

**T.C.  
SAKARYA ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ**

**YÜKSEK FIRIN ANALİZİ VE YAPAY SİNİR AĞI İLE  
MODELLENMESİ**

**YÜKSEK LİSANS TEZİ**

**Elektronik Müh. Erdoğan BOZKURT**

**Enstitü Anabilim Dalı : ELK.-ELEKTR. MÜHENDİSLİĞİ**

**Enstitü Bilim Dalı : ELEKTRONİK**

**Tez Danışmanı : Yrd. Doç. Dr. Ayhan ÖZDEMİR**

**Haziran 2007**

T.C.  
SAKARYA ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ

# YÜKSEK FIRIN ANALİZİ VE YAPAY SİNİR AĞI İLE MODELLENMESİ

## YÜKSEK LİSANS TEZİ

Elektronik Müh. Erdoğan BOZKURT

Enstitü Anabilim Dalı : ELK.-ELEKTR. MÜHENDİSLİĞİ

Enstitü Bilim Dalı : ELEKTRONİK

Bu tez 05 / 06 / 2007 tarihinde aşağıdaki jüri tarafından Oybirliği ile kabul edilmiştir.

Y. Doç. Dr. Ayhan ÖZDEMİR  
Jüri Başkanı

Prof. Dr. Uğur ARİFOĞLU  
Üye

Prof. Dr. Abdullah FERİKOĞLU  
Üye

## TEŞEKKÜR

Bu çalışmayı almamı sağlayarak her zaman üzerinde çalışmak istediğim iki konu olan bulanık mantık ve sinirsel ağlar konusunda bana araştırma ve çalışma fırsatı veren, çalışmam boyunca cesaretlendiren ve değerleri görüşleri ile yol göstererek çalışmamın tamamlanmasında büyük pay sahibi olan değerli hocam Sn. Yrd. Doç. Dr. Ayhan Özdemir'e, çalışmama olumlu yaklaşarak destek veren Demir Üretim Başmüdürü Sn. Şevket Erol'a ve Yüksek Fırınlara Müdürü Sn. Ufuk Gürbüz'e, başta başmühendisim Ertan Fidan ve mesai arkadaşlarım Selahattin Okur ve Serdar Köroğlu olmak üzere çalışmalarında beni sürekli cesaretlendiren ve destek olan tüm çalışma arkadaşlarıma, başta Aşkın Peker ve Kerem Doğan olma üzere yüksek fırın bilgileri ile beni aydınlatan ve hatalarımı düzelten tüm işletme başmühendisi ve işletme mühendisi arkadaşlarıma, başta Mustafa Demircan olmak üzere deneyimlerini bana aktararak çalışmamda büyük emekleri olan formen ve operatör arkadaşlarıma teşekkürü bir borç bilirim.

Ayrıca beni sürekli olarak destekleyen, maddi ve manevi desteklerini esirgemeyen, anneme, babama, eşime ve oğluma teşekkür ederim.

# İÇİNDEKİLER

TEŞEKKÜR.....	ii
İÇİNDEKİLER .....	iii
SİMGELER VE KISALTMALAR LİSTESİ.....	viii
ŞEKİLLER LİSTESİ .....	xii
TABLolar LİSTESİ.....	xiv
ÖZET.....	xv
SUMMARY.....	xvi

## BÖLÜM 1.

GİRİŞ.....	1
1.1. Mevcut Modelleme Çalışmaları.....	3
1.1.1. Matematiksel modelleme çalışmaları.....	3
1.1.2. Modelleme çalışmalarında yapay sinir ağı kullanımı.....	5

## BÖLÜM 2.

YÜKSEK FIRIN.....	9
2.1. Giriş.....	9
2.2. Yüksek Fırının Genel Yapısı.....	11
2.3. Hammaddeler.....	14
2.3.1. Demir oksitleri.....	14
2.3.2. Metalürjik kok.....	14
2.2.3. Curuf yapıcılar (CaO ve MgO).....	15
2.3.4. Sıcak hava.....	15
2.2.5. Gaz, sıvı veya katı hidrokarbonlar.....	15
2.4. Ürünler.....	16
2.5. Yüksek Fırın Yardımcı Sistemleri.....	18
2.5.1. Hammadde besleme sistemi.....	18

2.5.2. Fırın üstü şarj sistemi.....	19
2.5.3. Sobalar.....	19
2.5.4. Hidrokarbon ilavesi sağlayan sistemler.....	20
2.5.5. Dökümhane.....	20
2.5.6. Soğutma sistemleri.....	20
2.6. Üretim Süreci.....	21
2.6.1. Demir oksitlerin indirgenmesi.....	22
2.6.2. Alt bölge tepkimeleri.....	24
2.6.3 Orta bölge tepkimeleri.....	27
2.6.4 Üst bölge tepkimeleri.....	28
2.7. Verimlilikteki Gelişmeler.....	29
2.8. Yüksek Fırın Maliyetleri.....	30
2.9. Türkiye’de Demir Üretimi ve Yüksek Fırınlarda.....	31

### BÖLÜM 3.

VERİ MADENCİLİĞİ.....	32
3.1. Veri Madenciliğinin Tanımı.....	32
3.2. Veri Madenciliği İşlevleri.....	33
3.2.1. Keşifsel veri analizi (EDA).....	33
3.2.2. Betimsel (Tanımlayıcı) modelleme.....	34
3.2.3. Öngörülü modelleme.....	35
3.2.4. Örüntüleri ve kuralları keşfetme.....	36
3.2.5. İçerik ile erişim.....	37
3.3. Veri Madenciliği Metodolojisi.....	37
3.4. Veri Madenciliği Teknikleri.....	38
3.4.1. Sınıflandırma.....	39
3.4.2. Kestirim.....	40
3.4.3. Öngörü.....	41
3.4.4. Benzerlik gruplaması.....	42
3.4.5. Kümeleme.....	42
3.4.6. Tanımlama.....	43
3.5. Veri Madenciliği Yöntemleri.....	43
3.5.1. İstatistiksel yöntemler.....	43

3.5.2. Bellek tabanlı yöntemler.....	44
3.5.3. İlişkisel analiz.....	45
3.5.4. Karar ağaçları ve kural türetme.....	46
3.5.5. Yapay sinir ağları.....	47
3.5.6. Genetik algoritmalar.....	49
3.6. Veri Madenciliğinde Yeni Yaklaşımlar.....	49

## BÖLÜM 4.

BULANIK MANTIK.....	51
4.1. Giriş ve Tarihçe.....	51
4.2. Bulanık Küme Teorisi.....	54
4.2.1. Temel kavramlar ve terimler.....	55
4.2.2. Bulanık küme işlemleri.....	58
4.2.2.1. Kapsama.....	58
4.2.2.2. Birleşim.....	58
4.2.2.3. Kesişim.....	59
4.2.2.4. Tümleyen.....	60
4.2.3. Bazı bulanık küme kuralları.....	60
4.2.4. Üyelik fonksiyonları.....	61
4.2.4.1. Üçgen üyelik fonksiyonları.....	61
4.2.4.2. Yamuk üyelik fonksiyonları.....	62
4.2.4.3. Gaussian üyelik fonksiyonları.....	62
4.2.4.4. Genelleştirilmiş çan üyelik fonksiyonları.....	63
4.2.4.5. Sigmoid üyelik fonksiyonları.....	63
4.3. Bulanık Yargılama.....	65
4.3.1. Bulanık eğer-ise kuralları.....	65
4.3.2. Bulanık yargılama.....	66
4.4. Bulanık Çıkarım Sistemleri.....	68
4.4.1. Mamdani bulanık çıkarım sistemi.....	70
4.4.1.1. Alanın kitle merkezi.....	71
4.4.1.2. Alanın orta noktası.....	71
4.4.1.3. Maksimumun ortası.....	71
4.4.1.4. Maksimumun en küçüğü.....	72

4.4.1.5. Maksimumun en büyüğü.....	72
4.4.2. Sugeno bulanık çıkarım sistemi.....	73
4.4.3. Tsukamoto bulanık çıkarım sistemi.....	74
4.5. Bulanık Modelleme.....	75
4.5.1. Yaklaşımlar ve teknikler.....	77
BÖLÜM 5.	
YAPAY SİNİR AĞLARI.....	78
5.1. Giriş.....	78
5.2. Tarihi Gelişim.....	79
5.3. Biyolojik Sinir Sistemi.....	82
5.4. Yapay Sinir Ağlarının Özellikleri.....	85
5.4.1. Eğitilebilirlik.....	85
5.4.2. Genelleme.....	86
5.4.3. Doğrusal olmama.....	86
5.4.4. Sağlamlık ve hata toleransı.....	86
5.4.5. Tekbiçimlilik.....	87
5.4.6. Paralellik.....	87
5.5. Sinir Ağların Esasları.....	87
5.5.1. İşlem birimleri.....	88
5.5.1.1. Tek girişli nöron.....	88
5.5.1.2. Çok girişli nöron.....	90
5.5.2. Bağlantılar.....	91
5.5.3. Hesaplama.....	92
5.5.3.1. Transfer fonksiyonları.....	93
5.5.4. Öğrenme.....	97
5.6. Sinirsel Ağların Sınıflandırılması.....	99
5.6.1. Denetimli öğrenme.....	100
5.6.1.1. İleri beslemeli ağlar.....	100
5.6.1.2. Yinelenen ağlar.....	104
5.6.2. Yarı denetimli öğrenme.....	105
5.6.3. Denetimsiz öğrenme.....	106
5.6.4. Melez ağlar.....	108

5.6.5. Dinamik ağlar.....	109
5.7. Geri Yayılım Algoritması.....	110
5.7.1. Algoritma.....	111
5.7.1.1. Performans göstergesi.....	112
5.7.1.2. Zincir kuralı.....	114
5.7.1.3. Duyarlılıkların geri yayılımı.....	116
5.7.2. Geri yayılımdaki değişiklikler.....	119
5.8. Yapay Sinir Ağlarının Uygulamaları.....	120
<b>BÖLÜM 6.</b>	
<b>MODELLEME.....</b>	<b>122</b>
6.1. Giriş.....	122
6.2. İncelenen YSA Araçları.....	122
6.3. Çıktılar.....	123
6.3.1. Pik demir sıcaklığı.....	124
6.3.2. Pik demir silisyum içeriği.....	125
6.3.3. Curuf bazitesi.....	125
6.4. Pik Demir Sıcaklığının Kestirilmesi.....	126
6.4.1. Uygun değişkenlerin seçilmesi.....	126
6.4.2. Duvar hareketlerinin tespiti.....	129
6.4.3. Model üzerindeki çalışmalar.....	133
6.4.4. Model yapısı ve eğitme.....	138
6.4.5. Pik demir sıcaklığı test sonuçları.....	142
6.5. Pik Demir Silisyum İçeriği ve Curuf Bazitesinin Kestirilmesi.....	145
<b>BÖLÜM 7.</b>	
<b>SONUÇLAR VE ÖNERİLER.....</b>	<b>147</b>
<b>KAYNAKLAR.....</b>	<b>149</b>
<b>ÖZGEÇMİŞ.....</b>	<b>155</b>



## SİMGELER VE KISALTMALAR LİSTESİ

$\forall$	: 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
ADALINE	: Adaptive Linear Neuron
$Al_2O_3$	: Alüminyum Oksit
ANN	: Artificial Neural Network
ART	: Adaptive Resonance Theory
ASIC	: Application Specific Integrated Circuit
ASO	: Automatic Structure Optimization
AT&T	: American Telephone & Telegraph Company
$b$	: Bias
$\mathbf{b}$	: Bias matrisi
B2	: İkili curuf bazitesi
B4	: Dörtlü curuf bazitesi
BOA	: Bisector of Area
C	: Karbon
$CaC_2$	: Karpit
cal	: Kalori
$CaO$	: Kalsiyum oksit

$CaCO_3$	: Kalsiyum karbonat
$CO$	: Karbon monoksit
$CO_2$	: Karbon dioksit
COA	: Centroid (Center) of Area
DARPA	: Defense Advanced Research Projects Agency
$e$	: Sinirsel ağdaki hata
$e$	: Sinirsel ağdaki hata matrisi
EDA	: Exploratory data analysis
Erdemir	: Ereğli Demir ve Çelik Fabrikaları
$f$	: Transfer fonksiyonu
$FeO$	: Vüstit
$Fe_2O_3$	: Hematit
$Fe_3O_4$	: Magnetit
JavaNNS	: Java Neural Network Simulator
$H_2$	: Hidrojen
$H_2O$	: Su
IBM	: International Business Machines Corporation
IEEE	: Institute of Electrical and Electronics Engineers
İsdemir	: İskenderun Demir ve Çelik Fabrikaları
$k$	: Yineleme sayısı
$K$	: Potasyum
$K_2O$	: Potasyum oksit
Kardemir	: Karabük Demir ve Çelik 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
max	: Maksimum

<i>min</i>	: Minimum
<i>MgCO<sub>3</sub></i>	: Magnezyum karbonat
<i>MgO</i>	: Magnezyum oksit
<i>Mn</i>	: Mangan
MOM	: Mean Of Maximum
MSE	: Mean Squared Error
<i>n</i>	: Çok katmanlı ağlarda ara katman çıkışı
<i>N<sub>2</sub></i>	: Azot
<i>Na</i>	: Sodyum
<i>Na<sub>2</sub>O</i>	: Sodyum oksit
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
<i>p</i>	: Nöron girişi
<b>p</b>	: Nöron giriş matrisi
<i>P</i>	: Fosfor
P	: Paskal
R	: Bağlantı katsayısı
RBF	: Radial Basis Function
<i>s</i>	: Sinirsel ağlarda bir katmandaki nöron duyarlılığı
<b>s</b>	: Sinirsel ağlarda bir katmandaki nöron duyarlılıklarının matrisi
<i>S</i>	: Kükürt
<i>Si</i>	: Silisyum
<i>SiO<sub>2</sub></i>	: Silisyum oksit
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
$t$	: Sinirsel ađlarda hedef ıkıř deęeri
$\mathbf{t}$	: Sinirsel ađlarda hedef ıkıř deęerleri matrisi
TDNN	: Time Delay Neural Network
TSK	: Takagi-Sugeno-Kang
USD	: Amerikan Doları
VLBP	: Variable Learning Rate Back Propagation
YSA	: Yapay Sinir Ađları
yy	: Yüzyıl
$w$	: Sinirsel ađlarda baęlantının aęırlıęı
$\mathbf{W}$	: Sinirsel ađlarda baęlantıların aęırlık matrisi

## ŞEKİLLER LİSTESİ

Şekil 2.1.	Çelik üretim prosesi.....	10
Şekil 2.2.	Bir yüksek fırının düşey ve yardımcı sistemleri.....	12
Şekil 2.3.	Bir yüksek fırın tesisinin hammadde, şarj, dökümhane, gaz işleme ve sıcak hava sistemlerini gösteren kesiti.....	13
Şekil 2.4.	Gaz ve katıların sıcaklık dağılımının fırın yüksekliği boyunca ki ideal dağılımı ve üç sıcaklık bölgesinde oluşan kimyasal tepkimeler.....	26
Şekil 3.1.	Veri madenciliği metodolojisi.....	38
Şekil 4.1.	Dilsel değerlerin klasik ve bulanık küme üzerinde gösterimi.....	54
Şekil 4.2.	Üyelik fonksiyonun bazı özellikleri.....	56
Şekil 4.3.	Yaygın kullanılan birleşim (VEYA) operatörleri.....	59
Şekil 4.4.	Yaygın kullanılan kesişim (VE) operatörleri.....	59
Şekil 4.5.	Üyelik fonksiyonları.....	64
Şekil 4.6.	Bulanık çıkarım sistemi.....	69
Şekil 4.7.	Bir örnek üzerinden Mamdani bulanık çıkarım sisteminde adımlar.....	69
Şekil 4.8.	Sayısal çıktı elde etmek için kullanılan farklı berraklaştırma yöntemleri.....	70
Şekil 4.9.	Sugeno bulanık modeli.....	74
Şekil 4.10.	Tsukamoto bulanık modeli.....	75
Şekil 5.1.	Bir sinir hücresinin yapısı.....	83
Şekil 5.2.	Bir sinaps ve çalışması.....	84
Şekil 5.3.	Tek girişli nöron.....	89
Şekil 5.4.	Çok girişli nöron.....	90
Şekil 5.5.	Yapay sinir ağı topolojileri.....	91

Şekil 5.6.	Belirleyici yerel transfer fonksiyonları: (a) doğrusal; (b) eşik; (c) sigmoidal.....	94
Şekil 5.7.	Diğer transfer fonksiyonları.....	95
Şekil 5.8.	Belirleyici olmayan transfer fonksiyonları.....	96
Şekil 5.9.	Tek katmanlı ağ.....	101
Şekil 5.10.	Çok katmanlı ağlara örnek olarak üç katmanlı bir ağ.....	103
Şekil 5.11.	Katmanlı yinelenen ağlar. (a) Jordan ağı; (b) Elman ağı.....	105
Şekil 5.12.	Üç katmanlı bir ağ.....	112
Şekil 6.1.	Pik demir sıcaklıkları.....	128
Şekil 6.2.	Isı değişimi üyelik fonksiyonları.....	130
Şekil 6.3.	Isı değişim trendi üyelik fonksiyonları.....	131
Şekil 6.4.	Bulanık çıkarım çıkış üyelik fonksiyonları.....	131
Şekil 6.5.	Bulanık çıkarım yüzeyleri.....	132
Şekil 6.6.	Tespit edilen duvar hareketleri ve sıcak plaka sayıları ile çarpılmış değerleri.....	133
Şekil 6.7.	Seri-paralel(sp) veya paralel(p) tanımlama yöntemleri.....	134
Şekil 6.8.	Hava akışı ham verisi (seri 1) ve 6.5. eşitliğinin uygulanmış hali (seri 2) .....	137
Şekil 6.9.	Eğitim için kullanılan Matlab komut rutini.....	140
Şekil 6.10.	Eğitilen ağ yapılarının sahip oldukları nöron sayılarına göre MSE'leri.....	141
Şekil 6.11.	Test verisi hedef değerleri ve model çıkış değerleri.....	142
Şekil 6.12.	Sıcaklıktaki gerçek hata.....	143
Şekil 6.13.	Sıcaklıktaki gerçek hatanın dağılım grafiği.....	143
Şekil 6.14.	Hedef ve çıkışlar arasındaki ilişki.....	144
Şekil 6.15.	NARX, NOE modellerinin çıkışları ve hedefler(T) .....	145

## TABLULAR LİSTESİ

Tablo 2.1.	Genelleştirilmiş erimiş pik analizi.....	16
Tablo 2.2.	Genelleştirilmiş curuf analizi.....	17
Tablo 2.3.	Genelleştirilmiş yüksek fırın gazı analizi.....	18
Tablo 6.1.	Seçilen yüksek fırın değişkenleri.....	127
Tablo 6.2.	Değişkenlere uygulanan gecikmeler.....	136

## ÖZET

Anahtar kelimeler: Yüksek fırın, Yapay sinir ağı, Pik demir sıcaklığı

Yüksek fırınlar, çelik üretim sürecinin hammaddesi olan pik demirin üretilmesi için kullanılan tesislerdir. Yüksek fırınların çok karmaşık iç yapısı nedeniyle matematiksel olarak modellenmesinde bazı zorluklar vardır. Günümüzde bu tür karmaşık problemler için yapay sinir ağları yaygın biçimde kullanılmaktadır. Bu tez çalışmasında da yüksek fırında pik demir sıcaklığı yapay sinir ağı ile modellenmiştir.

Tez çalışmasında bugüne kadar yapılmış olan araştırmalar hakkında bilgi verilmiştir. Konunun kaynağı olan yüksek fırın tanıtılmıştır. Ayrıca bir veri madenciliği işlemi yapıldığından veri madenciliğine deyinilmiştir. Tez çalışmamın temel metotları; bulanık mantık ve sinirsel ağlar, hakkında yapılan araştırmalar verilmiştir. Son olarak yapılan modelleme çalışması anlatılmıştır.



# **BLAST FURNACE ANALYSIS AND MODELING WITH ANN**

## **SUMMARY**

Key Words: Blast furnace, Artificial neural networks, Pig iron temperature

Blast furnaces are plants for producing pig iron that is raw material for steel making process. There are some difficulties in mathematical modeling of blast furnace because of its complex internal structure. Today, it is very often to use artificial neural networks for such complex problems. In this thesis, the pig iron temperature in a blast furnace is modeled with artificial neural network.

In the thesis, information about previous researches that's been done until today is given. Blast furnace, that is source of the subject, is described. Also data mining is described briefly due to the usage of data mining in my research. Researches about the base methods of this thesis; fuzzy logic and neural networks, have been presented. Finally study of the modeling has been stated.

## **BÖLÜM 1. GİRİŞ**

Veritabanı teknolojisindeki gelişmeler sayesinde günümüzde şirketler daha önce saklamakta zorlandıkları bir çok veriyi geçmişe yönelik olarak saklamaya başladılar. Son yıllarda da veritabanlarında saklanan bu verilerin arasındaki matematiksel olarak ifade edilmiş veya edilememiş ilişkileri bulmak amacıyla yapay zeka tekniklerinden yapay sinir ağlarının (YSA) kullanımı artan bir ilgili odağı haline gelmiştir. Günümüzde ise yapay sinir ağları finans, bilgisayar, elektronik, ekolojik ve biyolojik çalışmalar da dahil olmak üzere akla gelebilecek hemen her konu üzerine çok geniş bir alanda denenmiş ve kullanılmaktadır [1-5].

Yapay sinir ağları karmaşık endüstriyel proseslerin modellenmesi ve bazı değer tahminlerinin yapılması gibi çalışmalarla endüstriyel uygulamalarda da kullanılmıştır. Çoğunlukla yapay sinir ağları, bir prosesdeki girdi ve çıktı parametreleri arasındaki büyük oranda karmaşık ve lineer olmayan bağlantıları yakalamadaki yetenekleri nedeni ile kullanılmışlardır.

Bu çalışmada yapay sinir ağlarının, demir ve çelik üretiminde en kritik aşamalardan biri olan yüksek fırın prosesinin modellenmesinde kullanılacaktır. Entegre demir çelik tesislerinin en önemli üretim aşamalarından biri olan ve demir üretiminin yapıldığı yüksek fırın prosesi analiz edilerek bir yapay sinir ağı ile modellenmesi çalışılacaktır.

Sıcak madenin (erimiş demirin) sıcaklığı ve kimyasal kompozisyonu yüksek fırının proses değerleri ve durumu hakkında bilgi sağladığı gibi üretilen pik demirin kalitesini de belirlemektedir. Pik demirin kalitesi ise çelik yapılmak üzere götürüldüğü çelikhane için en önemli parametrelerden biridir. Bu nedenle işletme personeli için; kullanılan girdi malzemeleri, yüksek fırının çalışma parametreleri ve daha önce üretilmiş olan pik

demir sıcaklığı ve kimyasal kompozisyonu gibi bilgileri kullanarak pik demir sıcaklığının ve kimyasal kompozisyonunun tahmin edilebilmesi sağlayacak bir model, yüksek fırının güvenli bir biçimde verimli çalışabilmesini, üretim maliyetlerinin aşağıya çekilmesini ve daha sonraki hatlardaki kaliteyi doğrudan etkileyeceğinden dolayı çok fazla getiri sağlayabilecek bir yapı oluşturacaktır. Bu sayede üretilen pik demir hakkında elde edilecek veri ile fırının öngörülmeyen çalışma durumlarını önceden bildireceğinden daha güvenli ve verimli bir çalışma sağlanabilir.

Yüksek fırın prosesi; kok, sinter ve demir cevheri gibi girdilerin karmaşık bir kimyasal reaksiyonu sonucunda çeliğin hammaddesi olan erimiş haldeki demire dönüştürüldüğü bir tesistir. Demir üretimi bir dizi kimyasal ve termal reaksiyon içerdiği gibi kontrol edilmesi zor olan mekanik olaylar da içerir. Bu nedenle bir çok değişkene sahip bir prosestir. Bu karmaşıklığı nedeni ile matematiksel olarak tam anlamda modellenmesinin çok zor olduğu hatta bazı durumlarda imkansız olduğu kanıtlanmıştır. Yıllar boyunca araştırmacıları yaptığı bir çok çalışmaya rağmen girdi ve fırın çalışma parametrelerini kullanarak pik demir kalitesini tespit edebilecek bir yöntem geliştirilememiştir. Sıcak maden üretiminin karmaşık ısı ve kütle transferleri içermesi, kullanılan hammaddelerin lineer olmayan bağlantıları nedeni ile standart istatistiksel tekniklerle ve hatta kütle transferi denklemleriyle bile doğru sonuçlar alınmamaktadır [7]. Bu sebeple bazı araştırmacılar bu modelleme için yapay sinir ağları, bulanık mantık gibi tekniklere yönelmişlerdir. Bugün tüm dünyada bir çok pik demir üreticisi pik demir kalitesi ve fırın verimliliği için uzman sistem, bulanık mantık ve yapay sinir ağı gibi teknikler kullanmaktadır.

Bu amaçla günümüze kadar yapılan bazı çalışmaların incelenme fırsatı bulunmuştur [9, 10, 11, 12]. Bu çalışmanın amacı, incelenen çalışmalar ışığında, bir ileri beslemeli yapay sinir ağı ile öncelikli olarak pik demir sıcaklığı modellenmeye çalışılacaktır.

## 1.1. Mevcut Modelleme Çalışmaları

Çelik üretimi, bir çok farklı tesiste bir çok farklı süreci kapsar. Hammadde olarak kullanılan sinter ve kok üretimi göz ardı edilirse, bu süreçlerden ilki çelikhane hammaddesi olarak kullanılan pik demirin üretimidir. Günümüzde yeni yeni teknolojiler geliştirilmeye çalışılsa da, pik demir üretiminin madenlerden en ekonomik ve hızlı bir biçimde elde edilmesinin yolu yüksek fırınlardır. Yüksek fırın genel yapısı ve işleyiş süreci ikinci bölümde anlatılacaktır.

Yüksek fırından elde edilen pik demirin üretimin artması ve sonraki tesisler için kalitesinin önemli olması ve bunun kontrol edilebilmesi nedeni ile fırında bazı tekniklerin kullanılması ihtiyacı ortaya çıkmıştır. Üretilen pik demirin kalitesinin artırılmasındaki ana adım, üretilen pik demirdeki silisyum içerik değişkenliğinin ayarlanabilmesidir. Bunu fırın içerisindeki ısı seviyeleri kontrol etmektedir. Fırın içerisindeki sıcaklık yüksek ise, pik demirin yapısındaki silisyum miktarı artarken, düşük ise azalmaktadır. Bu nedenle bazı araştırmacılar pik demir sıcaklığını fırının durumunu ve ürün olan pik demirdeki silisyum miktarı anlamak için bir gösterge olarak kullanmışlardır [6, 7]. Bunun yanında yine buna paralel olarak pik demir içeriğindeki karbon miktarı ve bir yan ürün olan yüksek fırın curufunun bazitesi de fırın çalışması hakkında işletme mühendislerine bilgi sağlayan önemli değişkenlerdir.

Bu kontrol işlemleri için genel olarak uzman sistemler kullanılmaktadır. Kayma, askı gibi fırında oluşan dengesizliklerin kestirimde yardımcı araç olarak kullanıldıkları gibi, esas olarak fırın iç sıcaklığı ve pik demir sıcaklığının kontrolü amacıyla kullanılırlar.

### 1.1.1. Matematiksel modelleme çalışmaları

Yüksek fırın üretim sürecinin modellenebilmesi için bir çok çalışmalar yapılmıştır. Ancak, çok sayıda gaz-katı, katı-katı, katı-sıvı tepkimeleri, yanma işlemleri, kütle hareket evreleri ile birleşen ısı ve kütle transfer olaylarının karmaşıklığı, yüksek fırının modellenmesini aşırı derece zor bir probleme dönüştürmektedir [10]. Kimya ve metalürji

mühendisleri, bu süreci kimya tabanlı deterministik model ve eşitlikler oluşturarak göstermeye sürekli olarak çalışmışlardır. Ancak kestirim ve kontrol için kullanıldıklarında küçük başarılar sağlamış olan bu eşitlikler, karmaşık termodinamik ve kütle transfer ilişkileri içerir [13-16].

Peacay ve Davenport [17], yüksek fırının kapsamlı bir ısı ve kütle dengesi kararlı durum modeli önermişlerdir. Modelleri verilen bir pik demir üretim oranı için gerekli olan hammadde oranlarının belirlenmesinde kullanılabilir. Bunun yanında pik demir ve curuf sıcaklıkları, çıkış gaz oranı ve analizi ve curuf üretimi de hesaplanabilir. Ancak model pik demir ve curuf kompozisyonunu hesaplayamamaktadır [10].

Ufret ve Williams modellerinde, ısı dengesi, kütle dengesi ve kinetik veriyi pik demir - curuf sistemindeki faz dengesi için gözlemsel bağlantılar ile birleştirmişlerdir. 10 durum değişkeni içeren modelleri ile fırın gövde, karın, hazne ve pik demir havuzu olmak üzere dört parçaya bölünmüştür. Model, farklı bileşenlerin etkinlik katsayılarını, kinetik parametreleri ve faz çözünürlüğünün sıcaklığa bağımlılığını tanımlamak için gözlemsel ilişkileri kullanır. Bu eşitlikler karmaşık doğrusal olmayan ilişkilerdir. Türevsel sonuç kümesi ve cebirsel eşitlikler sayısal olarak çözülür. Modelleri hammadde ve hava gereksinimi ile pik demirdeki silisyum ve kükürt konsantrasyonlarını hesaplayabilmektedir. Ancak pik demir ve curuf üretim miktarları ve curuf bazitesi gibi farklı diğer değişkenleri kestirememektedir [10].

Biswas, pik demir sıcaklığı ve silisyum içeriği gibi değişkenlerin doğru olarak kestiriminin ve kontrolünün yalnızca alan seviyesindeki modellerle yapılmasının aşırı derecede zor olduğunu belirtmiştir [16, 18].

Torsell ve arkadaşlarının fırının matematiksel olarak modellenmesi çalışmaları, fırın içerisinde olduğu varsayılan kütle transfer eşitliklerinin simülasyonuna dayanır. Sonuçta oluşan model sıcak hava sıcaklığı, oksijen zenginleştirilmesi, kömür enjeksiyonu gibi değişkenleri kullanmaktaydı. Her ne kadar iyi sonuçlar elde edilmiş olsa da, sonuçlar fırın parametrelerinin simülasyon ve kimyasal eşitlikleri tek başına kullanarak

kestirilemeyeceğini göstermektedir [14, 15]. Singh ve arkadaşları, pik demir sıcaklığı ile çok yakından ilgili bir değişken olan pik demirin içerisindeki silisyumu kestiren geleneksel modelleri inceleyerek bu sonucu onaylamışlardır. Singh'e göre bu geleneksel modeller, istenen doğruluk oranında silisyum içeriğinin kestirilmesi için yeterli değildir [16, 19].

Ullmann, modelleme sürecinde, farklı girdi malzemeleri arasındaki etkileşim etkilerini, yüksek fırının çalışma bölgelerindeki gelişigüzel değişimleri gibi diğer bazı belirsizliklerin varlığını açıklamıştır [20]. Bu nedenle yukarıda bahsedilen çalışmalar, yüksek fırın çalışmasındaki farklı parametrelerin güvenilir biçimde kestirimi ve kontrolünün, deterministik kimyasal eşitliklerin yalnız başına kullanılması ile elde edilemeyeceği sonucuna varmıştır [16].

### **1.1.2. Modelleme çalışmalarında yapay sinir ağı kullanımı**

Bugüne kadar yapay sinir ağları demir çelik üretiminin yüksek fırın, çelikhane, sıcak haddehane gibi çeşitli işlemlerin gerçekleştiği tesislerde kullanılmıştır. Bunun nedeni, öncelikle yapay sinir ağlarının değişkenler arasındaki yüksek oranda doğrusal olmayan ilişkilerin modelleyebilmesidir. Geleneksel teknikler genellikle doğrusal giriş-çıkış eşlemesi ile sınırlı iken sinirsel ağlar daha karmaşık ilişkileri bulabilme yeteneklerinin olduğu gösterilmiştir. Bunun yanında sinirsel ağların kullanımı model gelişim süresini oldukça kısaltmaktadır. Ayrıca sinirsel ağların işletme koşullarında oluşan değişimlere göre ayarlanabilmesinin çok çabuk olması da önemli bir faktördür [16].

Çalışmaya konu olan yüksek fırınlar göz önünde bulundurulursa, bugüne kadar bazı yapay sinir ağı uygulamaları, yüksek fırınlarda ki bazı problemlerin çözümünü için kullanılmaya çalışılmıştır.

Bhattacharjee ve arkadaşları, Hindistan'da üretimde olan bir yüksek fırının ürettiği pik demirin, pik demir sıcaklığını da içeren bazı kalite parametrelerini kestirmek için ileri beslemeli sinirsel ağlar kullanmışlardır. 24 giriş parametresi ile başladıkları

çalışmalarında, giriş değerlerinin pik demir sıcaklığındaki etkisine göre azaltarak parametre sayısını 15'e düşürmüşlerdir. Sonuçlar, geri yayılım öğrenmesi uygulanan tek gizli katmanlı çok katmanlı perseptronların günlük pik demir sıcaklığındaki eğilimleri kestirebildiğini göstermiştir [16, 21].

Ayrıca aynı demir çelik tesisinde, sinirsel ağlar, bir oksijen tesisindeki yüksek saflıkta oksijen, azot ve argon üretirken atık olarak düşük saflıkta azot üreten hava ayrıştırma ünitesinin kimyasal modellenmesinde de kullanılmıştır [22]. Üç girişli, tek gizli katmanlı olan, farklı durumlarda üretilen gaz durumundaki oksijeni kestirmek için geliştirilen modelin ilk sonuçları oldukça tatminkardır.

Nikus ve arkadaşları, Finlandiya'daki Koverhar yüksek fırınında, sinirsel ağları yüksek fırının termal durumunu kestirmek için kullanmışlardır [23]. Dakikada bir ölçülen veri analiz edilmiş ve 1-20 dakika ilerisi içinde değişen bir kestirim yapılmıştır. Tek gizli katmanlı ağ seçilmiş ve yedi girişli beş gizli nöronlu ağ yapısı en iyi sonucu vermiştir. İlaveten, kestirilen değerler geciktirilerek ilave giriş olarak ağ girişine verilmiştir [16].

İsveç'te yapılan bir çalışmada yüksek fırın üretim sürecinin modellenmesinde sinirsel ağlar kullanıştır. Bu çalışmadaki fark ise, pik demir silisyum içerik kestiriminin iki saat ilerisi için yapılabilmesi amacıyla, geri yayılım kullanan çok katmanlı perseptron ile kendini düzenleyen ağların (self-organizing networks) birleştirilerek kullanılmasıdır. Ancak, sık bir durum olan yüksek fırındaki işletme koşullarının değişmesi, ileriki birkaç saat için silisyum içeriğinin kestirilmesinde farklı bir statik ağ gerektirecektir. Bu yüzden, kendini düzenleyen ağlar, fırının çalışma durumun belirlemek amacıyla kullanılmış ve bu yolla her durum için farklı çok katmanlı perseptronlar eğitilmiştir. Kendini düzenleyen ağların ve çok katmanlı perseptronların birleştirilerek kullanılması, fırının çalışma şartlarına göre değişen melez dinamik bir ağ yapısı oluşturmuştur. Sıcak madendeki silisyum içeriği pik demir sıcaklığı ile ilişkili olduğundan, burada yapay sinir ağları kullanarak silisyum içeriğinin kestirilmesinde elde edilmiş olan başarılı sonuçlar, pik demir sıcaklığının kestirimi için de yapay sinir ağlarının kullanılabileceğini göstermiştir [16, 24].

İngiliz demir çelik üreticisi British Steel arařtırmacıları, beř ayrı yüksek fırını kontrol etmek amacıyla sinirsel ađları kullanmıřlardır. Özellikle, farklı fırınlarda kullanılan bu yapay sinir ađları, hammadde dađılımının kontrolünde bir araç olarak kullanılmıřtır. Buna ek olarak, üretilen pik demir kalitesinin tahmin edilebilmesi için sinirsel ađ modelleri geliřtirilmiřtir. Belirgin olarak, pik demir sıcaklıđı ve silisyum içeriđinin kestirilmesi için dođrudan bađlantılı modeller kurulmuřtur. Modeller oluřturulmadan önce, ilk olarak farklı giriřlerin zaman bađımlılıđının ayrı bir istatistiksel analizi yapılmıřtır [16, 25].

Bulsari ve arkadaşları, yüksek fırında üretilen pik demirin silisyum içeriđinin kestirilmesinde çok katmanlı ileri beslemeli sinirsel ađların kullanılmasında oldukça iyi sonuçlar elde etmiřlerdir. Bir ve iki gizli katmanlı ileri beslemeli ađlar eđitilmiř ve sinirsel ađın ađrılıkları geleneksel geri yayılım öđrenme algoritmasının dođrusal olmayan bir türevi kullanarak güncellenmiřtir. Bu yöntem Levenberg-Marquardt eđitme yöntemidir [26]. Yapılan bu çalıřma sonucunda ileri beslemeli yapay sinir ađlarının standart dođrusal zaman serileri ile kestirimden daha iyi sonuçlar verdiđi görülmüřtür [16].

Bulsari ve Saxen, sinirsel ađları yüksek fırındaki sonda sıcaklıklarının sınıflandırılması için tekrar kullanmıřlardır. Genellikle yüksek fırın operatörleri, fırın gövdesi içindeki gaz dađılımı hakkında pratik bilgiye ihtiyaç duyarlar. Bu bilgi, ergime bölgesinin durumu ve fırına gönderilen malzemenin akıřı ve dađılımı ile ilgili verilen kararlarda kullanılır. Geleneksel olarak operatörler bu tür kararları, fırın içerisine yatay biçimde yerleřtirilmiř sondalardan elde edilen sıcaklık ölçümlerine ve geçmiř tecrübelerine dayanarak vermektedir. Bulsari ve Saxen'in çalıřması ile bu sonda ölçümlerini kullanarak fırın içerisindeki gaz dađılımını sınıflandırabilen bir uzman sistem oluřturulmuřtur. Bu sınıflandırmayı sađlamak için çıkıř ve gizli katmanında sigmoid transfer fonksiyonu kullanılan ileri beslemeli sinirsel ađlar kullanılmıřtır. En iyi performansı tek gizli katmanlı ađ yapısı elde etmiřtir. Ayrıca Bulsari ve Saxen, çok az gizli nöronlu ađların gerekli iliřkileri dođru olarak yakalayamazken büyük ađların 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 [16, 27]

Zuo ve arkadaşları ileri beslemeli sinirsel ağlarını, işlemsel verilere bağlı olarak yüksek fırın düzensizliklerini kestirmek için kullanmışlardır. Fırındaki farklı tepe gazı dağılım profillerini sınıflandırmak, farklı ısı akış dağılımlarını tespit etmek, kaymaları ya da anormallikleri kestirmek için ayrı ayrı ağlar eğitilmiştir. Makalede, bahsedilen sınıflandırma ve kestirim işlerini yapan ve fırında tehlikeli bir durum oluştuğunda operatöre alarm oluşturan bir sinirsel ağ tabanlı denetleme sistemi sunulmuştur. Kayma kestirimi için ileri beslemeli ağlar kullanılırken, sınıflandırma için SOFM (Self-Organizing Feature Maps) ve LVQ (Learning Vector Quantizers) kullanılmıştır. Sonuçlar, bir kez daha sinirsel ağların yüksek fırınlar için kestirim sağlayabildiğini göstermiştir [16, 28].

Jimenez ve arkadaşlarının pik demir sıcaklığını kestirmek için yaptığı çalışmada da benzer şekilde iyi sonuçlar elde edilmiştir. Çalışmalarında sinirsel ağ modelini NARX modeline göre yapmışlar ancak sonra da aynı yapıyı kullanarak NOE modelini de uygulamışlardır. Sonuç olarak geliştirilen modellerin pik demir sıcaklığının ölçülmesinde başarılı olduğunu, NARX modelinin yüksek fırın kontrol sistemleri için daha uygun olduğunu, modelin bir önceki çıkışlardan bağımsız olduğu NOE modelinin ise simülasyona olanak sağladığını vurgulamışlardır [29].


## **BÖLÜM 2. YÜKSEK FIRIN**

### **2.1. Giriş**

Günümüzde tüketim oranının yüksekliği bir kalkınmışlık göstergesi olarak gösterilen çelik, ana birleşeni demir olmak üzere, çeliğin kalitesine göre %0.02 ile %1.7 arasında değişen oranda karbon içeren bir metal alaşımıdır. Çeliğin yapısındaki karbonun görevi alaşımı sertleştirmek ve demir atomlarının kaymasını engellemektir. Alaşımdaki karbon miktarı ile oynanarak çeliğin sertliği, esnekliği ve gerilme gücü değiştirilebilir. Demir-karbon alaşımının çelik olarak kabul edilebilmesi için tipik olarak en çok %2.1 oranında karbon içermesi gerekmektedir [30].

Uluslararası Demir ve Çelik Enstitüsü'nün verilerine göre ham çelik üreten 99 ülkedeki üretim miktarı 2006 yılında 2005 yılına oranla %8.8'lik bir artışla 1239.4 milyon ton olarak gerçekleşmiştir. Batı Avrupa'da Avrupa Birliği dışında ki en büyük çelik üreticisi konumunda olan Türkiye'de ise 2006 yılı üretimi %11.2'lik bir artışla 23.3 milyon ton olarak gerçekleşmiş ve bu üretim Türkiye'nin dünyada çelik üreten ülkeler arasında Tayvan ve Fransa'yı geçerek 11. sırada yer almasını sağlamıştır [31].

