

T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**YÜKSEK FIRIN VE TERMİK SANTRALLERDE
PROSES PARAMETRELERİNİN KESTİRİMİNE
YÖNELİK KARŞILAŞTIRMALI UYGULAMALAR**

DOKTORA TEZİ

Yasin TUNÇKAYA

**Enstitü Anabilim Dalı : ELEKTRİK-ELEKTRONİK
MÜHENDİSLİĞİ**
Enstitü Bilim Dalı : ELEKTRONİK
Tez Danışmanı : Prof. Dr. Etem KÖKLÜKAYA

Şubat 2015

T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**YÜKSEK FIRIN VE TERMİK SANTRALLERDE
PROSES PARAMETRELERİNİN KESTİRİMİNE
YÖNELİK KARŞILAŞTIRMALI UYGULAMALAR**

DOKTORA TEZİ

Yasin TUNÇKAYA

**Enstitü Anabilim Dalı : ELEKTRİK-ELEKTRONİK
MÜHENDİSLİĞİ**

Bu tez 09 / 02 / 2015 tarihinde aşağıdaki jüri tarafından oybirliği / oyçokluğu ile kabul edilmiştir.


**Prof. Dr.
Etem KÖKLÜKAYA
Jüri Başkanı**

**Prof. Dr.
Yusuf OYSAL
Üye**


**Doç. Dr.
Fırat HARDALAÇ
Üye**

**Doç. Dr.
Ali Fuat BOZ
Üye**

**Yrd. Doç. Dr.
İrfan YAZICI
Üye**

BEYAN

Tez içindeki tüm verilerin akademik kurallar çerçevesinde tarafımdan elde edildiğini, görsel ve yazılı tüm bilgi ve sonuçların akademik ve etik kurallara uygun şekilde sunulduğunu, kullanılan verilerde herhangi bir tahrifat yapılmadığını, başkalarının eserlerinden yararlanılması durumunda bilimsel normlara uygun olarak atıfta bulunulduğunu, tezde yer alan verilerin bu üniversite veya başka bir üniversitede herhangi bir tez çalışmasında kullanılmadığını beyan ederim.

Yasin TUNÇKAYA

09.02.2015

ÖNSÖZ

Bu tez çalışması boyunca göstermiş olduğu yoğun ilgi, destek ve yardımları nedeniyle tez danışmanım Prof. Dr. Etem Köklükaya'ya, tez önerisi sınavından itibaren yol gösterici yorum ve yönlendirmeleriyle teze katkıda bulunan Doç. Dr. Ali Fuat Boz ve Yrd. Doç. Dr. İrfan Yazıcı'ya teşekkür ederim. Tez savunma sınavı sırasında ve sonrasındaki dönemde pozitif katkıları ile tezi nihayetlendirmeme vesile olan Prof. Dr. Yusuf Oysal ve Doç. Dr. Fırat Hardalaç hocalarımıza da teşekkürü bir borç bilirim.

Doktora çalışmalarına başladığım 2009 yılından bu yana bilgi, yardım ve desteğini hiç esirgemeyen arkadaşım Sn. Erdoğan Bozkurt'a, özellikle istatistiksel yöntemlerle ilgili katkısı, yardımı ve yoğun akademik desteği nedeniyle Yrd. Doç. Dr. Beyza Ustaoglu'na, doktora öğrenimim sırasındaki her konudaki yardım ve desteği için Sn. Soydan Serttaş'a, yoğun motivasyon ve destekleri nedeniyle de arkadaşlarım Dr. Sertan Kurnalı, Dr. Ali Kemal Garip ve Sn. İsmail Ustaoglu'na teşekkür ederim. İş arkadaşlarım Sn. Cahit Ayan, Sn. Yasin Sartaş ve Sn. İsa Koçarslan'a da tüm katkı ve yardımlarından dolayı teşekkürlerimi sunarım. Tez çalışmasında kullandığım verilerin temin edilmesindeki yardımları için, ilgili tüm kurum yönetici ve personeline de teşekkür ederim.

Doktora çalışmalarına başladığım günden itibaren gösterdiği sabır ve yüksek motivasyon desteği nedeniyle değerli eşim Beril Ödevci Tunçkaya'ya, evimizin neşesi kızlarım Yağmur Ceylin ve Zeynep Derin'e, küçüklükten itibaren her türlü maddi manevi destekleri ile bugünlere erişmemize vesile olan annem Sema Tunçkaya, babam Satılmış Tunçkaya ve kız kardeşim Tuğba Tunçkaya'ya teşekkürü bir borç bilirim. Tez çalışmamı, bu günleri görmelerini çok istediğim, ancak Rahmet-i Rahman'a kavuşmuş olan tüm sevdiklerime ihtaf ederim.

İÇİNDEKİLER

ÖNSÖZ	i
İÇİNDEKİLER	iii
SİMGELER VE KISALTMALAR LİSTESİ	v
ŞEKİLLER LİSTESİ	ix
TABLolar LİSTESİ	xvi
ÖZET	xxii
SUMMARY	xiii

BÖLÜM 1.

ÇALIŞMANIN KAPSAMI VE LİTERATÜRDEKİ YERİ	1
1.1. Çalışmanın Kapsamı	1
1.2. Çalışmanın Literatürdeki Yeri	7

BÖLÜM 2.

ÇALIŞMADA İNCELENEN TESİSLER	17
2.1. Demir Çelik Fabrikaları ve Yüksek Fırınlr	17
2.1.1. Yüksek fırın prosesi	19
2.1.2. Yüksek fırınlarda kullanılan hammaddeler	24
2.1.3. Yüksek fırınlarda yardımcı sistemler	26
2.1.4. Yüksek fırınlarda reaksiyonlar ve sıcak maden üretimi	30
2.1.5. Sıcak maden kalite ölçütleri ve alev sıcaklığı	33
2.2. Enerji Kaynakları ve Enerji Üretimine Bakış	36
2.2.1. Kömür yakıtlı termik enerji santralleri	42
2.2.2. Termik santrallerde verimlilik	47
2.2.3. Termik santrallerde baca atık gazları ve çevresel etkiler	49

BÖLÜM 3.

VERİ MADENCİLİĞİ VE PERFORMANS KRİTERLERİ.....	52
3.1. Sistem Tanımlama ve Modelleme.....	52
3.2. Veri Madenciliği	55
3.3. Performans Kriterleri	59
3.3.1. Belirlilik katsayısı	59
3.3.2. Ortalama karakök hatası.....	60

BÖLÜM 4.

UYGULAMADA KULLANILAN KESTİRİM MODELLERİ.....	61
4.1. Yapay Sinir Ağları	61
4.1.1. Yapay sinir ağlarının tarihsel gelişimi	62
4.1.2. Biyolojik sinir hücreleri ve yapay sinir ağları.....	65
4.1.3. Yapay sinir ağlarının sınıflandırılması.....	70
4.1.4. Çok katmanlı ağlar	72
4.1.5. Aktivasyon fonksiyonları	74
4.1.6. Öğrenme stratejileri.....	75
4.2. Çoklu Doğrusal Regresyon Modeli	77
4.3. Otoregresif Entegre Kayan Ortalama Modeli	82
4.4. Destek Vektör Makinaları ve Regresyon Modeli	86
4.4.1. Destek vektör regresyonu.....	93

BÖLÜM 5.

YÖNTEM, UYGULAMA VE BULGULAR.....	96
5.1. Alev Sıcaklığı Kestirimi.....	97
5.2. Termik Santral Çıkış Gücü Jenaratör Kestirimi.....	103
5.3. Termik Santral Baca Çıkışında Emisyon Kestirimi.....	109

BÖLÜM 6.

SONUÇLARIN DEĞERLENDİRİLMESİ VE ÖNERİLER.....	115
---	-----

KAYNAKLAR.....	121
----------------	-----

ÖZGEÇMİŞ..... 128

SİMGELER VE KISALTMALAR LİSTESİ

ACO	: Arı kolonisi optimizasyonu
Al ₂ O ₃	: Alüminyumoksit
ANN	: Yapay sinir ağı
AR	: Otoregresif
ARIMA	: Otoregresif entegre kayan ortalama
ARMA	: Otoregresif kayan ortalama
ART	: Adaptif rezonans teorisi
ARX	: Otoregresif ekzojen modeli
b	: Bias değeri
BP	: Geri yayılım algoritması
C	: Karbon
CaO	: Kalsiyumoksit
CaCO ₃	: Kalsiyum karbonat
CaS	: Kalsiyum sülfür
CH ₄	: Metan
CO	: Karbonmonoksit
CO ₂	: Karbondioksit
CV	: Yakıt kalorifik değeri
DCS	: Dağıtılmış kontrol sistemi
e _i	: Hata terimi dizisi
Fe ₂ O ₃	: Hematit
Fe ₃ O ₄	: Magnetit
FF	: İleri beslemeli

FL	: Bulanık mantık
GA	: Genetik algoritma
GRNN	: Genelleştirilmiş regresyon yapay sinir ağı
HNO ₃	: Nitrik asit
HP	: Yüksek basınç bölgesi
h _f	: Besleme suyu entalpisi
h _g	: Buhar entalpisi
H ₂	: Hidrojen
H ₂ SO ₄	: Sülfirik asit
IP	: Orta basınç bölgesi
K	: Çekirdek fonksiyonu
kg/cm ²	: Kilogram / santimetrekare
KKT	: Karush-Kuhn-Tucker yöntemi
kW	: Kilowatt
kWh	: Kilowatt saat
LMS	: En küçük ortalama kareler
LP	: Düşük basınç bölgesi
LVQ	: Lineer vektör kuvantumlama
MA	: Kayan ortalama
MgCO ₃	: Magnezyum karbonat
MLR	: Çoklu doğrusal regresyon
MWe	: Megawatt elektrik enerjisi
NARX	: Doğrusal olmayan otoregresif ekzojen modeli
NGSA-II	: Baskın olmayan sıralayan genetik algoritma II modeli
NO _x	: Azotoksit
N ₂	: Azot
o _j	: Çıkış nöron dizisi
O ₂	: Oksijen
q	: Yakıt miktarı
pH	: Hidrojen gücü
PNN	: Olasılıksal sinir ağı

PSO	: Parçacık sürü optimizasyonu
Q	: Buhar miktarı
RBF	: Radyal temelli fonksiyonlar
RH	: Yeniden ısıtma bölgesi
RMSE	: Karakök ortalama hatası
R^2	: Belirlilik katsayısı
r^*	: Optimal hiperdüzleme uzaklık terimi
Si	: Silisyum
SiO ₂	: Silisyumdioksit
SOM	: Kendi kendine öğrenme nitelik haritaları
SO _x	: Sülfüroksit
SO ₂	: Sülfürdioksit
SO ₄	: Sülfat
SVM	: Destek vektör makinaları
SVR	: Destek vektör regresyonu
Tep	: Ton eşdeğer petrol
TSM	: Ton sıcak maden
VC	: Vapnik Chernonvekis
VOC	: Uçucu organik bileşenler
w_{nj}	: Ağırlık dizisi
W_t	: Birinci farklar serisi
XOR	: Bitsel özel veya
X_i	: Bağımsız değişken
x_i	: Giriş nöronları dizisi
x_i^{scaled}	: Normalize edilmiş değerler dizisi
x_{max}	: En yüksek değerli dizi elemanı
x_{min}	: En düşük değerli dizi elemanı
YF	: Yüksek fırınlar
Y_i	: Bağımlı değişken dizisi
\hat{Y}_1	: Tahmin edilen bağımlı değişken dizisi
Y_i^{obs}	: Öngörülen model değerleri

Y_i^{sim}	: Kestirilen model deęerleri
Z_t	: Orijinal serinin farkı alınmıř zaman serisi
γ_4	: Sabit regresyon terimi
γ_n	: Regresyon katsayı dizisi
(: Santigrat derece
%	: Yüzde
η	: Kazan verimlilięi
T	: Aktivasyon fonksiyonu
T_n	: Otoregresif parametre terimleri dizisi
P^6	: Varyans
E_b	: Hareketli ortalama operat6ru parametre terimleri deęerleri
,	: Ayırma marjı
C	: Penaltı parametresi
B	: Duyarsız kayıp fonksiyonu
	: Radyal temelli fonksiyon parametresi

ŞEKİLLER LİSTESİ

Şekil 2.1. 2013 yılı Türkiye çelik haritası	18
Şekil 2.2. İsdemir III. yüksek fırınının genel görünümü.....	19
Şekil 2.3. Yüksek fırınların profilden görünümü	21
Şekil 2.4. Yüksek fırınlar, hammadde sistemi ve çelik üretim süreci	22
Şekil 2.5. Yüksek fırın yardımcı tesislerinin görünümü	30
Şekil 2.6. Yüksek fırınlardaki kimyasal reaksiyon bölgeleri	33
Şekil 2.7. Bir termik santralin fiziksel görünümü	41
Şekil 2.8. Bir termik santral prosesinin görünümü	45
Şekil 2.9. Kazan prosesinin şematik gösterimi	46
Şekil 3.1. Dinamik sistem modelinin gösterimi	53
Şekil 3.2. Veri madenciliği metodolojisi.....	57
Şekil 4.1. İki farklı sinir ağının fiziksel yapısı ve etkileşimi	66
Şekil 4.2. Yapay sinir ağı blok diyagramı.....	69
Şekil 4.3. Çok katmanlı bir sinir ağı modeli	73
Şekil 4.4. İleri ve geri beslemeli ağ modelleri.....	74
Şekil 4.5. Literatürde sıklıkla kullanılan transfer fonksiyonlar.....	75
Şekil 4.6. Box-Jenkins metodolojisinin gösterimi	83
Şekil 4.7. Doğrusal olarak ayrılabilen durumda optimal hiperdüzlemin gösterimi	89
Şekil 4.8. Verinin doğrusal olarak ayrılabilmediği bir uzaya taşınması	92
Şekil 5.1. Seçili fırın parametrelerinin değişiminin 24 saat süresince gösterimi ...	99
Şekil 5.2. Kestirilen alev sıcaklıkları ve gerçek değerlerin karşılaştırılması	100
Şekil 5.3. Kestirilen alev sıcaklığı değerlerinin hata terimi gösterimi	101
Şekil 5.4. Bazı seçili giriş parametrelerinin 30 dakikalık trendlerinin gösterimi.	106
Şekil 5.5. Kestirilen alev sıcaklığı değerlerinin gerçek değerlerle karşılaştırması .	107
Şekil 5.6. Kestirilen çıkış gücü değerlerinin hata terimi gösterimi.....	108
Şekil 5.7. Seçili giriş parametrelerinin 10 günlük değişimi	111
Şekil 5.8. Gerçek ve kestirilen NO _x değerlerinin gösterimi.....	112

Şekil 5.9. Gerçek ve kestirilen NO_x değerleri arasındaki hata değerleri..... 113

TABLULAR LİSTESİ

Tablo 2.1. Ülkemizin birincil enerji arzı	39
Tablo 2.2. Linyit kömürle çalışan termik santrallerin emisyon oranları (kg/saat).	50
Tablo 5.1. Alev sıcaklığı kestiriminde kullanılan giriş parametreleri.....	97
Tablo 5.2. İlk ANN modelindeki gizli nöron sayılarının performansa etkisi	102
Tablo 5.3. Model çıktılarının değerlendirilmesi	103
Tablo 5.4. Termik santral gücünün kestiriminde kullanılan giriş parametreleri..	104
Tablo 5.5. Model çıktılarının değerlendirilmesi	109
Tablo 5.6. Emisyon kestiriminde seçili model parametreleri	110
Tablo 5.7. Model çıktılarının değerlendirilmesi	114

ÖZET

Anahtar kelimeler: Kestirim, Proses Parametresi, Regresyon, Yapay Sinir Ağı

Demir-çelik fabrikalarının kalbi niteliğindeki yüksek fırınlar, çeliğin hammaddesi olan sıcak madenin üretildiği tesislerdir. Çok sayıda değişken ve bozucu etken nedeniyle karmaşık bir prosese sahip olan fırınların matematiksel olarak modellenmesi oldukça güçtür. Günlük operasyon sırasında hammadde, yakıt maliyetleri ve işletme giderlerinin minimize edilmesi hem fırın verimliliğini ve stabilitesini artırır hem de tesisin ömrünü uzatır. O nedenle kritik bir parametre olan alev sıcaklığı değerinin tahminlenmesi ve kontrolü sağlanabilirse, oksijen zenginleştirilmesi, rutubet miktarı, soğuk hava sıcaklığı, pulverize kömür enjeksiyonu ve kok-demir oranı gibi yakıt değerleri, işletme operatörleri tarafından düzenlenebilir.

Günümüzde elektrik enerjisi, termal, nükleer, hidro, güneş, biyoyakıt, rüzgar gibi değişik tipteki üretim teknolojileri vasıtasıyla gerçekleştirilmektedir. Özellikle zengin kömür yataklarına sahip ülkeler için termik santraller kullanılarak enerji üretimi vazgeçilmez bir seçenektir. Termik santrallerde üretim verimliliği ve maliyet optimizasyonunun sağlanabilmesi için, hammadde girdi fiyatları, termodinamik proses faktörleri, NO_x, SO_x, CO₂ emisyon regülasyonları gibi teknik, ekonomik ve çevresel etkiler gözönünde bulundurulmalıdır. Bununla birlikte, özellikle son yıllarda öne çıkan emisyon izleme ve önleme kuralları çerçevesinde atık gazların takibi ve kontrolü büyük önem taşımaktadır.

Bu çalışmada üç farklı tesise ait kritik proses parametresi, bu parametreleri etkilediği düşünülen seçili giriş değişkenleri kullanılarak modellenmiştir. Yüksek fırın alev sıcaklığı, termik santral jeneratör çıkış gücü ve termik santral baca atık NO_x emisyonu değerleri, tesisleri otomasyon sisteminde tutulan geçmiş verileri kullanılarak, yapay sinir ağları, çoklu doğrusal regresyon ve otoregresif entegre kayan ortalama yöntemleri ile modellenmiş ve kestirilmiştir. Ayrıca alev sıcaklığı tahminlenmesinde destek vektör regresyonu modeli de ek olarak kullanılmıştır. Bu deneysel çalışmaların sonuçları incelendiğinde özellikle yapay sinir ağı yönteminin kullanıldığı modellerin oldukça yüksek başarımlar gösterdiği, diğer modellerin de başarılı olduğu gösterilmiştir. Sunulan bu modellerin tesis otomasyon sistemine entegre edilmesi ve proses optimizasyonu sağlayacak bir akıllı sistem ya da simülatör olarak kullanılması önerilmektedir.

COMPARATIVE APPLICATIONS TO PREDICT PROCESS PARAMETERS IN BLAST FURNACE AND THERMAL POWER PLANTS

SUMMARY

Keywords: Artificial Neural Networks, Prediction, Process Parameter, Regression

Blast furnaces, which are the hearth of iron and steel factories, are used to produce hot metal as a raw material of steel. Furnaces have a complicated process and it is very hard mathematically to model such plants due to multi variable process inputs and disturbances. During daily operations, minimization of raw materials, fuel costs and operating expenses increase furnace efficiency and stability and also extend the lifetime of the plants. Hence, if a critical process parameter, flame temperature, can be predicted and controlled properly, then operators can maintain oxygen enrichment, moisture content, cold blast temperature, pulverized coal injection and coke to ore ratio accordingly.

Recently, electricity production is carried out with thermal, nuclear, hydro, solar, biomass and wind technologies. In particular, energy production from thermal power plants is an indispensable option for especially countries with rich coal deposits. To ensure the productivity and cost optimization in thermal power plants, technical, economic and environmental impacts such as raw material prices, thermodynamic process factors, NO_x, SO_x and CO₂ emissions regulations should be taken into account. However, it has paramount importance of monitoring and tracking of effluent gas in the framework of rules in recent years.

In this study, three critical process parameters that belong to different plants, are modeled using the input parameters that are considered most effective. Flame temperature of a blast furnace, generator output rate of a thermal power plant and effluent gas NO_x rate of another thermal power plant, have been modeled and predicted using artificial neural networks, multiple linear regression and autoregressive integrated moving average models considering previous data that is received from process control systems. Further to these methods, support vector regression model is also employed to flame temperature prediction study. When the results of these experimental studies are investigated, especially the neural networks model has shown very high level of performance and accuracy, and remaining models are also found successful. Finally, the presented models should be integrated to plant automation systems which can be used as expert system or simulator in order to optimize the processes.

BÖLÜM 1. GİRİŞ

1.1. Çalışmanın Kapsamı

Günümüz dünyasının vazgeçilmez sanayi tesislerinden olan demir-çelik fabrikalarında üretilen çelik miktarı ile enerji santrallerinde üretilen elektrik enerjisinin toplamının ülke nüfusuna oranı, iktisat bilimi açısından, o ülkenin kalkınmışlık göstergelerinden birisi olarak kabul edilmektedir. Endüstriyel tesisler mümkün olan en az maliyetle, en yüksek miktar ve verimlilikte üretim yapabilmek, dolayısı ile kendi ayakları üzerinde duran, düzenli olarak kar eden güçlü müesseseler haline gelebilmek için küresel bir rekabet halindedir.

Ancak, hem ulusal ve uluslararası standartlar, hem de insani ve vicdani değerler anlamında empoze edilen, çevresel etkileri en düşük seviyeye indirme, iş güvenliği ve işyeri çalışma şartlarının sürekli iyileştirilmesi, toplam kalite yönetimi gibi hedefler sanayi tesisleri için ciddi maliyet kalemi olarak ortaya çıkan unsurlardır. Dolayısı ile bu tesislerde kullanılan sıvı, katı ya da gaz halindeki tüm girdi yakıtlar ile su, buhar ve diğer kimyasal maddelere ait sıcaklık, basınç, akış, seviye gibi bilgilerinin modern sensörler ve üst düzey otomasyon sistemleri kullanılarak kontrol edilmesi, üretim verimliliği ve optimizasyonu üzerinde çok önemli bir etkiye sahiptir.

Entegre demir-çelik fabrikalarında çeliğin hammaddesi olan sıcak maden (pik demir) üretimi için tasarlanan Yüksek Fırınlara (YF), çelik sacların birbirine kaynatılması ile biraraya getirilmiş, içi çok yüksek sıcaklıklardaki reaksiyonlara dayanıklı refrakter tuğlalarla örülerek yalıtılmış ve boru hatları ile birbirine bağlanmış büyük, silindirik ve görece olarak yüksek yapılı sanayi tesisleridir. Fırın prosesi temel olarak, basınçlı havanın sobalarda ısıtılarak tüyer bölgesinden fırın içerisine üflenmesi ile, belirli aralıklarda tepe bölgesinden şarj edilen kok ve demirli hammaddenin askıda

bırakılması sırasında oluşan tepkimeler vasıtasıyla sıcak maden üretiminin sağlanması prensibine dayanmaktadır.

İşletme giderleri, hammadde ve yakıt tüketimlerinin düşürülebilmesi, fırının kararlı, verimli ve dengeli bir şekilde çalıştırılabilmesi için birtakım proses parametrelerin kontrol altında tutulması gerekmektedir. Ancak, doğrusal yapıda olmayan ve çok sayıda parametrenin anlık olarak değişiminden olumsuz olarak etkilenen bu prosesinin matematiksel olarak modellenmesi oldukça güçtür, hatta neredeyse imkansızdır.

Bu çalışmanın ilk bölümünde, fırın içi ısı dağılımı ve çalışma performansı hakkında bilgi vermesi açısından kritik bir öneme sahip olan alev sıcaklığı değerinin kestirimi ve bu yolla kontrolü konusunda farklı modelleme denemelerinin yapılması hedeflenmektedir. Eğer alev sıcaklığını etkileyen faktörler düzgün olarak seçilebilirse, geçmişe dönük değerlerin temini ve kullanımı ile gerçekleştirilecek bir modelleme çalışması, bu sıcaklık değişimlerinin kestirimini mümkün kılacaktır. Bu nedenle yeni bir veri madenciliği, veri tasnif ve sınıflandırma metodolojisi kullanarak yüksek fırınların dinamik olarak modellenmesi amacıyla çeşitli kurallar dizini oluşturulacaktır. Model sonuçları fırın işletme grubunun ısı değişimlerini zamanında değerlendirebilmesi ile fırın gidişatı ve control yönünün önceden tespit edebilmesi için bir rehber olacaktır.

Yüksek fırınların temel çıktısı olan pik demirin üretim miktarının arttırılabilmesi ve çelik üretim sürecinde çok önemli bir kriter olan sıcak maden kalite koşullarının sağlanabilmesi için üst düzey kontrol ve tahminleme tekniklerine ihtiyaç duyulmaktadır. Üretilen pik demirin kalitesinin arttırılabilmesindeki temel adım, üretilen sıcak madenin içerisindeki silisyum içeriğindeki değişimin ayarlanabilmesi ile sağlanmaktadır. Bu denge, temel olarak fırın içerisindeki ısı seviyelerinin kontrolüne ve regülasyonuna bağlıdır. Fırın içerisindeki sıcaklık yüksek ise sıcak maden içerisindeki silisyum oranı artarken, sıcaklık görece olarak düşük ise pik demir içerisindeki silisyum oranı da bu varyasyonla doğru orantılı olarak azalmaktadır. Bununla birlikte pik demir içerisindeki karbon miktarı ve yüksek fırın cürufunun bazitesi de fırın çalışması hakkında bilgi veren önemli değişkenlerdir. Fırın ısı dengesinin fırın

çıktısına direk olarak etkisi olduğu düşünülürken, alev sıcaklığı parametresinin önemi ve kontrolünün fırın prosesine katkısı net olarak ortaya çıkmaktadır.

Fırınlarda meydana gelen düzensizlikler, alev sıcaklığının yönünü etkileyecek şekilde sıcak hava sıcaklığının azaltılıp rutubet miktarının artırılması, oksijen zenginleştirme oranının düşürülmesi, cevher/kok oranının azaltılarak geçirgenlik değerinin artırılması ya da duvar oluşumuna karşı fırına giren sıcak hava miktarının düşürülmesiyle veya bu sayılan operasyonların tam tersi yönündeki müdahalelerle kontrol altına alınabilir. Ancak bu düzensizlikler veya olası problemler, matematiksel modelleme ve simülasyon çalışmaları ile önceden öngörülebilirse, prosesin daha kontrollü çalışabilmesi için alınacak düzeltici aksiyonlar için geç kalınmamış olur. Örneğin, ilave kok enjeksiyonunun fırın sıcaklığına etkisi 6-8 saat gibi uzun bir süre sonrasında ancak görülebilmektedir.

Fiziksel prosesleri, kritik öneme sahip parametreleri gözönünde bulundurarak tanımlayan matematiksel modeller, endüstriyel tesislerin günlük operasyonunun anlaşılmasına büyük katkı sağlar, ancak karmaşık bir yapıya sahip olan bu fiziksel modellerin kullanılması, geniş ölçekli işletmelerde çok sayıda proses değişkeni ve dolayısıyla yoğun iterasyon içereceği için oldukça fazla zaman almaktadır [1]. Bu nedenle bilgisayar yazılımlarının kullanıldığı simülasyon, tahmin ve kestirim çalışmaları son dönemde yukarıda bahsi geçen matematiksel modellere alternatif olarak ortaya çıkmaktadır.

Özellikle yapay zeka modellerini kullanarak gerçekleştirilen deneysel çalışmalar, öngörülen matematiksel metodların ve nümerik çözümlerinin doğruluğunu ve performansını karşılaştırmalı olarak ölçmesi bakımından literatüre katkı sağlamaktadır. Geleneksel teknikler genel olarak doğrusal giriş-çıkış eşleşmesi konusunda başarılı çıktılar ortaya koymaktayken, sinirsel ağlar daha karmaşık ilişkileri keşfedebilme ve eşleştirebilme yetenekleri sayesinde ön plana çıkmaktadır. Bununla birlikte sinirsel ağların kullanımı, hem modellerin geliştirilme süresini oldukça kısaltmaktadır, hem de işletme koşullarındaki değişimlere göre tekrar kalibre edilebilmelerinin kolay olması bakımından oldukça kullanışlıdır.

Önemli bir veri madenciliği tekniği olan Yapay Sinir Ağları (Artificial Neural Networks, ANN), özellikle zamanla değişen, karmaşık ve doğrusal olmayan eşleştirme uygulamalarındaki yüksek performansı nedeniyle bu çalışma için seçilmiştir ve bu yöntemin genel olarak regresyon bazlı geleneksel modellerden daha iyi sonuçlar verdiği bilinmektedir [2]. Tez çalışmasında sunulan diğer istatistiksel modellerden Otoregresif Entegre Kayan Ortalama (Autoregressive Integrated Moving Average, ARIMA) ve Çoklu Doğrusal Regresyon (Multiple Linear Regression, MLR) algoritmaları da, modellemenin regresyon başarımlarının tespiti ve çıktıların birbiri ile karşılaştırılabilmesi için tercih edilmiştir.

Tüm bu modellerin yanında, son dönemlerde literatürde özellikle doğrusal olarak ayrılamayan veri gruplarının kestirimi çalışmalarında başarılı sonuçlar veren ve görece olarak yeni bir yöntem olan Destek Vektör Regresyonu (Support Vector Regression, SVR) modeli de kullanılmıştır. Söz konusu dört model arasındaki karşılaştırmaya ek olarak, sinir ağı modelinin eğitim algoritmasının değiştirilmesi suretiyle, öğrenme işleminin model performansına olan etkileri de araştırılmıştır. Model sonuçlarının karşılaştırılabilmesi için, literatürde kabul gören performans kriterleri olan Belirlilik Katsayısı (R^2) ve Karekök Ortalama Hatası (RMSE) ifadeleri kullanılmıştır.

Çalışmanın ikinci bölümünde Türkiye’de kurulu bulunan kömür yakıtlı bir termik enerji santralının operasyonu incelenmiş ve proses parametrelerinden oluşan veri grubu kullanılarak santralin ürettiği elektrik enerjisinin değişimi ve tahminlenmesi üzerine özgün bir çalışma gerçekleştirilmiştir. Termik Santraller, genel olarak, hammadde olarak kullanılan kömürün tozlaştırılarak kazanlarda yakılması ile ortaya çıkan yüksek sıcaklığın sağladığı ısı (buhar) enerjisinin öncelikle mekanik enerjiye, sonrasında da elektrik enerjisine dönüştürüldüğü enerji üretim tesisleridir. Yanma işlemi kazan olarak adlandırılan ve santralin en kritik ekipmanı olarak adlandırılabilen bir buhar üreticinde gerçekleştirilmektedir. Saf halde bulunan ve kazan içerisindeki borulama vasıtasıyla yoğun bir sıcaklık ve yüksek basınca maruz kalan su, kazan içerisine ulaştığında hızlı bir şekilde kızgın buhar haline dönüştürülür.

Kızgın buhar daha sonra buhar türbinine iletilir ve bu enerji nedeniyle türbin grubunun üzerindeki mekanik şaft dönmeye başlar. Bu işlem, aynı şaft üzerinde bulunan

jeneratör ünitesinin elektrik üretmesi ile sonuçlanan kritik bir prosesin temelini oluşturmaktadır. Buhar, ilk olarak türbinin yüksek basınçlı bölümüne verilmektedir ve sonrasında paralel bir ısı işlemi ile türbinin orta ve alçak basınç bölümlerinde genişlemektedir. Birbirini izleyen bu genişlemeler sırasında ısı enerjisi, mekanik enerjiye dönüşmektedir ve buhar türbininde bulunan jeneratör ünitesi vasıtasıyla periyodik olarak elektrik enerjisi elde edilmesi vazifesini görmektedir. Türbin çıkışında enerjisini yitirmiş bir halde bulunan çürük buhar, kondenser olarak adlandırılan yoğunlaştırıcı üniteye iletilir. Üzerinde kalan ısıyı soğutma suyuna aktaran çürük buhar böylelikle gaz halden sıvı faza geçmiş olur. Elde edilen belirli sıcaklıktaki bu su, pompalar yardımı ile besleme suyu olarak kullanılmak üzere tekrar kazana gönderilir. Böylelikle santralde kullanılan su, sıvı ve gaz fazında kapalı bir çevrim içerisinde sürekli dolaştırılmış olur.

