$



Şekil 4.7. Belirleyici olmayan transfer fonksiyonları.

Isı, genel olarak zamanla değişen  $T$  değişkeninin adıdır. Bu olasılık fonksiyonunun  $T$  parametresiyle değişimi Şekil 4.7'de gösterilmiştir. Sonlu olmayan  $T$  değeri ile tekdüze, sabit bir olasılık fonksiyonu, sıfır değerli  $T$  değişkeni ile eşik olasılık fonksiyonu ve sonlu  $T$  değeri ile sigmoidal olasılık fonksiyonu elde edilir. Benzetilmiş sertleşme,  $T$  değerinin sürekli azaldığı bir öğrenme sürecini tanımlamak için kullanılan terimdir.

Girdi ve ağırlık değerleri çarpıldığında üretilen net girdi, yukarıda bahsedilen transfer fonksiyonlarına uygulanır. Girdileri ağırlıklarla çarpmayan, bunun yerine net girdileri hesaplayan ve farkların karelerini toplayan transfer fonksiyonları vardır. Bu

topolojinin bir örneği olarak LVQ ve RBF ağlarının nöronlarını bu yapı için örneklendirilebilir [71].

#### 4.5.4. Öğrenme

En geniş anlamıyla, bir ağın eğitiminden gelen öğrenme, ağın gelen tüm veriler için beklendiği gibi davranmasını sağlamak için bağlantılarındaki ağırlıkların değiştirilmesini gerektirir. Yeni bir bağlantı eklemek veya çıkarmak gibi ağın topolojik yapısını zaman zaman değiştirmeye ek olarak, bu süreç tipik olarak ağırlıkların ayarlanmasını içerir. Çok bağlantılı bir ağın her üyenin ağırlığını 0'a ayarlamayı öğrenmesinin mümkün olduğu düşünüldüğünde, bu bir bağlantıyı ortadan kaldırmaya eşdeğerdir, bu ağırlık değişiklikleri bazı yönlerden topolojik değişikliklerden daha siktir. Ancak topolojik modifikasyonlar öğrenmeyi hızlandırabilir ve genellemeyi geliştirebilir.

Bir ağın belirli bir amacı gerçekleştirmesini sağlayacak ağırlık setini belirlemek zordur ve önemlidir. Ağın doğrusal olduğu ve ortogonal girdi vektörlerinin çıktı vektörleriyle eşleşmesinin beklendiği bir araştırma gibi en basit örnek eşleştirme örnekleri için, yalnızca analitik bir çözüm vardır.

Ağlar tipik olarak doğrusal değildir ve çok katmanlıdır. Küresel performans ölçümü temelinde, ağırlıkları gradyan descent gibi teknikler kullanılarak yinelemeli olarak belirlenebilir. Bu, tam eğitim seti boyunca eğitimin sayısız yinelemelerini (iteration) veya devirlerini (epoch) gerektirir. Ek olarak, tüm ağırlıklar toplu verilerden etkilendiğinden, önceki öğrenmenin bozulmaması için ağırlık değişiklikleri dikkatli yapılmalıdır. Küçük bir sabit olan öğrenme oranı ( $\alpha$ ), ağırlık değişimi büyüklüklerini düzenlemek için kullanılır. Öğrenme oranı için uygun bir değer bulmak çok önemlidir, çünkü çok küçükse öğrenme sonsuza kadar sürer ve çok büyükse öğrenme önceki bilgileri bozar. Yine de optimal öğrenme oranını belirlemek için analitik bir yaklaşım yoktur. Genellikle, bu değeri optimize etmek için deneysel bir ortamda farklı parametreler kullanılır.

Genel deęerlendirmede, Hebb kuralı, öğrenme algoritmalarının çoęunluęunun temelidir. Baęlantının her iki tarafındaki nöronlar aynı anda etkinleřtirilirse, bir sinapsın gücü artacaktır. 4.3'teki denklemini 4.6'daki řekilde deęiřtirsek, giriř baęlantı (sinaps)  $w_{ij}$  aęırlıęı,  $p_j$  giriři ve  $a_i$  çıkıřı arasındaki baęlantıdır.

$$a_i = \sum_{j=1}^R w_{ij} p_j \quad (4.6)$$

Hebb'in önermesi ve "Giriř  $p_j$  ve çıkıř  $a_i$  arasındaki baęlantı (sinaps) artırılmalıdır" sözü, 4.7'deki denklemin türetilmesi ile sonuçlanmaktadır. Bu ifadede  $p_{jq}$   $q$ 'nuncu giriř vektöründeki  $j$ 'ninci elemanı,  $a_{iq}$  ise aęa  $q$ 'nuncu giriř vektörü uygulandıęında oluřan çıkıř vektörünün  $i$ 'ninci elemanıdır [68].

$$w_{ij}^{yeni} = w_{ij}^{eski} + \alpha a_{iq} p_{iq} \quad (4.7)$$

Aę, eęitim sırasında bir baęlantının aktif çiftleri arasındaki iliřkiyi artırarak, sadece ilki test sırasında bilinen çiftin ikinci nöronunu uyarmak için hazırlanmıřtır.

İki nörondan birinin hedef deęeri bilindięinde uygulanan Delta Kuralı (Widrow-Hoff Öğrenme Algoritması veya LMS Algoritması olarak da bilinir), Hebb kuralının önemli bir modifikasyonudur. İki nöron arasındaki baęlantı girdi ve çıktıdaki hata bu kuralla kuvvetlendirilir. Takip eden denklemler bu kuralın matris ifadesini saęlar.  $k$  tekraralama sayısını,  $i$  çoklu çıkıřlardaki kaçınıcı çıkıř deęiřkeni olduęunu,  $e$  ise hedef deęer ile çıkıřın mevcut deęeri arasındaki baęıl hatayı ve  $t$  çıkıřta görölmek istenen hedef deęeri ifade etmektedir.

$$w_i(k+1) = w_i(k) + 2\alpha e_i(k) p(k) \quad (4.8)$$

$$b_i(k+1) = b_i(k) + 2\alpha e_i(k) \quad (4.9)$$

$$e_i(k) = t_i(k) - a_i(k) \quad (4.10)$$

Bu kuralda en dik iniş algoritması için performans göstergesi olarak en küçük hata karelerinin ortalaması kullanılır. Bu algoritma, çok katmanlı ağlar için ilk tür geri yayılım algoritması olması ve günümüzde çeşitli sinyal işleme algoritmalarında yaygın olarak kullanılması nedeniyle özellikle önemlidir [68]. Perceptron Öğrenme Kuralı, Delta Kuralının tek katmanlı ağırlıklara sahip ikili eşik nöronlarına uygulanmasına denir. Bu kural ile kusursuz bir sonuç mevcut ise, sonucu gösteren ağırlık setinin bulunması sağlanır.

Aynı zamanda bir Hebb Kuralı türevi olan öğrenme algoritması, LVQ ve RBF ağlarında olduğu gibi global fonksiyonlarda da kullanılmaktadır.

$$w_i(k+1) = w_i(k) + \alpha p(k)(a_i(k) - w_i(k)) \quad (4.11)$$

Çıkış değeri aktif olduğunda, bu kural, kürenin merkezini temsil eden ağırlık değerini giriş örneğine [71] yaklaştırır.

#### 4.6. SİNİRSEL AĞLARIN SINIFLANDIRILMASI

Ağın topolojisi, ağın düğümlerinin özellikleri, deterministik veya olasılıksal transfer fonksiyonları ve eğitim veya öğrenme teknikleri gibi yönlerin tümü, yapay sinir ağlarını kategorize etmek için kullanılabilir. Bu çalışmada öğrenme metodolojilerine göre sınıflandırma yapılacaktır. Farklı öğrenme stillerine göre üç ana sınıf vardır. Bu öğrenme yöntemleri denetimli öğrenme, yarı denetimli (pekiştirilmiş) öğrenme ve denetimsiz öğrenme olarak kategorize edilebilir.

Hibrit ağlar, ağ mimarilerinin çoğunluğunun bu kategorilerden birine girmesine rağmen, bu sınıflardan bazılarını aynı anda destekleyebilir. Buna ek olarak, mimarileri zamanla değişebilen ve farklı bir bölümde ele alınması gereken dinamik ağlar mevcuttur.

#### 4.6.1. Denetimli Öğrenme

Öğrenme denetlendiğinde, bir öğretici tarafından ağ hatalarını açıkça düzeltilir ve her bir girdi örneği için çıktı hedeflerini belirlenir [77]. Girişler ağa uygulandıktan sonra ağ çıkışları hedef değerlerle karşılaştırılır. Öğrenme kuralı daha sonra ağ çıkış değerlerini istenen değerlere yaklaştırmak için hata eğilim vektörlerini ve ağ ağırlıklarını değiştirir [68]. Bu sınıfta yinelemeli ve ileri beslemeli ağlar incelenebilir.

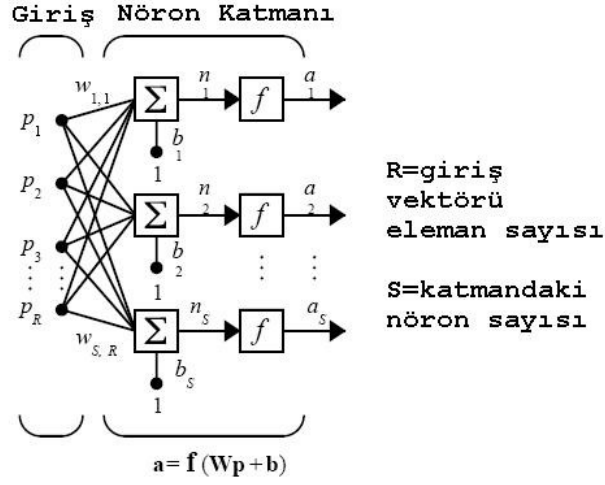
##### 4.6.1.1. İleri Beslemeli Ağlar

Bir nöronun birçok girdisi olmasına rağmen, bir problemi çözmek için yeterli olmayabilir. Bazı durumlarda bir katman veya aynı anda çalışan birçok nöron gerekebilir. Bu ağlar, soruna göre tek katmanlı veya çok katmanlı olabilir.

Şekil 4.8,  $S$  nöronları içeren tek katmanlı bir ağı göstermektedir.  $R$  girişlerinin her biri farklı bir nörona bağlanmıştır ve ağırlık matrisi, gösterildiği gibi  $S$  satırlarına sahiptir.

Katman, çıktı vektörü  $\mathbf{a}$ , toplayıcılar, hata eğilim vektörü  $\mathbf{b}$ , ağırlık matrisi ve transfer fonksiyonlarını içerir. Girdiler, bazı literatür kaynaklarında ayrı bir katman olarak da anılır.

$\mathbf{W}$  ağırlık matrisi, her bir nöronu, giriş vektörü  $\mathbf{p}$  'nin karşılık gelen elemanına bağlanmıştır. Her nöronun bir toplayıcısı, bir transfer  $f$  fonksiyonu, bir  $a_i$  çıktısı ve bir  $b_i$  hata eğilim vektörü vardır. Tamamı bütünsel ele alındığında çıkışlar; Çıkış vektörü  $\mathbf{a}$ 'yı oluşturulur.



Şekil 4.8. Tek katmanlı ağ.

Katmanın giriş sayısı sıklıkla nöron sayısından farklıdır. Katmanın nöronları için çeşitli transfer fonksiyonları isteniyorsa, bu fonksiyonlara sahip yeni bir nöron katmanı kurulur ve daha sonra iki katman paralel olarak birleştirilir. Her iki ağın girdileri aynı olmalı ve her ağın çıktısı her iki ağı da içermelidir.

5.12'de belirtilen denklemde, girdi vektör elemanları  $\mathbf{W}$  ağırlık matrisi ile birlikte ağa dahil edilir.

$$\mathbf{W} = \begin{bmatrix} w_{1,1} & w_{1,2} & \cdots & w_{1,R} \\ w_{2,1} & w_{2,2} & \cdots & w_{2,R} \\ \vdots & \vdots & & \vdots \\ w_{S,1} & w_{S,2} & \cdots & w_{S,R} \end{bmatrix} \quad (4.12)$$

$\mathbf{W}$  matrisi elemanlarının satır değeri, o ağırlıkla ilgili nöronu gösterirken, o ağırlık için kaynak girişi sütun değeri ile ifade edilir.  $w_{4,3}$  ağırlık değeri 4. nöron ile 3. giriş arasındaki bağlantıyı göstermesi örnek verilebilir. [68].

Denetimli öğrenmeyi kullanan ileri beslemeli ağların en temel tipleri perseptronlardır. İkili eşik nöronları, perseptronu oluşturan temeldir. Transfer fonksiyonları eşik fonksiyonu seçilerek, Şekil 4.8'de gösterilen tek katmanlı ağ topolojisi, delta kuralı veya türevleri ile eğitilebilen çok nöronlu bir perseptrona dönüştürülebilir.

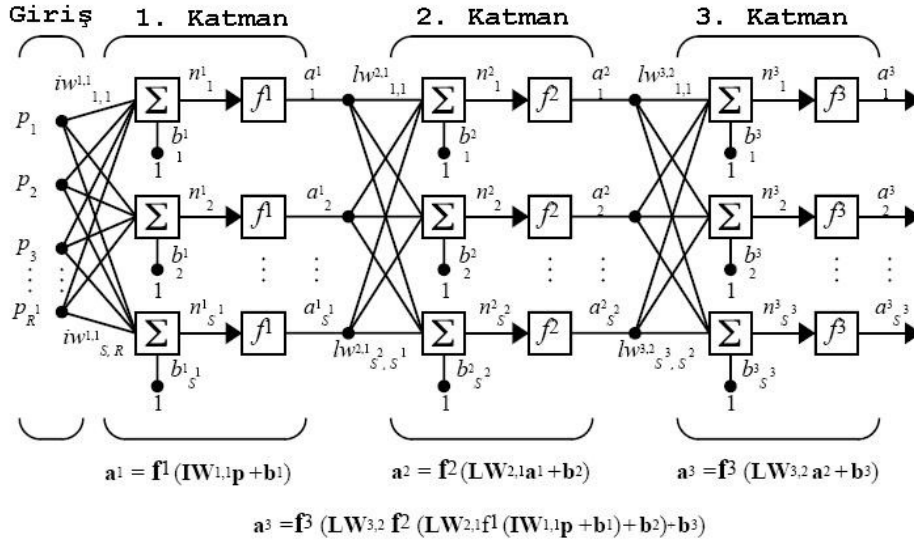
Delta Kuralı, tek katmanlı bir perseptrona hemen uygulanabilir. Perseptronun aktivasyonları ikili olduğu için, bu genel öğrenme kuralı, bir girdi aktif (=1) ve çıktı yanlış ise, ağırlık öğrenme oranının küçük bir değeri ile, tahmin edilen çıktının 0 veya 1 olmasına bağlı olarak ağırlığın azaltılması veya arttırılması gerektiğini belirten Perseptron Öğrenme Kuralı'na devşirilir. öğrenme oranı değeri. 'e düşürülür. Örnekler doğrusal olarak ayrılabilirse, bu teknik, örnekleri herhangi bir eğitim setinde doğru bir şekilde kategorize eden ağırlıkların keşfedileceğini garanti eder. Basit XOR örneğinden farklı olarak eğitim setlerinin çoğu doğrusal olarak ayrılamaz. Bu tür koşullar çok sayıda katman gerektirir [71].

Birden fazla katmanlı bir ağı değerlendirildiğimizde, katmanların kendileri için **b** hata eğilim vektörü, **W** ağırlık matrisi, **a** çıkış vektörü ve **n** net girişi vektörü vardır. Katmanların birbirlerinden ayrılabilmesi ve tanımlanabilmesi için üst simgeler kullanılır. Dolayısıyla  $W^1$ , birinci katmanın ağırlık matrisini gösterirken,  $W^2$  ikinci katmanın ağırlık matrisini gösterir. Aynı şekilde  $S^1$  bir numaralı katmana ait nöron sayısını gösterirken,  $S^2$  iki numaralı katmana ait nöron sayısını göstermektedir. Bu gösterimler şekil 4.9'de verilen üç katmanlı bir ağda görülebilmektedir. Katmanların nöron sayıları birbirlerinden farklı olabilir.

Şekil 4.9'da verilen ağın birinci ve ikinci katmanların çıkışları sırasıyla ikinci ve üçüncü katmanların girişleridir. Böylece ikinci katman  $R = S^1$  giriş sayısına sahip,  $S = S^2$  nöron sayısına sahip ve  $S^1 \times S^2$  satır sütunlu  $W^2$  ağırlık matrisli bir katmanlı ağ olarak değerlendirilebilir.  $a^1$  ağ girişidir,  $a^2$  ağ çıkışıdır.

Çıkışı, ağın çıkışı olan katmana “çıkış katmanı” denir. Geride kana katmanlar da “gizli katman” denir.





Şekil 4.9. Çok katmanlı ağlara örnek olarak üç katmanlı bir ağ.

Tek katmanlı ağlarla karşılaştırıldığında, çok katmanlı ağlar çok daha sağlamdır(güçlüdür). Örneğin, birinci katman için bir sigmoid transfer fonksiyonu ve ikinci katman için bir lineer transfer fonksiyonuna sahip iki katmanlı bir ağ, tek katmanlı ağlarla yaklaşık olarak tahmin edilmesi imkansız olan çeşitli fonksiyonların yaklaştırılmasında etkilidir. Sinir ağları genellikle sadece iki veya üç katmana sahiptir. Nadiren dört veya daha fazla seviyeli ağlar kullanılır. [68].

Eğitilmeleri daha zor olsa da, çok katmanlı perseptronlar herhangi bir işlevi öğrenme potansiyeline sahiptir. Gizli katman veya katmanlarda hedef olmadığı için Delta Kuralı çok katmanlı perseptronlara doğrudan uygulanamaz. Bununla birlikte, çok katmanlı bir perseptron ayrı bir işlev yerine sürekli bir etkinleştirme işlevi kullanıyorsa (örneğin, eşik yerine sigmoidal) herhangi bir ağırlığın zincirlenmiş herhangi bir çıktı aktivasyonu üzerindeki etkisini belirlemek için kısmi türevler uygulayabilecektir. Bu şekilde ağ hatasını azaltmak için ağırlığı ayarlamak mümkün olacaktır. Geri yayılım, Delta Kuralının bu kullanımı için kullanılan terimdir. [71].