Çelik üretim prosesi şekil 2.1'de verilmiştir. Sinter fabrikasından çıkan sinter ve kok fabrikasından gelen kok ile madenlerden sağlanan demir cevheri yüksek fırınlarda pik demir haline getirilmekte, daha sonra bu maden genellikle torpidolar ile çelikhaneye götürülüp önce oksijen fırınında oksijen ile işleme tabi tutulmaktadır. Daha sonra ise ikincil metalürjik işlemler için ilgili tesislerde işlem gördükten sonra, sürekli döküm tesislerinde yassı ve/veya çubuk mamul haline getirilmektedir.



Şekil 2.1. Çelik üretim prosesi [32]

Günümüzde her ne kadar çeliğin hammaddesi olan demir üretimi ve çelik üretimi “demir ve çelik endüstrisi” tek isim altında kullanılsa da, geçmişte bu iki sektör birbirinden ayrı isimlere sahiptiler [30].

Demir üretiminin Avrupa’da milattan önce 1700’lü yıllara kadar uzanan bir tarihi vardır. Demirin üretim şekli Hititlerden Orta Çağ sonlarına kadar hiçbir değişikliğe uğramamıştır. Demir cevherinin odun veya odun kömürü ile erimiş demir cevherini elde


edinceye kadar ısıtılması ile başlayan işlem, daha sonra erimiş cevherin sıcak halde çekiç ile dövülerek ilave elementlerden kurtulması sağlanmaya çalışılır ve sonrada elde edilen ham cevher demirhanelerde işlenmek üzere hazır hale getirilirdi. Çin’de milattan önce birinci yüzyılda ve Avrupa’da 1150-1350 yıllarında, ilk olarak İskandinavya’da (bugünkü İsveç) bulunmasına rağmen ilk resmi kayıtları 14. yy. İngiltere [33] olarak görülen yüksek fırınlar, modern demir üretiminin önemli bir parçası olarak kalmıştır. 1709 yılındaki odun kömürü yerine kok kullanılması ve İskoçya’da 1828 yılında sıcak hava üflenmesi yüksek fırın teknolojisini geliştirmiştir. 18. yüzyılda yıllık 400 ton olan üretim miktarları sanayideki rekabetin sonucunda, bugün haftalık üretimi 60000 ton olan büyük fırınlara ulaşılmıştır [34].

Günümüzde pik üretimi entegre demir çelik tesislerinde yüksek fırınlarda, daha küçük kapsamlı tesislerde ise elektrik ark ocaklarında yapılmaktadır. 2006 yılında yaklaşık olarak 750 milyon ton pik demir üretilmiş, üretilen bu pik demirin %60’ı yüksek fırınlarda üretilmiştir. Geri kalan kısım ise elektik ark ocaklarında hurdadan eritilerek elde edilmiştir [31]. Demir cevherinden kok kullanmadan pik demir üretiminde COREX ve FINEX ve pelet ve demir cevherini doğal gaz esaslı fırınlarda prosesi sonucu elde edilen doğrudan indirgenmiş demir elde edilebilen MIDREX gibi teknolojiler de mevcuttur [35].

Bugün yüksek fırınlar insanoğlunun en yararlı araçlarından biridir. Yüksek fırın demir kökenli araçlar için gerekli olan hammaddeyi cevherden hızlı ve verimli bir biçimde elde etmeyi sağlarken bir yanda da çelik üretiminin temelini oluşturur. Yüksek fırınlar bir ülke ekonomisindeki kayda değer faktörlerden biridir [17].

## 2.2. Yüksek Fırının Genel Yapısı

Cevherden demiri indirgemek için genelde kok yapısında karbon kullanan fırın büyük, düşey ve silindirik bir yapıya sahiptir [17]. Üretilen ürün, çeliğe dönüştürülmek için uygun olan pik demirdir (%4-5 Karbon (*C*), %0.5-1 Silisyum (*Si*)). Tipik bir yüksek fırın tesis şeması şekil 2.3’de ve detaylı bir yüksek fırın profili şekil 2.2’de verilmiştir.




Şekil 2.2. Bir yüksek fırının düşey ve yardımcı sistemleri [35]

Dış gövdesinin, bulunduğu bölgeye göre kalınlıkları değişen çelik sacdan (gövde sacı) oluşan bir kaplaması vardır. Gövde sacının iç yüzeyi reaksiyonlar sonucu oluşacak ısı miktarlarına göre değişen, çeşitli kalitelerde ısıya dayanıklı karbon tuğlalar ile örülmüştür. Bu sayede fırın içerisindeki reaksiyonlar sonucunda oluşan ısıның gövde sacına zarar vermesi engellenirken, oluşan yüksek ısıның fırın dışına çıkması engellenmiş olmaktadır.

Yüksek fırın, boğaz (throat), gövde (stack), bel (belly), karın (bosh) ve hazne (hearth) kısımları olma üzere beş kısımdan oluşmaktadır.

Yüksek fırının temel işlevi, belirli ve sabit bir kompozisyonda ki erimiş demiri yüksek orandaki verimlilikle üretmektir. En kritik işletme parametresi, demir ve curufun fırın döküm deliğinden erimiş halde alınabilmesi için demir ve curufun sıcaklığıdır ki bu



Şekil 2.3. Bir yüksek fırın tesisinin hammadde, şarj, dökümhane, gaz işleme ve sıcak hava sistemlerini gösteren kesiti [17]

sıcaklık 1700 Kelvin'den daha yüksek olmalıdır. Üretilen pik demir çoğunlukla yeniden işlenip çeliğe dönüştürüleceğinden pik demir kompozisyonu yüksek fırın prosesi için kritik sayılabilecek parametre değildir. Fakat bu kompozisyon çelikhane şartlarına göre uygun curuf kompozisyonu ve fırın sıcaklığı ile kontrol altında tutulmaktadır [17].

### 2.3. Hammaddeler

Bir yüksek fırın için hammaddeler, fırının üstünden şarj edilen katılar (cevher, kok, akışkanlık sağlayan maddeler) ve fırın tabanına yakın tüyerlerden üflenen hava olarak sayılabilir. Hidrokarbon katkıları (gaz, sıvı veya katı) ve oksijende yine tüyerlerden gönderilmektedir.

#### 2.3.1. Demir oksitleri

Genellikle hematit ( $Fe_2O_3$ ), zaman zaman magnetit ( $Fe_3O_4$ ). Modern işletmelerde demir oksitleri, sinter üretiminde kullanılmayan 0.05 milimetreden daha küçük cevher tozlarının işlenmesi ile elde edilen, %5-10  $SiO_2$  ve  $Al_2O_3$  ve geriye kalan kısmının %100'üne yakın kısmı  $Fe_2O_3$  olan 1-2 santimetre çapında pelet; cevher parçacıklarının işlenmesi ile elde edilen 1-3 santimetre büyüklüğünde sinter ve 1-5 santimetre büyüklüğündeki cevher yapılarında kullanılmaktadır. Zaman zaman az miktarlarda da olsa çelikhane curufu ve hurdadan da demir bileşeni olarak yararlanılmaktadır.

#### 2.3.2. Metalürjik kok

Yapısında %90 oranında karbon, %0.5-1 arasında kükürt ve %5-10 arasında rutubet içerir ve kül oranı %10-12 arasındadır. Cevherin indirgenmesi ve erimesi için gerekli olan gaz ve ısının büyük kısmını sağlar. Metalürjik kok çeşitli kalitelere sahip kömür harmanlarının havasız bir ortamda ısıtılması ile elde edilir. Bu, kömürdeki uçucuların damıtılarak yüksek sıcaklıklarda tepkime veren ve parçalanmadan fırının alt bölgelerine kadar inebilen gözenekli kok yapısı oluşmasını sağlar. Kok parçalarının fırın tabanına

kadar parçalanmadan inmesi, fırının alt bölgelerinde yumuşayan ve eriyen malzemelerin içinden düzenli bir gaz akışının sağlanabilmesi için ihtiyaç duyulan kok parçaları için çok önemli bir özelliktir. Kok, fırına 2-8 santimetre büyüklüğünde parçalar halinde gönderilir.

### 2.3.3. Curuf yapıcılar (CaO ve MgO)

Bu maddeler kok ve cevherdeki silisyum oksit ( $SiO_2$ ) ve alüminyum oksit ( $Al_2O_3$ ) bileşenlerine akışkanlık kazandırarak akışkan curufu oluşturur ve yaklaşık 1600 Kelvin olan düşük bir erime noktası oluşmasını sağlar.  $CaO$  ikinci bir fayda olarak, büyük oranda kok ile fırına şarj edilen kükürdün pik demirden daha ziyade curuf içerisinde fırından çıkmasını sağlar. Bu bileşenler sinter ile veya 2-5 santimetre büyüklüğünde parçalar halinde kireçtaşı ( $CaCO_3$ ) ve dolomit ( $CaCO_3$  ve  $MgCO_3$ ); nadiren de çelikhane curufu olarak fırına şarj edilir.

### 2.3.4. Sıcak hava

1200 – 1600 Kelvin arası ısıtılmış ve genellikle %25 oksijen oranında olacak biçimde oksijen ile zenginleştirilmiş havadır. Sıcak hava akkor kok (yaklaşık 1800 Kelvin) ile tüyerler önünde yanar, indirgenme reaksiyonları, şarj edilen malzemenin ısıtılması ve eritilmesi, erimiş pikin sıcaklığının korunması için gerekli ısıyı sağlar. Yüksek sıcak hava sıcaklığı pik demir ve curuf sıcaklıklarının erime sıcaklıklarından yeteri kadar yukarıda olmasını garanti eder.

### 2.3.5. Gaz, sıvı veya katı hidrokarbonlar

İndirgenme prosesi için gerekli olan indirgeme gazlarının ( $CO$  ve  $H_2$ ) miktarlarının artmasını sağlar. Akaryakıt, katran, doğal gaz ve tozlaştırılmış kömür kullanılan malzemeler arasındadır [17, 18].



## 2.4. Ürünler

Yüksek fırının ana ürünü, fırın hazne bölümünün altında yer alan bir veya birkaç döküm deliğinin birinden düzenli aralıklarla (çok büyük fırınlarda sürekli) alınan erimiş pik demirdir. Erimiş pik demirin tipik bir analiz örneği tablo 2.1’de verilmiştir.

Tablo 2.1. Genelleştirilmiş erimiş pik analizi

Element	Kompozisyon (%)	Element	Kompozisyon (%)
C	4-5	P	0.1-1 (cevhere bağlı)
Si	0.3-1	Mn	0.1-1 (cevhere bağlı)
S	0.03-0.1	Erime Noktası	1400 Kelvin

Bir yüksek fırındaki pik demirin kompozisyonu, üretilen demirin gönderileceği çelikhane tesisinin gereksinimlerini karşılamak üzere seçilir ve curuf kompozisyonu ve genellikle fırının alt yarısındaki fırın ısının ayarlanması ile kontrol edilir.

Pik demir erimiş bir halde genellikle torpidolar aracılığı ile çelikhaneye gönderilir ve burada oksijen ile artırılarak çelik içinde istenmeyen elementlerin çok düşük seviyelere indirilmesi sağlanır. Bazı durumlarda erimiş pik demir çelikhane işleme alınmadan önce  $CaC_2$  (kalsiyum karbür, karpit) veya magnezyum koku ile desülfürizasyon işlemine tabi tutulur.

Curuf ve yüksek fırın gazı ise diğer iki yüksek fırın ürünüdür. Genel bir curuf kimyasal kompozisyonu tablo 2.2’de verilmiştir.

Tablo 2.2. Genelleştirilmiş curuf analizi

Element	Kompozisyon (%)	Element	Kompozisyon (%)
$SiO_2$	30-40	$MgO$	5-15
$Al_2O_3$	5-15	$Na_2O + K_2O$	0-1
$CaO$	35-45	$S$	1-2,5

Curuf , fırının mükemmel indirgeme verimliliğinin bir göstergesi olarak içerisinde çok küçük bir oranda demir oksit içerir. Curuf kimyasal kompozisyonu;

- $SiO_2$  ve  $Al_2O_3$  'ün akışkan curuf içerisinde atılması,
- olmaması halinde fırın duvarlarına yapışarak fırın hacmini düşüren ve gaz akışı düzenine bozarak çalışmasını zorlaştıran alkalilerin ( $Na_2O$  ve  $K_2O$ ) soğurulmasını,
- kükürdün demir içerisinde erimesinin yerine soğurulmasını,
- metalin silisyum içeriğinin kontrolünü

sağlayacak biçimde seçilir. Curuf kimyasal özelliklerinin bir ifadesi olarak curuf bazitesi kullanılır. Curuf bazitesi oranı 2.1 ile verilen eşitlikteki gibi ifade edilir.

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

Yüksek fırın gazı ise fırın üstündeki gaz toplama sistemi tarafından fırından çıkar. Genel bir yüksek fırın gaz kompozisyonu tablo 2.3'de verilmiştir. Bu gaz yaklaşık olarak doğal gazın onda biri oranında yanma enerjisine ( $4000 \text{ kJ} / \text{Nm}^3$ ) sahiptir. Gaz temizleme sisteminden geçerek içerisindeki tozu alınan gaz, fırın yardımcı sistemlerinden sobalarda yakılarak fırına gönderilecek olan havanın ısıtılmasında kullanılır.

Tablo 2.3. Genelleştirilmiş yüksek fırın gazı analizi

Element	Kompozisyon (%)	Element	Kompozisyon (%)
$CO$	23	$H_2O$	3
$CO_2$	22	$N_2$	49
$H_2$	3		

Ayrıştırılan toz ise sinter prosesi ile bir araya getirilerek tekrar fırına şarj edilir veya ilerde kullanılmak üzere depolanır [17, 18].

## 2.5. Yüksek Fırın Yardımcı Sistemleri

Yüksek fırın yardımcı sistemleri, fırının çalıştırılabilmesi için gerekli olan malzemelerin fırına şarj edilmesi, havanın ısıtılması, pik demir ve curufun alınması gibi işlemlerin gerçekleştirildiği sistemlerdir.

### 2.5.1. Hammadde besleme sistemi

Yüksek fırına yukarıdan şarj edilen malzemelerin fırın üstüne çıkartılmasını sağlayan sistemdir. Hammaddelerin depolandığı silolar, yürüyen bantlar, tartı hazneleri ve kovalardan oluşur. Silolar, depolanacak malzeme cinsine ve fırın üretim kapasitesine göre farklılıklar gösterebilir. Önceki tesislerden bantlar vasıtasıyla silolara gelen hammaddeler aynı zamanda bir elek vazifesi gören besleyicilerle malzemeyi tartı haznelerine ulaştırır. Fırına gönderilecek malzeme miktarları fırının çalışması için çok önemli olduğundan hassasiyetleri sürekli kontrol altında tutulan tartı hazneleri ile tartılarak gerekli oranlarda bantlar ile kovalara aktarılır. Kovalar içlerindeki malzemeyi fırın üstüne çıkartan ekipmanlardır. Kovalar, mevcut 2 kovanın biri altta bantlardan malzeme alırken, diğeri fırın üstünde içerisindeki malzemeyi boşaltacak şekilde paralel olarak çalışır. Bazı büyük fırınlarda kovalı sistemler yerine tartım haznelerinden sonra fırın üstüne kadar yürüyen bant sistemleri mevcuttur.

### 2.5.2. Fırın üstü şarj sistemi

Hammadde besleme sistemi tarafından fırın üstüne çıkarılan malzemeyi fırına şarj etmede kullanılan sistemdir. Önceleri malzeme, büyük çan ve küçük çan ile adlandırılan ve bunların senkronize olarak çalışmasından oluşan “Çan Sistemi” adı verilen sistem ile fırına şarj edilirdi. Günümüzde ise çansız tepe ekipmanı olarak adlandırılan bir sistem ile şarj edilmektedir. Bu sistemde, fırın üstünde iki malzeme silosu bulunmakta ve bu silolara gelen malzemeler gerekli olan adımlardan (basınç eşitlemeleri gibi) sonra siloların altında bulunan kapak ile fırın içerisindeki açısı ayarlanabilir döner bir oluğa aktarılmaktadır. Malzemenin şarj edileceği yerlere göre döner oluk açısı ayarlanarak malzeme fırına şarj edilmektedir.

### 2.5.3. Sobalar

Sobalar, fırına kokun yanmasını sağlamak için gönderilen sıcak havanın ısıtıldığı sistemlerdir. Çalışma prensibine göre bir fırında üç veya dört tane bulunur. Her bir soba yanma ve ısınma hücresi olmak üzere iki bölümden oluşur. Bir sobanın ısınma devresi ve fırın devresi olmak üzere iki durumu vardır. Isınma devresinde yüksek fırın gazı gerek görülürse kok gazı, doğal gaz veya çelikhane gazlarından oluşan gaz karışımı, belirli bir sıcaklığa kadar ısıtılmış yeterli hava ile birlikte yanma hücresinde yakılır. Oluşan ısıdan ısınma hücresini tamamen kaplayan delikli tuğlalar ısınır. Atık gaz ise bacadan dışarıya atılır. Fırın devresinde ise fırına gönderilecek hava ısınma hücresinden geçirilerek tuğlalarda hapsedilmiş olan ısıyı alması sağlanır. Fırın devresinden çıkan soba soğuyacağına tekrar ısınma devresine girerek ısıtılır. Genelde sobaların biri fırın devresinde iken diğerleri ısınma devresindedir. Fırın aynı anda tek bir sobanın fırın devresinde olduğu seri ve fırın devresinde aynı anda iki sobanın olduğu paralel olmak üzere iki ayrı çalışma şekli vardır.

#### **2.5.4. Hidrokarbon ilavesi sađlayan sistemler**

Önceleri yüksek maliyeti olan kok tüketimini azaltıcı, fırın çalışma şartlarını düzenleyici fuel-oil, katran gibi sıvı olarak yapılmaktaydı. Ancak 1979 yılındaki petrol krizinden kaynaklanan maliyet artışları nedeni ile terk edildi. Ancak bu fırın çalışma şartlarında ve maliyetlerinde önemli olumsuz sonuçlar doğurdu. Bu nedenle şirketler tozlaştırılmış kömür enjeksiyonuna yönelmiş ve bu sistemi kullanan fırın sayısı artmıştır. Günümüzde ise fuel-oil, doğal gaz ve tozlaştırılmış kömür şeklinde yapılmaktadır. Kömür enjeksiyonu için; kömür enjeksiyon tesislerinde 75 mikron ve daha küçük parçacıklar haline getirilen kömür, yüksek fırın gazı, yüksek fırın soba bacası atık gazı, kok gazı ve/veya doğal gaz ile kurutulur. Daha sonra ise kömür enjeksiyon sistemi ile fırınlara sıcak havanın sađlandığı tüyerlerden fırına gönderilir.

#### **2.5.5. Dökümhane**

Üretilen pik demir ve curufun yüksek fırından alındığı yerlerdir. En az bir olan sayıları yüksek fırın üretim kapasitelerine göre dörde kadar çıkabilir. Pik ve curuf tahliyesi için kullanılan döküm ve curuf delikleri fırın haznesinin alt kısmında bulunur. Curuf delikleri ihtiyaç halinde açılırken pik delikleri düzenli olarak açılır. Genelde pik deliklerinden pik ve curufun tahliyesi sađlandığından bu deliklere döküm deliđi de denir. Döküm açma matkabı ile döküm deliđinin açılması ile sađlanan tahliyeden sonra döküm kapatma çamur topu ile bu deliđe özel bir çamur enjekte edilerek döküm deliđi kapatılır. Tahliye sırasında pik demir aşınmaya dayanıklı bir kanal ile çelikhaneye nakli için gereken torpidolara ulaşır. Curuf ise curuf kanalı ile curuf sahasında biriktirilir. Bazı fırınlarda curuf potalar ile taşınır.

#### **2.5.6. Sođutma sistemleri**

Yüksek fırındaki reaksiyonlar sonucu fırın içindeki sıcaklık bazı bölgelerde 2200 °C dereceye kadar çıkmaktadır. Fırın üstü şarj sisteminin maruz kaldığı sıcaklık ise 150-200

$^{\circ}\text{C}$  derecedir. Bu nedenle fırının bir soğutma sistemine ihtiyacı vardır. Fırın içerisinde oluşan sıcaklığın gövde sacına zarar vermemesi için fırın iç cephesi karbon,  $\text{SiC}$  (silisyum karbür), grafit  $\text{Al}_2\text{O}_3$  esaslı olmak üzere değişen çeşitli kalitelere ateşe dayanıklı tuğlalar ile örülmüştür. Bu tuğların ömrünü artırmak ve soğutmak, dolayısıyla fırının ömrünü artırmak için, bakırdan imal edilen plaka ve/veya pikten imal edilen panel soğutucular kullanılır. Soğutmada kullanılan su, kanallı yapıya sahip bu soğutucuların bir bölgesinden girerek tüm soğutucuyu dolaşır ve çıkar. Fırın gövdesindeki sıcak hava girişleri olan tüyerler, ısıdan etkilenmemeleri için bakırdan üretilir ve su ile soğutulur.

## 2.6. Üretim Süreci

Yüksek fırının çalışma süreci, hammaddelerin fırın üstünden düzenli aralıklarla şarj edilmesini, üretilen erimiş ürünlerin dökümhaneden sürekli veya düzenli aralıklarla alınmasını, sıcak hava ve yardımcı hidrokarbonların sürekli olarak üflenmesini ve gaz ve tozun sürekli olarak alınmasını kapsar.

Hammadde şarjı, sıcak hava üflenmesi, hidrokarbon enjeksiyonu gibi adımların bir çoğu otomatik kontrol altında mekanik olarak gerçekleştirilmektedir. Modern yüksek fırınlar sürekli gözlem sistemleri ile geniş ölçüde donatılmıştır. Tipik olarak sürekli gözlenen süreç değişkenleri;

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

olarak sayılabilir. Bunlara ilaveten pik demir ve curuf sıcaklıkları ve kimyasal kompozisyonları döküm sırasında aralıklı olarak ölçülmektedir. Teknolojik gelişmeler sayesinde bu noktaların sayıları ve geçmişe yönelik saklama oranları oldukça artmıştır.

Fırına gönderilecek hammadde miktarları fırının çalışma şartlarına ve alınan ölçüm değerlerine göre bilgisayarlar ile yapılan hesaplamalar sonucu bulunur. En önemli elle yapılan manevra dökümün açılıp pik demir ve curufun tahliye edilmesidir [17].

Fırın üstünden şarj edilen ve tüyer seviyesine kadar katı halde inen tek hammadde koktur. Kok, hammaddelerin pik demir ve curufa dönüştürülmesi için gerekli ısıyı sağlamanın ve indirgeyici işlevinin yanında, metal ve curufun sıvı olduğu genellikle karın bölgesinde malzemeye ihtiyaç duyduğu mekanik bir destek sağlar. Bu erimiş malzemeler kok parçacıklarının aralarındaki yarıklardan hazneye akarlar. Yüksek fırında en önemli gider kalemlerinden biri olan kok, ton pik demir başına 450-500 kg'dır. Maliyetleri nedeni ile düşük kok tüketimi uygun malzeme kullanımı, yüksek sıcak hava sıcaklığı, yüksek hidrokarbon takviyesi ve düzenli gaz dağılımı ile mümkündür.

Tüyelerden fırına giren sıcak hava, hemen tüyer önünde koktaki karbonu yakarak  $CO_2$  oluşturur. Oluşturulan bu güçlü yanma 2000-2200 °C derecede bir alev sıcaklığı (tüyer gaz sıcaklığı) oluşturur. 1000 °C derecenin üzerinde karbon bulunan ortamlarda  $CO_2$  kararlı bir yapıya sahip olmadığından,  $CO_2 + C = 2CO$  eşitliğinde  $CO$  oluşur. Kuru hava kullanıldığında tüyer gazı %35 oranında  $CO$  ve %65 oranında  $N_2$  içerir. Kok yukarıdan tüyer bölgesine sürekli olarak değil ama düzenli aralıklarla gelir. Bu sıcak indirgeyici gaz aktif kok yatağını kullanarak karın, bel ve gövdeye doğru yükselir ve demir oksitleri indirger [18].

### 2.6.1. Demir oksitlerin indirgenmesi

Hematit ( $Fe_2O_3$ ), magnetit ( $Fe_3O_4$ ) ve vüstit ( $FeO$ ) olmak üzere demir oksitlerin üç ayrı yapısı bulunmaktadır. Bu oksitler aşamalar halinde indirgenir. Demir oksitlerin  $CO$  ile reaksiyonları,  $CO/CO_2$  denge oranı ve 900 °C derecedeki  $CO$  verimlilik faktörleri ( $\eta_{CO}$ ) aşağıda verilmiştir. Verimliliğin boyutu,  $CO_2$ 'ye dönüşen  $CO$ 'nun oranı veya yüzdesi formül 2.2'deki gibi gösterilir.

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



Yüksek fırın ters akımlı bir süreç olduğundan yüksek oranda CO içeren tüyer gazı, Fe'ye dönüşmek için yüksek indirgeme potansiyeline ihtiyaç duyan FeO ile temas eder ve tepkimeye girer. Tepkime sonucunda ortaya çıkan düşük potansiyelli gaz yükselirken, daha düşük oksitlerine indirgenmek için çok daha az CO/CO<sub>2</sub> denge oranı gereken magnetit ve hematit ile karşılaşır. Bu nedenle vüstitin indirgenmesi indirgenme reaksiyonları içinde en önemli sırayı alır. CO<sub>2</sub>, karbonun son yanmasının ürünü ifade ettiğinden, karbonun kimyasal ve termal enerjisinin verimlilikleri 2.3 – 2.5 numaralı tepkimelerde ayrıştırılan oksijen miktarının fazlaşması ile daha da eskizsiz bir hale gelir. Biraz ısı açığa çıkaran bu tepkimelere dolaylı veya gazlı tepkimeler adı verilir ve tepkime sonuçlarında CO açığa çıkar.

Eğer sıcaklığın 1000 °C dereceyi aştığı bölgelerde indirgenmemiş vüstit kalmış ise, kalan vüstit 2.4 numaralı tepkime sonucunda ortaya çıkan CO<sub>2</sub>'de bulunan karbon ile hemen indirgenir .



2.5 ve 2.6 tepkime denklemlerini birleştirirsek ;





Yüksek oranda ısı alan ve  $CO$  kullanımını bozan 2.6 tepkimesi Boudouard veya çözün 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.

2000-2200 °C derecelik yüksek bir alev sıcaklığına sahip tüyer gazı yükselerek fırından ayrıldığı noktada 100-250 °C derecedeki sıcaklığa kadar soğurken, şarj edilen hammaddeler ise aşağıya inişlerinde 1400-1450 °C dereceye kadar ısınır. Şekil 2.4'de gösterildiği gibi, toplam ısı gereksiniminin yükselen gazların sağladığı alt ve üst, çok küçük ısı transferinin gerçekleştiği hemen hemen tüm bölgesi boyunca eşit sıcaklıkta (800-1000 °C) olan orta olmak üzere fırında üç ayrı sıcaklık bölgesi vardır [8].

### 2.6.2. Alt bölge tepkimeleri

Alt veya erime veya süreç bölgesi tüyer bölgesinden 3-5 m. yukarıya doğru uzanır. Bu bölgede erimiş maddelerin sıcaklıkları 1400-1450 °C derecelere kadar ulaşırken, gaz 800-1000 °C derecelere kadar soğur.

Tüyerler önündeki kokun yanması haznenin üst kenarında tüyerler önünde sürekli olarak boş bir alanın oluşmasıyla sonuçlanır ve bu olay şarj edilen malzemelerin aşağıya doğru akışını sağlar. Bu yanma alanının büyüklüğü ve şekli, düzenli bir gaz dağılımı ve şarj edilen malzemenin aşağıya inmesinde çok önemli bir etkidir. Sıcak havanın kinetik enerjisine bağlı olarak bu yanma alanının derinliği 1-2 m.'dir. Bu nedenle gerçek aktif alan, hazne üst kenarı etrafındaki bu 1-2 m. derinliğe sahip olan halkadır ve hazne halkası veya aktif çevre veya raceway olarak isimlendirilir. Bu halkanın ötesinde "dead man's zone" olarak isimlendirilen sıkı dolgulu merkezi bir kok sütunu mevcuttur. Bu kok sütunu haznedeki sıvı pikin içinde yüzer ya da hazne tabanına ulaşabildiği kadar


ulaşır. Bir miktar curuf ve demir kok parçacıkları arasındaki boşluklara girer ve buradan döküm açıldığında süzülür.

Akışkanlık verici malzemeler ile fırına giren demir oksit harici bileşenler fırının bel bölgesinde 1200 °C derecenin üzerindeki sıcaklıklarda erir ve bu bölgede birbirlerine karışmayan iki faz oluşmaya başlar. Daha sonra bu iki sıvı faz birbirlerinden ayrılarak hazne halkası (raceway) üstünde, kok bölgesinden sızarak haznede birikir. Kok mekanik bir destek sağlarken, tüyer gazı kok yatağındaki boşluklardan yukarıya doğru yükseldiğinden hazne halkası da ters akımlı bir sıvı-gaz dönüştürücüsüne benzer. Bu bölgedeki malzemenin akışı taşma riski açısından çok önemlidir.

Çalışırken söndürülmüş yüksek fırınlarda yapılan çalışmalar, alt gövde içine doğru uzayan zayıf dolgulu bir kok sütunun varlığını da göstermiştir. Bu zayıf dolgulu sütun, değişen kok katmanları içeren ve yukarı çıkan gazların geçmesine izin vermeyen geçirimsiz, yapışkan, yarı erimiş curuf ve demir içeren yumuşayan-eriyen veya birleşmiş bir bölge (cohesive zone) ile sınırlanmıştır. Kok yarıkları adı verilen geçirgen kok katmanları gaz dağıtıcısı gibi davranarak gazın içlerinden yatay olarak akmasını sağlarlar.

Gaz, yukarıya kadar uzanan geçirgen katı yatağın içinde yükselir. Gazın büyük çoğunluğu bu kok yarıklarından geçmek zorunda olduğundan, özellikle büyük fırınlarda, kok yarıkları geçirgen olmalıdır ki bu da kokun kırılma direnci ile çok önemli derecede ilişkilidir.

Oluşan ilk curuf, ilave edilen kireci alır ve karın bölgesi curufunu oluşturur. Daha sonra tüyer önündeki yanma sonucu oluşan kok külü ile döküm açıldığında rahatça akması için yeterli akışkanlık sağlayacak bir kompozisyona sahip olması gereken hazne curufunu oluşturur. Curuf kompozisyonu, 1400-1450 °C derece arasında değişen sıcaklıkta içerdiği tüm maddelerin sıvı halde olacak şekilde seçilir ve 1500 °C'deki akışkanlığı 10 P'dir. Bazitesi ise 0.9-1.2 arasında değişir. Curuf içerisinde  $FeO$  içermez. Çünkü indirgenmemiş  $FeO$ , ya hazne içerisinde yüzen kok sütunu ile teması



Şekil 2.4. Gaz ve katıların sıcaklık dağılımının fırın yüksekliği boyunca ki ideal dağılımı ve üç sıcaklık bölgesinde oluşan kimyasal tepkimeler [8]

sonucunda ya da ergime bölgesinde kok ızgaraları arasından süzülürken tamamıyla indirgenir.

Curufun kolaylıkla tahliyesi için gerekli olan en düşük hazne sıcaklığına kritik hazne sıcaklığı denir ve bu değer curuf ve demirin her türlü çalışma şartında sıvı halde olmasının garantilenmesi için 1500-1550 °C arasındadır.

Bu bölgede oluşan önemli tepkimeler şekil 2.4'de verilmiştir.

Demirin nihai sıcaklığı 1350-1450 °C ve curufun da bu sıcaklıktan 50-100 °C daha fazladır. Kullanılan hammadde ve üretilen ürünlere göre değişmekle birlikte, fırının alt bölgesindeki ısı ihtiyacı, ısı yayılımı ve soğutma kayıpları ile birlikte ton pik demir başına 0.7 ile 1 milyon kcal. arasında değişebilir. Bu aşamada gaz ve şarj malzemelerinin sıcaklıkları birbirlerine yaklaşır [8].

### 2.6.3. Orta bölge tepkimeleri

Gazın ve katıların sıcaklıklarının hemen hemen eşit oldukları (800-1000 °C) orta bölgeye izotermal veya termal rezerv denir. Bilhassa vüstit ( $FeO$ ) olmak üzere, dolaylı indirgemenin büyük bir kısmı burada gerçekleştiğinden bu bölge dolaylı indirgeme bölgesi olarak da adlandırılır. İyi çalışan bir fırında bu alan fırın hacminin %50-60'ını içerir.

Vüstitte mümkün olduğunca dolaylı olarak indirgenme şansı verilmesi gerektiğinden bu bölgenin genişliği çok önemlidir. Bu bölgenin başlangıcı, fırın içerisindeki yüksek miktarda ısı alan (endotermik) tepkimelerin başladığı seviyelere, ısı transfer verimliliğine ve farklı fırın kesitlerindeki homojen gaz dağılımına bağlıdır.

Modern fırınlarda değişik seviyelerde yapılan sondalar ve gaz örneklerinin analizleri, bu bölgede cevher ile gaz arasında çok küçük oksijen değişimi olan ve gaz

kompozisyonunun çok az deęiřtięi kimyasal olarak aktif olmayan bir bölgenin varlığını göstermiştir. Bu aktif olmayan bölgede gazdaki  $CO/CO_2$  oranı yaklaşık 2.3'tür ki bu deęer 2.5 ile verilen eřitlikteki  $Fe - FeO$  dengesini göstermektedir.

Bu bölgedeki bir dięer önemli tepkime su-gaz deęiřimi tepkimesidir.



Bu tepkime sonucu  $CO$ 'dan daha aktif bir indirgeyici gaz olan hidrojen açığa çıkar. Rutubet, demir oksitlerin hidrojen ile indirgenmesi ile oluşabileceęi gibi, nemli sıcak hava veya havaya katkı olarak buhar ve/veya hidrokarbon kullanılması ile fırına girer [8].

#### 2.6.4. Üst bölge tepkimeleri

Ön ısıtma veya hazırlama bölgesinde, orta bölgeden yükselen gazın sıcaklığı hızla 800-1000 °C dereceden 100-250 °C dereceye düşerken řarj malzemelerinin sıcaklıkları ortam sıcaklığından 800 °C dereceye kadar çıkar. Bu bölgede

- kalsiyum dışındaki karbonatların ayrışma,
- nem ve malzemedeki hidratın buharlaşma,
- $2CO = CO_2 + C$  tepkimesi ile karbon birikme,
- hematit ve magnetitin kısmen ya da tamamen alt oksitlerine indirgenme

olayları sayılabilir.

Şarj edilen malzemelerin tepeden tüyer seviyesine kadar inmesi üretim hızına baęlı olarak 5-8 saat arasında gerçekleşir. Bu malzemelerin her üç bölgede ne kadar kaldıkları kesin olarak bilinmemektedir. Buna ters olarak gazın fırında kalma süresi 1-10 saniye arasında deęişir [8].

## 2.7. Verimlilikteki Gelişmeler

Başlangıcından, günlük üretim kapasitesi 13000 ton olan fırınların inşa edilen günümüze kadar yüksek fırınların verimlilikleri sürekli olarak artmıştır. Bu gelişmenin en önemli sebebi daha iyi şarj dağılım sistemleri, daha iyi soğutma sistemleri, daha dayanıklı refrakter malzemesi gibi gelişmiş tasarımı daha büyük fırınlardır. Bunun yanında şarj malzemelerinin fiziksel ve kimyasal karakteristiklerindeki değişimlerin fırın şartlarında sağladığı değişimler de performansların artmasında önemli bir rol oynamıştır.

Verimlilikteki artışın en önemli etkeni ise ebatlandırılmamış cevherden ebatlandırılmış cevhere geçiş ve sinter ve peletin istenilen şekilde dağıtılabilesidir. Düzgün malzeme, fırın gazlarının şarj ile birlikte kanallama yapmadan hızlı bir biçimde yükselmesini ve bu da fırının yüksek hava oranlarında çalıştırılabilmesini sağlamıştır. Gerçekten de eski fırınların üretimleri, ebatlandırılmış sinter ve pelet kullanılması ile birlikte neredeyse iki katına çıkmıştır. İlave bir yarar olarak cevherin toz olarak fırın gazı ile kaybedilmesi oldukça azalmıştır.

Tüyerlerden hidrokarbon sıvı, gaz ve katıların enjeksiyonu, katı şarjın içindeki kok ihtiyacını düşürerek fırın üretimlerinin artırılmasını sağlamıştır. Bu gövdede demir oksitleri için daha fazla alan bırakarak daha yüksek indirgeme kapasitesi sağlamıştır. Ayrıca bu ilavelerin maliyetlerini kok maliyetleri ile karşılaştırdığımızda, doğrudan üretim maliyetlerini büyük oranlarda azaltıcı etkisi olmuştur.

Bununla birlikte hidrokarbon takviyesi daha sıcak hava kullanmasını ortaya çıkarmıştır. Soğuk olarak tüyer bölgesinde fırına verilen hidrokarbonlar ilave ısı ihtiyacına sebep olmuşlardır. Modern fırınlarda sıcak hava sıcaklığı 1350 °C derecelere kadar ulaşabilmektedir.

Havanın saf oksijen ile zenginleştirilmesi de yüksek fırın performansının gelişiminde etkili olmuştur. İlave edilen oksijen ihtiyaç duyulan hava oranını düşüreceğinden fırından geçen azot miktarını azaltacaktır. Azotun bu kısmi eliminasyonu;

- tüyerler önündeki alev sıcaklığını artırarak soğuk hidrokarbon enjeksiyonunun artırılmasını ve
- *CO* üretim oranında artış sağlayarak, fırından geçen toplam gaz miktarını artırmadan daha fazla demir oksitini indirgenmesine olanak sağlar. Bu kanallama veya taşmaya neden olmadan üretim oranının artırılmasında kullanılabilir.

Bir başka önemli gelişmede günümüzde bir çok fırının işletildiği yol olan fırın tepesinin 3 atmosfer basınca kadar basınçlandırılabilmesinin sağlanmış olmasıdır. Yüksek basınçlı çalışma, gaz hızında herhangi bir artış olmaksızın yüksek fırın şarjı vasıtasıyla gazda artırılmış bir ağırlık akış oranı sağlar. Bu gaz-katı tepkime süresinde herhangi bir azalmaya neden olmaksızın daha büyük bir indirgeme gazı ortaya çıkmasını sağlar ve bu da demir üretim oranında artış sağlar. Yüksek fırın basıncı fırından çıkan gazın klape ile akışının kısılması ile sağlanır. Fırın yapısının bu tür bir çalışma için güçlendirilmiş olması gerekmektedir [17].

## 2.8. Yüksek Fırın Maliyetleri

Yüksek fırın çok yüksek erimiş pik demir üretim oranı olan geniş bir tesistir. Günlük üretimi 5000 ton demir olan tek bir yüksek fırın hava üfleyicileri, sıcak hava sobaları, hammadde besleme ve şarj sistemi, toz toplama sistemi dahil olmak üzere 100 milyon USD'lik bir maliyetle kurulabilir. Tesis başına bu yüksek sermaye, bu üretim sürecinin en büyük dezavantajıdır. 1980'lerde yaklaşık olarak 100 USD olan ton pik demir maliyeti günümüzde 220-250 USD arasında değişmektedir. Bu oran tesisin yeri, hammadde fiyatları ve kullanılan hammadde oranları ile ilişkili olarak değişir [17].

## 2.9. Türkiye’de Demir Üretimi ve Yüksek Fırımlar

Türkiye’de toplam 3 entegre demir çelik tesisinde toplam 8 adet yüksek fırın bulunmaktadır. Şu anda her üç tesiste yatırım, proje ya da inşa aşamasında olan toplam 3 adet yeni yüksek fırın bulunmaktadır. Yeni yüksek fırınların devreye girmesiyle beraber bazı eski fırınların ekonomik ömrü de tamamlanmış olacaktır. Halihazırda Türkiye’de yüksek fırınlardan yıllık ortalama 6 milyon tonun üzerinde üretim alınmaktadır. Yeni fırınların (Erdemir Yeni 1 nolu Yüksek Fırını, İsdemir 4 nolu Yüksek Fırını, Kardemir 4 nolu Yüksek Fırını) ve bağlı yatırımların (çelikhane, blower vs.) devreye girmesi ile bu kapasite yıllık 8,5 milyon tonun üzerine çıkacaktır. Bu artış sıvı çelik ve nihai ürün üretimine de yansıtacak sonuç olarak çelik üreticileri liginde Türkiye’yi üst sıralara taşıyacaktır.



## **BÖLÜM 3. VERİ MADENCİLİĞİ**

### **3.1. Veri Madenciliğinin Tanımı**

Verilerin dijital ortamda saklanmaya başlanması ile birlikte, yeryüzündeki bilgi miktarının her 20 ayda bir kendini iki katına çıkardığı günümüzde, veri tabanlarının sayısı da benzer hatta daha yüksek bir oranda artmaktadır. Yüksek kapasiteli işlem yapabilme gücünün ucuzlaşmasının bir sonucu olarak, veri saklama hem daha kolay olmuş, hem de verinin kendisi de ucuzlamıştır.

Araştırmacıların, geniş, çok hacimli ve dağınık veri setleri üzerinde yapmış oldukları çalışmalar sonucu veri madenciliği ve bilgi keşfi (data mining & knowledge discovery), özellikle elektronik ticaret, bilim, tıp, iş ve eğitim alanlarındaki uygulamalarda yeni ve temel bir araştırma sahası olarak ortaya çıkmaya başlamıştır [36].