Gerçekleştirilen modelleme çalışmasında, prosesi etkilediği düşünülen parametreler daha önceki tecrübeler ve işletme grubun tavsiyelerine göre seçilmiştir. Bu parametrelerin seçimi ve doğruluğu, üretilen toplam gücün değişimi, kestirimi ve kontrolünün düzgün olarak saptanabilmesine zemin hazırlamaktadır. Çalışmada kullanılan veriler Türkiye’de üretim yapan ve 600 MWe’ lik kurulu güce sahip bir termik santralin 3 aylık konsolide işletme raporlarından elde edilerek kullanılmıştır. Kömür yakıtlı termik santralin günlük enerji üretimi, jeneratör çıkışında üretilmekte olan elektrik enerjisini etkilediği düşünülen ilgili parametrelerin yardımı ile Yapay Sinir Ağları (ANN), Otoresif Entegre Kayan Ortalama (ARIMA) ve Çoklu Doğrusal Regresyon (MLR) algoritmaları ile modellenmiş ve başarımları karşılaştırmalı olarak sunulmuştur.

Termik santrallerde güç üretimi genel olarak kömür, petrol, dizel yakıt ve doğalgaz kullanılarak gerçekleştirilmektedir. Ülkemizde özellikle 1970’ li yıllardan itibaren kurulan santrallerde yerli kaynak olan linyit kömürü kullanımı büyük bir artış trendi yakalamıştır. Termik santrallerde, bir taraftan ülke ve sanayi tesisleri için elzem elektrik enerjisi elde edilirken, diğer taraftan da kömür işletme sahaları, kömür nakil hatları ve kömür bantları ile yakıt transferi sırasında ortaya çıkan tozlar, baca gazları ve küller çevreyi olumsuz yönde etkilemektedir. Santrallerde yanma prosesi sonucu oluşan ve atmosfere atılan atık gazın içeriğindeki kirletici gazlar olan kükürtoksitler,

azotoksitler, karbonoksitler ve partikül maddeler önemli bir emisyon ortaya çıkartmaktadır.

Baca gazındaki bu emisyon oranları, kullanılan yakıtın türü, yakıtın bileşimi ve santralin yakma teknolojisine bağlı olarak değişiklikler göstermektedir. Kazanda gerçekleşen yanma prosesi sırasında yakıt içerisinde bulunan kükürtlü bileşikler büyük oranda kükürtdioksit ve nistepen az miktarda da kükürtoksit ortaya çıkmaktadır. Su ile tepkimeye giren kükürtoksitler, sülfirik asit bileşiklerini oluşturur ve sudaki çözünürlüğü yüksek olan bu bileşim yağmur damlacıkları ile birleşerek bir süre sonra asit yağmurlarına neden olur. Asit yağmurları toprakların asitlik derecesini artırır, alüminyum ve civa gibi toksik metalleri mobilize eder, topraktaki azot fiksasyonunu engeller ve nitratları mobil hale getirerek bitkilerin gelişmesini olumsuz etki yapar.

Termik santrallerin bir olumsuz etkisi de, uçucu kül ve kazan atıklarının açıkta depolanmaları durumunda, içerdikleri bileşiklerin yağmur ile su kaynaklarına sızmaları veya rüzgar ile atmosferde sürüklenerek çevreye zarar vermesi olarak ortaya çıkmaktadır. Bu zararlı küllerin çevreye yayılması ile doğal ve kültür bitkilerinin solunum ve fotosentez yapma imkanını azalır ve oluşan hava kirliliği insan sağlığını olumsuz yönde etkiler. Ayrıca santrallerin çalışması esnasında ortaya çıkan yoğun konsantrasyonlu karbondioksitin atmosferde birikmesi nedeniyle uzun vadede oluşacak sera etkisi nedeniyle ciddi iklim değişikliklerine yol açacağı beklenmektedir.

Söz konusu çevresel etkilerden yola çıkarak, tez çalışmasının son bölümünde, Kocaeli il sınırları içerisinde kurulu bulunan ve kömürle çalışan 180 MWe gücündeki bir termik enerji santrali üzerinde bir modelleme çalışması düşünülmüştür. Bu termik santrale ait baca gazı emisyon ölçüm verileri ve ilgili diğer parametrelerin yardımı ile baca gazı emisyonunun takibi ve tahminlenmesi hedeflenmiştir. Emisyon izleme sistemi raporlarından temin edilen ve her 15 dakikalık ortalama ölçüm değerlerinin kullanıldığı bu çalışmada, atık gaz emisyonu dinamik olarak modellenmektedir.

Modelleme sonucunda, sunulan modellerin çıktıları kullanılarak atık gaz emisyon değerlerindeki değişimlerin santral işletmesine olan etkilerinin önceden değerlendirilmesi ve sağlıklı bir işletmenin tesis edilebilmesine yönelik tedbirlerin

zamanında alınabilmesine katkı sağlanması hedeflenmiştir. Bu kestirim çalışmasında da yine önceki çalışmalardaki gibi Yapay Sinir Ağları, Ortalama Entegre Kayan Ortalama ve Çoklu Doğrusal Regresyon modelleri kullanılmıştır. Benzetim sonuçları, diğer çalışmalarla uyumlu olarak, belirlilik katsayısı ve karekök ortalama hatası kriterleri vasıtasıyla birbirleriyle karşılaştırılmıştır.

Birbirinden bağımsız olarak gerçekleştirilen her üç çalışma sonucunda elde edilen çıktılar göz önüne alındığında, kullanılan giriş değişkenlerinin çıkış değerini tatmin etme konusunda yüksek bir başarı gösterdiği anlaşılmaktadır. Model çıktılarının birbiri ile karşılaştırılması için seçilen kriterler olan belirlilik katsayısı ve ortalama karekök hatası değerleri göz önüne alındığında, modellerin genel olarak hesaplama ve analizler sonucunda yüksek tatmin oranı sağladığı gözlenmiştir. Her üç çalışma sonucunda da, en iyi benzetim performansının Levenberg-Marquardt eğitim algoritmasının kullanıldığı yapay sinir ağı modeli tarafından sağladığı görülmüştür. ANN modelinin SVR, ARIMA ve MLR modellerine göre daha iyi bir kestirim performansına sahip olduğunun gösterilmesi ise bu deneysel çalışmanın bir başka sonucu olarak ortaya çıkmaktadır.

1.2. Çalışmanın Literatürdeki Yeri

Yüksek Fırın günlük işletmesi sırasında operatörlerin anlık olarak takip ettiği kritik parametrelerden bir tanesi de alev sıcaklığıdır. Bu hedef parametrenin modellenmesi ve kestirimi konusunda literatürde birtakım çalışmalar mevcut olmasına rağmen, güncel fırın verileri ve özellikle yapay sinir ağları modeli kullanılarak gerçekleştirilen bir tahmin çalışmasına rastlanmamaktadır. Literatürdeki çalışmalara bakıldığında, araştırmacıların daha çok alev sıcaklığı değerinin matematiksel ve nümerik modeller yardımı ile anlaşılabilmesine yönelik uygulamalar yaptığı gözlenmektedir.

Örneğin, hidrokarbonlu yakıtların kullanıldığı yanma ortamında, alev sıcaklığı değerinin yapay sinir ağları ile modellenerek tahmin edildiği bir çalışmada, yakıt dağılımı, reaksiyonların basınç ve sıcaklığı, hava-yakıt oranı ve yakıt buharlaşma indeksi gibi giriş parametreleri seçilmiştir [3]. Değişik operasyon şartları için deneylerin gerçekleştirildiği bu araştırma sonucunda, alev sıcaklığı değerinin başarılı

bir şekilde kestirilebildiği gösterilmiştir. Diğer bir çalışmada, değişik miktarlarda yakıt, oksijen ve azot için yanma hattı ve alev bölgesi tahmin edilmektedir. Çalışmada alev sıcaklığı değerinin hesaplandığı bir metod literatüre sunulmaktadır ve sonuçlar eldeki geçmiş verilerle karşılaştırıldığında modelin başarılı bir hesaplama yaptığı görülmektedir [4].

2005 yılında gerçekleştirilen, temel olarak kok ve yüksek fırın gazları için değişik yakıt lansı açılarının yanmaya etkisinin araştırıldığı bir çalışmada, iki gazın tek bir yakma lansından enjeksiyonu, kok gazı miktarının yanmaya etkisi, tek ya da çift lans kullanımının etkileri ve fırın enjeksiyonu için lans açılarının performansı kestirilen sıcaklık, akış ve gaz kompozisyonları göz önünde bulundurularak tartışılmaktadır [5].

Sonuç olarak kok gazının yüksek fırın gazına göre daha etkin bir şekilde yandığı ve bu durumun tüyer bölgesi üzerinde daha yüksek bir alev sıcaklığı meydana getirdiği gösterilmiştir. Brezilya'da kurulu bulunan CSN III numaralı yüksek fırını için gerçekleştirilen bir çalışmada, fırının kimyasal ve termal parametreleri hibrid yapay sinir ağı kullanılarak modellenmiştir [6]. Malzeme sistemindeki dalgalanmalar, şarj ve üfleme sisteminin de model bünyesine alındığı bu çalışmada daha verimli bir işletme, kimyasal olarak kaliteli çıktı ve hedef maliyetlere ulaşma hedefine yaklaşıldığı rapor edilmiştir.

Gaz yakıtlardan kaynaklanan ısı enerjisi ve alev sıcaklığını etki eden parametrelerin tartışıldığı başka bir çalışmada, Matlab'da hazırlanan, FTC ismi verilen ve alev sıcaklığını hesaplayan model sunulmaktadır [7]. Program çıktılarına bakıldığında oksijen zenginleştirmesinin alev sıcaklığını marjinal şekilde arttırdığı görülmüştür. FTC modelinin karbondioksit, buhar, oksijen, azot, karbonmonoksit ve azotoksit konsantrasyonlarını hesaplayabildiği de gösterilmiştir. Ayrıca FTC tarafından hesap edilen proses parametreleri, yapay sinir ağı modeli ile de modellenmiş ve alev sıcaklığı değerinin %1,3 gibi güvenilir bir doğruluk ile kestirilebileceği gösterilmiştir.

2010 yılında gerçekleştirilen bir başka çalışmada da, Masmoc adı verilen bir yüksek fırın optimizasyon modeli uygulaması geliştirilmiştir [8]. Söz konusu yazılım, sobalar

sistemi, yanma modelleri, tepe gazı ve CO₂ salınımı gibi temel yüksek fırın operasyonunu modellemektedir. Çalışmanın bir parçası olarak geliştirilen alev sıcaklığı hesabı, tüyer bölgesi civarında yanma sonrası ortaya çıkan entalpi, kimyasal reaksiyon çıktıları, kok malzemesi başta olmak üzere yanmadan dolayı ortaya çıkan ısı enerjisi ve fırın gövdesinin ısı kapasitesi parametreleri göz önünde bulundurularak matematiksel olarak modellenmiştir. Sunulan denklem, iteratif olarak çözülmüş, optimize edilmiş ve hesaplama sonuçları referans değerler ile karşılaştırıldığında modelin başarılı bir sonuç verdiği gösterilmiştir.

Yüksek fırınların verimliliğinin temel teknolojik faktörler gözününe alınarak hesaplanarak gösterildiği bir çalışmada, yüksek fırınlardaki tepe kok şarjı miktarının alev sıcaklığına olan etkisi de değerlendirilmiştir [9]. Pik demir içerisinde ton başına düşen kok miktarının 250 kg/t, kömür miktarının ise 367 kg/t dolaylarında olduğu bir yüksek fırın üzerinde gerçekleştirilen çalışmada, alev sıcaklığını optimize edebilmek için gerçekleştirilen hesapta tüyer bölgesinden fırına şarj edilecek demir tozu oranının %10 dolayında arttırılması önerilmektedir.

Fırınlarda çok sayıda kütle hareketleri, yanma işlemleri, katı-katı, katı-sıvı, gaz-katı tepkimeleri ile birleşen yoğun ısı ve kütle transferleri nedeniyle son derece zor bir problem karşımıza çıkmaktadır. Yüksek fırın prosesi, çoklu değişkenli giriş parametrelerine bağlı olarak sürekli bir değişkenlik göstermektedir ve özellikle malzemeler arası etkileşimlerden dolayı aynı koşullarda bile farklı çıktılar vermektedir. Bu nedenle fırınların matematiksel olarak modellenmesi ve simülasyonu oldukça zordur. Ancak, literatürde alev sıcaklığı tahminlemesi ve kontrolünün yanında, önemli bir verimlilik parametresi olan pik maden sıcaklığının yapay sinir ağları ile kestirimine yönelik bazı çalışmalar gerçekleştirilmiştir.

Örneğin, Hindistan'da kurulu bir yüksek fırının ürettiği pik demirin sıcaklığı dahil olmak üzere bazı kalite parametreleri, ileri beslemeli yapay sinir ağı ile modellenmiştir [10]. Araştırmacıların 24 adet giriş parametresi ile başladıkları bu çalışmada maden sıcaklığına etkiyi maksimize eden parametre sayısı 15 adete indirilmiş ve geri yayılım öğrenmesi uygulanan tek gizli katmanlı bu ağın günlük pik maden sıcaklığını kestirebildiği gösterilmiştir.

Diğer bir çalışmada, pik demirin silisyum içeriğinin kestiriminde çok katmanlı ileri beslemeli sinirsel ağlar kullanılmıştır [11]. Levenberg-Marquardt öğrenme algoritmasının kullanıldığı bu makalede, ileri beslemeli ağların doğrusal zaman serilerine göre daha iyi bir performans gösterdiği rapor edilmektedir. Günümüzde, yüksek fırın pik demir sıcaklığı ve silisyum içeriği ile ilgili literatüre çok sayıda modelleme ve kestirim çalışması sunulmuştur. Ancak, bu tez çalışmasında alev sıcaklığına yoğunlaşıldığı için konu ile daha fazla referans verilmeyecektir.

Çalışmanın ikinci bölümünü oluşturan termik santrallerin modellenmesi ve jeneratör çıkış gücünün kestirimi ile ilgili yayınlar tarandığında, özellikle kömür yakıtlı termik enerji santrallerinin kritik işletme parametrelerinin ya da üretilen enerji miktarının kestirimine yönelik çalışmaların son dönemde yoğunlaşmakta olduğu gözlenmektedir. Sunulan bu çalışmalarda tahminleme algoritması olarak genellikle yapay sinir ağları modelinin seçildiği gözlenmektedir.

Örneğin, 2007 senesinde sunulan çalışmada, İsveç'in Helsinborg kentinde faaliyet göstermekte olan ve hammadde olarak kömür ile biyoyakıtın kullanıldığı çift yakıtlı bir kombine ısı ve enerji santrali, ileri beslemeli geri yayımlı bir yapay sinir ağı ile modellenmiştir [12]. Modellemede santralin geçmiş dönemdeki proses verileri kullanılmıştır ve geliştirilen bu model, santralin performansının hızlı bir şekilde ve yüksek doğrulukla izlenebileceğini göstermiştir.

Aynı yıl sunulan bir diğer çalışmada, kömür yakıtlı bir termik santralde bulunan doğal sirkülasyonlu kazanın modellenmesi üzerinde çalışılmıştır [1]. Yedi adet alt bölgeye ayrılan bu enerji santralinin modellenmesinde Matlab Simulink programı kullanılmıştır. Her bir bölge için basınç, sıcaklık, buhar akışı, besleme suyu gibi proses parametrelerindeki enerji, kütle ve momentum dönüşümleri tasarlanarak izlenmiştir. Sonuç olarak, bu parametrelerin simülasyonu ile kazanın etkin olarak kontrolünün sağlandığı gösterilmiştir.

2010 yılında gerçekleştirilen bir diğer çalışmada ise, daha önceden ölçülen ve kayıt altına alınan bir kömür yakıtlı termik enerji santraline ait işletme verileri ile, bu santralin çıkışında üretilen toplam gücü kestiren bir model tasarlanmıştır [13]. Buhar

türbini ve kazan ünitelerinin herbiri için ayrı ayrı iki yapay sinir ağı modeli, kazan modeli çıktıları vasıtası ile birbirine entegre edilmiştir. Baz yükteki işletme şartlarında ve santralin gerçek verileri kullanılarak tasarlanan ve eğitilen bu ağlar için öngörülen giriş parametreleri olabildiğince az tutulmaya çalışılmış ve modelin tatmin edici kestirim performansı gösterdiği rapor edilmiştir. Ayrıca bu işletme için yapay sinir ağının interpolasyon kabiliyetine yönelik bulgular da çalışma çıktılarının içerisinde gösterilmiştir.

2011 senesinde Hindistan'da yapılan bir başka çalışmada ise geliştirilmekte olan 800 MW'lık yüksek kül oranına sahip kömür yakıtlı süper kritik bir enerji santrali için termodinamik bir enerji ve ekserji analizi sunulmuştur. Santralin girişinde minimum enerji harcayarak maksimum verimlilikte çalışacak optimum işletme parametresinin seçimi üzerinde çalışma gerçekleştirilmiştir. Öncelikle söz konusu enerji santrali yapay sinir ağı ile modellenmiş ve sonrasında ilgili parametrenin yapay sinir ağı çıktıları genetik algoritma modeli içerisine dahil edilerek başarılı bir şekilde optimize edildiği rapor edilmektedir [14].

Pulverize kömürle çalışan bir enerji santralindeki toplam kazan külü miktarının yapay sinir ağı ile modellendiği çalışmada santralin ve işlenen kömürün bir senelik işletme verileri kullanılmıştır [15]. 653 adet veri grubunun kullanıldığı ileri besleme geri yayılım ağında tek gizli katman ve 29 gizli nöron ile model optimize edilmiştir. Başarım ölçütü olan belirlilik katsayısı test verisi için oldukça başarılı bir oran olan 0,984 bulunmuştur.

Ayrıca, 300 MW nominal gücündeki bir başka santral için, en küçük kareler hızlı öğrenen ağ modeli (LSFLN) olarak adlandırılan ve öğrenmenin sadece gizli katmandan değil, ayrıca giriş parametreleri kullanılarak da optimize edildiği bir yaklaşım sunulmuştur [16]. Ağırlık ve bias değerlerinin en küçük kareler metodunun iki kez çalıştırılması ile hızlı bir şekilde hesaplandığı bu yaklaşım, altı adet klasik regresyon uygulamasına ve 300 MW'lık santral verilerine uygulanmıştır ve öğrenme hızının klasik metodlara göre iki kata kadar arttırıldığı gösterilmiştir. Yapılan bu deneysel çalışmaların sonucunda daha az gizli katman kullanarak iyi kestirim sonuçları elde edildiği belirtilmektedir.

Literatürde bu çalışmalara ilaveten, yapay sinir ağları kullanılarak kömür yakıtlı enerji santrallerindeki farklı proses parametrelerinin ya da santral verimliliğinin kestirimine yönelik bazı çalışmalar yapıldığı da gözlenmiştir. Örneğin, Levenberg-Marquardt öğrenme algoritmasının kullanıldığı ileri beslemeli geri yayımlı yapay sinir ağının kullanıldığı ve 3 set halindeki 930 örnek verinin kullanıldığı bir kömür santralinde açığa çıkan hidrojen gazının kestirimi gerçekleştirilmiştir [17]. Yüksek bir regresyon ve düşük bir ortalama karakök hatasının ortaya çıktığı bu çalışmada, görece hatanın %5,46 mertebesinde olduğu gösterilmiştir.

Enerji santrallerinde kullanılan kazanların operasyonu ve dizaynında önemli parametrelerden birisi de kömür külü sıcaklığıdır. Bu sıcaklığın, kömür külünün kimyasal kompozisyonu ile orantılı olarak değiştiği düşünülür, ancak bu ilişki tam olarak tanımlanamamaktadır. Çin’de kurulu olan 80 adet termik santrale ait verilerin kullanıldığı bir yapay sinir ağı dizayn edilmiştir. 3 katmanlı ve 10 gizli nöronun öngörüldüğü bu ağ, arı kolonisi optimizasyon algoritması (ACO) vasıtasıyla eğitilmiştir. Sonuç olarak, arı kolonisi yaklaşımı ile eğitilen ağın, geri yayılım ağı modeli ve basit nümerik modellere göre daha iyi bir kestirim başarımı gösterdiği rapor edilmiştir [18].

Slovenya’da kurulu bulunan kömür yakıtlı bir enerji santraline ait kazan ünitesinin bazı buhar parametrelerinin gerçek saha verileri kullanılarak yapay sinir ağı ile modellenmesi ve kestirimi çalışması gerçekleştirilmiştir [19]. Sistemde ölçülen çok sayıda parametre içerisinde daha önceki tecrübe ve bilgiye de dayanılarak yeterince giriş parametresi seçilerek kullanılmıştır. Ancak gerçekleştirilen simülasyonlar sırasındaki denemelerde sistem başarımını optimize eden giriş parametreleri ile nihai giriş parametreleri belirlenmiştir. Geliştirilen ilk modelde kömürün akış oranı, diğer modelde ise konveyör hızı giriş parametresi olarak göz önüne alınmıştır ve geri kalan giriş değerleri her iki modelde de aynıdır. Sonuç olarak her iki modelin de iyi bir doğrulukla tahminleme yapabildiği gösterilmiştir.

Bu çalışmalarla birlikte, son dönemde destek vektör regresyonu yönteminin kullanıldığı ve genellikle yenilenebilir enerji santrallerindeki üretilen enerjinin tahminlendiği çalışmalara rastlanmaktadır. Bir rüzgar enerji santralinde

gerçekleştirilen çalışmada, öncelikle nümerik rüzgar kestirim metodları kullanılmıştır. Daha sonra destek vektör regresyon metodu kullanılarak rüzgar türbininin üretim gücü ileriki dönemler için tahminlenmiştir [20]. Farklı yenilenebilir enerji türü olan güneş enerji santralleri için yapılan diğer çalışmada, hava durumu bilgileri sınıflandırılmış ve destek vektör makineleri yöntemiyle santralin bir gün sonraki enerji üretimleri tahminlenmiştir. Çin’de kurulu bulunan 20 kW’lık bu santral için model çıktılarının gelecek vaat eden ve etkin sonuçlar verdiği değerlendirilmiştir [21].

Çalışmanın üçüncü bölümünü oluşturan ve kömür yakıtlı termik santrallerin atık gaz emisyonlarının modellenmesi ve kestirimi ile ilgili çalışmaların da son dönemde bir artış trendi yakaladığı görülmektedir. Literatür tarandığında, özellikle yapay sinir ağları modeli ve destek vektör regresyonu yöntemleri ile birlikte kullanılan doğrusal ya da doğrusal olmayan bazı modeller vasıtasıyla tahminleme çalışmalarına raslanmaktadır. Örneğin, 200 MW’lık bir kömür yakıtlı bir enerji santralinde gerçek zamanlı işletme şartlarında NO_x gaz emisyonunu modelleyen bir çalışma gerçekleştirilmiştir. ARX, NARX ve gri-kutu (grey-box) sistem tanımlama tekniklerinin sunulduğu bu modellemede işletme verileri doğrulama ve karşılaştırma için kullanılmıştır. Uzun vadeli tahminleme sonuçlarına bakıldığında gri-kutu modelinin diğer modellere göre daha iyi bir performans gösterdiği rapor edilmiştir [22].

Genelleştirilmiş regresyon yapay sinir ağı (GRNN) kullanılarak modellenen 300 MW’lık bir kömür yakıtlı bir santralde NO_x parametresinin başarılı bir şekilde kestirildiği belirtilmektedir. Ayrıca GRNN algoritmasının geri yayılım yapay sinir ağı modeli ve doğrusal regresyona göre daha iyi bir başarımlı sağladığı da rapor edilmiştir [23]. 2009 yılında sunulan çalışmada, 300 MW’lık yüksek kapasiteli bir kömür yakıtlı enerji santrallerinde uygulanacak yanma optimizasyonunun NO_x gazı emisyonlarını azaltabileceği tezi ile gerçekleştirilen çalışmada, yapay sinir ağı ve destek vektör regresyon (SVR) modelleri kullanılarak üretilen bir model ile tahminleme çalışması yapılmıştır [24]. Gerçekleştirilen deneylerde özellikle arı kolonisi optimizasyonu ile kombine edilen SVR yaklaşımının, yapay sinir ağı modeline göre biraz daha iyi bir tahminleme yapabildiği gösterilmiştir. Emisyon modelinin uygulaması için 6

dakikadan az bir süre gerekirken, optimizasyonun 2 dakika civarında gerçekleştirildiği rapor edilmiştir.

Endüstriyel kazanlardaki yanma neticesinde ortaya çıkan NO_x ve O_2 emisyonlarının tahminlenmesi için dinamik bir yapay sinir ağı modeli geliştirilen bir diğer çalışmada, seçilen giriş parametreleri alt gruplara ayrılarak testlere tabii tutulmuştur. Temel bileşen analizi (PCA) kullanılarak giriş veri dizinleri optimize edilmiştir. Generik algoritma kullanılarak da doğrusal zaman gecikmesi modelinin sistem parametreleri hesaplanmıştır. Kazan prosesinin geçmiş verileri kullanılarak sunulan bu modellerin doğrulanmasında kullanılmıştır. Ayrıca simülasyon çıktıları statik yapay sinir ağı modeli ile de karşılaştırılmıştır. Sonuçlar, sunulan modelin etkili bir şekilde emisyon değerlerini kestirebildiğini göstermiştir [25].

Farklı kestirim modellerinin kullanıldığı diğer bir çalışmada, kömür yakıtlı bir kazanın NO_x emisyon değerleri, yakma optimizasyonu kullanılarak modellenmiştir. Modelin ilk bölümünde destek vektör regresyonu yöntemi kullanılmış ve kestirim başarımının iyi seviyelerde olduğu gösterilmiştir. Çalışmanın ikinci bölümünde ise arı kolonisi algoritması (ACO), genetik algoritma (GA) ve parçacık sürü optimizasyonu (PSO) metodları kullanılarak toplam NO_x miktarını minimize eden optimum işletme parametreleri kestirilmiştir. Çalışma sonucunda SVR ile hidrid olarak kullanılan ACO ve hatta GA modellerinin daha iyi performans gösterdiği, ancak PSO modelinin başarısız olduğu gözlemlenmiştir [26].

Kömür yakıtlı bir enerji santralinde, geri yayılım yapay sinir ağı (BPNN), genel regresyon yapay sinir ağı (GRNN) ve destek vektör regresyonu yöntemleri kullanılarak NO_x emisyon değerleri modellenmiş ve kestirilmiştir. Bununla birlikte destek vektör regresyon modelinin genelleştirme ve Gauss kernel parametreleri arı kolonisi algoritması vasıtasıyla optimize edilmiştir. Çalışma sonucunda SVR yönteminin, BPNN yöntemine göre daha etkili olduğu ve GRNN yöntemi ile hemen hemen aynı başarımla sergilediği rapor edilmiştir [27].

300 MW'lık bir termik santralin ısı kaybı modeli ve NO_x emisyon karakteristiği, kazan proses parametreleri kullanılarak geri yayımlı yapay sinir ağı (BP) ile modellenmiştir

ve tahmin edilmiştir. Daha sonra BP ve baskın olmayan sıralayan genetik algoritma II (NSGA-II) modelleri birbiri ile kombine edilmiş ve daha düşük NO_x emisyonu ile minimum ısı kaybına neden olacak operasyon parametreleri tasarlanmıştır. Simülasyon sonuçları incelendiğinde, sunulan BP ve NSGA-II hibrid algoritmasının kömür yakıtlı kazana ait ısı dengesi ve emisyon parametrelerini başarılı bir şekilde optimize edebildiği gösterilmiştir [28].

2013 yılında gerçekleştirilen çalışmada ise, bir enerji santralinde atık gaz emisyonunu hesaplayan ve genetik algoritma ile doğrusal regresyon modellerinin kombine edildiği yeni bir yaklaşım sunulmuştur [29]. Bağımlı değişken olarak seçilen NO_x gazı değerini etkilediği düşünülen seçili giriş parametrelerinin geçmiş değerleri kullanılarak gerçekleştirilen tahminlerin başarılı olduğu gözlenmiştir. Ayrıca regresyon modeline kombine edilen genetik algoritmanın kullanımı ile kestirim optimizasyonunun başarı oranlarının arttığı ve bu yöntemin kullanılması ile daha sağlıklı tahminlerin yapabileceği gösterilmiştir.

Yine son dönemde sunulan bir başka çalışmada, biyoyakıt, biyoyakıt ve kömür ile sadece kömürün yakıt olarak kullanıldığı 55 MWe ve 179 MWt çıkışlı santralde açığa çıkan NO_x ve SO_x gaz miktarları nümerik olarak modellenmiştir. Atık gaz resirkülasyon oranı, hava ön ısıtma sıcaklığı, oksijen konsantrasyonu ve yakıt tiplerinin emisyon etkilerinin araştırıldığı bu çalışmada, kömür yerine biyoyakıtın kullanılması halinde daha düşük bir NO_x emisyonu elde edilebileceği gösterilmiştir [30].

2014 yılında yapılan çalışmada, Güney Kore’de bulunan bir enerji santrali bacasından dışarı salınan atık gazın oranı, öncesinde kullanılan yüksek verimli bir ısı dönüştürücü ünitesi ile birlikte değerlendirilmiş, modellenmiş ve kestirilmiştir [31]. Çalışmada ısı dönüştürücü ünite vasıtasıyla 115 °C sıcaklıktan 40 °C sıcaklığa indirilen atık gaz bünyesinde buharlaşma, nem ve NO_x gazı artışı meydana geldiği gözlenmiştir. Simülasyon ve kestirim çalışmaları sonucunda düşük sıcaklıklardaki atık gazın çevreye olumsuz etkilerinin daha büyük olduğu gösterilmiştir.

2014 yılında gerçekleştirilen bir başka çalışmada ise, Hindistan'da kurulu bulunan kömür yakıtlı bir termik santralin NO_x gazı emisyonu, sunulan iki aşamalı bir uzman öneri sistemi (expert system) vasıtasıyla modellenmiştir [32]. İlk aşamada kazan işletme parametrelerinin giriş, NO_x'in de çıkış olarak kullanıldığı bir yapay sinir ağı modeli önerilmiştir. Santralin maksimum yükte çalıştığı dönemde gerçekleştirilen bu çalışmada elde edilen kestirim sonuçları gerçek sonuçlarla doğrulanmıştır. İkinci aşamada ise bulanık mantık (FL) algoritması kullanılarak, operatörler için NO_x emisyonunu kontrol altına alabilmeye yönelik bir tavsiye sistemi sunulmuştur.

BÖLÜM 2. ÇALIŞMADA İNCELENEN TESİSLER

2.1. Demir Çelik Fabrikaları ve Yüksek Fırımlar

İktisat bilimi literatüründe fert başına tüketilme oranının o toplumun gelişmişlik göstergesi olarak tanımlandığı ve insanlık tarihi boyunca savaş aleti, süs, kaplama ve barınma gibi ihtiyaçların karşılanmasında yoğun olarak kullanılan demir ve çelik, günümüz endüstrisinin temel hammaddelerinden birini oluşturmaktadır. Demir-çelik üretiminin ilk olarak milattan önce birinci yüzyılda Çin’de, 1150-1350 yılları arasında da İskandinavya bölgesinde gerçekleştiğini gösteren birtakım kanıtlara ulaşılmına rağmen, resmi kayıtlar günümüz fırınlarının atası olan ilk tesisin 14. yüzyılda İngiltere’de üretim yaptığını göstermektedir [33].

1800’lü yılların başlarında, günümüzden farklı tekniklerle 1 milyon ton civarında demir-çelik malzeme üretildiği tahmin edilmekteyken, kitlesel üretim yöntemlerinin devreye sokulması ile dünya çelik üretiminin 1870’te 10 milyon tona, 1900 yılından itibaren de yıllık %4,5 gibi bir artışla 37 milyon tona yükseldiği bilinmektedir [34]. Sanayileşmenin lokomotifini olan demir-çelik imalatı, özellikle 20. yüzyılın başlarında yeni haddeleme ve alaşım yöntemlerinin keşfiyle ivme kazanmış, dünya savaşları dönemlerinden itibaren sürekli artan ihtiyaç ve teknolojik gelişmeler ile 2012 yılı sonunda dünyada 1.547 milyon ton düzeyinde ham çelik üretimi gerçekleştirilmiştir.