Zaman gecikmeli sinir ağı, başka bir çok katmanlı ağ formudur (TDNN). Bu mimari başlangıçta konuşma tanıma için oluşturulmuş olsa da, dudak okuma ve el yazısı tanıma gibi diğer uygulamalara da uygulanmıştır. Bağlantılı nöronların geçici olarak

yeniden düzenlenmesi(sırasızlaşması), zaman gecikmeli bağlantılar olmasından kaynaklıdır. Geleneksel geri yayılımı kullanarak eğitim alırlar. Eğitim sürecinin farklı olan tek yönü, düğümlü ağırlıkların bağımsız olarak değil, ortalananmış hata sinyallerine göre ayarlanmasıdır.

LVQ ağı, girdi örneklerini kategorize edebilen başka bir ağ yapısı türüdür. Bir LVQ ağı, çıktıların sınıflar olarak hizmet ettiği ve girdilerden gelen ağırlıkların hiper kürelerin merkezleri olarak hizmet ettiği tek katmanlı bir ağıdır. Eğitim sırasında sınıfları kapsayacak şekilde hiper küreleri hareket ettirilir [71].


#### 4.6.1.2 Yinelenen Ağlar

İçeriğe göre adreslenebilir çağrışımsal belleğin belirli bir biçimini oluşturmak için, Hopfield sinir ağlarıyla deneyler yapmıştır. Çift eşikli transfer fonksiyonuna ve asenkron aktivasyon güncellemelerine sahip nöronlarla simetrik ( $w_{ij} = w_{ji}$ ) olarak bağlı, yapısal olmayan ağları incelemiştir. Bu ağlar artık Hopfield ağları olarak anılmaktadır. Hopfield, bir ağıdaki ağırlıklar Hebb Kuralına göre değiştirilirse, eğitim örneklerinin durum uzayında çekicilere dönüşeceğini göstermiştir. Numunelerin bozulmuş bir versiyonu kendisine uygulanırsa ve ağın aktivasyonları rasgele, asenkron olarak (önceden öğrenilen ağırlıklar kullanılarak) güncellenirse, ağ sonunda durum uzayındaki örneklere en yakın olan aktivasyon örneğini yeniden oluşturur. Anahtar, ağın dinamiklerini, bir nöronun aktivasyonu güncellendikçe azalması gereken ve nihayetinde bellekte tutulanlara karşılık gelen aktivasyon kalıpları için minimum bir değere ulaşması gereken genel bir enerji fonksiyonu açısından incelemektir.

Boltzman makinesi, öğrenme sürecinde gizli nöronlara, olasılıksal aktivasyona ve simüle edilmiş sertleştirmeye sahip bir Hopfield ağıdır. Prensip olarak son derece güçlüdür ve sayısız uygulamada başarıyla uygulanmıştır.

Yinelemeli ağların diğer çeşitleri, daha önceki katmanlara geri bildirim sağlayan bağlantılara sahip sistematik bir tasarıma sahiptir. Şekil 4.10, Jordan ağları ve Elman ağları olmak üzere iki örnek sunmaktadır. Bu ağlar, aktivasyonları gizli katmandan veya çıktılardan kopyalanan ve gizli katmana bağlanan girdiler için ekstra "bağlam

nöronları" içerir. Ağlara, çok uzun mesafelerde olmasa da, bağlam nöronları tarafından azaltılmış bir bellek şekli verilir. Eğitilebilir tüm ağırlıkların ileri beslemeli olması nedeniyle, bu ağlar geri yayılım kullanılarak da eğitilebilir. [71].



Şekil 4.10. Katmanlı yinelenen ağlar. (a) Jordan ağı; (b) Elman ağı.

#### 4.6.2. Yarı Denetimli Öğrenme

Yarı denetimli öğrenme, algoritmanın her ağ girişi için doğru çıktılar yerine bir derecelendirme alması dışında denetimli öğrenmeyle aynıdır. Bu puan, ağın belirli girdi dizilerinde ne kadar iyi performans gösterdiğinin bir göstergesi olarak hizmet eder. Günümüzde, denetimli öğrenme bu tür öğrenmeden çok daha yaygındır [68]. Çeşitli türlerdeki yarı denetimli ağlar, topolojilerinden ziyade ortam yapıları ve öğrenme stratejileri ile ayırt edilir. Statik veya dinamik ortamların her ikisi de mümkündür. Örneğin, değerlendirmeler deterministik veya olasılıksal olabileceği gibi, "iyi" davranış kavramı da sabit olabilir veya zaman içinde değişebilir.

İlişkisel ödül-ceza yöntemi, ağları statik durumlarda eğitebilir. Algoritmanın olasılıksal çıktı nöronları varsayımı sayesinde ağ, farklı davranışlarla denemeler yapabilir. Yarı denetimli öğrenme sorunu, ağ hedeflerinin ağın ortalama çıktısıyla karşılaştırıldığı ve ağın davranışının iyi veya kötü olarak kabul edilip edilmediğine bağlı olarak gerekirse hatanın ağ üzerinden geri yayıldığı Delta Kuralı kullanılarak öğretilir.

Çevreyi temsil etmeye çalışan bir yardımcı ağ kurmak, statik veya dinamik bağlamlarda kullanılabilecek başka bir stratejidir. Bu destekleyici ağ, harici verileri bir sinyale dönüştürür. Sonuç olarak, yarı denetimli öğrenme sorunu, önceden belirlenmiş hedeflerle iki aşamada denetimli öğrenme sorununa basitleştirilmiştir. Her iki ağ üzerinde geri yayılımı kullanmadan önce, yardımcı ağ, ortamı simüle etmek için uygun şekilde eğitilmelidir. Sonuç olarak, yardımcı ağ, ana ağın çıkışlarının her birine ayrı hata sinyalleri sağlar.

Dinamik durumlara uygun benzer bir strateji, yardımcı ağ bir "kritik" olduğunda aşağıdaki destekleyici sinyali tahmin etmek için destek sinyalini ve çevresel verileri kullanır. Gerçek ağın performansının beklentileri aşp aşmadığını veya yetersiz kaldığını belirlemek ve mevcut ve beklenen destekleyici sinyalleri karşılaştırarak ağı buna göre ödüllendirmek veya cezalandırmak mümkündür. [71].

#### **4.6.3. Denetimsiz Öğrenme.**

Denetimsiz öğrenmede, ağın girdi yanıtları, ağırlıkları ve hata eğilim vektörlerini etkileyen tek şeydir. Hedef değerler mevcut değildir. İlk bakışta, kullanışlı görünmeyebilir. Kullanılan algoritmaların çoğu bir tür kümeleme ile uğraşmaktadır. Sınırlı bir dizi girdi örneğini sınıflandırmak için kullanılırlar. Bu, vektör kuantizasyon uygulamalarında çok faydalıdır [68]. Bu kendi kendini organize eden ağlar tipik olarak girdi verilerinin sıkıştırılması, kümeleme, nicemleme, sınıflandırma veya haritalama için kullanılabilir.

Denetimli eğitim modelini taklit etmek için yapıyı yeniden tasarlamak ve her girdi örneği için yapay bir hedef görüntüleyerek geri yayılım uygulamak denetimsiz eğitim elde etmenin iki yöntemidir. Örneğin, bir ağa girdi örneklerini çıktı katmanındaki gizli nöronlardan geçerken tekrar etmesi öğretilir. Böyle bir ağ, gizli katmanında mümkün olduğu kadar verileri koruma yeteneğini geliştirir. Sonuç olarak, girdi verileri sıkıştırılır ve gizli katmanda temsil edilir. Girişler ve çıkışlar ikili vektörler olduğunda, bu ağlara sıklıkla kodlayıcı denir. Bu ağlar, başka bir deyişle boyutsal indirgeme gerçekleştirir.

Hebbian öğrenimi, genellikle gizli birimler içermeyen diğer denetimsiz ağ türlerini eğitmek için kullanılır. Bu öğrenme yaklaşımı, örneğin, girdi örneğindeki benzerlikleri tanımak için tek bir doğrusal birimi eğitmek için kullanılabilir.  $M$  lineer çıktı birimlerine sahip bir set, bu öğrenme sürecinin uzantıları kullanılarak dağıtımın  $M$  birincil bileşenlerine bir girdi örneğini yansıtacak şekilde eğitilebilir. Böylece çıktı katmanı, girdilerin sıkıştırılmış temsillerini oluşturacaktır. Bununla birlikte, ağırlıkların aşırı derecede büyük olmasını önlemek için bu kuralın değiştirilmesi gerekir, çünkü doğrusal birimlere sahip Hebb kuralı, ağırlıkların sınırsız olarak genişlemesine neden olur. Sanger Kuralı, kullanılabilir bu değişikliklerden biridir.

Her katmanın bir sonraki katmana düzlemsel ve geometrik olarak yerel bağlantılara sahip olduğu çok katmanlı bir ağda kullanıldığında, Linsker, değiştirilmiş bir Hebbian öğrenme yönteminin otomatik olarak kullanılabilir özellik algılayıcıları oluşturabileceğini göstermiştir.

Günümüzde kullanılan diğer denetimsiz ağlar, kazananın çıkışlardan biri tarafından belirlendiği rekabetçi öğrenmeye dayanır. Kazanan hepsini alır ağları bu ağlar için başka bir isimdir. Çıkışlardaki yan blokaj bağlantılarını veya sadece kaybeden nöronların kayıp aktivasyonlarını sıfıra getiren çıkış aktivasyonlarını karşılaştırarak, kazanan nöron tanımlanabilir. Girdi örneklerini kategorize etmek veya nicelleştirmek için veri kümeleme için rekabetçi öğrenme yararlıdır. Bu öğrenme moduyla, bazı nöronlar girdilerden öğrenemeyecek kadar uzakta olabilir, bu yüzden asla öğrenmezler. Gerçek girdi örneklerine karşılık gelen ağırlıkların başlangıç değerlerini vermek veya kazanan hepsini alır gereksinimini biraz azaltmak, bunun gibi ölü nöronların oluşmasını önlemeye yardımcı olur.

İkili ve sürekli girdiler için Adaptif Rezonans Teorisi ağları, ART1 ve ART2, sırasıyla Carpenter ve Grossberg tarafından oluşturulmuştur. Girdi örneği herhangi bir mevcut kümeden bir uyanma parametresine göre yeterince sapsa yeni bir küme oluşturarak, bu ağlar rekabetçi öğrenmeyi kolaylaştırır. Bireysel çıktı nöronları, kümeler için standart temsil görevi görür. Ancak, bir ART ağındaki çıkış nöronları, gerekli olana kadar gizli tutulur. Bu ağlar, donanımla uygulanabilen arama teknikleri kullanır.

Kohonen, topolojik bağlantıları korurken örnekleri girdi uzayından çıktı uzayına eşlerkenki gibi özellik eşleştirmesin amaçlı rekabetçi bir öğrenme yöntemi oluşturmuştur.

#### **4.6.4. Melez Ağlar**

Çeşitli düzeylerinde, bazı ağlar denetimli ve denetimsiz eğitimi entegre eder. Çoğu durumda, verileri kümelemek için en düşük dereceli katmana denetimsiz eğitim uyguladıktan sonra veri kümelerini amaçlanan çıktılarla ilişkilendirmek için geri yayılım kullanılır. Örneğin bir Radyal Tabanlı Fonksiyon ağında, gizli katman, geleneksel bir rekabetçi öğrenme algoritması kullanılarak eğitilmiş hiper küreleri tanımlayan nöronlara sahiptir ve Delta Kuralı kullanılarak eğitilen çıktı katmanı, bu anlayışlı alan fonksiyonlarının normalleştirilmiş doğrusal kombinasyonlarını hesaplar. Bu tür hibrit ağlar çekicidir çünkü çok katmanlı geri yayılım algoritmasını tek katmanlı Delta Kuralına küçülterek basitleştirilmesini ve eğitim süresini büyük ölçüde kısaltılmasını sağlar. Bununla birlikte, bu tür ağlar, entegre bir şekilde eğitilmekten ziyade tipik olarak bağımsız modüller açısından geliştirildiğinden, tek başına bir geri yayılım yöntemi kullanılarak eğitilen ağlardan biraz daha az doğrudurlar.

#### **4.6.5. Dinamik Ağlar**

Önceki dört alt bölümde bahsedilen statik ağlara ek olarak, en yüksek performansı elde etmek için yapıları zamanla değişen dinamik ağlar da vardır. Bir ağın tasarımı, nöronları, ağırlıkları veya her ikisini de dahil ederek veya kaldırarak değiştirilebilir. Bu budama ve derleme birbirine zıt iki stratejidir. Derleme algoritmaları çoğu zaman mütevazı boyutları nedeniyle genellikle daha hızlı çalışırken, belirli öğeleri yok saydığı için budama daha kolaydır.

Budama, elbette, ağın en az değerli bileşenlerini bulmak için bir teknik gerektirir. En hafif ağırlıkların kaldırılması açık ve basit bir işlemdir. Bu, genellemeyi artırabilir, ancak bazen hatalı ağırlıkları da ortadan kaldırabilir. Daha karmaşık ama güvenilir bir yöntem olan Optimal Beyin Hasarı, kaldırılması ağın çıktı hatası işlevinde en az artışa

neden olacak ağırlıkları tanımlar. Bunun için bilginin ikinci dereceden türevinin hesaplanması gereklidir.

Cascade Correlation en popüler ve verimli yapıcı yöntemdir. Bu algoritma, gizli katman nöronları olmadan başlar, ancak herhangi bir çıktı hatasını, azaltılmasına katkıda bulunduğu kademeli olarak artırır. Önceki tüm ağ ağırlıkları, her eğitim turunda dondurulur ve çıktı olmayan her birime yeni bir aday birim havuzu eklenir. En etkili birim ağa tam olarak entegre edilirken, daha az etkili olan aday birimler kaldırılır. Her aday birim, çıktısı ile ağın kalan hatası arasındaki bağlantıyı optimize etmek için eğitilir. Ünitinin çıktı katmanına göre ağırlığı uygun şekilde kalibre edilmiştir. Bu süreç istenen ağ performansına erişilinceye kadar yinelenir. Bu algoritma hızlı bir şekilde son derece etkili, yoğun ve güçlü ağlar oluşturabilir.

Son olarak Bodenhausen, Otomatik Yapı Optimizasyonu olarak bilinen yararlı yöntemini önermiştir. Özellikle çevrimiçi el yazısı tanıma ve konuşma tanıma dahil olmak üzere çok az eğitim verisi içeren uzamsal ve zamansal sorunlar için yapılmıştır. Küçük bir ağdan başlayarak, ASO algoritması yavaş yavaş bağlantılar, zaman gecikmeleri, gizli nöronlar ve durum birimleri gibi kaynakları ekler [71].

#### **4.7. GERİ YAYILIM ALGORİTMASI**

Geri yayılım tekniği, çok katmanlı ağ eğitimi için popüler bir algoritmadır. Performans göstergesi ve delta kuralından algoritmanın karelerinin ortalaması arasındaki tek fark, bu algoritmada sadece türevlerin hesaplanmasıdır. Hata, tek katmanlı bir ağdaki ağ ağırlıklarının açıkça doğrusal bir fonksiyonudur ve ağırlıklara göre türevinin hesaplanması kolaydır. Ağ ağırlıkları ve hata arasındaki ilişki, doğrusal olmayan transfer fonksiyonlarına sahip çok katmanlı ağlarda daha karmaşıktır. Türevler, değişkenler hesabının zincir kuralı kullanılarak hesaplanır.

Delta kuralı algoritması ve Perseptron öğrenme kuralı, tek katmanlı Perseptron benzeri ağları eğitmek için kullanılır. Bu tek katmanlı ağların dezavantajı, yalnızca doğrusal ayrılabilirlikle sınıflandırma sorunlarını çözebilmeleridir. Bu kuralların ve

algoritmaların önericileri tarafından bu sınırların üstesinden gelmek için sunulan çok katmanlı ağlar, bu kısıtlamaların farkında olmalarına rağmen, bu daha sağlam ağları eğitmek için algoritmalarını genelleştirememişlerdir.

Werbos'un tezi, geriye dönük olarak, çok katmanlı ağları eğitmek için bir algoritmanın ilk tanımını içerir. Genel ağlar bağlamında, bu tez belirli bir senaryo için bir algoritma ve sinir ağları sunmuştur. 1980'lerin ortalarında, geri yayılım algoritması yeniden keşfedildi ve çok popüler olmuştur. Rumelhart, Hinton ve Williams, Parker ve Le Cun gibi bağımsız araştırmacılar birbirlerinden bağımsız olarak ayrı ayrı keşfetmişlerdir. Paralel Dağıtılmış İşleme kitabına dahil edilerek, Rumelhart ve McClelland liderliğindeki Paralel Dağıtılmış İşleme Grubu'nun çalışması ile popülerlik kazanmıştır [68].

Bir ağ eğitildiğinde, bir girdi veri kümesine yanıt olarak belirli bir işlevsel özelliğe sahip çıktılar üretmek için ağırlıkları değiştirilir. Her girdi vektörü, eğitimin tamamlanması için istenen çıktı vektörünü temsil eden bir hedef çıktı vektörüne sahip olmalıdır. Bu eğitim çifti, girdi ve hedef çıktı vektörlerinden oluşur. Geri yayılım ağında öğrenmeyle ilgili adımlar aşağıdaki gibidir [75]:

- Eğitim setinden aşağıdaki eğitim çifti seçilirken giriş vektörü ağ girişine uygulanır.
- Ağın çıktısı hesaplanır.
- Eğitim çiftinden ağ çıkışı ile hedef vektör arasındaki hatayı belirlemek için bir hesaplama yapılır.
- Hatayı azaltmak için ağın ağırlıkları değiştirilir.