Gartner Grubuna göre veri madenciliği; veri ambarlarında saklanan çok fazla miktardaki verilerin elenerek yeni anlamlı bağlantıların, örüntülerin ve eğilimlerin istatistiksel ve matematiksel teknikler kadar iyi örüntü tanıma teknikleri ile keşfedilme sürecidir [37]. Bu tanıma ilave olarak; gözlemsel veri kümelerinin arasında var olduğu bilinmeyen ilişkilerin bulunması için bu veri setlerinin analizi ve verilerin veri sahibi için hem anlaşılabilir hem de kullanılabilir olması amacıyla özetlenmesi veya büyük veritabanlarından bilgi çıkarma amacına odaklı olarak makine öğrenmesi, örüntü tanıma, istatistik, veritabanları ve görselleştirme gibi teknikleri bir araya getiren dallar arası alan olarak nitelendirilebilir [37].

Temel olarak veri madenciliği, veri setleri arasındaki desenlerin ya da düzenin, verinin analizi ve yazılım tekniklerinin kullanılması ile ilgilidir. Veriler arasındaki ilişkiyi,

kuralları ve özellikleri belirlemekten bilgisayar sorumludur. Amaç, daha önceden fark edilmemiş veri desenlerini tespit edebilmektir.

Veri madenciliğini bir istatistiksel yöntemler serisi olarak görmek mümkün olabilir. Ancak veri madenciliği, geleneksel istatistikten birkaç yönde farklılık gösterir. Veri madenciliğinde amaç, kolaylıkla mantıksal kurallara ya da görsel sunumlara çevrilebilecek nitel modellerin çıkarılmasıdır. Bu bağlamda, veri madenciliği insan merkezlidir ve bazen insan – bilgisayar ara yüzü birleştirilir.

Veri madenciliği sahası, istatistik, makine bilgisi, veri tabanları ve yüksek performanslı işlem gibi temelleri de içerir.

Veri madenciliği konusunda bahsi geçen geniş verideki geniş kelimesi, tek bir iş istasyonunun belleğine sığamayacak kadar büyük veri kümelerini ifade etmektedir. Yüksek hacimli veri ise, tek bir iş istasyonundaki ya da bir grup iş istasyonundaki disklerle sığamayacak kadar fazla veri anlamındadır. Dağıtık veri ise, farklı coğrafi konumlarda bulunan verileri anlatır [36].

Veri madenciliği, geleceğin en azından yakın geleceğin, geçmişten çok fazla farklı olmayacağını varsayarsak geçmiş veriden çıkarılmış olan kurallar gelecekte de geçerli olacak tezi ile ilerisi için doğru tahmin yapmamızı sağlama amacındadır [38].

### **3.2. Veri Madenciliği İşlevleri**

Veri analiz eden kişinin farklı amaçlarını doğrultusunda, veri madenciliğini işlevlere bölerek sınıflandırmak uygun olacaktır. Her ne kadar işlevler birbirlerinden ayırt edilmeye çalışılsa da bir çok ortak noktaları vardır.

#### **3.2.1 Keşifsel veri analizi (EDA)**

İsminden de anlaşılacağı gibi, buradaki amaç basitçe; verilerin ne arandığı konusunda açık fikirler olmadan araştırılmasıdır. EDA teknikleri etkileşimli ve görseldir

ve küçük, düşük boyutlu veri kümelerinin bir çok grafiksel gösterim metodu vardır. Boyutluluk (değişken sayısı,  $p$ ) arttıkça,  $p$  uzayında nokta bulutlarının gösterimi daha da zor bir hale gelecektir. 3 veya 4'den daha büyük boyutlarda, verinin yöntem aydınlatıcı düşük boyutlu izdüşümleri olan en önemli bileşen analizi gibi izdüşüm teknikleri çok yararlı olabilir. EDA uygulamalarına örnek verecek olursak;

- 1858 yılında Florence Nightingale'in Londra içinde ve çevresindeki askeri hastanelerde olan ölüm oranı istatistiklerini gösterirken kullandığı, şimdiki dilimli grafiğe benzer bir dairenin, dilimli grafikte ki dilim açılarının değişimi yerine kısımların yarı çaplarını değiştiren bir grafik,
- 1856'da John Bennett Lawes'in kullandığı bir teknik ve
- daha yakın olarak, Becker, Eicks ve Wilks 1995'de tanımladıkları, 12000 bağlantının üzerindeki zamanla değişen, uzun mesafeli telefon hattı örüntülerinin gösterimi için bir dizi karışık uzaysal gösterimini içeren teknik

sayılabilir [39].

### 3.2.2. Betimsel (Tanımlayıcı) modelleme

Betimsel modellemenin amacı tüm verinin (veya veriyi üreten sürecin) tanımlanmasıdır. Bu tür tanımlamaları içeren modeller, verinin dağılım olasılığı (yoğunluk hesaplama),  $p$ -boyutlu uzayın gruplandırılması (kümeleme analiz ve bölme) ve değişkenler arasındaki ilişkileri tanımlayan modellerin (bağımlılık modellemesi) tamamını içerir. Örneğin bölümlenme analizinde amaç, ticari veritabanlarındaki pazar bölümlenmesi gibi benzer kayıtların beraber gruplanmasıdır. Burada amaç, kayıtları homojen gruplara bölerek, kayıtların insanları gösterdiğini düşünürsek, benzer insanların aynı gruba koyulmasını sağlamaktır. Bu reklam verenlerin ve pazar sahiplerini promosyonlarını, cevap verecek gibi olanlara, daha verimli şekilde yönlendirmelerini sağlayacaktır. Burada grup sayısı araştırmacı tarafından seçilir ama gerçekte doğru bir sayı yoktur. Amacı bilimsel veritabanlarında bulunan veri içerisindeki doğal grupları keşfetmek olan kümeleme analizine terstir. Betimsel modelleme çeşitli yollar ile kullanılır.

- Bölümleme, pazarlamada müşterileri satın alma örüntüleri ve yaş, gelir gibi demografik verileri sınıflamada geniş ölçüde ve başarılı bir biçimde kullanılmıştır.
- Kümeleme analizi, psikiyatrik araştırmalardaki psikiyatrik hastalıkların cinslerine göre tasniflerinin oluşturulmasında geniş ölçüde kullanılmıştır.
- Kümelene teknikleri, Dünya'nın kuzey yarım küresinde üst atmosferdeki uzun süreli iklim değişikliklerinin analizinde kullanılmıştır [39].

### 3.2.3. Öngörülü modelleme

Burada amaç; bir değişken değerinin, bilinen diğer değişkenlerle tahmin edilmesini sağlayan modeller oluşturmaktır. Tahmin edilecek değişken sınıflandırmada kategorik iken gerilemede niceldir. Burada kestirim genel bir sezi olarak kullanılır ve herhangi bir uzay-zaman sürekliliği kavramı uygulanmaz. Bu nedenle, örneğin, bir süre sonraki hisse senedi piyasası değerlerini tahmin edilmesini veya bir yarışta hangi atın kazanacağını bilmek istediğimizde, olayın tanılarını ve/veya kestirimin güçlülüğünü de bilmek isteriz. İstatistikte ve makine öğrenmesinde kestirim modelleme problemlerinin üstesinden gelmek için çok sayıda metod geliştirilmiş, bu alandaki çalışmalarla önemli teorik gelişmeler elde edilmiştir. Kestirimsel ve betimsel arasındaki anahtar fark, kestirimin tek bir değişken üzerinde hedefi varken betimsel problemlerde model merkezinde herhangi bir değişken yoktur. Kestirimsel modellere örnek olarak;

- Fayyad, Djorgovski ve Weir SKICAT sisteminde, bir sınıflandırma ağacının 40 boyutlu özellik vektörlerinden yıldız ve galaksilerin sınıflandırılmasında en az insan uzmanlar kadar başarılı olup olamayacağını göstermek için bir ağaç yapılı gösterim kullanmışlardır. Sistem, milyonlarca yıldız ve galaksinin gökyüzü sayısal resimlerinden otomatik olarak kataloglanmasında rutin olarak kullanılmaktadır.
- AT&T araştırmacıları, Amerika Birleşik Devletleri'ndeki 350 milyon telefon numarasına sahip abonelerin karakteristiklerinin izlenmesini sağlayacak bir sistem geliştirmişlerdir. Bir telefon numarasının iş veya ev telefonu olma

olasılığını hesaplayan modeller oluşturabilmek için gerileme teknikleri kullanılmıştır [39].

### 3.2.4. Örüntüleri ve kuralları keşfetme

Daha önce bahsedilen 3 işlev model oluşturma konuları ile ilgilenen işlevlerdir. Diğer veri madenciliği uygulamaları örüntü tespiti ile ilgilenmektedir. Uzayın değişik yerlerinde görülen sahte leke davranışının tespiti bir örnek olarak verilebilir. Astronomideki bir başka kullanımı ise daha önce bilinmeyen olayların keşfini sağlayabilecek garip yıldız ve galaksilerin tespiti gösterilebilir. Buradaki önemli meydan okuma, geleneksel olarak dışsal tespitin içeriği ile uğraşmış istatistikçilerin, normal değişkenlik içeriğindeki beklenmedik davranışların gerçekten oluşma nedenlerini çözmeye çalışmalarıdır. Bu, özellikle çoklu boyutlarda zor olabilir. Geriye yönelik alan bilgisi ve insan yorumu paha biçilmez bir duruma gelebilir. Uygulanmış örnekler olarak;

- Amerika Birleşik Devletleri’ndeki profesyonel basketbol oyun istatistikleri, çok zaman tabanlı kayıtlar olarak detaylı bir biçimde tutulur. Bhandari’in “Gelişmiş İzci (Advanced Scout)” sistemi, bu kayıtlardan, çalıştırıcıların gözlerinden kaçabilecek ilginç bilgileri açığa çıkarmak için “X oyuncusu sahadayken Y oyuncusunun atış oranı %75’den %30’a düşmektedir” gibi kural benzeri örüntüleri araştırır. 1997’den bu yana bazı takımlar tarafından kullanılmaktadır.
- Amerika Birleşik Devletleri’nde hileli cep telefonu kullanımının telefon endüstrisine zararı birkaç yüz milyon dolardır. Fawcett ve Provost, müşteri işlemlerinin tutulduğu çok büyük veritabanlarından hileli davranış karakteristiklerini keşfetmek için bir kural öğrenim algoritması uygulaması tanımlamışlardır. Ortaya çıkan sistemin, eski el ile yürütülen sisteme oranla daha doğru olduğu rapor edilmiştir [39].

### 3.2.5. İçerik ile erişim

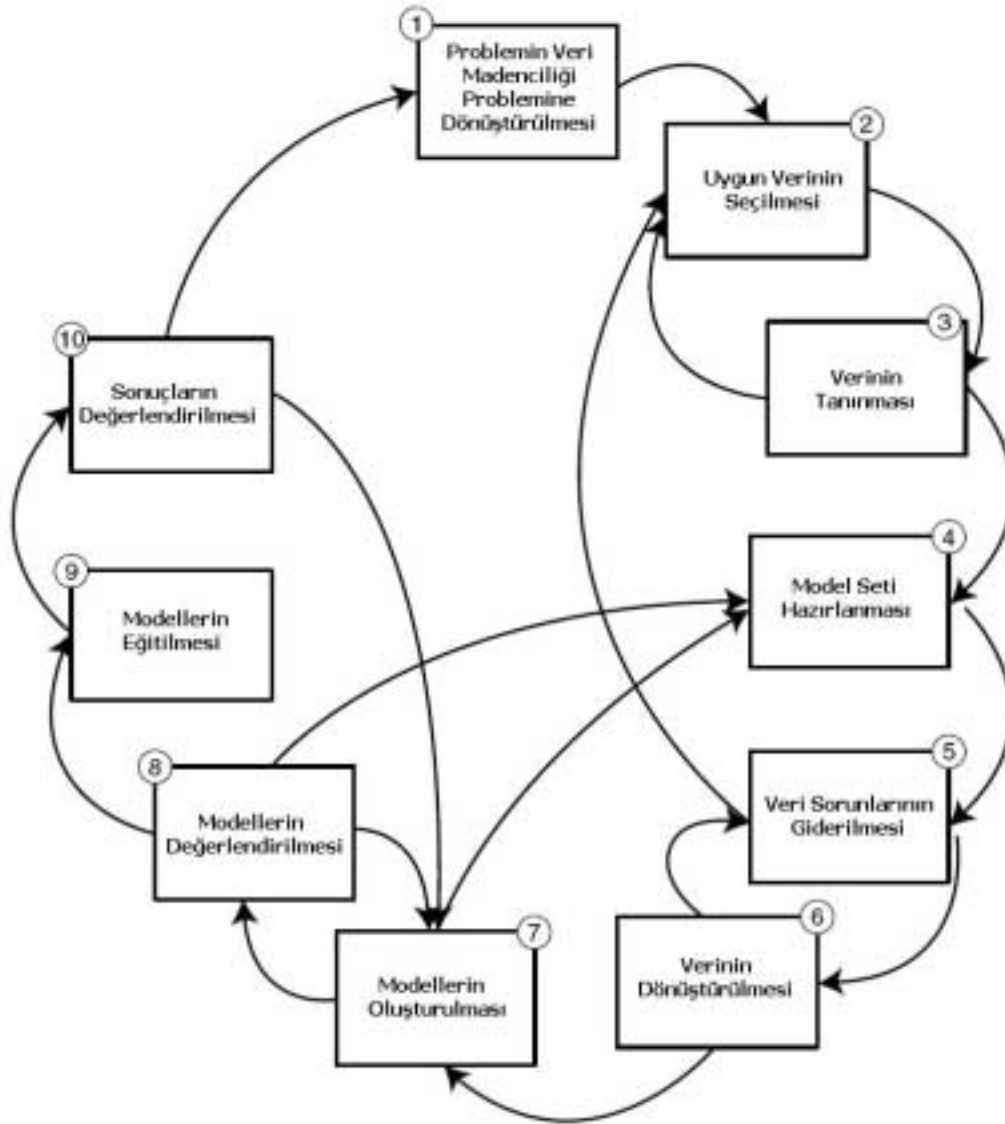
Buradaki olay kullanıcının elinde ilgilendiği örüntü ile veri kümeleri içindeki benzer örüntüleri bulma isteğidir. Bu işlev daha çok metin ve görüntü veri kümelerinde kullanılır. Metin için, çok geniş bir doküman kaynağından ilgili olanların bulunabilmesi için örüntü aranacak olan bir kelime kümesi, görüntü için ise geniş bir görüntü arşivinden benzerlerini bulmak üzere örnek veya taslak görüntü olabilir. Her iki durumda da arama stratejisinin detayları kadar benzerlik tanımı çok önemlidir.

- “PageRank” isimli matematiksel bir algoritma kullanan bağlantı, örüntülerini kullanarak farklı web sayfalarının izafi önemini hesaplayan Google sistemi,
- IBM araştırmacıları tarafından geliştirilen QBIC, görüntü içeriği ile sorgulama (Query by Image Content), renk doku ve izafi pozisyon bilgisi gibi tanımlayıcılar ile çok büyük görüntü veritabanlarının araştırılması

bu işleve örnek olarak verilebilir [39].

### 3.3. Veri Madenciliği Metodolojisi

Veri madenciliği metodolojisi şekil 3.1’de gösterildiği gibi 11 adımda incelenebilir. Şekilde gösterildiği gibi süreci düz bir çizgi olarak düşünmek yerine iç içe döngüler halinde düşünülmesi en iyi düşünce tarzıdır. Adımların doğal bir sıralaması olmasına rağmen, bazen gerekli görülmeyen veya bir sonraki adıma geçmek için mevcut adımın tamamen tamamlanması gerekmeyebilir. Sonraki adımlarda öğrenilen bilgiler daha öncekilerin tekrar edilmesine neden olur [40].



Şekil 3.1. Veri madenciliği metodolojisi [40]

### 3.4. Veri Madenciliği Teknikleri

Amacı özel bir değişkenin değerini bulmak olan yönlendirilmiş veri madenciliği, amacı herhangi bir değişkeni hedef almadan veri yapılarını açmak olan yönlendirilmemiş veri madenciliği veya her ikisi de olabilen teknikler vardır. “Sınıflandırma (Classification)”, “Kestirim (Estimation)”, “Öngörü (Prediction)” yönlendirilmiş veri madenciliği,

“Benzerlik Grublaması (Affinity Grouping)” ve “Kümeleme (Clustering)” yönlendirilmemiş veri madenciliği sınıfına girer. Betimsel bir işlev olan “Tanımlama ve Profil Çıkarma” ise yönlendirilmiş veya yönlendirilmemiş olabilir.

### 3.4.1 Sınıflandırma

İnsanın iradesi dışında görünen bir biçimde en yaygın kullanılan veri madenciliği işidir. Genel olarak bizler, anlamak ve dünya ile iletişim kurabilmek için her şeyi sınıflandırır, kategorize eder ve derecelendiririz. Maddeleri elementlere, ülkeleri şehirlere, şehirleri semtlere vb. böleriz.

Sınıflandırma, yeni karşılaşılan bir girdinin özelliklerini inceleyerek, onu daha önceden tanımlanmış olan belirlenmiş bir sınıf kümesinden hangisine atanacağını içerir. Genellikle sınıflanacak olan girdiler veritabanında veya dosyada kayıtlı kayıtlar şeklindedir ve sınıfa atama işlemi bu kayda yeni bir sınıf sütunu ilave edilmesi ile gerçekleşmektedir.

Sınıflandırma işi, daha önceden tanımlanmış örnekleri içeren eğitim kümeleri ve sınıfın çok iyi bir biçimde tanımlanması ile karakterize edilmiştir. Burada görev, sınıflandırılmamış veriye uygulandığında istenilen sınıflamayı oluşturacak bir model oluşturmaktır.

- Kredi başvurularının düşük, orta ve yüksek riskli olarak sınıflandırılması,
- Bir web sayfasında gösterilecek verinin içeriğini seçilmesi,
- Hangi telefon numaralarının belge geçer makinesine ait olduğunun tespiti,
- Hileli sigortaların fark edilmesinin sağlanması

gibi örnekler sınıflandırma örneği olarak verilebilir.

Tüm bu örneklerde sınırlı sayıda sınıf bulunur ve beklenen de her bir kaydın bu sınıflardan birisine atanmış olmasıdır. Sınıflandırma için karar ağaçları, bellek tabanlı



sistem yöntemleri en uygun olan yöntemlerdir. Bazı durumlarda ilişkisel analiz yöntemi ve yapay sinir ağları da faydalı sonuçlar vermektedir [40].

### 3.4.2 Kestirim

Sınıflandırma işlemi “evet” veya “hayır” gibi ayırık sonuçlar ortaya çıkarırken, kestirim sürekli değer alabilen çıktılar oluşturmaktadır. Verilen bir girdi verisine göre kestirim, gelir, boy, kredi kartı bakiyesi gibi daha önceden bilinmeyen sürekli bir değer olarak ortaya çıkar.

Uygulamada kestirim sınıflandırma işlemlerini gerçekleştirmek için kullanılır. Bir kredi kartı şirketi, hesap özetlerinde yer alan reklam alanını bir kayak botu üreticisine kiralamak istediği zaman, şirketin hesap özeti gönderdiği tüm müşterilerini kayak yapanlar ve yapmayanlar şeklinde bir sınıflandırma modeli kurması gereklidir. Bir başka yaklaşım ise hesap özeti gönderilen müşterilerin kayak yapma ihtimalinin hesaplanmasıdır ve bu hesaplamanın çıktısı “0” ve “1” olan sınıflandırmadan farklı olarak 0 ile 1 arasında herhangi bir değer alabilir. Bu noktadan sonra sınıflandırma işi, uygun bir eşik değer seçimine indirgenmiştir. Hesaplama sonucu eşik değerine eşit veya daha büyük olanlar “kayak yapanlar”, eşik değerinin altındakiler ise “kayak yapmayanlar” olarak sınıflandırılmış olur.

Kestirim işleminin sınıflandırma işlemine göre en büyük avantajlarından birisi de her bir kaydın sahip olduğu değere göre tüm kayıtların sıralanabilir hale gelmesidir. Yukarıda verilen örnekteki kayak botu üreticisinin reklam için kısıtlı bir bütçesi olması durumunda, bu modelleme ile kayak yapma ihtimali en yüksek olanlara reklam vererek en uygun çözüm sağlanmış olacaktır.

Kestirim işlemine verilecek örnekler aşağıdaki gibidir:

- Bir ailedeki çocuk sayısının tahmini,

- Ailenin toplam gelirini hesaplanması,
- Müşterilerin bağlılık süresinin hesaplanması,
- Banka müşterilerinin yeni hesap tipleri seçme olasılıklarının hesaplanması

Regresyon (Gerileme) ve yapay sinir ağları kestirim işi için çok uygundur [40].

### 3.4.3 Öngörü

Öngörü, sınıflandırma veya kestirim ile aynıdır, ancak bu işlemde kestirilen ileriki davranışlar veya hesaplanan ileriki değerlerden oluşan kayıtlar sınıflandırılır. Öngöründe sınıflandırmanın doğruluğu ancak “bekle ve gör” prensibi ile kontrol edilebilir. Öngörünün sınıflandırma ve kestirimden ayrı olarak ele alınmasının en önemli nedeni, öngörüselle modellemede girdi değişkenlerin geçmişe bağlı ilişkileri gibi ilave sorunların olmasıdır.

Sınıflandırma ve kestirim işlemlerinde kullanılan herhangi bir teknik, eski verilerden öngörüsü yapılacak değişkenin de bilindiği eğitim kümeleri hazırlanması gibi küçük uyarlamalar ile öngörü işi için de kullanılabilir duruma getirilebilir. Modelin oluşturulmasında kullanılacak eski veriler, gözlenen mevcut durumu açıklayacaktır. Model şimdiki verileri içeren kümelere uygulandığında sonuç gelecekteki davranışların bir tahmini olacaktır.

Veri madenciliği kapsamında yer alan bazı öngörü tahminleri aşağıdaki gibidir:

- 6 aylık zaman süresinde ayrılacak müşterilerin belirlenmesi,
- Cep telefonu kullanıcıları arasında hangilerinin katma değeri yüksek özel servisleri kullanmak isteyeceğinin tahmin edilmesi.

Öngörü işlemi için kullanılacak olan tekniğin seçimi giriş verilerinin özelliklerine, öngörülecek değerlerin tipine ve yapılan öngörünün açıklanabilirlik özelliğinin derecesine

doğrudan bağlıdır. Yapay sinir ağları, karar ağaçları gibi teknikler öngörü işlemi için uygun tekniklerdir.

#### **3.4.4 Benzerlik gruplaması**

Benzerlik gruplaması ya da sepet analizi, hangi ürünlerin hangi ürünlerle daha çok satıldığının belirlenmesi için kullanılır. En yaygın örneği süpermarketlerdeki alışveriş kayıtlarının incelenerek hangi satışlarda hangi ürünlerin daha çok beraber satıldıklarının saptanmasıdır. Perakende satış yapan mağazalar, benzerlik gruplamasını daha çok ürünlerin raflardaki yerleştirilmesinin, çok satılan ürünlerin birlikte gözükcek şekilde uygun olarak düzenlenmesi amacı ile kullanmaktadır. Aynı zamanda bu işlev ile çapraz satış fırsatlarının belirlenmesi ya da hizmetlerde ve ürünlerde satış artırıcı paketlerin, gruplandırılmalarının ve promosyonların yapılması sağlanabilmektedir. Aynı zamanda bu işlev, verilerden kurallar çıkarmanın en basit yöntemidir.

#### **3.4.5 Kümeleme**

Kümeleme, ayrışık yapıdaki popülasyonu daha bağdaşık alt gruba ya da kümeye bölme işlemidir. Sınıflandırma ile arasındaki en önemli fark, kümelemede bölümlenmeyi sınıflandırmadaki gibi önceden belirlenmiş bir takım sınıflara göre yapılmamasıdır. Sınıflandırmada yeni gelen her bir kayıt, önceden sınıflandırılmış bir takım sınıflar üzerinde yapılan bir eğitim neticesinde ortaya çıkan bir modele göre önceden belirlenmiş olan bir sınıfa atanmaktadır. Kümelemede ise önceden tanımlanmış sınıflar ya da örnek sınıflar yoktur. Kayıtların gruplandırılması işlemi, kayıtların birbirine olan benzerliklerine göre yapılmaktadır. Oluşan sınıfların hangi anlamları taşıdığıının belirlenmesi tamamen analizi yapana kalmıştır. Hasta kayıtlarından oluşan semptomların kümelenmesi, farklı hastalıkları gösterebilir. Müşteri özelliklerinin kümelenmesi farklı pazar yapılarının oluşmasını gösterebilir.

Kümeleme çoğunlukla başka bir veri madenciliği işlemi için bir ilk işlem olarak kullanılır. Örneğin bir pazar payı araştırması için bir ilk işlem olarak uygulanabilir. “Ne

tip promosyonlar müşteriler tarafından ilgi görür?” sorusunun cevabını bulmayı kolaylaştırmak için herkes için tek bir model yerine, müşteriler alışveriş alışkanlıklarına göre gruplandırılırsa, her küme için “Bu kümedeki müşteriler hangi tip promosyonlara ilgi duyar?” sorusunun cevabı çok daha kolay verilir [40].

Kümeleme işleminin kullanıldığı alanlara örnekler aşağıdaki gibi verilebilir:

- Örüntü tanıma,
- Konuşma tanıma,
- Şehir planlamacıları için konumlarına, değerlerine ve türlerine göre binaların gruplanması,
- Belge sınıflandırma [41].

### 3.4.6 Tanımlama

Veri madenciliği uygulamalarının amaçlarından birisi de, karmaşık bir veritabanında neler olup bittiğini, verileri ilk elden oluşturan insanlar, ürünler ve işlemler bazında daha iyi anlamamızı sağlayacak açıklamalar bulmaktır. Bir davranış için verilen iyi bir “tanımlama” çoğu kez bu davranış için bir de “açıklama” getirmelidir. İyi bir tanımlama en azından açıklamayı bulmak için nereden başlanması gerektiğini göstermelidir [40].

Sepet analizi tamamen tanımlayıcı bir tekniktir [42]. Karar ağaçları da çok güçlü bir araçtır.

## 3.5. Veri Madenciliği Yöntemleri

### 3.5.1. İstatistiksel yöntemler

Veri madenciliği çalışması, esas olarak verilen bir örnek kümesine bir kestirici oturtmayı amaçlayan bir istatistik uygulamasıdır. İstatistik literatüründe son elli yılda bu amaçla

değişik teknikler önerilmiştir. Bu teknikler, istatistik literatüründe çok boyutlu analiz (multivariate analysis) başlığı altında toplanır ve genelde verinin parametrik bir modelden (çoğunlukla çok boyutlu bir Gauss dağılımından) geldiğini varsayar. Bu varsayım altında sınıflandırma (classification; discriminant analysis), regresyon, kümeleme (clustering), boyut azaltma (dimensionality reduction), hipotez testi, varyans analizi, bağıntı (association / dependency) kurma için teknikler istatistikte uzun yıllardır kullanılmaktadır [41].

### 3.5.2. Bellek tabanlı yöntemler

İnsanlar kararlarını genellikle daha önce yaşadıkları deneyimlere göre verirler. Örneğin doktorlar bir hastayı incelerken elde ettiği bulguları tanımlamada daha önce tedavi ettiği benzer hastalığa yakalanmış hastalar üzerindeki deneyimlerini kullanırlar. Aynı şekilde bir sigorta uzmanı da bir olayın sahtekarlık olup olmadığını bulmak için daha önceki olaylar ile olan benzerlikleri göz önünde bulundurmaktadır. Benzer şekilde deneyimleri kullanan gözetimli bir veri madenciliği tekniği olan bu yöntemlerde, bilinen kayıtların bulunduğu veritabanı oluşturulur ve sistem yeni gelen bir kayda komşu olan diğer kayıtları belirler ve bu kayıtları kullanarak tahminde bulunur ya da bir sınıflandırma yapar.

Bellek tabanlı yöntemlerin en önemli özelliği veriyi olduğu gibi kullanabilme yeteneğidir. Diğer veri madenciliği yöntemlerinin aksine bu yöntemler kayıtların biçimi yerine sadece iki kayıt arasındaki uzaklığı belirleyen bir uzaklık fonksiyonu ve komşu kayıtları işleyerek bir sonuç üreten bir kombinasyon fonksiyonunun varlığı ile ilgilenir.

Bellek tabanlı yöntemler sahtekarlık tespiti, müşteri tepki tahmini ve klinik işlemler gibi bir çok alanda kullanılabilir.

Günümüzde bilgisayarların ucuzlaması ve kapasitelerinin artmasıyla, özellikle de çok işlemcili sistemlerin yaygınlaşmasıyla, kullanılabilir olmuşlardır. Bu yöntem en iyi örnek en yakın-k komşu algoritmasıdır [43].

Bu yöntemlerin güçlü olduğu noktalar şunlardır:

- Kolayca anlaşılabilir sonuçlar üretmesi,
- Rastgele seçilen, hatta ilişkisiz dahi olabilen verilere uygulanabilirliği,
- Analiz alanlarının çok olduğu durumlarda bile verimli olarak çalışabilmesi,
- Eğitim kümesinin oluşturulmasının basitliği.

Bu yöntemlerin zayıf olduğu noktalar şunlardır:

- Sınıflandırma ve kestirim işlemleri için kullanıldığında işlem maliyeti yüksekliği,
- Eğitim kümesi için ihtiyaç duyulan büyük miktardaki yer,
- Üretilen sonuçların seçilen uzaklık, kombinasyon fonksiyonlarına ve komşu adedine doğrudan bağlı oluşu [42].

### 3.5.3. İlişkisel analiz

İş dünyası, insanların, mekanların ve bütün her şeyin birbirleri ile bağlantı kurduğu bir ilişkiler dünyasıdır. Havayolu şirketleri, kargo şirketleri ve benzeri firmalar şehirleri birbirlerine bağlar. Haberleşme şirketleri aracılığı ile müşterileri birbirleri arasında telefon ve benzeri şekillerde bağlantı kurarlar. Benzer şeklide ilişkiler her alanda bolca bulunmaktadır ve bu ilişkiler bir çok veri madenciliği tekniğinin kullanamayacağı kadar zengin bilgi içermektedir. Burada, matematiğin bir alt alanı olan “Graf teorisi” tabanlı ilişkisel analiz devreye girer. Buna rağmen bu yöntem de her türlü sorunu çözemez ya da her türlü veri üzerinde uygulanamaz.

İlişkisel analizi gerçekleştirmek için birkaç yazılım bulunmaktadır ve bu yazılımların bir çoğu hukuksal alanda özelleşmişlerdir. En basit ilişkisel analiz aracı olarak ise ilişkisel veritabanları üzerinde kullanılan SQL gösterilebilir.

Bu yöntemin uygulanmasında ki bir diğer sorun ise maddeler arasındaki ilişkilerin ortaya çıkarılmasıdır. Telefon çağrılarının analizinde ilişkiler açıktır; bir kişi bir diğerini

arar ve burada çağrının kendisi ilişkidir. Ancak her durumda ilişkileri bulmak o kadar kolay olmadığından bulunabilmeleri için otomatikleşmiş bazı işlemler gerekebilir [41].

#### 3.5.4. Karar ağaçları ve kural türetme

Tahmin edici ve tanımlayıcı özelliklere sahip olan karar ağaçları, veri madenciliğinde kuruluşlarının ucuz olması, yorumlanmalarının kolay olması, veritabanı sistemleri ile kolayca entegre edilebilmeleri, güvenilirliklerinin iyi olması nedenleri ile sınıflama modelleri içerisinde en yaygın kullanıma sahip sınıflandırma ve öngörü araçlarından biridir [41]. Bu yöntemin sık kullanılmasının nedeni yapay sinir ağlarının tersine ağaç yapılarının kuralları ifade edebilmesinden kaynaklanmaktadır. Kurallar insanların okuyup anlayabileceği herhangi bir dile çevrilebileceği gibi, bir veritabanında belirli bir kategoriye düşen kayıtların getirilmesi için bir SQL cümleciği haline de getirilebilir.

Sık oynanan bazı oyunlarda olduğu gibi, karar ağaçları bir dizi soru ve bunların cevapları doğrultusunda hareket ederek en kısa sürede sonuca gider. Sorulan bir sorunun cevabı ile sorulacak olan diğer sorular belirlenir. Yeni gelen bir kaydın sınıflandırılması işlemi en az sayıda soru sorularak gerçekleştirilmesi için soruların iyi seçilmesi gerekmektedir. Sorulacak sorular ve bu sorulara gelebilecek cevapların yönlendireceği başka soruların bulunduğu bir ağaç yapısı olarak tanımlanan karar ağaçları ile değerlendirme yaparken, yeni gelen her kayıt ağacın köküne gider. Kökte test edilen bu yeni kayıt, bu test sonucuna göre bir alt düğüme gönderilir. Bu süreç yeni kayıt herhangi bir yaprak düğüme gelene kadar devam eder. Ağacın belirli bir yaprağına gelen bütün yeni kayıtlar aynı şekilde sınıflandırılır. Kökten her bir yaprağına giden tek bir yol vardır ve bu yol kayıtları sınıflandırmak için kullanılan bir kuralı tanımlamaktadır. Bazı yapraklar aynı sınıflandırmayı yapabilir ancak her bir yaprak bu sınıflandırmayı farklı nedenlere dayanarak yapar [42].

İstatistiksel yöntemlerde veya yapay sinir ağlarında veriden bir fonksiyon öğrenildikten sonra bu fonksiyonun insanlar tarafından anlaşılabilir bir kural olarak yorumlanması zordur. Karar ağaçları ise veriden oluşturulduktan sonra ağaç kökten yaprağına doğru

inilerek kurallar (IF-THEN rules) yazılabilir. Bu şekilde kural çıkarma (rule extraction), veri madenciliği çalışmasının sonucunun doğrulanmasını sağlar. Bu kurallar uygulama konusunda uzman bir kişiye gösterilerek sonucun anlamlı olup olmadığı denetlenebilir. Sonradan başka bir teknik kullanılacak bile olsa, karar ağacı ile önce bir kısa çalışma yapmak, önemli değişkenler ve yaklaşık kurallar konusunda analiste bilgi verir ve daha sonraki analizler için yol gösterici olabilir [43].

Karar ağaçlarının güçlü olduğu noktalar şunlardır:

- Kolayca anlaşılabilir sonuçlar üretmesi,
- Çok sayıda işlem yapılmasına gerek duymadan sınıflandırmanın yapılması,
- Hem sayısal hem de kategorik veriler üzerinde işlem yapılabilmesi,
- Hangi alanların sınıflandırma ve kestirim için daha önemli olduğunu açık biçimde belirtmesi.

Karar ağaçlarının zayıf olduğu noktalar şunlardır:

- Tahmin için kullanıldıklarında tahmin edilecek değişkenin sürekli değerler alması durumunda uygun sonuçlar üretememesi.

### **3.5.5. Yapay sinir ağları**

İnsanlığın doğayı araştırma ve taklit etme çabalarının en son ürünlerinden bir tanesi yapay sinir ağları (YSA) teknolojisidir. Yapay sinir ağları, basit biyolojik sinir sisteminin çalışma şeklini simüle etmek için tasarlanan programlardır. Simüle edilen sinir hücreleri (nöronlar) içerirler ve bu nöronlar çeşitli şekillerde birbirlerine bağlanarak ağı oluştururlar. Bu ağlar öğrenme, hafızaya alma ve veriler arasındaki ilişkiyi ortaya çıkarma kapasitesine sahiptirler. Diğer bir ifadeyle, YSA normalde bir insanın düşünme ve gözlemlemeye yönelik doğal yeteneklerini gerektiren problemlere çözüm üretmektedir.



Öğrenme, eğitime yoluyla örnekler kullanarak olur; başka bir deyişle, gerçekleşme girdi/çıktı verilerinin işlenmesiyle, yani eğitime algoritmasının bu verileri kullanarak bağlantı ağırlıklarını (weights of the synapses) bir yakınsama sağlanana kadar, tekrar tekrar ayarlamasıyla olur.

YSA, ağırlıklandırılmış şekilde birbirlerine bağlanmış bir çok işlem elemanlarından (nöronlar) oluşan matematiksel sistemlerdir. Bir işlem elemanı, aslında sık sık transfer fonksiyonu olarak anılan bir denklemdir. Bu işlem elemanı, diğer nöronlardan sinyalleri alır, bunları birleştirir, dönüştürür ve sayısal bir sonuç ortaya çıkarır. Genelde, işlem elemanları kabaca gerçek nöronlara karşılık gelirler ve bir ağ içinde birbirlerine bağlanırlar, bu yapı da sinir ağlarını oluşturmaktadır [44].

YSA'nın yaygınlığı, veri madenciliği ve karar destek sistemlerinde önceden kanıtlanmış başarılarından gelmektedir. YSA, sınıflandırma, kümeleme ve kestirim amaçları ile kolaylıkla kullanılacak genel amaçlı ve güçlü araçlardır. Ekonomik alandan tıbbi konulara, değerli müşterilerin belirlenmesi için yapılan kümeleme işlemlerinden kredi kartı sahtekarlıklarının belirlenmesine kadar çok geniş bir alanda uygulama alanı bulmuştur.

YSA'nın güçlü olduğu noktalar şunlardır:

- Çok geniş bir alandaki sorunların çözümünde kullanılabilmeleri,
- Çok karmaşık durumlarda dahi iyi sonuçlar üretebilmeleri,
- Hem sayısal hem de kategorik veriler üzerinde işlem yapabilmeleri.

YSA'nın zayıf olduğu noktalar şunlardır:

- 0 ile 1 arasında giriş verileri olması zorunluluğu,
- Ürettikleri sonuçların açıklamasının yapılamaması,
- Ulaşılan sonucun olası en iyi sonuç olma garantisinin olmaması [42].

### 3.5.6. Genetik algoritmalar

Genetik algoritmalar da YSA ve bellek tabanlı yöntemler gibi biyolojik işlemlerden kaynağını almıştır. Milyonlarca yıl süren evrim ve doğal ayrışma, çevrelerine çok büyük oranda uyum sağlamış özel türlerin hayatta kalması ile sonuçlanmıştır. Evrim, başarılı nesildeki en uygun bireylerin genetik materyallerini bir sonraki nesle geçirilmesini sağlar. Genetik algoritmalar da aynı biçimde çalışmaktadır.

Genetik algoritmalar çeşitli endüstrilerde karmaşık planlama problemlerinde, büyük fabrikalarda kaynak iyileştirmesinde ve karmaşık veri tiplerini içeren sınıflandırma problemlerinde kullanılmışlardır. En iyi yapay sinir ağı topolojisinin belirlenmesi, bellek tabanlı sistemlerde skor fonksiyonu belirlenmesinde ve yapay sinir ağlarının eğitilmelerinde gördüğümüz gibi diğer veri madenciliği algoritmaları ile birlikte de kullanılmışlardır. Buna rağmen, genetik algoritmalar genel veri madenciliği paketlerinde yaygın olarak bulunmamaktadır.

Veri madenciliği dünyasında genetik algoritmalar, diğer teknikler kadar yaygın değildir. Veri madenciliği optimizasyondan daha ziyade sınıflandırma ve kestirime odaklanır. Alışıl gelmiş bir tanımlama olmasa da veri madenciliği problemleri, optimizasyon problemleri şeklinde yapılandırılabilir [40].

Açıklanabilir sonuçlar üreten bu algoritmaların kullanımlarında bazı sıkıntılar mevcuttur. Bunların en başında karmaşık sorunların genetik olarak kodlanmasının çok zor olmasıdır. Ayrıca en iyi sonucun üretildiğine dair bir garanti de yoktur. Son olarak, çalıştırılmalarında çok ağır bir işlem yükü getirmektedir [41].

### 3.6. Veri Madenciliğinde Yeni Yaklaşımlar

Uzun yıllardır veri madenciliği problemlerinin çözümünde kullanılan genetik algoritmalar, yapay sinir ağları gibi yaklaşımların yanında, son yıllarda mühendislik

problemlerinin çözümünde de yeni yeni kullanılmaya başlanan yöntemler, veri madenciliği problemlerinin çözümünde de kullanılmaya başlanmıştır.

Yapay bağışıklık sistemi, bağışıklık sistemindeki etkileşimleri daha iyi anlayabilmek için bağışıklık sisteminin bir modelini oluşturmak ve sistemdeki olayları hesapsal araç olarak kullanabilmek amacıyla ortaya atılmıştır.

Karıncalar koloni optimizasyonu ile, yiyecek arayan ve yiyecek buldukları durumlarda diğer karıncalar için koku izleri bırakan öncü karıncaların uyguladıkları yöntemi, sanal karıncalar oluşturarak ve bilgisayarlarla benzerini yaparak çoğu problemin daha kolay çözüleceği gösterilmiştir. Yeni yeni kullanılmaya başlanmış ve tatmin edici sonuçlar alınmıştır.

Destek vektör makineleri yeni bir öğrenme yöntemidir. Veri madenciliği alanındaki pratik problemlerde iyi sonuçlar verdiği bulunmuştur.

Veri madenciliğinde, kümelemede, kestirimde ve zaman verisinin kullanıldığı durumlarda, birliktelik kural keşfinde kullanılan kaos kuramı ile endüstriyel alanlarda çoğu işlemlerin doğrusal olmamasından dolayı kaotik işlemlerin tahmini yapılmaya çalışılmaktadır [45].

## BÖLÜM 4. BULANIK MANTIK

### 4.1. Giriş ve Tarihçe

Temelleri eski yunan felsefelerine dayanan, uygulamada ise yapay zekanın yönlendirici bir unsuru olan bulanık sistemler (fuzzy systems), Aristoteles'ten günümüze gelişen klasik küme üyeliğine ve mantığına karşı oluşturulmuş bir alternatiftir. Çok eskilere dayanan temellerine karşı göreceli olarak yeni bir bilim sahasıdır ve gelişimini sürdürmektedir [46].

Matematiğin doğruluğundaki ve bütünlüğündeki başarısında Aristoteles'in ve onun izinden giden düşünürlerin büyük katkısı olmuştur. Onların mantık teorisini oluşturma çabaları ile matematik gelişmiş ve "Düşüncenin Yasaları" oluşturulmuştur. Bu yasalardan biri her önermenin "Doğru" ya da "Yanlış" olması gerektiğini öngörmüştür. Bu kavramı Perminedes ilk ortaya attığı zaman bile (yaklaşık M.Ö. 400) karşı görüşlerin oluşması uzun sürmemiştir. Heraclitus bazı şeylerin aynı anda hem doğru olmasının hem de doğru olmamasının mümkün olabileceğini savunmuştur [47].