Ülkemizde ise son yıllarda çelik üretimine yönelik yeni yatırımların da devreye girmesiyle yıllık elli milyon tonu aşkın bir imalat hacmine ulaşılmıştır. Gelişmiş ülkelerde çelik tüketimi ortalama 400-600 kg/kişi/yıl civarındayken, ülkemizde bu rakam yaklaşık 200 kg/kişi/yıl dolayındadır. Şekil 2.1’de, 2013 yılı itibarıyla devrede olan Türk demir-çelik üretim tesislerinin, bölgelere göre coğrafi dağılımları ve ortalama kapasiteleri hakkında bilgi verilmektedir.



Şekil 2.1. 2013 yılı Türkiye çelik haritası

Entegre demir-çelik tesislerinin kalbi niteliğinde olan yüksek fırınlar, çeliğin hammaddesi, sıcak maden üretimi için kullanılmakta olan endüstriyel tesislerdir. Bu tesislere alternatif olarak geliştirilen daha küçük ölçekli ark ocaklı fırınlarda sıcak maden üretimi, hurda levhaların elektrik enerjisi vasıtasıyla ergitilmesiyle elde edilmektedir. Yüksek fırınlar görece olarak büyük, yüksek, çelik sacların birbiri ile kaynatılması ile temel zemine oturtulmuş, üzerinde çok sayıda platform ve borulamanın bulunduğu silindirik yapılardır [35].

Fırının iç yüzeyi, özellikle yüksek sıcaklıklardaki reaksiyonlara karşı gövdeyi korumak ve fırın içi sıcaklık dengesini sağlayabilmek için refrakter tuğlalarla örülmüştür [33]. Fırına şarj edilen malzemeler yukarıdan aşağıya indikçe ısı nedeniyle genişlemektedir ve bu nedenle fırın gövde sacı aşağıya doğru genişlemeye imkan verecek şekilde dizayn edilmekte ve uygulanmaktadır. Şekil 2.2'de, Türkiye'nin güney bölümünde faaliyet gösteren İskenderun Demir Çelik Fabrikasına ait olan 3. Yüksek Fırın tesisinin fiziksel görünümü gösterilmektedir.



Şekil 2.2. İsdemir III. yüksek fırınının genel görünümü

Yüksek fırınlar genel olarak, yukarıdan aşağıya sıralanırsa, boğaz (throat), gövde (stack), bel (belly), karın (bosh) ve hazne (hearth) olmak üzere beş ana kısımdan oluşacak şekilde dizayn edilmektedir. Entegre demir-çelik tesislerinde kullanılmakta olan fırınların temel amacı, sıcak madenin mümkün olan en verimli ve kaliteli bir şekilde, olabildiğince sabit bir kimyasal kompozisyonda üretiminin sağlanması olarak özetlenmektedir [33].

2.1.1. Yüksek fırın prosesi

Yüksek fırınlarda gerçekleşen kimyasal reaksiyonlardaki temel amaç, demirli malzeme girdisi içerisinde birleşik halde bulunan demir oksit bileşenlerinin içerisindeki oksijen elementinin ayrıştırılmasının sağlanmasıdır. Kok içerisinde bulunan karbon ile demir oksitlerin tepkimeleri sonucu karbon monoksit ve karbon dioksit gazları açığa çıkmaktadır ve bu reaksiyonların sonucunda nihai ürün olarak 1400-1550 °C sıcaklık aralığında ve genel olarak kompozisyonunda % 4-5 dolaylarında karbon elementi bulunan ergimiş sıcak maden elde edilmektedir [33].


Sıcak maden oluşumu için fırınlara şarj edilen temel hammaddeler en ana haliyle; demirli malzeme, metalurjik kok ve kireçtaşı olarak sıralanmaktadır [36]. Günümüzde yüksek fırınların en yoğun olarak kullandığı demir cevheri türü pelettir. Bazı demir çelik tesisleri içerisinde bulunan sinter fabrikalarında üretilmekte olan sinter malzemesini ikincil demirli malzeme türü olarak da kullanılmaktadır. Tesislerde atık cevherlerin geri kazanımı prensibiyle üretim yapmakta olan sinter malzemesinin kullanımı, tesisin toplam hammadde ve proses verimliliğini arttırmakta ve çevre atık etkisini olabildiğince baskılamaktadır.

Metalurjik kok kömürü, fırının iç ısısını arttırmak ve demir cevherinin saflaştırma prosedürünü hızlandırmak amacıyla kullanılan bir diğer önemli hammaddedir. Kok ayrıca indirgeme prosesi için katalizör etkisi de yapmaktadır ve bu malzemenin kullanımının optimizasyonu ile fırın içi ısı dengesi stabil halde tutulması sağlanmaktadır. Genellikle tesis içerisinde kurulu bulunan kok fabrikaları sayesinde düşük kalorili taşkömürü ya da linyit kömürü yakılarak saflaştırılır ve ortaya çıkan yüksek kalorili kok yüksek fırınlarda kullanılmak üzere depolanır. Bu proses sonucu ortaya çıkan kok gazı, tesislerdeki yakıt arıtma sistemleri vasıtasıyla temizlenmektedir ve değişik tesislerde yakıt olarak kullanılabilir.

Yüksek fırınlarda metalurjik kok kullanımı, fiziksel anlamda gaz ve sıvı geçirgenliği sağlamak, kimyasal anlamda indirgeyici gaz ve termal anlamda da ısı girdisi olması nedeniyle büyük bir öneme sahiptir. Fırınlarda kullanılan bir diğer önemli hammadde ise kireçtaşıdır. Kireçtaşı kullanımı ile demir cevherinde bulunan artıkların kimyasal tepkimeler vasıtasıyla cüruf olarak adlandırılan artık maddeye dönüştürülmesi hedeflenmektedir. Ortalama olarak 1 ton sıcak maden elde edebilmek için yaklaşık 450-650 kg civarında kok kullanılmaktadır ve 1 ton kokun yanması için de fırına verilen sıcak hava miktarının yaklaşık olarak 3000 m³ civarında olması gerekmektedir [37]. Yüksek fırınların iç hacmi genellikle 250-850 m³ aralığındadır ve 1 m³ fırın hacmine karşılık olarak 24 saatte 0,5-1,4 ton civarında sıcak maden elde edilmektedir.

Yüksek fırınlar prosesinde temel amaç olan sıcak maden üretimini sağlayabilmek için temel olarak fırına şarj edilen hammadde sistemi ile fırına basınçlı ve sıcak hava üfleme sağlanan hava sistemi ve sobalar kullanılmaktadır. Kuvvet santralindeki

yüksek güçlü hava kompresörleri vasıtasıyla üretilen hava ortalama 90-120 °C aralığında bir sıcaklığa sahiptir. Üretilen bu hava, içi refrakter tuğla ile örülü olan ve belirli aralıklarla ısıtılan sobalar sistemine ilgili boru hattı boyunca ilerler ve soba çıkışında ortalama 900-1250 °C aralığında bir sıcaklığa ulaşır. Hat üzerinde bulunan basınç, sıcaklık, akış ölçümleri ve otomatik olarak kumanda odasındaki kontrol sistemi vasıtasıyla kontrol edilen vanaların yardımıyla fırına ilerleyen sıcak hava fırın girişinde simit olarak adlandırılan silindirik boru hattı vasıtasıyla tüyer olarak adlandırılan lanslar üzerinden fırın içine üflenir. Fırındaki tüyer sayısı fırın dizaynına göre değişmektedir ve fırının görece olarak alt bölgesinde yatay ekseninde belirli açılarla dağılmaktadır. Yüksek fırının genel görünüşü Şekil 2.3'te verilmektedir.




Şekil 2.3. Yüksek fırınların profilden görünümü [33]

Tüyerler, fırınlara hava enjeksiyonu gerçekleştiren mekanik boru lanslar olarak tanımlanabilir. Tüyerler, kömür enjeksiyon, doğalgaz, oksijen, vb. yakıtlar fırına direk ve bölgesel olarak şarj edilmesine yarayan önemli ekipmanlardır. Sobalar sistemi

üzerinden ısınarak gelen ve tüyerler vasıtasıyla fırına üflenen sıcak hava, fırın tepe sistemi vasıtasıyla belirli aralıklarda ve tonajda şarj edilen kok, sinter, pelet, kireçtaşı, vb. maddeleri yüksek basıncı ve hacmi nedeniyle askıda tutmaktadır. Hammadde katmanları ile hava içerisinde bulunan oksijen elementlerinin kimyasal tepkimesiyle fırının iç ısısı ortalama 2000-2500 °C mertebelerine çıkmaktadır. Oksijen ve kok malzemesinin buluşması neticesinde ortaya yoğun bir karbonmonoksit gazı çıkar ve bu gaz fırın tepe bölgesine doğru yükselir. CO gazı, demir cevheri üzerindeki oksijeni indirir ve böylece ergime noktası üzerine çıkan sıcaklıklar nedeniyle sıcak maden oluşumu başlamış olur. Sıvı haldeki sıcak maden, fırın duvarlarından süzülme ve tüyer bölgesinin altında yer alan ölü bölgede birikmeye başlar.

Demir cevheri içerisinde bulunan artık malzemelerle kireçtaşının tepkimeye girmesiyle de cüruf olarak adlandırılan atık malzeme üretilmiş olur. Yüksek fırın cürufunu oluşturan oksitler sırasıyla SiO_2 , CaO , MgO , FeO , MnO ve sülfürlü bileşiklerdir [38]. Cüruf ile sıcak maden özgül ağırlık farkı nedeniyle birbirinden kolaylıkla ayrılabilir. Cüruf sıcak madene göre daha düşük bir özgül ağırlığa sahiptir ve bu özelliği nedeniyle sıcak madenin üstünde akmaktadır. Bir yüksek fırında hammadde besleme sistemi ve demir-çelik üretim süreci Şekil 2.4'te gösterilmektedir.



Şekil 2.4. Yüksek fırınlar, hammadde sistemi ve çelik üretim süreci

Fırına tepe sistemi vasıtasıyla şarj edilen malzemeler genel olarak dökümhane deşarj hattına fırının iç çalışma şartlarına bağlı olarak 5 ila 8 saat arasında ulaşmaktadır. Operatörler fırın içerisindeki sıcak maden ve cüruf seviyesinin belirli bir noktaya ulaştıklarını anladıklarında maden deşarj işlemine geçilir. Sıcak maden ve cürufun fırın dışına alınması genellikle otomatik döküm makinası eşliğinde fırın yüzeyinin delinmesi ile gerçekleştirilmektedir [39]. Fırın tüyer bölgesinin altında bulunan ve hearth olarak adlandırılan hazne bölgesinde belirli aralıklarla açılan delikler vasıtasıyla sıcak maden ve cüruf malzemeleri fırın dışına alınmaktadır.

Dökümhane olarak adlandırılan bölümde bulunan ve altı refrakter tuğlalar ile sıcaklık ölçen sensörlerle donatılmış olan eğimli bir kanal üzerinde ilerleyen bu malzemeler bir süre sonra ağırlık farkları nedeniyle birbirinden ayrışır. Zaman zaman operatörlerin de yardımıyla cüruf kanalı üzerinden farklı bir bölgeye alınan cüruf malzemesi su ile soğutulur, katı hale dönüştürülür ve malzeme stok sahasında depolanır. Bazı tesisler su püskürtmesi ile soğutma yöntemi dışında çökeltme havuzu yöntemini de kullanmaktadır. Çimento endüstrisinde önemli hammadde olarak kullanılan atık cüruf, böylece demir çelik tesisleri için ek bir gelir kaynağına dönüştürülmektedir.

Cüruftan ayrılan sıcak maden sırasıyla bir sonraki durağı olan kimyasal zenginleştirme, kükürt giderme ve çelikhane sahalarına götürülmek üzere torpido arabalarına boşaltılır. Torpido arabaları, içerisinde biriktirilen sıvı pik demirin ısı kaybını minimize etmek için refrakter tuğlalarla örülmüştür. Fırından deşarj edilen pik demirden belirli aralıklarla alınan numune örnekleri laboratuvar tesislerinde analiz edilmektedir.

Bu işlem neticesinde ortaya çıkan sıcak madenin kimyasal kompozisyonu, kimyasal zenginleştirme ve kükürt giderme tesislerinde kullanılacak kimyasalların oranı ve yüzdelerini belirlemektedir. Sıcak madenin bir sonraki durağı olan çelikhane tesisinde, torpido içerisindeki pik demir vinçler vasıtasıyla çelikhane potalarına alınır. Pik demir içerisinde kalan diğer artıkları giderebilmek için ince ve ısı dayanımlı bir lans vasıtasıyla pota içerisindeki sıcak madene oksijen üflenir ve böylece belirli kalite ölçütü sınırları içerisinde karbon çelik elde edilmiş olur.

2.1.2. Yüksek fırınlarda kullanılan hammaddeler

Yüksek fırın teknolojisi demir-çelik sektörünün kalbi konumundadır ve son yirmi yıldır, dünya çelik ihtiyacının %50-60 oranında yüksek fırınlardan karşılandığı görülmektedir. Kömür ve cevher miktarının yeterli olduğu, hurdanın yetersiz kaldığı ya da pahalı olduğu durumlarda, yüksek enerji tüketimine rağmen, yüksek fırın ile üretim kaçınılmazdır. Bu nedenle, üretim verimliliğini arttırırken, paralel olarak enerji maliyetlerini düşürebilmek için farklı enerji kaynakları ile sentezleme ve alternatif üretme çalışmaları gerçekleştirilmektedir. Yüksek fırınlarda kullanılan ana hammaddeler fırın üstünden şarj edilen kok, cevher, akışkanlık sağlayan ve cüruf yapıcı katılar ile tüyer bölgesinden üflenen sıcak hava olarak sıralanabilir.

Bununla birlikte sıvı, gaz ya da katı haldeki hidrokarbonlar ile oksijen yine tüyer bölgesinden fırın içerisine şarj edilmektedir. Proseste kullanılmakta olan demir oksitler genellikle hematit (Fe_2O_3) formunda olmakla beraber zaman zaman da magnetit (Fe_3O_4) malzemesinin kullanıldığı görülmektedir. Modern işletmelerde en yoğun kullanılan demir oksidi, sinter üretiminde kullanılmayan 0,05 milimetreden daha küçük çapta cevher tozlarının işlenmesi ile elde edilen, %5-10 arasında SiO_2 ve Al_2O_3 içeren, geriye kalan kısmı Fe_2O_3 olan 1-2 santimetre çapındaki pelet olarak karşımıza çıkmaktadır [33]. Cevher parçacıklarının sinter fırınlarında işlenmesi ile elde edilen ve 1-3 santimetre büyüklüğünde bir malzeme olan sinter ile 1-5 santimetre büyüklüğündeki cevher formundaki malzemeler diğer demirli malzemelerdir. Dönem dönem eser miktarlarda da olsa çelikhane cürufu ve hurda demirli malzemeler, fırınlara ek olarak şarj edilebilmektedir.

İçeriğinde %90 oranında karbon, %5-10 oranında rutubet ve %0,5-1 oranında kükürt içeren metalurjik kokun kül oranı %10-12 aralığındadır. Kok fırın prosesinde cevherin indirgenmesi ve ergitilmesi için gerekli olan ısı ve gazı büyük oranda temin eden kritik bir malzemedir. Metalurjik kok, çeşitli kalitelerdeki harmanlanmış kömür karışımının havasız bir ortamda ısıtılarak koklaştırılması ile elde edilmektedir. Bu proses kömürdeki uçucuların damıtılarak yüksek sıcaklıklarda tepkime veren ve parçalanmadan fırının alt bölgelerine kadar inebilen gözenekli kok yapısının oluşmasını sağlamaktadır [33].

Yüksek Fırınlarda kok hammaddesinin kritik işlevleri vardır. Bunlar, sıcak maden ve cürufun erime ve kızdırma sıcaklığının fiziksel olarak sağlanması, kimyasal reaksiyonların gereksinimi olan ısı enerjisinin sağlanması, demir oksitlerin indirgenmesi için indirgeyici gazların bir çoğunun sağlanmasına katkısı ve geçirgen bir yatak sağlayarak maden ve cürufun hazneye, sıcak gazların da fırın tepe bölgesine geçişini sağlaması olarak sıralanabilir. Dolayısı ile koktaki karbon miktarının olabildiğince fazla olması, kül, kükürt ve uçucu madde miktarının da olabildiğince düşük olması fırın ısı dengesi açısından çok önemlidir. Ayrıca kokun yeterli boyutta olması ve fırın geçişi boyunca kırılmaması için yeterli mukavemete sahip olması da büyük önem taşır.

Fırın prosesinde indirgenme ve ergime proseslerinde demirli malzemeler kok tarafından desteklenmektedir ve bu işlem için kokun yerini alabilecek başka bir malzeme bulunmamaktadır. Kok şarjı ile fırının alt bölgelerinde parçalar arası boşluklar meydana gelir ve bu durum fırının istikrarlı çalışmasına katkıda bulunur. Kok ayrıca fırın içerisindeki değişken atmosfer ve sıcaklığa karşı mekanik dayanım sağlar. Kokun kimyasal ve fiziksel özellikleri, fırın gövdesindeki geçirgenliği, ısı kayıplarını, hazne ve döküm şartlarını, sıcak madendeki silisyum miktarını, ısı tüketimini ve indirgenme verimliliğini doğrudan etkilemektedir. Verimli yüksek fırın çalışmasını etkileyen önemli bir kalite parametresi olan kokun rutubet miktarındaki %1 dolaylarındaki artış, 10 kg/ton kok veya 5 kg/TSM kok değerine eşdeğerdir.

Fırın tabanına kadar parçalanmadan inebilen yapıya sahip olan ve ortalama 2-8 cm. büyüklüğündeki kok parçalarının en önemli özelliklerinden birisi de yumuşayan ve ergiyen malzemelerin içerisinden düzenli bir gaz akışının sağlanmasına büyük katkı sağlamasıdır. Fırınlara için bir başka önemli hammadde olan cüruf yapıcılar (CaO ve MgO), kok ve cevherdeki silisyum oksit (SiO_2) ve alüminyum oksit (Al_2O_3) bileşenlerine akışkanlık kazandırarak akışkan cürufun ortaya çıkmasını ve yaklaşık 1300 °C'lerde düşük bir erime noktası oluşumunu tetikler. CaO malzemesinin bir başka faydası da kükürtün sıcak madenden ziyade cüruf içerisinde fırından çıkmasını sağlamasıdır. Bu maddeler sinter ile birlikte ya da 2-5 cm. büyüklüğünde parçalar halinde kireçtaşı (CaCO_3) ve dolomit (CaCO_3 ve MgCO_3), nadiren de çelikhane cürufu ile fırına şarj edilmektedir [33].

900-1300 °C'ler arasında ısıtılmış ve ortalama %25 oksijen oranına sahip zenginleştirilmiş sıcak hava, indirgeme reaksiyonları için kritik bir öneme sahiptir. Sıcak havanın fırına şarj edilmesi ile 1500 °C'ler civarında akkor hale gelen kok, fırın içerisine bir ısı kaynağı olarak katkı sağlar ve bu ısı nedeniyle indirgenme reaksiyonları, şarj edilen malzemenin ısıtılması ve eritilmesi, erimiş pikin sıcaklığının korunması için gerekli sıcaklığı sağlamaktadır. Katı, sıvı ve gaz halinde bulunan ve fırına tüyer bölgesinden deşarj edilen doğalgaz, katran, pulverize kömür ya da akaryakıt gibi hidrokarbonlar indirgenme prosesi için gerekli olan indirgeme gazlarının (CO ve H₂) miktarlarının artmasına katkıda bulunur [35].

Son dönemde yoğun olarak kullanılan pulvarize kömür enjeksiyonu, kok üretiminde kullanılması gereken yüksek kalite kömürün nispeten düşük kaliteli kömürlerin kullanılabilmesine olanak tanınması, fırın istikrarının yakalanması ve sıcak maden kalitesinin yükselmesine katkı sağlaması, sıcak madendeki silisyum oranının artması ve kükürt oranının azalmasına katkısı nedeniyle oldukça caziptir [40]. Pulvarize kömür enjeksiyon miktarının artırılması, kömürün yanması sonucu oluşan indirgeyici gaz miktarındaki artış ve pulvarize kömürün koka oranla daha az hacim kaplaması sonucu fırın faydalı hacminin artması nedeniyle, sıcak metal üretimi arttırmaktadır. Ancak, kömür enjeksiyonunun verimli bir şekilde kullanılabilmesi için yanma veriminin iyileştirilmesi ve prosese olan negatif etkilerinin alınacak önlemlerle bastırılması gerekmektedir [41].

2.1.3. Yüksek fırınlarda yardımcı sistemler

Yüksek fırınlara hizmet eden yardımcı sistemler temel olarak hammadde hazırlama ve besleme sistemi, hava ısıtma sistemi, sıcak maden ve cüruf deşarj sistemleri olarak sıralanabilir. Hammadde hazırlama ve besleme sistemi, fırınlara tepe bölgesinden şarj edilen malzemelerin fırın üstüne çıkartılmasını sağlayam sistemlerdir. Hammaddelerin depolandığı silo sistemi, yürüyen bantlar, ölçü hazneleri ve fırın tipine göre konveyör ve kova sistemi bu sistemin altyapısını oluşturur. Daha önceki sistemlerden fırın bölgesine konveyörlerle iletilen hammaddeler, fırın üretim kapasitesi ve malzeme cinsine bağlı olarak değişen ölçülerdeki silolarda depolanmaktadır. Silolardan elek vazifesi gören besleyeciler vasıtasıyla tartı haznelerine gelen hammaddeler, hassas

ölçüm sistemleri kullanılarak belirlenen oranlarda bantlar üzerinden kovalara dökülür. Kovalar, içerisindeki malzemeyi fırın tepesine çıkartan ve biri malzeme alırken diğeri de fırına hammadde şarj edecek şekilde paralel çalışan iki kritik ekipmandır. Günümüzde modern fırınlar kova sistemi yerine tartım haznelerinden sonra fırın tepesine kadar malzemeyi çıkartan konveyör bant sistemlerini kullanmaktadır.

Fırın üstü şarj sistemi, hammadde besleme sistemi tarafından fırın tepesine çıkarılan hammaddelerin fırına şarjı için kullanılan kritik ekipmanlardan oluşmaktadır. Daha önceki yıllarda büyük çan ve küçük çan olarak adlandırılan ve bunların eşgüdümlü olarak çalışması sonucu fırına malzeme şarjını sağlayan çanlı tepe sistemleri kullanılmaktayken, günümüzde genelde çansız sistem olarak adlandırılan teknoloji ile bu aktivite sürdürülmektedir. Çansız tepe sistemi filozofisine göre, fırın tepesinde birbirine paralel iki adet malzeme silosu bulunmaktadır. Bu siloların üstünde ve altında, basınç eşitleme ve malzeme şarj hızlarını kontrol etmeye yarayan çeşitli vanaların çalışması ile hammaddeler fırın içerisine iletilmektedir ve fırın içerisnde bulunan döner oluk sayesinde malzeme şarj açısı ayarlanabilmektedir.

Fırın tepesindeki hammadde silolarına alınan malzemelerin fırın içerisine şarj edilmesi iki aşamada gerçekleşmektedir. Bu aşamalardan ilki, izolasyon vanasının açılması ile fırın iç basıncı ile silo basıncının birbirine eşitlenmesidir, ikinci aşamada ise malzeme fırın içerisine boşaltılır. Basınç eşitleme işleminin temel amacı, daha sonra yakıt olarak kullanılacak olan yüksek fırın gazının atmosfere kaçmasını engellemek, enerji tasarrufu sağlamak ve tepe basıncını koruyarak verimliliği arttırmaktır [34]. Malzeme fırın içerisine döner oluk vasıtasıyla üst üste halkalar şeklinde ve olabildiğince düzgün bir geometride boşaltılmalıdır. Malzeme dağılımının düzenli bir yapıda olması fırının çalışmasını da olumlu yönde etkilemektedir [33].

Yüksek fırın tepesinde sıcak ve kirli gazın geçiş yaptığı genellikle dört adet gaz çıkış borusu bulunmaktadır. Bu borular fırının tepe noktasında birbiriyle birleşerek kirli gaz ana borusunu oluşturur ve fırının hemen yanında bulunan toz tutucu üniteye bağlanır. Gaz çıkış borularının birleştiği bölgede fırın iç basıncının aniden yükselmesi halinde açarak fazla basıncın atmosfere tahliyesini sağlayan ve mekanik olarak çalışan güvenlik vanaları bulunmaktadır. Toz tutucuya gelen sıcak ve kirli gaz içerisindeki

kaba parçacıklar tutulur ve biriktirilir. Gaz bir sonraki aşama olan yıkayıcı sistemine geldiğinde soğutulmuş ve ikincil bir temizleme işlemine tabi tutulur. Bu işlem yıkayıcılarda kapalı bir düzenden geçen basınçlı gazın üzerine püskürtülen su ile gerçekleştirilmektedir. Bünyesindeki küçük parçacıklardan da arınan ve temizlenen yüksek fırın gazı, kurutma prosesi sonrasında enerji kaynağı olarak kullanılmak üzere gazometrelerde toplanır.

Fırın prosesi için bir başka önemli yardımcı sistem olan sobalar, fırın içerisindeki kokun uygun bir şekilde yanmasını sağlamak ve malzemeyi askıda tutmak için kullanılan basınçlı havanın ısıtıldığı kritik yardımcı sistemlerdir. Fırınlarda genel olarak sistemin büyüklüğü ve çalışma prensibine bağlı olarak üç ya da dört adet soba bulunur. Her bir soba, yanma ve ısınma hücresi olarak iki bölümden oluşmaktadır [33]. Bir sobanın ısınma, bekleme ve fırın devresi olmak üzere üç durumu vardır. Isınma devresindeki soba, yakma havası fanlarından gelen hava ile gaz sisteminden gelen kok gazı, yüksek fırın gazı, çelikhane gazı ya da doğalgaz karışımının reaksiyona girmesi sayesinde belirli bir süre boyunca yanma hücresinde ısıtılır.

Yanma sonucu ortaya çıkan atık gazlar vanalar sayesinde bacadan dışarı atılır. Sobalar yüksek sıcaklıklara dayanımlı ve ısınma hücresini tamamen kaplayan delikli tuğlalar ile kaplanmıştır. Bekleme devresindeki soba, ısınma süresini tamamlamış ve çıkış vanalarının kapatılması ile içerisinde yoğun ısı enerjisi barındırır pozisyondadır ve fırın devresine girmek için sırasını beklemektedir. Fırın devresinde, fırına gönderilecek havanın ısınma hücresinden geçirilerek tuğlalarda haspedilmiş olan ısıyı bünyesine alması sağlanır. Fırın devresinde belirli bir süreyi dolduran ya da sıcaklığı limitlerin altına düşen soba bekleme ya da ısınma moduna alınırken bir sonraki soba da otomatik olarak fırın devresi moduna alınır. Genelde sobalardan birisi fırın devresindeyken diğerleri de ya ısınma ya da bekleme modunda tutulmaktadır, ancak bazı fırınlarda ihtiyaca binaen aynı anda iki soba fırın modunda da tutulabilmektedir.

Fırınlarda tüyer bölgesinden fırın içerisine hidrokarbon ilavesi sağlayan üniteler, fırın verimliliğine katkıda bulunan bir diğer önemli yardımcı sistemlerdir. Daha önceki yıllarda yüksek maliyetli kok tüketimini azaltıcı ve fırın şartlarını düzenleyici katran ve fuel oil gibi sıvılar kullanılsa da petrol fiyatlarındaki artışlar nedeniyle oluşan


maliyetler bu yakıtların kullanımında olumsuz sonuçlar doğurmuştur. Alternatif olarak tozlaştırılmış pulverize kömür enjeksiyon sistemleri zamanla daha popüler bir şekilde kullanılmaya başlanmıştır. Günümüzde, kömür enjeksiyon tesislerinde öğütülerek, çapı 75 mikronun altındaki parçacıklara indirgenen pulverize kömüre ilave olarak yine tüyer bölgesinden fırına şarj edilen doğalgaz enjeksiyonu da yoğun bir şekilde kullanılmaktadır.

Yüksek fırınlardaki kimyasal reaksiyonlar sonucu ortaya çıkan sıcaklıklar, fırın gövdesindeki bazı bölgelerde 2200-2400 °C'ler mertebesine çıkabilmektedir. Fırın tepesinde ise şarj sisteminin maruz kaldığı sıcaklık ortalama 150-200 °C'ler mertebesindedir ve dolayısı ile özellikle fırın gövdesi boyunca bir soğutma sistemine ihtiyaç duyulmaktadır. Fırın içi genellikle karbon, grafit ve silisyum karbür esaslı refrakter tuğla ile örülerek yüksek sıcaklıklara direnç gösterecek bir yapıya kavuşturulur. Bu tuğlaların ömrünü arttırabilmek için genellikle bakırdan imal edilen plaka ya da panel soğutuculardan su sirkülasyonu sağlayarak soğutma işlemi gerçekleştirilir. Soğutma suyu kanallı bir yapıya sahip olan bu soğutucu bölgesinden girerek tüm soğutucuyu dolaşır ve geri çıkar.

Üretilen sıcak maden ve cürufun yüksek fırın içerisinden alındığı bölge dökümhane olarak adlandırılmaktadır. Fırınlara kapasitesine göre kullanılan dökümhane sayısı bir ile dört arasında değişebilmektedir. Sıcak maden ve cürufun tahliyesi için kullanılan döküm ve cüruf delikleri fırın haznesinin alt kısmında bulunmaktadır [33]. Döküm delikleri sürekli olarak açılırken cüruf deliği ihtiyaç halinde açılmaktadır. Döküm deliğinden hem sıcak maden hem de cüruf birlikte çıkartılmaktadır. Döküm açma matkabı vasıtasıyla açılan döküm deliği belirli bir süre açık kalır ve sonrasında çamur topu vasıtasıyla özel bir çamur enjekte edilerek döküm deliği kapatılır.

Döküm deliğinden dışarıya doğru akan sıcak maden ve cüruf, üzerinde refrakter tuğlalar bulunan ısı dayanımlı döküm kanalı boyunca iletilir. Cüruf ile sıcak maden, özgül ağırlık farkı nedeniyle döküm kanalı üzerinde gerçekleştirilen manevralar yardımıyla birbirinden ayrıştırılır ve sıcak maden çelikhaneye götürülmek üzere torpido adı verilen araçlara doldurulur. Cüruf kanalı vasıtasıyla cüruf sahasına ya da su havuzuna alınarak soğutulan cüruf, özellikle çimento sektörü için hammadde olarak

kullanılmaktadır. Yüksek fırınlarda kullanılan hammadde hazırlama, şarj sistemi, dökümhane, gaz temizleme ve sobalar sistemine ait genel görünüş Şekil 2.5'te gösterilmektedir.



Şekil 2.5. Yüksek fırın yardımcı tesislerinin görünümü [35]

2.1.4. Yüksek fırınlarda reaksiyonlar ve sıcak maden üretimi

Yüksek Fırınlarda proses temel olarak iki önemli fonksiyonu içermektedir. Bunlardan birincisi, demirli hammadde girdisinde demir ile birleşik halde bulunan oksijenin ayrıştırılmasıdır. Bunun için ilk olarak, demir oksitlerinin karbon monoksit, karbon dioksit ve metalik demir oluşturacak şekilde, kok içerisinde bulunan karbon ile kimyasal reaksiyonları gerekmektedir [41]. Bu işlemle beraber ikincil olarak, cevher ve kok külü hammaddelerinin içerisinde bulunan artık maddelerin kimyasal reaksiyonlar nedeniyle birleşerek oluşturduğu cüruf malzemesini, üretilen sıcak madenden ayrıştırılması gerekmektedir. Sıcak maden ve cüruf arasındaki yoğunluk farkı, bu iki malzemenin fırın çıkışında birbirlerine karışmadan ayrıştırılmasını sağlamaktadır.