Bu işlemler, hata karelerinin ortalamasının performans kriteri olduğu bir ağdaki hata karelerinin ortalamasının önceden tanımlanmış belirli bir sınır değerinin altında kalması sağlanana kadar gerçekleştirilir. Bu sınır değeri karşılandığında ağın eldeki görev için eğitilmiş olduğu kabul edilir. Ağın bu gereksinimi karşılayan ağırlıkları belirlenir ve ileride kullanılmak üzere saklanır. Ağ, eğitim işinin yürütülmesi sırasında sonuca ulaşmak için bu ağırlık değerlerini kullanır.



### 4.7.1. Algoritma

Şekil 4.9’de verilen 3 katmanlı bir ağ yapısını ele alacak olursak, 4.4 eşitliğindeki çok girişli bir nöronun çıkış eşitliğinden  $M$ ’nin katman sayısını ifade ettiği çok katmanlı bir ağ için matrisel gösterim ile;

$$\mathbf{a}^{m+1} = \mathbf{f}^{m+1}(\mathbf{W}^{m+1} \mathbf{a}^m + \mathbf{b}^{m+1}) \quad m = 0,1,\dots,M-1 \quad (4.13)$$

eşitliğine ulaşılabilir. Birinci katman nöronlarının dış girdilere maruz kalacağı göz önüne alındığında:

$$\mathbf{a}^0 = \mathbf{p} \quad (4.14)$$

olacaktır ve 4.13 eşitliği için başlangıç sağlar. Ağ çıkışı, son katmandaki nöron çıkışları olarak değerlendirilir.

$$\mathbf{a} = \mathbf{a}^M \quad (4.15)$$

Sürecin bu ilk adımı ileri yayılım olarak isimlendirilir (forward propagation).

#### 4.7.1.1 Performans Göstergesi

Çok katmanlı ağlar için geri yayılım algoritması olan genişletilmiş delta kuralı yöntemi, performans ölçütü olarak hata karelerinin ortalamasını kullanır. Bu algoritma için uygun ağ özelliklerini gösteren örnekler aşağıda verilmiştir.

$$\{\mathbf{p}_1, \mathbf{t}_1\}, \{\mathbf{p}_2, \mathbf{t}_2\}, \dots, \{\mathbf{p}_Q, \mathbf{t}_Q\}, \quad (4.16)$$

Bu durumda, hedef çıkış  $\mathbf{t}_q$ , ağ girişine uygulanan  $\mathbf{p}_q$  girişine karşılık gelir. Ağ çıkışı, ağa uygulanan her giriş için hedefle karşılaştırılır. Ortalama karesel hatayı azaltmak için algoritmanın ağ ayarlarını değiştirmesi gerekir.

$$F(x) = E[e^2] = E[(t - a)^2] \quad (4.17)$$

Burada  $x$ , hata ve net ağırlık trend vektörlerini temsil etmektedir. Beklenen değer  $E[\ ]$  ile gösterilir. Ağırlık birden fazla çıktısı varsa, 4.17 ile verilen denklem, matris yapılı 4.18 ile verilen denklemle genelleştirilebilir.

$$F(\mathbf{x}) = E[\mathbf{e}^T \mathbf{e}] = E[(\mathbf{t} - \mathbf{a})^T (\mathbf{t} - \mathbf{a})] \quad (4.18)$$

Karelerin hata beklentisi veya karelerin ortalaması yaklaşımı,  $k$  yinelemede hata kareleri ile değişir ve delta kuralı gibi denklem 4.19 ile belirtilen yapıyı alır.

$$\hat{F}(\mathbf{x}) = (\mathbf{t}(k) - \mathbf{a}(k))^T (\mathbf{t}(k) - \mathbf{a}(k)) = \mathbf{e}^T(k) \mathbf{e}(k) \quad (4.19)$$

Öğrenme oranı  $\alpha$ 'yı ifade eden 4.20 ve 4.21 denklemleri, yaklaşık hata karelerinin ortalaması için en dik iniş algoritmasını sağlamak için kullanılabilir.

$$w_{i,j}^m(k+1) = w_{i,j}^m(k) - \alpha \frac{\partial \hat{F}}{\partial w_{i,j}^m} \quad (4.20)$$

$$b_i^m(k+1) = b_i^m(k) - \alpha \frac{\partial \hat{F}}{\partial b_i^m} \quad (4.21)$$

Buraya kadar olan çıkarımlar delta kuralı ile aynıdır.

#### 4.7.1.2 Zincir Kuralı

Hata gizli katmanlardaki ağırlıkların bir türevi olduğundan türevler zincir kuralı kullanılarak hesaplanır. Zincir kuralını hatırlayacak olursak, sadece  $n$  değişkenli bir  $f$  fonksiyonunun türevini ve üçüncü değişken olarak  $w$ 'yi almak istediğimizde, aşağıda sunulan denklem 4.22'ye benzer.

$$\frac{df(n(w))}{dw} = \frac{df(n)}{dn} \times \frac{dn(w)}{dw} \quad (4.22)$$

Örnek verecek olursak;  $f(n) = e^n$  ve  $n = 2w$  eşitliklerinden  $f(n(w)) = e^{2w}$  sonucuna ulaşılırken bu kural ile  $\frac{df(n(w))}{dw} = \frac{df(n)}{dn} \times \frac{dn(w)}{dw} \Rightarrow \frac{df(n(w))}{dw} = (e^n)(2)$  sonucuna ulaşılabilir.

Bu kural, 4.20 ve 4.21 denklemlerindeki türev hesaplamalarının aşağıdaki yapılara dönüştürülmesine izin verir.

$$\frac{\partial \hat{F}}{\partial w_{i,j}^m} = \frac{\partial \hat{F}}{\partial n_i^m} \times \frac{\partial n_i^m}{\partial w_{i,j}^m} \quad (4.23)$$

$$\frac{\partial \hat{F}}{\partial b_i^m} = \frac{\partial \hat{F}}{\partial n_i^m} \times \frac{\partial n_i^m}{\partial b_i^m} \quad (4.24)$$

Katman  $m$  'ye net girdi, denklem 4.25 ile verilen ağırlık ve hata eğilim vektörlerinin bir fonksiyonu olduğundan, yukarıda belirtilen 4.23 ve 4.24 denklemlerinin her birinin ikinci kısımlarının hesaplanması kolaydır. Bu noktadan aşağıdaki denklemler elde edilebilir.

$$n_i^m = \sum_{j=1}^{s^{m-1}} w_{i,j}^m a_j^{m-1} + b_i^m \quad (4.25)$$

$$\frac{\partial n_i^m}{\partial w_{i,j}^m} = a_j^{m-1} \quad (4.26)$$

$$\frac{\partial n_i^m}{\partial b_i^m} = 1 \quad (4.27)$$

Bu aşamada, aynı denklemler 4.23 ve 4.24'ün ilk kısımları  $\hat{F}$  'in net girdinin  $i$ 'inci elemanındaki değişikliklere duyarlılığı olarak tanımlanarak bu denklemler aşağıda gösterildiği gibi daha basit hale getirilebilir.

$$s_i^m \equiv \frac{\partial \hat{F}}{\partial n_i^m} \quad (4.28)$$

$$\frac{\partial \hat{F}}{\partial w_{i,j}^m} = s_i^m a_j^{m-1} \quad (4.29)$$

$$\frac{\partial \hat{F}}{\partial b_i^m} = s_i^m \quad (4.30)$$

Aşağıda, 4.20 ve 4.21 denklemleri tarafından sağlanan yaklaşık en dik iniş algoritması için bir ifade yer almaktadır.

$$w_{i,j}^m(k+1) = w_{i,j}^m(k) - \alpha s_i^m a_j^{m-1} \quad (4.31)$$

$$b_i^m(k+1) = b_i^m(k) - \alpha s_i^m \quad (4.32)$$

Bunu matris yapısında ifade etmek için aşağıdaki denklemler kullanılabilir. Sağlanan bir  $\mathbf{s}^m$  matrisi de vardır.

$$\mathbf{W}^m(k+1) = \mathbf{W}^m(k) - \alpha \mathbf{s}^m (\mathbf{a}^{m-1})^T \quad (4.33)$$

$$\mathbf{b}^m(k+1) = \mathbf{b}^m(k) - \alpha \mathbf{s}^m \quad (4.34)$$

$$\mathbf{s}^m \equiv \frac{\partial \hat{F}}{\partial \mathbf{n}^m} = \begin{bmatrix} \frac{\partial \hat{F}}{\partial n_1^m} \\ \frac{\partial \hat{F}}{\partial n_2^m} \\ \vdots \\ \frac{\partial \hat{F}}{\partial n_{s^m}^m} \end{bmatrix} \quad (4.35)$$

#### 4.7.1.3 Duyarlılıkların Geri Yayılımı

Başka bir zincir kuralı uygulamasının kullanılmasını gerektiren işlemi bitirmek için  $\mathbf{s}^m$  duyarlılıklarının hesaplanması gereklidir. Geri yayılım, bu fenomeni tanımlamak için kullanılan ifadedir. Çünkü  $m+1$  katmanının duyarlılığını  $m$  katmanının duyarlılığından çıkararak tekrar eden bir ilişki kurar.

Aşağıdaki Jacobian matrisi kullanılarak duyarlılıkların tekrar eden ilişkileri belirlenir.

$$\frac{\partial \mathbf{n}^{m+1}}{\partial \mathbf{n}^m} \equiv \begin{bmatrix} \frac{\partial n_1^{m+1}}{\partial n_1^m} & \frac{\partial n_1^{m+1}}{\partial n_2^m} & \cdots & \frac{\partial n_1^{m+1}}{\partial n_{s^m}^m} \\ \frac{\partial n_2^{m+1}}{\partial n_1^m} & \frac{\partial n_2^{m+1}}{\partial n_2^m} & \cdots & \frac{\partial n_2^{m+1}}{\partial n_{s^m}^m} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial n_{s^{m+1}}^{m+1}}{\partial n_1^m} & \frac{\partial n_{s^{m+1}}^{m+1}}{\partial n_2^m} & \cdots & \frac{\partial n_{s^{m+1}}^{m+1}}{\partial n_{s^m}^m} \end{bmatrix} \quad (4.36)$$

Bu matris için bir ifade elde etmek için yapılması gereken çalışmada matrisin  $i,j$  elemanını dikkate alırsak;

$$\frac{\partial n_i^{m+1}}{\partial n_j^m} = \frac{\partial (\sum_{l=1}^m w_{i,l}^{m+1} a_l^m + b_i^{m+1})}{\partial n_j^m} = w_{i,j}^{m+1} \frac{\partial a_j^m}{\partial n_j^m} = w_{i,j}^{m+1} \frac{\partial f^m(n_j^m)}{\partial n_j^m} = w_{i,j}^{m+1} f^m(n_j^m), \quad (4.37)$$

$$f^m(n_j^m) = \frac{\partial f^m(n_j^m)}{\partial n_j^m}$$

Buradan da, Jacobian matrisi son olarak aşağıdaki şekile dönüştürülebilir.

$$\frac{\partial \mathbf{n}^{m+1}}{\partial \mathbf{n}^m} = \mathbf{W}^{m+1} \mathbf{F}^m(\mathbf{n}^m) \quad (4.38)$$

$$\mathbf{F}^m(\mathbf{n}^m) = \begin{bmatrix} f^m(n_1^m) & 0 & \cdots & 0 \\ 0 & f^m(n_2^m) & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & f^m(n_{s^m}^m) \end{bmatrix} \quad (4.39)$$

Zincir kuralı kullanılarak denklem 4.35 aşağıdaki denklem yapısına dönüştürülerek duyarlılık için tekrar eden bir ilişki elde etmek mümkündür.

$$\mathbf{s}^m = \frac{\partial \hat{F}}{\partial \mathbf{n}^m} = \left( \frac{\partial \mathbf{n}^{m+1}}{\partial \mathbf{n}^m} \right)^T \frac{\partial \hat{F}}{\partial \mathbf{n}^{m+1}} = \mathbf{F}^m(\mathbf{n}^m)(\mathbf{W}^{m+1})^T \frac{\partial \hat{F}}{\partial \mathbf{n}^{m+1}} = \mathbf{F}^m(\mathbf{n}^m)(\mathbf{W}^{m+1})^T \mathbf{s}^{m+1} \quad (4.40)$$

Bu denklemi kullanarak geriye yayılımın adımı nasıl aldığımızı kolayca görebiliriz. Ağın üst katmanından alt katmanına kadar duyarlılık iletilir.

$$\mathbf{s}^M \rightarrow \mathbf{s}^{M-1} \rightarrow \dots \rightarrow \mathbf{s}^2 \rightarrow \mathbf{s}^1 \quad (4.41)$$

Geri yayılım algoritmasının hala bir aşamadan daha geçmesi gerekir. Denklem 4.40'ın yinelemeli ilişkisi bir  $\mathbf{s}^M$  başlangıç noktası gerektirir. Son katman, bunun elde edildiği yerdir.

$$s_i^M = \frac{\partial \hat{F}}{\partial n_i^M} = \frac{\partial (\mathbf{t} - \mathbf{a})^T (\mathbf{t} - \mathbf{a})}{\partial n_i^M} = \frac{\sum_{j=1}^{s^M} (t_j - a_j)^2}{\partial n_i^M} = -2(t_i - a_i) \frac{\partial a_i}{\partial n_i^M} \quad (4.42)$$

Burada;

$$\frac{\partial a_i}{\partial n_i^M} = \frac{\partial a_i^M}{\partial n_i^M} = \frac{\partial f^M(n_i^M)}{\partial n_i^M} = f^M(n_i^M) \quad (4.43)$$

olduğundan 4.42'deki eşitlik:

$$s_i^M = -2(t_i - a_i) f^M(n_i^M) \quad (4.44)$$

olarak yazılabilir. Denklem 4.45 elde edilmiş eşitliğim matrisel yapısı ifade eder.

$$\mathbf{s}^M = -2\mathbf{F}^M(\mathbf{n}^M)(\mathbf{t} - \mathbf{a}) \quad (4.45)$$

Özetlemek gerekirse: İlk adımda, girdi ağ boyunca yayılır:

$$\mathbf{a}^0 = \mathbf{p} \quad (4.46)$$

$$\mathbf{a}^{m+1} = \mathbf{f}^{m+1}(\mathbf{W}^{m+1}\mathbf{a}^m + \mathbf{b}^{m+1}) \quad m = 0,1,\dots,M-1 \quad (4.47)$$

$$\mathbf{a} = \mathbf{a}^M \quad (4.48)$$

Duyarlılığı ağ üzerinden geri yaymak sonraki aşamadır.

$$\mathbf{s}^M = -2\mathbf{F}^M(\mathbf{n}^M)(\mathbf{t} - \mathbf{a}) \quad (4.49)$$

$$\mathbf{s}^m = \mathbf{F}^m(\mathbf{n}^m)(\mathbf{W}^{m+1})^T \mathbf{s}^{m+1}, \text{ for } m = M-1, \dots, 2, 1 \quad (4.50)$$

Son olarak, kabaca en dik iniş kullanılarak ağırlıklar ve hata eğilimi vektörleri güncellenir:

$$\mathbf{W}^m(k+1) = \mathbf{W}^m(k) - \alpha \mathbf{s}^m (\mathbf{a}^{m-1})^T \quad (4.51)$$

$$\mathbf{b}^m(k+1) = \mathbf{b}^m(k) - \alpha \mathbf{s}^m \quad (4.52)$$

#### 4.7.2 Geri Yayılımdaki Değişiklikler

Geri yayılım yöntemi, sinir ağı araştırmalarındaki en önemli ilerlemelerden birini temsil etse de, temel teknik birçok gerçek dünya kullanımı için çok yavaştır. Araştırmacılar, bunu aşmak için bu algoritmanın yakınsamasını hızlandırmak için stratejiler üzerinde önemli araştırmalar yaptılar. Bu çalışmalar geri yayılımın sayısal ve bulgusal değişiklikleri olarak kabaca iki ana sınıf değerlendirilebilir.

Momentum, değişken öğrenme oranı (VLBP) ve değişken yeniden ölçeklendirme araştırması, buluşsal değişiklikler altında sayılabilir. Levenberg-Marquardt algoritması (LMBP) ve eşlenik gradyan algoritmasının her ikisi de sayısal araştırmalarda sayılabilir. Bu algoritmaların her birinin türevleri, üst katmandan alt katmana geri yayılım yaklaşımını kullandığından, hepsine geri yayılım algoritmaları denilebilir. [68].

## BÖLÜM 5

### ARIMA (Autoregressive Integrated Moving Average)

Zaman Serileri, bir değişkenle ilişkili belirli ve düzenli zamanlarda meydana gelen sayısal verilerin kronolojik sırasına göre oluşturulan veri kümelerini tanımlamak için kullanılan bir terimdir. Tek değişkenli veri seti ile yapılan zaman serisi analizleri, tek değişkenli zaman serisi analizleri olarak adlandırılır [80]. Zaman serileri haftalık, aylık, altı aylık, yıllık, on yıllık veya daha geniş veya daha dar dönemlerde toplanan verilerden oluşabilir. Zaman serisi verileri stokastik tiptedir, yani zaman içinde belirli noktalarda rastgele değerler alırlar ve tahmin edilemezler. [81].