Bulanık mantığı oluşturacak temel düşünceyi Plato, "Doğru" ve "Yanlış"ın iç içe girdiği üçüncü bir durumu belirterek oluşturmuştur. Hegel ve Marx gibi modern düşünürler bu düşünceyi desteklemiş ancak ilk kez Lukasiewicz, Aristoteles'in iki-değerli mantığına sistematik bir alternatif getirmiştir [47].

1920'li yıllarda Polonyalı mantıkçı Jan Lukasiewicz, önermelerin sadece bir veya sıfır doğruluk değeri alabildiği klasik mantıktan farklı olarak önermelerin bir ve sıfır arasında da kesirli doğruluk değeri alabildiği "çok değerli" mantık ilkelerini oluşturmuştur.

1937'de ise kuantum felsefecisi Max Black, 1937'de yayımlanan bir makalesinde liste ya da nesnelere oluşan kümelerle "çok değerli mantığı" uygulayarak ilk bulanık küme eğrilerini çizmiştir [46]. Lukasiewicz ve onu izleyen diğer matematikçiler bu değerleri nümerik olarak ifade etmiş olsalar da , 1965 yılında Lotfi A. Zadeh, bu değerleri [0.0, 1.0] aralığındaki sayılarla ifade ettiği teorisini "Bulanık Mantık" adlı çalışmasında tanımlayana dek, sonsuz-değerli mantık uygulamada başarılı olamamıştır [47]. Zadeh'in çığır açan bu makalesinde, bir kümenin tüm elemanlarına Lukasiewicz'in mantığını uygulayarak bulanık kümeler için eksiksiz bir cebir geliştirilmiştir. Buna rağmen, 1974'de İngiltere'de Ebrahim H. Mamdani'nin bir buhar makinesi için bulanık mantıkla çalışan bir kontrol sistemi gerçekleştirdiği 1970'li yılların ortalarına dek bulanık kümeler kullanım alanı bulamamıştır [46]. Daha sonra Hans Zimmermann bulanık mantığı karar destek sistemleri için kullanmıştır. Bulanık mantığa "çok değerli mantık" veya "sürekli mantık" isimleri de verilmiş ama sanayide geniş bir kabul görmemiştir [48].

Bulanık mantık, 1980'lerde Avrupa'da karar destek ve veri analizi uygulamalarında daha fazla önem kazanmış ve uygulama ve araştırma projelerinde ileri seviye bulanık mantık teknolojileri geliştirilmiştir.

1980'lerde Avrupa'daki bulanık mantık uygulamalarından esinlenen Japon şirketler, bulanık mantığı kontrol mühendisliğinde kullanmaya başlamışlardır. 1983'de bir su arıtma tesisinde Fuji Elektrik ve 1987'de açılan metro sisteminde Hitachi tarafından kullanılmıştır. İlk bulanık mantık algoritmalarının standart donanımlar üzerindeki zayıf sayısal performansları nedeni ile uygulamaların bir çoğu bulanık mantık donanımı içermiştir.

Bulanık mantık hızlı prototip oluşturma ve artan bir optimizasyon sağlarken, sistemi sürekli anlaşılabilir bir biçimde sade ve basit kalmaktadır. Sonuç olarak bulanık mantık şimdilerde hemen hemen tüm veri işleme ve akıllı kontrol sistemlerinde kullanılmaktadır. Fotoğraf ve video kameralardan, Mitsubishi'nin duyurduğu her bir

kontrolü bulanık sistem esaslı dünyanın ilk arabasına kadar bir çok alanda yaygınlaşmıştır. Fabrika otomasyonunda Omron şirketi 350'den fazla patent alırken bir çok kimyasal ve biyolojik süreç bulanık mantık ile iyileştirilmiştir.

Avrupalı şirketler anahtar bir teknolojiyi Japonya'ya kaptırdıklarını anladıklarında uygulamalarında bulanık mantığı kullanmak için daha fazla gayret göstermişlerdir. Şimdilerde pazardaki bir çok üründe bulanık mantık başarılı bir biçimde uygulanmış ve sayısız sanayi otomasyonu ve süreç kontrol uygulamalarında başarılı bir biçimde kullanılmaktadır. Bu uygulamaların pazar başarısından sonra bulanık mantık, standart bir tasarım tekniği haline gelmiş ve mühendislik topluluklarında geniş bir kabul görmüştür [48].


O tarihten sonra önemi gittikçe artarak günümüze kadar gelen bulanık mantık, belirsizliklerin anlatımı ve belirsizliklerle çalışılabilmesi için kurulmuş katı bir matematik düzen olarak tanımlanabilir. Bilindiği gibi istatistikte ve olasılık kuramında, belirsizliklerle değil kesinliklerle çalışılır. Ama insanın yaşadığı ortam daha çok belirsizliklerle doludur. Bu yüzden insanoğlunun sonuç çıkarabilme yeteneğini anlayabilmek için belirsizliklerle çalışmak gereklidir.

Bulanık mantık ilk olarak Amerika'da keşfedilmiş olmasına rağmen teknolojinin hızlı ilerleyişi Japonya'dan başlayıp tekrar Amerika'ya ve Avrupa'ya ulaşmıştır. Bulanık mantık hala Japonya'da hızlı bir ilerleme seyri sürdürmektedir. Basit bulanık kontrol kurallarının kullanıldığı uygulamalarda “fuzzy” kelimesi pazarlamada anahtar kelime durumuna gelmiş durumdadır [46].

## 4.2. Bulanık Küme Teorisi

Bulanık mantığın temeli bulanık küme ve alt kümelerine dayanır. Klasik yaklaşımda bir varlık ya kümenin elemanıdır ya da değildir. Matematiksel olarak ifade edildiğinde varlık, küme ile olan üyelik ilişkisi bakımından kümenin elemanı olduğunda (1), kümenin elemanı olmadığına (0) değerini alır. Örnek olarak normal oda sıcaklığını 23 derece olarak kabul edersek, klasik küme kuramına göre 23 derecenin üzerindeki sıcaklık derecelerini sıcak olarak kabul ederiz ve bu derecelerin sıcak kümesindeki üyelik dereceleri (1) olur. 23 altındaki sıcaklık dereceleri ise soğuktur ve sıcak kümesindeki üyelik dereceleri (0) olur. Soğuk kümesini temel aldığımızda bu değerler tersine döner.

Bulanık mantık klasik küme gösteriminin genişletilmesidir. Bulanık varlık kümesinde her bir varlığın üyelik derecesi vardır. Varlıkların üyelik derecesi,  $[0,1]$  aralığında herhangi bir değer olabilir. Yukarıdaki örnek üzerinden; 14 derecelik sıcaklık için üyelik derecesi (0), 23 sıcaklık derecesi için üyelik değeri (0,25) olabilir.



Şekil 4.1. Dilsel değerlerin klasik ve bulanık küme üzerindeki gösterimi [49]

Klasik kümelerin aksine bulanık kümelere elemanların üyelik dereceleri  $[0, 1]$  aralığında sonsuz sayıda değişebilir. Bunlar üyelik derecelerinin devamlı ve aralıksız bütünüyle bir kümedir. Keskin kümelere soğuk-sıcak, hızlı-yavaş, aydınlık-karanlık

gibi ikili deęişkenler, bulanık mantıkta biraz soęuk, biraz sıcak, biraz karanlık gibi esnek niteleyicilerle yumuřatılarak gerek dnyaya benzetilir. En nemli fark, byle bir atıda bilginin kaynaęındaki kme yelięinin kesin tanımlanmıř nkořullarının olmayıřı ve daha ok problemlerle rastgele deęişkenlerin hazır bulunmasındadır [50].

#### 4.2.1 Temel kavramlar ve terimler

İnsan beyni "aık yeřil", "serin hava" veya "yksek hız" gibi matematiksel olarak kesin olmayan belirsiz ya da deęer yargıları ieren "bulanık dilsel niteleyicileri" kullanarak saęduyulu kararlar verebilir ve sonu ıkartabilir. Bulanık mantık, temel olarak yaklařıklık ve kesin olmama gibi insan dřncesinde ve doęada var olan belirsizlięi kullanmaktadır ve kesin doęru veya kesin yanlıř yerine, doęal derece doęru ya da yanlıřlık belirten tanımlar kullanır. Bylelikle bulanık mantıkta, gnlk konuřmalarda kullanılan belirsiz ifadeler tanımlanabilmekte ve bu dilsel niteleyiciler kullanılarak insan benzeri sonu ıkarma iřlemleri gereklenebilmektedir. Bu sayede bulanık mantık, bilgisayarlarla dolayısıyla kontrol sistemlerine insan dřnme ve karar verebilme yeteneęinin kazandırılmasında bařarılı bir yol saęlamaktadır.

Bulanık kme kuramı, bir elemanın bir kmeye kısmi yelięine olanak saęlar. Eęer yelik derecesi olarak adlandırılan yelik fonksiyonunun deęeri bire eřitse  $x$  elemanı bulanık kmeye tamamen aittir. Eęer bu deęer sıfır ise,  $x$  bulanık kmeye ait deęildir. Eęer yelik derecesi sıfır ile bir arasında ise  $x$  bulanık kmenin kısmi yesidir. Bulanık kme literatrnde, genellikle kesin terimi, bulanık olmayan byklkleri belirtmek iin kullanılır. rneęin; kesin sayı, kesin kme, vb. [51].

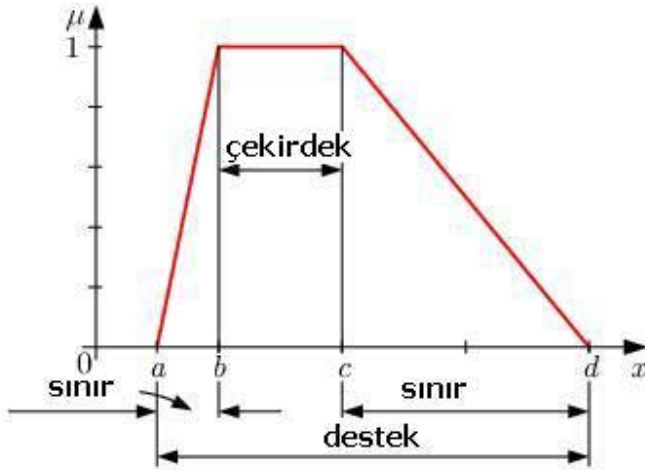
Bulanık kme,  $X$  evrensel tanım kmesi zerinde  $A$  bulanık kmesi,  $X$  uzayından birim aralıęa bir dnřm olan  $\mu_A(x)$  yelik fonksiyonları ile tanımlanır:



$$\mu_A(x) : X \rightarrow [0,1] \quad (4.1)$$

F(X) ile X uzayındaki tüm bulanık kümeler gösterilir. Eşitlikteki  $\mu_A(x)$  üyelik fonksiyonudur.

Bir girdi değerinin, dilsel değişkenin bir terimine ne derecede ait olduğunu belirleyen değere üyelik derecesi (degree of membership) denir. Dilsel değişkenin tümü için bu değerler, bir fonksiyon olarak, üyelik fonksiyonu (membership function) veya bulanık sayı (fuzzy number) olarak adlandırılır [51]. Bir başka deyişle üyelik fonksiyonu X'in her elemanını 0 ile 1 arasındaki bir üyelik derecesine eşitler [53].



Şekil 4.2. Üyelik fonksiyonun bazı özellikleri [54]

Bir bulanık kümenin desteği (support), X'deki bütün x noktalarının  $(\mu_A(x)) > 0$  olduğu kümedir [55].

$$\text{destek}(A) = \{x \mid \mu_A(x) > 0\} \quad (4.2)$$

Bir bulanık kümenin çekirdeği (core),  $X$ 'deki bütün  $x$  noktalarının  $(\mu_A(x)) = 1$  olduğu kümedir [55].

$$\text{çekirdek}(A) = \{x \mid \mu_A(x) = 1\} \quad (4.3)$$

Bir  $A$  bulanık kümesinin en az bir elemanı 1 değerini alıyor ise bu bulanık küme normal (olağan) bulanık kümedir [56].  $X$ 'de  $\mu_A(x) = 1$  ile sadece bir noktayı destekleyen  $A$  bulanık kümesi bulanık tekil (fuzzy singleton) olarak adlandırılır [55]. Bunlar dışında kalan bulanık kümelere ise normal dışı (subnormal) bulanık kümeler denir [56].

Bir  $A$  bulanık kümesinin çapraz geçiş noktaları (crossover points),  $\mu_A(x) = 0.5$  olduğu  $x \in X$  noktalarıdır [55].

$$\text{çaprazgeçiş}(A) = \{x \mid \mu_A(x) = 0.5\} \quad (4.4)$$

Bir bulanık kümenin üyelik değerleri monoton artan ve daha sonra monoton azalan bir durumda ya da belirli üyelik değerlerinde 1 olduktan sonra monoton azalan ise bu kümelere dışbükey bulanık kümeler (convex fuzzy sets) adı verilir [56]. Normal ve dışbükey bir bulanık küme için bant genişliği veya genişlik, çapraz geçiş noktaları arasındaki mesafe olarak tanımlanır [53].

$$\text{bantgen}(A) = |x_2 - x_1|; \mu_A(x_1) = \mu_A(x_2) = 0.5 \quad (4.5)$$

Bir A bulanık kümesinde eğer üyelik fonksiyonu belirli bir  $x = c$  noktasına göre sağda ve solda eşit dağılımlı ise bu küme simetriktir [53].

$$\mu_A(c+x) = \mu_A(c-x) \quad ; \quad \text{bütün } x \in X \quad \text{için} \quad (4.6)$$

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 [53].

## 4.2.2. Bulanık küme işlemleri

### 4.2.2.1. Kapsama

Sadece ve sadece bütün  $x$ 'ler için  $\mu_A(x) \leq \mu_B(x)$  ise A kümesi B kümesi tarafından kapsanmaktadır (A kümesi B kümesinin alt kümesidir) [55].


$$A \subseteq B \Leftrightarrow \mu_A(x) \leq \mu_B(x) \quad (4.7)$$

### 4.2.2.2. Birleşim

Üyelik fonksiyonları arasındaki ilişki 4.8'deki eşitlik ile verilen A ve B bulanık kümelerini birleşimi olan C bulanık kümesi  $C = A \cup B$  ya da  $C = A \text{ VEYA } B$  ile ifade edilir [55]. T-konorm işlemleri olarak da bilinir [57].

$$\mu_C(x) = \max(\mu_A(x), \mu_B(x)) = \mu_A(x) \vee \mu_B(x) \quad (4.8)$$

- (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 4.3. Yaygın kullanılan birleşim (VEYA) operatörleri [57]

#### 4.2.2.3. Kesişim

Üyelik fonksiyonları arasındaki ilişki 4.9'daki eşitlik ile verilen A ve B bulanık kümelerini birleşimi olan C bulanık kümesi  $C = A \cap B$  ya da  $C = A \text{ VE } B$  ile ifade edilir [55]. T-norm işlemleri olarak da bilinir [57].

$$\mu_C(x) = \min(\mu_A(x), \mu_B(x)) = \mu_A(x) \wedge \mu_B(x) \quad (4.9)$$

- (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 4.4. Yaygın kullanılan kesişim (VE) operatörleri [57]

#### 4.2.2.4. Tümlen

Bir A bulanık kümesinin tümlenini  $\bar{A}$  ile gösterilir ve aşağıdaki eşitlik ile ifade edilir.

$$\mu_{\bar{A}}(x) = 1 - \mu_A(x) \quad (4.10)$$

#### 4.2.3 Bazı bulanık küme kuralları

Bulanık kümelerdeki bazı kurallar aşağıda verilmiştir.

- Eğer  $\forall x \in X$  için  $\mu_A(x) = \mu_B(x)$  ise  $A = B$  'dir.
- Eğer  $\forall x \in X$  için  $\mu(x) = 0$  ise  $A$  kümesi boş kümedir.
- Eğer  $\forall x \in X$  için  $\mu_A(x) = 1$  ise  $A$  kümesi  $X$  uzayına eşittir (evrensel küme).
- Bir A bulanık kümesinin boş küme ile birleşimi kendisine eşittir ( $A \cup 0 = A$ ).
- Bir A bulanık kümesinin evrensel küme ile birleşimi evrensel kümeyle eşittir ( $A \cup X = X$ ).
- Bir A bulanık kümesinin boş küme ile kesişimi boş kümedir ( $A \cap 0 = 0$ ).
- Bir A bulanık kümesinin evrensel küme ile kesişimi A bulanık kümesine eşittir ( $A \cap X = A$ ).
- İki küme kesişimi kümelerin altkümeleri ve kümeler de iki küme birleşiminin alt kümesidir ( $A \cap B \subseteq A \subseteq A \cup B$ ).
- Bulanık küme işlemlerinde birleşebilirlik 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 kümesi ve tümleninin kesişimi boş küme değildir ( $A' \cap A \neq 0$ ).
- Bir A bulanık kümesi ve tümleninin birleşimi evrensel küme değildir ( $A' \cup A \neq X$ ).

- 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  $A \cup (B \cap C) = (A \cup B) \cap (A \cup C)$ ) [51].

#### 4.2.4. Üyelik fonksiyonları

##### 4.2.4.1. Üçgen üyelik fonksiyonları

{a,b,c} parametreleri ile tanımlanmış bir üçgen üyelik fonksiyonu 4.11 eşitliği ile tanımlanmakta ve şekil 4.5a'da görülmektedir [55].

$$y = \text{üçgen}(x; a, b, c) = \begin{cases} 0, & x \leq a \\ (x-a)/(b-a), & a \leq x \leq b \\ (c-x)/(c-b), & b \leq x \leq c \\ 0, & c \leq x \end{cases} \quad (4.11)$$

4.11 numaralı eşitlikteki ifade min-max işlemleri kullanılarak aşağıdaki eşitlik ile gösterilebilir [53].

$$y = \text{üçgen}(x; a, b, c) = \max\left(\min\left(\frac{x-a}{b-a}, \frac{c-x}{c-b}\right), 0\right) \quad (4.12)$$

$a < b < c$  olmak üzere {a,b,c} parametreleri üçgen üyelik fonksiyonun üç köşesinin x koordinatlarını belirler [55].

#### 4.2.4.2. Yamuk üyelik fonksiyonları

$\{a,b,c,d\}$  parametreleri ile tanımlanmış bir yamuk üyelik fonksiyonu 4.13 eşitliği ile tanımlanmakta ve şekil 4.5b'de görülmektedir [55].

$$y = yamuk(x; a, b, c, d) = \begin{cases} 0, & x \leq a \\ (x-a)/(b-a), & a \leq x \leq b \\ 1, & b \leq x \leq c \\ (d-x)/(d-c), & c \leq x \leq d \\ 0, & d \leq x \end{cases} \quad (4.13)$$

4.13 numaralı eşitlikteki ifade min-max işlemleri kullanılarak aşağıdaki eşitlik ile gösterilebilir [53].

$$y = yamuk(x; a, b, c) = \max\left(\min\left(\frac{x-a}{b-a}, 1, \frac{d-x}{d-c}\right), 0\right) \quad (4.14)$$

$a < b < c < d$  olmak üzere  $\{a,b,c,d\}$  parametreleri yamuk üyelik fonksiyonun dört köşesinin x koordinatlarını belirler.

Basit formülleri ve hesaplama verimlilikleri ile üçgen ve yamuk üyelik fonksiyonları özellikle gerçek zamanlı uygulamalarda olmak üzere geniş ölçüde kullanılmıştır. Ancak bu fonksiyonlar düz çizgi parçalarından oluştuğu için parametreler ile belirlenen köşe noktalarında pürüzsüz değildirler [55].

#### 4.2.4.3. Gaussian üyelik fonksiyonları

$\{c, \sigma\}$  parametreleri ile tanımlanmış bir gaussian üyelik fonksiyonu 4.15 eşitliği ile tanımlanmakta ve şekil 4.5c'de görülmektedir [55].

$$gaussian(x; c, \sigma) = e^{-\frac{(x-c)^2}{2\sigma}} \quad (4.15)$$

Bir gaussian fonksiyonu tamamen  $\{c, \sigma\}$  parametreleri ile belirlenirken,  $c$  üyelik fonksiyonun merkezini,  $\sigma$  ise genişliğini belirler.

#### 4.2.4.4. Genelleştirilmiş çan üyelik fonksiyonları

$\{a, b, c\}$  parametreleri ile tanımlanmış ve genelde  $b$  parametresinin pozitif olduğu bir genelleştirilmiş çan üyelik fonksiyonu 4.16 eşitliği ile tanımlanmakta ve şekil 4.5d'de görülmektedir [55].

$$\zeta an(x; a, b, c) = \frac{1}{1 + \left| \frac{(x-c)}{a} \right|^{2b}} \quad (4.16)$$

Olasılık teorisindeki Cauchy dağılımının doğrudan genelleştirilmiş şekli olan bu üyelik fonksiyonu bu nedenle Cauchy üyelik fonksiyonu olarak da bilinir [55].

Yumuşak geçiş ve basit denklem parametreleri ile Gaussian ve çan üyelik fonksiyonları bulanık kümeleri tanımlamada sıklıkla kullanılmaktadır. Çan üyelik fonksiyonu, Gaussian üyelik fonksiyonuna göre daha fazla parametre içermektedir. Çekirdek kısmının genişliğinin değiştirilebilmesi ve çapraz geçiş noktalarının eğimlerinin kontrolü için fazladan bir parametre kullanılması sonucunda eğimin daha hassas ayarlanabilmesi sağlanmış ve gaussian üyelik fonksiyonuna üstünlük sağlamıştır [53].

#### 4.2.4.5. Sigmoid üyelik fonksiyonları

Gaussian ve çan üyelik fonksiyonları yumuşak geçişli olmalarına rağmen simetrikler ve simetrik olmayan üyelik fonksiyonlarının tanımlamalarında kullanılamazlar. Bu

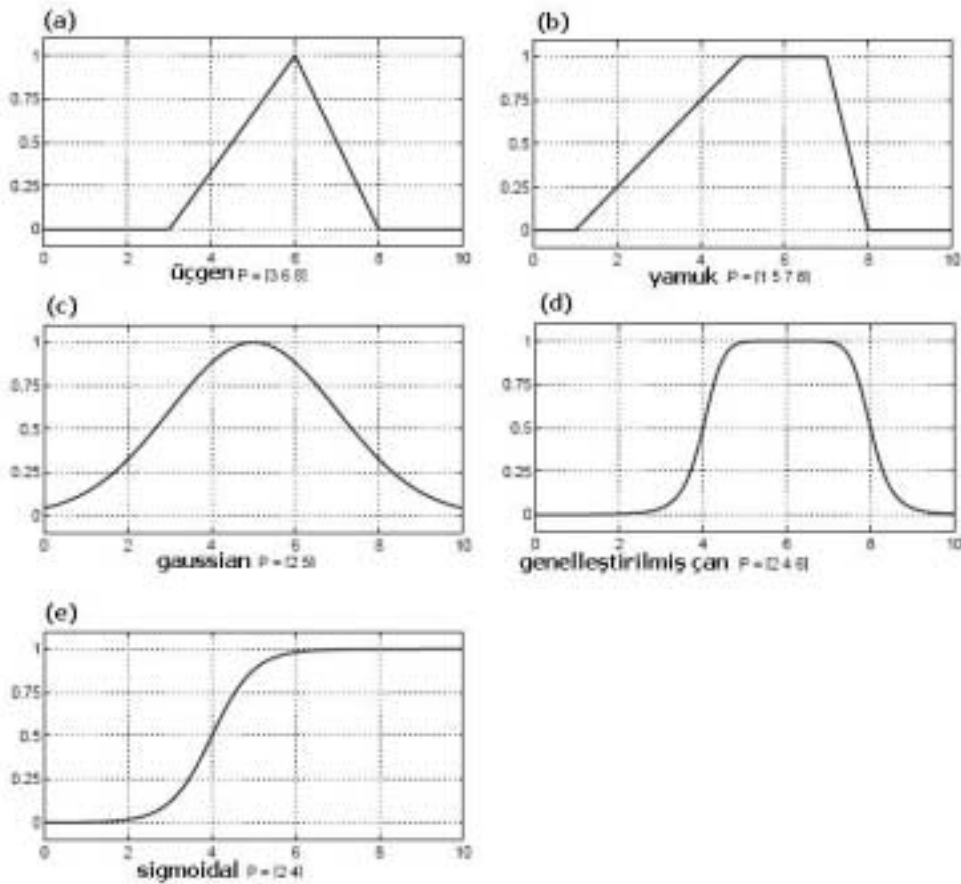


durumlarda sigmoid üyelik fonksiyonu veya birkaç sigmoid üyelik fonksiyonunun işleme tabi tutularak elde edilmiş olan üyelik fonksiyonu kullanılır.

{a,c} parametreleri ile tanımlanmış ve bir sigmoid üyelik fonksiyonu 4.17 eşitliği ile tanımlanmakta ve şekil 4.5'e görülmektedir [55].

$$\text{sig}(x; a, c) = \frac{1}{1 + e^{-a(x-c)}} \quad (4.17)$$

Burada a, x=c'deki çarpaz geçiş noktasının eğimini kontrol eder. Bu değişkenin işaretine bağlı olarak üyelik fonksiyonu sağdan veya soldan açık olarak değişebilir.



Şekil 4.5. Üyelik fonksiyonları [49]

### 4.3. Bulanık Yargılama

#### 4.3.1 Bulanık eğer-ise kuralları

Bir bulanık eğer-ise kuralı (bulanık kural, bulanık içerik veya bulanık koşullu ifadeler olarak da bilinir) “eğer  $x$   $A$  ise,  $y$   $B$ 'dir” şeklinde varsayılır ve burada  $A$  ve  $B$ , sırasıyla  $X$  ve  $Y$  uzaylarında bulanık kümelerce tanımlı dilsel değişkenlerdir. Genellikle “ $x$   $A$ ” ifadesi koşul (antecedent), “ $y$   $B$ 'dir” ifadesi de sonuç (consequence) olarak adlandırılır.

Bulanık eğer-ise kurallarına günlük dilsel ifadelerimizden örnekleri aşağıdaki gibi verilebilir [55].

- Eğer basınç yüksek ise, hacim küçüktür.
- Eğer yol kaygan ise, araç kullanmak tehlikelidir.
- Eğer hız yüksek ise, yavaş fren yap.

Eğer basınç yüksek ise, hacim küçüktür örneğini ele alacak olursak dikkat edilmelidir ki; basınç 0 ile 1 arasındaki bir sayıyı ifade eder ve bu yüzden koşul 0 ile 1 arasında tek bir sayı döndüren bir gösterimdir. Diğer yandan hacim de bir bulanık küme ile ifade edilir ve bu yüzden sonuç tüm  $B$  bulanık kümesini çıkış değişkeni  $y$ 'ye atayan bir atamadır [49].

Bir sistemin modellenmesi ve analizinde 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 gösterim,  $x$  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 birleştirilmiştir şeklinde yorumlarsak;

$$R = A \rightarrow B = A \times B = \int_{x \ x \ y} \mu_A(x) \tilde{*} \mu_B(y) / (x, y) \quad (4.18)$$

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

$$R = A \rightarrow B = \overline{A} \cup B \quad (4.19)$$

$$R = A \rightarrow B = \overline{A} \cup (A \cap B) \quad (4.20)$$

Her ne kadar bu denklemler görünüşte farklı da olsa, A ve B iki değerli mantık önermeleri olduğunda, her ikisinde bilinen  $A \rightarrow B \equiv \overline{A} \cup B$  özdeşliğine indirgenir [55].

### 4.3.2. Bulanık yargılama

Yaklaşık yargılama olarak da bilinen bulanık yargılama, olgular adı ile bilinen bir bulanık eğer-ise kurallar kümesinden sonuçlar türetmek için bir çıkarım yöntemidir. Geleneksel iki değerli mantıkta çıkarımın temel kuralı  $A \rightarrow B$  ile gösterilen, A'nın doğruluğundan B önermesinin doğruluğunu çıkarabileceğimiz durum doğrulamadır (modus ponens). Bu kavram aşağıdaki gibi örneklendirilmiştir.

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

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 örneklendirecek olursak;

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

$A, A', B$  ve  $B'$  uygun uzayların bulanık kümeleri iken, yapılan bu çıkarım “yaklaşık yargılama” veya “bulanık yargılama” olarak adlandırılır. Aynı zamanda özel bir durum olarak durum doğrulama içerdiği için “genelleştirilmiş durum doğrulama” olarak da adlandırılır.

$A$  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.

$$\mu_{B'}(y) = \max_x \min[\mu_{A'}(x), \mu_R(x, y)] = V_x [\mu_{A'}(x) \wedge \mu_R(x, y)] \quad (4.21)$$

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

En kolay durum olan “tek koşullu tek kural” için eşitlik 4.21'deki gibidir. Bu eşitliğin ileriki sadeleştirilmesi, eşitliği aşağıdaki duruma dönüştürür.

$$\mu_{B'}(y) = V_x [\mu_{A'}(x) \wedge \mu_A(y)] \wedge \mu_B(y) = \omega \wedge \mu_B(y) \quad (4.22)$$

Diğer bir deyişle, öncelikle uyum derecesi olan  $\omega$ ,  $\mu_{A'}(x) \wedge \mu_A(y)$  işleminin en büyük değeri olarak bulunur ve sonuç olan  $B'$ 'nin üyelik fonksiyonu  $B$ 'nin  $\omega$  ile kırılmış üyelik fonksiyonuna eşittir. Sezgisel olarak,  $\omega$ , kuralın koşul kısmına olan inancın derecesinin ölçümünü gösterir. Bu ölçüm, eğer-ise kuralları tarafından dağıtılarak sonuçta oluşacak inanç derecesinin veya sonucun üyelik fonksiyonunun  $\omega$ 'dan büyük olmamasını sağlar.

Genelleme yapılarak “çok koşullu çok kurallar” için bulanık yargılama veya yaklaşık yargılama dört aşamaya bölünmüştür.

Uygunluk derecesi: her koşulun üyelik derecesine göre uygunluk derecesinin bulunabilmesi için bulanık kuralların koşulları ile bilinen olgular karşılaştırılır.

Tetikleme Gücü: uygunluk dereceleri, kuraldaki hangi koşul parçasının sağlandığını gösteren bir derece olan tetikleme gücünü oluşturmak için bulanık VE veya VEYA operatörleri kullanılarak bir kuraldaki koşulların üyelik derecelerine göre birleştirilir.

Nitelikli sonuç üyelik fonksiyonları: nitelikli sonuç üyelik fonksiyonunun oluşturulması için kuralın sonuç üyelik fonksiyonunda bulunan tetikleme gücü uygulanır.

Genel çıkış üyelik fonksiyonu: genel çıkış üyelik fonksiyonunun elde edilebilmesi için bütün nitelendirilmiş sonuç üyelik fonksiyonları birleştirilir.

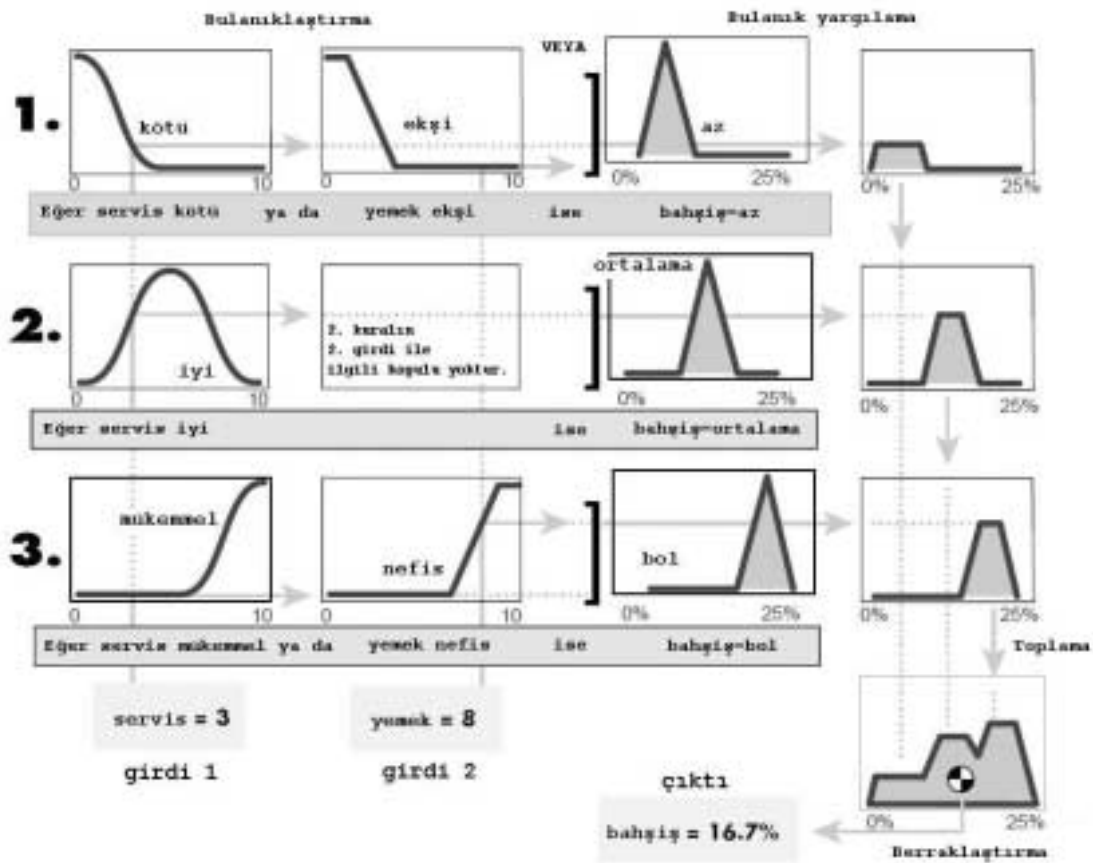
#### **4.4. Bulanık Çıkarım Sistemleri**

Bulanık çıkarım, verilen girdiler ile çıktılar arasındaki eşlemenin bulanık mantık kullanarak kesin ve açık olarak belirtme işlemidir. Eşleme, daha sonra karar vermenin yapılabildiği veya örüntülerin ayıt edilebildiği bir temel sağlar. Bulanık çıkarım işlemi, üyelik fonksiyonları, bulanık mantık işlemleri ve eğer-ise kuralları gibi yukarıda bahsedilen her konuyu içerir. Üç tipte bulanık çıkarım sistemi vardır. Bunlar Mamdani, Sugeno (Takagi-Sugeno) ve Tsukamoto bulanık modelleridir.

Bulanık çıkarım sistemleri otomatik kontrol, veri sınıflandırma, karar analizi, uzman sistemler ve bilgisayar görmesi alanlarında başarılı bir biçimde uygulamıştır. Disiplinler arası olan doğası nedeni ile bulanık çıkarım sistemleri bulanık-kural-tabanlı sistemler, bulanık uzman sistemler, bulanık modelleme, bulanık çağrışımlı bellek, bulanık mantık kontrolörleri ve basit olarak bulanık sistemler olarak farklı isimlendirmeye sahiptir.



Şekil 4.6. Bulanık çıkarım sistemi [58]




Şekil 4.7. Bir örnek üzerinden Mamdani bulanık çıkarım sisteminde adımlar [49]

Şekil 4.6 üzerinden gidecek olursak bir bulanık çıkarım sisteminde öncelikle gerçek değişkenlerin bulanık kümeler ve üyelik fonksiyonları kullanılarak dilsel değişkenlere dönüştürülür ve bu dönüştürülmeye bulanıklaştırma denir. Girişlerin bulanıklaştırılması ile bilgi tabanından elde edilen eğer-ise kurallarındaki her kural için her koşul parçasının ne kadar sağlandığı bilinir. Eğer verilen bir kuraldaki koşulun birden fazla parçası varsa, o kuralın koşul sonucunu ifade eden tek bir sayı elde etmek için bulanık işlemlere (VE, VEYA) tabi tutulur. Elde edilen sayı çıkış fonksiyonuna uygulanır. Her bir kuralın çıktısını ifade eden bulanık kümelerin birleştirilmesi işi olan toplama işlemi yapılır. Son olarak bulanık kümeden temsili sayısal değer elde edilmesi işlemi olan berraklaştırma (durulaştırma) yapılır [49].

#### 4.4.1. Mamdani bulanık çıkarım sistemi

Mamdani bulanık çıkarım sistemi, ilk kez bir buhar motoru ve kazan birleşiminin uzman operatörlerden elde edilen bir dilsel kontrol kuralları kümesi ile kontrolü için önerilmiştir. Şekil 4.7’de 3 kurallı bir Mamdani bulanık çıkarım sisteminde sayısal iki girdiden toplam çıkışın nasıl elde edildiği görülebilmektedir. Genel olarak kullanılan beş berraklaştırma yöntemi aşağıda incelenmiştir [55].



Şekil 4.8. Sayısal çıktı elde etmek için kullanılan farklı berraklaştırma yöntemleri [55]

#### 4.4.1.1. Alanın kitle merkezi

Alan ağırlık merkezi (Centroid-Center of Area - COA) [55] olarak da bilinen yöntemde,  $Z$  uzayında bir toplanmış çıkış üyelik fonksiyonunu gösteren  $A$  kümesi için ağırlık merkezi hesaplanır. Elde edilen ağırlık merkezinin  $Z$  uzayındaki değeri berraklaştırma işleminin sonucunu oluşturur [53].

$$Z_{COA} = \frac{\int \mu_A(z)zdz}{\int \mu_A(z)dz} \quad (4.23)$$

4.23 eşitliğinde  $\mu_A(z)$ , toplam çıkış üyelik fonksiyonudur. Bu yöntem geniş ölçüde benimsenmiş, olasılık dağılımında beklenen değerlerin hesaplanmasını andıran berraklaştırma stratejisidir [55].

#### 4.4.1.2. 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,  $Z_{BOA}$  4.24'deki matematiksel ifadeyi sağlar.

$$\int_{\alpha}^{Z_{BOA}} \mu_A(z)dz = \int_{Z_{BOA}}^{\beta} \mu_A(z)dz \quad (4.24)$$

#### 4.4.1.3. Maksimumun ortası

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



$$Z_{MOM} = \frac{\int z dz}{\int_{z'} dz}, \quad z' = \{z \mid \mu_A(z) = \mu^*\} \quad (4.25)$$

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.

#### 4.4.1.4. Maksimumun en küçüğü

Maksimumun en küçüğü yöntemi (Smallest Of Maximum-SOM)  $Z_{SOM}$  ile gösterilir. Üyelik fonksiyonunun maksimum olduğu  $z$  noktalarının en küçük olanı veren yöntemdir.

#### 4.4.1.5. Maksimumun en büyüğü

Maksimumun en büyüğü yöntemi (Largest Of Maximum-LOM)  $Z_{LOM}$  ile gösterilir. Üyelik fonksiyonunun maksimum olduğu  $z$  noktalarının en büyük olanı veren yöntemdir.

SOM ve LOM yöntemleri, en anlamlı değer çıkarılmasında sapmaya neden olabileceklerinden [53] diğer üç berraklaştırma yöntemi kadar sık kullanılmazlar.

Uzmanlaşmış bilginin yakalanmasında Mamdani yöntemi geniş ölçüde kabul görmüştür. İnsani düşünce mantığı ile daha fazla sezgisel olarak uzmanlığın tanımlanabilmesine izin verir [61]. Buradaki beş berraklaştırma işleminin gerçekleştirilmesi için gerekli hesaplama özel donanım desteği olmadığı durumlarda zaman alır. Dahası bu berraklaştırma işlemleri kolay kolay sıkı matematiksel analizlere bağlanamadıklarından yapılan çalışmalar daha çok deneysel sonuçlar temel alınarak yapılır. Bu hiç


berraklaştırma ihtiyacı istemeyen başka tipteki bulanık çıkarım sistemlerinin önerilmesine neden olmaktadır. Bunlardan ikisi burada tanımlanacaktır. Bunlar dışında da (Yager&Filer,1993), (Runkler&Glesner,1994) gibi daha esnek berraklaştırma yöntemleri de yakın zamanlı makalelerde bulunabilir [55].

#### 4.4.2. Sugeno bulanık çıkarım sistemi

Sugeno bulanık modeli (TSK bulanık modeli olarak da bilinir) verilen girdi ve çıktı veri setlerinden bulanık kurallar oluşturmak için sistematik bir yaklaşım geliştirmek gayreti ile Takagi, Sugeno ve Kang tarafından önerilmiştir. Sugeno bulanık modelinde A ve B'nin koşuldaki bulanık kümeleri,  $z = f(x, y)$  ise sonuç kısmındaki geleneksel bir fonksiyonu gösterdiği bir tipik bulanık kural yapısı;

eğer  $x, A \vee y, B$  ise,  $z = f(x, y)$ 'dir,

şeklindedir. Genellikle  $f(x, y)$  girdi değişkenleri  $x$  ve  $y$ 'den oluşan bir polinomdur, ancak kuralın koşulları ile belirlenmiş bulanık bölge içerisinde modelin çıktısını uygun şekilde tanımladığı sürece herhangi bir fonksiyon olabilir.  $f(x, y)$  birinci dereceden bir polinom ise, bulanık çıkarım sistemi “birinci derece Sugeno bulanık modeli” ile adlandırılır. Eğer  $f$  fonksiyonu sabit ise, “sıfırıncı derece Sugeno bulanık modeli” olarak adlandırılır. Bu her bir kural koşulunun bulanık tekil üyelik fonksiyonu ile tanımlandığı Mamdani bulanık çıkarımının özel bir durumu veya her bir kural koşulunun sabit merkezindeki bir basamak fonksiyonu ile tanımlandığı bir Tsukamoto bulanık çıkarım sisteminin özel bir durumu olarak görülebilir.