Yüksek fırın çalışması karmaşık ve birçok faktöre bağlı olarak değişken olduğu için, çalışma parametrelerinde herhangi bir değişiklik olmamasına rağmen fırın performansı ani olarak değişebilir. Bu nedenle işletme grubuna bağlı operatörlerin

prosesi sürekli ve dikkatli bir şekilde takip etmesi gerekmektedir. Yüksek fırın şarj malzemeleri içerisinde en kritik ve pahalı hammadde girdilerinden biri olan kok, fırın çalışması ve pik maden üretimine etkisi bakımından en önemli malzemedir.

Her fırında kullanılan kok hammaddesinin fiziksel ve kimsayal özellikleri fırının çalışma şartlarını, kullanılan yakıt oranlarını, fırının verimliliğini ve pik maden kalitesini direk olarak etkiler. Malzeme silolardaki hammaddeler işletme şartlarına göre belirli oran ve sıklıklarda fırına şarj edilir. Malzemeler fırın prosesi boyunca birtakım kimsayal reaksiyonlara girerek fırın haznesinden sıcak maden ve cüruf olarak çıkmaktadır. Demir cevheri, pelet, sinter ve kireçtaşı bünyesinde bulunan oksijen, fırın içerisindeki seri reaksiyonlar sonrasında ayrıştırılır [34]. Bu reaksiyonlar ile başladıkları sıcaklıklar şu şekilde gösterilmektedir:



veya




Bu reaksiyonlarla beraber demir oksit saflaştırma reaksiyonundan da geçmektedir. Fırına şarj edilen malzemeler, fırın tepesinde fırını terketmekte olan gazın sıcaklığının yardımı ile bünyesindeki rutubetten kurtulur. Daha sonra fırın gövesinin ortalarında malzemelerde bir yumuşama durumu yaşanır ve daha alt bölgelerde ise nihai ürün olan sıcak maden ve cüruf açığa çıkar [33]. Denklem (2.1), (2.2), (2.3)'teki reaksiyonlarda demirli malzemelerin indirgenmesinde karbonmonoksit gazının kullanıldığı görülmektedir. Öncelikle tüyerlerden fırın içerisine üflenen sıcak havanın fırına şarj edilen kok kömürü ile reaksiyonu sonrasında karbondioksit gazı ortaya çıkar:



Karbondioksit gazı daha sonra bünyesinde yüksek ısı barındıran karbon ile tepkimeye girmektedir ve böylece karbonmonoksit gazı ortaya çıkmış olur:



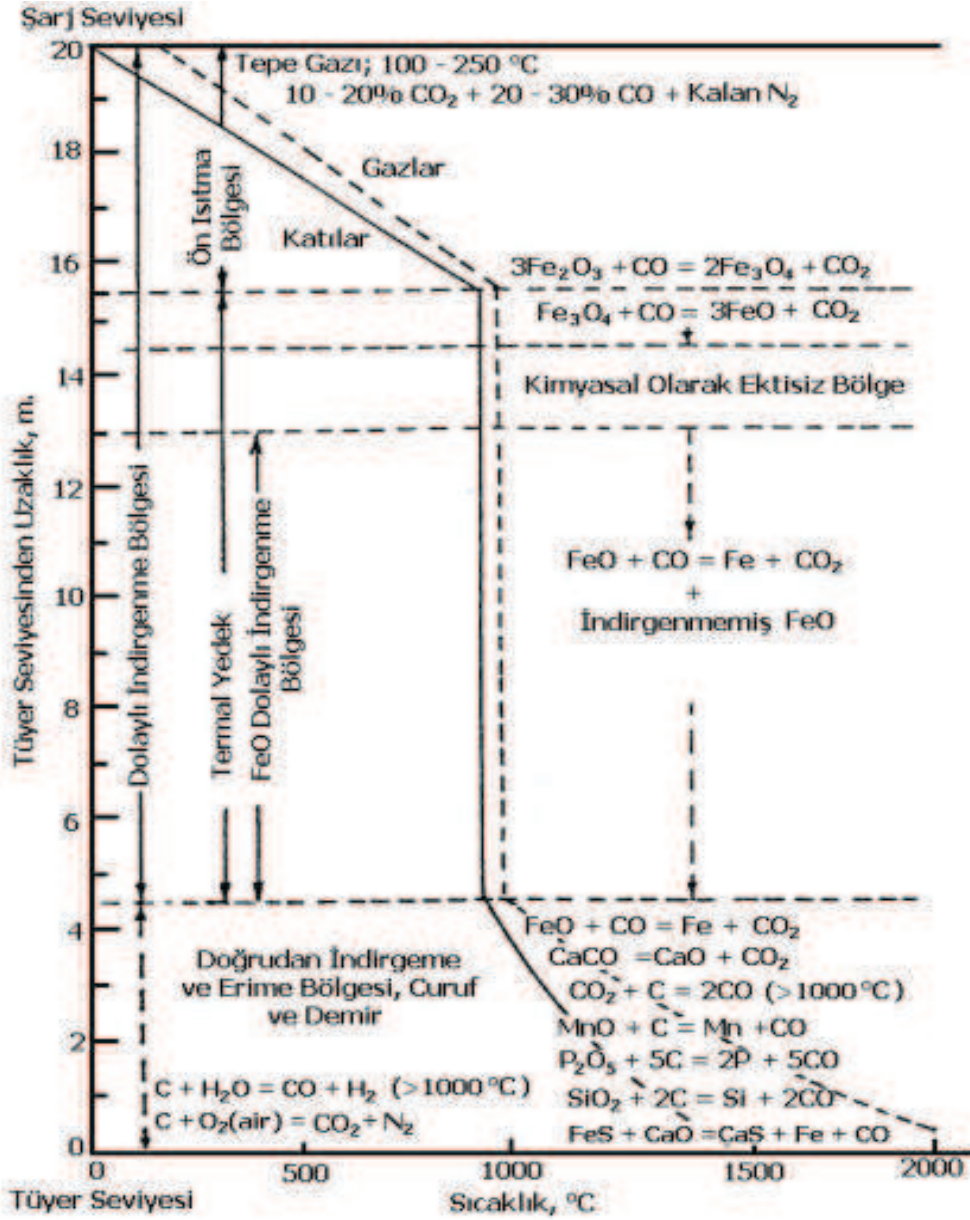
Bu kimyasal reaksiyon sonucu ortaya çıkan CO gazı, (2.1), (2.2) ve (2.3) reaksiyonlarında demirli malzemelerle tepkimeye girer ve demir ile oksijenin ayrışmasını sağlar [33]. Fırına şarj edilen hammaddelerden olan kireçtaşı özellikle kükürdün sıcak maden içerisinde birikmemesi için önemli bir görev ifa etmektedir:



Kireçtaşı bileşiminde yoğun olarak buluna kalsiyum karbonatın 870 °C mertebelerinde ısı almasıyla başlayan tepkimeler sonucunda kireçtasından CaO elde edilir ve reaksiyonlar sonucu ortaya çıkan sıcak maden hazneye inmeden önce CaO ile reaksiyona girerek madendeki kükürt ayrıştırılmış olur:



Bu tepkimeler sonucu ayrışan CaS cüruf olarak malzemeler arasından süzülerek hazne bölgesine inmektedir. Fırın prosesi sırasında ortamda bulunan gazlar kirli yüksek fırın gazı olarak tepe bölgesine doğru hareket ederken, reaksiyona girmeyen CO, CO₂, H₂, N₂, vb. gibi gazları da bünyesine katar [34]. Gaz tepe bölgesindeki uptake ismi verilen boru hattı vasıtasıyla tozdan arındırılacağı ve soğutulacağı yardımcı ünitelere iletilmektedir. Temizlenen gaz, daha sonra fabrikanın değişik ünitelerinde tekrar kullanılmak üzere gazometrelerde depo edilmektedir. Yüksek fırın prosesinde kimyasal tepkime bölgelerinin sıcaklık bölgeleri ve tüyer seviyesine uzaklıklarına göre gösterimi Şekil 2.6'da belirtilmektedir.



Şekil 2.6. Yüksek fırınlardaki kimyasal reaksiyon bölgeleri [33]

2.1.5. Sıcak maden kalite ölçütleri ve alev sıcaklığı

Pik demirin kalitesini belirleyen iki ana unsur, sıcak maden içerisindeki silikon miktarı ve sıcak maden sıcaklığı olarak sıralanmaktadır [41]. Silikon sıcak madene hammadde olarak kullanılan kok külü ve demir cevheri üzerinden geçmektedir. Sıcak maden içerisindeki silikon miktarı, kalite standartları gereği %0,3-0,9 aralığında bulunmalıdır. Fırın için yüksek sıcaklık bölgelerinde, silikaların bir kısmı çözünmektedir ve silikon molekülü halinde ergimiş maden içerisine nüfuz etmektedir. Sıcak maden içerisinde beklenenin üzerinde silikon bulunursa, fırın istenen verimde

çalışmıyordur denilmektedir. Diğer bir verimlilik ölçütü olan sıcak maden sıcaklığı ise, aynı fırın içi çalışma şartları altında pik demir içerisinde bulunan silikon miktarına paralel olarak artmakta ya da azalmaktadır.

Fırınlarda verimliliğini tarif etmekte olan en önemli kriterlerin başında, fırının birim faydalı hacmi başına düşen pik demir üretimi (m^3/TSM) gösterilmektedir ve bu değer fırınları karakterize eden önemli bir ölçüttür. Yüksek fırın verimliliğini arttıran en önemli etken, kimyasal reaksiyonları hızlandıran girdi oksijen miktarının arttırılması ile sağlanır. Girdi oksijen miktarı ya ilave oksijen enjeksiyonu ile ya da sıcak hava sıcaklığının arttırılması ile arttırılabilir. Kömürün yanması sonucu oluşan indirgeyici gaz miktarındaki artış, daha fazla cevherin ergitilmesine, oksijen zenginleştirilmesi karşılığında pulvarize kömür enjeksiyonunun miktarının arttırılması da fırının faydalı hacminin artması anlamına gelir. Böylelikle üretimde verimlilik optimizasyonu yapılarak üretim artışı gözlenmiş olur.

Sıcak metalin kalitesini belirleyen ölçütlerden olan sıcak maden içerisindeki % Kükürt ve % Silikon miktarı, hammadde girdilerin içeriği ile orantılı olarak değişmektedir. Kükürt, yüksek fırın girdilerinden kokun içerisinde oransal olarak daha yüksek bir miktarda bulunur. Kükürt oranını düşürmenin en etkili yolu, kok yerine içerisinde daha az yoğunluklu kükürt bulunan pulvarize kömürün kullanılması ile sağlanır. Ayrıca kömür enjeksiyon miktarının arttırılması sıcak maden sıcaklığının artmasına yol açmaktadır. Bunun başlıca nedeni ise koka göre reaktivitesi daha yüksek olan pulvarize kömürün, doğrudan yüksek sıcaklık bölgesine enjekte edilerek fırının termal kapasitesinin arttırılması ile açıklanmaktadır [41].

Ancak kömür enjeksiyonunun düzenli bir şekilde uygulanabilmesi için fırının genel yanma verimliliğinin uygun seviyelerde tutulması gerekmektedir. Sıcak maden sıcaklığındaki artış, fırında yüksek ısı potansiyelinin oluşmasına imkan tanır, daha fazla kükürt cürufa geçer ve sıcak maden içerisindeki % Kükürt oranı düşmüş olur. Aynı şekilde sıcak maden sıcaklığı artma eğilimine girdiğinde, ergime bölgesi ve haznedeki yüksek ısı potansiyelinin artmasıyla beraber cüruf yapısında bulunan SiO_2 'nin yüksek sıcaklıktaki deadman (ölü bölge) kokunun gözenekleri arasında

süzülürken kokun karbonu ile reaksiyona girmesi ve indirgenerek silise ayrışması sonucunda sıcak metaldeki % Silis miktarının artmış olur [41].

Yüksek Fırınların kontrol ve optimum işletimi açısından kullanılmakta olan bir başka verimlilik göstergesi de alev sıcaklığı parametresidir. Kararlı ve dengeli bir fırın prosesinin yürütülebilmesi için alev sıcaklığı değerinin stabil ve optimum seviyelerde olması büyük önem arz etmektedir. Alev sıcaklığı, değişik tesislerde değişik şekillerde nümerik olarak hesaplanan ve kullanılan bir parametredir. Alev sıcaklığının belirli bir operasyon bandında tutulması özellikle yakıt oranlarının uygun bir şekilde ayarlanabilmesi ve kontrolü için büyük önem arz etmektedir. Alev sıcaklığı değeri, pulverize kömür enjeksiyonu, ilave buhar enjeksiyonu, oksijen zenginleştirme değeri, sıcak hava sıcaklığı, sıcak hava miktarı, sıcak hava basıncı ile sobaların ısıtılmasında kullanılan kok gazı ve yüksek fırın gazının dengeli bir şekilde ayarlanabilmesi açısından çok önemli bir göstergedir.

Fırın gövdesindeki gerçek ısı, alev sıcaklığı değerinin hesaplanmasında bazı ısı kayıplarının ihmal edilmesi nedeniyle daha yüksektir ve bazen hesaplanan sıcaklık değerleri öngörülere dayandığı için de gerçekçi olmayabilir. Ancak operatörler için temel bir referans değeri ve diğer fırın parametrelerini dengede tutmaya yarayan çok önemli bir gösterge olduğu için kritik bir parametredir. Optimum alev sıcaklığının yakalanması fırının dengeli, düzenli, gürbüz ve sürekli operasyonu için büyük önem taşır. Eğer alev sıcaklığı normal fırın operasyonu sırasında belirli bir azalma trendine girerse, bu ergime kapasitesinin ve ingirgeme işleminin yavaşladığını gösterir. Aynı zamanda bu fırın ısı dengesinin zayıflaması anlamına gelmektedir. Eğer alev sıcaklığı değerinde sürekli artma ve azalma şeklinde bir dalgalanma oluyorsa, bu durumda yumuşama ve ergime bölgesinin istikrar ve kararlılığını kaybettiği görülür. Eğer alev sıcaklığı değeri artış trendine girdiyse de, ergime kapasitesinin özellikle tüyer bölgesinde bir artış trendine girdiği anlaşılır.

Pulvarize kömür enjeksiyonunun artırılması alev sıcaklığını ve tüyer önü ergitme kapasitesini düşürmektedir. Kömür enjeksiyon miktarının arttırıldığı durumlarda alev sıcaklığının düşmesini engelleyebilmek ve dengeleyebilmek için fırına giren sıcak hava sıcaklığının ve ilave oksijen oranının arttırılması, sıcak hava rutubeti değerinin

de azaltılması gerekmektedir. Böylece tüyer önündeki oksijen konsantrasyonu ve kömürün yanma reaksiyon hızı da artmış olur ve oksijen miktarındaki bu artış nedeniyle kimyasal reaksiyonların sonucu olarak açığa çıkan CO miktarında da artış meydana gelir [33].

CO miktarındaki artış ise demir cevheri olarak kullanılan hematitin (Fe_2O_3) indirgenme oranını arttırır, dolayısı ile alev sıcaklığını sabit tutulur, demirin indirgenmesinde kullanılan kok miktarının azaltıldığı için de fırın verimliliğinin artmasına yol açmaktadır [41]. Tüm bu olasılıklara karşı alınacak düzeltici aksiyonlar, alev sıcaklığının anlık takibi, bu sıcaklığı etkileyen faktörlerin doğru olarak tespiti ve kontrolünün gerçekleştirilmesine bağlıdır. Kömür fırına şarj edildikten sonra tüyer önüne girmeye başladığında ortamın ısısını üzerine alır ve böylelikle alev sıcaklığı düşer. Bu olay ergime kapasitesinin azalmasına neden olur. Alev sıcaklığının düşmesine izin vermemek için sıcak hava sıcaklığı arttırılır ve bu işlem sonucu kömürün yanma reaksiyonu arttırılarak kömür yanma verimi arttırılmış olur.

Kömür enjeksiyonunun yapıldığı durumlarda, cevher/kok oranında artış, tüyer alev sıcaklığında düşüş, fırın duvarında ısı kaybı, merkezi gaz geçirgenliğinde zayıflama, ölü bölge kok aktivitesinde bozulma, tüyer seviyesi ve fırın içi basınçta artış ve anma şartlarının bozulması gibi olumsuzluklar ortaya çıkabilmektedir [41]. Ancak bununla birlikte maliyeti daha düşük olan pulvarize kömürün yüksek fırına enjekte edilmesi ile fırın proses şartları olabildiğince bozulmadan, kullanılan kok miktarının azaltılması ve yakıt tasarrufunun sağlanması mümkündür. Pulvarize kömür enjeksiyonu, sadece kararlı bir fırın prosesi elde edilmesinde ve sıcak maden kalitesinin artırılmasında önemli bir rol oynamakla kalmaz, bununla birlikte proses kolaylığı ve işletme şartlarındaki olumsuzluklara ani müdahale şansı da tanımaktadır.

2.2. Enerji Kaynakları ve Enerji Üretimine Bakış

20. yüzyıl başlarından itibaren hızla gelişen teknoloji ve sanayileşmenin bir sonucu olarak elektrik enerjisine olan talep sürekli bir artış içerisinde. Dünya nüfusundaki ve bireysel teknoloji kullanımındaki artışlar da kişi başına enerji tüketimini tetiklemektedir. Bununla birlikte enerjinin verimli ve tasarruflu kullanılmaması da

mevcut enerji kaynaklarının hızla tüketilmesine neden olmaktadır. Ülkelerin enerji ihtiyacı, nüfus, sosyal ve ekonomik gelişme düzeyi, sanayileşme, teknolojik gelişmişlik ve kentleşme gibi pekçok sosyo-ekonomik faktörle ilintili olarak şekillendiği için, elektrik enerjisi arzının kaliteli, yeterli miktarda, zamanında, ekonomik şartlar ve çevre etkileri de dikkate alınarak temini büyük önem taşımaktadır.

Elektrik enerjisi günlük insan hayatı ve sanayi için vazgeçilmez bir fenomendir. Günümüzde enerji üretimi nükleer, termik, jeotermal, hidroelektrik, biyoyakıt ve solar enerji gibi değişik avantaj ve dezavantajlara sahip çok farklı tipteki santrallerde gerçekleştirilmektedir. Türkiye'deki kurulu güç, yaklaşık %89,3 oranında ülkenin en büyük enerji kaynağı yerli kömür ve dışarıdan ithal edilen doğalgazın kullanıldığı santrallerde gerçekleştirilen üretime dayanmaktadır. Toplam üretim maliyeti, enerji santralleri için verimlik anlamında çözülmesi gereken önemli bir kısıt ve ciddi bir optimizasyon problemidir ve bu en uygun çözümü üretebilmek için hammadde, yakıt fiyatları, emisyon değerleri, işletme giderleri ve sistemin termodinamik ısı dengesi gibi teknik, ekonomik, çevresel etkiler gözönünde bulundurulmalıdır.

Son yıllarda meydana gelen teknolojik devrimler, elektrik enerjisi üretim çeşitliliğini arttırmaktadır ve bu yeni süreçler kalite, verimlilik, üretim maliyetleri anlamında sürekli artan iyileştirme ve gelişmelerden olumlu olarak etkilenmektedir. Bir enerji santrali işletmesi temel olarak; tesisin verimliliğinin mümkün olduğunca yükseltebilmek, kabul edilebilir NO_x, SO_x ve CO₂ oranlarını yakalayarak optimum yanma sağlayabilmek, termal ısı kararlılığı ve verimini arttırabilmek ve üretim maliyetlerini olabildiğince düşük tutabilmek için gereken işletme şartlarını sağlamayı amaç edinmektedir.

Proses açısından bakıldığında, kritik ve çok hassas bir yapıya sahip olan enerji santrallerinde, çok çeşitli sıcaklık, basınç, seviye, akış, emisyon, vibrasyon ölçümleri ve su çevrimi dengesi, buhar, yakıt ve hammadde oranları anlık olarak üst seviyeli otomasyon sistemleri kullanılarak kontrol altında tutulmalıdır. Bununla birlikte geçmişe dönük tüm veriler kayıt edilerek, takip altında tutulmalıdır.

Enerji piyasalarındaki global gelişmelerin özellikle enerji kaynakları ile çevre ilişkisinin önemini giderek arttırması, Türkiye gibi fosil yakıt kaynakları dünyadaki diğer rezervlere göre daha sınırlı olan ülkelerde dışa bağımlılığı daha da arttırmaktadır. Bu nedenle yenilenebilir enerji kaynakları ile nükleer enerji gibi alternatif enerji politikalarının geliştirilmesi büyük önem arz etmektedir. Ülkemizde gerçekleştirilen elektrik üretimi yaklaşık %45 oranında yerli kaynaklardan, %55 oranında ise ithal kaynaklardan karşılanmaktadır. Bu oranlar, son dönemde her ne kadar önemli yatırımlar yapılıyor olsa da, enerjide büyük bir dışa bağımlılığın olduğunu göstermektedir.

Tablo 2.1’de de gösterildiği gibi, 2010 yılında 109,27 milyon ton petrol eşdeğeri (milyon tep) civarındaki yıllık enerji arzı, bir önceki yıla nazaran yaklaşık %3’lük bir artışa tekabül etmektedir. Planlama çalışmalarına göre, 2015 yılında bu oranın 170 milyon ton petrol eşdeğeri (milyon tep), 2020 yılında ise 222 milyon ton petrol eşdeğeri (milyon tep) düzeyine ulaşacağı beklenmektedir. Enerji arzında %31,9 ile doğalgaz en büyük payı alırken, %30,7 ile kömür, %26,7 ile petrol, geri kalan %10,7’lik bölüm ise hidrolik başta olmak üzere yenilenebilir ve diğer kaynaklardan karşılanmıştır. Bir önceki sene ile karşılaştırıldığında, 2010 yılında doğalgazın kömürün yerini alarak enerji arzında birinci sıraya yükseldiği görülmektedir.

Son dönemde, sanayi sektörünün temel girdilerinden olan enerji sektöründeki bu büyüme rakamları, gelişmiş ülkelere kıyasla oldukça yüksektir. Sanayileşme sürecindeki ülkelere biri olan Türkiye’nin son 10 senede doğalgaz ve elektrik tüketimindeki artış oranlarına bakıldığında Avrupa’da ilk, dünyada ise Çin’den sonra ikinci sırayı almaktadır. 2010 itibariyle ortalama 74 milyonluk bir nüfusa sahip olan ülkemizde, kişi başına enerji tüketiminin %8,56 oranındaki bir artışla 2347 kWh olduğu hesaplanmaktadır. Yakıt arzı, üretim maliyetleri ve enerji fiyatlarındaki değişimler, gerçekleştirilen fizibilite çalışmaları için önemli bir veri kaynağıdır ve ileride kurulması planlanan santraller için kritik bir öneme sahiptir.

Tablo 2.1. Ülkemizin birincil enerji arzı [42]

KAYNAKLAR	2008	2009	2010	2011
Taşkömürü (Bin Ton)	2.601	2.863	2.524	2.528
Linyit (Bin Ton)	76.171	75.577	69.698	72.550
Asfaltit (Bin Ton)	630	1.058	1.177	900
Petrol (Bin Ton)	2.160	2.237	2.544	2.433
Doğalgaz (10 ⁶ m ³)	1.017	685	682	790
Hidrolik ve Jeotermal Elektrik (GWh)	33.432	36.395	52.464	53.033
Jeotermal Isı (Bin Tep)	1.011	1.250	1.391	694
Rüzgar (GWh)	847	1.495	2.916	4.724
Güneş (Bin Tep)	420	429	432	630
Odun (Bin Ton)	12.264	11.766	11.306	8.154
Hayvan ve Bitki Artıkları (Bin Ton)	4.883	4.862	4.960	4.745
Biyoyakıt (Bin Ton)	20	10	14	20
Toplam (Bin Tep)	29.209	30.328	32.493	32.229

Fosil enerji kaynakları bakımından fakir bir konumda bulunan ülkemizde enerjide dışa bağımlılığı azaltmak ve ekonomik olarak fayda sağlamak için alternatif ve yenilenebilir enerji kaynaklarına olan talep artmaktadır. Ülke coğrafyası özellikle

hidroelektrik, rüzgar ve güneş kaynakları bakımından yüksek bir potansiyele sahiptir. Ancak yatırım maliyetleri ve işletme zorlukları nedeniyle bu tesislerin zaman içerisinde daha etkin olarak ülkeye katkı sağlayacağı düşünülmektedir. Türkiye’de şu anda olduğu gibi en azından yakın gelecekte de fosil kaynaklı üretim tesisleri vasıtasıyla elektrik üretimlerine devam edileceği gözlemlenmektedir. Petrol, kömür ve doğalgaz rezervlerimiz göz önüne alındığında, ülke kaynaklarının verimli kullanılması gerekmektedir ve kullanılan enerjinin belirli oranlarda geri dönüşümünün sağlanması ile ekonomik ve çevresel fayda sağlanabilir. İnsanoğlunun daha kaliteli bir yaşam sürdürebilmesi için enerji tasarrufu ve verimliliği ile çevreye uyum kavramları oldukça önemli bir hal almaktadır.

Kavram olarak enerji, termodinamik bir sistemin iş ve ısı verme kabiliyeti olarak tanımlanmaktadır [43]. Yani ısı ve iş almakta olan bir sistemin enerjisi artmaktadır, dolayısı ile bu tanımdan enerjisi yüksek bir sistemden ısı ve iş gücünün alınabileceği görülmektedir. Isı ve iş arasında bir benzerlik ve geçişlilik bağıntısı bulunur. Enerji sistemlerinin daha yüksek verimlilikte çalışabilmesi için gerçekleştirilen çalışmalar genel olarak termodinamiğin birinci yasasına dayanan enerji analizi kavramı ile açıklanabilir. Bu kanuna göre, enerji korunur, bir şekilden diğerine dönüşebilir ancak yok edilemez.

Dolayısı ile bir enerji çevriminde ısı ve iş alışverişinin birbiri ile orantılı olması zorunludur. Bu kanun nicelik açısından bir fikir verirken, termodinamiğin ikinci yasasına dayanan ekserji analizi, enerjinin hem niceliği hem de niteliği dikkate alınarak gerçekleştirilir. Bir kaynağın iş yapabilme potansiyeli olarak tanımlanan ekserji, enerji kaynağının ne kadarının yararlı işe dönüştürülebileceği sorusuna cevap bulmaktadır. Güç üreten tüm sistemlerin termodinamik analizleri yapılırken enerji ve ekserji analizinin birlikte gerçekleştirilmesi, analizlerin hassasiyetini ve doğruluğunu arttıracaktır.

Termik santrallerde, kullanılan yakıt cinsi ve sistemin temel çalışma prensipleri göz önüne alındığında, termodinamik analizlerin yapılması oldukça önemlidir. Gerçekleştirilecek enerji ve ekserji analiz sonuçları ile santrallerin sistem performansı ve verimlilikleri değerlendirilebilir. Ancak termodinamik analiz belli aşamaları

içermeli ve belli bir sıra ile yapılmalıdır, bununla birlikte hangi ünitelerde modelleme çalışması gerçekleştirilecekse sistem sınırlarının dikkatlice çizilmesi gerekmektedir. Santralde mevcut bölümler ve sistemin tamamı için ısı dönüşüm sistemleri belirlenmeli ve kütle, enerji, entropi denge durumları gözönünde bulundurulmalıdır. Çalışmalarda santralin kurulu olduğu bölgedeki iklim ve çevre koşulları da unutulmamalıdır. Analiz sonuçları sonucunda ortaya çıkan değerlere istinaden yapılabilecek iyileştirme ve düzenlemeler hakkında değişik öneriler sunulabilir.

Termik santraller, prensip olarak buhar gücü ile çalışan güç santralleridir. Kazanda yakıtın yanması sonucu elde edilen ısı, suya transfer edilir ve elde edilen kızgın buhar buhar türbini kanatçıklarını çevirir. Kanatçıkların bağlı olduğu türbin mili dönmeye başlar ve belli bir devire ulaşıldığında mile bağlı jeneratör sayesinde elektrik enerjisi üretilmeye başlanmış olur. Termik santrallerde elektrik üretimi süreci belirli aşamalarda gerçekleşen enerji dönüşümleri ile sağlanmaktadır. Temel olarak bu dönüşümler, ilk olarak kimyasal enerjinin ısı enerjisine, daha sonra da ısı enerjisinin mekanik enerjiye ve son olarak da mekanik enerjinin elektrik enerjisine dönüştürülmesi şeklindedir. Bir termik santralin yardımcı üniteleri ile birlikte genel görünümü Şekil 2.7’de verilmektedir.



Şekil 2.7. Bir termik santralin fiziksel görünümü

2.2.1. Kömür yakıtlı termik enerji santralleri

Kömür yakıtlı termal enerji santralleri temel olarak, fosil yakıtlı enerji kaynaklarının kullanılması ile çalışan enerji üretim tesisleri olarak sınıflandırılmaktadır. Bu tesislerdeki temel çalışma prensibi, su ile kızgın buhar arasındaki dönüşüm ve döngüye dayanmaktadır [13]. Kömürle çalışan kazanlarda sıvı fazdan gas fazına geçen, yani buharlaşan, su türbin bölgesindeki jeneratörlerin aynı hat üzerinde bulunduğu şaftı döndürerek elektrik üretimini sağlamaktadır. Termik santrallerin ana hammaddesi olan kömür, hem kazan dizaynına uygun olarak hem de tesisin verimli bir şekilde çalışabilmesi için öncelikle pulverize olarak adlandırılan toz hale dönüştürülmelidir [12].

Kömür ocaklarına yakın bölgelerde kurulan santrallerde yeraltından çıkartılan kömür, konveyör bantları ya da iş makinaları vasıtasıyla kömür alma ve hazırlama tesisine getirilmektedir. Ocaklardan çıkartılan kömürler ortalama 0-1000 mm. aralığında bir büyüklüğe sahipken, uygulanan kömür kırma prosesi ile 0-300 mm. aralığına, daha sonra uygulanan çekiçli kırıcı prosesi vasıtasıyla 0-30 mm. aralığına ve bir sonraki kırıcı sistemi ile 0-10 mm. iriliğe düşürülür ve taşıma sistemleri ile stok sahasına depolanır.

Bu işlemlere paralel olarak kömür içerisinde bulunabilecek metal parçaların ayıklanması için metal dedektörü ve metal ayırıcı sistemi kullanılır. Stok sahasından konveyör bantları vasıtasıyla ana kömür bunkerlerine taşınan kömür, değişken hızlı çıkarıcı ekipmanlar ile kömür bantlarına taşınır ve sıcak gaz kanalına dökülür. Bu işlem kömürün yapısında bulunan ve verimliliği negatif yönde etkileyen nem miktarının olabildiğince az seviyelere indirilmesi için kritik bir öneme sahiptir.

Nemi belirli ölçülerde alınan kömür, daha sonra fanlı tip değirmenler altında ezilerek pulverize hale getirilir. Böylece toz hale getirilmiş olan kömür, kömür kanalları vasıtasıyla kazana püskürtülmek üzere hazır hale getirilmiş olur. Santralin enerji dönüşümü tek kademede gerçekleştirilen bir çevrim olmadığı için yakıtın kimyasal enerjisinin ısı enerjisine dönüşümü, kimyasal bir olay olan yanma işlemi ile sağlanmaktadır. Kazanın ilk ateşlenmesinde fuel-oil, dizel yakıt ya da propan yakan

yakıcılar ve hava ısıtıcılarından geçerek belirli bir sıcaklığa ulaşan yakma havası vasıtasıyla ilk yanma sağlanır. Kazanın sıcaklığı ortalama olarak 375-425 °C aralığına ulaştığında, pulverize kömür enjeksiyonuna başlanır. Normal şartlar altında kazan yanma odası çalışma sıcaklığı ortalama 820-960 °C aralığında tutulmaktadır.