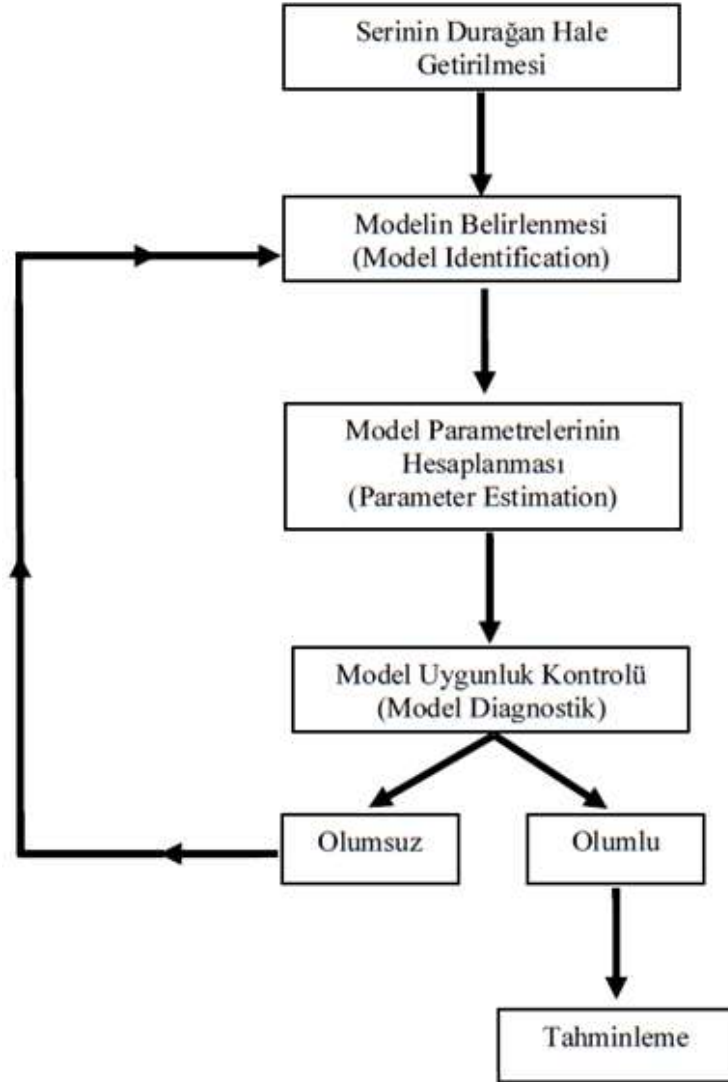
Tek değişkenli zaman serileri tipik olarak ilgili değişkenin tahmini ve gelecekteki değer değerlendirmesi için kullanılır ve bir serinin tutarlı gelecek dönem tahminleri, varsa fonksiyonel yapısını veya bu yapıya en yakın olan fonksiyonel formu tanımlamayı içerir [82]. İşler normalken zaman serilerinin gerçekte nasıl bir işlevsel yapıya sahip olduğu bilinmez. Bununla birlikte, bağlantılı seriler üzerinde kullanılan bazı istatistiksel analiz ve test yöntemlerinin sonuçları, bu fonksiyonel formlar hakkında bir takım ipuçları sağlayabilir.

George Box ve Gwilym Jenkins tarafından yazılan ve 1970 yılında yayınlanan kitap, ARIMA ile zaman serilerinin modellenmesi için zemin hazırlamıştır. Bu yaklaşımı literatüre kazandıran Box-Jenkins metodolojisi üç adımdan oluşur: durağan veya kararlı bir zaman serisi için en iyi ARIMA modelinin seçilmesi (model tanımlama), modelin parametrelerinin hesaplanması (parametre tahmini) ve modelin uygunluğunun değerlendirilmesi (model teşhisi) [82].

Keşfedilen model uygunluk testlerini geçemezse prosedür yeniden başlatılır ve nihai olarak uygunluk kriterlerine en iyi uyan model seçilir. Bu seçilen model daha sonra tahmin için kullanılır. Box-Jenkins metodolojisi, örnek otokorelasyon ve kısmi



otokorelasyon katsayılarına artan gecikme uzunlukları ile incelenen zaman serilerinin sayısına dayalı en iyi modeli seçmek için çeşitli teorik otoregresif, AR(p), kayan ortalama, MA(q) ve otoregresif kaymalı ortalama, ARMA(p) modelleri kullanır [82]. Şekil 5.1, bu süreçte kullanılan yöntemlerin akış şemasını göstermektedir.



Şekil 5.1. Box-Jenkins metodolojisinin gösterimi.

Tek değişkenli zaman serileri tahmin edilirken, Otoregresif Entegre Kayan Ortalama (ARIMA) modelleri sıklıkla kullanılmaktadır. Doğrusal filtreleme modelleri olarak da bilinen bu modeller tipik olarak ARIMA (p, d, q) gösterimi ile gösterilir. Burada p ve q sırasıyla uygun modelin standart hareketli ortalamasını ve otoregresif derecelerini

temsil ederken  $d$ , seriyi durağan hale getirmek için uygulanacak standart farkı göstermektedir. Modelin matematiksel gösterimi aşağıdaki eşitlikte gösterilmiştir.

$$Z_t = \varphi_1 Z_{t-1} + \varphi_2 Z_{t-2} + \dots + \varphi_p Z_{t-p} + a_t + \theta_1 a_{t-1} + \theta_2 a_{t-2} + \dots + \theta_q a_t \quad (5.1)$$

Eşitlikte  $a_t$  hata terimi katsayıları,  $\varphi_p$  otoregresif operatör için parametre değerleri,  $Z_t$  orijinal serinin  $d$  dereceden farkı alınmış zaman serisi ve  $\theta_q$  hareketli ortalama operatörü için parametre değerlerini ifade etmektedir. Yani  $t = 1, 2, \dots, t$  için,

$$W_t = Y_t - Y_{t-1} \quad (5.2)$$

birinci farklar serisi olarak tanımlanır. Burada  $W_t$  birinci farklar serisi,  $Y_t$  ise orijinal zaman serisinin tesadüfi değişkenler kümesi olarak adlandırılır. Birinci farklar serisi de durağan değilse, yine  $t = 1, 2, \dots, t$  için,

$$Z_t = W_t - W_{t-1} \quad (5.3)$$

ifadesi ile durağanlık kontrolü ilk fark serisinin tekrar farkı alınacak şekilde yapılır ve modelleme gerçekleşir. serisinden çıkararak ARIMA modeli, ilk seri durağansa, yani  $d = 0$  farkı için AR, MA veya ARMA modeline geçecektir [83]. Bu özelliğin bir sonucu olarak ARIMA modelinin Box-Jenkins modellerinin tamamını içerdiği iddia edilebilir. Zaman serisi, fark derecesi  $d = 1$  olduğunda doğrusal bir eğri ve  $d = 2$  olduğunda bir parabolik eğri olduğunu varsayar. Aşağıdakiler temel ARIMA model denklemleridir.

$$ARIMA(0,1,1) = IMA(1,1) \quad \rightarrow Y_t = Y_{t-1} + a_t + \theta_1 a_{t-1} \quad (5.4)$$

$$ARIMA(1,1,0) = ARI(1,1) \quad \rightarrow Y_t = (1 + \varphi_1)Y_{t-1} - \varphi_1 Y_{t-2} + a_t \quad (5.5)$$

$$ARIMA(1,1,1) = ARIMA(1,1,1) \rightarrow Y_t = (1 + \varphi_1)Y_{t-1} - \varphi_1 Y_{t-2} + a_t - \theta_1 a_{t-1} \quad (5.6)$$

Derlenmiş ayırık zaman serilerine sahip dinamik sistemler, ARIMA modeli kullanılarak etkin bir şekilde modellenmiştir. Bu modellerin temel amacı, zaman serisine en iyi uyan en az parametreye sahip doğrusal modeli belirlemektir. Tanımlanan değişkenlerin zaman içinde nasıl dalgalandığı, zaman serisi modellerindeki en önemli zorluklardan biridir. Bazı seriler ortalamaya yakın kısa varyasyonlar sergilerken, diğerleri zamanla azalan veya artan yönde güçlü modeller sergileyebilir. Bununla birlikte, bu seriler, yukarı veya aşağı giden düzensiz eğilimler de sergileyebilir.

Zaman serilerinde ele alınan değişken için veri setinin seviye, fark ve logaritmik farklarını alınması ve zamana karşı grafiklere bakılmasıyla ve çeşitli gecikme uzunluklarındaki otokorelasyonları ve kısmi otokorelasyonları analiz edilmesi ile serilerin özellikleri hakkında bir ilk izlemin elde edilebilir [84]. Belirli bir trende sahip zaman serilerinde zamandan bağımsız bir ortalama ve varyans yoktur. Belirli serilerin ortalamaları ve varyansları uzun vadede sabitken, kısa vadede ciddi dalgalanmalar yaşayabilirler. ARIMA modellerinin kullanılabilmesi için incelenen serilerin durağan ve trendsiz olması gerekir.

Uygun bir örnek uzay kullanıldığında bu zaman serilerinin varyansını ve ortalamasını başarılı bir şekilde tahmin etme yeteneği, zaman serilerinde katı ve zayıf durağanlığın en önemli faydasıdır. ARIMA modeli, önce trend olan herhangi bir serinin trendini kaldırmak için kullanılmalıdır. Daha sağlam ve güvenilir yargılar geliştirmek için bazı titiz analizler ve testler yapmak gerekir. Bu yaklaşımın başarılı bir şekilde uygulanabilmesi için trend ve mevsimsellik konularının belirlenmesi ve ortadan kaldırılmasına yönelik bazı testler ve analizler çok önemlidir.

ARIMA modellerinin kurulabilmesi için dört aşamanın tamamlanması gerekmektedir. İlk aşamada genel model sınıfını tanımlamak için otokorelasyon ve kısmi otokorelasyon fonksiyon grafikleri kullanılmasıdır. Geçici modelleme ikinci aşamanın adıdır. Model belirleme aşamasında AR, MA, ARMA veya ARIMA model sınıfından bir model seçilir [83].  $AR(p)$  modelindeki kısmi otokorelasyon fonksiyonu, modeldeki otokorelasyon fonksiyonu üstel ve sinüsoidal olarak azalırken,  $p$  gecikmesinden istatistiksel olarak ihmal edilebilir hale gelir.

$MA(q)$  modelindeki kısmi otokorelasyon fonksiyonu kademeli olarak üstel veya sinüsoidal olarak azalırken,  $MA(q)$  modelindeki otokorelasyon fonksiyonu  $q$  gecikmeden sonra aniden düşer ve istatistiksel olarak ihmal edilebilir. Gecikmeden sonra,  $ARMA(p, q)$  modelindeki otokorelasyon fonksiyonu ve kısmi otokorelasyon fonksiyonu  $(q-p)$ , üstel ve azalan sinüs dalgalarının bir kombinasyonu olarak ortaya çıkar. İstatistiksel yöntemler kullanılarak zamansal model parametrelerinin tahmin edilmesini ve anlamlı olup olmadığının belirlenmesini içeren üçüncü aşama, katsayıların standart hatalarının kontrol edilmesi olarak bilinir.

Son adım, belirlenen modelin tahmin için uygunluğunun değerlendirilmesini içerir. Bunun için uygun olduğu düşünülen geçici modelden hataların otokorelasyon katsayılarının otokorelasyon fonksiyonu ve grafiği incelenir [83]. Söz konusu fonksiyon belirli bir şekil sergiliyorsa ve hatalar rastgele dağılmıyorsa model uygun değildir. Bu yapıldıktan sonra ikinci aşamada yeni bir geçici model ile işlem yeniden başlatılır ve doğru model bulununcaya kadar işlem tekrarlanır. Model artık uygunluk kontrolünden geçtikten sonra tahminlerde kullanılmak üzere hazır duruma gelmiş olmaktadır [83].

## BÖLÜM 6

### YÖNTEM, UYGULAMA VE BULGULAR

Bileşenler arasındaki etkileşimler nedeniyle, yüksek fırın pik demir üretim süreci, çok değişkenli girdi faktörlerine bağlı olarak sürekli değişir ve koşullar aynı olsa bile farklı sonuçlar üretir. Fırınlarda meydana gelen çoklu kütle hareketleri, yanma süreçleri, muazzam ısı, kütle transferi ve katı-katı, katı-sıvı ve gaz-katı reaksiyonları nedeniyle çok zorlu bir durum gelişir. Günlük operasyon boyunca hammadde, yakıt ve işletme giderleri azaltılarak fırının verimliliği ve kararlılığı artırılır ve tesisin ömrü uzatılır. Bu nedenle, sıcak metal sıcaklık değerinin tahmini ve kontrolü gerçekleştirilebilirse, sıcak hava akışı, oksijen zenginleşmesi, nem içeriği, soğuk hava sıcaklığı, geçirgenlik, toz kömür enjeksiyonu ve kok demir oranı gibi yakıt değerleri ayarlanabilmektedir. Bu, daha istikrarlı fırın çalışma koşulları ve daha düşük işletme giderleri ile sonuçlanacaktır.

Pratik uygulamaların içinde oluşan tecrübeler ve çalışma sırasında yapılan araştırmalarda yüksek fırın sürecinin matematiksel olarak modellenmesi için yapılan çalışmalar görülmüştür. Bir yüksek fırının üretim sürecini modellemek için çok sayıda araştırma yapılmıştır. Bununla birlikte, yüksek fırının modellenmesi, ısı ve kütle transferi fenomenlerinin karmaşıklığının yanı sıra çok sayıda gaz-katı, katı-katı, katı-sıvı ve katı-katı etkileşimleri, yanma süreçleri ve kütle hareketi aşamaları nedeniyle çok zorlu bir konudur [85]. Kimya ve metalurji mühendisleri, kimyaya dayalı deterministik modeller ve denklemler kullanarak bu süreci göstermek için tekrar tekrar girişimlerde bulundular. Bununla birlikte, bu denklemler karmaşık termodinamik ve kütle transfer bağlantılarını içerir, bu nedenle tahmin ve kontrol için kullanıldıklarında çok az etkinliğe sahip olmuşlardır [43,72, 86, 87, 88].

Yüksek fırının kapsamlı bir ısı ve kütle dengesi kararlı durum modeli Peacay ve Davenport [17] tarafından önerilmiştir. Isı dengesi, kütle dengesi ve kinetik veriler,

Ufret ve Williams modellerinde pik demir-cüruf sisteminde faz dengesi için gözlemsel bağlantılar ile entegre edilmiştir [85]. Biswas'a göre, basitçe saha düzeyinde modeller kullanarak pik demir sıcaklığı ve silikon konsantrasyonu gibi faktörleri tam olarak tahmin etmek ve yönetmek çok zordur [43, 90]. Torsell ve arkadaşları, fırın modellemesi, fırın içinde var olduğu düşünülen kütle transfer denklemlerinin simülasyonuna dayanmaktadır [87,88]. Singh ve arkadaşları, pik demir sıcaklığıyla yakından bağlantılı bir faktör olan pik demirdeki silikonu tahmin eden yerleşik modellere bakarak bu sonucu doğrulayabildiler. Singh'in görüşüne göre bu standart yöntemler silikon içeriğini doğru bir şekilde tahmin edememektedir [43, 91]. Ullmann, çeşitli girdi malzemeleri arasındaki etkileşim etkileri ve yüksek fırının çalışma bölgelerindeki keyfi dalgalanmalar dahil olmak üzere ek modelleme belirsizliklerinin ortaya çıkması için bir açıklama yapmıştır [92].

Sonuç olarak, yukarıda belirtilen araştırma, deterministik kimyasal denklemlerin tek başına yüksek fırın işletiminde yer alan çeşitli parametrelerin güvenilir bir şekilde değerlendirilmesini ve kontrolünü sağlayamayacağı sonucuna varılmıştır [43].

Yüksek fırınlar, çelikhaneler, sıcak haddehaneler gibi demir-çelik üretimi gibi farklı işlemlerin yapıldığı yerlerde şimdiye kadar yapay sinir ağları kullanılmıştır. Bu öncelikle, sinir ağlarının değişkenler arasındaki son derece doğrusal olmayan etkileşimleri simüle etme yeteneğinden kaynaklanmaktadır. Geleneksel yöntemler genellikle yalnızca doğrusal girdi-çıkı eşlemesine izin verirken, sinir ağlarının daha karmaşık bağlantıları tanımlayabildiği gösterilmiştir. Ek olarak, sinir ağlarının kullanılması model geliştirmeyi önemli ölçüde hızlandırır. Sinir ağlarının çalışma koşullarındaki değişikliklere hızlı bir şekilde uyum sağlama yeteneği, bir diğer önemli husustur [43].

Çalışmanın yüksek fırınlara odaklanması ışığında, yüksek fırınlardaki belirli sorunları ele almak için belirli yapay sinir ağı uygulamaları test edilmesinin anlamlı ve pratikte uygulama bulabilecek çıktılar ile sonuçlanabileceği değerlendirilmiştir. Bununla birlikte, bugüne kadar yapılmış çalışmalar göz önünde bulundurulduğunda birden fazla modelleme tekniğinin karşılaştırması ve beraber kullanılması gibi uygulamaların kullanılma fırsatı doğacaktır.

En önemli aşamalardan biri, bir sinir ağı modeli ve modelleme için bir öğrenme stratejisi seçmeden önce modelin düzgün çalışmasına izin verecek girdi veri setini seçmektir. Günümüzün gelişmiş yüksek fırınlarında, teknik gelişmelerle aynı anda kurulan otomasyon ve izleme sistemleri sayesinde yüzlerce parametre izlenir ve kaydedilir ve bu unsurların çoğunun pik demirin sıcaklığı üzerinde çok az etkisi vardır veya hiç etkisi yoktur. Pik demir sıcaklığı için kabul edilebilir birkaç noktadan birini seçmek ve bunu model girişine uygulamak zordur. Önemli unsurların atlanması modelin doğruluğunu azaltabilirken, sadece küçük etkilerle değişkenler eklemek, modelin eğitilmesini ve çalıştırılmasını zorlaştıracaktır.

Böyle bir modelin, araştırılan belirli sistem durumlarını, özellikle pik demir sıcaklıklarını ölçmek için kullanılan düzensiz örnekleme oranını dikkate alması gerektiği açıktır. Bunu başarmak için zaman kavramı açıkça paradigmaya dahil edilmeye çalışılmıştır. Modele girdi olarak, dökümler arasındaki süre, son sıcaklık ölçümünden bu yana geçen süre ve dökümün açılmasından sıcaklık ölçümüne kadar geçen süre kullanılmıştır. Bu sürelerin dikkate alınmasının temel gerekçesi, modelin pik demirin rezervuarda ne kadar süre kaldığını hesaba katabilmesidir. Birkaç istisna dışında ve genel olarak konuşursak, yüksek fırın hızlı bir şekilde soğur, bu da dökümden önce elde edilen pik demirin sıcaklık ölçümünü takip eden ölçümlerden daha düşük hale getirir. Bunun nedeni, ilk pik demirin odanın soğuk alt bölgelerinde, duvarlara yakın üretilmesidir.