Şekil 4.9. Sugeno bulanık modeli [60]


Şekil 4.9’da birinci derece Sugeno bulanık modeli için bulanık yargılama işlemi görülebilmektedir. Her bir kuralın sayısal bir çıktısı olduğu için, Mamdani modelinde gerekli olan, zaman alan berraklaştırma işleminin kullanılması yerine, tüm çıktı “ağırlıklı ortalama” ile elde edilebilmektedir [55].

Sugeno yöntemi hesapsal olarak verimlidir ve özellikle lineer olmayan dinamik sistemlerinin kontrol sorunları için çekici hale getiren optimizasyon ve uyarlamalı teknikler ile birlikte iyi çalışmaktadır [61].

#### 4.4.3. Tsukamoto bulanık çıkarım sistemi

Kural yapısının Mamdani bulanık sistemi ile aynı olduğu Tsukamoto bulanık modellerinde, her bir eğer-ise kuralının sonucu şekil 4.10’da görülebileceği gibi tek yönlü artan veya azalan (monoton) bir üyelik fonksiyonlu bulanık küme ile gösterilir [51, 55]. Sonuç olarak, her bir kural için çıkarılan sonuç çıktısı, kural tetikleme kuvveti ile sağlanan sayısal bir değerdir. Tüm çıktı, her kural çıktısının ağırlıklı ortalaması

şeklinde bulunabilir. Şekil 4.10'de iki giriş, iki kural için bulanık yargılamayı örneklendirmektedir.



Şekil 4.10. Tsukamoto bulanık modeli [60]

Her kural sayısal bir çıktı ürettiğinden, Tsukamoto bulanık modelinde her kuralın çıktısı ağırlıklı ortalama yöntemi ile toplanır ve bu zaman alıcı berraklaştırma işleminden sakınılmasını sağlar. Ancak bu model Mamdani ve Sugeno kadar açık ve belirgin olmadığından çok fazlaca kullanılmamıştır [55].

#### 4.5. Bulanık Modelleme

Bulanık modelleme, bir bulanık çıkarım sisteminde beklenen davranışa ulaşmayı sağlayacak parametrelerin tanımlanması işidir [57]. Yani, genel olarak bulanık çıkarım sistemleri hedef sistemin bilinen geçmiş davranışları esas alınarak tasarlanır. Bu sayede bulanık sistemden hedef sisteminin davranışlarını taklit etmesi beklenir [55]. Dilsel ve

sayısal gereksinimlerden dolayı, bulanık modelleme işlemi, modelin doğruluğu ve yorumlanabilirliği arasındaki ters orantılı ilişki ile uğraşması gerekir. Diğer bir deyişle, modelden yüksek hassasiyette sayısal sonuç beklenirken bir yandan da dilsel tanımlama gücünden mümkün olan en az kayıp beklenmektedir. Bu işlem, eldeki bilginin tam olmadığı veya problem uzayı çok geniş olduğunda zor bir hale geldiğinden bulanık modellemede otomatik yaklaşımların kullanılmasını harekete geçirir. Bulanık modellemenin en büyük sorunlarından birisi de değişken sayısının artması ile hesaplama gereksiniminin üssel olarak 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 ile ilgilidirler. Değişik dilsel örnekler arasındaki bağlantıları tanımlarlar. Koşulları, sonuçları ve kuralların ağırlıklarını içerirler.
4. **İşlevsel Parametreler.** Bu parametreler değişkenlerin dilsel ve sayısal gösterimleri arasındaki eşleşmeyi tanımlar. Dilsel değişkenlerin üyelik fonksiyonlarını niteler.

Bulanık modellemede mantıksal parametreler, deneyim ve problem karakteristikleri esas alınarak genelde tasarımcı tarafından tanımlanır. Yargılama mekanizmaları için tipik seçimler Mandani ve Sugeno tipleridir. Yaygın bulanık operatörler minimum, maksimum, çarpım, sınırlı çarpım, sınırlı toplam ve olasılıklı toplamdır. En yaygın

üyelik fonksiyonları üçgen, yamuk ve çan tipidir. Berraklaştırma için birkaç yöntem olsa da COA ve MOM yöntemleri en yaygın kullanılanlarıdır.

Diğer parametreler önceden tanımlı olabileceği gibi bir sentez ve araştırma ile sağlanabilir. Genellikle arama uzayı ve dolayısı ile hesaplama gereksinimi parametre sayısı ile üssel olarak artar. Bu yüzden arama metodolojisine daha fazla kaynak ayrılabilmesi gibi, sisteme daha fazla önceki uzman bilgi katarak arama uzayı daraltılabilir. Daha önce bahsedilen doğruluk ve yorumlanabilirlik arasındaki ilişki genellikle parametre değerlerindeki sınırlamaların kümesi olarak ifade edilir ki bu arama işlemini karmaşıktırır [57].

#### **4.5.1.Yaklaşımlar ve teknikler**

İlk bulanık modelleme, uzman sistemlerde kullanılan bilgi mühendisliği yöntemlerinden esinlenmiş ve bu yöntemlere çok benzemektedir. Mamdani, Zadeh'in düşüncelerini, doğrudan yaklaşım dediğimiz doğrudan uzman bilgiden bulanık bir model kurarak uygulamıştır. Modellenen sistemdeki doğrudan yaklaşımda, bulanık modelin yapısını veya parametrelerini belirlemede belirli bir biçimde kullanılmayan giriş ve çıkış verisinin varlığının artması, beraberinde uzman bilginin toplanma zorluğunu getirmiştir. Bu da bulanık modellemede bulanık modelin sadece bir kısmının önceki bilgiden oluşturulduğu otomatik yaklaşımların kullanılmasını harekete geçirmiştir.

Arama stratejinde ayrılan çok fazla sayıda bulanık modelleme yöntemi vardır. Bunların en önemlileri:

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

olarak sayılabilir.

## BÖLÜM 5. YAPAY SİNİR AĞLARI

### 5.1. Giriş

İnsan okuma, nefes alma, hareket etme ve düşünce gibi işlerini kolaylaştırmak için birbirine sıkı sıkıya bağlı  $10^{11}$  sinir hücresinden (nöron) oluşan karmaşık biyolojik sinir sistemi ile sağlar. Doku ve kimyanın zengin bir birleşimi olan her bir biyolojik nöron, mikroişlemciler kadar hızlı olmasa da karmaşıktır. Sahip olunan nöron yapısının bir kısmı doğum ile beraber gelirken diğer kısımları ise öğrenme ile oluşur.

Bilim insanları biyolojik sinir sisteminin nasıl çalıştığını yeni yeni anlamışlardır. Genel olarak anlayış, hafıza da dahil olmak üzere tüm biyolojik sinirsel fonksiyonlar nöronlar ve nöronlar arasındaki bağlantılarda saklandığıdır. Öğrenme, nöronlar arasında kurulan yeni bağlantılar ya da mevcut bağlantılardaki değişiklikler olarak görülmüştür. Bu, her ne kadar biyolojik sinir sistemini anlamada temel bir bilgimiz olsa da, yanıtı evet olan “Basit yapay nöronlar oluşturulabilir mi?” ve “Oluşturulan bu yapay nöronlar faydalı fonksiyonlara hizmet etmeleri için eğitilebilir mi?” sorularını ortaya çıkarmıştır.

Biyolojik nöronların aşırı derecede basit kopyaları olan yapay nöronlar, program parçaları veya bekli de silikon devre elemanları olarak görülebilir. Bu yapay nöronlardan oluşturulan sistemler (ağlar), insan beyin gücünün küçük bir parçası bile olamayacakken, faydalı bazı fonksiyonların gerçekleştirilmeleri için eğitilebilir sistemlerdir [62].

İnsanlığın doğayı araştırma ve taklit etme çabalarının en son ürünlerinden bir tanesi olan yapay sinir ağlarının (YSA) [63] bir çok tanımlaması vardır. Bu teknolojinin anahtar özelliklerinin vurgulamak için, “Yapay sinir ağları, bir çok farklı işlem elemanı ile

oluşturulmuş dağıtık, uyarlanabilen, genel olarak lineer olmayan öğrenen makinelerdir” tanımlaması kullanılabilir [64].

Bağlantıcılık veya başka bir deyişle yapay sinir ağı çalışmaları, ilk olarak nörobiyolojiden esinlenmiş olmasına rağmen şimdilerde bilgisayar bilimi, elektrik-elektronik mühendisliği, matematik, fizik, psikoloji ve dilbilimini dahi içerecek biçimde fazlaca disiplinler arası bir hale gelmiştir [65].

## 5.2. Tarihi Gelişim

Yapay sinir ağlarının modern çalışmaları 19.yy.da nörobiyologların insan sinir sistemi üzerindeki geniş çalışmaları ile başlamıştır. Anatomi uzmanı Cajal (1892) sinir sisteminin birbirleri ile sahip oldukları aksonlar vasıtasıyla gönderdikleri elektriksel sinyaller ile haberleşen, sonunda dallanarak diğer binlerce nöronun dentritine (alıcı bölgeler) dokunan ve elektriksel sinyali sinapslar (değişken dirençli bağlantı noktaları) ile ileten ayrık nöronlardan oluştuğunu belirlemiştir. Bu temel resim ileriki on yıllar boyunca farklı nöron tiplerinin tanımlanması, elektriksel tepkilerinin analiz edilmesi, bağlantı örüntüleri ve beyinin ana fonksiyonel bölgeleri ortaya çıkarılarak detaylandırılmıştır. Nörobiyologlar için tek olarak bir nöronun işlevselliği konusunda çalışmak kolay olmasına rağmen, nöronların algı ve bilme gibi üst seviye işlevleri başarmak için nasıl birlikte çalıştıklarını belirlemek zor olmuştur. Yüksek hızlı bilgisayarların gelişi ile sinir sistemlerinin çalışan modellerinin oluşturulabilmesi mümkün olmuş ve bu, araştırmacılara bu sistemler ile rahatlıkla deneyler yaparak özelliklerinin daha iyi anlaşılması sağlanmıştır [65].

Sinirsel ağlar için 19yy. sonları ve 20yy. başlarında Hermann von Helmholtz, Ernst Mach ve Ivan Pavlov gibi bilim adamlarının öncelikle fizik, psikoloji ve nörofizyoloji gibi disiplinler arası çalışmalarından oluşan arka plan çalışmaları yer almıştır. Bu ilk çalışmalar öğrenme, görme, koşullandırma gibi genel teoriler üzerinde yapılmış ve nöron çalışmasının belirgin bir matematiksel modelini içermemiştir.



Sinirsel ağların modern bakışı, McCulloch ve Pitts'in 1940'lardaki çalışmaları ve 1943'te yayınladıkları makale ile yapay nöronlardan oluşan ağların herhangi bir aritmetik veya mantıksal fonksiyonu gerçekleyebileceğini göstermeleri ile başlamıştır [62]. İkili eşik birimi (binary threshold unit) olarak adlandırılan bir nöronun sayısal modeli, net girişin verilen bir eşik değerini aşıp aşmamasına bağlı olarak çıkışı 0 veya 1 olan bu önermeleri [65] çoğu kez bu çalışmaları sinirsel ağ alanının kökeni olarak kabul edilmiştir [62]. Bu modelde, bu tür nöronlardan oluşan, sonlu durumlu bir otomatta toplanmış, nöronları arasındaki ağırlık katsayılarına uygun değerler verilen bir sistemin herhangi sıralı bir fonksiyonu hesaplayabileceği gösterilmiş olması epey heyecan oluşturmuştur. Daha sonra araştırmacılar herhangi bir işlevi yapabilecek ağların ağırlık katsayılarının bulunmasını sağlayacak öğrenme yöntemleri araştırmaya başlamışlardır [65].

Bunu daha sonra 1949 yılındaki çalışması ile Donald Hebb izlemiştir. Pavlov'un keşfettiği gibi klasik koşullanmanın, nöronların ayrı özelliklerinden kaynaklandığı önermesini getirmiş ve biyolojik nöronlardaki öğrenme için bir mekanizma önermesinde bulunmuştur. Gelecekte Hebbian öğrenmesi olarak bilinecek olan 20 yıllık çalışmalarını, sonunda 1949 yılında "The Organization of Behavior" başlığında yayınlamıştır.

Yapay sinir ağlarının pratikte ki ilk uygulamaları 1950'lerin sonlarına doğru Rosenblatt'ın perseptron ağı ve ilişkilendirilmiş öğrenme kuralını buluşu ile ortaya çıkmıştır. Rosenblatt ve meslektaşları bir perseptron ağı oluşturarak örüntü tanımayı gerçekleştirmedeki yeteneğini göstermişlerdir. Ancak sonrasında temel perseptron ağının sadece sınırlı bir sınıftaki problemleri çözebildiği gösterilmiştir [62]. Bu çalışmadan önce, IBM araştırma laboratuvarlarında Nathaniel Rochester'ın önce başarısız olan ancak sonraki denemelerinde başarılı sonuçlar veren bir sinirsel ağın simülasyonu, yapay zeka ve sinirsel ağlardaki çalışmaları hızlandıran 1956 yılında yapay zeka üzerine yapılan Dartmouth Yaz Araştırma Projesi ve aynı yıllarda John von Neumann'ın telgraf röleleri ve vakum tüpleri ile yaptığı basit nöron fonksiyonlarını taklit çalışmaları da çok önemli çalışmalardır [66].

Hemen hemen aynı zamanlarda, Widrow ve Hoff, halen günümüzde Widrow-Hoff öğrenme kuralı olarak kullanılan, yeni bir öğrenme algoritması (LMS-Least Mean Square) geliştirmişler ve bunu yapısal ve yeteneksel olarak Rosenblatt'ın perseptronuna yakın olan uyarlamalı (adaptif) lineer sinir ağının (ADALINE-ADaptive LInear NEuron) eğitiminde kullanmışlardır.

1969'da Minsky ve Papert'in kitaplarında geniş bir biçimde irdelenen ve duyurulan aynı ayrılmaz sınırlamalar nedeni ile Rosenblatt ve Widrow ağları zorluklar yaşarken, bu kısıtlamaların farkında olan iki araştırmacı bu kısıtlamaların üstesinden gelebilmek için yeni ağ önermelerinde bulundularsa da daha karmaşık ağların eğitilmesi için öğrenme algoritmalarının başarılı bir biçimde geliştirememişlerdir. Bu kitaptan etkilenen bir çok kişi sinirsel ağlar araştırmalarının ilerisinin olmadığına inanmışlardır. Bununla beraber deneylerin yapılabilmesi için güçlü sayısal bilgisayarların olmayışı, araştırmacıların bu alanı terk etmesine ve sinirsel ağlardaki çalışmaların bir on yıl boyunca duraklaması ile sonuçlanmıştır.

Buna rağmen 1970'lerde bazı önemli çalışmalar sonucunda, Kohonen ve Anderson, birbirlerinden ayrı çalışmaları ile hafıza gibi davranan sinirsel ağlar geliştirmişlerdir. 1976'da Grossberg kendinden organize olan ağların keşfinde oldukça aktif rol almıştır.

1960'ların sonralarına doğru yeni fikir ve deney yapılabilecek bilgisayarların olmayışı nedeni ile sendeleyeni sinirsel ağlara olan ilgi ve araştırmalar, 1980'lerde kapasite olarak hızlı biçimde gelişen yeni kişisel bilgisayarlar ve iş istasyonlarının geniş biçimde varolması ve önemli yeni yaklaşımlarla bu engellerin üstesinden gelinmesinin sağlanmasıyla dramatik bir biçimde artmıştır. Sinirsel ağların yeniden doğuşunda iki yeni yaklaşım çok etkin olmuştur. Bunlardan ilki, fizikçi John Hopfield tarafından bir seminerde sunulan ve birliksel hafıza olarak kullanılabilen yinelenen ağların belirli bir sınıfının çalışmasını açıklamada istatistiksel mekaniğin kullanılmasıdır [62]. Hopfield'ın bir ağın bir enerji fonksiyonu açısından analiz edilebileceğini önerdiği bu çalışması, bir olasılıklı ağ olan, istenen herhangi bir davranış için eğitilebilen Boltzman makinesinin geliştirilmesinin de tetikleyicisi olmuştur [65]. Aynı zamanlarda Japonya'nın Kyoto

kentinde Ortak/Rekabetçi Sinirsel Ağlar üzerine Amerika-Japonya Bağlantı Konferansı yapılmıştır. 1987’de IEEE’nin ilk Uluslararası Sinirsel Ağlar Konferansı 1800’ün üzerinde katılımcı ile yapılmıştır [66].

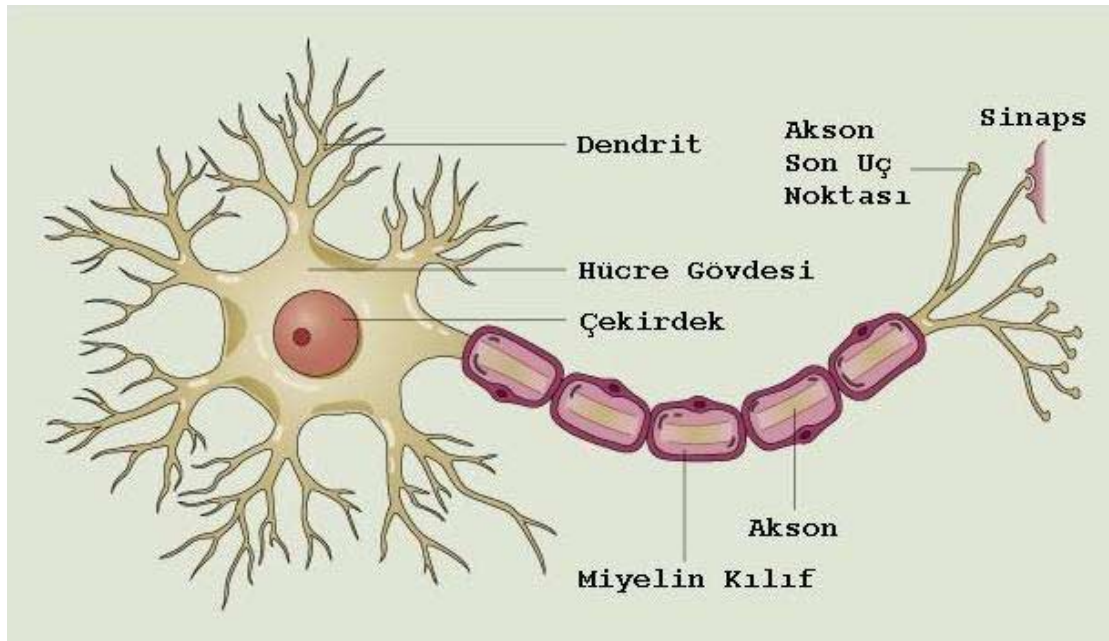
1980’lerdeki ikinci anahtar gelişme ise birbirinden bağımsız birkaç farklı araştırmacı tarafından keşfedilen çok katmanlı perseptron ağlarının eğitilmesi için geri yayılım algoritmasının geliştirilmesidir. Geri yayılım algoritmasının en etkili yayını 1986’daki Rumelhart ve McClelland tarafından yayınlanmış olanıdır. Bu algoritma 1960’larda Minsky ve Papert’in eleştirilerine cevap niteliğindedir.

Bu yeni gelişmelerle sinirsel ağlar alanı yeniden canlanmıştır. O zamandan günümüze binlerce sayfa yayın yapılmış ve sinirsel ağlar bir çok uygulama bulmuş ve bu alan, yeni teorik ve pratik çalışmalarla gelişmektedir. “Önümüzdeki 10-20 yılda neler olacak?” veya “Sinirsel ağlar bir matematiksel veya mühendislik aracı olarak kalıcı bir yer alacak mı, yoksa gelecek vaat eden bir çok teknoloji gibi yavaş yavaş yok olup gidecek mi?” sorularına yanıt vermek gerekir ise; mevcut durumda, her probleme çözüm olarak değil, ancak uygun durumlarda kullanılacak bir araç olarak sinirsel ağların kalıcı bir yerinin olacağı ve beyin hakkındaki bilgimizin sınırlı olması göz önünde bulundurulduğunda sinirsel ağlardaki gelişmenin gelecekte daha fazla olacağı söylenebilir [62]. Ancak tüm bu teknolojide donanımsal gelişmenin çok önemli bir anahtar görevi vardır. Günümüzde şirketler sayısal, analog ve optik olmak üzere üç tipte sinirsel yonga üzerinde çalışmaktadır. Bazıları ise Uygulamaya Özel Tümüleşik Devre (Application Specific Integrated Circuit - ASIC) sinirsel ağı oluşturmak için silikon derleyici üzerinde çalışmalarını sürdürmektedir. ASIC’ler ve nöron benzeri sayısal yongalar yakın geleceğin yeni dalgası olacak gibi görünmektedir [66].

### 5.3. Biyolojik Sinir Sistemi


Beyin, sinir hücresi (nöron) adı verilen çok fazla sayıda (yaklaşık  $10^{11}$ ), yüksek oranda bağlı (her bir eleman için yaklaşık  $10^4$  bağlantı) eleman içerir. Bizim amacımız

doğrultusunda incelendiğinde bu nöronların dendrit, hücre gövdesi ve akson olmak üzere üç temel bileşeni vardır. Dendritler elektriksel sinyali hücre gövdesine ileten sinir fiberlerinin ağaç benzeri alıcı ağlarıdır. Hücre gövdesi dendritlerden gelen sinyalleri etkin olarak toplar ve eşikten geçirilmesini sağlar. Akson ise sinyali hücre gövdesinden diğer hücelere taşıyan tek uzun bir fiberdir. Şekil 5.1’de bir sinir hücresi görülmektedir. Bir hücre aksonunun diğer hücre dendriti ile bağlantı noktasına sinaps adı verilir. Sinirsel ağın işlevini belirleyen, karmaşık bir kimyasal tepkime ile belirlenen nöronların düzeni ve her bir sinapsın gücüdür. Bir sinaps yapısı şekil 5.2’de görülmektedir [62].



Şekil 5.1. Bir sinir hücresinin yapısı [67]

Akson ve dendrit bağlantı noktasında, akson “ön sinaptik uç” adı verilen bir düğüm oluşturur. Bu uç diğer hücre dendrit yüzeyi boyunca uzanır. Akson uyarıldığında, ön sinaptik uç, bitişik dendrite doğru akan “sinir taşıyıcısı” olarak isimlendirilen bir madde salar. Bu kimyasal, dendriti uyararak ikinci nöronun da uyarılmasını sağlamış olur. Sinir tepkileri her ne kadar hücreler arasındaki boşluklardan kimyasal sinir taşıyıcıları ile iletilseler de, esasında doğaları elektrikseldir ve bu olay Na – K pompası ile sağlanır [68].



Şekil 5.2. Bir sinaps ve çalışması [69]

Sinirsel yapıların bir kısmı doğuştan olmakla beraber diğer kısımları öğrenme ile yeni bağlantılar oluştuğunda veya mevcut bağlantılar değiştiğinde gelişir. Sinirsel yapılar hayat boyunca değişmeye devam eder. Bu sonraki değişimlerin başlıca içeriği sinaptik bağlantıların güçlenmesi ya da zayıflamasıdır. Örneğin, yeni hatıraların bu sinaptik güçlerdeki değişikliklerle oluştuğuna inanılmaktadır. Böylece yeni bir kişi yüzünün öğrenilme işlemi, çeşitli sinapsların değişimini içerir.

Yapay sinir ağları beynin karmaşıklığına yaklaşamazlar. Buna rağmen biyolojik ve yapay sinir ağları arasında iki anahtar benzerlik vardır. Bunlardan ilki, her iki ağın yapı taşlarının da yüksek derecede birbirine bağlı basit sayısal aygıtlar (her ne kadar yapay nöronlar biyolojik nöronlardan çok daha basit olsa da) olmasıdır. İkincisi ise, nöronlar arasındaki bağlantıların ağın işlevini belirlemesidir.

Elektriksel devrelerle karşılaştırıldığında biyolojik nöronlar oldukça yavaş olmalarına rağmen ( $10^{-3}$ ,  $10^{-9}$  ile karşılaştırıldığında), beyin bir çok görevi herhangi bir geleneksel bilgisayardan çok daha hızlı yapabilme yeteneğine sahiptir. Bunun nedeni, biyolojik sinirsel ağların bütün nöronların aynı anda çalışmasına olanak veren oldukça büyük paralel yapıda olmasıdır [62].

#### **5.4. Yapay Sinir Ağlarının Özellikleri**

Yapay sinir ağları öğrenerek karar verme prensibi üzerine kurulmuştur. Öğrenme, sistemlerin benzeri işlemleri yaptıklarında, o işleri bir önceki yaptıkları şekilden daha verimli ve etkin olarak gerçekleştirerek değişiklikleri oluşturma süreci olarak tanımlanabilir. İnsan beynini taklit etme esası üzerine kurulan yapay sinir ağları, bir bilgi işleme yöntemi olup, birbirine paralel olarak bağlanmış işlem birimlerinden ve bu birimlerin hiyerarşik organizasyonundan oluşur.

Yapay sinir ağları lineer olmayan sistemlerin kontrolü ve modellenmesinde büyük kolaylıklar sağlamaktadır. Mühendislik problemlerinde ve bir çok pratik uygulamalarda verimli bir kullanım için yapay sinir ağlarının bazı özelliklerinin bilinmesi gereklidir [70].

##### **5.5.1. Eğitilebilirlik**

Bilgi işleme yöntemlerinin çoğu programlama yoluyla hesaplamaya dayanır. Bu yöntemlerle herhangi bir problemin çözümü için uygun algoritmanın geliştirilmesi zorunluluğu vardır ve ispatı mümkün olmayan durumların çözülmesinde kullanılamaz [70]. Yapay sinir ağları herhangi bir giriş ve çıkış örüntüleri arasındaki ilişkilerin oluşturulması olarak düşünülebilir [65]. Bu işlemin yapılabilmesi için yapay sinir ağları çalışmasına konu olan sistemin kayıtlı verileri ile eğitilir ve bu sayede yapay sinir ağı sistemin çalışmasını öğrenir. Böylece eğitilen ağ sistemde kayıtlı olmayan giriş değerlerine de çıkış değeri üretebilecek işlevi kazanmış olur. Eğitilmiş bir ağdan istenen

verimin elde edilebilmesi için nöronlar arasında doğru bağlantıların kurulması ve uygun ağırlıkların belirlenmesini sağlayan eğitime işi rastgele seçilen ağırlıkların ve kayıtlı verilerin kullanımı ile seçilen bir öğrenme algoritması kullanarak belirli bir hata kriterine ulaşması sonucu gerçekleşir.

#### **5.4.2. Genelleme**

Ağlar sadece eğitim verisini ezberlemek yerine temelinde bulunan düzeni öğrenirler ve bu sayede eğitim verisinden farklı yeni giriş verileri için eğitim verisinden genelleme yaparlar. Başka bir deyişle ağ yapısının eğitim sırasında kullanılan nümerik bilgilerden eşleştirmeyi betimleyen ana özellikleri çıkarması ve böylelikle eğitim sırasında kullanılan giriş değerlerinden farklı değerler için de anlamlı çıkış değerleri üretebilmesini sağlayan özelliğidir.

#### **5.4.3. Doğrusal olmama**

Yapay sinir ağları, yapıları gereği doğrusal olduğu gibi, daha çok doğrusal olmayan yönleri ile öne çıkmışlardır. Ağın ya da temel işlem elemanı nöronun doğrusallığı transfer fonksiyonu ile belirlenir [74]. Ağların doğrusal ve parametrik olmayan fonksiyonları hesaplayabilmesini sağlayan bu özelliği, onların veride keyfi olarak karmaşık dönüşümler yapmalarına olanak verir [65].

#### **5.4.4. Sağlamlık ve hata toleransı**

Yapay sinir ağları çok sayıda nöronun çeşitli biçimlerde bağlanmasından dolayı paralel dağıtılmış bir yapıya sahiptir. Bilgi tek bir yerde saklanmayıp yerel belleklere dağıtılarak ağ boyunca yayılmıştır. Bu nedenle nöronlardan veya bağlantılardan herhangi birindeki fiziksel bir hasar durumunda, sistemin verimliliğinde bir düşme olmasına rağmen tamamen başarısız sonuçların ortaya çıkması engellenir. Seri bilgisayarlarda ise herhangi bir işlem birimini devre dışı kalması, tüm sistemin çalışmaz duruma gelmesi anlamına gelir. Bu nedenle hata toleransında yapay sinir ağları geleneksel yaklaşımlara göre çok

avantajlıdır. Ayrıca gürültülü verilere karşı da aynı derecede hata toleransı vardır. Gerçekte de gürültülü veri, ağların daha iyi genellemeler yapabilmesine yardımcı olur [65].

#### **5.4.5. Tekbiçimlilik**

Yapay sinir ağları, farklı tiplerde olan girişlerdeki kısıtlamaları kolayca birleştirilebilen tek biçimli bir sayısal örnek sağlar.

#### **5.4.6. Paralellik**

Bilgi işlem yöntemlerinin çoğu hız problemlerini beraberinde getiren ardışık seri işlemlerden oluşmaktadır. İnsan beyni, bilgisayarlar ile karşılaştırıldığında çok daha yavaş olmasına rağmen, işlem kapasitesi ve toplam hız bakımından, nöronların birbirlerinden bağımsız paralel çalışarak aynı anda bir çok işlevi gerçekleştirmesi sayesinde bilgisayarlardan çok daha üstündür. Yapay sinir ağları da paralel bir yapıya sahip olduğundan girişler bir katmandaki nöronlara aynı anda uygulanır ve bu sayede aynı katmanda bulunan nöronlar arasında zaman bağımlılığı yoktur. Bir çok nöronun eş zamanlı olarak çalışması ve karmaşık işlevlerin bir çok nöron aktivitesinin bir araya gelmesi ile oluşması sağlanır. İşlem hızı artığından geleneksel yöntemlere göre daha kısa sürede sonuca ulaşılması sağlanır.

### **5.5. Sinir Ağların Esasları**

Bir çok farklı yapıda yapay sinir ağı bulunmasına rağmen, bütün hepsi aşağıdaki dört temel özelliğe sahiptir [65].

- İşlem birimi kümesi,
- Bağlantı kümesi,
- Bir hesaplama yöntemi,



- Bir öğrenme yöntemi.

### 5.5.1. İşlem birimleri

Bir yapay sinir ağı, beyin nöronlarına kabaca benzer yapay sinir (yapay nöron) olarak adlandırılan, imkan dahilinde çok fazla sayıda basit işlem birimlerini içerir. Yapay sinir, biyolojik sinirin birinci dereceden karakteristiklerini göstermek üzere tasarlanmıştır [62]. Bütün yapay sinirler, muazzam paralelliği destekleyerek eş zamanlı olarak çalışır. Sistemdeki bütün hesaplama, nöronların aktivitelerinin denetlenmesi ve düzenlenmesi herhangi başka bir işlemciye gereksinim duyulmadan bu nöronlarda olur. Zamanın her anında her nöron basitçe kendi yerel girişlerindeki değerleri bir sayısal fonksiyon ile hesaplar ve aktivasyon değeri olarak adlandırılan sonucu komşu nöronlara yayar.

Bir ağda bulunan birimler, tipik olarak çevreden ham duyuşal bilgi gibi verileri alan “giriş birimleri - giriş nöronları”, dahili olarak verinin gösterimini dönüştürebilecek olan “gizli birimler - gizli nöronlar” ve/veya kararları ya da kontrol sinyallerini gösteren “çıkış birimleri – çıkış nöronları” olarak bölümlenebilir.

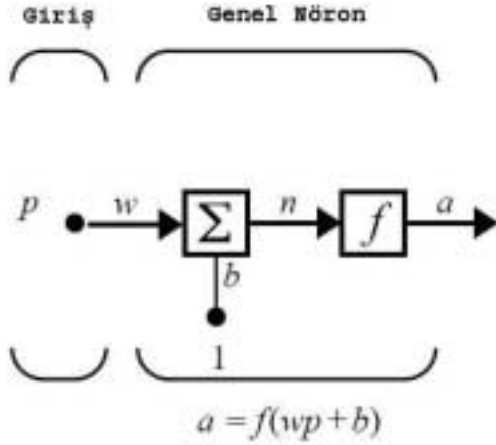
Bir ağın her bir andaki durumu, tüm nöronların üzerindeki aktivasyon değerleri kümesi ile gösterilir. Bir ağın durumu tipik olarak girişler deęiştğinde ve/veya sistemdeki geri besleme, ağın durum uzayı boyunca dinamik bir yörünge izlemesine neden olabileceğinden an ve an deęişir [65].

Tek girişli ve çok girişi birer nöron yapısı aşağıda verilmiştir.

#### 5.5.1.1 Tek girişli nöron

Bir tek girişli nöron şekil 5.3’de verilmiştir. Sayısal giriş  $p$ , sayısal ağırlık  $w$  ile çarpılarak toplayıcıya gönderilen terimlerden biri olan  $wp$ ’yi oluşturur. 1 olan dięer giriş hata eğilim vektörü [71] (bias)  $b$  ile çarpılarak toplayıcıya gönderilir. Genelde net giriş

olarak adlandırılan toplayıcı çıkışı  $n$ , sayısal nöron çıkışı  $a$ 'yı üreten bir  $f$  transfer fonksiyonuna girer.



Şekil 5.3. Tek girişli nöron [72]

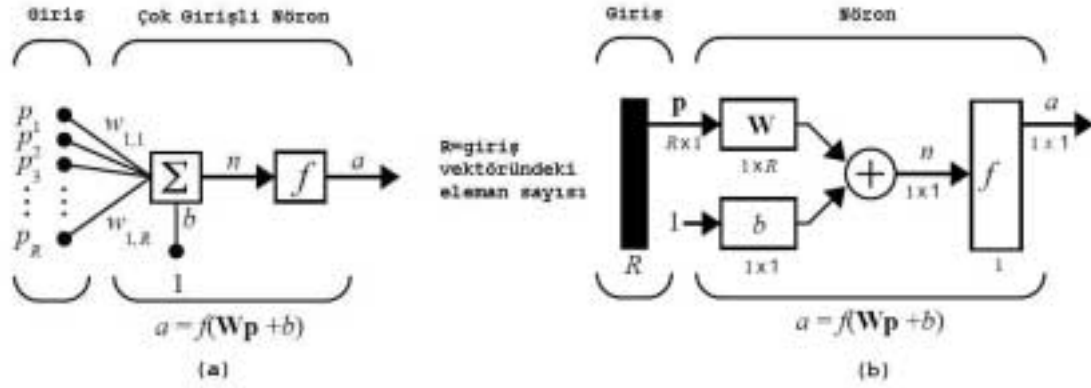
Şekil 5.3'de gösterilen basit modeli biyolojik nöron ile ilişkilendirecek olursak, ağırlık  $w$  sinapsların gücü ile uyuşurken, hücre gövdesi toplama ve transfer fonksiyonu ile ve aksondaki sinyal de nöron çıkışı  $a$  ile temsil edilebilir. Nöron çıkışı 5.1'deki eşitlik ile hesaplanabilir.

$$a = f(wp + b) \quad (5.1)$$

Eşitlikten de görülebileceği gibi gerçek çıkış seçilen transfer fonksiyonuna bağlıdır.

Herhangi bir nöron için istenilmediğinde dahil edilmeyebilen hata eğilim vektörü, girişi sabit 1 olan bir ağırlığa benzer.  $w$  ve  $b$ 'nin nöronun ayarlanabilir sayısal parametreleridir. Tipik olarak transfer fonksiyonu tasarımcı tarafından seçilir ve  $w$  ve  $b$  parametreleri nöron giriş ve çıkışı arasındaki hedeflenen ilişkinin kurulması için bir öğrenme kuralı sonucunda ayarlanır.

### 5.5.1.2. Çok girişli nöron



Şekil 5.4. Çok girişli nöron [72]

Genelde bir nöron birden fazla girişe sahiptir. Şekil 5.4a'da  $R$  girişli bir nöron yapısı ve şekil 5.4b'de genel kısıltılmış gösterimi verilmiştir. Her biri ayrı giriş olan  $p_1, p_2, \dots, p_R$ ,  $W$  ağırlık matrisinin eş düşen  $w_{1,1}, w_{1,2}, \dots, w_{1,R}$  elemanı ile ağırlıklandırılır. Hata eğilim vektörü  $b$  olan bir nöron için net giriş 5.2'deki eşitlik ile ifade edilebilir ve 5.3'deki eşitlik ile matris yapısında yazılabilir.

$$n = w_{1,1}p_1 + w_{1,2}p_2 + \dots + w_{1,R}p_R + b \quad (5.2)$$

$$n = \mathbf{W} p + b \quad (5.3)$$


$W$ , tek bir nöron için tek satırlı bir matris olacaktır. Bundan sonra nöron çıkışı 5.4'deki eşitlik ile ifade edilebilir.

$$a = f(\mathbf{W} p + b) \quad (5.4)$$

### 5.5.2. Bağlantılar

Bir ağdaki nöronlar, bir şekilde çizgilerle gösterilen bağlantılar veya ağırlıklar kümesiyle verilen bir topoloji içinde düzenlenir. Her nöron ağırlığının, bazen aralığı sınırlı olmakla beraber tipik  $-\infty, +\infty$  olarak arasında değişen değerlerde gerçek değeri vardır. Bir ağırlığın değeri (veya gücü), bir birimin komşu birimi üzerinde ne kadar etkisi olacağını tanımlar. Pozitif bir değer bir nöronun diğer bir nöronu uyarmasına sebep olurken, negatif bir değer bir nöronun bir diğerini engellemesine sebep olur.

Tüm ağırlıkların değerleri, herhangi rastgele bir giriş örneğine, ağın sayısal tepkimesini önceden belirler. Böylece ağırlıklar, ağın uzun vadeli belleğini ya da bilgisini kodlar. Ağırlıklar bir öğrenme sonucundan değişebilir ama, birikmiş bilginin yavaş değişmesi nedeniyle değişime karşı çok yavaş bir eğilimleri vardır. Bu mevcut girişin geçici fonksiyonları olması nedeniyle kısa vadeli bellekler olan etkinleştirme modellerinin aksinedir.



Şekil 5.5. Yapay sinir ağı topolojileri

Bir ağ, herhangi bir topoloji ile bağlantılandırılmış olabilir. Yapısal olmayan, katmanlı, yinelenen ve modüler ağları içeren genel topolojiler şekil 5.5'de gösterildiği gibidir. Her bir topoloji belirgin bir tipteki uygulama için en uygundur. Yapısal olmayan ağlar, bir örüntünün bir parçasının verilmesi ile depolanmış örüntülerden çıkarılması gibi örüntü

tamamlama, arama gibi işlemlerde çok faydalıdır. Katmanlı ağlar giriş vektörlerinin çıkış vektörlerine eşlenmesi gibi örüntü eşlemede yararlıdırlar. Yinelenen ağlar örüntü sıralamada ve modüler ağlar ise basit yapılardan karmaşık sistemlerin oluşturulmasında faydalıdır.

Dikkat edilecek olursa yapısal olmayan ağlar döngüler içerir ve bu yüzden gerçekte yinelenendirler. Katmanlı ağlar yinelenen olabilir veya olmayabilir. Modüler ağlar ise farklı türdeki ağları birleştirebilir. Genel olarak yapısal olmayan ağlar iki yönlü bağlantılar kullanırlarken diğer ağlar tek yönlü bağlantılar kullanırlar.

İki katman gibi iki grup birimin birbirine bağlanabilirliği, genelde tümünü tümüne bağlayarak “tamamen” olabildiği gibi, bazılarının bazılarına bağlandığı “gelişigüzel” veya bir bölgenin diğerine bağlandığı “yerel” biçimlerde olabilir. Tamamen bağlanmış bir ağın serbestlik derecesi en yüksektir. Bu yüzden teorik olarak alışılmadık ağlara göre daha fazla işlev öğrenebilirler. Ancak bu her zaman istenen bir durum değildir. Bir ağ çok fazla serbestlik derecesine sahipse, ağ öğrenme sırasında sorunun yapı temelinde bulunanı öğrenme yerine basitçe eğitim kümesini ezberler ve sonuç olarak yeni verilere zayıf bir genelleme yapabilir. Bağlanabilirliği sınırlamak, ağı daha ekonomik çözümler bulmaya zorlarken daha iyi genelleme yapmasına da yardımcı olabilir. Özellikle yerel bağlanabilirlik, bir görsel işleme sisteminde katmanlar arasında bulunan geometrik kısıtlamalarda olduğu gibi sorunun tabiatında var olan topolojik kısıtlamaları yansıttığında çok faydalı olabilir [65].

### 5.5.3. Hesaplama

Hesaplama, her zaman ağ girişine bir giriş örneği uygulanması veya aktivasyon örneğinin girişlere kenetlenmesi ile başlar. Sonra diğer kalan bütün birimlerin aktivasyonu duruma göre, ya eşzamanlı (paralel sistemlerde hepsi bir kerede) ya da eşzamansız (rastgele ya da doğal sıralı olarak bir anda biri) olarak hesaplanır. Yapısal olmayan ağlarda bu işlem “yayılan aktivasyon-spreading activation”, katmanlı ağlarda işlem giriş katmanından çıkışa doğru ilerlediğinden “ileri yayılım-forward propagation”

olarak isimlendirilir. İleri beslemeli ağlarda (geri beslemesi olmayan ağlar) hesaplama çıkış katmanına ulaşır ulaşmaz aktivasyonlar dengelenir. Ama yinelenen ağlarda (geri beslemesi olan ağlar) aktivasyonlar hiçbir zaman dengelenemeyebilirken, bunun yerine birimler sürekli güncellendiğinden durum uzayı boyunca dinamik bir yörünge izleyebilir.