Bu sıcaklık değerinin kazan dizaynına uygun olarak, santral işletme grubu tarafından ve otomasyon sistemleri vasıtasıyla stabil olarak tutulması, kazanın ısıl dengesi açısından büyük önem arz etmektedir [1]. Kazan besleme suyu tankında depo edilen ve kazan besleme pompaları vasıtasıyla ortamala 150 °C civarındaki bir sıcaklıkta pompalanan demineralize saf su (demineralized water), ısıtıcılardan geçirilerek 240-250 °C aralığında bir sıcaklığa ulaşır ve bu haliyle kazana gönderilir.

Kazanda gerçekleştirilen sürekli yanma işleminde ortaya çıkan ısı enerjisi, kazana boru hattı üzerinden sürekli olarak şarj edilen demineralize saf suyu kızgın buhar fazına çevirir. Sistemin kapasitesine göre 520-540 °C aralığındaki bir sıcaklığa ve 130-140 kg/cm² aralığında basınca ulaşan enerji yüklü kızgın buhar, buhar türbininin rotoruna iletilir ve rotorda yavaş yavaş bir dönme hareketi başlatılmış olur. Genel olarak nominal 3000 devir/dakika oranında bir hızla dönen rotor, buhardaki ısı enerjisini hareket enerjisine dönüştürmüştür.

Elde edilen hareket enerjisi sayesinde ortak bir shaftla türbin rotoruna akuple halde bulunan jenaratör rotoru aynı hızla çevirmeye başlar. Böylece jenaratörden elektrik enerjisi üretilmeye başlanmış olur. Üretilen elektrik enerjisi, santralin bulunduğu ülkenin yüksek gerilim standartlarına göre seçilen yükseltici güç trafoları vasıtasıyla regüle edilir ve istenilen voltaj ile güç seviyesine çıkartılır. Trafo çıkışında istenilen standartlara ulaştırılan elektrik enerjisi, açık ya da gaz izoleli yüksek gerilim şalt tesisi vasıtasıyla ülkenin enerji şebekesine bağlanır.

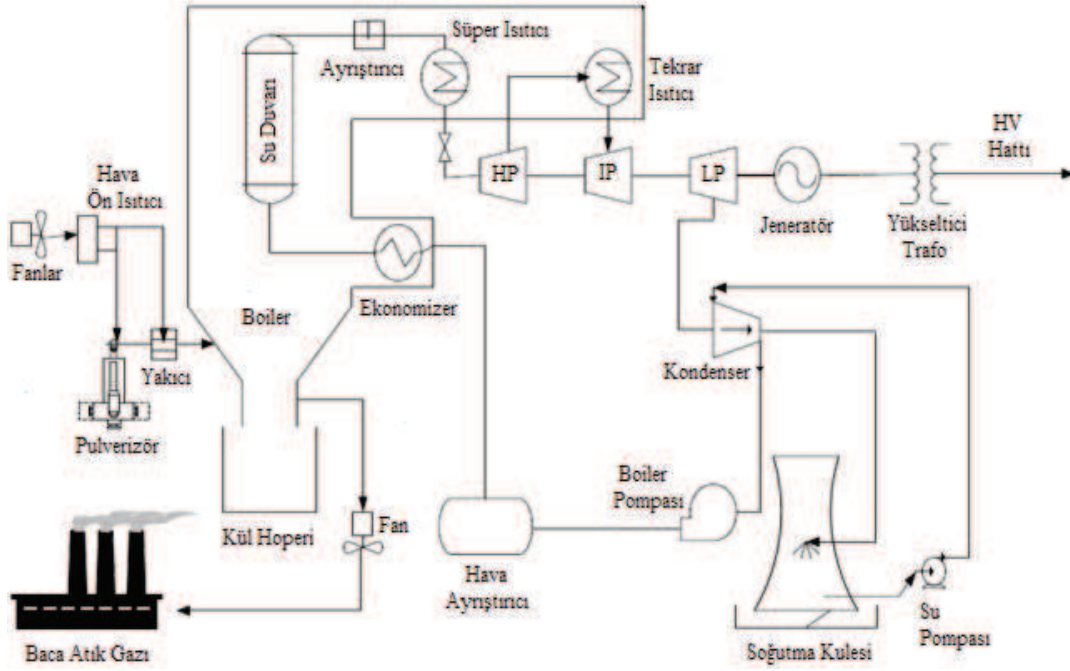
Termik santrallerde üretilen enerji, santralin verimliliğine göre %30-40 civarındaki bir oran ile elektrik enerjisine dönüştürebilir ve geri kalan enerji ise kaçak olarak adlandırılır. Kaçak enerji, kazanlarda oluşan termal radyasyon ya da baca gazı olarak santral dışına atılmaktadır. Buhar türbininden çıkan çürük buhar, basınç ve sıcaklığı azalmış olarak kondenser adı verilen yoğunlaştırıcı bir üniteye toplanır. Kondenserde

soğutulan ve yoğunlaştırılan buhar, bu üniteye faz değiştirerek su haline dönüşür ve daha sonra tekrar çevrimiçi sistemde kullanılmak üzere soğutma kuleleri olarak adlandırılan üniteye iletilir. Soğutma kulelerinin ana amacı, sistemde sirküle edilecek bu suyun yağmurlama usulü ile soğutulması ve sisteme geri gönderilmesi olarak tanımlanabilir. Termik enerji santrallerinde kullanılan soğutma kulelerinde soğutma işlemi, kurulu buldukları bölgenin coğrafi özelliklerine göre göl, ırmak suyu ya da deniz suyu kullanılarak gerçekleştirilmektedir.

Deniz suyu kullanılan santrallerde öncelikli operasyon klor havuzlarıdır. Daha sonra pompalar yardımıyla iki koldan kondensere gönderilen ve buharın ısısını üzerine alan deniz suyu, kondenserden çıkarak denize geri gönderilir. Termik santrallerde kullanılan su, temel olarak su-buhar çevrimi suyu ve soğutma suyu olarak ikiye ayrılır. Yanma esnasında kazan çeperlerinde bulunan yoğun boruların içerisinden geçmekte olan saf su buhara dönüştürülerek türbine gönderilir. Santralde kullanılan saf suyu elde edebilmek için kimsiyal temizleme ve dönüşüm işlemi uygulanmaktadır.

Soğutma suyu sistemde kazan artığı kül ve çürüğün ıslatılması ve sahadan nakledilmesi işleminde, soğutma ve yangın sistemi tanklarında ve kondense soğutma suyu olarak kullanılmaktadır. Alçak basınç türbininde işlem gören buharı yoğunlaştırma işleminde kullanılan su, borulardan geçerek üzerine dökülen çürük buharı yoğunlaştırır ve fazını değiştirir. Santralin değişik bölgelerinde çalışan sistemlerin soğutulmasında da saf su kullanılmaktadır.

Kondenser bölümünde çürük buharın faz değiştirerek su haline getirilmesinin ana nedeni, buharın depolanma özelliğinin olmamasıdır. Soğutma kulelerinde sıcaklığı belirli oranlara düşürülen su, soğutma suyu pompaları vasıtasıyla kapalı çevrim saf su sistemine geri gönderilir. Kazan, ekonomizer, IP, LP, HP basınç hattı, kondenser, soğutma kulesi, hammadde hattı, su sistemi, baca, jeneratör, yükseltici trafo ve HV hattının gösterildiği bir termik santral prosesinin şematik görünümü Şekil 2.8'de verilmektedir.



Şekil 2.8. Bir termik santral prosesinin görünümü

Termik santrallerde en önemli ve hassas ekipman, ısı dönüşümlerinin gerçekleştirildiği kazan (boiler) isimli ekipmanlardır. Termik santrallerin verim hesabında da en çok dikkat edilmesi gereken ekipman Kazan olarak ortaya çıkmaktadır ve kazanda elde edecek küçük bir tasarruf doğrudan santralin verimliliğini artırıcı bir etki yapmaktadır. Bir kazana giren ve çıkan toplam enerji arasındaki oranı gösteren ve toplam verimliliği gösteren eşitliğe ısı balansı denir [13]. Kazanda üretilen buhardaki verimli ve yararlı ısı enerjisi yüzdesi olarak tanımlanan verimlilik ifadesi, şu şekilde tanımlanmaktadır:

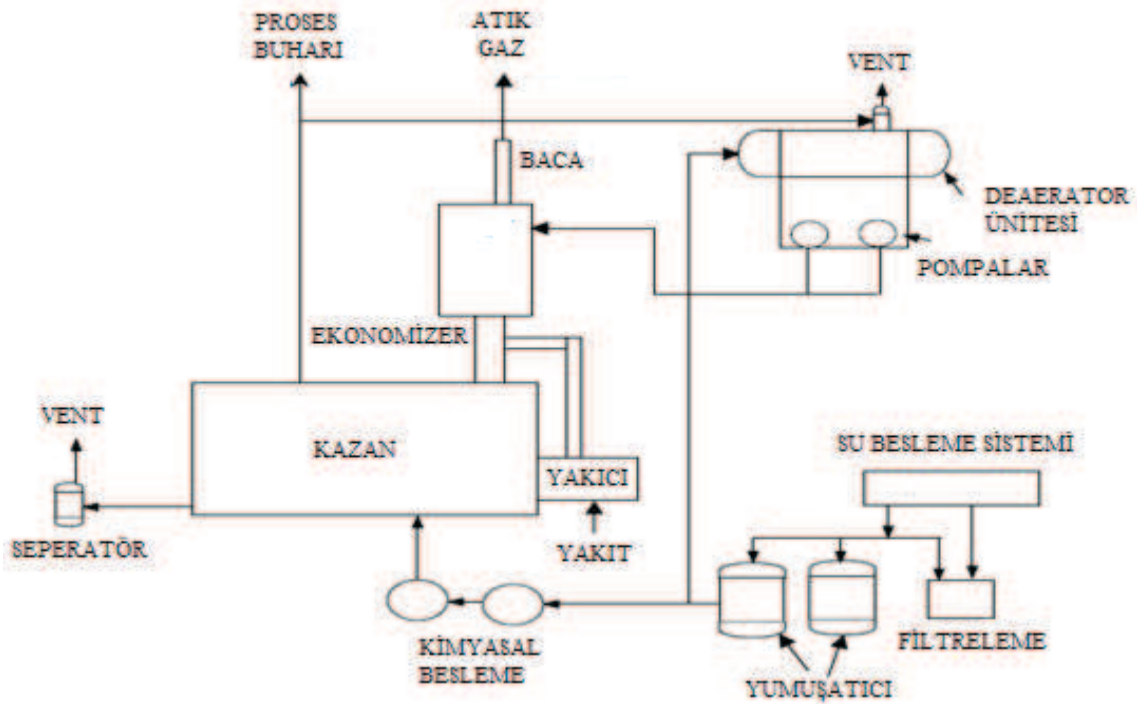
$$Kazan\ Verimliliği\ (\eta) = \frac{Kazandan\ Ç\ *}{E} \cdot \frac{h_g - h_f}{E^*} \cdot T_{SR} \cdot \frac{1}{T_{SR}} \quad (2.9)$$

Bu ifadeye Q, kg/h cinsinden saatte üretilen buhar miktarını, q, kg/h cinsinden saatte kullanılan yakıt miktarını, CV, kcal/kg cinsinden kullanılan yakıtın toplam kalorifik değerini, h_g, kcal/kg cinsinden doyuma ulaşmış buharın entalpisi ve h_f ise kcal/kg cinsinden besleme suyunun entalpisini göstermektedir. Bu metod giriş-çıkış modeli olarak da bilinmektedir ve hesaplama için sadece faydalı buhar çıkışı ile ısı girişi değerlerinin bilinmesi yeterlidir. Her ne kadar bu yöntem az sayıda parametreye gereksinim duyacak şekilde kolayca hesaplanabilecek bir durumdaysa da, çok çeşitli ısı kayıplarını gözardı etmesi nedeniyle söz konusu bu eşitliğin zaafiyete sahip olduğu

muhtemeldir. Bir başka verimlilik hesaplama yöntemi de endirekt model olarak adlandırılır ve şu şekilde tanımlanmaktadır:

$$Kazan\ Verimliliği = \frac{E}{L + s + r + F} = \frac{6}{K + L + H + \Theta + F} = \frac{U}{H} = \eta \quad (2.10)$$

Bu ifadede atık gaz, buharlaşarak uçan su, atık kütle bulunan yanmamış yakıt, radyasyon enerjisi, yakma havasında bulunan nem oranı, yakıtta bulunan nem oranı ve geri kalan sayılmayan kayıplar birleşerek toplam ısı kaybı yüzdesini göstermektedir. Bir kazana ait proses akış diyagramı Şekil 2.9'da gösterilmektedir.



Şekil 2.9. Kazan prosesinin şematik gösterimi

Çalışmada kullanılmakta olan kömür yakıtlı termik santral Çanakkale'de faaliyet göstermektedir. Kurulu gücü 600 MWe olan İÇDAŞ firmasına ait bu santralde bir adet kazan ve bir adet buhar türbini üniteleri bulunmaktadır. Ayrıca santralde proseste kullanılan hava, atık gaz, doğalgaz, hava kompresörü, sirkülasyon ve kapalı çevrim su sistemi, ana buhar, tekrar ısıtılmış buhar ve türbin bypass sistemleri bulunmaktadır. Değişken hızlı hidrolik kaplin tip motor ile çalışan besleme suyu pompaları su sirkülasyonu için kritik öneme sahiptir. Kondenser deniz suyu ile soğutulmaktadır, buhar türbini yağ ile geri kalan yardımcı ekipmanlar ise kapalı çevrim su sistemi ile soğutulmaktadır. Tüm bu sistemlere ilişkin ölçümler sahada yer alan değişik tipte

sensörlerle ölçülmektedir ve elde edilen bu bilgiler tüm sistemi kontrol edecek şekilde ana kumanda odasında bulunan DCS sistemine aktarılmaktadır.

2.2.2. Termik santrallerde verimlilik

Günümüzde dünya üzerindeki mevcut enerji kaynaklarının yüksek verimlilik ile kullanılmasının sağlanmasına yönelik çalışmalar son yıllarda önemini giderek arttırmaktadır. Dünya genelinde enerji üretiminin büyük oranda fosil kaynaklı olması ve bu kaynakların rezervlerinin tükenme tehlikesi ile karşı karşıya kalınması bunun en önemli nedenidir. Bununla birlikte alternatif enerji üretim şekli olarak ortaya çıkan hidroelektrik, rüzgar, biyoyakıt ve güneş enerjisi gibi yenilenebilir kaynakların son dönemde yaygınlaşmasına rağmen kısa vadede kurulum ve ekonomik geri dönüş sağlama konularındaki dezavantajları nedeniyle fosil kaynaklı üretim modelinin hakimiyeti daha da artmaktadır. Türkiye’de şu anda ve yakın gelecekte enerji üretiminin yoğun olarak fosil kaynaklı tesislerinde gerçekleştirileceği aşikardır. Mevcut doğalgaz, kömür ve petrol rezervlerimizdeki sorunlar göz önüne alındığında, enerji yönetimi, tasarruf ve verimlilik konularının önemi ortaya çıkmaktadır.

Termik santrallerde, özellikle ülkemizde, fosil yakıt ailesinin bir üyesi olan linyit kömürü temel yakıt olarak kullanılmaktadır. Tüm dünyada olduğu gibi ülkemizde de ısı değerleri düşük olan linyitlerin termik santrallerinde değerlendirilmesi yoluna gidilmektedir, ancak malesef bu linyitlerin çoğu planlanan kalite değerlerinin altındadır [44]. Bununla birlikte linyitin nem ve kül oranının yüksek olması da santral kapasitesini ve enerji verimliliğini olumsuz yönde etkilemektedir. Linyit kalitesi, içerisindeki kükürt gibi yabancı maddelerin oranı ile ters orantılı olarak değişmektedir. Ülkemizde nem oranı %36'nın üzerinde olan linyit rezerv miktarı, potansiyel rezervin %63'üne karşılık gelmektedir ve rezervlerin sadece %36,7'sinin %1'in altında kükürt içerdiği, toplam rezervin %31,7'sinin de kükürt oranının %4-5 gibi yüksek oranlarda olduğu rapor edilmiştir [45].

Kömürünün elektrik üretiminde önemli bir kaynak olarak kullanılma sebeplerinin başında, fuel oil ya da doğalgaz gibi ithal yakıtlara göre daha ucuz olarak kabul edilmesi gelmektedir ve dolayısı ile linyit kalitesiyle ilgili bazı sorunlar olsa da bu

hammaddeden vazgeçmek verimlilik ve maliyet kaygıları nedeniyle mümkün gözükmemektedir. Termik santrallerde verim kavramı en temel hali ile tüketilen yakıtın yüzde olarak kullanılabilir enerjiye çevrilme oranını ifade etmektedir. Santrallerde bu değer termodinamik yasalar gereği %33-48 aralığında olması beklenmektedir [43]. Elektrik enerjisine dönüştürülemeyen ve çevrimden çıkan buhardaki ısının bir kısmının geri dönüşümünün sağlanması da mümkündür. Kojenerasyon olarak adlandırılan bu işlem, yoğunlaştırıcı kondenserden ünitesinden çıkan buharın soğutma kulelerine gönderilmesi ile bir takım ısı transferlerinin sağlanması prensibine dayanmaktadır. Giren yakıttan azami fayda sağlamaya yönelik bir yaklaşım olan bu işlemler sistemin genel verimliliğini arttırmaktadır.

Kondenser içindeki basıncı azaltmak sureti ile yoğuşma sıcaklığını düşürmek de sistem verimini iyileştirmeye sebep olmaktadır. Bu işlem kondenser içindeki bir vakum pompası yardımı ile yapılır, ancak yoğuşan buhar sıcaklığı düşükçe kondensere devrettirilen su miktarı artmaktadır. Kondenser basıncı soğutucu ortamın sıcaklığına karşı gelen doyma basıncından daha düşük olmamalıdır. Buhara ısının verildiği ortalama sıcaklık değeri, kazan basıncı sabit tutularak buharın kızgın buhar bölgesinde daha yüksek sıcaklıklara yükseltilmesi ile de arttırılabilir. Buharın kızdırılması, türbin çıkışındaki buharın nem derecesini azaltmaktadır. Ancak bu işlem buharın kızdırılabileceği maksimum sıcaklığı türbin ve kazanda kullanılan malzemenin özellikleri belirlemektedir ve günümüzde bu 600-630 °C mertebelerine çıkmaktadır.

Çevrime ısı girişi sırasında ortalama sıcaklığın yükseltilmesinin bir diğer yolu ise kazan çalışma basıncının yükseltilmesidir [43]. Kazan basıncının yükseltilmesi işlemiyle, buharlaşmanın gerçekleşeceği sıcaklık da otomatik olarak yükselir ve böylece buhara ısının verildiği ortamdaki ortalama sıcaklık ve çevrim verimi de yükseltilmiş olur. Rejeneratif besleme suyu ısıtması bu amaca hizmet eden yöntemlerden birisidir. Nispeten soğuk durumdaki besleme suyu kazana verilmeden önce ısıtılabilirse, kondenserden gelen sıcak durumdaki su ile karıştırıldığında ısı kaybı yaşanmamış olur. Buhar türbini ile çalışan büyük termik santrallerde ekonomik çalışmaya imkan sağlayan bu rejeneratif yöntemde, türbinden ara buhar almak sureti ile besleme suyunun önceden ısıtılması sağlanmaktadır [43]. Ara buhar alma işlemi,

hem sistem verimliliği arttırırken hem de besleme suyuna kondenserde karışmış olan havanın tahliyesi ve kazandaki olası paslanmaların önlenmesini sağlamaktadır.

2.2.3. Termik santrallerde baca atık gazları ve çevresel etkiler

Fosil yakıtlı enerji santralleri günümüzün vazgeçilmez enerji kaynaklarıdır, ancak maalesef bu yakıtların çevreye çok olumsuz etkileri de bulunmaktadır. Gelişmiş ülkeler fosil yakıtları olabildiğince verimli bir şekilde kullanmaya çalışırken, paralel olarak yasal düzenlemelerden kaynaklanan kriterler nedeniyle, çevresel etkileri azaltmaya yönelik çalışmalar da yapmaktadır. Ülkemizde enerji üretiminde dışa bağımlılığı azaltmak ve maliyetleri minimize edebilmek için linyit kömürü yoğun olarak kullanılmaktadır. Kömürden kaynaklanan çevresel etkileri aşabilmek için temiz kömür teknolojileri olarak adlandırılan yöntemlerine başvurulmaktadır. Genel olarak bakıldığında linyitin termik santrallerde yanması sonucunda küresel ısınmaya ve asit yağmurlarına neden olan karbon oksitler (CO ve CO₂), sülfür oksitler (genel olarak SO_x olarak tanımlanan SO, SO₂ ve SO₃) ve azot oksitler (genel olarak NO_x olarak tanımlanan NO ve NO₂) gibi gazlar yanında, kül olarak adlandırılan katı kirleticiler açığa çıkmaktadır [46].

Açığa çıkan bu kirleticiler atmosferde asılı kalarak zincirleme birtakım olaylarla neden olmaktadır. Bu etkilerden en önemlisini asit yağmurlarıdır. Asit yağmuru genel olarak pH derecesi 5,6' dan az olan yağmur olarak tanımlanmaktadır. Asit yağmurlarının oluşumunun en önemli nedeni, SO ve NO_x gazlarından dolayı H₂SO₄ (sülfürik asit) ve HNO₃ (nitrik asit) bileşiklerinin oluşması olarak gösterilmektedir. Asit yağmurları bitkilerin stomalarından içeri nüfuz ederek bitkinin pH değerini değiştirmekte, bitkinin fotosentez yapmasına engel olmakta ve dolayısı ile bitkinin gelişimi üzerine olumsuz etkiler sergilemektedir.

Termik santrallerin çevresel etkilerinin başında, bacadan dışarı verilen gazların ortaya çıkardığı hava kirliliği gelmektedir. Termik santraller yüksek oranda soğutma suyuna ihtiyaç duyan tesislerdir. Bu soğutma sularının arıtılmadan ve özellikle de sıcak bir halde tesis dışına deşarj edilmesi yeraltı sularının kimyasal yapısını etkileyerek birtakım çevre sorunlarına neden olmaktadır. Termik santrallerin en tehlikeli

çıkıntılarında olan ve katı atık olarak adlandırılan küller, özellikle uygun depolama sistemi olmayan santrallerde büyük bir risk unsurudur. Rüzgar ya da yağışların etkisi ile çevreye yayılan baca külleri ile santral bacasından çıkan toz ve atık gazlar malesef ölümcül olumsuz etkilere sahiptir. Tablo 2.2’de ülkemizde bulunan bazı termik santrallere ait ortalama emisyon değerleri gösterilmektedir.

Tablo 2.2. Linyit kömürle çalışan termik santrallerin emisyon oranları (kg/saat)

Santral	PM	SO ₂	NO _x	CO	VOC	CH ₄
Afşin-Elbistan	1,518	67,200	19,200	960	128	48
Çayırhan	94	1,776	1,528	76	10	3,8
Kangal	756	16,620	3,324	166	22	8,3
Orhaneli	30	5,700	1,200	60	8	3
Seyit Ömer 1-2-3	1,302	18,000	3,600	180	24	9
Seyit Ömer 4	660	7,980	1,596	80	11	4
Soma A	67	937	528	26	4	1,3
Soma B 1-2	618	4,880	1,992	100	13	5
Tunçbilek 1-2	123	1,800	360	18	2,4	0,9
Yatağan	263	27,945	4,140	207	28	10
Yeniköy	302	33,600	3,360	168	23	8,4

Tablo incelendiğinde, termik santraller arasında SO₂, NO_x, CO₂, VOC (uçucu organik bileşenler) ve CH₄ (metan) değerleri yüksek olan santrallerin çevreye büyük etkilerinin olduğu görülmektedir. Baca gazı arıtma sistemleri olan santrallerin emisyon oranları %95 mertebelerinde tutularak, havaya verilmemektedir. Santrallerin yakın çevresinde bulunan topraklar üzerinde gerçekleştirilen çalışmalarda, toprak örneklerin kükürt, arsenik, kadmiyum, kurşun, çinko, bakır, mangan, molibden, kobalt, demir, civa gibi zararlı elementleri içerdiği görülmüştür [46].

Bu zararlı maddelerin miktarlarındaki artışın yanında, toprağa yararlı olan üreaz, asit ve alkali fosfataz aktivitelerinde önemli derecede azalmalar gözlenmiştir. Kül ve baca gazlarının çevre bitki örtüsü üzerine etkileri konusunda yapılan araştırmalar, özellikle radyoaktif uranyum elementi ve bitkiye yararlı SO₄ (Sülfat) konsantrasyonlarının santrallere yakın alanlarda artış gösterdiği kanıtlamaktadır.

Termik santrallerin çevresel etkilerinin bir başka boyutu da insan sađlığına olan zararları olarak gösterilmektedir. Hava kirliliđinin, insanların akciđer hastalıklarını artırıcı bir rol oynadıđı pek çok arařtırmada kanıtlanmıřtır. Bununla birlikte sađlık üzerinde olumsuz etkileri bilinen ađır metallerden arsenik ve kadmiyumun kansere, civanın genetik bozukluklara, kurřun ve bakır elementlerinin beyin ve kemik hastalıklarına neden olduđu bilinmektedir. Su ve topraktaki bu tür kirliliklerin düzeyinin artması, bilinen veya etkisi tam olarak arařtırılmamıř pek çok hastalıkları da beraberinde getirmektedir [46]. Ancak tüm bunlarla birlikte, termik santrallerden kaynaklı hastalıkları anlayabilmek için, çevre halkın sađlık taramasından geçirilmesi ve verilerin istatistiksel olarak ortaya konması elzemdir.

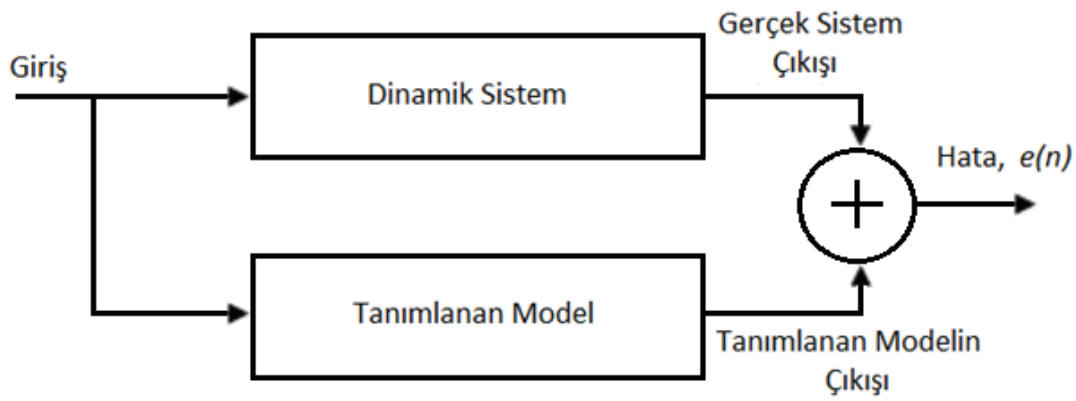
BÖLÜM 3. VERİ MADENCİLİĞİ VE PERFORMANS KRİTERLERİ

3.1. Sistem Tanımlama ve Modelleme

Bir sistemin dinamik karakteristiğinin matematiksel ifadelerle tanımlanması matematiksel model olarak ifade edilmektedir. Mekanik, elektriksel, ekonomik, ısıl, biyolojik, vb. çok sayıda ve değişik sistemler, sürekli zamanda diferansiyel denklemler, ayrık zamanda ise fark denklemleri kullanılarak matematiksel olarak ifade edilebilmektedir. Ele alınan bu sistemlere ait matematiksel denklemler, fizik kanunlarından yararlanılarak elde edilmektedir [47]. Dinamik sistemlerin çözümlenmesindeki ilk adım, o sistemin uygun bir matematiksel modelinin çıkartılması işlemidir. Modellemede, genel olarak karmaşık bir mühendislik sisteminin bazı kabullerle ideal durumları gözetilmeli ve uygun elemanlar kullanılarak fiziksel kurallar uygulanmalıdır. Matematiksel model elde edildikten sonra bir sonraki aşama bu problemin uygun yöntemler kullanılarak sistem çözümünün bulunmasıdır.

Elde edilen çözüm, gerçek sistemi ne kadar iyi temsil ediyorsa, tasarlanan model gerçek sisteme o kadar uygun demektir [34]. Aksi halde, başlangıçta düşünülen kabullerde bir hata olacağı düşünülmelidir ve bu kabuller tekrar gözden geçirilerek gerçeğe daha yakın bir modelin tasarlanması sağlanmalıdır. Bununla birlikte bir modelin hem basitliği hem de çözümlenme sonuçlarının doğruluğu arasındaki uyum çok önemlidir. Bazen tüm sistemi tanımlayan onlarca denklemden oluşan bir model tasarımı ve yüksek hızlı bilgisayarlar vasıtasıyla bu problemin çözümü de mümkündür. Ancak yüksek dereceden bir doğruluğa ihtiyaç varsa, olabildiğince basite indirgenmiş bir model kurulması daha anlamlıdır. Daha basit modellerin elde edilmesi ise, genellikle bazı sistem özelliklerinin ve fiziksel parametrelerin ihmal edilmesi sureti ile sağlanır.

Herhangi iki farklı girişe karşılık elde edilen sistem tepkileri bu girişlerin ağırlıklı toplamı için de aynı tepkilerin toplamı şeklindeyse, bu sistemin doğrusallık özelliği gösterdiği söylenir. Aradaki bu ilişkiyi gösteren modelin de doğrusal bir model olduğu aşıkardır. İnsan yapımı ya da doğal yapıdaki sistemlerin matematiksel modelleri günümüz bilim dünyası için çok kritik bir öneme haizdir ve bu modeller mühendislik ve bilimin hemen her dalı için kontrol, kestirim ve simülasyon uygulamalarında yoğun olarak kullanılmaktadır. Dinamik bir sistemin modeli Şekil 3.1’de de verildiği gibi giriş ve çıkışlardan oluşan, matematiksel kaidelerle çalışan kutucuklar olarak gösterilebilir. Model içerisindeki matematiksel modeller, bilinen bazı eşitliklerden yararlanılarak oluşturulabilir [34].



Şekil 3.1. Dinamik sistem modelinin gösterimi

İhmal edilen parametrelerin özellikleri eğer sistem cevabı üzerinde küçük bir etkiye sahipse, matematiksel modelin çözümlenmesinden elde edilen sonuçlar ile fiziksel sistemin deneysel sonuçları arasında iyi bir uyumun sağlandığı söylenebilir. Eğer doğrusal yığılmış parametrelili bir modele ihtiyaç duyuluyorsa, o fiziksel sistemin yapısında bulunan dağılımlı parametrelerin ya da belirli doğrusalsızlıkların ihmal edilmesi gerekmektedir [34]. Normalde mühendislik sistemleri doğrusal olmayan yapıdadır ve bu sistemler için matematiksel bağıntıları elde etmek ile analitik çözümleri üretebilmek kolay değildir. Doğrusal olarak ele alınan yapılar da gerçekte doğrusal olmayıp, sistem elemanlarının belli çalışma bölgeleri için doğrusal olarak kabul edildiği sistemlerdir.

Sistemin matematiksel modelini oluşturmak için fiziksel önbilgi yoksa sistemle ilgili giriş ve çıkış verilerini kullanarak, o sistemin matematiksel modeli elde edilebilir ki

bu literatürde sistem tanımlama problemi olarak bilinmektedir [48]. Sistem tanımlama probleminin çözümü, hatayı minimum yapan dinamik sistemin matematiksel modelinin gerçekleştirilmesini sağlayarak bulunabilir. İdeal durumda, bu dinamik sistem için hata terimi sıfıra eşit olmalıdır. Özellikle doğrusal sistemler için sistem tanımlama probleminde temel amaç, bilinmeyen bir transfer fonksiyonunu belirleyebilmektedir. Doğrusal olmayan sistemler için sistem tanımlama problemi, giriş-çıkış ilişkisini tanımlayabilme anlamında daha da karmaşık bir yapıdadır.