Pik demir, ergime bölgesindeki erimiş cevherden doğrudan çıkarılır ve döküm süresi uzadıkça daha sıcak hale gelir. Modelin uygun sonuçları elde etmesi için ek fırın değişkenleri ayarlanmalı ve model girişine uygulanmalıdır. Elimizdeki ham veriler, önceki beş dakikanın ortalama değerleridir. NARX modeli, doğası gereği her girdi değişkeni için yeterli geçmiş veri gerektirir. Yüksek fırın tepkilerinin genellikle yavaş olması ve alınacak geçmiş verilerin çok fazla olması bu modelin giriş sayısının artmasına neden olmaktadır. Bu girişler ayrıca çıkış (döküm numaraları) numaralarına karşılık gelmelidir ki, sıcaklıkların eşleştirilmesi mümkün olabilsin. Her giriş için geçmiş veri miktarı burada ortaya çıkan ilk konudur. Bu rakam, girdideki

değişikliklerin pik demirin sıcaklığını değiştirmesinin ne kadar sürdüğü ile ilgili olmalıdır.

Bugüne kadar yapılan çalışmalarda bu sürenin her bir girdi değişkeni için ampirik olarak belirlenmeye çalışıldığı not edilmiş ve belirlenen süre araştırma boyunca sabit olarak kullanılmıştır. Ancak çalışma şartlarına bakıldığında bu sürenin fırının çalışma şartlarına göre değişkenlik gösterdiği görülmektedir. Yani her değişken için fırının ne kadar hızlı çalıştığına bağlı olarak değişir. Yüksek fırında her senaryoyu temsil edebilecek bir yapı oluşturmak için bu süre bir sabitten ziyade bir değişken olarak ele alınmalı veya başka bir değişkenle ifade edilmelidir. Örneğin fırının büyüklüğüne bağlı olarak tipik çalışma koşullarında çıkışta üst sistemle birlikte içine dökülen malzemeler görülebilir ancak fırının çalışması bir X saat sürer. Bazı çalışma koşulları nedeniyle fırının yavaş çalışması nedeniyle bu süre X saatten daha hızlı veya daha yavaş olabilir.

Bu gibi durumlarda X saatlik bir modelleme hatalı sonuçlar verebilir. Yukarıdakiler göz önünde bulundurularak bu çalışmada yapılan sabit süreler değil, bu sürelerin belirlenmesi için fırın çalışma hızı kullanılarak değişken bir süre elde etmektir. Örneğin, baş üstü sistemdeki yüklü malzemeler, belirtilen zamanda değil, fırın boyutları ile sabit olan bir sayı ile ilişkilendirilir. Fırın kapasitesinden dolayı 40 şarj malzemesini alabilmektedir. Yani fırına 41. dolun yapıldığında ilk dolun fırından pik demir ve cüruf olarak çıkar. Bu sayı sabit olduğundan, üst sistemle şarj edilen malzemeler için sabit süreler yerine 40 şarjı tamamlamak için geçen süre dikkate alınır.

Bu koşullar altında, X saatlik modelleme hatalı bulgular üretebilir. Bu periyotları hesaplamak için fırının çalışma hızı kullanılarak bu çalışmada sabit süreler yerine değişken bir zaman elde edilme üzerine çalışmalar da yapılmıştır. Örneğin, fırın üstü sistemin yüklü malzemeleri, fırının boyutlarına göre değişen ancak önceden belirlenmiş bir anda değişmeyen bir sayıya bağlıdır. Fırın kapasitesinden dolayı Y şarj malzemesini barındırabilmektedir. Yani fırın Y+1. kez dolunca ilk dolun pik demir ve cüruf olarak üretilir. Şarj malzemeleri için önceden belirlenmiş süreler yerine Y şarjı tamamlamak için gereken süre bu hacim/kütle olarak sayı sabit olduğundan için dikkate alınmasının daha doğru sonuçlar verebileceği değerlendirilmiştir.




Girdi olarak kullanılacak deęişkenlerin hesaplanması da önemli bir çalışma olmuştur. Girdi olarak kullanılacak deęerin etki süresindeki tüm deęerlerinin girdiye etkisi olmalıdır. Bu da yine bir hesaplama gerektirmiş ve oldukça yoğun bir veri seti ile çalışılarak her bir girdinin belirlenen gecikme süreleri boyunca etkileri hesaplanmıştır. Yapılan çalışmada genelde seri-paralel model olarak isimlendirilen NARX model yapısı kullanılmıştır. Daha sonra kullanılabilir olan ve girişten son pik demir sıcaklığını çıkartarak bazı kazanımlar sağlayacak olan yapı ise NOE model yapısıdır. Bu yapılar ise genelde paralel model olarak isimlendirilir. İki modelin yapısı da şekil 6.1’de verilmiştir. Şekilden de anlaşılacağı üzere NARX model yapısında giriş sistemden elde edilen gerçek deęerler geri besleme olarak uygulanırken, NOE model yapısında ise oluşturulan modelin çıkışı geri besleme olarak uygulanmaktadır. NARX modellerini tanımlayan genel eşitlik aşağıda verilmiştir.

Jimenez ve arkadaşlarının yaptıkları çalışma belirlenen gecikmenin girdi deęerleri üzerindeki etkileri ve nasıl hesaplanabilecekleri konusunda referans olarak alınmıştır [26]. Çalışmada kullanılan girdi seti ve tez çalışmasında kullanılan girdi seti farklılıkları bulunmaktadır. Bunun temel nedeni, seçilen girdi kümesinin geçmiş bilgiye dayalı olarak yapılması ve sıcak maden sıcaklığı üzerinde etkisinin olduğu deęerlendirilen parametlerin farklı olarak ele alınmasıdır. Bununla beraber zaman deęişkenlerinin de eklenmesi girdi parameter sayısını arttırmıştır.

NFIR, NARX, NOE, NARMAX ve NBJ, dinamik sistemleri simüle etmek için kullanılabilir birkaç model yapısıdır. Yapılan çalışmada NARX model yapısı olarak da bilinen seri-paralel model kullanılmıştır. NOE model yapısı daha sonra kullanılabilir ve son pik demir sıcaklığını girişten çıkararak bazı avantajlar sağlayacak bir modeldir. Paralel modeller bu mimarilerin ortak adıdır. Şekil 6.1, iki modelin topolojik yapılarını göstermektedir. Resimde görüldüğü gibi NOE model yapısı geliştirilen modelin çıkışını geri besleme olarak uygularken, sistemden toplanan gerçek deęerler NARX model yapısında geri besleme olarak uygulanmaktadır. Aşağıdaki genel denklem NARX modellerini açıklamaktadır.

$$\hat{y}(k) = F(y(k-1), y(k-2), \dots, y(k-p), u(k), u(k-1), \dots, u(k-q)) \quad (6.1)$$

$y$  değişkeninin  $k$  örnekleme zamanındaki tahmin edilen değeri, bu değişkenin önceki  $p$  örnekleme zamanlarındaki değerlerini ve genel olarak önceki  $q$  örnekleme zamanlarındaki  $u$  ile ifade edilen giriş değişkenlerinin değerlerini alan bir fonksiyon olarak ifade edilir [26].



Şekil 6.1. Seri-paralel (sp) veya paralel (p) tanımlama yöntemleri [93].

Böyle bir modelin, araştırılan belirli sistem durumlarını, özellikle pik demir sıcaklıklarını izlemek için kullanılan düzensiz örnekleme oranını dikkate alması gerektiği açıktır. Bunu başarmak için zaman açıkça modellemeye dahil edilmiştir. Modele girdi olarak, dökümler arasındaki süre, son sıcaklık ölçümünden bu yana geçen süre ve dökümün açılmasından sıcaklık ölçümüne kadar geçen süre kullanılmıştır.

Pik demirin haznede olduğu sürenin de modelde kullanılabilmesi için öncelikle bu süreler dikkate alınır. Döküm başında yapılan pik demir sıcaklık ölçümü, yüksek fırın hızla soğuduğu için bazı aykırı değerler olmasına rağmen, sonraki ardışık ölçümlerden genellikle daha düşüktür. Bunun nedeni, ilk pik demirin haznenin serin, duvarlara

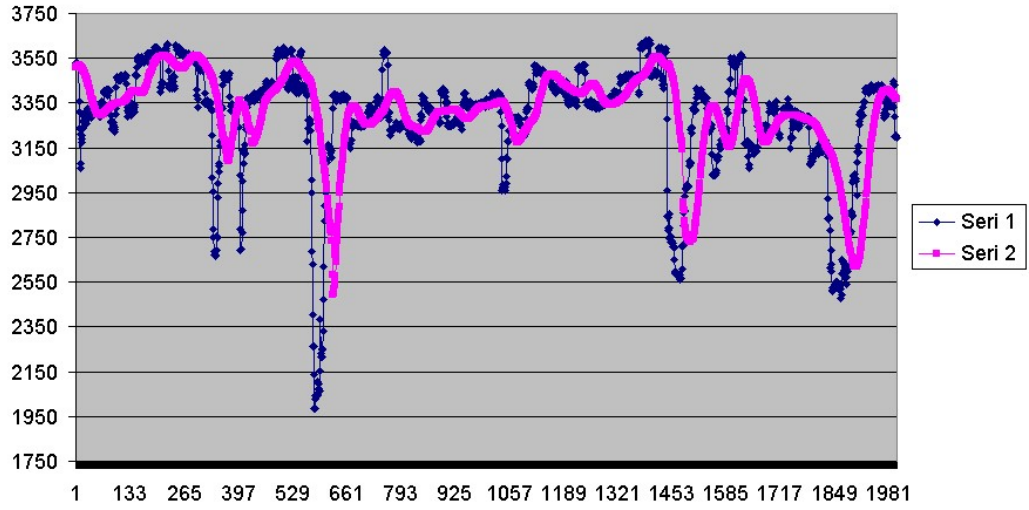
yakın alt bölgelerinde akmaya başlamasıdır. Döküm süresi uzadıkça pik demir ısınır ve doğrudan ergime bölgesindeki erimiş cevherden gelir ve daha yüksek sıcaklıklara sahiptir.

Model girişine uygulanacak olan diğer fırın değişkenleri de modelin istenen sonuçları vermesi amacıyla uyarlanması gerekmektedir. Elimizdeki mevcut ham veri 5 dakikalık ortalama değerleri gösteren veridir. 6.1. eşitliği ile tanımlanan modelin yapısına uygun olarak, her giriş değişkeni için yeterli sayıda geçmiş veriyi almak gereklidir. Yüksek fırın cevaplarının genelde yavaş olması nedeni ile alınacak geçmiş verinin çok fazla olması nedeniyle bu modelin giriş sayısında bir artışa neden olmaktadır. Ayrıca bu girişlerin çıkış sayıları ile uyumu gerekmektedir [26].

Modelin gerekli sonuçları üretebilmesi için model girdisine uygulanan diğer fırın değişkenlerinin üzerinde çalışma yapılması gerekliliği oluşmuştur. Elimizdeki veri seti yalnızca 5 dakikalık ortalama değerleri gösteren ham verilerdir. 6.1 ile gösterilen eşitlikteki her bir girdi değişkeni için yeterli tarihsel verinin elde edilmesi, modelin yapısına uyum sağlamak için önemlidir.

6.1. eşitliği ile ifade edilen model yapısına uygulanacak olan giriş değişkenleri, zamana göre ortalamaları alınarak kullanılmıştır. Bu ortalamalar, pik demir sıcaklığını ölçüldüğü bir  $t_a$  anından değişkenin tepki süresinin iki katı ( $2\tau$ ) kadar geriye doğru olan bir süreyi kapsayan değişken değerleri alınarak hesaplanmıştır. Belirlenen süre için elde edilen değerler ( $u_i$ ) maksimum noktası değişkenin göz önüne alınan tepki süresine ( $\tau$ ) yerleştirilmiş bir Gaussian fonksiyonu ile ortalaması alınmıştır. Böylelikle bu yöntem kullanılarak ortalama değerler ( $\bar{u}_i$ ) elde edilmiştir [26]. Bu hesaplamalar 6.2. ile verilen eşitlik ile yapılmıştır.

$$\bar{u}_i = \frac{\sum_{t=t_a-2\tau}^{t_a} e^{-2\left(\frac{[\tau-(t_a-t)]}{\tau}\right)^2} u_i(t)}{\sum_{t=t_a-2\tau}^{t_a} e^{-2\left(\frac{[\tau-(t_a-t)]}{\tau}\right)^2}} \quad (6.2)$$



Şekil 6.2. Hava akışı ham verisi (seri 1) ve 6.2. eşitliğinin uygulanmış hali (seri 2).

Denklemden  $t$  ile  $u_i$ 'nin örneklendiği an ifade edilmektedir. Ham veriler bu denklemden iki farklı şekilde etkilenmiştir. Giriş sinyalinin düzgünleştirilmesi ve ileri yönde kaydırılmasıdır [26]. Bu sıcaklık alınma altında kullanılmaya hazır hale getirilen giriş parametresini sağlar. Şekil 6.2'deki örnek verilmiştir. Bu yapıyı oluşturmak için her bir şarj grubunun süresi keşfedilmiş ve her bir şarj grubuna düşen noktaların sayısı hesaplanarak denkleme dahil edilecek örnek sayısı belirlenmiştir.

Bu durumda 6.1'deki verilen denklemleri aşağıdaki gibi yazmak mümkün olacaktır:

$$\hat{T}(k) = F(T(k - tta), tta(k), thc(k), tic(k), u(k), u(k-1), \dots, u(k-2\tau)) \quad (6.3)$$

Noktalar üzerinde çalışmaya başlamadan önce çalışma aralığındaki herhangi bir noktada veri kaybı yaşayıp yaşamadığı incelenmiştir. Değişkenler kısa süreler içinde oldukça değişken değerler içermediğinden, önceki ve sonraki değerlerin ortalaması alınarak tespit edilen eksiklikler giderilmiştir. Bu çalışmalar, tüm noktalar için oluşturulmuş Excel makroları kullanılarak gerçekleştirilmiştir.

Diğer girdi değişkenlerinin süreleri için süre değil, şarj sayısı dikkate alınmıştır. Bu çalışmada fırın operasyonları ve bakım ekiplerinin tecrübesi nedeniyle 20 giriş

parametresi ve önceki pik demir sıcaklık değerleri seçilmiştir. İki kapatma arasındaki 2 aylık sabit yüksek fırın çalışma süresi boyunca elde ettiğimiz tüm veri seti kullanılmıştır. Bu dönemdeki sıcaklık değişimlerine baktığımızda ısınma (+1500) ve soğuma (-1400) dönemlerini kapsadığını görebiliriz. Deneyler sırasında her bir parametrenin toplam 5.000 adeti dikkate alındığından modelde toplam 105.000 değer kullanılmıştır. Minimum, maksimum değerler ve mühendislik birimleri ile seçilen girdi değişkenleri ve bu değişkenlere fırın şarj sayısına göre uygulanan gecikmeler aşağıda gösterilmiştir.

Çizelge 6.1. Model giriş parametreleri.

Parametre	Minimum	Maksimum	Birim	Gecikme
	Değer	Değer		
Sıcak hava sıcaklığı	2149	3718	Nm <sup>3</sup> /min	8 şarj
İlave buhar akışı	0	5067	kg/hour	4 şarj
İlave oksijen akışı	0	128	Nm <sup>3</sup> /min	8 şarj
Pulvarize kömür enjeksiyon oranı	0	651	gr/m <sup>3</sup>	8 şarj
Sıcak hava basıncı	883	1136	°C	8 şarj
Saatlik şarj hızı	4.2	9.3	-	8 şarj
Tepe gazı basıncı	78	340	°C	4 şarj
Tepe gazındaki H <sub>2</sub>	0.44	5.73	%	4 şarj
Tepe gazındaki CO	13.4	29.9	%	4 şarj
Tepe gazındaki CO <sub>2</sub>	13.6	26.7	%	4 şarj
Şarj edilen kok	8827	13090	kg	40 şarj
Şarj edilen demir cevheri	39985	45516	kg	40 şarj
Şarj edilen kireçtaşı	178	1796	kg	40 şarj
Geçirgenlik	6583	14892	-	4 şarj
Kok rutubeti	13.6	26.5	%	40 şarj
Duvar hareketleri	0	1	-	-
İki döküm arası süre (thc)	16	6140	min	-
Bir önceki sıcaklık alımı (tta)	2	43	min	-
Bir önceki döküm açılışı (tic)	185	10885	min	-
Önceki pik maden sıcaklığı	1379	1541	°C	-

Formül (6.4) kullanılarak, veri kümesinin normalleştirilmesi tipik olarak öğrenme sürecini hızlandırıp stabilize ettiğinden, daha hızlı bir yakınsama ile sonuçlandığından ve tahmin yeteneği ve verimliliği artırdığından, tüm veri kümesi normalleştirilir. Her ölçümü ve kaydedilen veri modelde kullanılmıştır.

Verilerin dağıtımına ilgili herhangi bir özel bilgisi sinirsel ağ mimarisinin seçiminde çok önemlidir. Mevcut durumda tüm veriler ölçülen fiziksel değerlere ve kompozisyon değişkenlere karşılık gelir. Sistemde tonaj, debi, sıcaklık gibi fiziksel değişkenler kapalı çevrim kontrolü altındadır. Tüm şarj malzemelerinin bileşim değişkenleri, uygun ön harmanlama sistemleri ile kontrol altındadır. Benzer şekilde, normal fırın operasyonlarında çıktı değişkenleri, tasarım değerlerine neredeyse eşit değerlere sahip olacaktır. Bu nedenle, tüm değişkenlerin kesik kuyruklarla normal olarak dağılması beklenir. Değişkenlerinin istatistiksel özelliklerine ait örnekler Çizelge 6.2’de sunulmuştur. Değişkenlerin istatistiksel dağılımı Hamilton tarafından önerilen yöntem kullanılarak analiz edilmiştir[85].