Bir birim tipik olarak iki adımda güncellenir; ilk olarak birimin net girişi hesaplanır ve sonra çıkış aktivasyonu net girişin bir fonksiyonu olarak hesaplanır [65]. Net girişin hesaplanması 5.2 ve 5.3 eşitliklerinde verilmiştir. Bir birimin net girişinin hesaplanmasında sonra, 5.4 eşitliği ile verilen şekilde çıkış aktivasyonu net girişin bir fonksiyonu olarak hesaplanır. Bu fonksiyona aktivasyon fonksiyonu ya da transfer fonksiyonu denir.


### **5.5.3.1. Transfer fonksiyonları**

Bir başka deyişle transfer fonksiyonu net girdiyi işleyerek nöron çıktısını üreten fonksiyondur. Eşik veya işaret veya aktivasyon fonksiyonu olarak da bilinir [73]. Nöronun çözmeye çalıştığı problemin bazı özelliklerini sağlayan özel bir transfer fonksiyonu seçilir [62].

Analog elektriksel sistemleri ile benzer olarak aktivasyon fonksiyonu bir yapay nöronun lineer olmayan kazancı olarak düşünülebilir. Bu kazanç net girişteki küçük bir değişikliğe karşı çıkıştaki değişikliğin oranı bulunarak hesaplanır. Dolayısıyla kazanç, eğrinin özel bir uyarım noktasındaki eğimidir. Grossberg, aynı ağın hem küçük hem de büyük sinyalleri işleyebilmesini transfer fonksiyonunun bu lineer olmayan karakteristiği ile açıklanabileceğini bulmuştur. Bu fonksiyonun ortasındaki yüksek kazanç bölgesi küçük sinyalleri işlerken, uçlardaki kazanç düşürücü bölgeler büyük sinyalleri işlemektedir. Böylece bir yapay nöron, geniş bir girişi yelpazesi içindeki sinyalleri kazanç uydurma yolu ile işleyebilmektedir [70].

Transfer fonksiyonları belirleyici (deterministic) ya da olasılıklı (stochastic) ve yerel veya yerel olmayan şekilde olabilir [65].

Belirleyici yerel aktivasyon fonksiyonları genelde şekil 5.6'da görülen doğrusal, eşik ya da sigmoidal yapılardan birini alırlar. Eşitliği şekil 5.6a'da verilen doğrusal transfer




Şekil 5.6. Belirleyici yerel transfer fonksiyonları: (a) doğrusal; (b) eşik; (c) sigmoidal

fonksiyonu, çok katmanlı doğrusal birimlerin aynı işlevsellikle tek bir katmanda birleştirilebilecek olmalarının verdiği zayıflık nedeni ile çok sık kullanılmaz. Doğrusal olmayan fonksiyonlar oluşturabilmek için ağırlı doğrusal olmayan birimlere ihtiyacı vardır. Bu doğrusal olmamanın en basit yapısı şekil 5.6b'de verilen eşik fonksiyonudur. Çok katmanlı bir ağda bu fonksiyon doğrusal fonksiyondan çok daha etkilidir. Öyle ki, eşik birimlerinden oluşan çok katmanlı bir ağda teorik olarak herhangi bir ikili mantık işlemini gerçekleştirebilir. Ancak, fonksiyondaki devamsızlığın, istenilen ağırlık kümesini bulmanın bir üssel arama gerektirebileceğini göstermesi nedeniyle bu tür bir ağırlı eğitilmesi zordur. Bu tür birimlerden oluşan tek katmanlı ağlar için pratik bir öğrenme kuralı mevcuttur. Bundan başka, sürekli çıkışların ikili çıkışlara tercih edildiği bir çok uygulama vardır. Bu yüzden, şimdilerde en yaygın fonksiyon, şekil 5.6c'de verilen sigmoidal 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.

Yerel olmayan transfer fonksiyonları, kısıtlamaların tüm ağ geneline uygulanmasında yararlı olabilir. Örneğin, olasılıklarda olduğu gibi bazen ağın tüm çıkış aktivasyonları toplamının 1 olmasını sağlamak yararlı olabilir. Bu çıkışların doğrusal olarak normalleştirilmesi ile gerçekleştirilebilir ama daha yaygın olan yaklaşım, doğrudan net girişler üzerinde çalışan “softmax” fonksiyonlarını kullanmaktır. Yerel olmayan fonksiyonlar, daha fazla genel gidere ve/veya donanımına ihtiyaç duyarlar ve bu yüzden biyolojik olarak inanılmazdırlar, ancak genel kısıtlamalar istenildiğinde yararlı olabilirler. Genel olarak kullanılan yerel olmayan ve belirleyici yerel transfer fonksiyonları şekil 5.7’de verilmiştir.




Şekil 5.7. Diğer transfer fonksiyonları [72]



Belirleyici olmayan transfer fonksiyonları belirleyici olanların aksine olasılıklıdır. Çıkışa 1 vermenin olasılığı 5.5'deki eşitlik ile verildiğinde, tipik olarak ikili aktivasyon değerleri (0 ya da 1) üretirler.

$$P(y=1) = \frac{1}{1 + e^{-\frac{n}{T}}} \quad (5.5)$$



Şekil 5.8. Belirleyici olmayan transfer fonksiyonları

Genelde zamanla değişen  $T$  değişkenine ısı denir. Şekil 5.8'de bu olasılık fonksiyonunun  $T$  değişkeni ile nasıl değiştiği gösterilmiştir. Sonsuz bir  $T$  değeri ile tekdüze, sabit bir olasılık fonksiyonu, sonlu bir  $T$  değeri ile sigmoidal olasılık fonksiyonu ve 0 değerli bir  $T$  değişkeni ile eşik olasılık fonksiyonu elde edilir. Eğer  $T$  değeri öğrenme sırasında sürekli düşüyorsa, bu işleme “benzetilmiş sertleşme-simulated annealing” denir.

Yukarıda anlatılan transfer fonksiyonları, giriş ve ağırlık değerlerinin çarpılarak toplanması sonucu elde edilen net girişin uygulandığı fonksiyonlardır. Net giriş hesaplaması, girişlerin ağırlıklar ile çarpılması yerine farklarının kareleri alınarak toplanması ile elde edilen net girişlerin kullanıldığı transfer fonksiyonları da mevcuttur. LVQ ve RBF ağlarında kullanılan nöronlar bu yapıya örnek olarak verilebilir [65].

#### 5.5.4. Öğrenme

Bir ağıın eğitilmesi sonucu olan öğrenme en genel anlamda, bağlantılarındaki ağırlıkları ayarlayarak ağıın tüm giriş verileri için istenen davranışı gösterecek biçimi sağlayacak şekilde gelmesidir. Bu işlem genellikle ağırlıkların değiştirilmesini içerdiği gibi bazen de ağıa yeni bağlantı ekleme veya ağıdan bağlantı çıkarma gibi ağıın mevcut topolojik yapısının değiştirilmesini de içerir. Bir anlamda, çok bağlantılı bir ağıın, bir bağlantısının silinmesi ile aynı anlama gelen, ilgili ağırlıklarını 0'a ayarlayabilecek şekilde öğrenmesi mümkün olduğundan, bu ağırlık değişimleri topolojik değişimlerden daha yaygındır. Ancak, topolojik değişiklikler genellemeyi ve öğrenme hızını geliştirebilir.

Bir ağıın verilen bir fonksiyonu gerçekleştirilebilmesini sağlayacak ağırlık kümesinin bulunması önemsiz olmayan bir işlemdir. Ağıın doğrusal olduğu ve dikey giriş vektörlerinin çıkış vektörleri ile eşleştirilmesinin hedeflendiği bir çalışma gibi, sadece örnek eşleştiriminin en basit durumları için analitik bir çözüm vardır.

Genel olarak, ağılar doğrusal değildir ve çok katmanlıdır. Ağırlıkları, küresel performans ölçümü üzerinde gradient descent gibi tekrarlanan yöntemlerle bulunabilir. Bu, her bir geçişte tekrarlama (iteration) veya devir (epoch) adı verilen, eğitimin tüm eğitim kümesinden çoklu geçişini gerektirir. Ayrıca, toplanmış bilginin tüm ağırlıklara dağıtılmış olması sebebiyle, daha önceki öğrenmenin bozulmaması sağlamak için ağırlıklar çok yumuşak olarak değiştirilmelidir. Ağırlık değişim büyüklüklerinin kontrolü için "öğrenme oranı-learning rate" ( $\alpha$ ) adı verilen, küçük bir sabit kullanılır. Değeri çok küçük olması durumunda öğrenmenin sonsuza kadar süreceğinden ya da fazla büyük olması durumunda öğrenme, önceki bilgiyi bozacağından öğrenme oranı için iyi bir değer bulmak çok önemlidir. Ancak en iyi öğrenme oranının bulunabilmesi için analitik bir yöntem yoktur. Genellikle farklı değerler kullanılarak deneysel biçimde en iyileştirilir.

Aslında öğrenme algoritmalarının çoğu, Hebb kuralının çeşitlemeleridir. Bir sinapsın her iki tarafındaki nöronların eşzamanlı olarak uyarılması durumunda, sinapsın gücü

artacaktır. 5.3'deki eşitliği 5.6'deki eşitliğe dönüştürürsek, giriş  $p_j$  ve çıkış  $a_i$  arasındaki bağlantı (sinaps)  $w_{ij}$  ağırlığıdır.

$$a_i = \sum_{j=1}^R w_{ij} p_j \quad (5.6)$$

Dolayısı ile Hebb'in önermesi ile "Giriş  $p_j$  ve çıkış  $a_i$  arasındaki bağlantı (sinaps)  $w_{ij}$  artırılmalıdır" ifadesinin sonucunda 5.7'deki eşitlik elde edilebilir. Bu ifadede  $p_{jq}$   $q$ 'nuncu giriş vektöründeki  $j$ 'ninci elemanı,  $a_{iq}$  ise ağa  $q$ 'nuncu giriş vektörü uygulandığında oluşan çıkış vektörünün  $i$ 'ninci elemanıdır [62].

$$w_{ij}^{yeni} = w_{ij}^{eski} + \alpha a_{iq} p_{jq} \quad (5.7)$$

Eğitim sırasında bir bağlantının aktif ikilileri arasındaki ilişkinin güçlendirilmesiyle ağ, test sırasında sadece birincisi bilinen ikilinin ikinci nöronunu uyarmak için hazırlanır.

Hebb kuralının önemli çeşitlemelerinden birisi, iki nöronun birisi için hedef değer bilindiğinde kullanılan Delta Kuralı (ya da Widrow-Hoff Öğrenme Algoritması veya LMS Algoritması)'dır. Bu kural iki nöron arasındaki bağlantıyı giriş ve çıkıştaki hata ile güçlendirir. Bu kuralın matrissel gösterimi aşağıdaki eşitlikler ile verilmiştir.  $i$  çoklu çıkışlardaki kaçınıcı çıkış değişkeni olduğunu,  $k$  tekraralama sayısını,  $t$  çıkışta görülmek istenen hedef değeri ve  $e$  ise hedef değer ile çıkışın mevcut değeri arasındaki bağlı hatayı göstermektedir.

$${}_i w(k+1) = {}_i w(k) + 2\alpha e_i(k) p(k) \quad (5.8)$$

$$b_i(k+1) = b_i(k) + 2\alpha e_i(k) \quad (5.9)$$

$$e_i(k) = t_i(k) - a_i(k) \quad (5.10)$$

Bu kural, performans göstergesinin en küçük hata kareleri ortalaması olduğu yaklaşık en dik iniş (steepest descent) algoritmasıdır. Bu algoritma günümüzde bir çok işaret işleme algoritmasında yaygın olarak kullanıldığından ve çok katmanlı ağlar için geri yayılım algoritmasının ilk şekli olduğundan çok önemlidir [62]. Tek katmanlı ağırlıklar ile ikili eşik nöronları bağlamında Delta Kuralı, Perseptron Öğrenme Kuralı olarak bilinir. Bu kural ile mükemmel sonuç varsa bu sonucu ifade eden ağırlık kümesinin bulunması garanti edilmiştir.

LVQ ve RBF ağlarında olduğu gibi küresel fonksiyonlar durumunda kullanılan algoritma yine Hebb Kuralı türevi olan öğrenme algoritmasıdır.

$${}_i w(k+1) = {}_i w(k) + \alpha p(k)(a_i(k) - {}_i w(k)) \quad (5.11)$$

Bu kural, çıkış değeri aktif iken, küre merkezini ifade eden ağırlık değerini, giriş örneğine yaklaştırır [65].

### 5.6. Sinirsel Ağların Sınıflandırılması

Genel olarak yapay sinir ağlarını ağın yapısına, ağda yer alan düğüm özelliklerine, transfer fonksiyonlarının belirleyici veya olasılıklı oluşlarına, eğitim veya öğrenme algoritmaları gibi özelliklerine göre sınıflamak mümkündür. Bu çalışmada sınıflama, öğrenme yöntemlerine göre yapılacaktır. Öğrenme yöntemlerine göre üç ana sınıf mevcuttur. Bunlar;

- Denetimli öğrenme,
- Yarı denetimli (takviyeli) öğrenme,
- Denetimsiz öğrenme

olarak sayılabilir. Ağ yapılarının bir çoğu bu sınıfların birine ait olmasına rağmen melez ağlar bu sınıfların bazılarını aynı anda destekleyebilir. Bunların yanında, ayrı bir başlık

altında incelenmesi gereken, mimarileri zamanla büyüeyebilen veya küçülebilen dinamik ağlar da mevcuttur.

### 5.6.1. Denetimli öğrenme

Denetimli öğrenme, bir öğreticinin her giriş örneği için çıkış hedeflerini sağlaması ve ağ hatalarını açıkça düzeltilmesi anlamında gelir [65]. Girişler ağa uygulandığında, ağ çıkışları hedef değerler ile karşılaştırılır. Sonrasında ise öğrenme kuralı, ağ çıkış değerlerini hedef değerlere yaklaştırmak için ağ ağırlıkları ve hata eğilim vektörlerini ayarlar [62]. İleri beslemeli ağlar ve yinelenen ağlar bu sınıfta incelenebilir.

#### 5.6.1.1. İleri beslemeli ağlar


Problemlerin çözümünde bir çok girişe sahip olsa dahi genelde bir nöron yeterli olmayabilir. Katman adı verilen, paralel çalışan birden fazla nörona ihtiyaç olabilir. Probleme göre bu ağlar tek katmanlı veya çok katmanlı olabilirler.

$S$  nöronlu, tek katmanlı bir ağ şekil 5.9'da verilmiştir.  $R$  girişlerinin her birinin her bir nörona bağlandığı görülebilmektedir ve ağırlık matrisi  $S$  satırlıdır.

Katman, ağırlık matrisini, toplayıcıları,  $\mathbf{b}$  hata eğilim vektörünü, transfer fonksiyonlarını ve  $\mathbf{a}$  çıkış vektörünü içerir. Literatürdeki bazı kaynaklarda girişler de ayrı bir katman olarak nitelendirilmektedir.

$\mathbf{p}$  giriş vektörünün her bir elemanı  $\mathbf{W}$  ağırlık matrisi ile her bir nörona bağlanmıştır. Her nöron bir  $b_i$  hata eğilim vektörüne, bir toplayıcıya, bir  $f$  transfer fonksiyonuna ve bir  $a_i$  çıkışına sahiptir. Hepsi beraber ele alındığında çıkışlar  $\mathbf{a}$  çıkış vektörünü oluştururlar. Katmana giren giriş sayısının nöron sayısından farklı olması yaygındır. Katmanda bulunan nöronların farklı transfer fonksiyonlarına sahip olması isteniyorsa; farklı transfer fonksiyonuna sahip olan nöronlarla ayrı bir nöron katmanı tanımlanarak bu iki

katman paralel olarak birleştirilir. Her iki ağda aynı girişlere sahip olmalı ve her ağ çıkışın bir kısmını oluşturmalıdır.



Şekil 5.9. Tek katmanlı ağ

Giriş vektörü elemanları 5.12’de verilen eşitlikteki  $\mathbf{W}$  ağırlık matrisi ile ağa girerler.

$$\mathbf{W} = \begin{bmatrix} w_{1,1} & w_{1,2} & \cdots & w_{1,R} \\ w_{2,1} & w_{2,2} & \cdots & w_{2,R} \\ \vdots & \vdots & \cdots & \vdots \\ w_{S,1} & w_{S,2} & \cdots & w_{S,R} \end{bmatrix} \quad (5.12)$$

$\mathbf{W}$  matrisi elemanlarının satır göstergesi, o ağırlıkla ilişkilendirilmiş hedef nöronu gösterirken, sütun göstergesi, o ağırlık için kaynak girişi gösterir. Örneğin,  $w_{3,2}$  ağırlık değeri üçüncü nöron ile ikinci giriş arasındaki bağlantıyı göstermektedir [62].

Perseptronlar, ileri beslemeli ağların denetimli öğrenmeyi kullanan en basit tipidir. Bir perseptron ikili eşik nöronlarından oluşur. Şekil 5.9 ile verilen tek katmanlı ağ yapısı, transfer fonksiyonları eşik fonksiyonu seçilerek yapı çok nöronlu bir perseptrona dönüştürülebilir. Delta kuralı veya türevleri ile eğitilebilir.

Tek katmanlı bir perseptron durumunda Delta Kuralı doğrudan uygulanabilir. Çünkü perseptronun aktivasyonları ikili olması nedeniyle bu genel öğrenme kuralı, eğer bir giriş aktif (=1) ise ve çıkış yanlış ise ağırlık küçük bir öğrenme oranı değeri ile, beklenen çıkışın 0 ya da 1 olmasına bağlı olarak sırasıyla küçültülmeli ya da artırılmalı diyen Perseptron Öğrenme Kuralı'na indirgenir. Bu yöntem, herhangi bir eğitim kümesindeki örnekleri, örnekler doğrusal olarak ayrılabilen ise, doğru olarak sınıflayan ağırlıkların bulunmasını garantiler. Ancak eğitim kümelerinin bir çoğu (basit XOR örneğindeki gibi) doğrusal olarak ayrılamazlar. Bu tür durumlar çoklu katmanlar gerektirir [65].

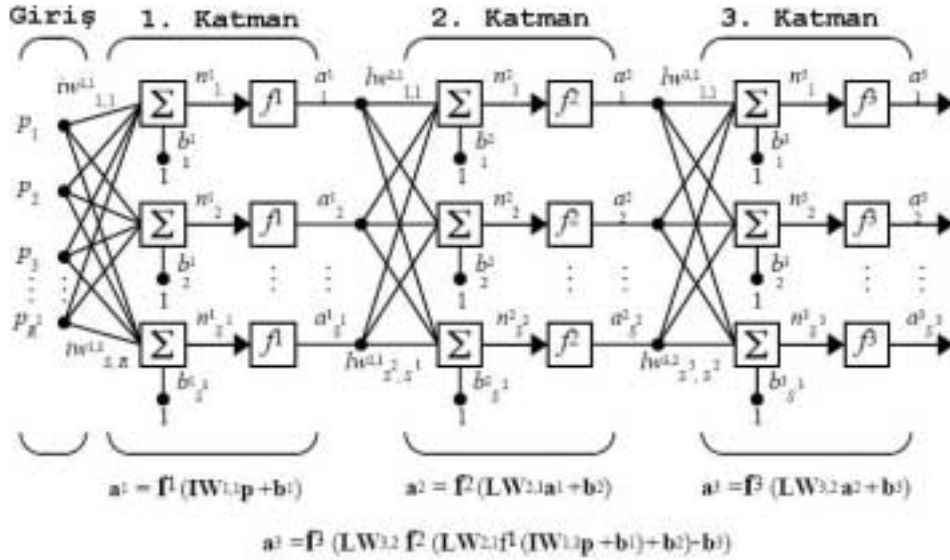
Eğer birkaç katmana sahip bir ağı ele alacak olursak, her katmanın kendisine ait  $\mathbf{W}$  ağırlık matrisi,  $\mathbf{b}$  hata eğilim vektörü,  $\mathbf{n}$  net girişi vektörü ve  $\mathbf{a}$  çıkış vektörü vardır. Katmanların birbirlerinden ayrılabilmesi ve tanımlanabilmesi için üst simgeler kullanılır. Dolayısıyla  $\mathbf{W}^1$ , birinci katmanın ağırlık matrisini gösterirken,  $\mathbf{W}^2$  ikinci katmanın ağırlık matrisini gösterir. Aynı şekilde  $S^1$  birinci katmandaki nöron sayısını ifade ederken,  $S^2$  ikinci katmandaki nöron sayısını ifade etmektedir. Bu gösterimler şekil 5.7'de verilen üç katmanlı bir ağda görülebilmektedir. Katmanların nöron sayıları birbirlerinden farklı olabilir.

Şekil 5.10'da verilen ağın birinci ve ikinci katmanların çıkışları sırasıyla ikinci ve üçüncü katmanların girişleridir. Böylece ikinci katman  $R = S^1$  girişli,  $S = S^2$  nöronlu ve  $S^1 \times S^2$  satır sütunlu  $\mathbf{W}^2$  ağırlık matrisi olan tek katmanlı bir ağ olarak düşünülebilir.  $\mathbf{a}^1$  ağ girişi ve  $\mathbf{a}^2$  ağ çıkışıdır.

Çıkışı, ağın çıkışı olan katmana “çıkış katmanı” denir. Diğerleri ise “gizli katman” olarak isimlendirilir.

Çok katmanlı ağlar tek katmanlı ağlara göre çok daha güçlüdür. Örneğin birinci katmanın transfer fonksiyonu sigmoid, ikinci katmanın transfer fonksiyonu doğrusal olan iki katmanlı bir ağ, tek katmanlı ağlar ile mümkün olmayan bir çok fonksiyonun

yaklaşımında iyidir. Pratikte sinirsel ağlar sadece iki veya üç katmanlıdır. Dört ve daha fazla katmanlı olan ağlar çok nadir kullanılır [62].



Şekil 5.10. Çok katmanlı ağlara örnek olarak üç katmanlı bir ağ

Çok katmanlı perseptronlar teorik olarak herhangi bir fonksiyonu öğrenebilirler ancak eğitmek için daha karmaşıktır. Çok katmanlı perseptronlara Delta Kuralı, gizli katmanda veya katmanlarda hedef olmadığı için doğrudan uygulanamaz. Ancak bir çok katmanlı perseptron ayrık yerine sürekli aktivasyon fonksiyonu kullanırsa (örneğin eşik yerine sigmoidal), kısmi türevlerin kullanılması ve zincirleme olarak herhangi bir ağırlığın, herhangi bir çıkış aktivasyonundaki etkisini türetmek mümkün hale gelecektir. Bu sayede ağ hatasının düşürülmesi için ağırlığın değiştirilmesi mümkün olacaktır. Delta Kuralı'nın bu geliştirilmesine geri yayılım denir [65].

Çok katmanlı ağların bir başka yapısı da zaman gecikmeli sinirsel ağlardır (TDNN). Bu mimari başlangıçta ses tanıma için geliştirilse de el yazısı tanıma, dudak okuma ve diğer işler için de kullanılmıştır. Bağlantıların zaman gecikmeli olması, bağlı nöronları geçici olarak sırasızlaştırır. Eğitimlerinde standart geri yayılım kullanılır. Eğitimdeki tek farklı



bakış açısı, düğümlenmiş ağırlıkların bağımsız olarak değil, kendilerinin ortalanmış hata sinyallerine göre değiştirilmesidir.

Giriş örneklerini sınıflayabilen başka bir ağ yapısı da LVQ ağıdır. Bir LVQ ağı tek katmanlı bir ağ olup, çıkışları sınıfları temsil ederken girişlerden ağırlıkları hiperkürelerin merkezlerini ifade eder. Eğitim, hiperkürelerin sınıfları kapsayacak şekilde hareket ettirilmesini içerir [65].


### 5.6.1.2 Yinelenen ağlar

Hopfield bir tür içeriği adreslenebilir çağrışimli bellek uygulamak için sinirsel ağlarla çalışmıştır. Nöronlarının transfer fonksiyonu ikili eşik olan, simetrik bağlantılı ( $w_{ij} = w_{ji}$ ), aktivasyonları eşzamanlı olmadan güncellenen, yapısal olmayan ağlar üzerine çalışmıştır. Şimdilerde bu tür yinelenen ağlara Hopfield ağı denir. Hopfield, bir ağdaki ağırlıklar Hebb Kuralı'na göre değiştirilmişse, eğitim örneklerinin durum uzayında çekiciler (attractors) haline geleceğini göstermiştir. Yani, eğer daha sonra ağa örneklerden bozulmuş bir sürüm uygulanır ve ağın aktivasyonları rastgele, eşzamansız biçimde güncellenirse (daha önce eğitilen ağırlıklar kullanılarak), ağın tüm aktivasyonu durum uzayındaki örneklere en yakın aktivasyon örneğini kademeli olarak yeniden oluşturacaktır. Buradaki anahtar, anlayış ağın dinamiklerinin, bir nöronun aktivasyonu güncellendiğinde muhakkak azalan ve bellekte saklananlarla uygun düşen aktivasyon örnekleri için minimum bir değere ulaşan, genel bir enerji fonksiyonu açısından analiz edilmesidir.

Teorik olarak çok güçlü olan ve başarı ile bir çok uygulamada kullanılan Boltzman makinesi de gizli nöronlara sahip, olasılıklı aktivasyonlu ve öğrenme yönteminde benzetilmiş sertleşme olan bir Hopfield ağıdır.

Yinelenen ağların diğer tipleri, daha önceki katmanlara geri besleme bağlantıları olan yapısal bir yapıya sahiptir. Jordan ağları ve Elman ağları olarak bilinen iki örneği şekil

5.11’de verilmiştir. Bu ağlar, aktivasyonları çıkışlardan veya gizli katmandan kopyalanarak gizli katmana bağlanan, girişlere ek “bağlam nöron” özelliklerini taşır. Bağlam nöronları ağlara çok uzun mesafelerde olmamakla birlikte bir çeşit azalan bellek sağlar. Bu ağlar da tüm eğitilebilir ağırlıkların ileri beslemeli olması nedeni ile geri yayılım ile eğitilebilirler [65].



Şekil 5.11. Katmanlı yinelenen ağlar. (a) Jordan ağı; (b) Elman ağı

### 5.6.2. Yarı denetimli öğrenme

Yarı denetimli öğrenme, her ağ girişi için doğru çıkışların sağlanması yerine algoritmaya bir derece verilmesi dışında denetimli öğrenmeye benzemektedir. Bu derece, ağın bazı giriş dizileri üzerinde performans ölçütüdür. Bu tip öğrenme bugünlerde denetimli öğrenmeden çok daha az kullanılmaktadır [62]. Yarı denetimli ağların farklı tipleri, topolojileri ile değil, ortam doğaları ve öğrenme yöntemleri ile ayırt edilmiştir. Ortam statik veya dinamik olabilir. Örneğin değerlendirmelerin belirleyici ya da olasılıklı olabilmesine benzer biçimde “iyi” davranışının tanımı, sabit olabildiği gibi zamanla değişebilir.

Statik ortamlarda ağlar çağrışımsal ödül-ceza algoritması (associative reward-penalty algorithm) ile eğitilebilirler. Bu algoritma, ağın çeşitli davranışlar denemesini sağlayan olasılıklı çıkış nöronlarını varsayar. Ağın davranışı, iyi veya kötü olarak incelenmesine

bağlı olarak, eğitim hedeflerini gerçek çıkışlara veya onların zıtlarına ayarlanmasıyla yarı denetimli öğrenme problemi, denetimli öğrenme problemine dönüşür ve ağ hedeflerinin ağın ortalama çıkışı ile karşılaştırıldığı ve eğer gerekliyse hatanın ağ boyunca geri yayıldığı Delta Kuralı ile eğitilebilir.

Statik veya dinamik ortamlara uygulanabilen bir başka yaklaşım da, ortamı modellemeye çalışan yardımcı bir ağ kurmaktır. Bu yardımcı ağ çevresel veriyi destekleyici bir sinyale dönüştürür. Böylece yarı denetimli öğrenme problemi, hedefleri bilinen iki aşamalı denetimli öğrenme problemine indirgenir. Öncelikle yardımcı ağ ortamı tam anlamıyla modelleyecek biçimde eğitilir ve geri yayılım her iki ağ boyunca uygulanabilir. Böylelikle asıl ağın her çıkışı, yardımcı ağdan gelen ayrı hata sinyallerine sahip olur.

Dinamik ortamlara uygulanabilen yardımcı ağın “tenkitçi” durumuna geldiği benzer bir yaklaşımda da, çevresel veri ve destek sinyali, sonraki destekleyici sinyali kestirmede kullanılır. Gerçek ve beklenen destekleyici sinyallerin kıyaslanması ile asıl ağın performansının beklentileri aştığı ya da düştüğü tespit edilebilir ve buna göre ödüllendirme veya cezalandırma yapılabilir [65].

### 5.6.3. Denetimsiz öğrenme

Denetimsiz öğrenmede, ağırlıklar ve hata eğilim vektörleri sadece ağın giriş tepkilerine göre değiştirilir. Hedeflenen çıkışlar elde yoktur. İlk bakışta pratik olarak görünmeyebilir. Kullanılan algoritmaların bir çoğu, bazı kümeleme işlemleri gerçekleştirir. Giriş örneklerinin sonlu bir sayıda sınıflandırılmasında kullanılırlar. Bu özellikle vektör kuantalama gibi uygulamalarda çok yararlıdır [62]. Genel olarak kendi düzenlenen bu tür ağlar girişi verisini sıkıştırma, kümeleme, kuantalama, sınıflama veya eşleme işlemleri için kullanılabilir.

Denetimsiz eğitimi gerçekleştirmenin bir yolu, her giriş örneği için yapay hedef göstererek yapıyı denetimli eğitim modeline benzeyecek biçimde yeniden

biçimlendirmek ve geri yayılımı uygulamaktır. Özellikle bir ağ, veriyi gizli nöronlar boyunca geçirirken, giriş örneklerinin çıkış katmanında yeniden oluşmasını sağlamak için eğitilebilir. Bu tür bir ağ gizli katmanında bilgiyi olabildiğince korumayı öğrenir. Bu yüzden gizli katman, giriş verisinin sıkıştırılmış bir gösterimi haline gelir. Bu tür ağlara, özellikle giriş ve çıkışlar ikili vektörler ise, genelde kodlayıcı-encoder denir. Bu ağların boyutsal indirgemeyi gerçekleştirdiği de söylenebilir.

Genelde gizli birimleri olmayan denetimsiz ağların diğer tipleri Hebbian öğrenmesi ile eğitilirler. Örneğin, giriş örneğindeki benzerliği algılamak için tek doğrusal birim bu öğrenme algoritması kullanılarak eğitilebilir. Bu öğrenme algoritmasının uzantıları ile  $M$  doğrusal çıkış birimli bir küme, bir giriş örneğini dağılımın  $M$  ana birleşenine yansıtmak için eğitilebilir. Böylece girişlerin sıkıştırılmış gösterimleri çıkış katmanında oluşacaktır. Ancak doğrusal birimlerle Hebb kuralı, ağırlıkların sınırı olmaksızın artmasına neden olacağından bu kural, ağırlıkların çok fazla büyümesini engelleyecek biçimde değiştirilmelidir. Bu değişikliklerden uygulanabilir olanlarından birisi Sanger Kuralı'dır.

Linsker, değiştirilmiş bir Hebbian öğrenme kuralının, her katmanı düzlemsel ve bir sonraki katmana geometrik olarak yerel bağlantıları olan çok katmanlı bir ağa uygulandığında, otomatik olarak yararlı özellik algılayıcıları geliştirebildiğini göstermiştir.

Halen diğer denetimsiz ağlar, çıkışların birinin kazanan olarak nitelendirildiği rekabetçi öğrenmeyi esas alır. Bu ağlar kazananın hepsini aldığı (winner-take-all) ağlar olarak da bilinir. Kazanan nöron, kaybeden nöronların kaybeden aktivasyonları sıfıra düşüren, çıkışlardaki yan engelleyici bağlantılar ya da sadece çıkış aktivasyonlarının karşılaştırılması incelenmesi ile bulunabilir. Rekabetçi öğrenme, giriş örneklerinin sınıflandırılması veya kuantalanması amacıyla yapılan veri kümelemesi için yararlıdır. Ancak bu öğrenme yöntemi ile bazı nöronlar, hiçbir zaman öğrenememeleri ile sonuçlanan, girişlerden hiçbir zaman kazanamayacakları kadar çok uzak olma durumları olabilir. Bunun gibi ölü nöronlar, ağırlıklara gerçek giriş örneklerini eşleyecek başlama

değerleri verilerek ya da kazanan her şeyi alır kısıtlaması biraz gevşetilerek kaybeden nöronlarında kazanalar gibi öğrenmeleri sağlanarak önlenabilir.

Carpenter ve Grossberg, sırasıyla ikili ve sürekli girişler için Uyarlamalı (Adaptif) Rezonans Teorisi ağları olan ART1 ve ART2 ağlarını geliştirmişlerdir. Bu ağlar, her ne zaman giriş örneği bir uyanıklık parametresine göre, mevcut herhangi bir kümeden yeteri kadar farklı ise, yeni bir küme oluşturma yolu ile rekabetçi öğrenmeyi destekler. Her zamanki gibi kümeler ayrı ayrı çıkış nöronları ile temsil edilir. Ama bir ART ağında çıkış nöronları kendilerine ihtiyaç duyuluncaya kadar saklanmışlardır. Bu tip ağları, donanımsal olarak uygulanabilecek arama yöntemleri kullanır.

Kohonen, topolojik bağlantıları korurken giriş uzayındaki örnekleri çıkış uzayına eşlerken olduğu gibi, özellik eşleştirmesini gerçekleştiren bir rekabetçi öğrenme algoritması geliştirmiştir.

#### **5.6.4. Melez ağlar**

Bazı ağlar, denetimli ve denetimsiz eğitimi farklı katmanlarında birleştirir. Genel olarak, denetimsiz eğitim, veriyi kümelemek için en düşük dereceli katmana uygulanır ve sonra bu kümeler ile istenen çıkışları ilişkilendirmek için geri yayılım daha üst katman veya katmanlarda uygulanır. Örnek olarak bir Radyal Esaslı Fonksiyon ağında, gizli katman standart rekabetçi öğrenme algoritması ile eğitilen hiperküreleri tanımlayan nöronları içerirken, Delta Kuralı ile eğitilmiş çıkış katmanı bu kavrayışlı alan fonksiyonlarının normalleştirilmiş doğrusal kombinasyonlarını hesaplar. Bu tür melez ağların cazibesi, çok katmanlı geri yayılım algoritmasını, eğitim süresini oldukça düşüren tek katmanlı Delta Kuralı'na indirgemesidir. Diğer bir yandan, bu tür ağlar, genelde entegre bir biçimde eğitilme yerine, bağımsız modüller açısından eğitildiklerinden, tamamen geri yayılım algoritması ile eğitilen ağlara göre biraz daha düşük doğruluğa sahiptir.

### 5.6.5. Dinamik ağlar

Yukarıdaki dört alt bölümde anlatılan statik yapıdaki ağların yanında, en iyi performansa erişmek için zamanla mimarileri değişen dinamik ağlar mevcuttur. Mimarinin değişmesi bir ağa nöron ve/veya ağırlık silinmesini veya eklenmesini içerir. Bu zıt yaklaşımlara sırasıyla budama-pruning ve yapım-construction denir. Bu yaklaşımlardan budama, sadece seçilen öğelerin göz ardı edilmesini içermesinden dolayı daha kolay olma eğilimindeyken, yapım algoritmaları, çoğu zaman küçük yapıda olmaları nedeniyle daha hızlı olma eğilimindedirler.

Tabi ki budama, ağdaki en az yararlı öğelerin tanımlanması için bir yöntem gerektirir. Karmaşık olmayan açık bir teknik, en küçük büyüklükte ağırlıkların silinmesidir. Bu genellemeyi geliştirebildiği gibi bazen de yanlış ağırlıkları çıkarır. Daha karmaşık ancak daha güvenilir bir yaklaşım olan En Uygun Beyin Hasarı-Optimal Brain Damage, kaldırılması ile ağırlık çıkış hata fonksiyonunda en az artışa neden olacak ağırlıkları tanımlar. Bu, bilginin ikinci dereceden türevinin hesaplanmasını gerektirir.

Yapıcı algoritmalar arasında, Cascade Correlation en yaygın ve etkili olanıdır. Bu algoritma gizli katmansız nöronu olmadan başlar, ama herhangi kalan çıkış hatasını kesilmesine yardımcı oldukları sürece kademeli olarak ekler. Eğitimin her aşamasında, ağdaki tüm önceki ağırlıklar dondurulur ve yeni bir aday birimleri havuzu çıkış olmayan tüm birimlere bağlanır. Her aday birim, birimin çıkışı ile ağırlık kalan hatası arasındaki bağlantının en yükseğe çıkarılması için eğitilir ve sonra en etkili birim tamamen ağla birleştirilirken diğer aday birimler atılır. Birimin çıkış katmanına olan ağırlığı iyi ayarlanmıştır. Bu işlem, ağ kabul edilebilir bir performansa ulaşmaya kadar tekrarlanır. Bu algoritma, çabuk bir biçimde mükemmel performans sergileyen, yoğun ve güçlü ağlar kurabilir.

Son olarak, Bodenhausen, Otomatik Yapı Eniyileştirilmesi-Automatic Structure Optimization adı verilen bir yapıcı algoritma geliştirmiştir. Özellikle kısıtlı eğitim verisinin verildiği, ses tanıma ve çevrimiçi el yazısı tanıma gibi uzay ve zamana ait

görevler için tasarlanmıştır. ASO algoritması küçük bir ağ ile başlar, ve daha sonra bağlantılar, zaman gecikmeleri, gizli nöronlar ve durum birimlerini içeren kaynakları ekler [65].

### 5.7. Geri Yayılım Algoritması

Geri yayılım algoritması, çok katmanlı ağların eğitilmesinde yaygın bir biçimde kullanılan algoritmadır. Delta kuralında olduğu gibi performans göstergesi, hata kareleri ortalaması olan algoritmanın delta kuralından tek farkı sadece bu algorithmada türevlerin hesaplanmasıdır. Tek katmanlı bir ağda hata, açıkça ağ ağırlıklarının doğrusal bir fonksiyonudur ve ağırlıklara göre türevi kolaylıkla hesaplanabilir. Doğrusal olmayan transfer fonksiyonlu çok katmanlı ağlarda ağ ağırlıkları ve hata arasındaki ilişki daha karmaşıktır. Türevlerin hesaplanmasında değişkenler hesabının zincir kuralı kullanılır.

Perseptron öğrenme kuralı ve delta kuralı algoritması tek katmanlı perseptron benzeri ağların eğitilmesi için tasarlanmıştır. Ancak bu tek katmanlı ağlarda, sadece doğrusal olarak ayrılabilen sınıflandırma problemlerini çözebildiklerinin verdiği dezavantajın sıkıntısı duyulmuştur. Bu kural ve algoritmaların tasarımcıları bu kısıtlamaların farkındaydılar ve bunun üstesinden gelebilmek için çok katmanlı ağları önermişler, ancak bu daha güçlü ağları eğitmek için algoritmalarını genelleştirememişlerdir.

Geçmişe bakıldığında çok katmanlı ağların eğitilmesi için bir algoritmanın ilk tanımlaması Werbos'un tezinde bulunmaktadır. Bu tez, genel ağlar bağlamında bir algoritma ile özel bir durum için sinirsel ağlar sunmuştur. Geri yayılım algoritmasının tekrar keşfedilerek yaygın biçimde kullanılması 1980'lerin ortalarını bulmuştur. Rumelhart, Hinton ve Williams, Parker, Le Cun gibi birbirlerinden bağımsız araştırmacılar tarafından ayrı ayrı bulunmuştur. Rumelhart ve McClelland'ın önderliğindeki Paralel Dağıtık İşleme Grubu'nun çalışması, Paralel Dağıtık İşleme kitabına dahil edilmesi ile yaygınlaşmıştır [62].

Bir ağı eğitmekteki amaç, bir giriş veri kümesine karşılık olarak özel bir fonksiyonel karakteristiği elde edebilmek için çıkışlar oluşturmak üzere ağırlıkların ayarlanmasıdır. Eğitmenin tam olabilmesi için, her bir giriş vektörüne karşılık istenen çıkış vektörünü gösteren bir hedef çıkış vektörü olmalıdır. Bu giriş ve hedef çıkış vektörleri bir eğitim çiftini oluşturur. Bir geri yayılım ağındaki öğrenme aşağıdaki basamaklardan oluşur [70].

1. Eğitim kümesinden bir sonraki eğitim çifti seçilir ve ağ girişine giriş vektörü uygulanır.
2. Ağın çıkış hesaplanır.
3. Ağ çıkışı ile istenen vektör (eğitim çiftindeki hedef vektör) arasındaki hata hesaplanır.
4. Hata küçültülecek şekilde ağın ağırlıkları ayarlanır.

Bu adımlar, performans kriteri, hata kareleri ortalaması olan bir ağda, hata kareleri ortalaması istenen belirli bir sınır değerinin altında kalması sağlanana kadar tekrar edilir. Bu sınır değeri ulaşıldığında ağın yapılacak iş için eğitildiği sonucuna varılır. İstenildiği zaman kullanılabilmesi amacıyla ağın bu koşulunu sağlayan ağırlıkları saptanır ve saklanır. Eğitimi yapılan işin uygulanması sırasında ağ, bu ağırlık değerlerini kullanarak sonuca ulaşır.