Gerçek dünyadaki bir sürecin, olayın, birimlerin ya da birimlerin iç ilişkileri yanında çevre ile ilişkilerini özetleyen anlatıma model denir. Bu anlatım fiziki benzerlikleri yakalamak, çizim ve sözle gerçekleştirilebileceği gibi, bilim ve teknolojinin vazgeçilmezi olan matematik bilimi ile de sağlanabilmektedir. Günümüzde gelişen bilgisayar teknolojilerinin de yardımı ile sayısal modellerin tasarımı ve kullanımı oldukça yaygınlaşmaktadır.

Bu modeller, özellikle tasarım, tasarımda gerçekleştirilen değişimlerin gösterilmesi ve optimizasyon gibi farklı alanlarda kullanılmaktadır. Model çıktıları, başta yapılan kabullere bağlı olarak gerçeğe yakın ya da gerçekten uzak olabilmektedir. Sistem tanımlamada üç temel adım, modelin seçimi ve deney planlaması yapılarak modelin denenmesi, parametre tahmini ve son olarak modelin doğrulanması ya da yüksek hata nedeniyle güncellenmesi olarak sıralanabilir.

Sistemler genel olarak birimler arasındaki ya da çevre ile olan çapraz ilişkiler nedeniyle karmaşık bir yapıya sahiptir. Ancak bu sistemlerin modellenmesi sırasında bazı basitleştirmeler, ihmaller ya da kabuller nedeniyle daha makul bir karmaşıklığa indirgenme sağlanmış olur. Sistem davranışlarını öğrenebilmek, gerek duyulduğunda sistemi yenilemek, sistemi denetlemek veya korumak amacıyla gerçekleştirilen incelemeler sırasında, bilinen girdiler için sistemin vereceği tepkilerin ve sistem çıkışların ne olacağı sorgulanmaktadır.

Bazı sistemlerde istenilen çıktıları yakalayabilmek için çıktılar üzerinde gerçekleştirilen gözlemlere istinaden sisteme girdiler de verilebilmektedir ve bu yöntem geri bildirim olarak adlandırılır. Gerçek dünyadaki olguların modellenmesi

sırasında takip edilen bazı özellikler ile modeldeki karşılıkları olan kavramlar arasında bir bağ tesis edildikten sonra, fiziksel metodolojiye göre olgular ile karşı kavramlar arasında bir bağ kurulur.

Bu modelin ne şekilde ölçüleceğine, ölçü aletine ve yonteme karar verildikten sonra ölçülen özelliğin modeldeki karşılığı olan değişkenin aldığı değerin bulunması aşamasına gelinir. Ölçülen bu özellik, eğer rastgelelik özelliği taşıyorsa, modelde buna karşılık gelen değişken de rasgele değişkenlik özelliği taşıyor denir. Sistemlerin matematiksel modellerinin elde edilmesi işi, titizlik ve büyük bir dikkat gerektiren işlemdir. Sistemi uyaracak uygun bir giriş sinyalinin seçimi ile başlayan sistem tanımlama işlemi, bu sistemi karakterize eden uygun verilerin bulunması ve sonrasında da uygun modelin belirlemesi işlemi ile devam eder [48].

Bu aşamadan bir sonraki kritik aşama da modelik geçerliliğinin sınanması işlemidir. Eğer modelin uygun olmadığı anlaşılırsa model yapısının değiştirilmesi gerekir. Yine de sonuçlar uygun çıkmazsa, sistemin deneysel planlamasına geri dönülerek, örneğin doğrusallık yerine doğrusal olmayan modellerle, tasarım yeni şartlara göre tekrarlanır. Sistem yaklaşımında gri kutu (grey box) ve kara kutu (black box) olmak üzere iki yaklaşım bulunmaktadır.

Gri kutu yaklaşımında, incelenen sistemin yapısına dair elde ön bilgi bulunmaktadır ve bu nedenle sisteme uygulanan bilinçli girişler sayesinde çıkan sonuçlar izlenir ve kontrol altına alınabilir. Kara kutu yaklaşımı ise, incelenen sistemin yapısı hakkında herhangi bir bilgi bulunmadığında kullanılmaktadır. Dolayısı ile içeriğinden haberdar olunmayan bu sisteme çeşitli girişler uygulanır ve elde edilen çıktılar analiz edilerek uygun bir model yapısının kullanılmasına karar verilir.

3.2. Veri Madenciliği

Veri madenciliği terimi, çok hacimli, dağınık ve geniş veri kümeleri üzerinde yapılan çalışmalar sonucu, birbiri ile anlamlı bağlantıların, eğilimlerin ve örüntülerin bir takım metodlar ile keşfedilme sürecini ifade etmektedir. Son dönemde araştırmacılar eğitim, tıp, iş, ticaret alanlarında yeni bir araştırma sahası olarak ortaya çıkan veri madenciliği


(data mining) ve bilgi keşfi (knowledge discovery) metodlarını matematiksel ve istatistiksel yöntemler vasıtasıyla geliştirmektedir. Veri madenciliği, gözlemsel veri kümeleri arasında var olduğu bilinmeyen ilişkilerin bulunması için bu veri setlerinin analizi ve verilerin, veri sahibi için hem anlaşılabilir hem de kullanılabilir olması amacıyla özetlenmesi ya da büyük veritabanlarından bilgi çıkarma amacına odaklı olarak makine öğrenmesi, örüntü tanıma, istatistik, veritabanları ve görselleştirme gibi teknikleri bir araya getiren disiplinlerarası alan olarak nitelendirilebilir [49].

Veri madenciliği tekniğinde geniş veri kavramı, tek bir iş istasyonunun belleğine sığamayacak kadar büyük bilgiyi ifade etmektedir. Yüksek hacimli veri ise tek ya da çoklu iş istasyonlarındaki belleklere sığmayacak kadar fazla veriyi anlatmaktadır. Veri madenciliğini istatistiksel yöntemler silsilesi olarak tanımlamak mümkündür. Ancak bu teknikleri geleneksel istatistik yaklaşımlarından bazı farklılıklar içermektedir. Örneğin, veri madenciliği insan merkezlidir ve insan-bilgisayar arayüzü mantıksal kurallara ya da görsel sunumlara imkan veren nitel modellerin çıkartılmasını ön planda değerlendirmektedir. Veri madenciliği sahası makine bilgisi, istatistik, matematik, veri tabanları ve yüksek performanslı işlemler bütünüdür.

Verilerin keşifsel olarak analizi, verilerin içerisinde ne arandığı konusunda ciddi bir fikir olmadan araştırmanın gerçekleştirilmesini ifade etmektedir. Bu yöntem etkileşimli ve görseldir. Küçük hacimli verilerin analizi grafik gösterim metodu kullanılarak gösterilebilir, ancak veri boyutu büyüdükçe uzayda nokta bulutlarının gösterimi zorlaşacaktır. Verilerin betimsel modellenmesi kavramı ise, tüm verinin ya da veriyi üreten sürecin anlamlandırılması olarak ifade edilebilir.

Bu tür modeller, verinin dağılım olasılığı, uzayda gruplandırma, kümesel bölme ve analiz ile değişkenleri değişkenler arası ilişkilerin tanımlandığı modellerin tamamını içermektedir. Bölümleme analizinde temel nokta, benzer kayıtların beraber gruplandırılması adımını içerir. Bilimsel veritabanlarında bulunan veriye ait doğal grupları keşfetmek araştırmacının tercihinine bağlıdır, yani genellikle deneme yanılma metodu ile gerçekleştirilmektedir.

Öngörülü modelleme kavramı ise, bir değişken değerinin bilinen diğer değişkenlerle tahmin edilmesidir. Burada kestirim genel bir sezgi olarak kullanılmaktadır ve herhangi bir uzay-zaman sürekliliği kavramı aranmamaktadır [33]. Veri madenciliği metodolojisi Şekil 3.2’de gösterildiği gibi 10 adımda incelenebilir. Süreci iç içe geçmiş grift döngüler olarak düşünmek mümkündür. Adımlarda belirli bir sıra gözetiliyor olsa da gerekli görülmeyen süreçlerin atlanması da mümkündür. Sonraki adımlarda öğrenilen bilgiler daha önceki adımlarda da bir tekrar gerektirmektedir.



Şekil 3.2. Veri madenciliği metodolojisi [33]

Basitçe, bağımlı değişkenin değerini bulmaya hedefleyen veri madenciliği, öngörü (prediction), sınıflandırma (classification), benzerlik gruplaması (affinity grouping), tanımlama (identification) ve kümeleme (clustering) problemlerine çözüm bulabilmek için kullanılmaktadır. Sınıflandırma, insan iradesi dışında görünen, nesnelere kategorize eden ve derecelendiren yaygın bir yöntemdir. Sınıflandırma, daha önceden tanımlanan örnekleri içeren eğitim kümelerinden oluşur. Yeni karşılaşılan girdilerin özellikleri incelenerek, bu bilgilerin daha önceden tanımlanmış bir sınıf kümesine atanması bu yöntemin temel görevidir. Sınıflandırma işi evet-hayır ya da 0-1 gibi ayrık sonuçlar ortaya çıkarırken, kestirim sürekli değer alabilen çıktılar ortaya koymaktadır.

Uygulamaya bakıldığında kestirim işlemi, sınıflandırma işlemlerini gerçekleştirmek için kullanılmaktadır. Kestirim işleminin sınıflandırmaya göre avantajı her kaydın sahip olduğu değere göre tüm kayıtların sıralanabilir olmasıdır [33]. Öngörü ise, sınıflandırma ve kestirim işleri ile prensip olarak aynıdır, ancak bu işlemdeki temel fark, kestirilen ileriki davranışların ya da hesaplanan ileriki değerlerden oluşan kayıtların sınıflandırılmasıdır. Öngöründe sınıflandırma işleminin doğruluğu, bekle ve gör prensibi ile kontrol edilmektedir. Kestirim ve sınıflandırma işlemlerinde kullanılan bir yöntem, eski verilerden uyarlanacak eğitim kümesinin ilavesi ile, öngörü işlemini gerçekleştirecek bir hal almaktadır. Modelin oluşturulmasında kullanılan eski veriler yardımı ile mevcut durumun açıklanması ve gelecek davranışların tahmini belirli bir hata payı ile sağlanabilecektir.

Sepet analizi olarak da tanımlanan benzerlik gruplaması işlemi, hangi ürünlerin hangi ürünlerle daha çok kullanıldığının analizi için kullanılmaktadır. Bu işlem aynı zamanda çapraz satış fırsatlarının belirlenmesi ya da hangi ürün veya hizmetlerin gruplanması ve promosyonlarının yapılması sağlanabilir. Kümeleme işlemi ise, ayrışık yapıdaki bir sistemin alt grup ya da kümeye bölme işlemi olarak tanımlanabilir. Kümelemenin sınıflandırmadan en önemli farkı, bu işlem sırasında daha önceden tanımlanmış alt sınıfların bulunmamasıdır. Kayıtların gruplandırılması, kayıtların birbirine olan benzerliğine göre yapılmaktadır.

Veri madenciliğinde kullanılan istatistiksel yöntemler çok boyutlu analiz (multivariate analysis), regresyon, kümeleme, boyut azaltma, hipotez testi, varyans analizi, bağıntı

olarak tanımlanabilir [33]. Bununla birlikte bellek tabanlı yöntemler, graf teorisi tabanlı ilişkisel analiz, karar ağaçları ve kural türetme, genetik algoritmalar, destek vektör makinaları gibi yöntemler de yoğun olarak kullanılmaktadır. Literatüre bakıldığında, kestirim işlemlerinde son dönemde yapay sinir ağları ve regresyon modelleri ile yoğun ve başarılı çalışmaların gerçekleştirildiği gözlenmektedir.

3.3. Performans Kriterleri

Literatürde yazılım ya da simülasyon çalışmalarında kullanılan modellerin sonuçlarının birbiri ile karşılaştırmak için bazı kriterler kullanılmaktadır. Bu çalışmada Belirlilik Katsayısı ve Ortalama Karekök Hatası parametreleri karşılaştırma ve performans kriteri olarak önerilmektedir.

3.3.1. Belirlilik katsayısı

Belirlilik Katsayısı (R^2), modelin verilere ne kadar iyi uyduğunu göstergesi olarak kullanılan bir performans parametresidir. Belirlilik katsayısı temel olarak bağımlı değişkendeki değişmelerin yüzde kaçının bağımsız değişkenler tarafından açıklanabildiğini ifade etmektedir. Belirlilik katsayısı 0 ile 1 arasında değerler almaktadır. R^2 değerinin 1 değerine yakın olması modelin verilere olabildiğince uyumlu olduğunu göstermektedir. Aynı şekilde bu parametrenin 0 değerine yakınlığı da bağımlı değişken ile bağımsız değişkenler arasında uyumsuzluğun göstergesidir. Belirlilik katsayısı çoklu doğrusal regresyon modelinde, model içerisine dahil edilen değişken sayısı arttıkça artmaktadır [50].

Yapay sinir ağları, çoklu doğrusal regresyon ve ARIMA modellerinin uygulandığı bir problemde, ilgili parametreler tahmin edildikten ve en küçük kareler doğrusu belirlendikten sonra, bu doğrunun bağımlı ve bağımsız değişkenlerine ne kadar iyi uyduğunun bilinmesi çok önemlidir. Yani gözlemlerin regresyon doğrusu etrafındaki dağılımlarının nasıl olduğunun ölçülmesi gerekmektedir. Burada gözlemler doğruya ne kadar yakınsa bağımlı değişkenlerin bağımsız değişkendeki değişmelerle açıklanması o kadar iyidir. Bu uyum iyiliğinin bir ölçüsü, bağımlı değişkendeki toplam değişimin yüzde kaçının bağımsız değişken x tarafından açıklanabildiğini gösteren

korelasyon katsayısının karesi olan belirlilik katsayısıdır ve bu parametre aşağıdaki denklem ile hesaplanmaktadır [50]:

$$R^2 = \frac{\sum_{i=1}^n (\hat{y}_i - \bar{y})^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (3.1)$$

Burada \bar{y} gözlenen değerlerin ortalaması, n toplam veri sayısı, \hat{y}_i gözlenen değerler, y_i ise modelden elde edilen sonuçlardır.

3.3.2. Ortalama karekök hatası

Ortalama Karekök Hatası (Root Mean Square Error, RMSE) ifadesi, istatistikte değişen miktarın büyüklüğünün ve öngörünün başarısının ölçülmesinde kullanılan bir ölçüttür. Bu ifade ayrıca kuadratik ortalama olarak da adlandırılır. Karekök ortalama ismi ise karelerin ortalamasının karekökünün alınması nedeniyle kullanılmaktadır. Fiziksel olarak öngörülen ve gerçek değerler arasındaki fark ifadesinin karelerinin toplamının öngörülen gözlem sayısına bölümünün karekökü ile elde edilen bir değerdir. Ortalama Karekök Hatası ifadesinin matematiksel gösterimi şu şekildedir:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (3.2)$$

Burada \hat{y}_i modelde öngörülen değerleri, y_i ifadesi ise modelin uygulanması sonrasında elde edilen kestirilmiş değerleri, n ise kullanılan örnek sayısını göstermektedir. Bu ifade özellikle tahminleme ve kestirim problemleri için önemli bir verimlilik ve güvenilirlik ölçütü olarak kullanılmaktadır. Bir problem sonucunda ortaya çıkan RMSE değeri ne kadar küçükse, sistemin o kadar iyi bir doğruluk oranına sahip olduğu ve yüksek başarımlı gösterdiği anlaşılmaktadır.

BÖLÜM 4. UYGULAMADA KULLANILAN KESTİRİM MODELLERİ

4.1. Yapay Sinir Ağları

Teknolojik gelişmelerin önemli aşamalar kaydettiği günümüzde, bilgisayar yazılımlarının kullanımının hızla yaygınlaşması yapay zeka (artificial intelligence) çalışmalarındaki artışı da beraberinde getirmektedir. Yapay zeka, “insanın düşünce yapısını anlayabilmek için birtakım metodolojiler geliştirmek ve bunun benzerlerini ortaya çıkaracak bilgisayar işlemleri geliştirmeye çalışmak” prensibi ile ortaya çıkmıştır. Bir diğer deyişle yapay zeka programlanmış bilgisayarlara düşünme yeteneği kazandırabilme girişimi olarak tanımlanabilir. 20. yüzyılın ortalarından itibaren süregelen yapay zeka çalışmaları mühendislik, biyoloji, nöroloji ve psikoloji gibi alanlara yayılmıştır. Bununla birlikte insan gibi düşünen ve davranabilen sistemlerin geliştirilme çalışmalarında bugün gelinen nokta itibariyle tam olarak başarı sağlandığı söylenememektedir.

Yapay zeka uygulamalarının temel alanlarından birisi de Yapay Sinir Ağları modelidir. Kestirim ve öngörü modellemesi alanında yaygın bir şekilde kullanılmakta olan bu matematiksel model, temel olarak insan beyninin çalışma şeklini taklit eden yapay zeka uygulaması olarak tanımlanabilir. Evrensel Fonksiyon Yakınsayıcı Yöntem (Universal Function Approximators) olarak ifade edilen bu model, veriden öğrenebilme kapasitesi, sınırsız sayıda değişken ile çalışabilme, genelleme yapabilme gibi önemli özelliklere sahiptir. İnsan beyninin en temel işlem elemanı olan nöronları (neuron) şekilsel ve işlevsel olarak olarak taklit eden, bu şekilde insanoğluna özgü yaşayarak ve deneyerek öğrenme yeteneğini bilgisayar ortamına taşıdığı düşünülen bu yöntem, bilgisayar sistemine inanılmaz bir girdi verilerden öğrenebilme kapasitesi sağlamaktadır.

Biyolojik sistemlerde öğrenme, nöronlar arasındaki sinaptik (synaptic) bağlantıların ayarlanması ile olur, yani bir diğer deyişle, insanlar doğumlarından itibaren bir “yaşayarak öğrenme” süreci içerisine girerler [51]. Bu uzun süreç içerisinde beyin sürekli olarak gelişme gösterir, yaşayıp tecrübe ettikçe sinaptik bağlantılar tekrar ayarlanır ve hatta yeni bağlantılar oluşur ve bu sayede etkin bir öğrenme gerçekleşir. Bu durum sürekli öğrenme, hafızaya alma, eğitime ve veriler arasındaki ilişkiyi ortaya çıkarma kapasitesine sahip olan ANN’ler için de geçerlidir. Bu yaklaşım, eğitim algoritmaları kullanılarak girdi ve çıktı verilerin işlenmesi, bu verilerin ağırlık fonksiyonlarında belirli bir kurala göre yakınsama sağlanana kadar tekrarlanarak ayarlanması ile gerçekleştirilmektedir.

Matematiksel olarak bakıldığında ANN’ler, ağırlıklandırılmış şekilde birbirine bağlanmış bulunan çok sayıda nöronlardan oluşmaktadır ve herbir işlem elemanının bir transfer fonksiyonu olarak düşünüldüğü denklemlerdir. İşlem elemanı nöronlardan gelen sinyalleri toplar, bunları birleştirir, belirli kurallara göre dönüştürerek bir sayısal sonuç ortaya çıkarır. ANN’leri herbiri büyük bir problemin bir parçası olarak eş zamanlı çalışan çok sayıda ve basit işlem elemanlarından oluşan bir yapı olarak tarif etmek mümkündür. Her bir işlem elemanı bir girdiyi bir ağırlık kümesi ile ağırlıklandırır, doğrusal olmayan bir şekilde dönüşümünü sağlar ve bir çıktı değeri oluşturur [51]. Tüm bu işlemler her işlem elemanı için basit gibi görünüyorsa da, toplam işlem yükünü paylaşan elemanlar arasındaki yoğun bağlantı sinir ağının hata oranını azaltan en önemli faktördür.

4.1.1. Yapay sinir ağlarının tarihsel gelişimi

İnsan beyninin çalışma sistemi ve fonksiyonları uzun yıllar boyunca araştırılmıştır. 1940’tan önceki yıllarda bazı bilim adamlarının yapay sinir ağı kavramı üzerinde çalıştıkları bilinmektedir ancak bu çalışmaların mühendislik değeri olduğu söylenemez. 1940’lı yıllardan sonra Hebb, McCulloch ve Pitts gibi bilim adamları gerçekleştirilen araştırmaları mühendislik alanlarına kaydırmaya başlamışlardır. Özellikle ilk yapay sinir hücresinin yapısı ortaya konulması günümüzdeki yapay sinir ağlarının temellerini oluşturmuştur. Araştırmacılar yapay sinir ağları ile her türlü mantıksal ifadeyi formülize etmenin mümkün olabileceğini göstermişlerdir. Bununla

birlikte hücrelerin birbiriyle paralel çalışması gerektiği fikrini ortaya atarak öğrenme kurallarını belirlemeye başlamışlardır.

Yapay sinir ağlarında ilk girişimler McCulloch ve Pitts'in 1943 yılında nöroloji konusunda ortaya attıkları modellerle başlamıştır. Bu modeller geliştirilirken nöronların çalışma şekilleri hakkında birtakım varsayımlarda bulunmuştur. Ortaya konulan ağlar, sabit eşik değerlerine sahip olarak ikili (binary) nöronları baz almıştır. Model çıktıları ise ve / veya şeklindeki basit mantıksal fonksiyonlardı. Büyük işlemcilerin geliştirilmeye başlandığı 1950'li yıllarda, beyin hücrelerinin taklidini gerçekleştiren sinir ağlarının oluşturulabilmesi mümkün hale gelmiştir. Yapay sinir ağı simülasyonları dijital işlemcilerin geliştirilmesinden sonra ise büyük bir ivme kazanmıştır. IBM araştırmacılarından Farley ve Clark 1954 yılında, Rochester, Holland, Haibit ve Duda ise 1956 yılında bilgisayar simülasyonları yardımıyla bu konuda yeni girişimde bulunmuşlardır. Özellikle nörobilimcilerle beraber gerçekleştirilen çalışmalar, bu konudaki çoklu disiplinli bir çalışma trendinin gelişimine de öncülük etmiştir.

Yapay sinir ağlarının gelişiminde sadece nörobilimin etkisi yoktur, bununla birlikte mühendisler ve psikologlar da sinir ağı simülasyonlarındaki ilerlemelere büyük katkıda bulunmuştur. Rosenblatt, 1958 yılında algılama ağını (perception) geliştirdikten sonra, bu alandaki etkinlikler daha da canlanmıştır [51]. Algılama ağı prensip olarak üç tabaka halinde tasarlanmıştı ve ortadaki tabaka birleştirme tabakası olarak adlandırılıyordu. Bu ağ, bir veri girdi kümesinin rassal bir çıktıya bağlanma veya birleşme şeklinde bağlantı ağırlıklarının ilişkiye göre ayarlayarak öğrenebilmekteydi. Stanford Üniversitesinden Hoff ve Widrow, 1960 yılında basit bir analog elektronik alet olan ADALINE'ı geliştirmiştir. Bu sistem en küçük ortalama kareler (LMS - Least Mean Square) algoritmasını kullanmaktadır ve bu yönüyle algılama ağından farklılaşmaktadır.

Bununla beraber, bu alandaki araştırmalar ve çalışmalar her ne kadar büyük bir ilgi ile başlamış olsa da beklenen gelişmelerin gerçekleşmemesi ve birtakım problemlerin çıkması sonucunda konuya bir süre ilgi azalmış ve suskunluk dönemine girilmiştir. Minsky ve Papert, 1969 yılında yayınladıkları bir kitapta, araştırmacılar arasında ön

plana çıkan ve ekstra analiz yapılmadan kabul gören olumsuzlukları toplamışlardır. Bu kitapta tek tabakalı algılama ağının, çok tabakalı sistemlere göre bir takım sınırlamaları olduğu belirtilmiştir. Yazarların sezgisel görüşleri, çok tabakalı sistemlere genişlemenin verimsiz olduğunu ortaya koymaktadır. Araştırmacılar tarafından ortaya çıkarılan ve iteratürde XOR problemi olarak bilinen bu sorun nedeniyle, yapay sinir ağları konusunda önyargılar oluşmuş, araştırma bütçelerinde kısıntıya gidilmiştir.

Bilimsel ve maddi katkıların minimum olduğu bu dönemde, yine Minsky ve Papert tarafından tanımlanan ve sinir ağları sınırlamalarını etkisiz kılan yeni bir teknoloji geliştirilmiştir. Yapay sinir ağlarının tarihsel gelişimi bakımından Rummelhart ve arkadaşlarının literatüre katkısı oldukça büyüktür. Paralel programlama konusundaki bu çalışmalar sonucunda, çok katmanlı algılayıcıların bulunması ile XOR problemi çözülmüş ve yapay sinir ağlarının çalışmadığını söyleyen tüm tezler çürütülmüştür [52]. Yapay sinir ağları konusunda bilimadamları tarafından ortaya konulan birtakım paradigmlar bulunmaktadır. Klopff, 1972 yılında heterostasis olarak adlandırılan ve nöronsal öğrenmenin biyolojik prensiplerine dayanan bir temel oluşturduğu bir model ortaya koymuştur.

Werbos, 1974 yılında geribesleme öğrenme metodunu geliştirmiş ve bu metod birkaç yıl sonrasında büyük popüleriteye sahip olmuştur. Günümüzde geribesleme ağ modeli en çok bilinen ve kullanılan yapay sinir ağlarıdır. Fukishima tarafından 1975 yılında el yazısı karakterlerini yorumlamak için adım adım (step wise) eğitilmiş çok katmanlı bir ağ modeli ortaya konulmuştur. 1980 yılında beyin fonksiyonları hakkında bilgi veren ilk eser yayınlanmıştır. Kohonen, 1982 yılında kendi kendine öğrenme nitelik haritaları (self-organizing feature maps - SOM) konusundaki çalışmasını yayınlamıştır. Grossberg, yapay sinir ağlarının mühendislik uygulamalarındaki kolaylığını ve psikolojik mantıksallığını göstermiş, Carpenter ile birlikte Adaptif Rezonans Teorisini (ART) geliştirmiştir. Bu teori ile öğretmensiz öğrenme konusunda zamanının geliştirilmiş en karmaşık yapay sinir ağı literatüre kazandırılmıştır.

1986'da Rumelhard ileri beslemeli modellerde yeni bir öğrenme modeli oluşturarak hatanın geriye yayılımı algoritmasını (Back Propagation) geliştirmiştir. 1988'de Broomhead ve Lowe, çok katmanlı ağlara alternatif olarak radyal temelli fonksiyonlar

modelini (Radial Basis Functions - RBF) geliřtirmiřtir [52]. Daha sonra Specht bu ađların geliřmiř řekli olan olasılıksal (PNN) ve genel regresyon ađlarını (GRNN) geliřtirmiřtir. 1995 yılında gerekleřtirilen alıřmalarda yankı algoritmalarını arařtıran bir dűřünce okulunun temellerini atarken, bu yazarlar őrüntü sınıflandırma ve hata dűzeltme metodu konularında matematiksel modeller geliřtirmiřtir.

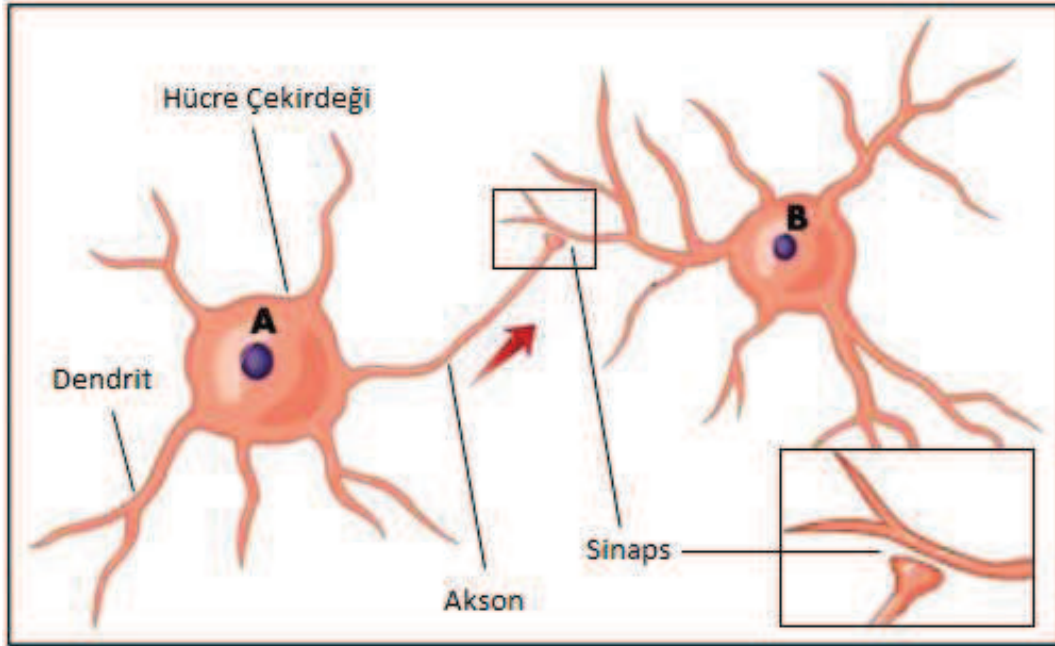
1970'li yılların sonları ile 1980'li yılların bařlarındaki bu ivmelenme yapay sinir ađları alanına ilginin yeniden canlanması bakımından ok őrnelidir. őrzellikle kitaplar, dergiler, konferanslar ve akademik programların etkisiyle arařtırma projelerine ynelik fonlar ve arařtırma merkezlerinin sayısında artıř trendine girilmiřtir. Son yıllarda yapay sinir ađları alanı sinir sistemi tabanlı iřlemcilerin geliřtirilmesi ve komplike problemlerin özümüne ynelik uygulamalar ile bilim dűnyası tarafından yođun ilgi ve katkı gormektedir.

4.1.2. Biyolojik sinir hücreleri ve yapay sinir ađları

Günümüzde yođun olarak kestirim, eřleřtirme, sistem tanımlama, őrüntü tanıma, kontrol ve optimizasyon uygulamalarında kullanılmakta olan ANN modeli, karmařık matematiksel iřlemlerin ve ok sayıda deđiřken parametrenin bulunduğu problemlerin özümünde bařarısını kanıtlamıřtır [53]. ANN modeli iřlem elemanları ile karakterize edilir ve her bir iřlem elemanı giriř, ađırlıklar, birleřme fonksiyonu, transfer fonksiyonu ve ıkıřlar olmak üzere beř temel өгeden oluřur. ANN'ler őrzellikle dođrusal olmayan sistemlerin kontrolü ve modellenmesinde büyük kolaylıklar sađlamaktadır. Genel olarak bir biyolojik sinir hűresinin gürnümüleri řekil 4.1'de verilmektedir.

Nöronlar, insan beyninin hatırlama, dűřünme, gemiř deneyimlere bařvurarak bir sonraki hareketi öngörme yeteneđine sahip temel paralarıdır. Sinir hücreleri arasındaki iletiřim ve bilgi geiřleri, hücrelerin birbiri ile temas etmeden kimyasal bir maddenin salgılanması ile Sinaps üzerinden sađlanmaktadır. oklu giriřli liflere sahip olan Dendrit ile uzun tařıyıcılı bir life sahip olan Akson birbirine yaklařır. Aksonun ucuna bilgi ulařtıđı zaman salgılanan kimyasal bir madde vasıtasıyla tek yönlü veri geiři sađlanır ve bu nedenle haberleřme tek taraflıdır. Sinir hücreleri uyarıldıkları

zaman ani bir aksiyon potansiyeli oluşur ve çok kısa süreli olan bu olaya sinirsel darbeler ya da darbe boşalması adı verilmektedir.