Çizelge 6.2. Önemli model giriş parametreleri ve veri çalışma örnekleri.

	Mean	Median	Standard deviation	Pseudo standard deviation	Skew	Kurtosis	Standard error of estimate
HMT	1469.0	1471.0	23.61	23.60	-1.1906	7.6632	0.2902
PCI	549.9	538.5	78.7	78.7	-1.6847	12.4286	1.3381
O2 (Nm3 )	92.9	75.7	42.2	42.2	-0.5187	-1.2421	0.3301

Simetri testi, verinin çarpıklığına dayanır: Skew=0, simetrik; çarpık<0 asimetric pozitif değerlere uzanan kuyruk; Skew>0 Negatif değerlere uzanan asimetric kuyruk.

Normallik, simetrik veriler standard sapma ve pseudo standard sapmanın karşılaştırılması ile test edilebilir: SD=PSD Normal; SD>PSD Ağır kuyruklu; SD<PSD Hafif kuyruklu.

Verilerin Göreceli Zirveliği veya Düzlüğü Kurtosis göre test edilir: Kurt=0, Normal; Kurt>0 zirve dağılım; Kurt<0 düz dağılım.

Yukarıdaki testler temelinde, girdi ve çıktı setlerindeki tüm bileşim değişkenlerinin esasen normal dağıldığı sonucuna varılmıştır. Çarpıklık ve basıklık değerleri, dağılımın normalliğini gösteren çok küçüktür. Harmanlamadan sonra ham maddelerin bileşimlerinin normal olarak dağılması gerektiğinden bu beklenen bir durumdur. Değişkenlerin çoğu normal olarak dağıtıldığından, bu verilerle eğitilen sinir ağının iyi performans göstermesi beklenmektedir.

Hesaplanan istatistiksel parametreler, verilerdeki aykırı değerleri belirlemek ve kaldırmak için kullanılabilir. Normal olarak dağıtılan bileşim verileri için aykırı değerlerin çıkarılması gerekçelendirilir. Aykırı değerlere analiz hataları veya diğer sistematik hatalar neden olabilir. Aykırı değerler, keşifsel veri analizi ilkesi kullanılarak kaldırılmıştır [85]. Yöntem, Denklem 2'de verilen bir çift iç çit ve bir çift dış çitin tanımlanmasından oluşur. (5). İç sınırlar arasındaki veriler doğru verilerdir, iç ve dış sınırlar arasındakiler hafif aykırı değerlerdir ve dış sınırlar dışındakiler ciddi aykırı değerlerdir.

$$\text{Alt İç Sınır} = Q1 - 1.5(IQR) \quad (6.4)$$

$$\text{Alt Dış Sınır} = Q1 - 3(IQR) \quad (6.5)$$

$$\text{Üst İç Sınır} = Q3 + 1.5(IQR) \quad (6.6)$$

$$\text{Üst Dış Sınır} = Q3 + 3(IQR) \quad (6.7)$$

Verilerin %1,5'sinin hafif aykırı değerler olduğu ve verilerin %0,3'ünün ciddi aykırı değerler olduğu bulunmuştur. Şiddetli aykırı değerler, önerildiği gibi veri setinden çıkarılmıştır [85].

Çoğu durumda, verileri normalleştirmek için [0, 1] veya [-1, 1] aralığı kullanılır. Çalışmanın normalizasyon aralığı [0, 1] olarak seçilmiştir.  $x_i$  parametresinin normal değeri,  $x_{min}$  parametresini içeren tüm veri grubundaki en küçük değer,  $x_{max}$  tüm veri grubundaki en büyük değer ve parametrenin normalleştirilmiş sürümünü gösteren  $x_i^{scaled}$  değerinin normalleştirme sürecini hesaplayan ifade aşağıda gösterilmiştir.

$$x_i^{scaled} = \frac{x_i - x_{min}}{x_{max} - x_{min}} \quad (6.8)$$

Çalışma Mathworks Matlab R2018a kullanılarak yapılmıştır. Matlab, yeniden programlama kolaylığı, parametrelerin değiştirilmesi (gizli nöronlar ve eğitim algoritmaları), trendler vb. gibi birçok avantajı nedeniyle kullanılmaktadır. Donanım olarak Windows 10 Enterprise işletim sistemli, 8 GB RAM'e sahip Intel Core i7-7500U bir dizüstü bilgisayar kullanılmıştır.

Fırına yüklenen malzeme miktarı analiz değerleri ve sıcak maden ölçüm değerleri ölçüm anında elde edilen verilerdir. Bunlar dışında izlenen parametreler 30 saniye aralıklarla elde edilmiş ve her 5 dakikada bir bu değerlerin ortalama değeri saklanarak elde edilen değerlerdir. Bu işlemin amacı saklanacak veri miktarını optimize etmektir. Parametre değer değişimlerinin geniş aralıklarda olması ve değişimin takip edilmesi gereken durumlarda en büyük, en küçük veya anlık değerler de saklanabilir. Fırın üzerinden şarj edilen malzemeler fırına yüklendikleri andaki değerleri ile birlikte saklanmakta ve şarj gecikmeleri dikkate alınarak tüm girdi parametrelerini eşleştirmek için veri işleme teknikleri kullanılmıştır.

Pik demir sıcaklığının giriş verileri üzerinde yapılan çalışmaları, sinirsel ağ yapısının oluşturulması izlemiştir. Sinirsel ağ olarak geri yayılım algoritması ile eğitilen bir ileri beslemeli sinirsel ağ yapısının kullanılması benimsenmiştir. Bugüne kadar çok yaygın bir biçimde kullanılmış olması nedeniyle tercih edilmiştir.

Önceki HMT değerlerinin zaman serilerini kullanarak HMT tahminini hassas bir şekilde dikkate alma avantajından dolayı, bu çalışmada ANN model yapısı ile birleştirilmiş NARX (eXogenous girişli doğrusal olmayan OtoRegresif modeller) seçilmiştir.  $k$  örnekleme zamanı için  $y$  değişkeninin tahmin edilen değeri, girdi değişkenlerinin önceki  $p$  örnekleme zamanlarında bu değişken tarafından alınan değerlerin bir fonksiyonu olarak kabul edilir ve çıktı değişkeni, önceki  $q$  örnekleme zamanlarında  $u$  ile temsil edilir [26].

NARX modeli tanımlandıktan sonra bir sonraki adım sinir ağı seçimi olacak ve çalışmada bir gizli katman ve başlangıçta 10 gizli nöron içeren ileri beslemeli geri yayımlı sinir ağı modeli seçilmiştir. Bu çalışmalar için elde bulunan veri kümesi eğitim, onaylama ve test veri kümeleri olmak üzere üçe bölünmüştür. 20 girdi parametresi ve HMT çıktısından oluşan 5000 örnek verinin her biri, verilerin %70'i (her birinden 3500 adet) eğitim, %15'i (her birinden 750 adet) doğrulama ve kalan %15'' (her birinden 750 adet) olmak üzere test ve performans analizi için dikkate alınır. Yüksek fırının iki aylık çalışma süresinde alınan 940 döküme ait 5000 sıcaklık verisi ve bu sıcaklıkların alınma zamanlarına göre eşleştirilen diğer giriş değerleri belirli oranlarda bölüştürülerek kullanılmıştır. Sinirsel ağın eğitiminde günümüzde çok



yaygın olarak kullanılan Levenberg-Marquardt algoritması kullanılmıştır. Bu algoritma eğitim süresini oldukça düşürmektedir.

Giriş katmanı girişe uygulanan veri setinin eleman sayısı kadar nörona sahiptir. Bu girişlerin bazıları modele doğrudan bazıları ise yukarıda anlatılan biçimde bir ön işlemden geçirilerek uygulanmışlardır. Burada ki ön işlemin amacı modelin geçmiş veriye olan ihtiyacının ortadan kaldırılarak giriş sayısının azaltılmasıdır. Örneğin değerleri 5 dakika aralıklarla saklanan bir değişken için bir saatlik bir zaman gecikmesi söz konusu olsaydı, bu girişte ilaveten 11 değer daha uygulanmasını gerektirecekti. Değişken sayısı ve gecikme süreleri göz önüne alındığında bu modelin neredeyse eğitimini imkansız bir duruma getirebilirdi. Yapılan ön işlem sayesinde modelin geçmişe yönelik verileri tutması gereksinimi ortadan kaldırılmış ve giriş sayısının artması engellenmiştir.


Çıkış katmanında ise sayısal değeri kestirilmek istenen pik demir sıcaklığını gösteren tek bir nöron vardır.

Gizli katman nöron sayısı ise bir sinirsel ağı değişken parametrelerinden birisidir ve modellenen problemin karmaşıklığına göre ayarlanmalıdır. Genel olarak problemin karmaşıklığı arttıkça gizli katmanda bulunan nöron sayısı da artmaktadır. Nöron sayısını tespit için bazı genel kabul görmeyen formülasyonlar olsa da, geliştirilmiş herhangi bir yöntem olmadığından bu çalışma çoğunlukla deneysel olarak yapılmaktadır. Bu çalışmada da deneysel olarak bulunmuştur. Gizli katman sayısı olarak bir seçilmiştir. Bu konu üzerine inceleme fırsatı bulunan çalışmalarda ikinci bir gizli katmanın herhangi bir fayda sağlamadığı, eğitim süresini arttırdığı gözlenmiştir.

Ayrıca transfer fonksiyonları değiştirilerek de dört farklı ağ yapısı üzerinde denemeler yapılmıştır.

Yukarıda verilen yapı kullanılarak ağ, gizli katmanında 10 nöronla başlamak üzere her seferinde 5 nöron ilave edilerek 60 nörona kadar farklı nöron sayıları ile eğitilmiştir. Bu transfer fonksiyonları Matlab programındaki fonksiyon isimleri ile

tansig-tansig, tansig-purelin, logsig-longsig ve logsig-purelin olacak biçimde dört kere tekrar edilmiştir. Elde edilen sonuçlar şekil 6.3 ile verilmiştir.




Şekil 6.3. Eğitilen ağ yapılarının sahip oldukları nöron sayılarına göre MSE'leri.

Şekil 6.3a'daki grafikten görülebildiği gibi gizli katmanda sigmoidal transfer fonksiyonu (logsig) kullanılması, hiperbolik tanjant sigmoidal fonksiyonu kullanılmasına göre çok daha iyi performans sağlamıştır.

Şekil 6.3b'deki grafikte sigmoidal ve doğrusal transfer fonksiyonlarının hataları, onaylama hataları ve ortalamaları verilmiştir. Görülebileceği gibi en iyi sonucu 0.00141 MSE değeri ile 40 gizli katman nöronuna sahip sırasıyla sigmoidal ve doğrusal transfer fonksiyonlarına sahip ağ yapısı elde etmiştir. Ancak onaylama seti MSE'lerine bakıldığında 0.0025 değeri ile 30 gizli katman nöronuna sahip sırasıyla sigmoidal ve doğrusal transfer fonksiyonlarına sahip ağ yapısı en iyi performansa sahiptir. Ancak ortalamalara bakıldığında her iki transfer fonksiyonu da sigmoidal olan 50 gizli katmana sahip ağ yapısı 0.00211 ile en başarılı yapı olmuştur. Pik demir sıcaklığının modellenmesinde ise onaylama hatalarının en düşük olduğu 30 gizli katman nöronuna sahip logsig-purelin yapısı kullanılmıştır.


Test edilen 750 deęer için gerek ve tahmini sıcak metal sıcaklıęının karřılařtırmasını ieren model ıktıları Őekil 6.4'te gsterilmiřtir. ngrlen deęerler kırmızı renk ile gerek deęerler ise mavi renk ile ifade edilmekte ve her iki parametrenin de birbirini olduka iyi takip ettięi grlmektedir. ve neredeyse rtřyor, bu da ok bařarılı bir tahmin anlamına gelmektedir.



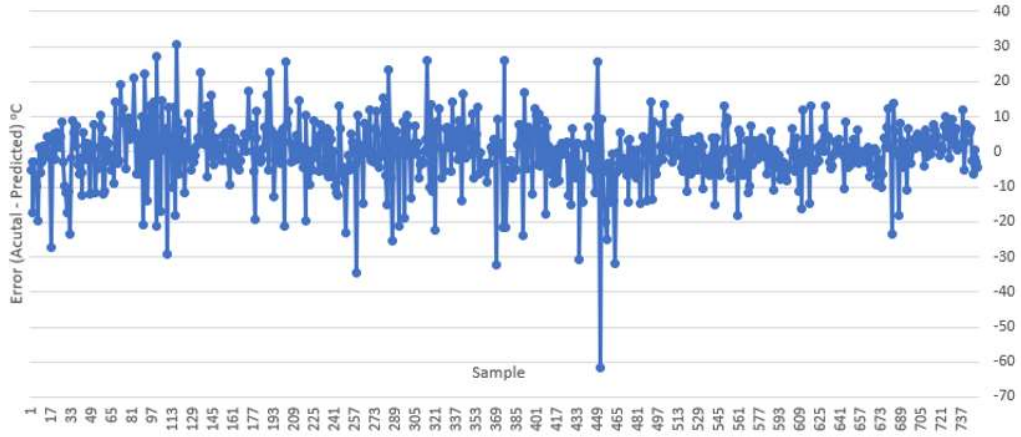
Őekil 6.4. Gerek ve tahmin edilen pik maden sıcaklık deęerleri.

Tahmin modelinin HMT'nin pozitif ve negatif hareketlerini bařarılı ve zamanında tanıyabildięi gsterilmiřtir. 750 test edilmiř HMT için mutlak ortalama tahmin hatası 6.02 °C bulunmuřtur ve hata oranlarının oęu  $\pm 10$  °C'ye arasındadır. Tahmin hatasının 20 °C'den fazla olduęu 750 deęerin zerinde 32 ngrlen sıcaklık ve hatanın 10 °C'den fazla olduęu 141 ngrlen HMT deęeri vardır. Bu nedenle, tahmin edilen HMT deęerlerinin %81,2'lik hata oranı  $\pm 10$  °C'nin altındadır ve Jimenez'in hataların  $\pm 20$  °C arasında yoęunlařtıęı nceki alıřmasına kıyasla daha iyi tahmin sonuları alınmıřtır [26]. İyileřtirme, sabit dngler yerine fırın hacmine ve kapasitesine gre malzeme ykleme dnglerinin tanımlanması ve tahsis edilmesinden kaynaklanmaktadır. Gerek ve tahmin edilen sıcak metal sıcaklık deęerleri arasındaki hata oranları Őekil 6.5'te gsterilmiřtir.

Őekil 6.5 ve Őekil 6.6 deęerlendirildięinde yapılan alıřmanın Jimenez'in hata daęılımından daha iyi bir hata daęılımına sahip olduęu grlmüřtür.



Şekil 6.5. Gerçek ve tahmin edilen pik maden sıcaklık değerleri arasındaki Hata (Jimenez)[26].



Şekil 6.6. Gerçek ve tahmin edilen pik maden sıcaklık değerleri arasındaki hata.

Çalışma çıktılarına göre, NARX sinir ağı modeli için R<sup>2</sup>, RMSE ve MAPE istatistiksel ölçümleri çizelge 6.2'de gösterilmektedir.

Çizelge 6.3. NARX YSA modeli çıktıları.

R <sup>2</sup>	RMSE	MAPE
0.92	8.59	0.41

Çalışmanın bir sonraki aşamasında ise ARIMA modeli yine IBM SPSS yazılımı kullanılarak uygulanmıştır. Tüm p, d ve q parametrelerinin “1” olarak seçildiği

ARIMA(1,1,1) modelinde, diğerlerinde de olduğu gibi tüm veri testlerde kullanılmıştır ve belirlilik katsayısı değeri 0,797 olarak elde edilmiştir. Verilere ARIMA modeli uygulandığında elde edilen RMSE değeri ise 19,282 olarak bulunmuştur.


Levenberg-Marquardt öğrenme algoritmasının kullanıldığı ANN modeli çalışma sonucunda ARIMA modeline göre daha yüksek performansı sağlayan model olarak gözlenmiştir.

Çizelge 6.4. Model çıktılarının değerlendirilmesi.

<b>KARŞILAŞTIRMA PARAMETRELERİ</b>	<b>ANN MODEL</b>	<b>ARIMA MODEL</b>
<b>R<sup>2</sup></b>	0,92	0,797
<b>RMSE</b>	8,59	19,282

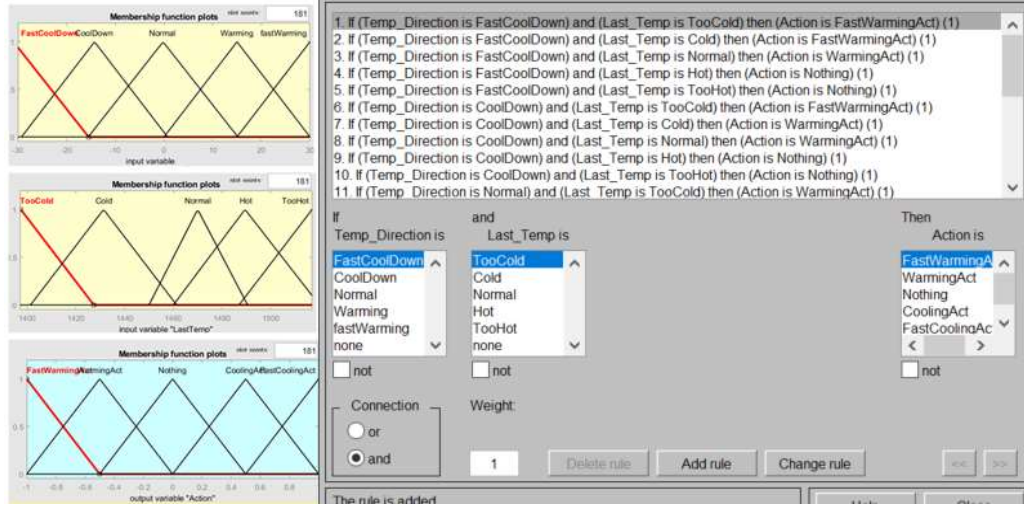
Çalışamın bu noktadan sonraki aşamasında elde edilen kestirimsel sıcaklıklar bir bulanık mantık modeli ile işlenecektir. ANN ile elde edilen değerler ile ilerlenmesi uygun olduğu değerlendirilmiştir. Alınan sıcaklık ölçümü ve önceki sıcaklık ölçümleri fırının diğer çalışma parametreleri ile birlikte değerlendirilebilir ve istenilen çalışma koşullarını oluşturmak için çalışma parametrelerinde değişiklik yapılabilir. Buradaki en önemli değişkenlerden biri sıcak metal sıcaklığıdır. Bu nedenle fırın ısıtma veya soğutma değişimlerinin modellenmesinde bu durum dikkate alınarak uzman modelci olarak bulanık öneri modeli oluşturulmuştur. Son tahmin edilen sıcak metal sıcaklığı ve tahmin edilen son 5 sıcak metal sıcaklığının ortalaması girdi değişkenleri olarak seçilir. Bu sayede geçmiş sıcaklık verilerine göre son sıcaklık ve çalışma yönü bulunacak ve hareket boyutlandırmasına göre yapılacak işlem belirlenecektir.