### 5.7.1. Algoritma

Şekil 5.12’de verilen 3 katmanlı bir ağ yapısını ele alacak olursak, 5.4 eşitliği ile verilen çok girişli bir nöronun çıkış eşitliğinden  $M$ ’nin katman sayısını ifade ettiği çok katmanlı bir ağ için matrisel gösterim ile;

$$\mathbf{a}^{m+1} = \mathbf{f}^{m+1}(\mathbf{W}^{m+1} \mathbf{a}^m + \mathbf{b}^{m+1}) \quad m = 0, 1, \dots, M - 1 \quad (5.13)$$

eşitliği elde edilebilir. İlk katmandaki nöronlar harici girişleri alacağından;

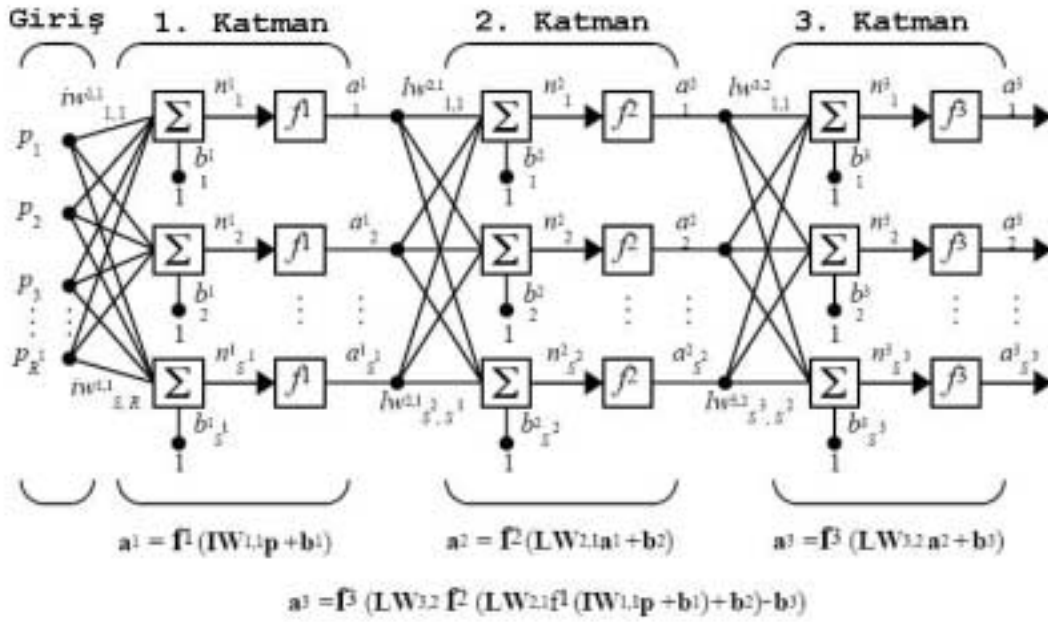


$$\mathbf{a}^0 = \mathbf{p} \quad (5.14)$$

olur ve 5.13 eşitliği için başlangıç noktası sağlar. Son katmandaki nöron çıkışları ağ çıkışı olarak nitelendirilir.

$$\mathbf{a} = \mathbf{a}^M \quad (5.15)$$

Yapılan bu ilk adım ileri yayılımdır (forward propagation).



Şekil 5.12. Üç katmanlı bir ağ

### 5.7.1.1 Performans göstergesi

Çok katmanlı ağlar için geri yayılım algoritması, genelleştirilmiş bir delta kuralı algoritmasıdır ve her iki algoritma da hata kareleri ortalamasını performans göstergesi

olarak kullanılmaktadır. Bu algoritma, aşağıdaki gibi verilen uygun ağ özelliklerini gösteren örnekler kümesi ile sağlanır.

$$\{\mathbf{p}_1, \mathbf{t}_1\}, \{\mathbf{p}_2, \mathbf{t}_2\}, \dots, \{\mathbf{p}_Q, \mathbf{t}_Q\}, \quad (5.16)$$

Burada  $\mathbf{p}_q$  ağ girişine uygulanan girişi ve  $\mathbf{t}_q$  ise uygun düşen hedef çıkışı göstermektedir. Ağa uygulanan her giriş için, ağ çıkışı hedef ile karşılaştırılır. Algoritma, hata kareleri ortalamasını en küçük değerine getirmek için ağ parametrelerini ayarlamalıdır.

$$F(x) = E[e^2] = E[(t - a)^2] \quad (5.17)$$

Burada  $x$  ağ ağırlık ve hata eğilim vektörleridir.  $E[\ ]$  ise beklenen değeri göstermek için kullanılır. Eğer ağın birden fazla çıkışı varsa 5.17 ile verilen eşitliği, 5.18 verilen eşitlik ile matrisel bir yapı ile genelleştirilebilir.

$$F(\mathbf{x}) = E[\mathbf{e}^T \mathbf{e}] = E[(\mathbf{t} - \mathbf{a})^T (\mathbf{t} - \mathbf{a})] \quad (5.18)$$

Delta kuralında olduğu gibi, hata karelerinin ortalaması yaklaşımı, karelerin hata beklentisi,  $k$  tekrarlamaındaki hata kareleri olarak değiştirilerek 5.19 eşitliği ile verilen yapıya dönüşür.

$$\hat{F}(\mathbf{x}) = (\mathbf{t}(k) - \mathbf{a}(k))^T (\mathbf{t}(k) - \mathbf{a}(k)) = \mathbf{e}^T(k) \mathbf{e}(k) \quad (5.19)$$

Yaklaşık hata karelerinin ortalaması için en dik iniş (steepest descent) algoritması ise  $\alpha$ 'nın öğrenme oranını gösterdiği 5.20 ve 5.21 eşitlikleri ile verilebilir.

$$w_{i,j}^m(k+1) = w_{i,j}^m(k) - \alpha \frac{\partial \hat{F}}{\partial w_{i,j}^m} \quad (5.20)$$

$$b_i^m(k+1) = b_i^m(k) - \alpha \frac{\partial \hat{F}}{\partial b_i^m} \quad (5.21)$$

Buraya kadar olan çıkarımlar delta kuralı ile aynıdır. Buradan sonra ise kısmi türev hesaplaması yapılacaktır.

### 5.7.1.2 Zincir kuralı

Hatanın, gizli katmanlardaki ağırlıkların dolaylı fonksiyonu olması nedeniyle, türevlerin hesaplanmasında zincir kuralı kullanılır. Zincir kuralını hatırlayacak olursak, değişkeni sadece  $n$  olan bir  $f$  fonksiyonunun, üçüncü bir değişken olarak  $w$ 'ye göre türevi alınmak istendiğinde, zincir kuralı aşağıda verilen 5.22 eşitliği gibi olmaktadır.

$$\frac{df(n(w))}{dw} = \frac{df(n)}{dn} \times \frac{dn(w)}{dw} \quad (5.22)$$

Örneğin  $f(n) = e^n$  ve  $n = 2w$  eşitlikleri ile  $f(n(w)) = e^{2w}$  elde edilirken zincir kuralından  $\frac{df(n(w))}{dw} = \frac{df(n)}{dn} \times \frac{dn(w)}{dw} \Rightarrow \frac{df(n(w))}{dw} = (e^n)(2)$  elde edilebilir.

5.20 ve 5.21 eşitliklerinde bulunan türev hesaplamaları, bu kural ile aşağıdaki yapılara dönüştürülebilir.

$$\frac{\partial \hat{F}}{\partial w_{i,j}^m} = \frac{\partial \hat{F}}{\partial n_i^m} \times \frac{\partial n_i^m}{\partial w_{i,j}^m} \quad (5.23)$$

$$\frac{\partial \hat{F}}{\partial b_i^m} = \frac{\partial \hat{F}}{\partial n_i^m} \times \frac{\partial n_i^m}{\partial b_i^m} \quad (5.24)$$

Yukarıda verilen 5.23 ve 5.24 eşitliklerinin her birinin ikinci kısımları,  $m$  katmanına giren net giriş, ağırlık ve hata eğilim vektörlerinin 5.25 eşitliği ile verilen bir fonksiyonu olduğundan kolayca hesaplanabilir. Buradan aşağıdaki eşitliklere ulaşılabilir.

$$n_i^m = \sum_{j=1}^{s^{m-1}} w_{i,j}^m a_j^{m-1} + b_i^m \quad (5.25)$$

$$\frac{\partial n_i^m}{\partial w_{i,j}^m} = a_j^{m-1} \quad (5.26)$$

$$\frac{\partial n_i^m}{\partial b_i^m} = 1 \quad (5.27)$$

Bu noktada, 5.23 ve 5.24 eşitliklerindeki her biri aynı olan ilk kısımları,  $\hat{F}$ 'in, net girişteki  $i$ 'nci elemanın değişimlerine olan duyarlılığı (sensitivity) olarak tanımlarsak, bu eşitlikler aşağıda verilen şekilde sadeleştirilebilir.

$$s_i^m \equiv \frac{\partial \hat{F}}{\partial n_i^m} \quad (5.28)$$

$$\frac{\partial \hat{F}}{\partial w_{i,j}^m} = s_i^m a_j^{m-1} \quad (5.29)$$

$$\frac{\partial \hat{F}}{\partial b_i^m} = s_i^m \quad (5.30)$$

5.20 ve 5.21 eşitlikleri ile verilen yaklaşık en dik iniş (steepest descent) algoritması aşağıdaki gibi ifade edilebilir.

$$w_{i,j}^m(k+1) = w_{i,j}^m(k) - \alpha s_i^m a_j^{m-1} \quad (5.31)$$

$$b_i^m(k+1) = b_i^m(k) - \alpha s_i^m \quad (5.32)$$

Matrisel yapıda ise aşağıdaki eşitlikler ile ifade edilebilir.  $s$  matrisi de verilmiştir.

$$\mathbf{W}^m(k+1) = \mathbf{W}^m(k) - \alpha \mathbf{s}^m (\mathbf{a}^{m-1})^T \quad (5.33)$$

$$\mathbf{b}^m(k+1) = \mathbf{b}^m(k) - \alpha \mathbf{s}^m \quad (5.34)$$

$$\mathbf{s}^m \equiv \frac{\partial \hat{F}}{\partial \mathbf{n}^m} = \begin{bmatrix} \frac{\partial \hat{F}}{\partial n_1^m} \\ \frac{\partial \hat{F}}{\partial n_2^m} \\ \vdots \\ \frac{\partial \hat{F}}{\partial n_{s^m}^m} \end{bmatrix} \quad (5.35)$$

### 5.7.1.3 Duyarlılıkların geri yayılımı

Algoritmanın tamamlanabilmesi için, zincir kuralının bir başka uygulamasının kullanılmasını gerektiren  $\mathbf{s}^m$  duyarlılıklarının hesaplanması gerekmektedir. O, bize geri yayılım terimini sağlayan bu işlemdir. Çünkü,  $m$  katmanındaki duyarlılığın  $m+1$  katmanındaki duyarlılıktan hesaplanmasıyla yinelenen bir ilişki tanımlar.

Duyarlılıkların yinelenen ilişkilerinin türevlerini almak için, aşağıdaki Jacobian matrisi kullanılır.

$$\frac{\partial \mathbf{n}^{m+1}}{\partial \mathbf{n}^m} \equiv \begin{bmatrix} \frac{\partial n_1^{m+1}}{\partial n_1^m} & \frac{\partial n_1^{m+1}}{\partial n_2^m} & \cdots & \frac{\partial n_1^{m+1}}{\partial n_{s^m}^m} \\ \frac{\partial n_2^{m+1}}{\partial n_1^m} & \frac{\partial n_2^{m+1}}{\partial n_2^m} & \cdots & \frac{\partial n_2^{m+1}}{\partial n_{s^m}^m} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial n_{s^{m+1}}^{m+1}}{\partial n_1^m} & \frac{\partial n_{s^{m+1}}^{m+1}}{\partial n_2^m} & \cdots & \frac{\partial n_{s^{m+1}}^{m+1}}{\partial n_{s^m}^m} \end{bmatrix} \quad (5.36)$$

Bu matris için bir ifade bulmak için yapılacak olan çalışmada, matrisin  $i,j$  elemanını ele alırsak;

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

$$f^m(n_j^m) = \frac{\partial f^m(n_j^m)}{\partial n_j^m}$$
(5.37)

Bu nedenle, Jacobian matrisi aşağıdaki şekilde yazılabilir.

$$\frac{\partial \mathbf{n}^{m+1}}{\partial \mathbf{n}^m} = \mathbf{W}^{m+1} \mathbf{F}^m(\mathbf{n}^m)$$
(5.38)

$$\mathbf{F}^m(\mathbf{n}^m) = \begin{bmatrix} f^m(n_1^m) & 0 & \cdots & 0 \\ 0 & f^m(n_2^m) & \cdots & 0 \\ \vdots & \vdots & & \vdots \\ 0 & 0 & \cdots & f^m(n_{s^m}^m) \end{bmatrix}$$
(5.39)

5.35 eşitliğindeki duyarlılık için yinelenen ilişki, zincir kuralı kullanılarak aşağıdaki eşitlik yapısına dönüştürülerek elde edilebilir.

$$\mathbf{s}^m = \frac{\partial \hat{F}}{\partial \mathbf{n}^m} = \left( \frac{\partial \mathbf{n}^{m+1}}{\partial \mathbf{n}^m} \right)^T \frac{\partial \hat{F}}{\partial \mathbf{n}^{m+1}} = \mathbf{F}^m(\mathbf{n}^m) (\mathbf{W}^{m+1})^T \frac{\partial \hat{F}}{\partial \mathbf{n}^{m+1}} = \mathbf{F}^m(\mathbf{n}^m) (\mathbf{W}^{m+1})^T \mathbf{s}^{m+1}$$
(5.40)

Elimizdeki bu eşitlik ile geri yayılımın adını nereden aldığını da görebiliriz. Duyarlılıklar ağın son katmanından ilk katmanına geriye doğru yayılmıştır.

$$\mathbf{s}^M \rightarrow \mathbf{s}^{M-1} \rightarrow \dots \rightarrow \mathbf{s}^2 \rightarrow \mathbf{s}^1$$
(5.41)

Geri yayılım algoritmasının tamamlanması için yapılması gereken son bir adım daha vardır. 5.40 eşitliğindeki yinelenen ilişki için bir başlangıç noktasına,  $\mathbf{s}^M$ , ihtiyaç vardır. Bu son katmanda elde edilir.

$$s_i^M = \frac{\partial \hat{F}}{\partial n_i^M} = \frac{\partial (\mathbf{t} - \mathbf{a})^T (\mathbf{t} - \mathbf{a})}{\partial n_i^M} = \frac{\sum_{j=1}^{s^M} (t_j - a_j)^2}{\partial n_i^M} = -2(t_i - a_i) \frac{\partial a_i}{\partial n_i^M} \quad (5.42)$$

Burada;

$$\frac{\partial a_i}{\partial n_i^M} = \frac{\partial a_i^M}{\partial n_i^M} = \frac{\partial f^M(n_i^M)}{\partial n_i^M} = f^M(n_i^M) \quad (5.43)$$

olduğundan 5.42'deki eşitlik;

$$s_i^M = -2(t_i - a_i) f^M(n_i^M) \quad (5.44)$$

olarak yazılabilir. Bu yapının matrisel yapısı ise 5.45 eşitliği ile verilebilir.

$$\mathbf{s}^M = -2\mathbf{F}^M(\mathbf{n}^M)(\mathbf{t} - \mathbf{a}) \quad (5.45)$$

Özetleme yapacak olursak; ilk adım olarak giriş ağ boyunca ileriye doğru yayılır:

$$\mathbf{a}^0 = \mathbf{p} \quad (5.46)$$

$$\mathbf{a}^{m+1} = \mathbf{f}^{m+1}(\mathbf{W}^{m+1} \mathbf{a}^m + \mathbf{b}^{m+1}) \quad m = 0, 1, \dots, M-1 \quad (5.47)$$

$$\mathbf{a} = \mathbf{a}^M \quad (5.48)$$

Bir sonraki adım duyarlılıkların ağ boyunca geri yayılımının yapılmasıdır:

$$\mathbf{s}^M = -2\mathbf{F}^M(\mathbf{n}^M)(\mathbf{t}-\mathbf{a}) \quad (5.49)$$

$$\mathbf{s}^m = \mathbf{F}^m(\mathbf{n}^m)(\mathbf{W}^{m+1})^T \mathbf{s}^{m+1}, \text{ for } m = M-1, \dots, 2, 1 \quad (5.50)$$

Son olarak da ağırlıklar ve hata eğilim vektörleri, yaklaşık en dik iniş kullanılarak güncellenir:

$$\mathbf{W}^m(k+1) = \mathbf{W}^m(k) - \alpha \mathbf{s}^m (\mathbf{a}^{m-1})^T \quad (5.51)$$

$$\mathbf{b}^m(k+1) = \mathbf{b}^m(k) - \alpha \mathbf{s}^m \quad (5.52)$$

### 5.7.2 Geri yayılımdaki değişiklikler

Geri yayılım algoritması sinirsel ağ çalışmalarındaki büyük atılımlardan biri olmasına rağmen temel algoritma, bir çok pratik uygulama için çok yavaştır. Bunun aşılabilmesi için araştırmacılar bu algoritmanın yakınsamasını hızlandırılabilmesini amaçlayan yöntemler üzerine önemli çalışmalar yapılmıştır. Bu çalışmalar kabaca iki ana sınıfta incelenebilir.

- Geri yayılımın bulgusal değişiklikleri
- Geri yayılımın sayısal değişiklikleri

Bulgusal değişiklikler altında momentum, değişken öğrenme oranı (VLBP) ve değişkenlerin yeniden ölçeklendirilmesi çalışmaları sayılabilir. Sayısal çalışmalarda ise conjugate gradient algoritması ve Levenberg-Marquardt algoritması(LMBP) sayılabilir. Bu algoritmaların tamamı, türevleri son katmandan ilk katmana doğru olan geri yayılıma yöntemini kullandıklarından, tamamı geri yayılım algoritmaları olarak isimlendirilebilir [62].



## 5.8 Yapay Sinir Ağlarının Uygulamaları

1988 yılında DARPA Sinirsel Ağ Çalışmaları, 1984 yılındaki uyarlamalı kanal dengeleyicisinden itibaren yapılan çeşitli sinirsel ağ uygulamalarını listelemiştir. Üstün ticari başarıya ulaşan bu aygıt, uzun mesafeli telefon sistemlerinde ses sinyallerinin dengede tutulması için kullanılan tek nöronlu bir ağdan oluşur. DARPA raporunda, küçük kelime algılayıcı, işlem monitörü, sonar sınıflayıcı ve risk analiz sistemi gibi uygulamalar yer almıştır.

DARPA raporunun yayınlanmasından bu yana sinirsel ağlar başka bir çok alana uygulanmıştır. Aşağıda literatürdeki bazı uygulamaların bir listesi verilmiştir.

- Havacılık: Uçaklar için yüksek performanslı otomatik pilot, uçuş rota simülasyonu, uçak kontrol sistemleri, otomatik pilot gelişmeleri, uçak parçalarının simülasyonu, uçak parçalarının hata algılaması.
- Otomotiv: Otomobil otomatik yol gösterim sistemi, garanti aktivite analizi.
- Bankacılık: Çek ve diğer doküman okuma, kredi başvuru değerlendirme, garip kredi kartı aktivitelerinin tespiti
- Savunma: Silah yönlendirme, hedef izleme, nesne ayırt etme, yüz tanıma, yeni tür algılayıcılar, veri sıkıştırma da dahil olma üzere sonar, radar ve görüntü işaretlerinin işlenmesi, özellik çıkarımı ve gürültü bastırılması, işaret/görüntü tanımlama.
- Elektronik: Kod sırası kestirimi, tümleşik devre yonga yerleşimi, süreç denetimi, yonga hata analizi, makine görmesi, ses sentezleme, doğrusal olmayan modelleme.
- Eğlence: Animasyon, özel efektler, pazar tahmini.
- Finans: Gayrimenkul değerlendirme, borçlanma tavsiyesi, tutulu ev kredisi araştırılması, ortak bono değerlendirme, kredi hattı kullanım analizi, portföy ticaret analizi, ortak finansal analiz, döviz değeri kestirimi.

- Endüstri: Bugüne kadar bazı fırınların çıkış gazlarının kestirimi ve diğer bir çok endüstriyel işlemlerde kullanılmıştır. Sonra da bu amaçla kullanılan karmaşık ve maliyeti yüksek donanımın yerini almışlardır.
- Sigorta: Poliçe başvuru değerlendirmesi, ürün en iyileştirmesi.
- Üretim: Üretim süreç denetimi, ürün tasarımı ve analizi, süreç ve makine tanı işlemleri, gerçek zamanlı nesne tanıma, görsel kalite gözlem sistemleri, kaynak kalite analizi, kağıt kalite kestirimi, bilgisayar yongası kalite analizi, öğütme işlemlerinin analizi, kimyasal ürün tasarım analizi, makine bakım analizi, proje teklifleri, planlama ve yönetim, kimyasal sistemlerin dinamik modellenmesi.
- Tıbbi: Göğüs kanser hücresi analizi, EEG ve ECG analizi, protez tasarımı, organ nakli zamanlamasının en iyileştirilmesi, hastane giderlerinin azaltılması, hastane kalitesinin geliştirmesi, acil odası test danışması.
- Petrol ve Gaz: Arama
- Robotbilim: Yörünge kontrolü, çatal kaldırıcılı robot, uzaktan el ile çalıştırılan aygıtların denetleyicileri, görüş sistemleri.
- Konuşma: Konuşma tanıma, konuşma sıkıştırma, ünlü ses sınıflaması, metinden ses sentezlenmesi.
- Haberleşme: Görüntü ve veri sıkıştırma, otomatikleşmiş bilgi hizmetleri, gerçek zamanlı olarak konuşulan dilin bir başka dile çevrilmesi, müşteri ödeme işlem sistemleri.
- Taşıma: Araç programlama, güzergah belirleme sistemleri.

Burada verilen sinirsel ağ uygulamalarının listesi, sinirsel ağ yazılım ve donanımına yapılan yatırım miktarı ve bu aygıtlara olan ilginin derinliği ve genişliği hızlı biçimde artmaktadır [72].

## **BÖLÜM 6. MODELLEME**

### **6.1. Giriş**

Giriş bölümünde de anlatıldığı üzere, bu tez çalışmasının içeriğinde yapılmak istenen, elde bulunan gerçek çalışma verilerinin kullanılarak yüksek fırının ürünü olan pik demir kalitesine ait bazı değerleri sinirsel ağlar kullanarak kestirmektir. Yani amaç, girişine uygulanacak bir giriş kümesi ile istenen çıkış değerlerini elde eden bir sinirsel ağ modeli oluşturmaktır. Bununla birlikte, modellemede mutlaka göz önüne alınması gereken giriş ve çıkış değerleri arasında bulunan zaman gecikmesinin, bugüne kadar yapılan ve inceleme fırsatı bulunan çalışmalarda uygulanandan farklı bir bakış açısı ile ele alınarak sinirsel ağa uygulanması gerçekleştirilmiştir. Çalışma, bir demir çelik fabrikasının 2003 yılındaki iki aylık gerçek çalışma verisi ile yapılmıştır.

### **6.2. İncelenen YSA Araçları**

Çalışma için gerekli olan yapay sinir ağının gerçekleştirilmesi için günümüzde yaygın olarak kullanılan programlama dilleri kullanılabileceği gibi, araştırma veya ticari amaç ile üretilmiş bir çok yapay sinir ağı araçları da kullanılabilir. Çalışmanın esas amacı bir yüksek fırının modellenmesi olması sebebiyle, algoritmanın programlama dilleri vasıtasıyla yazılmasının yerine, mevcut araçlardan birinin kullanılmasına karar verilmiştir. Bu amaçla erişim sağlanan çeşitli araçların inceleme ve deneme fırsatı bulunmuştur.

İlk olarak Almanya Stuttgart Üniversitesi'nin geliştirdiği Stuttgart Sinirsel Ağ Simülatörü-SNNS incelenmiştir. İncelenen bazı çalışmalarda da kullanılan bu araç Unix tabanlı sistemler için geliştirilmiş olsa da Windows tabanlı sistemler için de sürümü

vardır. C programla dili ile yazılmış ve kaynak kodları açık olan bir çekirdeğe sahiptir. X11-R4 ve X11-R5 altında çalışan, ağların iki ve üç boyutlu gösterimine olanak veren grafiksel ara yüzü mevcuttur. Geri yayılım algoritması başta olmak üzere bir çok ağ yapısını desteklemektedir.

İncelenen ve denemeler yapılan bir diğer sinirsel ağ aracı JavaNNS'dir. Java programlama dili ile geliştirilen SNNS ile uyumlu olan bu araç, her ne kadar SNNS'in bir devamı olarak geliştirilse de SNNS kadar yaygınlaşmamıştır.

Ticari bir yazılım olan NeuroSolutions programı ve beraberinde gelen örnek uygulamalar incelenmiştir. Windows işletim sistemi altında simgeler üzerine kurulu grafiksel bir ara yüz ile kolay kullanıma sahip ve günümüzde yaygın olarak kullanılan bir çok sinirsel ağ modeli destekleyen bir programdır.

Son olarak Matlab programının araçlarında biri olan Sinirsel Ağ Aracı-Neural Network Toolbox (nntool) incelenmiştir. Çok yaygın olarak kullanılan bu aracın, programın R2006a sürümü ile gelen Sinirsel Ağ Deneme Aracı-Neural Network Fitting Tool (nftool), LMBP eğitim algoritması kullanan ileri beslemeli sinirsel ağların kullanımını oldukça kolaylaştıran bir araçtır.

Sonuç olarak çalışmalar, kullanım kolaylığı, modelleme işleminden önce ve sonra sağladığı veri işleme olanakları nedeni ile Matlab programı kullanılarak yapılmıştır.

### 6.3. Çıktılar

Daha önce de bahsedildiği gibi yüksek fırınlar pik demir üretmek için kullanılan tesislerdir. Üretilen her üründe olduğu gibi pik demirin de, hem yüksek fırının çalışması hakkında bilgi veren hem de çelikhane için önemli olan bazı kalite değişkenleri mevcuttur. Kullanılan farklı giriş malzemelerinin miktar ve kaliteleri olduğu kadar çevresel faktörler de üretilen pik demirin kalitesi üzerinde etkilidir. Kalite değişkenleri arasında, üretilen pik demirin sıcaklığı, kimyasal kompozisyonu, fırın verimliliği

açısından üretilen miktar, yan ürün olan curufun kimyasal kompozisyonu gibi parametreler sayılabilir. Ancak bunlar arasında pik demir sıcaklığı, pik demir kompozisyonu ve fırın çalışma şartları hakkında genel bilgi sağlayan pik demir silisyum içeriği ve curuf bazitesi öne çıkan değişkenlerdir. Yapılan bu tez çalışmasında esas olarak pik demir sıcaklığının kestirilmesi için modelleme yapılmış olsa da diğer iki değişken için de aynı yöntemler kullanılarak modelleme denemesi yapılmıştır. Bahsedilen iki değişkenin modellenmesinde kestirilen pik demir sıcaklığı da bir giriş parametresi olarak kullanıldığından, ilk olarak pik demir sıcaklığının kestirilmesi için çalışma yapılmıştır. Daha sonra ise pik demir sıcaklığını kestirilmesinde izlenen aynı adımlarla diğer 2 çıkış değişkeninin kestirilmesi yapılmıştır.

### 6.3.1. Pik demir sıcaklığı

Aralığı 1350-1550 arasında değişebilen, pik demirin yüksek fırından çıkış sıcaklığını gösteren değerdir. Pik demirin kalitesinde çok önemli bir değişken olmakla birlikte fırının kontrolü ve çalışma şartlarının da bir göstergesidir. Fırın içi alt bölgelerinden herhangi bir sıcaklık ölçümü alınabilmesi mümkün değildir. Bu nedenle özellikle pik demir sıcaklığı fırının çalışma şartlarını göstermesi açısından önem kazanmaktadır. Yüksek fırın operatörlerinin fırına gönderilen malzemelerde yaptıkları değişikliklerde göz önüne alınan en önemli değişkendir. Sıcaklık ölçümünde, sürekli ölçüm için kızılötesi aygıtlar kullanılabildiği gibi yaygın olarak ise ısı çifti (thermocouple) kullanılmaktadır. Isı çiftinin kullanım sebebi sıvı pik demir içine daldırılarak sağlıklı ölçüm sağlayabilmesidir. Sürekli ölçüm sağlayan aygıtlar ise sıcaklığı sadece yüzeyden ölçtüğü için gerçek sıcaklığı yansıtmayabilmektedirler. Ölçümler yüksek fırın döküm deliğinden çıkan sıvı pik demirin ve curufun birlikte aktığı yerden değil, pik demir ve curuf ayrımının yapıldığı sifondan sonra yapılmaktadır. Dolayısıyla ölçümler, dökümün açık olduğu, yani fırından sıvı pik demir alınırken yapılmaktadır. Döküm açma sıklığı yüksek fırının büyüklüğüne ve döküm deliği sayısına göre değişmekle beraber düzeni olmayan bir sıklıkta yapılmaktadır. Pik demir sıcaklığı ölçüm sıklığı ise tamamen işletme şartlarına göre değişmektedir.

### 6.3.2. Pik demir silisyum içeriği

Pik demir içeriğindeki silisyum miktarı kalite ve kontrol amaçları doğrultusunda çok önemlidir. Pik demir sıcaklığı, curuf içerisindeki  $SiO_2$  aktivitesi, pik demirdeki oksijen aktivitesi ve eriyikler silisyum içeriğini doğrudan etkiler. Silisyum miktarı önemli bir kalite göstergesi olduğu kadar, pik demir silisyum içeriğinde, pik demir sıcaklığındaki değişimlere uyan bir çok dinamik değişikliğin yer aldığı yüksek fırının yüksek sıcaklıklardaki alt bölgesinin iç durumunu yansıtır. Bu, silisyum içeriğini yüksek fırın kontrolü için önemli bir değişken haline getirir. Çoğu zaman, operatörler ilerleyen bir çok tepkimenin boyutları hakkında ki yorumlarını  $SiO_2$  indirgenmesinin boyutunu esas alarak yaparlar. Silisyum içerik oranının tekdüzeliği, doğruluğu ve gelişmiş kestirimi yüksek fırın çalışma şartlarını dengede tutmak açısından fazlasıyla yardımcı olabilir. Ayrıca pik demirin silisyum içeriği, pik demirin çelik yapılmak üzere gönderildiği çelikhanede ilk olarak işlem gördüğü oksijen fırınlarındaki oksijen yük dengesinde de belirleyiciliği vardır [26]. Pik demirin silisyum içeriği akan eriyikten alınan numunenin spektrometre ile yapılan analizi ile elde edilir. Ölçüm sıklığı dökümden alınan pik demir miktarına göre değişmektedir.

### 6.3.3. Curuf bazitesi

İçeriğinin yaklaşık %99'u  $CaO$ ,  $SiO_2$ ,  $Al_2O_3$ ,  $MgO$  ve  $S$  olan yüksek fırın curufu, demir cevherindeki demir haricindeki maddelerin kireçtaşı ile tepkimesi sonucu oluşur. Oluştuktan sonra erimiş demir üzerinde kalır ve pik demirden ayrı olarak fırından alınabileceği gibi genel olarak döküm deliğinden pik demir ile birlikte alınır. Sıvı demirin üretilmesi sırasında oluşan indirgenme süreçlerinde curufun önemli fonksiyonları vardır. Hammadde içerisinde olan ancak pik demir içerisinde istenmeyen bileşenlerin ayrılmasını sağlar. Curuf pik demir ile karşılaştırıldığında sahip olduğu düşük akışkanlık, düşük yoğunluk ve bileşenlerinin gaz halindeki basınçlarının düşüklüğü ile pik demirden ayrılması kolaylıkla sağlanabilir. Genel olarak bu işlem için döküm kanalında bulunan ve sifon olarak adlandırılan bir yapı kullanılır. Her ne kadar yüksek

fırın curufu kimyasal tepkimeler sonucu oluşan bir atık olsa da, kimyasal özellikleri ve yapısı sayesinde satılabilir bir yan ürün niteliği kazanır. Özellikle çimento hammaddesi olarak kullanılmaktadır. Curuf bazitesi, içerisinde bulunan bazı bileşenlerin oranı olarak tanımlanabilir. Bu değişken de üretilen pik demir kalitesini etkileyen bir değişkendir. Curuf kimyasal kompozisyonuna göre birkaç hesaplama yöntemi olmakla beraber genel olarak kullanılan iki hesaplama yöntemi aşağıda verilen eşitlikler ile yapılır.

$$B2 = \frac{\%CaO}{\%SiO_2} \quad (6.1)$$

$$B4 = \frac{\%CaO + \%MgO}{\%SiO_2 + \%Al_2O_3} \quad (6.2)$$

#### 6.4. Pik Demir Sıcaklığının Kestirilmesi

Yukarıda bahsedildiği gibi ilk olarak öncelikli amaç olan pik demir sıcaklığının kestirilmesi için modelleme çalışması yapılmıştır.

##### 6.4.1. Uygun değişkenlerin seçilmesi

Modelleme çalışması için sinirsel ağ modeli ve bir öğrenme algoritmasının seçimi yapılmadan önce yapılması gereken en önemli çalışma, modelin verimli bir şekilde çalışmasını sağlayacak giriş veri setinin belirlenmesidir. Bir yüksek fırında yüzlerce nokta izlenir ve saklanır. Bu noktalardan bir çoğu pik demir sıcaklığını az ya da çok etkiler. Mevcut bulunan yüzlerce noktadan hangilerinin çıkış pik demir sıcaklığında etkili olduğunun belirlenerek model girişine uygulanması kolay bir süreç değildir. Etkisi çok küçük değişkenlerin modele katılması modelin eğitimini ve kullanımını zorlaştırırken, önemli değişkenlerin de modellemede kullanılmaması, modelin doğruluğunu saptıracaktır.

Bugüne kadar yapılan çalışmalar incelendiğinde kullanılan değişkenlerin genelde aynı değişken gruplarında yoğunlaştığı görülmüştür. Kullanılan giriş kümesi, bu çalışmalar

ışığında seçilse de bazı noktalar eklenmiş veya kullanım yöntemleri değiştirilmiştir. Seçilen değişkenler genel itibarı ile operatörler tarafından pik demir sıcaklığını kontrol etmek için kullanılan değişkenleri içerdiği gibi fırın çalışma şartlarını gösteren bazı değişkenleri de içermektedir. Aşağıda verilen tablo 6.1’de seçilen ve girişe uygulanacak yüksek fırın değişkenleri gösterilmiştir.

Tablo 6.1. Seçilen yüksek fırın değişkenleri

Hava akış miktarı
İlave buhar akışı
İlave oksijen akışı
Kömür enjeksiyon miktarı
Sıcak hava sıcaklığı
Duvar hareketi
Saatlik şarj sayısı
Tepe sıcaklığı
Tepe gazı $H_2$ miktarı
Tepe gazı $CO$ miktarı
Tepe gazı $CO_2$ miktarı
Kullanılan kok miktarı
Kullanılan demirli malzeme miktarı
Kullanılan curuf yapıcı malzeme miktarı
Geçirgenlik
Kok rutubeti
Dökümhane değişimi

Fırın üstünden şarj edilen malzeme miktarları hariç olmak üzere bu veriler, 30’ar saniyelik aralıklarla okunan ve bu değerlerin her 5 dakikada bir ortalama değerinin saklanması ile oluşan değerlerdir. Fırın üstünden şarj edilen malzemeler ise fırına şarj edildiği andaki değerleri saklanmaktadır. Bunlara ilaveten ölçülen bir önceki pik demir





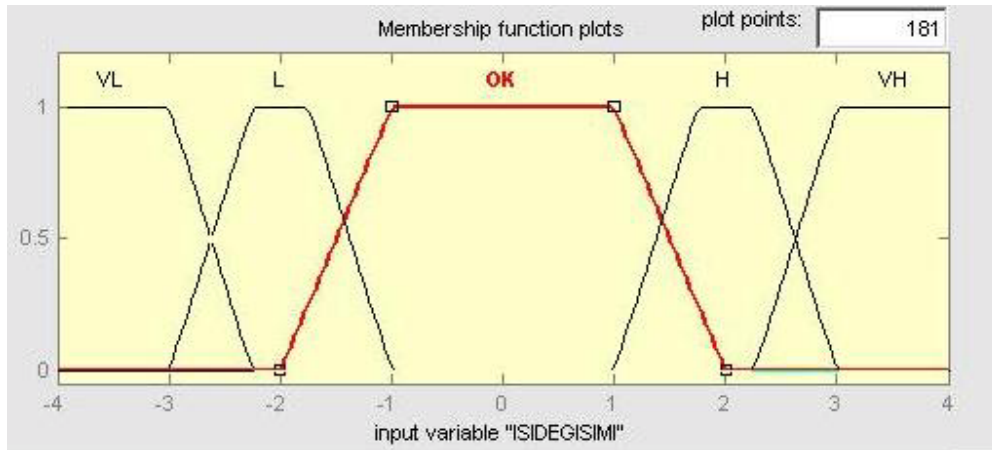
Bir dinamik modelleme için bu özellikler de dikkate alınmalıdır. Burada kestirilmesi planlanan değişkenin değeri, giriş değişkenlerinin örnekleme oranına eşit bir örnekleme oranı ile ölçülemez olgusu, bu değerlerin modele verilmeden önce düzgün dağılımlı değerler elde edebilmek için bir ön işleme tabii tutulması gerekliliğini ortaya çıkarır. Bu eldeki verinin ara değer kestirimi (interpolasyon) aracılığı ile yapılabilir. Bir diğer yol ise zamanı açıkça model içerisinde katmaktır [29].

#### **6.4.2. Duvar hareketlerinin tespiti**

Yüksek fırınlarda duvar hareketleri, fırın iç çeperine yapışmış olan alkali malzemenin işletme isteği ile yapılan operasyonlarla veya çalışma şartları nedeniyle yapıştıkları yerden koparak fırın haznesine inmesidir. İşletme isteği ile kontrollü bir biçimde yapıldığında, kopacak parçalara göre haznede oluşacak soğumaya karşı önlem alındığından genelde herhangi bir sorun ile karşılaşılmaz. Ancak bazı durumlarda hazneye inen parçalar hazneye göre çok soğuk olduklarından haznede eriyerek hazne ısısında düşmeye, dolayısı ile de pik demir ve curuf sıcaklıklarının düşmesine neden olur. Bu yüzden modellemede bu durumun da göz önünde bulundurularak, duvar hareketlerinden kaynaklanacak anormalliklerin de tespit edilmesi gereklidir.

Bu olay bugüne kadar yapılmış olan çalışmalarda, fırın etrafında birkaç katta mevcut soğutma suyu giriş ve çıkış sıcaklık ölçümleri ve buralardan geçen su miktarı ile hesaplanan ısı akılarının tamamının veya birkaç katın modele katılması ile yapılmıştır. Bu çalışmada ise hesaplanmış ısı akıları bir bulanık küme işlemine tabii tutularak duvar hareketi olasılığı belirlenmiş ve bu olasılık modele uygulanmıştır. Bu sayede sadece birkaç kat değil tüm katlarda oluşan duvar hareketleri göz önüne alınırken, ısı akıları ile ilgili olarak sadece bir nokta girişe uygulandığından sinirsel ağı eğitilmesi ve kullanılmasında ortaya çıkabilecek olumsuzlukların önüne geçilmeye çalışılmıştır. Bu bölümde kullanılan bulanık küme yapısından bahsedilecektir.

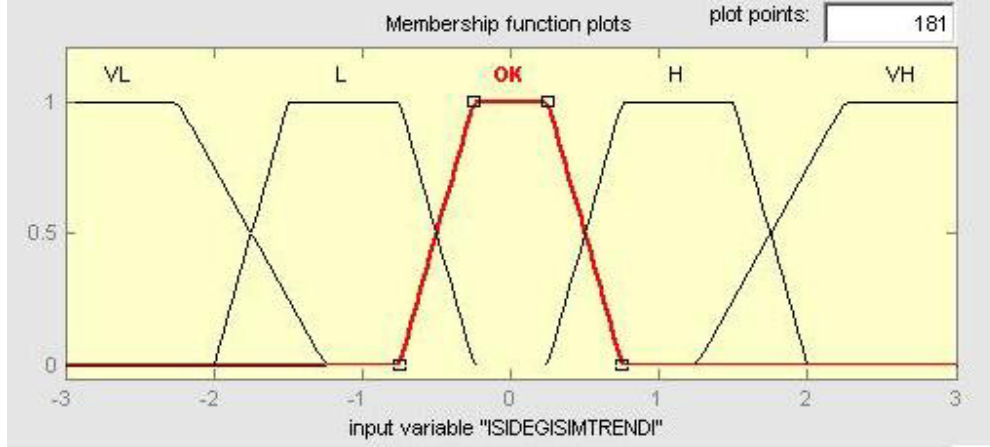
Duvarlarda oluşan hareketler iki yönlüdür. Ya duvardan parça koparak duvarın incilmesi ve duvar yüzeyinin ısınması ve bu nedenle soğutma suyu sıcaklıklarında yükselme, ya da duvara alkali yapışması ile duvar oluşumu sonucu duvar yüzeyinin soğuması ve soğutma suyu sıcaklıklarında düşme meydana gelir. Bunların tespit edilebilmesi için ısı değişim miktarlarını ve hızlarını göz önüne almak gerekir. Bunun için bir Mamdani bulanık çıkarım sistemi oluşturulmuş ancak bu aynı girişler, farklı kurallar ile iki kere kullanılarak duvar oluşumu veya duvar kopma hareketi tespit edilmeye çalışılmıştır. Elde edilen çıktılar ise birlikte kullanılmıştır. Çıkarım sisteminde elimizde mevcut olan ısı değişimleri ile ısı değişim trendleri kullanılmıştır. Kullanılan ısı değişimi ve ısı değişim trendinin üyelik fonksiyonları, çıkış üyelik fonksiyonları, çıkarım sisteminin oluşan iki yüzeyi aşağıdaki şekillerde verilmiştir.