Şekil 4.1. İki farklı sinir ağının fiziksel yapısı ve etkileşimi

Yapay sinir ağları, yapı gereği ilgilendiği problemi öğrendikten sonra eğitim sırasında karşılaşmadığı test örnekleri için arzu edilen tepkileri de üretebilir. Örneğin karakter tanıma amacıyla eğitilmiş bir sinir ağı, bozuk karakter girişlerinde de doğru karakteri verebilir ya da bir sistemin eğitilmiş sinir ağı modeli eğitim sürecinde verilmeyen giriş sinyalleri için de sistemle aynı davranışı gösterebilir [54]. Dolayısı ile görülmemiş örnekler hakkında genelleme yaparak bilgi üretebilme kapasitesine sahip olan yapay sinir ağları eksik bilgi içeren sistemlerin modellenerek eksik bilgiye ulaşılabilmesi konusunda oldukça başarılıdır. Ayrıca belirli bir problemi çözmek amacıyla eğitilen yapay sinir ağları, problemdeki değişimlere göre tekrar eğitilebilir, değişimler devamlı ise gerçek zamanda da eğitime devam edilebilir [54].

Yapay sinir ağı modeli için en önemli kriterlerden birisi de kullanılan örnek veri kümesidir. Yapay sinir ağlarının istenilen davranışı gösterebilmesi için amaca uygun olarak ayarlanması gerekir ve bu hücreler arasındaki bağlantıların uygun ağırlıklarda olması gerektiğini ifade eder. Ancak sinir ağları karmaşık bir yapıya sahiptir, dolayısı ile bağlantılar ve ağırlıklar önceden ayarlı olarak verilemez ya da tasarlanamaz [54]. Bu nedenle sinir ağı, ilgilenilen problemde alınan eğitim örneklerini kullanarak problemi öğrenmelidir.

Seri bilgi işleme yapan sistemlerde, herhangi bir birimin hatalı çalışması ya da bozulmuş olması tüm sistemde hataların oluşmasına neden olmaktadır. Ancak paralel bilgi işleme yapan sistemlerde, sistemin ayrı işlem elemanlarından dolayı ortaya çıkan hatalı çalışma ya da hasar, sistem performansında ciddi bir infiale yol açmadan, sadece performansın hatalı birimlerinin bir oranı ile düşmesine sebep olmaktadır. Yapay sinir ağları paralel bilgi işleme yapan bir yapıdadır ve hatayı tolere etme yetenekleri son derece gelişmiştir. Yapay sinir ağlarında genel olarak bilgi, ağdaki bağlantıların değerleri ile ölçülmektedir ve bu bilgiler ağın içerisinde saklı olup ortaya çıkartılması oldukça zordur. Ağı oluşturan her işlem birimi çözülecek problemin tamamı ile ilgilenmek yerine, problemin gerekli parçası ile ilgilenir. Her bir hücre çok basit bir işlem yapmasına rağmen, sağlanan bu görev paylaşımının sayesinde çok karmaşık problemler kolayca ve büyük bir hızla çözülmektedir [54].

Yapay sinir ağlarında bilgi ağa yayılmaktadır, diğer bir deyişle hücrelerin birbirine bağlantılarının değerleri ağın bilgisini göstermektedir. Ağın tamamı, öğrenmiş olduğu olayın bütünü karakterize eder ve bu yapı ile doğrusal olmayan karmaşık problemlerin çözümü kolaylaşmaktadır. Sinir ağını oluşturan sinir hücreleri üç katman halinde bir araya gelerek ana yapıyı oluşturmaktadır. Genel olarak bir yapay sinir ağı hücresi, giriş, ağırlık, toplama, aktivasyon fonksiyonu ve çıkış olmak üzere beş ana bileşenden meydana gelir. Ağın öğrenmesi istenen örnekler tarafından belirlenen ve dış dünyadan gelen girdi bilgileri giriş değerleri olarak adlandırılır. Gelen bilginin hücre üzerindeki etkisi ve bu bilginin önemi ağırlık değerleri göstermektedir. Ağırlıkların büyük, küçük, negatif ya da pozitif değerli olması başlı başına bir anlam ifade etmez, dolayısı ile bu değerlerin ağın tamamındaki etkisini göz önüne almak gerekmektedir. Eğer ağırlık değerleri sıfır ise bu ilgili ağırlığın bir etkisinin olmadığını gösterir.

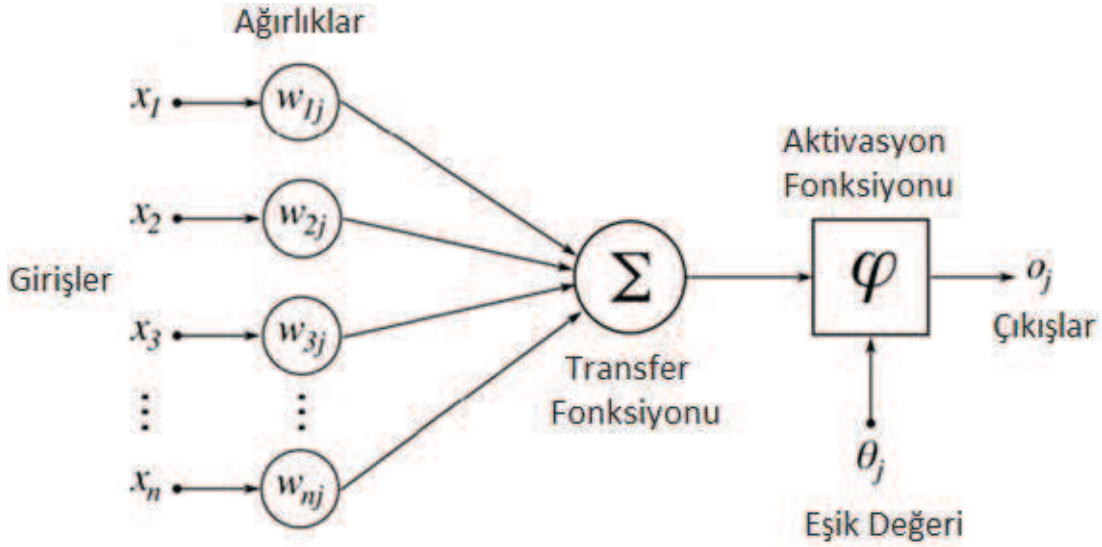
Ağa gelen net girdi, her bir girdi değerinin kendi ağırlığı ile çarpılması ve birbirleriyle toplanması ile bulunur. Bu, toplama fonksiyonu olarak tanımlanan ve her problem karşısında farklı formüller kullanılarak ortaya konulan işlem ile gerçekleştirilir. Burada her proses elemanı aynı ya da bağımsız olarak farklı bir toplama fonksiyonuna sahip olabilmektedir. Toplama fonksiyonu genel olarak deneme yanılma metodu ile belirlenir. Hücreye gelen net girdi, aktivasyon fonksiyonu olarak tanımlanan ve gelen

girdiye karşı çıktı bilgisini belirleyen bir işleme tabi tutulur. Aktivasyon fonksiyonu olarak değişik formüller kullanılabilir. Bu fonksiyon tarafından belirlenen çıktı değerleri ise sinir ağının çıkış değerleri olarak adlandırılır ve bu bilgi dış dünyaya aktarılır.

Bir proses elemanı olarak da düşünülen yapay sinir hücreleri girdi katmanı vasıtasıyla dış dünyadan bilgileri alır ve herhangi bir işleme tabi tutmadan ara katmana iletir. Gelen bu bilgiler ara katmanda işlenir ve çıktı katmanı üzerinden dış dünyaya gönderilir. Buradan anlaşıldığı üzere yapay sinir ağlarında bir proses elemanının birden fazla çıktısı görülmesine rağmen aslında tek bir çıktı değeri vardır, aynı değer birden fazla proses elemanın girdi olarak gitmektedir [54]. Yapay sinir ağları işlevlerine göre statik ya da dinamik davranışlar göstermektedir.

Ağırlıklar giriş değerlerinin işlem elemanı üzerindeki etkisini kontrol eder ve sinir ağının bilgisinin depolandığı birimlerdir. Değişken değerler alabilen ağırlıklar, ağırlık giriş ve çıkışları arasındaki optimum ilişkiyi yakalayabilmek için öğrenme algoritmaları tarafından sürekli olarak değiştirilirler. Birleşme fonksiyonu, işlem elemanından gelen bilgileri birleştirir ve en sık kullanılan fonksiyon toplam fonksiyonudur.

Transfer veya aktivasyon fonksiyonu, birleştirme fonksiyonun sonucunu değerlendirir ve bu fonksiyon aldığı değeri bir algoritma ile gerçek bir çıktıya dönüştürür. En yaygın kullanılan fonksiyonlar sigmoid, lineer ve basamak fonksiyonlarıdır. Transfer fonksiyonundan çıkan değerler ise sinir ağının çıktısıdır. Bir yapay sinir ağı modeline ilişkin detaylı blok diyagram ve sinir ağını oluşturan birimler, Şekil 4.2'de verilmektedir.



Şekil 4.2. Yapay sinir ağı blok diyagramı

Bir yapay sinir ağı sisteminin matematiksel gösterimi şu şekilde verilmektedir:

$$o_j = \varphi(\sum_i^n x_i w_{nj} + b) \quad (4.1)$$

Burada φ aktivasyon fonksiyonu, $i=0, 1, 2, \dots, n$ olmak üzere x_i değeri giriş nöronları, w_{nj} ağırlık, b bias değerini ve o ise çıkış nöronunu gösterir. Yapay sinir ağı geliştirme sürecinde veriler ikiye ayrılır. Bir bölümü ağın eğitilmesi için kullanılır ve eğitim seti adını alır, diğer bölümü ise ağın eğitim verileri dışındaki performansını ölçmede kullanılır ve test seti olarak adlandırılır [55]. Yapay sinir ağı öğrenme sürecinde, gerçek hayattaki problem alanına ilişkin veri ve sonuçlardan, bir başka deyişle örneklerden yararlanır. Gerçek hayattaki problem alanına ilişkin değişkenler yapay sinir ağının girdi dizisini, bu değişkenlerle elde edilmiş gerçek hayata ilişkin sonuçlar ise yapay sinir ağının ulaşması gereken hedef çıktıların dizisini oluşturur.

Test işlemi için, eğitim setinde kullanılmayan verilerden oluşan test seti kullanılır. Test setindeki girdiler sinir ağı modeline verilir ve ağın çıktı değeri ile istenilen çıktı değeri karşılaştırılır. Amaç, sinir ağı modelinin yeterli bir genelleme yapıp yapamadığını görmektir. Eğitim ve test aşamalarında istenilen başarı elde edilirse sinir ağı modeli kullanılabilir. Eldeki verinin % 25 ile % 90 arasında değişen miktarı eğitim seti olarak seçilir. Geri kalan kısım ise test seti olarak ayrılır. Eğitim ve test setleriyle ilgili temel sorun, yeterli eğitim ve test verisinin miktarının ne olduğu şeklindedir.

Sınırsız sayıda verinin bulunabildiği durumlarda, yapay sinir ağı mümkün olan en çok veriyle eğitilmelidir. Eğitim verisinin yeterli olup olmadığı konusunda emin olmanın yolu ise eğitim verisinin miktarının artırılması ile ağın performansında bir değişiklik yaratıp yaratmadığının takibi ile anlaşılmaktadır. Ancak bunun mümkün olmadığı durumlarda yapay sinir ağının eğitim ve test verileri üzerindeki performansının yakın olması da verilerin sayıca yeterli olduğuna ilişkin bir gösterge olarak kabul edilebilir. Bununla birlikte eğitim setinin içermesi gereken veri miktarı değişik yapay sinir ağı modellerine göre ve özellikle problemin gösterdiği karmaşıklığa göre farklılık gösterebilmektedir.

4.1.3. Yapay sinir ağlarının sınıflandırılması

Yapay sinir ağları öğrenerek karar verme prensibi üzerine kurulmuştur ve öğrenme, sistemlerin benzeri işlemleri yaptığında, o işleri bir önceki yaptıkları şekilden daha verimli ve etkin olarak gerçekleştirecek şekilde değişiklikleri oluşturma süreci olarak tanımlanabilir [33]. Yapay sinir ağları, ileri beslemeli ve geri beslemeli ağlar olarak ikiye ayrılabilir. İleri beslemeli ağlar da kendi içerisinde tek katmanlı ve çok katmanlı olarak ikiye ayrılır. İleri beslemeli ağlarda işlem elemanları birbiri ardına sıralanır.

Bu ağ modelinde nöronların yalnız bir sonraki katmanda bulunan nöronlar ile bağlantısı bulunmaktadır, yani önceki katmanlar veya aynı katmandaki diğer nöronlar ile bağlantısı bulunmamaktadır. Tek katmanlı ileri beslemeli ağlarda, yalnızca giriş ve çıkış katmanları bulunurken, çok katmanlı ileri beslemeli ağlarda ise giriş ve çıkış katmanları arasında gizli katmanlar bulunur. Ağ yapısında girişler ilk olarak gizli katmana bağlanırken gizli katman çıkışları ise bir sonraki gizli katmanın girişlerine bağlanır. Yapı bu şekilde gizli katman tabakaları bitene kadar tekrarlanarak devam eder.

Girdi katmanında herhangi bir işlem yapılmaz, ancak girdi katmanındaki her işlem elemanı, bir sonraki gizli katmandaki işlem elemanları ile bağlantılıdır. Bu ağlarda birden fazla gizli katman olabilir ve gizli katmanda bulunan her bir işlem elemanı çıkış katmanındaki her bir işlem elemanı ile ilişkilidir. Gizli katmandan gelen tüm bilgiler çıkış katmanında işlenmekte ve çıktı olarak dışarıya verilmektedir. Her düğüm bir

sonraki düğüme tamamen bağlanıyorsa tam bağlı ağ, eğer kısmen bağlanıyorsa kısmi bağlı ağ olarak adlandırılır. İleri beslemeli ağlar sistem tanıma, kestirim ve denetiminde yaygın olarak kullanılmaktadır. Bu tür sinir ağlarında temel amaç sinaptik ağırlıkların ayarlanarak girdi çıktı arasındaki ilişkinin öğrenmeye çalışılmasına dayanır. Hopfield, Elman ve Jordan ağları bu ağlara örnek olarak gösterilebilir.

Geri beslemeli yapay sinir ağları, çıkış ya da ara katmanlardaki çıkışların giriş birimlerine ya da önceki ara katmanlara geri beslendiği bir ağ yapısı olarak tanımlanabilir. Dolayısı ile girişler hem ileri yönde hem de geri yönde aktarılmış olur. Bu tip ağların dinamik bir hafızası bulunur ve bir andaki çıkış hem o anı hem de daha önceki giriş değerlerini yansıtır. Bu nedenle geri beslemeli ağlar önceden tahmin uygulamaları için çok uygundur.

Geri beslemeli ağlarda en az bir hücrenin çıkışı kendisine kendisine ya da diğer hücrelere giriş olarak verilir ve geri besleme işlemi, hücre içi ya da hücreler arası bir geciktirici üzerinden gerçekleştirilir. Geri besleme işleminin yapılış şekline göre farklı yapı ve davranışlarda ağ yapıları elde edilir. Geriye doğru hesaplamada, ağın ürettiği çıktı değeri ile ağın beklenen çıktıları kıyaslanır ve bunlar arasındaki fark, hata değeri olarak kabul edilir. Çıktı katmanında oluşan toplam hatayı bulmak için tüm hata değerlerinin toplanması gereklidir ve temel amaç bu hatanın minimum değerlere düşürülmesidir.

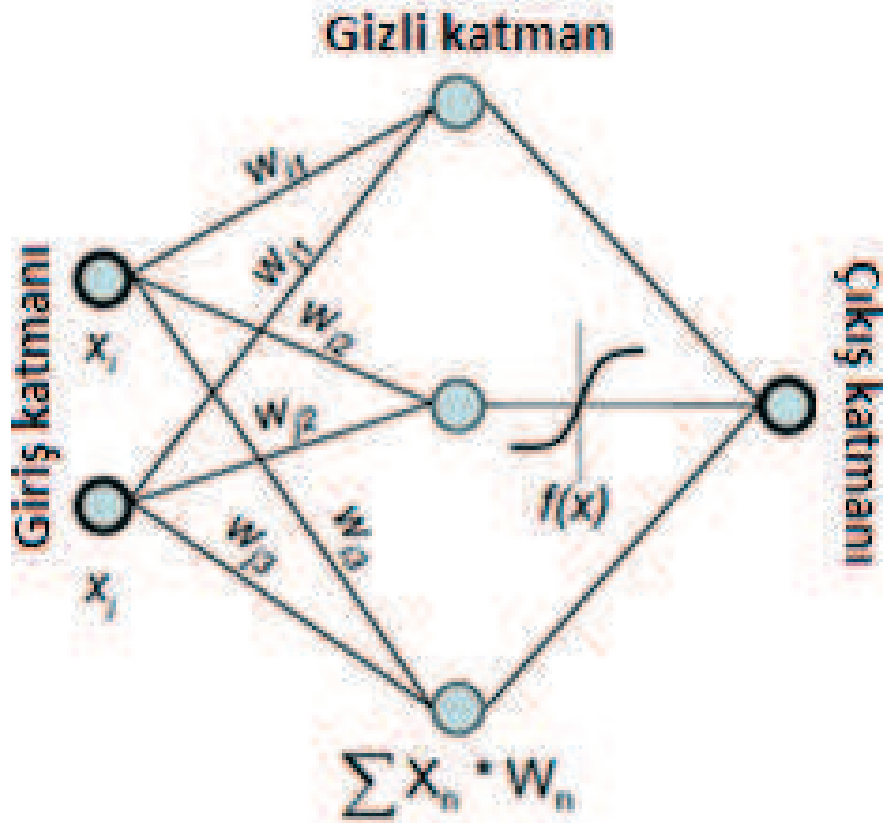
Yapay sinir ağı modelleri, eğitim ve öğrenme fonksiyonu açısından danışmalı ve danışmasız olmak üzere ikiye ayrılır [51]. Sinir ağlarında bilgi ağıdaki bağlantıların ağırlıklarında depolanmaktadır ve bir ağın öğrenme süreci, bu ağırlıkların istenilen işlevi yerine getirecek şekilde ağırlıkların ayarlanması sürecidir. Kullanılan eğitim algoritmasının kurallarına bağlı olarak ağırlıklar dinamik olarak değiştirilebiliyorsa bu tür ağlara eğitilebilen ağlar denir. Bu tür ağlar yeni şekilleri tanıyabilir ya da bir girişin hangi sınıfa ait olduğunu çözebilir. Danışmalı öğrenmede yapay sinir ağı, eğitim kümesi olarak adlandırılan ve daha önceki giriş ve çıkış değerlerinin bulunduğu veri seti vasıtasıyla eğitilir. Toplam ağ hatasının kabul edilebilir hatadan daha büyük olması durumunda ağırlık matrisi güncelleştirilir. Eğitim setinde her bir giriş kümesine

karşılık olarak uygun bir çıkış kümesi bulunmalıdır ve istenilen istatistiksel doğruluk oranı yakalandığında eğitim işlemi tamamlanır.

Yapay sinir ağları sayısal giriş bilgileri ile çalışır ve bu nedenle ham bilgilerin ölçeklendirilmesi gerekir. Danışmalı öğrenmede performans kriteri hata terimidir ve hata fonksiyonunun minimum olduğu noktada iterasyon durdurulur. Danışmalı eğitimin en büyük dezavantajı, bir eğitici olmadan ağın yeni bir strateji öğrenme şansına sahip olmamasıdır. Danışmasız öğrenmede, eğitim işinden sorumlu herhangi bir eğitici bulunmamaktadır. Sinir ağı birbirine benzer giriş bilgilerini gruplamakta ya da giriş bilgisinin hangi gruba ait olduğunu göstermektedir [51]. Dolayısı ile ağ eğitimi için sadece giriş bilgilerine sahip olunması yeterlidir ve eğitici bilgiye ihtiyaç duymamaktadır. Sinir ağı giriş sinyallerinin yönüne ve düzenine göre ayarlama yapmaktadır ve ağ performansını kendiliğinden izlemektedir. Danışmasız öğrenmeye Hebbian öğrenme kuralı, rekabe dayalı öğrenme ve kendi kendine öğrenme algoritmaları örnek olarak verilebilir.

4.1.4. Çok katmanlı ağlar

Yapay sinir ağlarının ilk geliştirilen modellerinden olan doğrusal ve tek katmanlı ağ yapısı doğrusal olmayan problemleri öğrenmekte çok başarısız olmuştur. Bu sorunun çözümü literatüre çok katmanlı ağ yapısının geliştirilmesi ile çözülmüştür. Çok katmanlı ağlar giriş, çıkış ve bir ya da daha fazla gizli olmak üzere üç farklı tipteki katmanlardan oluşmaktadır. Bu tip ağların temel amacı ağın beklenen çıktısı ile gerçek çıktı arasındaki hatanın en aza indirilmesidir. Giriş ve çıkış katmanları arasındaki ilave gizli katmanlar ile ağ çok katmanlı olmaktadır. Gizli katman sayısının fazla olması ağın genelleme yapma kapasitesini düşürmektedir. Bununla birlikte gizli katman sayısının artması, ağın eğitimi için geçen süreyi de arttırmaktadır. Deneme yanılma yöntemi ile ağın çıkışı ile arzu edilen çıkış arasındaki hata tekrar geriye doğru yayılarak minimum seviyeye indirilinceye kadar ağın ağırlıklarını değiştirme yoluyla başarı arttırılabilir. Böylece optimum seviyedeki gizli katman sayısı tespit edilebilir. Yapay sinir ağları doğrusal olmayan sistemlerin modellenmesindeki başarısını çok katmanlı ağ yapısına borçludur [33]. Şekil 4.3 tek bir gizli katmanın kullanıldığı, çok katmanlı bir sinir ağı yapısını göstermektedir.

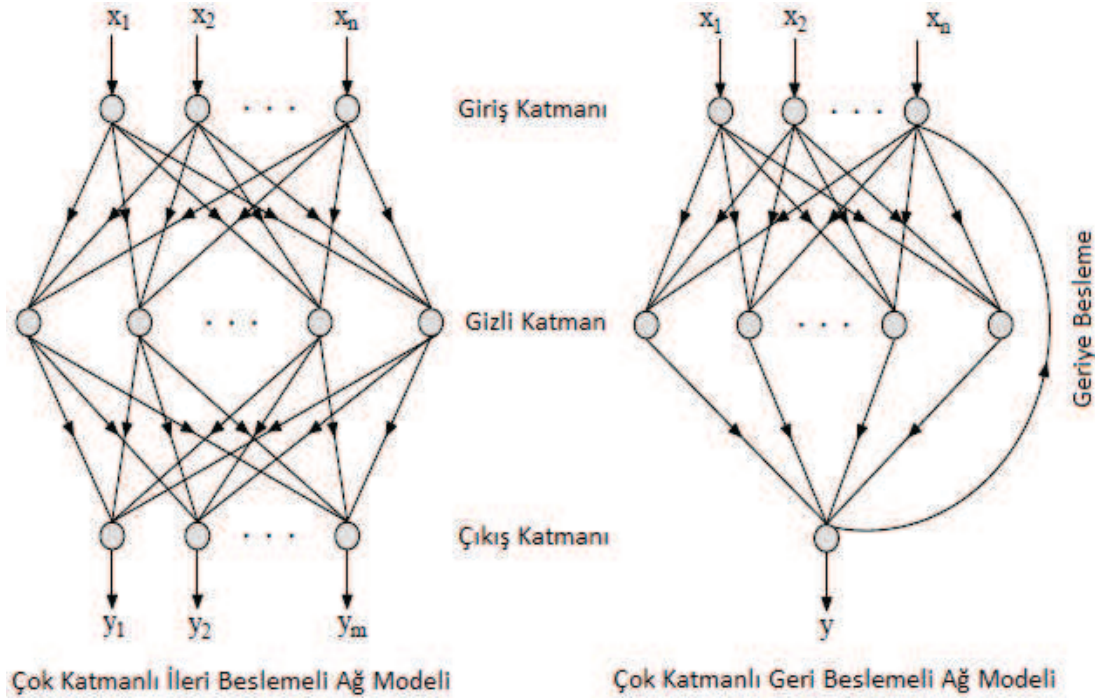


Şekil 4.3. Çok katmanlı bir sainsir ağı modeli

Yukarıdaki şekilde giriş katmanında iki, gizli katmanda üç ve çıkış katmanında da tek bir nöronun kullanıldığı görülmektedir. Gizli katman sayısı için genel bir ölçüt yoktur ve genellikle deneme yanılma yoluyla bulunur. Giriş katmanında yer alan giriş değerlerinin her biri birbirinden farklı ağırlık faktörleri ile çarpılır ve birbirlerine eklenir. Daha sonra bir transfer fonksiyonu vasıtasıyla çıkış katmanındaki kestirilecek değer elde edilir. Çok katmanlı ağ yapısı, danışmalı öğrenme prensibine göre çalışmaktadır ve bu ağlara bir eğitim kümesi halinde girdiler ve bu girdilere karşılık üretilmesi gereken çıktılar gösterilir. Ağ, belirlenen hata performans kriterine göre her tipteki girdiye karşılık gelen çıktıyı üretmeye çalışmaktadır.

Giriş ve çıkış katmanları sinyaller ile aynı sayıda nörona sahiptir ve gizli katman sayısı genel olarak deneme yanılma yolu ile bulunmaktadır. Geri beslemeli yapay sinir ağlarında, ileri beslemeli ağ yapısının aksine, bir nöronun çıktısı sadece kendinden sonra gelen nöron katmanına girdi olarak verilmez, kendinden önceki katmanda ya da kendi katmanında bulunan herhangi bir nörona girdi olarak bağlanabilir. Böylece doğrusal olmayan ve dinamik bir davranış gösterilmiş olur. Bu ağ yapısı herhangi bir

zamanadaki çıktı hem o andaki hem de daha önceki girdileri yansıttığı için dinamik bir hafızaya sahiptir. İleri ve geri beslemeli çok katmanlı ağ modeli Şekil 4.4'te karşılaştırmalı olarak gösterilmektedir.

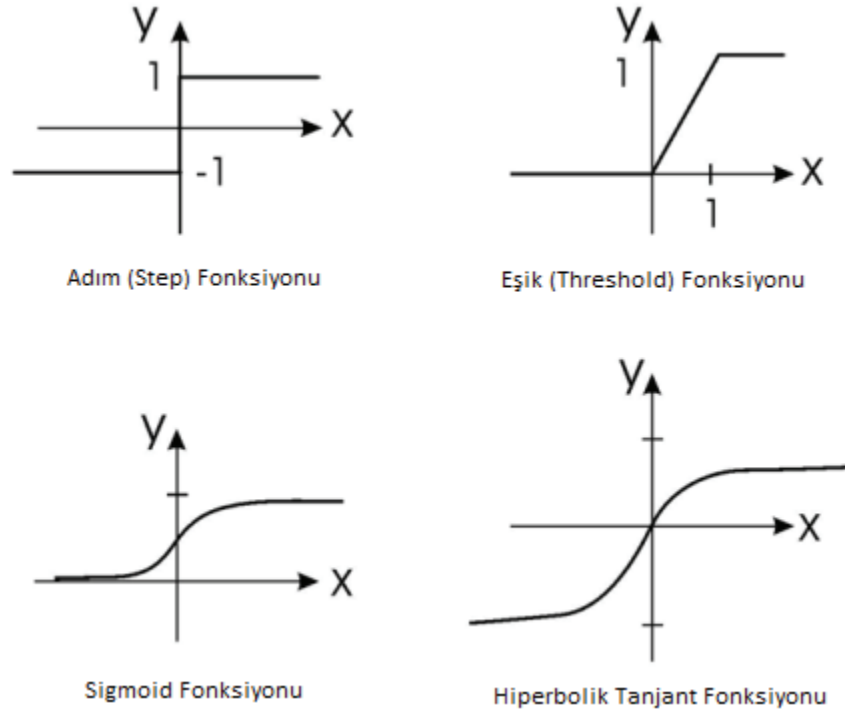


Şekil 4.4. İleri ve geri beslemeli ağ modelleri

4.1.5. Aktivasyon fonksiyonları

Yapay sinir ağı modelindeki en kritik öğelerden biri olan aktivasyon fonksiyonları, toplama fonksiyonundan elde edilen net girdinin işlemde geçirilmesiyle hücre çıktısının belirlendiği bir fonksiyondur [51]. Gerçekleştirilecek işleve göre aktivasyon fonksiyonunun sabit parametrelili ya da uyarlanabilir parametrelili mi olacağı, doğrusal ya da doğrusal olmayan bir formda olup olmayacağı belirlenir. Aktivasyon fonksiyonunun seçimi genellikle yapay sinir ağı verilerine ve ağın nasıl bir öğrenme isteği olduğuna bağlıdır. Sigmoid ve tanjant hiperbolik fonksiyonları genellikle en çok kullanılan fonksiyon çeşitleridir ve Şekil 4.5'te dört farklı fonksiyonun grafiği gösterilmektedir. Ağ modelinin ortalama davranışı öğrenmek isteniyorsa sigmoid fonksiyonu, ortalamadan sapmanın öğrenilmesi isteniyorsa da tanjant hiperbolik fonksiyonunun kullanılması avantajlı olacaktır. Aktivasyon fonksiyonları, yapay sinir ağı modelinde nöron çıkış genliğini genel olarak $[0,1]$ ya da $[-1,1]$ değerleri arasında

sınırlar. Kullanılacak aktivasyon fonksiyonunun türevinin alınabilir olması yani bir diğer deyişle sürekli olması gerekmektedir.



Şekil 4.5. Literatürde sıklıkla kullanılan transfer fonksiyonları

Transfer fonksiyonlarının doğrusal ya da doğrusal olmayan bir yapıda olması sayesinde karmaşık ve farklı türdeki problemlere uygun çözümler sağlanmaktadır. Doğrusal bir problemin çözümü için kullanılan doğrusal hücre ve özellikle çok katmanlı sinir ağının çıkış katmanında kullanılan doğrusal fonksiyon, hücre girdisini doğrudan doğruya hücre çıkışına verir. Sigmoid aktivasyon fonksiyonu, sürekli ve doğrusal olmayan bir yapıda olması nedeniyle sıklıkla kullanılmaktadır ve girdinin her değeri için sıfır ile bir arasında bir çıkış değeri üretir. Tanjant hiperbolik fonksiyonu ise giriş uzayının genişletilmesinde etkili bir fonksiyonudur ve çıkışlar -1 ile 1 aralığındadır. Literatürde kullanılan diğer aktivasyon fonksiyonları ise, step fonksiyonu, kutuplamalı step fonksiyonu, parçalı doğrusal fonksiyon, sinüs fonksiyonu ve eşik değer fonksiyonu olarak sayılabilir.

4.1.6. Öğrenme stratejileri

Yapay sinir ağlarında öğrenme, istenen çıktıları elde etmek için işlem elemanları arasındaki optimum ağırlıkların bulunması süreci olarak tarif edilebilir. Ağ boyunca

bilgi ifadesi tüm bağlantılarda ağırlıklar şeklinde dağıtıldığı için tek bir bağlantının anlamlı bir karşılığı yoktur. Bu nedenle öğrenme faaliyetinde ağ bir bütün olarak dikkate alınmaktadır. Problemlerin en küçük hata ile çözülebilmesi için ağ bağlantılarının doğru ağırlık değerlerine sahip olması gerekir ve bu işlem öğrenme kuralları ile gerçekleştirilmektedir. Yapay sinir ağlarında genel olarak, öğretmenli öğrenme, destekli öğrenme ve öğretmensiz öğrenme olarak üç tip öğrenme stratejisinden söz edilebilir.