Son 5 sıcaklık, çeşitli ortalama değerlerin karşılaştırılmasına göre seçilir. Şekil 6.6'da görüldüğü gibi, ortalama hesaplama için sıcaklık sayımının artırılması, dalgalanmaları azaltır. Numune sayısını artırırsak, duyarlılık kaybı riski de artar. Bu nedenle ortalama hesaplama için 5 örnek seçilmiştir.




Şekil 6.7. Sıcaklık ortalamalarının karşılaştırma grafiği.

Fırındaki sıcaklık hareketleri çift yönlüdür. Bu durumun tespit edilebilmesi için sıcaklık değişiminin miktarı ve hızının dikkate alınması gerekmektedir ve bu nedenle çalışmanın ikinci bölümünde bir Mamdani bulanık çıkarım sistemi oluşturulmuştur. Modelde kullanılan sıcaklık değişiminin üyelik fonksiyonları, sıcak metal sıcaklığının üyelik fonksiyonları, çıktının üyelik fonksiyonları ve Matlab altyapısında bulanık if-then kuralları Şekil 6.7'de verilmiştir.



Şekil 6.8. Bulanık mantık modeli.


Bulanık çıkarım sistemi, fırının hızlı soğuma veya ısınma veya sıcaklık hareketlerinin normal durumda olup olmadığını anlamak için tasarlanmıştır. Matris tasarımı ve çıktılardan birinin Şekil 6.8'de gösterilen girdilerden herhangi birine veya ikisine bağımlılığını gösteren bulanık çıkarım sistemi çıktı yüzey haritası kullanılarak 25 bulanık eğer-ise kuralı oluşturulur.



Şekil 6.9. Öneri matrisi.

Burada genel çalışma metodolojisini açıklamak için, son sıcak metal sıcaklığı ve önceki sıcaklık ölçümleri dikkate alınarak eylem planının belirlenmesi için uzman

önerisi oluşturulmuştur. 25 kural ile ilerlemenin nedeni, veri seti ile bir ön öneri sistemi oluşturmaktır. Daha sonra, daha gelişmiş tahminlere sahip olmak için cüruf bazıklık veya silikon gibi diğer metal kimyası parametreleri kullanılarak üyelik fonksiyonlarının veya model girdilerinin sayısını artırarak daha ayrıntılı eylemler üretmek mümkündür. Uzman öneri sistemi deneylerine göre, HMT verileri kullanılarak fırının termal durumunu iyileştirme önerileri, 750 model çıktı ile Şekil 6.9'da gösterilmiştir. Elde edilen bu çıktı ile bir öneri sistemi geliştirilebilir.



Şekil 6.10. Sıcaklık durumunda bağlı öneri çıktıları.



## BÖLÜM 7

### SONUÇLARIN DEĞERLENDİRİLMESİ, ÖNERİLER

Endüstriyel tesislerde yapay zeka uygulaması olarak planlanan bu tez çalışmasında, yüksek fırın pik maden sıcaklığı değeri, günümüzde yaygın bir şekilde kullanılan yapay zeka tekniği olan Yapay Sinir Ağları yöntemi ile modellenmiştir. Ardından, elde edilen tahmin değerini oluşturmak için bulanık mantık modellemesi kullanılarak fırın işletmecilerine eylem önermek için bir model oluşturulmuştur. Söz konusu tesisten geçmiş süreç verilerini ve bu çıktı parametresi üzerinde etkisi olduğuna inanılan bir dizi girdi karakteristiğini kullanan çalışmalara göre, Yapay Sinir Ağı modeli oldukça başarılı bir performans sergilemiştir. YSA çıktıları ile karşılaştırma için, Otoregresif Entegre Kayan Ortalama modeli de referans olarak kullanılmıştır.

Türkiye'deki bir yüksek fırın tesisinden alınan tarihsel verileri kullanan çalışmanın ilk kısmı, çok önemli bir proses parametresi olan en yüksek sıcak maden sıcaklık değerlerini tahmin etmektir. Çok önemli bir sürece sahip olan yüksek fırının çalışması, en yüksek maden sıcaklık değerindeki değişikliklerden hemen etkilenmektedir. Bu parametreyi kontrol etmek ve büyümesini veya düşüşünü takip etmek, etkin iş yönetimi için çok önemlidir. Operatörler bu parametreyi hesaplayarak ekstra oksijen miktarını, kömür enjeksiyonunu, buhar ilavesini, soğuk hava sıcaklığını vb. hesaplayabilirler. Ayarların yönetilmesiyle fırının doğru yönetimi sağlanacaktır.

Bu çalışmada, Türkiye'de yerleşik bir yüksek fırının sıcak metal sıcaklığı, veri madenciliği teknikleri ve yapay sinir ağları kullanılarak seçilen 20 girdi parametresi kullanılarak modellenmiş ve fırın operasyon ekibine önceden gerekli aksiyonları önermek için bir başka bulanık eğer-öyleyse kuralı kullanılmıştır. 5 önceden tahmin edilen sıcak metal sıcaklık değerlerinin ortalaması kullanılarak fırının termal durumuna göre. Bu deneysel çalışmanın temel amacı, güvenilir ve verimli üretimi güvence altına almak için bulanık uzman sistemle birleşen yüksek seviyeli bir sıcaklık

tahmin sistemi tasarlamak, geliřtirmek ve yrtmek ve fırının alıřması sırasında gelecekteki beklenmeyen termal kesintiler iin dzeltici bir eylem altyapısı geliřtirmektedir.

Veri setinde giriř ve ıkıř parametrelerinin 5.000 rneęinin her biri kullanılmakta ve sinir aęları hesaplamalarında toplam 105.000 veri iřlenmektedir. Verilerin ilk %70'i (73500) eęitim, %15'i (15750) doęrulama ve kalan %15'i (15750) test amalı kullanılmaktadır. alıřmada NARX modeli, yapay sinir aęları ve bulanık mantık yapısı ele alınmıřtır. YSA modelinde ileri beslemeli geri yayılım tipi sinir aęları ve Levenberg-Marquardt ęrenme algoritması, bir gizli katman ve 10 gizli nron ele alınmıřtır. R2, RMSE ve MAPE istatistiksel lleri kullanılmıř ve en iyi performans gsteren model iin deęerler sırasıyla 0,92, 8,59 ve 0,41 olarak bulunmuřtur. ngrlen HMT'ye karřı nceki 5 HMT tahmin deęerinin ortalaması kullanılarak bařka bir uzman neri sistemi nerilmiřtir ve erken uyarı ve neri sistemi olarak fırın sıcaklık hareketlerini nceden ynlendirmek iin 25 eęer-yleyse kuralına sahip Mamdani tipi bir ıkarım sistemi uygulanır.

Simlasyon testleri, nerilen modellerin bu parametreyi hızlı, doęru ve gvenli bir řekilde tahmin edebildięini gstermiřtir. En nemlisi, sıcak maden sıcaklıęı dalgalanmalarının ynn tahmin etmenin mmkn olduęu gsterilmiřtir. Deneysel alıřmalar, gerekten meydana gelen sıcak maden sıcaklık deęerleri ile beklenen sıcak maden sıcaklık deęerleri arasında ok kk bir mutlak fark olduęunu ortaya ıkarmıř ve fırının sıcaklık rejimini ok dřk bir hata oranıyla tahmin etmeyi mmkn kılmıřtır.

Jimenez'in nceki alıřmasından [26] farklı olarak, malzeme ykleme dngleri, sabit dngler yerine fırın hacmine ve kapasitesine gre tanımlanır ve tahsis edilir. Sıcak metal retimini etkileyen ilgili zaman erevesini dzenlemek iin kapsamlı bir veri madencilięi alıřması yrtlr ve bu prosedrde  $\pm 10$  °C civarında daęılmıř daha dřk hata oranları ile daha iyi ve doęru tahmin sonuları elde edilir.

Gerekleřtirilen simlasyon alıřmaları sonucunda elde edilen ıktılar ařaęıda zetlenmektedir.

- ANN modeli 0.92 R<sup>2</sup> ve 8,59 RMSE değerleri ile 0.797 R<sup>2</sup> ve 19,282 RMSE değerleri ARIMA modeline göre, performans kriteri olarak seçilen R<sup>2</sup> ve RMSE anlamında daha iyi bir başarıyı göstermiştir.
- Levenberg-Marquardt eğitim algoritmasının kullanıldığı Feed forward backpropagation neural networks – ileri beslemeli ve geri yayılım sinir ağı modeli, literatürdeki çalışmalara uygun olarak, başarılı sonuçlar vermiştir hem de test süresi bakımından oldukça hızlı performansa sahip olduğu görülmüştür,
- Pik sıcaklığı değerinin ANN modeli kullanılarak HMT değerlerinin %81,2'lik hata oranı  $\pm 10$  °C'nin altındaki değerleri ile başarılı ve yüksek doğruluk ile tahmin edilebildiği gösterilmiştir.
- ANN modelinin özellikle ani sıcaklık dalgalanmalarını hızlı ve doğru bir şekilde kestirebildiği gösterilmiştir,
- Hatanın genel ortalama seyri  $\pm 10$  °C'nin aralığındadır. Dışındaki değerler ele alındığında en yüksek hatanın tek bir değerde  $\pm 63$  °C olduğu görülmüş bu hatanın da modele dahil edilmeyen olağan dışı bir fırın işletme şartından kaynaklandığı değerlendirilmektedir
- Jimenez çalışmasına göre daha başarılı sonuçlar elde edilmesinin temel nedeni sabit gecikme yerine hesaplanmış ve şarj hızına bağlı olarak değerlendirme yapılmasıdır. Bu ek olarak farklı ve fırın değişkenlerinin seçilmesi de önemli bir noktadır.
- Pik maden sıcaklığı değerinin tahminlenmesinde önerilen 20 adet giriş parametresinin bu parametre ile yüksek bir regresyon ilişkisine sahip olduğu gösterilmiştir. Dolayısı ile 20 adet parametrenin seçimindeki kriterin doğru olduğu gözlenmektedir,

- Literatürde belirtildiği gibi, fazla sayıda parameter kullanmak işlem sayısını ve süreyi artırır, yeterince giriş parametresi kullanmamak ise çıkış parametresinin kestirim başarımını olumsuz olarak etkiler. Bu çalışmada optimum sayıda giriş parametresi kullanıldığı ve genel sistem başarımın gayet yüksek olduğu gösterilmektedir.
- Pik maden sıcaklığının izlenmesi ve kestirimi yüksek başarımla sağlanması ile operatörlerin farkındalığının, fırın verimliliğinin ve kararlılığının artmasına büyük katkı sunacağı gösterilmektedir. Bu fırın soğumasının önlenmesi, yakıt tüketiminde elde edilebilecek iyileşmeler, gereksiz enerji tüketiminin önüne geçilmesi, karbon emisyonunda düşüş, duvar hareketlerine karşı hızlı ve önceden aksiyon alma gibi bir çok noktada takip ve operasyonel kolaylık sağlayacaktır.
- Kestirilen pik maden sıcaklığının bulanık mantık modeli ile değerlendirilmesi ve sıcaklık durumuna göre operatörlere geçmiş deneyimleri doğrultusunda tutarlı öneri sunabileceği gösterilmiştir.

Gerçekleştirilen çalışmanın sonucunda, yüksek fırınlarda pik maden sıcaklığı parametresi, tesisin geçmiş verileri kullanılarak farklı yöntemlerle modellenmiş ve çıktılarının yüksek başarımla sağlandığı gösterilmiştir. Kestirimin çıktısı bulanık mantık modeline girdi olarak kullanılmış ve aksiyon önerilerinin oluşturulması sağlanmıştır. Dolayısıyla literatüre sunulan bu modellerin tesis otomasyon sistemine entegre edilmesi ve proses optimizasyonu sağlayacak gerçek zamanlı bir simülasyon olarak kullanılması önerilmektedir.

Bununla birlikte, gerçek zamanlı verileri işlenmesi ile, tesislerin ilgili işletme parametre kontrollerine anlık olarak önerilerde bulunabilecek bir Seviye-2 uzman sistem (Level-2 expert system) yazılımı geliştirilebilir. Bu mevcut kontrol sistemleri ile entegre edilerek gerçek zamanlı bir öneri sistemi gerçekleştirilebilir ve bu sistemin kapalı çevrim olarak çalışması da sağlanabilir. Bu çalışmaya alternatif olarak ise, sistem başarımını arttırmaya yönelik, farklı doğrusal olmayan matematiksel modeller, bulanık mantık tabanlı yöntemler ya da iki yöntemin birbirine entegre edilmesiyle elde

edilecek hibrit modeller kullanılabilir. Ayrıca yüksek fırın proseslerinde kullanılan farklı parametrelere ilişkin kestirim ve tahminleme çalışmaları da gerçekleştirilebilir.

Model yapısında NOE modeli denenerek elde edilen gerçek ölçüm değeri yerine tahmin edilen sıcaklık değeri girdi olarak değerlendirilebilir ve sıcak maden sıcaklığı ölçüm değerinden bağımsız çalışacak bir model oluşturulabilir.

## KAYNAKLAR

1. İnternet: Wikipediada, “Çelik”, <http://en.wikipedia.org/wiki/celik> (2020).
2. İnternet: Bloomberg Haber Türk, “Küresel ham çelik üretimi Çin'e rağmen arttı” <https://www.bloomberght.com/kuresel-ham-celik-uretimi-cin-e-ragmen-artti-2297348> (2022).
3. İnternet: Bartın Üniversitesi, “Yüksek Fırın (Blast Furnace)” <https://cdn.bartın.edu.tr/metalurji/d7ee7cd9-f063-4669-8e1c-393503ed6ffb/demircelikuretimisunu2.pdf> (2022).
4. Bozkurt, E., “Yüksek Fırın Analizi ve Yapay Sinir Ağları ile Modellenmesi”, Yüksek Lisans Tezi, *Sakarya Üniversitesi, Fen Bilimleri Enstitüsü*, Sakarya, 9-100 (2007).
5. İnternet: The National Iron & Steel Heritage Museum, “Steelmaking Process)” [https://steelmuseum.org/steelmaking\\_exhibit\\_2016/steelmaking\\_process.cfm](https://steelmuseum.org/steelmaking_exhibit_2016/steelmaking_process.cfm) (2022).
6. İnternet: American Iron and Steel Institute “Steel Flowlines” [http://www.steel.org/AM/Template.cfm?Section=How\\_Steel\\_is\\_Made&CONTENTID=8497&TEMPLATE=/CM/ContentDisplay.cfm](http://www.steel.org/AM/Template.cfm?Section=How_Steel_is_Made&CONTENTID=8497&TEMPLATE=/CM/ContentDisplay.cfm) (2021).
7. İnternet: Wikipediada, “Çelik”, [http://en.wikipedia.org/wiki/blast\\_furnace](http://en.wikipedia.org/wiki/blast_furnace) (2022).
8. Ersöz, F., “Dünyada ve Türkiye’de Ham Çelik Üretimine Bakış”, *Erciyes Üniversitesi Fen Bilimleri Enstitüsü Dergisi* Cilt 32, Sayı 2, Kayseri, (2016).
9. Peacey, J. G., Davenport, W.G., “The iron blast furnace theory and practice”, *Pergamon Press*, 1-29, Oxford, (1979).
10. İnternet: Primetals Technologies, “Competence in Iron Making”, [www.vai.at/competence\\_in\\_ironmaking.pdf](http://www.vai.at/competence_in_ironmaking.pdf) (2018).
11. McKinsey&Company., “Decarbonization challenge for steel”, *McKinsey Report*, (2020).
12. Bhambre K.S., Mitra S.K., Gaitonde U.N., “Modeling of a coal-fired natural circulation boiler”, *ASME Journal of Energy Resources Technology*, Vol. 129, pp. 159-167, (2007).