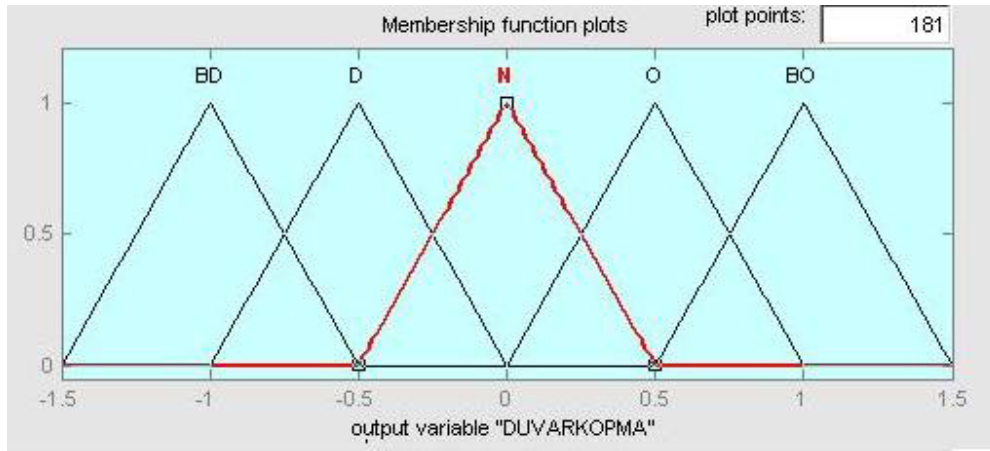
Şekil 6.2. Isı değişimi üyelik fonksiyonları

Isı değişimi ile nitelenen değer, belirli bir süre içerisindeki toplam ısı akı ortalaması göz önüne alınarak, belirlenen süre içerisinde oluşan ısı akısı arasındaki farkın yüzdesel olarak ifadesidir. Burada ortalaması alınan süre 12 saat olarak alınmıştır. Isı değişiminin kontrol edildiği süre ise 15 dakikadır. Özetle ısı değişimi aşağıda verilen eşitlik ile bulunabilir.

$$ISIDEGISIMI = \frac{Ak_{15 \text{ dakika}} - Ak_{12 \text{ saat}}}{Ak_{12 \text{ saat}}} * 100 \quad (6.3)$$




Şekil 6.3. Isı değişim trendi üyelik fonksiyonları



Şekil 6.4. Bulanık çıkarım çıkış üyelik fonksiyonları


Yukarıda da bahsedildiği gibi bu üyelik fonksiyonları her iki çıkarım sistemi içinde kullanılmış ancak kurallar değiştirilmiştir. Bulanık çıkarım sistemine otuz yedişer kural yazıldıktan sonra oluşan yüzeyler aşağıdaki gibidir.



Şekil 6.5. Bulanık çıkarım yüzeyleri

Buradaki genel işleyişi anlatmak gerekirse, yürütülen mantık, çıkış değerinin merkeze, yani sifira, yakın olduğu durumlarda herhangi bir hareketin olmadığı yönündedir. Artı veya eski yönde olan çıkış değerleri ise kopmanın başlamasını, başlamış olan bir kopmanın devamını, duvar oluşumunu veya duvar oluşumunun devamını göster. Giriş değerleri her iki çıkarım sistemine de uygulanır ve elde edilen çıkış değerlerinin mutlak değerleri alınır. Daha sonra elde edilen iki değer karşılaştırılır ve büyük olan çıkışın güçlü olduğu varsayımı ile duvar oluşumuna veya duvar kopmasına karar verilir. Diğeri ise sıfırlanır.

Duvar kopması tespit edildikten sonra ise bu hareketin büyüklüğünü tespit etmek önemli hale gelmektedir. Bu da toplanarak toplam akıyı oluşturan fırının her bölgesindeki soğutma plakalarına giren su giriş ve çıkış sıcaklıklarının ayrı ayrı ele alınarak değerlendirilmesi ile yapılmıştır. Isı akıları yukarıdaki ısı değişiminde olduğu gibi 12 saatlik ortalama değerleri, son 15 dakikalık değerleri ile karşılaştırılmış ve artı yönde olanlar sıcak olarak nitelendirilmiştir. Sıcak plaka sayısı ile kopan parçanın kapladığı alan belirlenir. Bu sıcak plaka sayısı bu çalışmadaki modellemeye duvar kopma hareketini gösteren bulanık çıkarım sisteminin çıkışı ile çarpılmış olarak kullanılmıştır. Bu sayede sıcak soğutma plaka sayısı da modellemeye dahil edilmiştir.




Şekil 6.6 Tespit edilen duvar hareketleri ve sıcak plaka sayıları ile çarpılmış değerleri

### 6.4.3. Model üzerindeki çalışmalar

Bu konuda büyük ölçüde Jimenez ve arkadaşlarının çalışmasından faydalanılmıştır. Dinamik sistemlerin modellenmesinden NFIR, NARX, NOE, NARMAX, NBJ gibi model yapıları kullanılabilir. Yapılan çalışmada, öncelikle seri-paralel model olarak isimlendirilen NARX model yapısı kullanılmıştır. Daha sonra kullanılan model yapısı ise, girişteki son pik demir sıcaklığının yerine model çıkışının giriş olarak kullanılmasıyla bazı kazanımlar sağlayan NOE model yapısıdır. Bu yapılar ise genelde paralel model olarak isimlendirilir. İki modelin yapısı da şekil 6.7’de verilmiştir. Şekilden de anlaşılacağı üzere NARX model yapısında girişe sistemden elde edilen gerçek değerler geri besleme olarak uygulanırken, NOE model yapısında ise oluşturulan modelin çıkışı geri besleme olarak uygulanmaktadır. NARX modellerini tanımlayan genel eşitlik aşağıda verilmiştir.

$$\hat{y}(k) = F(y(k-1), y(k-2), \dots, y(k-p), u(k), u(k-1), \dots, u(k-q)) \quad (6.4)$$

$y$  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 [29].



Şekil 6.7. Seri-paralel (sp) veya paralel (p) tanımlama yöntemleri [75]

Böyle bir modele, çalışılan belirli sistem durumlarını, özellikle pik demir sıcaklıklarının ölçümündeki düzensiz örnekleme oranının hesaba katılması gerekliliği açıktır. Buna ulaşmak için zaman açık olarak modelin içine eklenmiştir. Dökümler arası geçen süre, bir önceki sıcaklık ölçümünden bu yana geçen süre, dökümün açılışından sıcaklık ölçümüne kadar geçen süre modele giriş olarak uygulanmıştır.

Bu zamanların hesaba katılmasının ana nedeni, pik demirin haznede kaldığı sürenin de modelde kullanılabilmesinin sağlanmasıdır. İstisnalar olmakla birlikte genel olarak, yüksek fırın çabuk soğuduğundan döküm başında alınan pik demir sıcaklığı ölçümü daha sonraki ardışık ölçümlerden daha düşüktür. Bunun nedeni ilk pik demirin haznenin duvarlara yakın ve soğuk alt bölgelerinden gelmesidir. Döküm süresi ilerledikçe, pik demir doğrudan erime bölgesindeki erimiş cevherden gelmektedir ve daha sıcaktır.

Model girişine uygulanacak olan diğer fırın değişkenlerinin de modelin istenen sonuçları vermesi amacıyla uyarlanması gerekmektedir. Elimizdeki mevcut ham veri 5 dakikalık

ortalama deęerleri gsteren veridir. 6.4 eřitlięi ile tanımlanan modelin yapısına uygun olarak, her giriş deęiřkeni için yeterli sayıda gemiř veriyi almak gereklidir. Yüksek fırın cevaplarının genelde yavaş olması nedeni ile alınacak gemiř verinin ok fazla olması nedeniyle bu modelin giriş sayısında bir artışa neden olmaktadır. Ayrıca bu girişlerin ıkıř sayıları ile uyuřması gerekmektedir [29].

Burada karřılařılan sorunlardan ilki, her giriş için gemiře yönelik alınması gereken veri sayısıdır. Bu sayının girişteki deęiřimin, pik demir sıcaklıęında grlmesine kadar geen sre ile iliřkili olması gerekmektedir. Bugne kadar yapılan alıřmalarda bu srenin, her giriş deęiřkeni için deneysel olarak tespit edilmeye alıřıldıęı ve tespit edilen srenin tm alıřma boyunca bir sabit olarak kullanıldıęı grlmřtr. Ancak iřletme řartları incelendięinde aıka grlebilmektedir ki, bu sre fırının alıřma řartlarına gre deęiřkendir. Yani her deęiřken için fırının alıřma hızına gre deęiřmektedir. Yüksek fırının her kořulunu modelleyebilen bir yapının oluřturulabilmesi için bu srenin sabit olarak deęil deęiřken olarak alınması veya bařka bir deęiřken ile ifade edilmesi gereklilięi vardır. rneęin normal alıřma řartlarında tepe sistemi ile fırına řarj edilen malzemelerin ıkıřta grlmesi, fırın byklęne gre deęiřmekle beraber, zerinde alıřılan fırın için 5 saat srmektedir. Ancak bu fırının bazı alıřma řartları nedeni ile yavaşlamasından dolayı 6-7 saate ıkabilmektedir. 5 saate gre yapılan bir modelleme bu tr durumlarda hatalı sonular retebilecektir.

Yukarıda anlatılanlar gz nne alınarak, bu alıřmada yapılan ise, sabit sreler deęil, fırın alıřma hızının bu sreleri belirlemede kullanarak deęiřken bir sre elde edilmesidir. rneęin tepe sisteminde řarj edilen malzemeler belirlenen srede deęil fırın byklkleri ile sabit olan bir sayı ile iliřkilendirilmiřtir. Fırın kapasitesi dolayısı ile 40 řarj malzeme alabilmektedir. Yani fırına 41. řarj yapıldıęında birinci řarj pik demir ve curuf olarak fırından kmıř olmaktadır. Bu sayı sabit olduęundan, tepe sistemi ile řarj edilen malzemeler için sabit sreler yerine 40 řarjın tamamlanması için geen sre gz nne alınmıřtır. Dięer giriş deęiřkenlerinin sreleri için de zaman deęil řarj sayısı gz nnde bulundurulmuřtur. Yapılan alıřmada řarj sayısına gre uygulanan gecikmeler tablo 6.2'de verilmiřtir.




Tablo 6.2. Değişkenlere uygulanan gecikmeler

Değişken	Gecikme - $\tau$	Birimi
Hava akış miktarı	8 şarj	$Nm^3 / dak.$
İlave buhar akışı	4 şarj	$kg / saat$
İlave oksijen akışı	8 şarj	$Nm^3 / dak.$
Kömür enjeksiyon miktarı	8 şarj	$gr / m^3$
Sıcak hava sıcaklığı	8 şarj	$^{\circ}C$
Duvar hareketi	12 şarj	-
Saatlik şarj sayısı	8 şarj	-
Tepe sıcaklığı	4 şarj	$^{\circ}C$
Tepe gazı $H_2$ miktarı	4 şarj	%
Tepe gazı $CO$ miktarı	4 şarj	%
Tepe gazı $CO_2$ miktarı	4 şarj	%
Kullanılan kok miktarı	40 şarj	$kg$
Kullanılan demirli malzeme miktarı	40 şarj	$kg$
Kullanılan curuf yapıcı malzeme miktarı	40 şarj	$kg$
Geçirgenlik	4 şarj	-
Kok rutubeti	40 şarj	%
Dökümhane değişimi	-	-
Bir önceki pik demir sıcaklığı	-	$^{\circ}C$
Dökümler arası süre (thc)	-	$dak$
Bir önceki sıcaklık ölçümünden bu yana geçen süre (tta)	-	$dak$
Döküm açılışından buyana geçen süre (tic)	-	$dak$

6.4. eşitliği ile ifade edilen model yapısına uygulanacak olan giriş değişkenleri, zamana göre ortalamaları alınarak kullanılmıştır. Bu ortalamalar, pik demir sıcaklığının 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. Bu hesaplamalar 6.5 ile verilen eşitlik ile yapılmıştır.

$$\bar{u}_i = \frac{\sum_{t=t_a-2\tau}^{t_a} e^{-2\left(\frac{t-t_a}{\tau}\right)^2} u_i(t)}{\sum_{t=t_a-2\tau}^{t_a} e^{-2\left(\frac{t-t_a}{\tau}\right)^2}} \quad (6.5)$$



Şekil 6.8. Hava akışı ham verisi (seri 1) ve 6.5 eşitliğinin uygulanmış hali (seri 2)

Eşitlikte  $t$  ile  $u_i$ 'nin örneklendiği an ifade edilmektedir. Giriş değişkenlerine uygulanan bu eşitliğin, ham veri üzerinde iki etkisi olmuştur. Bunlar giriş sinyalinin düzgünleştirilmesi ve ileri yönde kaydırılmasıdır [29]. Şekil 6.8'de bir örneği verilmiştir. Bu yapının oluşturulabilmesi için her şarj grubunun süresi bulunmuş ve bu

süre içerisinde kaç nokta olduğu tespit edilerek eşitlikte kullanılacak örnek sayısı tespit edilmiştir.

Bundan sonra 6.4 ile verilen eşitliği aşağıdaki gibi yazmak mümkün olacaktır.

$$\hat{T}(k) = F(T(k - tta), tta(k), thc(k), tic(k), u(k), u(k - 1), \dots, u(k - 2\tau)) \quad (6.6)$$

Noktalar üzerinde çalışmaya başlamadan önce üzerinde çalışılan aralık içerisinde tüm noktaların herhangi bir veri kaybının olup olmadığı kontrol edilmiştir. Bulunan eksiklikler, değişkenlerin kısa sürelerde çok değişken olan değerler içermemesinden dolayı önceki ve sonraki değerlerin ortalamaları alınarak eksiklikleri giderilmiştir. Tüm noktalar için bu çalışmalar Excel içinde yazılan makrolar ile yapılmıştır.

#### 6.4.4. Model yapısı ve eğitime

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. 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.

Giriş katmanı girişe uygulanan veri setinin eleman sayısı kadar nörona sahip olacağından 21 nörona sahiptir. Bu girişlerin bazıları modele doğrudan bazıları ise yukarıda anlatılan biçimde bir ön işlemden geçirilerek uygulanmışlardır. Buradaki 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, neredeyse model eğitimi imkansız bir duruma getirebilirdi. Yapılan ön

işlem sayesinde modelin geçmişe yönelik verileri tutma 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 ağın 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.

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

Bu çalışmalar için elde bulunan veri kümesi eğitim, onaylama ve test veri kümeleri olmak üzere üçe bölünmüştür. Yüksek fırının iki aylık çalışma süresinde alınan 969 döküme ait 5970 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.

Sinirsel ağın eğitiminde, kullanılan Matlab programının nftool aracının kapasitesinde olan aşağıdaki kod kullanılmıştır. Bunun araçtan farkı, transfer fonksiyonları da dahil olmak üzere bazı ayarların değiştirilebilmesidir. Bu sayede nftool kullanılarak yapılamayan bazı çalışmalar bu kod ile yapılabilmektedir.


```

rand('seed',9.31316785E8)
[normInput,ps] = mapminmax(p,0,1);      % logsig
%[normInput,ps] = mapminmax(p,-1,1);   % tansig
[normTarget,ts] = mapminmax(t,0,1);    % logsig
%[normTarget,ts] = mapminmax(t,-1,1);  % tansig
numInputs = size(p,1);
numHiddenNeurons = 35;
numOutputs = size(t,1);
net=newff(minmax(normInput),[numHiddenNeurons,numOutputs],
          {'logsig','purelin'},'trainlm') ;
testPercent = .2;
validatePercent = .2;
[trainSamples,validateSamples,testSamples]
    =dividevec(normInput,normTarget,testPercent,validatePercent) ;
net.trainParam.mu_dec = 0.1
net.trainParam.mu_inc = 10
net.trainParam.show = 5
net.trainParam.epochs = 1000
net.trainParam.mu = .001
[net,tr] = train(net,trainSamples.P,trainSamples.T,[],[],validateSamples,testSamples);
[normTrainOutput,Pf,Af,E,trainPerf] =
    sim(net,trainSamples.P,[],[],trainSamples.T);
[normValidateOutput,Pf,Af,E,validatePerf]=
    sim(net,validateSamples.P,[],[],validateSamples.T);
[normTestOutput,Pf,Af,E,testPerf] =
    sim(net,testSamples.P,[],[],testSamples.T);
trainOutput = mapminmax('reverse',normTrainOutput,ts);
validateOutput = mapminmax('reverse',normValidateOutput,ts);
testOutput = mapminmax('reverse',normTestOutput,ts);
figure
postreg({trainOutput,validateOutput,testOutput},{t(:,trainSamples.indices),
    t(:,validateSamples.indices),t(:,testSamples.indices)});

```

Şekil 6.9. Eğitim için kullanılan Matlab komut rutini

Yukarıda verilen yapı kullanılarak ağ, gizli katmanında 10 nörondan 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-logsig ve logsig-purelin olacak biçimde dört kere tekrar edilmiştir. Elde edilen sonuçlar şekil 6.10 ile verilmiştir.



Şekil 6.10. Eğitilen ağ yapılarının sahip oldukları nöron sayılarına göre MSE'leri

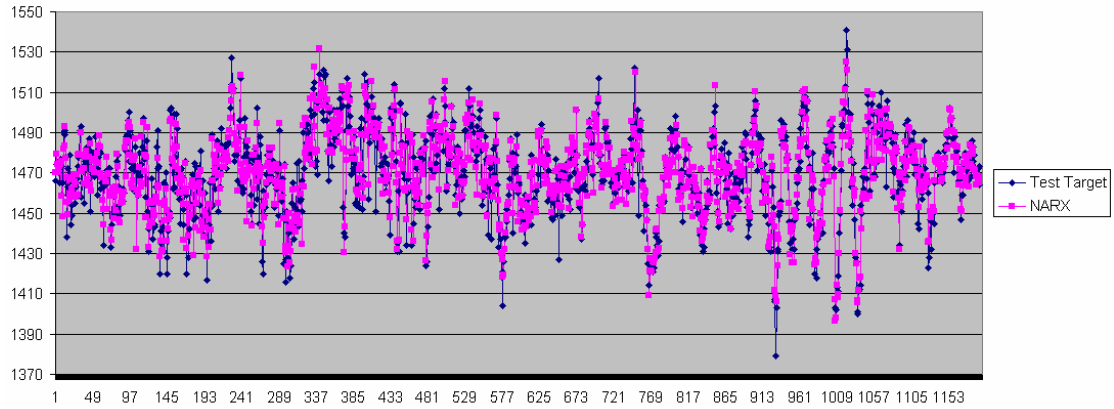
Şekil 6.10a'daki grafikten görülebildiği gibi gizli katmanda sigmoidal transfer fonksiyonunun, sigmoidal fonksiyonu olarak kullanılması, hiperbolik tanjant sigmoidal fonksiyonu kullanılmasına göre çok daha iyi performans sağlamıştır.

Şekil 6.10b'deki grafikte sigmoidal ve doğrusal transfer fonksiyonlarının hataları, onaylama hataları ve ortalamaları verilmiştir. Görülebileceği gibi en iyi sonucu 0.00146 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 0.00216 ile en başarılı yapı olmuştur. Pik demir sıcaklığının modellenmesinde ise onaylama hatalarının en düşük olduğu 30 gizli katman nöronuna sahip logsig-purelin yapısı kullanılmıştır.

#### 6.4.5. Pik demir sıcaklığı test sonuçları


Bu bölümde, sinirsel ağ yapısı oluşturulduktan sonra modele uygulanan test verilerinin sonuçlarına yer verilmiştir.




Şekil 6.11. Test verisi hedef değerleri ve model çıkış değerleri

Şekil 6.11’de verilen grafikten de anlaşılacağı gibi model çıkışları ile hedeflenen değerler büyük oranda örtüşmektedir. Özellikle sıcaklığın değişim trendinin de yakalanabildiği açıkça görülebilmektedir. Ani düşüş ve çıkışların oluşması durumunda aynı iniş ve çıkışın model çıkışında da oluştuğu görülmüştür. Modelin hedef değerleri ve çıkış değerlerinin farkı alınarak oluşan hata değerleri bulunmuştur. Şekil 6.12 ve 6.13 ile verilen grafiklerde görülebileceği gibi hata oranı genelde  $\pm 10$  °C derece arasında yoğunlaşmaktadır. 1350 ile 1550 °C derece aralığında değişen pik demir sıcaklığı için bu değer kabul edilebilir ölçülerdedir. Bununla birlikte hata dağılımı detaylı

incelendiğinde  $\pm 10$  °C derece arasında olan hatanın da  $\pm 5$  °C arasında yoğunlaştığı görülmüştür.



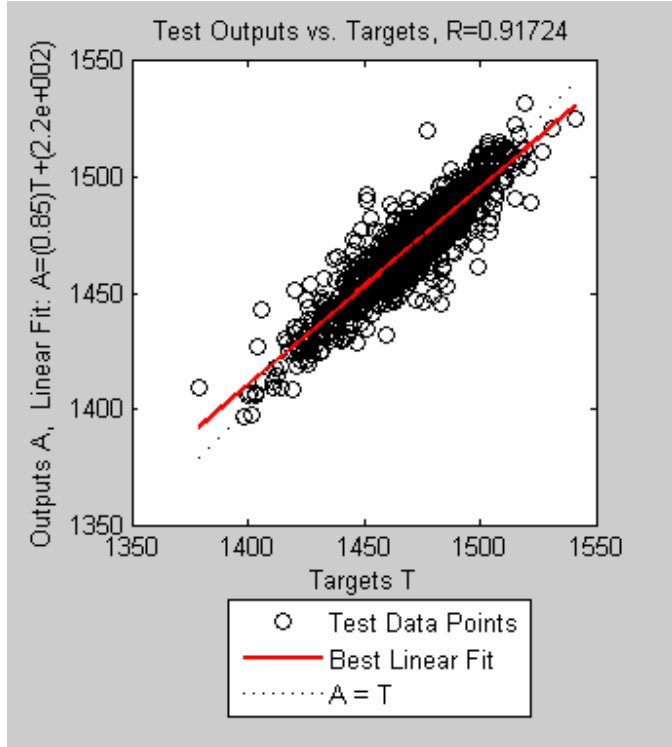
Şekil 6.12. Sıcaklıktaki gerçek hata



Şekil 6.13. Sıcaklıktaki gerçek hatanın dağılım grafiği

Ayrıca hedef değerleri ile modelin çıkış değerleri arasında bir bağlantı katsayısı (R) bulunmuştur. Bu 0 ile 1 arasında değişen sayıdır ve çıkışların hedefler ile ilişkisinin gücünü gösterir. 1 ise çok güçlü ilişkiyi gösterirken 0 iken zayıf ilişkiyi gösterir. Şekil 6.14'de görülebileceği gibi R değeri 0.91724'dür ve bu güçlü bir ilişki gösterir.






Şekil 6.14. Hedef ve çıkışlar arasındaki ilişki

Bu çalışmadan sonra NARX yapısındaki model, girişe uygulanan pik demir sıcaklıkları yerine modelin bir önceki çıkışı verilerek bir NOE modeli oluşturulmuştur. Bu tür bir yapı kullanılabilirliğinde çok büyük kazançlar sağlar. Bu sayede model pik demir sıcaklığına ihtiyaç duymadan (sadece ilk başlangıç için bir adet gereklidir) sürekli olarak kendi çıkışlarını kullanır. Böylelikle kestirim süresi istenen sürede uzatılabilir. Bu modellenen sistemin simülasyonunun yapılabilmesine olanak verir.

Bu amaçla NARX model yapısına uygulanan aynı test verisi ile elde edilen veriler NOE yapılı olan modelin girişine pik demir sıcaklığı olarak uygulanmıştır. Bu modelden elde edilen sonuçlar bir önce elde edilen sonuçlar kadar iyi olmamakla birlikte simülasyon amaçlı olarak kullanılabilir yeterliliktedir. Sıcaklık iniş ve çıkış trendlerinin

yakalanmasında bir sorun yoktur. Ancak hata oranı artmıştır. Genel olarak hata  $\pm 20^{\circ}\text{C}$  derece arasında olduğu görülmüştür.



Şekil 6.15. NARX, NOE modellerinin çıktıları ve hedefler (T)

### 6.5. PİK DEMİR SİLİSYUM İÇERİĞİ VE CURUF BAZİTESİNİN KESTİRİLMESİ

Yapılan çalışmaya ek olarak, tamamen pik demir sıcaklığını kestirilmesinde kullanılan yöntemler ile pik demir içeriğindeki silisyum miktarı ve curuf bazitesinin kestirilmesi denenmiştir. Aynı model yapısı ve aynı veri kümeleri kullanılmıştır. Ancak bu değerlerin bir önceki çalışmada ikinci bir çıkış olarak kullanılamamasının nedeni, pik demirin kimyasal kompozisyonunun pik demir sıcaklığı kadar örneklenmemesidir. Bundan dolayı eğitim, onaylama ve test setlerinin veri sayıları azalmıştır.

Silisyum miktarının kestirilmesinde kullanılan veri kümesine ilave olarak bir önceki ölçümde elde edilen analiz sonucundan silisyum ve karbon içerikleri ile modellenen pik demir sıcaklığı giriş setine dahil edilmiştir. Curuf bazitesinin kestirilmesi için ise kullanılan sinter malzemesi miktarı ve sinterin bazitesi ile modellenen pik demir sıcaklığı girişe dahil edilmiş ve girişte toplanarak tek bir değişken olarak modele uygulanan curuf yapıcı malzemeler ayrı ayrı uygulanmıştır. Silisyum için kullanılacak veri seti 2700 örnek, curuf için kullanılacak veri seti ise 971 örnek

ile sınırlı kalmıştır. Yapılan denemeler sonucunda MSE oranı her iki deęişken içinde 0.01-0.015 seviyelerinde kalmıştır.

Elde edilen sonuçlar pik demir sıcaklığında elde edilen sonuçlar kadar başarılı deęilse de, bu deęişkenlerin kestirilmesi için yapılacak spesifik çalışmalar ile istenen sonuçları üretebilecek modellemelerin yapılabileceęi düşüncesi edinilmiştir.

## BÖLÜM 7. SONUÇLAR VE ÖNERİLER

Bu tez çalışmasında yüksek fırın üretim süreci incelenmiş ve yüksek fırın verileri kullanılarak pik demir sıcaklığının kestirilmesini sağlayacak bir model geliştirilmiş ve yüksek fırınlarda yapay sinir ağlarının, kontrol ve/veya simülasyon amaçlı olarak model geliştirilmesinde kullanılabileceği gösterilmiştir.

Çalışma sonucu elde edilen sonuçların başarı oranı oldukça yüksektir. Yapay sinir ağının eğitilmesi sonucunda oldukça düşük bir değer olan 0.00146 MSE oranı elde edilmiştir. test verileri modele uygulandığında da elde edilen değerlerin başarı oranı açıkça görülebilmektedir. Modele uygulanan 1193 test verisi sonucunda elde edilen çıkış değerlerinin 967 adetinin hatası  $\pm 10$  °C derece aralığında kalmıştır. 183 adetinin ise  $\pm 20$  °C derece aralığındadır. Hedef sıcaklıkların ortalaması 1469,8 °C derece olduğu göz önüne alındığında, sonuçların %81.05'inin en yüksek %0.68, %96,4 ise en yüksek %1,36 hata oranında olduğu görülmüştür. Bu değerler, modelin fırın kontrolü için kullanılabileceğini göstermektedir. Jimenez ve arkadaşlarının çalışması ile karşılaştırıldığında, giriş değerlerindeki gecikmenin sabit olarak alınmasının yerine fırın çalışma hızına göre değişken olarak ayarlanmasının çok daha iyi sonuçlar verdiği görülmüştür.

Model girişine gerçek pik demir sıcaklığının yerine model çıkışının uygulanması ile elde edilen değerlerin, kontrol amaçlı olmasa da simülasyon amaçlı olarak kullanılabilecek nitelikte olduğu görülmüştür. Bu sayede elde olan veriler ile istenen sürede ileriye yönelik tahminler yapılabilen sistemler geliştirilebilir.

Bununla beraber pik demir silisyum içeriği ve curuf bazitesi için aynı model kullanılmış ve değerlerin pik demir sıcaklığındaki kadar başarılı olmasa da, üzerinde çalışılması ile

pik demir sıcaklığındaki oranları yakalamak için umut verice değerler ve trendler elde edilmiştir.

Çalışmada gecikme, her ne kadar şarj hızına bağlanmış ve önceki çalışmalardan daha iyi sonuçlar elde edilmiş olsa da, yüksek fırın büyüklüğü ve kullanılan malzemelerin özellikleri gibi parametreler kullanılarak, katman kalınlığı, ergime bölgesi yüksekliği gibi modeli etkileyebilecek fırın içi parametrelerinin bulunabileceği ve gerçek anlamda bir fırın çalışma hızı tespit edilerek, gecikme geçmiş tecrübelerle dayalı olarak tespit edilmesinin önüne geçilerek daha iyi sonuçların elde edilebileceği düşünülmektedir. Yine alınan pik demir sıcaklığında oluşabilecek hataların giderilebilmesi veya etkilerinin azaltılabilmesi amacıyla son alınan sıcaklık olarak son 2 veya 3 sıcaklığın belirli oranda ağırlıklarla ortalaması kullanılabilir. Bu, çalışmada hatanın daha da azalmasını sağlayabilir.

Bu çalışmanın ileriki adımları olarak pik demir silisyum içeriği ve curuf bazitesi için detaylı çalışmalar yapılabileceği düşünülmektedir. Ayrıca, üretilen pik demir miktarı, pik demir karbon ve kükürt içeriği gibi parametreler için de kestirimci modeller geliştirilebilir. Bunun yanında elde edilen değerlerin çok iyi olması göz önüne alınarak yüksek fırın için pik demir sıcaklığına bağlı olan bir kontrol sistemi geliştirilebilir.

## KAYNAKLAR

- [1] ZILOUCHIAN, A., JAMSHIDI, M., Intelligent Control Systems Using Soft Computing Methodologies, CRC Press, Chapter 4, USA, 2001.
- [2] TEIXEIRA, R., BRAGA, A., MENEZES, B., Control of a robotic manipulator using artificial neural networks with on-line adaptation, Neural Processing Letters, 12, pp.19-31, 2000.
- [3] KUTSURELIS, J., Forecasting financial markets using neural networks: an analysis of methods and accuracy, Master of science in management thesis, Naval Postgraduate School, September 1998, pp.1-13.
- [4] <http://www.mare-net.com/mscardi/work/nn/nn.htm>.
- [5] <http://www.makhfi.com/realworld.htm>.
- [6] BANKS, B., Neural network based modeling and data mining of blast furnace operations, MEng Thesis, MIT, September 1999.
- [7] GE, A. X., A neural network approach to the modeling of blast furnace, MEng Thesis, MIT Department of Electrical Engineering and Computer Science, May 1999.
- [8] BISWAS, A. K., Principles of blast furnace ironmaking, Cootha Publishing House, pp.1-13, Brisbane, Australia, 1981.
- [9] ANGSTENBERGER, J., Blast furnace analysis with neural networks, ICANN, pp.203-208, 1996.
- [10] 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, pp.509-524, 2000.
- [11] IIDA, O., TANIYOSHI, S., UETANI, T., Application of AI techniques to blast furnace operation, Kawasaki Steel Technical Report, No.26, pp.30-37, June 1992.
- [12] SCHLANG, M., FELDKELLER, B., LANG, B., POPPE, T., RUNKLER, T., Neural computation in steel industry, Hamilton Institute, Maynooth, September 2003.

- [13] YOSHIKAWA, F., Mathematical modeling of fluid flow and heat Transfer in blast furnace hearth, MIT M.S. Thesis, 1980.
- [14] TORSSELL, K., Xuegong B., Wijk, O., Simulation of the blast furnace process by a mathematical model, ISIJ International, Vol.32 No.4, pp.470-480, 1992.
- [15] TORSSELL, K., Xuegong B., Wijk, O., Prediction of the blast furnace process by a mathematical model, ISIJ International, Vol.32 No.4, pp.481-488, 1992.
- [16] <http://web.mit.edu/profit/PDFS/RaviT.pdf>.
- [17] PEACEY, J. G., DAVENPORT, W.G., The iron blast furnace theory and practice, Pergamon Press, pp.1-29, Oxford, 1979.
- [18] 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.
- [19] 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.
- [20] Ullmann's Encyclopedia of Industrial Chemistry, 5th complete revised edition, Wiley VCH, Vol.A14, pp.517-540, Weinheim, 1985.
- [21] BHATTACHARJEE, D., DASH, S. K., Das, A. K., Application of artificial intelligence in Tata Steel, Tata Search 1999, 1999.
- [22] SADHUKHAN, A. K., BAG, S. K., TAPAS A. M., RAY, R. S., Prediction of air separation column behavior based on static neural network. Tata Search 1999, 1999.
- [23] NIKUS, M. SAXEN, H., Prediction of a blast furnace burden distribution variable, ISIJ International, Vol.36, No.9, pp.1142-1150, 1996.
- [24] GYLLENRAM, P., WIKSTROM, J., HALLIN, M., Blast furnace control after the year 2000, Iron and Steelmaking, Vol.23, No.11, pp.57-63, November 1996.
- [25] O'HANLON, J., Blast furnace control philosophy at British Steel, Iron and Steel Engineer, December 1991.
- [26] 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.

- [27] BULSARI, A., SAXEN, H., Classification of blast furnace probe temperatures using neural networks, *Steel Research*, Vol.66 No.6, pp.231-236, 1995.
- [28] 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.
- [29] 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.
- [30] <http://en.wikipedia.org/wiki/celik>
- [31] <http://www.steelonthenet.com/production.html>, World Steel Review, February 2007.
- [32] <http://www.posco.co.kr/homepage/images/flash/en/process.swf>.
- [33] [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).
- [34] [http://en.wikipedia.org/wiki/blast\\_furnace](http://en.wikipedia.org/wiki/blast_furnace).
- [35] [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).
- [36] VAHAPLAR, A., İNCEOĞLU, M. M., Veri madenciliği ve elektronik ticaret, Ege Üniversitesi Bilgisayar Mühendisliği Bölümü, VII. Türkiye’de İnternet Konferansı, Kasım 2001.
- [37] LAROSE, D. T., *Discovering knowledge in data; an introduction to data mining*, John Wiley, pp.1-25, New Jersey, 2004.
- [39] ALPAYDIN, E., *Zeki veri madenciliği: ham veriden altın bilgiye ulaşma yöntemleri*, Bilişim Eğitim Semineri, 2000.
- [39] HAND, D., MANNILA, H., SMYTH, P., *Principles of data mining*, MIT Press, pp.1-25, London, 2001.
- [40] BERRY, M. J. A., LINOFF, G. S., *Data mining techniques for marketing, sales, and customer relationship management; 2nd edition*, Wiley Publishing, pp.1-86, Indiana, 2004.
- [41] KEKEÇ, G., Veri madenciliği ve karınca koloni optimizasyonu ile kümeleme, Yüksek Lisans Tezi, SAÜ, Fen Bilimleri Enstitüsü, Sakarya, 2005, Sayfa 11-45.



- [42] SARIFAKIOĞLU, M. B., Bilgi keşfi ve veri madenciliği, Yüksek Lisans Tezi, SAÜ, Fen Bilimleri Enstitüsü, Sakarya, 2004, Sayfa 13-34.
- [43] [http://www.bilgiyonetimi.org/cm/pages/mkl\\_gos.php?nt=538](http://www.bilgiyonetimi.org/cm/pages/mkl_gos.php?nt=538).
- [44] <http://www.genbilim.com/content/view/1329/37/>.
- [45] ALATAŞ, B., AKIN E., Veri madenciliğinde yeni yaklaşımlar, Yöneylem Araştırması/Endüstri Mühendisliği-XXIV Ulusal Kongresi, Gaziantep, 2004.
- [46] <http://www.genbilim.com/odev/odevgoster.php?il=&id=15904>.
- [47] <http://www.genbilim.com/odev/odevgoster.php?il=&id=13933>.
- [48] MIAN, T.M., Fuzzy logic based automotive airbag control system, Master of Applied Science Thesis, University of Windsor, Ontario, Canada, 1999, pp.1-30.
- [49] Fuzzy logic toolbox for use with Matlab user's guide, Mathworks Inc, 1999.
- [50] [http://tr.wikipedia.org/wiki/Bulan%C4%B1k\\_Mant%C4%B1k](http://tr.wikipedia.org/wiki/Bulan%C4%B1k_Mant%C4%B1k).
- [51] [http://www.elk.itu.edu.tr/~yesil/bulanik\\_kume\\_tanimlar.htm](http://www.elk.itu.edu.tr/~yesil/bulanik_kume_tanimlar.htm).
- [52] TEMURTAŞ, F. Bulanık sistemler ve uygulamaları, Ders Notları, SAÜ, Fen Bilimleri Enstitüsü, Sakarya, 2004.
- [53] ÇALIŞKAN, E., Gaz konsantrasyonlarının saptanmasında bulanık mantık ve yapay sinir ağı tabanlı algoritmaların kullanılması, Yüksek Lisans Tezi, SAÜ, Fen Bilimleri Enstitüsü, Sakarya, 2004, Sayfa 34-65.
- [54] <http://www.atp.ruhr-uni-bochum.de/rt1/syscontrol/node117.html>.
- [55] MELIN, P., CASTILLO, O., Modeling, simulation and control of non-linear dynamical systems: an intelligent approach using soft computing and fractal theory, Taylor & Francis, pp.9-28, New York, 2002.
- [56] <http://ay.kut1980.sitemynet.com/fuzzy1.pdf>.
- [57] REYES, C. A. P., Coevolutionary fuzzy modeling, Pour L'obtention Grade de Docteur Es Sciences, Lausanne, EPFL, 2002, pp.1-68.
- [58] [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)
- [59] MENON, V., Fuzzy logic controller for an artificial hearth, MEng Thesis, Ottawa-Carleton Institute, Ottawa, pp.15-21, Ontario, 1998.

- [60] [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).
- [61] HOLLAND, A., Fuzzy systems lecture notes, Department of Computer Science, University College Cork, Ireland.
- [62] HAGAN, M. T., DEMUTH, H. B., BEALE, M., Neural network design, PWS Publishing, ch.1-12, USA, 1996.
- [63] [http://tr.wikipedia.org/wiki/Yapay\\_sinir\\_a%C4%9Flar%C4%B1](http://tr.wikipedia.org/wiki/Yapay_sinir_a%C4%9Flar%C4%B1).
- [64] PRINCIPE, J. C., EULIANO, N. R., LEFEBVRE W. C., Neural and adaptive systems- Fundamentals through simulations, pp.101-222, John Wiley, 2000.
- [65] TEBELSKIS, T., Speech recognition using neural networks, Doctoral Thesis, Carnegie Mellon University, Pennsylvania, 1995, pp.27-48.
- [66] ANDERSON, D., MCNEILL, G., Artificial neural networks technology, Kaman Sciences Corporation, A DACS State-of-the-Art Report for Rome Laboratory, ELIN: A011, pp.1-40, New York, 1992.
- [67] <http://www.usm.maine.edu/psy/broida/101/neuron.JPG>.
- [68] CAVUTO, D., J., An exploration and development of current artificial neural network theory and applications with emphasis on artificial life, MEng Thesis, The Cooper Union Albert Nerken School of Engineering, 1997, pp.1-24.
- [69] <http://kvhs.nbed.nb.ca/gallant/biology/synapse.html>.
- [70] YUMUŞAK, N., Güç sistemi devre elemanlarının elektriksel özelliklerinin elde edilmesinde yapay sinir ağı tabanlı algoritmaların kullanılması, Doktora Tezi, SAÜ, Fen Bilimleri Enstitüsü, 1998, Sayfa 6-33.
- [71] KAYA, M., TUNCER, İ., H., Çırpan kanat kesitlerinde itkinin yapay zeka ile en iyileştirilmesi, HITEK, 2004.
- [72] DEMUTH, H., BEALE, M., Neural network toolbox for use with Matlab-user's guide, Mathworks Inc, 2002.
- [73] EĞRİSÖĞÜT, A., Çimento hammadde karışım prosesinin yapay sinir ağları ile matematiksel modellenmesi, Yüksek Lisans Tezi, SAÜ, Fen Bilimleri Enstitüsü, 2002, Sayfa 27-53.
- [74] HAYKIN, S., Neural Networks A Comprehensive Foundation, Prentice Hall Publishing, New Jersey, Vol.1, pp.1-14, USA, 1999

- [75] LIPTAK, B. G., Instrument Engineers' Handbook Vol.2: Process Control and Optimization - 4th Edition, CRC Press, pp.253-263, USA, 2005.
- [76] MURRAY, S., Neural networks for statistical modeling, Van Nostrand Reinhold Press, pp.111-133, New York, 1993.
- [77] KNOBLOCK, C., Neural networks in real-world applications, IEEE Expert, pp.4-10, August 1996.
- [78] FALZETTI, M., CHIATOTTI, U., First Experiences in the Use of Artificial Neural Network Pattern Recognition Techniques for the Monitoring of Wall Temperatures, ECSC Workshop – Measuring Techniques in Blast Furnace Ironmaking and their Benefits for Industrial Practise, Dusseldorf, 1998.

## ÖZGEÇMİŞ

Erdoğan Bozkurt, 08.03.1976'da Karadeniz Ereğli'de doğdu. İlk, orta ve lise eğitimini Ereğli'de tamamladı. 1994 yılında Karadeniz Ereğli Anadolu Lisesi'nden mezun oldu. 1994 yılında başladığı İstanbul Üniversitesi Mühendislik Fakültesi Elektronik Mühendisliği Bölümü'nü 1999 yılında bitirdi. 1999 yılında Ereğli Demir ve Çelik Fabrikaları Elektronik Otomasyon Müdürlüğü'nde mühendis olarak çalışmaya başladı. 2001 yılında askerlik görevine başladı ve askerlik dönüşü 2003 yılında Ereğli Demir ve Çelik Fabrikaları'ndaki görevine tekrar başladı. 2004 yılında Sakarya Üniversitesi Elektronik Mühendisliği Bölümü'ne girdi. Evli ve bir çocuk babası olan Erdoğan Bozkurt, halen aynı görevinde çalışma hayatına devam etmektedir.