13. Ustaoglu B., Cigizoglu H.K., Karaca M., "Forecast of Daily Mean, Maximum and Minimum Temperature Time Series by Three Artificial Neural Network Methods." *Meteorological Applications*, Vol. 15, pp. 431-445, (2008).
14. Zhou M., Gauthier J.E.D., "A new method for adiabatic flame temperature estimations of hydrocarbon fuels", *Fuel*, Vol. 78, Issue 4, pp. 471-478, March (1999).
15. Mashuga C.V., Crowl D.A., "Flammability zone prediction using calculated adiabatic flame temperatures", *Process Safety Progress*, [Vol. 18, Issue 3](#), pp. 127-134, (2004).
16. Hellberg P., Jonsson T.L.I., Jonsson P.G., Sheng D.Y., "A Model of Gas Injection into a Blast Furnace Tuyere", *Fourth International Conference on CFD in the Oil and Gas Metallurgical & Process Industries*: SINTEF / NTNU Norway, Vol. 1, Issue 1, (2005).
17. De Medeiros F.T.P., Noblat S.J.X, Fileti A.M.F., "Reviving traditional blast furnace models with new mathematical approach", *Ironmaking & Steelmaking*, Vol. 34, Issue 5, pp. 410-414, September (2007).
18. Asl Z.M., Salem A., "Investigation of the flame temperature for some gaseous fuels using artificial neural network", *International Journal of Energy and Environmental Engineering*, Vol. 1, Issue 1, pp. 57-63, (2010).
19. Hooney P.L., Boden A., Wang C., Grip C., Jansson B., "Design and Application of a Spreadsheet based Model of the Blast Furnace Factory", *ISIJ International*, Vol. 50, Issue 7, pp. 924-930, 2010.
20. Geerdes M., Toxopeus H., Galis G., "On the future of blast furnace ironmaking", *Proceedings of the 8th Ironmaking Conference IAS'2011*, Rosario, Santa Fe, Argentina, pp. 183-191, (2011).
21. Bhattacharjee D., Dash S.K., Das A.K., "Application of Artificial Intelligence in Tata Steel", *Tata Search* 1999, (1999).
22. Bulsari A., Saxen H., Saxen B., "Time-series prediction of silicon in pig iron using neural networks", *International Conference on Engineering Applications of Neural Networks (EANN' 92)*, (1992).
23. Banks, B., "Neural network based modeling and data mining of blast furnace operations", Yüksek Lisans Tezi, *MIT*, September (1999).

24. Ge A. X., “A neural network approach to the modeling of blast furnace”, Yüksek Lisans Tezi, *MIT Department of Electrical Engineering and Computer Science*, May 1999.
25. Nikus, M. Saxen, H., “Prediction of a blast furnace burden distribution variable”, *ISIJ International*, Vol.36, No.9, pp.1142-1150, 1996.
26. Jimenez, J., Mochon, J., Ayala, J. S., Obeso, F., “Blast furnace hot metal temperature prediction through neural networks-based models”, *ISIJ International*, Vol.44 No.3, pp.573-580, (2004).
27. İnternet: Win Thermal Engineering For Productivity, “How to Make a Mini Blast Furnace? And How Does It Works?” <https://www.win-therm.com.my/how-to-make-a-mini-blast-furnace/> (2022).
28. Aslan Ö., “Demir Çelik Alanında Doğrusal ve Doğrusal Olmayan Model Yapıları Tabanlı Model Öngörümü Denetleyici Uygulamaları”, Yüksek Lisans Tezi, *Karaelmas Üniversitesi*, Haziran (2009).
29. Peacey J.G., Davenport W.G., “The iron blast furnace theory and practice”, *Pergamon Press*, Oxford, pp.1-29, (1979).
30. İnternet: Türkiye Çelik Üreticileri Derneği, “Çelik Haritası” <https://celik.org.tr/harita/> (2022).
31. İnternet: Foreks, “2021 Yılında global ham çelik üretimi %3,6 arttı”, <https://foreks.com/haber/detay/61f0c8e05908010001db368f/PICNEWS/tr/2021-yilinda-global-ham-celik-uretimi-3-6-artti> (2022).
32. İnternet: Danieli, “Modern Blast Furnace Design” [https://www.danieli.com/en/products/products-processes-and-technologies/modern-blast-furnace-design\\_26\\_71.htm#](https://www.danieli.com/en/products/products-processes-and-technologies/modern-blast-furnace-design_26_71.htm#) (2022).
33. İnternet: Thermo Scientific, “Thermo Scientific Products in the Iron and Steel Manufacturing Processing”, <http://www.thermoscientific.com/content/dam/tfs/ATG/CAD/CAD%20Documents/Product%20Manuals%20&%20Specifications/Elemental%20Analysis/Thermo-Scientific-Iron-Steel-process-A3.pdf> (2022).
34. Omori, Y., “Committee on Reaction within Blast Furnace, Joint Society on Iron and Steel Basic Research”, *The Iron and Steel Institute of Japan, Blast furnace phenomena and modeling, Elsevier Applied Science Publishers Ltd.*, pp.1-61, New York, (1987).



35. Biswas, A. K., “Principles of blast furnace ironmaking”, *Cootha Publishing House*, pp.1-13, Brisbane, Australia, (1981).
36. İnternet: EKC Metallurgy, “Yüksek Fırınlar” <http://www.ekcmetallurgy.org/Haber/10/YUKSEK-FIRINLAR.html> (2022).
37. İnternet: Nischal, “Mimicking Biological Neural Network | Artificial Neurons and Biological Neurons | Perceptron | Multi-Layer Perceptron | Backpropagation” <https://nischal.info.np/very-stupid-introduction-to-deep-learning> (2022).
38. Madalla G.S., “Introduction to Econometrics”, *Macmillan Publishing Company*, Second Edition, New York, (1992).
39. Özdemir Y., “Afşin-Elbistan Termik Santrallerinin Çevresel Etkileri: Mesafe Tabanlı Algı Analizi”, Yüksek Lisans Tezi, *Kahramanmaraş Sütçü İmam Üniversitesi*, (2013).
40. Kemal M., Semerkant O., “Türkiye Linyit Kömürü Potansiyeli ve Kullanım Olanağı”, *Türkiye 4. Kömür Kongresi*, pp. 17-31, Zonguldak, (1984).
41. Çam N.F., Yaprak G., Gür F., Candan O., Bayram A, Onat B., Tanıl H., Mert A.,” Batı Anadolu’ daki Termik Santraller Çevresindeki Doğal Radyonüklid (226Ra, 232Th, 40K ve 210Pb) Emisyonundan Kaynaklanan Radyoaktif Kirliliğin İncelenmesi ve Radyolojik Risk Tahmini”, *Tübitak, Çaydağ 103Y057*, İzmir, (2006).
42. Poo J.M.R., “Computer Aided Introduction to Econometrics”, *Springer Verlag GmbH & Co. KG* , New York, (2003).
43. Ravindra K. Sarma, Amar Gupta, Sanjeev Vadhavkar., “Neural Network-Based Data Mining Techniques for Steel Making Institute of Technology”, Yüksek Lisans Tezi, *MIT, Productivity from Information Technology (PROFIT) Initiative*, Cambridge (2004).
44. Gyllenram, P., Wikstrom, J., Hallin, M., “Blast furnace control after the year 2000”, *Iron and Steelmaking*, Vol.23, No.11, pp. 57-63, (1996).
45. O’Hanlon, J., “Blast furnace control philosophy at British Steel”, *Iron and Steel Engineer*, (1991).
46. Bulsari, A., Saxen, H., Saxen, B., “Time-series prediction of silicon in pig iron using neural networks”, *International Conference on Engineering Applications of Neural Networks (EANN '92)*, (1992).

47. Bulsari, A., Saxen, H., “Classification of blast furnace probe temperatures using neural networks”, *Steel Research*, Vol.66 No.6, pp.231-236, (1995).
48. Zuo, G., Ma, J., Bjorkman, B., “Some applications of neural networks for prediction of blast furnace irregularities”, *Steel Research*, Vol.69 No.2, pp.41-48, (1998).
49. Bozkurt, E., “Yüksek Fırın Analizi ve Yapay Sinir Ağları ile Modellenmesi”, Yüksek Lisans Tezi, *Sakarya Üniversitesi, Fen Bilimleri Enstitüsü*, Sakarya, 9-100 (2007).
50. İnternet: Siemens, “Metal Mining”, [http://www.industry.siemens.com/metals-mining/EN/processes/mp\\_proc\\_02\\_03.htm](http://www.industry.siemens.com/metals-mining/EN/processes/mp_proc_02_03.htm) (2020).
51. İnternet: DokümTek, “Pik Dökümde Tavsiye Analiz Oranları Nedir”, <https://dokumtek.tumblr.com/post/129276107153/pik-d%C3%B6k%C3%BCmde-tavsiye-analiz-oranlar%C4%B1-nedir> (2022).
52. İnternet: Çimsa, “Yüksek Fırın Cürufu Özelliklerinin Beton Dayanımına Etkisi Nasıl Olur?”, <https://cimsa.com.tr/formulhane/hazir-beton/yukse-firin-curufu-ozelliklerinin-beton-dayanimina-etkisi-nasil-olur>, (2022).
53. Balli M., “Tav Fırınlarında Kok Gazı Yerine Doğalgaz Kullanımının Ekonomik ve Çevresel Sürdürülebilirlik Anazlizi”, Yüksek Lisans Tezi, *Karabük Üniversitesi*, (2021).
54. İnternet: Genç Bilim, “Bulanık Mantık”, <http://www.genccbilim.com/odev/odevgoster.php?il=&id=15904>
55. İnternet: Genç Bilim, “Bulanık Mantık”, <http://www.genccbilim.com/odev/odevgoster.php?il=&id=13933>
56. Mian, T.M., “Fuzzy logic based automotive airbag control system”, Yüksek Lisans Tezi, *University of Windsor, Ontario, Canada*, 1-30 (1999).
57. Jang J. S.R, Gulley N. “Fuzzy logic toolbox for use with Matlab user’s guide”, *Mathworks Inc*, (1999).
58. İnternet: Wikipeda, “Bulanık Mantık”, [http://tr.wikipedia.org/wiki/Bulan%C4%B1k\\_Mant%C4%B1k](http://tr.wikipedia.org/wiki/Bulan%C4%B1k_Mant%C4%B1k) (2022).
59. İnternet: İstanbul Teknik Üniversitesi, “Bulanık Küme Tanımları”, [http://www.elk.itu.edu.tr/~yesil/bulanik\\_kume\\_tanimlar.htm](http://www.elk.itu.edu.tr/~yesil/bulanik_kume_tanimlar.htm) (2019).

60. Çalışkan, E., “Gaz konsantrasyonlarının saptanmasında bulanık mantık ve yapay sinir ağı tabanlı algoritmaların kullanılması”, Yüksek Lisans Tezi, *SAÜ, Fen Bilimleri Enstitüsü, Sakarya*, 34-65, (2004).
61. İnternet: Bochum Üniversitesi, “Üyelik fonksiyonu”, <http://www.atp.ruhr-uni-bochum.de/rt1/syscontrol/node117.html> (2019).
62. Melin, P., Castillo, O., “Modeling, simulation and control of non-linear dynamical systems: an intelligent approach using soft computing and fractal theory”, *Taylor & Francis*, New York, 9-28 (2002).
63. İnternet: “Bulanık Mantık”, <http://ay.kut1980.sitemynet.com/fuzzy1.pdf> (2018).
64. Reyes, C. A. P., ”Coevolutionary fuzzy modeling”, *Pour L’obtention Grade de Docteur Es Sciences, Lausanne, EPFL*, 1-68, (2002).
65. İnternet: Imperial College London, “Fuzzy Sets”, [http://www.doc.ic.ac.uk/~nd/surprise\\_96/journal/vol4/sbaa/report.fuzzysets.html](http://www.doc.ic.ac.uk/~nd/surprise_96/journal/vol4/sbaa/report.fuzzysets.html), (2010).
66. Holland, A., “Fuzzy systems lecture notes”, *Department of Computer Science, University College Cork*, Ireland (2012).
67. İnternet: AI CIT, “Fuzzy çıkarım modelleri”, [http://www.ai-cit.sk/source/publications/thesis/master\\_thesis/1997/holecy/html/node\\_19-17-27.html](http://www.ai-cit.sk/source/publications/thesis/master_thesis/1997/holecy/html/node_19-17-27.html), (2010).
68. Hagan, M. T., Demuth, H. B., Beale, M., “Neural network design”, *PWS Publishing*, 1-12, USA, (1996).
69. İnternet: Wikipediada, “Yapay Sinir Ağları”, [http://tr.wikipedia.org/wiki/Yapay\\_sinir\\_a%C4%9Flar%C4%B1](http://tr.wikipedia.org/wiki/Yapay_sinir_a%C4%9Flar%C4%B1) (2022).
70. Principe, J. C., Euliano, N. R., Lefbvre W. C., “Neural and adaptive systems-Fundamentals through simulations”, *John Wiley*, 101-222 (2000).
71. Tebelskis, T., “Speech recognition using neural networks”, Doctora Tezi, *Carnegie Mellon University*, Pennsylvania, 27-48 (1995).
72. Tunckaya Y., “An experimental modelling and performance validation study: Top gas pressure tracking system in a blast furnace using soft computing methods”, *Proceedings of the Institution of Mechanical Engineers, Part E: Journal of Process Mechanical Engineering*, (2021).

73. Abderson, D., Mcneill, G., “Artificial neural networks technology”, **Kaman Sciences Corporation, A DACS State-of-the-Art Report for Rome Laboratory, ELIN: A011**, New York, 1-40 (1992).
74. Cavuto, D., J., “An exploration and development of current artificial neural network theory and applications with emphasis on artificial life”, Yüksek Lisans Tezi, **The Cooper Union Albert Nerken School of Engineering**, 1-24, (1997).
75. Yumuşak, N., “Güç sistemi devre elemanlarının elektriksel özelliklerinin elde edilmesinde yapay sinir ağı tabanlı algoritmaların kullanılması”, Doktora Tezi, **SAÜ, Fen Bilimleri Enstitüsü**, 6-33, (1998).
76. Haykin, S., “Neural Networks A Comprehensive Foundation”, **Prentice Hall Publishing**, New Jersey, Vol.1, 1-14, (1999).
77. Kaya, M., Tuncer, İ., H., “Çırpan kanat kesitlerinde itkinin yapay zeka ile en iyileştirilmesi”, **HİTEK**, (2004).
78. Demuth, H., Beale, M., “Neural network toolbox for use with Matlab-user’s guide”, **Mathworks Inc**, (2002).
79. Eğrisöğüt, A., “Çimento hammadde karışım prosesinin yapay sinir ağları ile matematiksel modellenmesi”, Yüksek Lisans Tezi, **SAÜ, Fen Bilimleri Enstitüsü**, 27-53. (2002).
80. Madalla G.S., “Introduction to Econometrics”, **Macmillan Publishing Company, Second Edition**, New York, (1992).
81. Gujarait D., “Basic Econometrics”, **The McGraw-Hill Companies, Fourth Edition**, (2004).
82. Subaşı D.B., “Enflasyonun ARIMA Modelleri ile Tahminlenmesi: 1995-2004 Türkiye Uygulaması”, Yüksek Lisans Tezi, **Dumlupınar Üniversitesi, Kütahya**, 113, (2005).
83. Yaman K., Sarucan A., Atak M., Aktürk N., “Dinamik Çizelgeleme için Görüntü İşleme ve ARIMA Modelleri Yardımıyla Veri Hazırlama”, **Gazi Üniv. Müh. Mim. Fak. Der., Cilt 16, No. 1**, 19-40, (2001).
84. Poo J.M.R., “Computer Aided Introduction to Econometrics”, **Springer Verlag GmbH & Co. KG**, New York, (2003).

85. Radhakrishnan, V. R., 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).
86. Yoshikawa, F., “Mathematical modeling of fluid flow and heat Transfer in blast furnace hearth”, Yüksek lisans tezi, *MIT*, (1980).
87. Torssell, K., Xuegong B., Wijk, O., “Simulation of the blast furnace process by a mathematical model”, *ISIJ International*, Vol.32 No.4, 470-480, (1992).
88. Torssell, K., Xuegong B., Wijk, O., “Prediction of the blast furnace process by a mathematical model”, *ISIJ International*, Vol.32 No.4, .481-488, (1992).
89. Peacey, J. G., Davenport, W.G., “The iron blast furnace theory and practice”, *Pergamon Press*, 1-29, Oxford, (1979).
90. Omori, Y., “Committee on Reaction within Blast Furnace, Joint Society on Iron and Steel Basic Research”, *The Iron and Steel Institute of Japan, Blast furnace phenomena and modeling*, Elsevier Applied Science Publishers Ltd., 1-61, New York, (1987).
91. Singh, H., Sridhar, N., Deo, B., “Artificial neural nets for prediction of silicon content of blast furnace hot metal”, *Steel Research*. Vol.67, No.12, (1996).
92. Ullmann’s Encyclopedia of Industrial Chemistry, 5th complete revised edition, *Wiley VCH*, Vol.A14, 517-540, Weinheim, (1985).
93. Liptak, B. G., “Instrument Engineers’ Handbook Vol.2: Process Control and Optimization - 4th Edition”, *CRC Press*, 253-263, (2005).

## ÖZGEÇMİŞ

Erdoğan BOZKURT ilk, orta ve lise öğrenimini aynı şehirde tamamlamıştır. Ereğli Anadolu Lisesi mezunu olduktan sonra 1994 yılında İstanbul Üniversitesi Mühendislik Fakültesi Elektronik Mühendisliği Bölümü'nde üniversite öğrenime başlamış 1999 yılında mezun olmuştur. Aynı yıl Ereğli Demir ve Çelik Fabrikaların'da Elektronik Otomasyon Müdürlüğünde Seviye2 Sistemleri Mühendisi olarak iş hayatına başlamıştır. 2010 yılında Bridgestone Lassa Lastik San. A.Ş. için çalışmaya başlamış, 2016 bir arkadaşı ile kendi girişimleri olan Antares Mühendisliği kurmuştur. 2017'de Faydasıçok Holding'de, 2020'den sonra da Şenpiliç AŞ'de Bilgi Sistemleri ekiplerinde çeşitli görevlerden sonra 2022 Nisan'dan bu yana General Electric bünyesinde çalışma hayatına devam etmektedir. Buna paralel olarak; 2007 yılında Sakarya Üniversitesi Elektrik-Elektronik Mühendisliği yüksek lisans, 2019 yılında Gebze Teknik Üniversitesi İşletme yüksek lisans, 2013 yılında Açıköğretim İşletme lisans ve 2020 yılında Uluslararası Ticaret ve Lojistik Yönetimi lisans programlarından mezun olmuştur.