Öğretmenli (supervised) öğrenmede bir öğretmene ihtiyaç vardır ve bu öğretmen sisteme öğrenilmesi istenen problemlerin girdi ve çıktılarını vermektedir. Sistemin ürettiği çıktılar ile gerçek çıktılar karşılaştırılır. Eğer istenen minimum hata oranına yakalanamamış ve tatmin edici sonuçlar elde edilememişse ağırlıklar yeniden ayarlanır. Bu döngüsel işlemler istenen sonuçlar elde edilinceye kadar devam etmektedir ve bu tip öğrenmeye örnek olarak delta ve geriye yayılım öğrenme prosedürlerini verilebilir. Destekli (reinforcement) öğrenme, öğretmenli öğrenmenin özel bir türüdür ve bu stratejide sisteme bir öğretmen yardımcı olur. Öğretmen sisteme çıktının ne olması gerektiğini değil de doğru yada yanlış olduğunu belirten bir sinyal gönderir [56]. Sistem sözkonusu sinyali dikkate alarak öğrenme sürecini devam ettirerek minimum hatayı yakalamaya çalışır. Bu öğrenme kuralını uygulayan sistemlere LVQ (Linear Vektör Quantization) ağı örnek olarak verilebilir.

Öğretmensiz (unsupervised) öğrenmede herhangi bir öğretmene ihtiyaç yoktur. Diğer bir deyişle öğrenme işlemi problemin gerçek çıktılarına ihtiyaç duymaksızın gerçekleşmektedir. Dolayısı ile sistem istenilen çıktıları kendi kendine üretmektedir ve bu strateji daha çok sınıflandırma problemleri için kullanılmaktadır. Bu öğrenme tipine örnek olarak Grossberg ve Hebbian öğrenmeleri verilebilir. Bununla birlikte bazı ağlar yukarıda açıklanan stratejilerden bazılarını birlikte kullanarak öğrenme işlemini gerçekleştirirler. Karma tip öğrenme olarak adlandırılan bu yapıdaki ağlar, kısmen öğretmenli, kısmen ise öğretmensiz olarak öğrenme yapmaktadır. Radial tabanlı yapay sinir ağları ve olasılık tabanlı ağlar bu tip öğrenme yöntemlerine örnek olarak verilebilir [56].

Yapay sinir ağlarında eğitime işleminin tamamlanması için genel olarak iki seçenek mevcuttur. Bunlardan birincisi belli miktardaki hata toleransını göze almak ve o hata değerinden daha düşük hata değerine ulaşmaya kadar eğitim işlemini sürdürmektir. Bu durumda hata miktarının değeri, eğitime sayısına göre daha önceliklidir. Diğer seçenek ise sabit bir eğitim sayısının seçilerek, belirlenen eğitime sayısı sonunda elde edilecek hatayı kabul etmek şeklinde özetlenebilir. Yapay sinir ağları modellerinde özellikle son dönemde hızlı ve etkili bir eğitim algoritması olan Levenberg-Marquard yöntemi sıkça kullanılmaktadır. Bu algoritma, temel olarak maksimum komşuluk fikri üzerine kurulmuş bir en küçük kareler hesaplama metodudur. Gauss-Newton ve Steepest-Descent algoritmalarının en iyi özelliklerinden yararlanılarak ortaya çıkartılan Levenberg-Marquard algoritması, bu iki metodun kısıtlamalarını ortadan kaldırmaktadır ve özellikle yavaş yakınsama problemlerinden etkilenmemektedir.

4.2. Çoklu Doğrusal Regresyon Modeli

Regresyon analizi bağımlı bir değişken ile bir ya da daha fazla bağımsız değişkenin bağlantı ve nedensellik ilişkisini inceleyen istatistiksel bir araştırma yöntemidir [57]. İki ya da daha fazla değişken arasında bir ilişki olup olmadığını, ilişki varsa gücünü ve yönünü inceleyen korelasyon analizi ile değişkenlerden birinin belli bir birim değişiminde diğerlerinin nasıl bir değişim gösterdiğini inceleyen regresyon analizi, bilimsel araştırmalarda yoğun olarak kullanılan istatistiksel yaklaşımlardır. Bağımlı değişken, regresyon modelinde açıklanan veya tahmin edilen değişkendir ve bu değişkenin bağımsız değişken ile ilişkisi olduğu varsayılır [50]. Bağımsız değişkenin regresyon modelindeki rolü, açıklayıcı değişken olarak bağımlı değişkenin değerini tahmin etmek için kullanılmasıdır.

Regresyon analizi ile bağımlı ve bağımsız değişkenler arasında bir ilişki olup olmadığı, ilişki varsa bu ilişkinin gücü, değişkenler arası ilişkinin türü gibi soruların cevabı aranmaktadır. Bağımlı değişkene ilişkin ileriye dönük değerlerin tahmini ve belirli koşulların kontrol altına alınması durumunda özel bir değişken ya da değişkenler grubunun diğer değişkenler üzerindeki etkisi araştırılmaktadır. Regresyon analizinde iki değişken arasındaki ilişki basit (tek değişkenli) regresyon, daha fazla değişken arasındaki ilişki ise çoklu regresyon olarak tanımlanır. Basit regresyon, bağımlı ve

bağımsız değişkenler arasında doğrusal bir ilişkiyi temsil eden bir doğru denklemi olarak formüle edilmektedir:

$$Y_i = \beta_0 + \beta_1 X_i + e \quad (4.2)$$

Formülde Y_i bağımlı değişken, X_i bağımsız değişken, β_0 değeri sabit, β_1 değeri regresyon katsayısı ve e hata terimi olarak adlandırılır. Hata teriminin ortalaması sıfır, varyansı σ^2 olan ve normal dağılım gösteren bir değişken olduğu varsayılır. Söz konusu hata terimi, modelin raslantısallığını ifade etmektedir ve modele dahil edilmeyen değişkenleri bünyesinde barındırdığı düşünülür. Regresyon katsayısı, bağımsız değişkenin kendi cinsinden bir birim değişikliğine karşı bağımlı değişkenin kendi birim cinsinden meydana gelecek değişikliği göstermektedir.

Regresyon analizinde iki değişken arasında bir ilişkinin olabilmesi için sebepsellik nihai bir şart değildir. Yani bağımlı ve bağımsız değişkenler arasında pozitif ya da negatif bir ilişkinin olması her zaman bağımsız değişkenlerin bağımlı değişkenin sebebi olduğu sonucunu doğurmamaktadır. İlişkinin sebebi farklı üçüncü bir değişkenle olan ilişkiden de kaynaklanabilir ya da söz konusu ilişki tamamen tesadüfi olarak da ortaya çıkmış olabilir. Bir olayı etkileyen çok sayıda faktör varsa aradaki sebep-sonuç ilişkisinin araştırılması çoklu regresyon analiziyle mümkün olabilmektedir.

Sebep-sonuç ilişkisi arama çalışmalarında temel amaç, bağımlı değişkene etki eden birden çok bağımsız değişkenin etkisinin nasıl olduğunu incelemek ya da sadece aralarındaki karmaşık yapıyı tanımlamak olabildiği gibi, bağımsız değişkenlerden hangisi veya hangilerinin bağımlı değişkeni diğer değişkenlere nazaran daha çok etkilediğini bulmak ya da bağımsız değişkenler yardımıyla bağımlı değişkeni tahmin etmek şeklinde de olabilmektedir [50]. Regresyon analizinin sonucunda, bağımsız değişkenlerin geçmiş değerlerinden yola çıkılarak bağımlı değişkenin ortalama değeri kestirilmeye çalışılır.

Çoklu Doğrusal Regresyon modeli, sayısal bir bağımlı değişken ve birkaç bağımsız değişken arasındaki ilişkinin fonksiyonel şeklini ifade etmektedir ve aşağıdaki matematiksel bağıntı ile tanımlanmaktadır:

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_p X_p + e_i \quad (4.3)$$

Formülde Y bağımlı değişken, X_1, X_2, \dots, X_p bağımsız değişkenler, β_0 sabit, $\beta_1, \beta_2, \dots, \beta_p$ değerleri regresyon katsayıları ve e_i hata terimi olarak adlandırılır. Hata terimi ise şu şekilde hesaplanmaktadır:

$$e_i = Y_i - \hat{Y}_i \quad (4.4)$$

Burada Y_i bağımlı değişkenin gerçek değerlerini, \hat{Y}_i de bağılı değişken için gerçekleştirilen tahmin değerini göstermektedir. Verilerin genel durumları göz önünde bulundurularak aradaki ilişkinin durumu tahmin edilmeye çalışılır. Eldeki gözlem verileri kullanılarak, her gözlem bir noktayı gösterecek şekilde bir diyagram çizilebilecek olursa ve bu diyagramda her değişkene karşılık noktalar doğrunun etrafında toplanmış görülüyorsa, diğer bir deyişle eşleşmişse, bu fonksiyonun doğrusal bir fonksiyon olduğu söylenebilir.

Eğer hata teriminin normal dağılım göstermesi şeklinde bir varsayım varsa en büyük olabilirlik, hata teriminin dağılımı ile ilgili herhangi bir varsayım söz konusu değilse en küçük kareler tekniği kullanılarak parametreler tahmin edilir [50]. En küçük kareler optimizasyon yöntemi, eski ve çok yaygın bir şekilde kullanılan bir tahmin sürecidir. Çoğunlukla, elde hata kaynaklarına ilişkin bir bilgi olmadığı durumlarda deterministik modellerin çözümünde kullanılır. En küçük kareler metodunda tahmin ediciler gözlenen aktif değerler ile tahmin değerleri arasındaki farklı karelerinin toplamını olabildiğince minimize eder. Tahmin ediciler, ilgili parametrelerin doğrusal fonksiyonlarının belirli bir kümesi için minimum varyanslı, yansız ve toplamsal olarak tahminde bulunur. Bu parametrelerin doğrusal olmayan fonksiyonlarının olduğu bölgelerde bile en küçük kareler tahmin edicileri tutarlı ve asimptotik olarak yansız bir tahmin sürecine sahiptir.

Bunun yanında, en büyük olabilirlik tahmin edicileri, tam bir olasılık yoğunluk fonksiyonu belirlenmesi prensibi ile çalışmaktadır. Bu tahmin ediciler, küçük örneklem alanında optimal özelliklere sahip olmamasına rağmen, örneklem boyutu arttıkça asimptotik olarak tutarlı, etkin ve yansız çözüm sunmaktadır. En büyük olabilirlik tahmin edicisi, bir parametrenin olabilirlik fonksiyonunu bu parametreye göre maksimum yapan değer olarak tanımlanabilir. Bu değer, olabilirlik fonksiyonunun ilgili parametreye göre türevinin alınıp sifıra eşitlenmesi ile bulunmaktadır. Ancak bazı durumlarda, olabilirlik fonksiyonunu maksimum yapan değer bulunması iteratif olarak bulunabilmektedir. Örneğin bir regresyon probleminde, Y bağımlı değişkenini etkileyen iki adet X_1 ve X_2 bağımsız değişkeni olduğu düşünülürse, bu sistem için fonksiyon denklemi şu şekilde verilebilir:

$$Y = \beta_0 + \beta_1 X_{1i} + \beta_2 X_{2i} + e_i \quad (4.5)$$

Tahmin edilen bağımlı değişkenin değerinin \hat{y} olduğunu düşünürsek, Y 'nin regresyon denklemi aşağıdaki şekilde ifade edilir:

$$\hat{y} = \beta_0 + \beta_1 X_1 + \beta_2 X_2 \quad (4.6)$$

Tahminlemenin gerçeğe olabildiğince yakın olması için hata değerinin olabildiğince küçük olması gerekmektedir. Bu optimizasyonu yapabilmek için genellikle en küçük kareler metodu kullanılır. Bu yöntemin kullanılması ile β_0 , β_1 ve β_2 değerleri bulunur ve aşağıdaki çoklu regresyon denklemi elde edilir:

$$\sum_{i=0}^n (Y - \hat{y})^2 = \sum_{i=0}^n (Y - \beta_0 - \beta_1 X_1 - \beta_2 X_2)^2 \quad (4.7)$$

Yukarıdaki denklemde her ifadenin sırasıyla β_0 , β_1 ve β_2 'ye göre türevleri alınarak sonuç sifıra eşitlenir. Bu üç denklemin çözümü ile sırasıyla $\hat{\beta}_0$, $\hat{\beta}_1$ ve $\hat{\beta}_2$ parametrelerinin değerleri bulunur. Bu değerler kullanılarak da regresyon denklemi ortaya çıkmış olur [58].

Çoklu doğrusal regresyon modeli diğer karmaşık metodlara göre çok sayıda değişken arasında matematiksel ilişkiyi bulabilmek adına görece olarak daha az hesaplama eforu

gerektirdiğinden son dönemde sıklıkla kullanılmaktadır. Model, değişkenler arasındaki ilişkiyi kurarken ortalama karasel hatayı minimize etmeyi sağlayacak şekilde ağırlık çarpanlarını değiştirir. Doğal olarak bu işlem sonucunda kestirilen değerlerle gerçek değerler arasında belirli bir hata değeri olacağını aşıkardır. Bu modelin analizinde ya en küçük kareler metodu ya da en büyük olabilirlik (maximum likelihood) teknikleri olarak bilinen iki yaklaşımdan birisi kullanılır.

Çoklu doğrusal regresyon modelinde hata terimi ile ilgili bir takım varsayımlar bulunmaktadır. Bunlar genel olarak, hata teriminin normal dağılıma sahip olması, hata terimlerinde otokorelasyon olmaması ve hata terimlerinin sabit varyansa sahip olması olarak tanımlanabilir. Regresyon modelleri, bağımlı ve bağımsız değişkenler arasındaki ilişki yapısını belirli ihtimallere dayalı olarak örnekleyen ve tahmin etmeye çalışan istatistiksel modellerdir. Çoklu regresyon modeli gerçeğe ne kadar yakınsa, istenilen amaçlara o ölçüde iyi bir şekilde ulaşılmış olacaktır.

Bu modellerin temel olarak ortak özelliği, bir olayın veya sürecin temel özelliklerini değiştirmeden olabildiğince basite indirgenmesi ve gösterimi olarak değerlendirilebilir. Dolayısı ile bu basit gösterim, olaylar arasındaki etkileşimin kolayca incelenebilmesini ve benzer olaylarla ilgili önceden bilgi edinilmesini sağlar. Böylece geleceğe yönelik tahmin ve tasarımların güvenli bir şekilde yapılması da sağlanmaktadır. Modeller belirleyici ve kesin olmadığı için rasgelelik yasalarına bağlı olarak işlem görmektedir.

Modellemede seçilen bağımsız değişkenler yardımıyla, bağımlı değişken değerleri arasındaki değişim ve benzerliği olabildiğince iyi oranda açıklayabilmek bu yaklaşımın en temel amacıdır. Çoklu regresyon modelinde kullanılacak değişken sayısı ve bu değişkenlerin seçimi, bağımlı değişkeni en çok etkileyen faktör olarak tanımlanabilir. Bununla birlikte, modelin doğruluğuna etki eden daha az önemsiz parametrelerin etkisi ise genellikle şans değişkeni olarak modele eklenebilecek bir parametre ile açıklanmaktadır. Bu değerlerin model içerisindeki etkisi, diğer değişkenlerde olduğu gibi direkt olarak görünmemekle birlikte, bu parametrenin dağılımı hakkında birtakım mantıklı varsayımlar yapmak ve tahminde bulunmak mümkün olmaktadır.

4.3. Otoregresif Entegre Kayan Ortalama Modeli

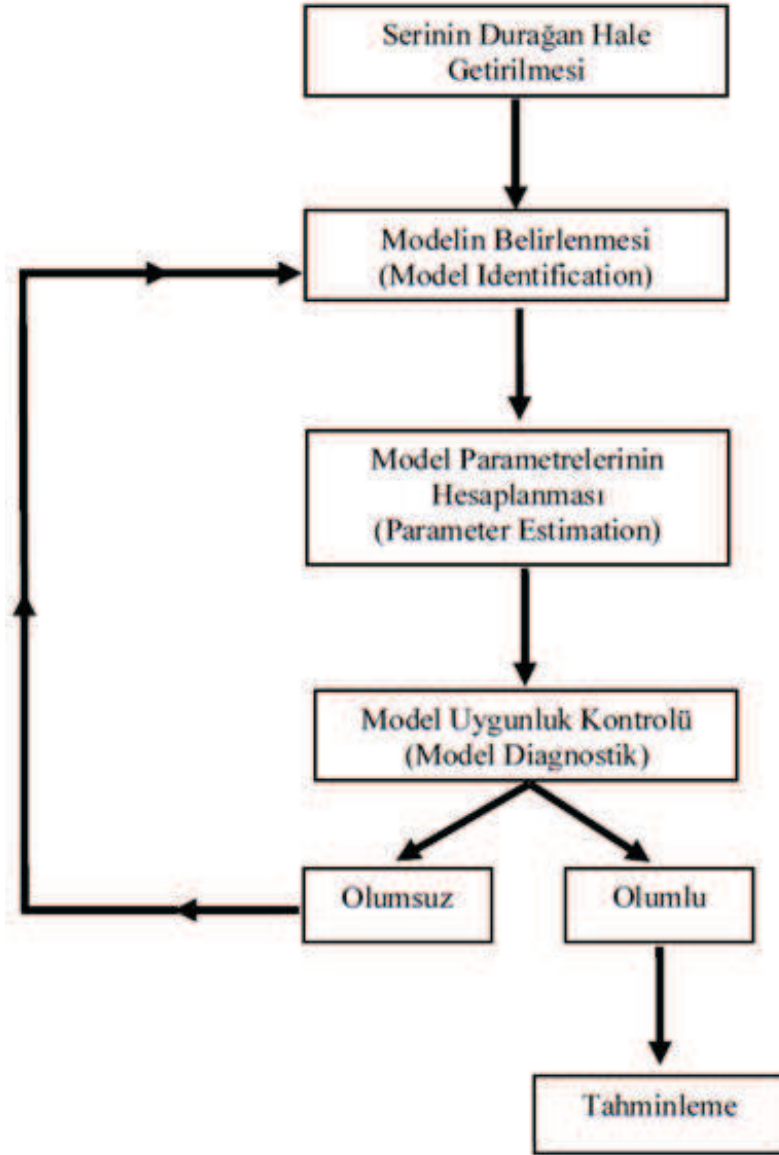
Bir deęiřkene iliřkin belirli ve dzenli periyotlarda ortaya ıkan nmerik verilerin kronolojik olarak diziliřiyle oluřan veri setleri Zaman Serileri olarak ifade edilmektedir. Zaman serileri haftalık, aylık, altı aylık, yıllık, on yıllık ya da daha geniř veya dar aralıklarda toplanmıř verilerden oluřabilir ve tek bir deęiřkene ait veri setiyle yapılan analizler, tek deęiřkenli zaman serisi analizi olarak adlandırılmaktadır [59]. Zaman serilerine iliřkin veriler stokastik tiptedir, yani dięer bir ifadeyle zamanın belli anlarında rastsal deęerler alırlar ve aldıkları bu deęerlerin önceden kestirilebilmesi de mümkün deęildir [60].

Tek deęiřkenli zaman serileri genel olarak ilgili deęiřkenin gelecek deęerlerinin tahminlenmesi ve kestirimi amacıyla kullanılır ve bir serinin ileriki dönemlerine iliřkin tutarlı tahminlerinin yapılabilmesi bu serinin, eđer varsa, nasıl bir fonksiyonel yapı içerisinde oluřtuęunun veya bu yapıya en yakın fonksiyonel formun bulunmasını gerektirir [61]. Zaman serilerinin gerekte nasıl bir fonksiyonel yapıya baęlı olarak oluřtuęu normal kořullar altında tam olarak bilinmemektedir. Ancak ilgili serilere iliřkin birtakım istatistiksel analiz ve test araları kullanılarak elde edilen bulgular vasıtasıyla bu fonksiyonel formlara iliřkin eřitli ipuları yakalanabilir.

Zaman serilerinin ARIMA ile modellenmesi alıřmalarının temelini, George Box ve Gwilym Jenkins'in 1970 yılında yayınladıęı kitap ile atılmıřtır. Literatüre Box-Jenkins metodolojisi olarak giren bu yöntem, temelinde duraęan ya da duraęanlıęı saęlanmış bir zaman serisine iliřkin birok olası model arasında uygun ARIMA modelinin belirlenmesi (model identification), parametrelerin hesaplanması (parameter estimation) modelin uygunluęunun deęerlendirilmesi (model diagnostic) olmak üzere üç ařamadan oluřmaktadır [61].

Bulunan model eđer uygunluk testlerini geemiyorsa, süreç bařtan bařlatılır, uygunluk kriterlerinden en iyi dereceyi alan model nihai olarak seilir ve tahminlemede seilen bu model kullanılır. Box-Jenkins metodolojisinde, uygun modelin belirlenmesi, ele alınan zaman serisinin örneklem otokorelasyon ve kısmi otokorelasyon katsayılarının artan gecikme uzunluklarında izledikleri seyrin, eřitli derecelerden teorik otoregresif,

AR(p), kayan ortalama, MA(q) ve otoregresif kayak ortalama, ARMA(p,q) modelleriyle karşılaştırılmasına dayanmaktadır [61]. Bu sürece ilişkin metodolojinin akış şeması Şekil 4.6'da gösterilmektedir.



Şekil 4.6. Box-Jenkins metodolojisinin gösterimi

Tek değişkenli zaman serilerinin tahminlemede yoğun olarak kullanılan Ototegresif Entegre Kayan Ortalama (Autoregressive Integrated Moving Average, ARIMA) modelleri, genel olarak ARIMA(p,d,q) şeklindeki notasyon ile gösterilmektedir ve bu modeller doğrusal filtreleme modelleri olarak da adlandırılmaktadır. Burada p ve q sırasıyla ilgili modelin standart otoregresif ve standart hareketli ortalama derecelerini gösterirken, d ise serinin durağanlaştırılabilmesi için kaçınıcı dereceden standart

farkının alınması gerektiğini göstermektedir. Modelin matematiksel gösterimi şu şekilde verilmektedir:

$$Z_t = \varphi_1 Z_{t-1} + \varphi_2 Z_{t-2} + \dots + \varphi_p Z_{t-p} + a_t + \theta_1 a_{t-1} + \theta_2 a_{t-2} + \dots + \theta_q a_{t-q} \quad (4.8)$$

Burada, φ_p otoregresif operatör için parametre değerleri, a_t hata terimi katsayıları, θ_q hareketli ortalama operatörü için parametre değerleri ve Z_t orijinal serinin d dereceden farkı alınmış zaman serisi olarak tanımlanmaktadır. Yani $t = 1, 2, \dots, t$ için:

$$W_t = Y_t - Y_{t-1} \quad (4.9)$$

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

$$Z_t = W_t - W_{t-1} \quad (4.10)$$

gösterimi ile birinci fark serisinin tekrar farkı alınacak şekilde durağanlık kontrolü yapılır ve bu şekilde modellenir. Orijinal seri durağan ise, yani fark alma derecesi $d = 0$ için, ARIMA modeli, AR, MA ya da ARMA modeli haline gelecektir [62]. ARIMA modelinin bu özelliği nedeniyle, Box-Jenkins modellerinin tamamını bünyesinde barındığı söylenebilir. Fark alma derecesi $d = 1$ olduğunda zaman serisi doğrusal, $d = 2$ olduğunda ise parabolik bir eğri haline dönüşmektedir. Temel ARIMA modellerine ait eşitlikler şu şekilde verilmektedir:

$$ARIMA(0,1,1) = IMA(1,1) \quad \rightarrow Y_t = Y_{t-1} + a_t + \theta_1 a_{t-1} \quad (4.11)$$

$$ARIMA(1,1,0) = ARI(1,1) \quad \rightarrow Y_t = (1 + \varphi_1)Y_{t-1} - \varphi_1 Y_{t-2} + a_t \quad (4.12)$$

$$ARIMA(1,1,1) = ARIMA(1,1,1) \rightarrow Y_t = (1 + \varphi_1)Y_{t-1} - \varphi_1 Y_{t-2} + a_t - \theta_1 a_{t-1} \quad (4.13)$$

ARIMA modeli derlenen kesikli zaman serileri ile dinamik sistemlerin modellenmesinde başarılı bir şekilde kullanılmaktadır. Bu modellerde temel amaç,

zaman serisine en iyi uyan ve mümkün olan en az parametre içeren doğrusal modeli belirlemektir. Zaman serisi modellerinde en önemli konulardan bir tanesi de ele alınan değişkenlerin zaman içerisinde nasıl hareket ettiği. Bazı seriler belli bir ortalama etrafında kısa dalgalanmalar göstermekteyken, bazıları ise zaman içerisinde azalma ya da yükselme yönünde belirgin trendler takip edebilir. Bununla birlikte bu seriler, artış ya da azalış yönünde istikrar göstermeyen trendlere de sahip olabilirler.

Zaman serilerinde ele alınan değişkene ait veri setinin düzey, fark ve logaritmik farkları alınarak zamana karşı grafiklerinin incelenmesi, çeşitli gecikme uzunluklarındaki otokorelasyonlarının ve kısmi otokorelasyonlarının analizi, serilerin karakteristik özellikleri hakkında bir ön fikir sağlamada yardımcı olmaktadır [63]. Belli bir trend içeren zaman serileri zamandan bağımsız bir ortalama ve varyansa sahip değildir. Ancak bazı seriler uzun dönemde sabit ortalamaya ve varyansa sahipken, kısa dönemde bakıldığında aşırı dalgalanmalar gösterebilmektedir. ARIMA modelleri, ele alınan serilerin trend içermemesini ve durağan olmasını gerektirir.

Zaman serilerindeki katı ve zayıf durağanlığın sağladığı en önemli avantaj, yeterince geniş bir örneklem uzayı kullanıldığında, bu zaman serilerinin varyans ve ortalamalarının başarılı bir şekilde kestirilebilmesi olarak adlandırılabilir. Trend içeren seriler, ARIMA modeli kullanılarak öncelikle trendden arındırılmalıdır. Bununla birlikte, daha sağlam ve güvenilir tespitlerin yapılması için bazı ciddi analizler ve test yöntemlerinin kullanılması elzemdir. Trend ve mevsimsellik sorunlarının tespiti ve giderilmesi için bazı test ve analizler bu modelin sağlıklı olarak uygulanabilmesi için büyük önem taşımaktadır.

ARIMA modellerinin kurulmasında temel olarak dört aşamanın tamamlanması gerekmektedir. İlk aşama, otokorelasyon ve kısmi otokorelasyon fonksiyonlarının grafiklerinden faydalanarak genel model sınıfının belirlenmesi işidir. İkinci aşama, geçici model belirleme olarak adlandırılmaktadır. Model belirleme aşamasında AR, MA, ARMA ya da ARIMA model sınıfından bir model seçilir [62]. $AR(p)$ modelinde, otokorelasyon fonksiyonu üstel ve sinüzoidal olarak gittikçe azalır, kısmi otokorelasyon fonksiyonu ise p gecikmesinden istatistiksel olarak anlamsız bir hal almaktadır.

$MA(q)$ modelinde, otokorelasyon fonksiyonu q gecikmesinden sonra ani olarak düşer ve istatistiksel olarak anlamsız hale gelir, kısmi otokorelasyon fonksiyonu ise üstel ya da sinüzoidal olarak gittikçe azalır. $ARMA(p,q)$ modelinde ise, hem otokorelasyon fonksiyonu hem de kısmi otokorelasyon fonksiyonu $(q-p)$ gecikmesinden sonra üstel ve azalan sinüs dalgalarının bir karışımı olarak gözükmemektedir. Üçüncü aşama, geçici model parametrelerinin istatistiksel teknikler kullanılarak tahmin edilerek, katsayıların standart hatalarının kontrol edilmesi ve bunların anlamlı olup olmadığının testi olarak adlandırılabilir.

Son aşamada ise, belirlenen modelin tahmin amacına uygunluğunun kontrolü yapılır. Bunun için uygun olduğu varsayılan geçici modelin hatalarının otokorelasyon katsayılarının grafiğine bakılır ve otokorelasyon fonksiyonu incelenir [62]. Sözkonusu fonksiyon belirli bir şekil gösteriyorsa, hataların tesadüfi dağılmadığı ve modelin uygun olmadığı sonucuna varılır. Bu noktada, ikinci aşamaya tekrar dönüş yapılır ve bu süreç, yeni bir geçici modelle tekrar başlatılarak uygun model belirleninceye kadar tekrar edilir. Uygunluk kontrolünden geçen model, artık tahmin yapmak amacıyla kullanıma hazır hale gelmiş durumdadır [62].

4.4. Destek Vektör Makinaları ve Regresyon Modeli

Destek Vektör Makinaları (Support Vector Machines, SVM), çok boyutlu bir uzayda farklı sınıflardaki kayıtları, dizayn edilen hiperdüzlemler vasıtasıyla ayıran bir sınıflandırma, kümeleme, yoğunluk tahmini ve regresyon metodudur. 1990'lı yıllarda Vapnik tarafından geliştirilen, veri madenciliği algoritmaları arasında dayanıklı ve doğru çıktılar verdiği bilinen bu yöntemin alt kolları, sınıflandırma problemlerinde Destek Vektör Sınıflandırıcı ve regresyon problemlerinde Destek Vektör Regresör olarak adlandırılır. İstatistiksel öğrenme teorisinde köklü ve sağlam bir teorik temele sahip bu yöntem, öğrenme işlemi için az örnek gerektirmesi bakımından önemli bir kullanım alanına sahiptir [64].

SVM modeli, özellikle son yıllarda veri madenciliği uygulamalarında değişkenler arasındaki örüntülerin bilinmediği veri setlerindeki sınıflandırma problemlerinde sıklıkla kullanılmaktadır. Temel olarak iki sınıflı problemlerin çözümünde doğrusal

bir sınıflayıcı olarak ortaya çıkan bu yöntem, daha sonra doğrusal olarak ayrılamayan ya da çok sınıflı problemlerin çözümü için de genelleştirilmiştir. İlk olarak optik karakter tanıma alanında uygulanan yöntem, günümüzde örüntü tanıma, veri madenciliği, alfabe ve kelime sınıflandırması, biyolojik uygulamalar, gen ve protein analizleri ile yüz tanıma problemlerinde kullanılmaktadır. SVM literatüründe, tahmin edici veya bağımsız (predictor) değişkene doğal nitelik (attribute), optimum hiperdüzlemi belirlemek için kullanılan dönüştürülmüş doğal niteliğe belirleyici nitelik (feature) ve bir deneği (gözlemi) tanımlayan belirleyici nitelik setine ise, vektör denilmektedir [65].


Destek vektör makinesi yönteminin kökeni, bir fonksiyonlar sınıfının elemanlarının ne kadar dinamik olduğunu ve sınıflama fonksiyonlarının bulunduğu hipotez uzayının kapasitesini ölçen skaler bir değer olan VC-boyutu (Vapnik Chernonvekis Dimension) modelinin alt kümesi olan yapısal risk minimizasyon presibine dayanmaktadır. VC-boyutu, istatistiksel öğrenme teorisi ile elde edilen tahmin setinin özelliğidir ve buradaki temel düşünce, iki sınıfın doğru bir şekilde sınıflandırılabilmesi ve sonra da genelleme yapılmasıdır. Makine tasarımı, destek vektörler olarak hizmet veren eğitime verisinin bir alt kümesinin elde edilmesi ile gerçekleştirilir ve bu verinin istikrarlı olduğunun bir göstergesidir. İstatistiksel öğrenme teorisi üzerine inşa edilen destek vektör makineleri, çok terimli (polinom) makine öğrenmesi, radyal temelli fonksiyon ağ ve iki katmanlı algılayıcı (two-layer perception) fonksiyonları ile yakın akrabalık göstermektedir [66].

SVM modelinin temel dayanağı, verileri sınıflara optimum şekilde ayırabilecek maksimum marjlinli bir hiperdüzlem bulunmasıdır. Veriler, yapısal risk minimizasyonu ile test edilmekte ve bu işlem de sınıflandırmanın yanlış bir şekilde gerçekleştirilmesi olasılığını düşürmektedir. SVM modeline baz oluşturan veriler, ya doğrusal ya da doğrusal olmayan bir şekilde ayrıştırılabilecek yapıya sahip olabilir. Eğer veriler doğrusal olarak ayrılabilirse, iki sınıf arasındaki bir doğru bu görevi gerçekleştirir. Ancak veriler doğrusal olarak ayrılamıyorsa, veriler farklı bir boyuta taşınır ve bu boyutta optimum ayırıcı hiperdüzlem araştırılır. SVM yönteminde bir sınıflandırıcı, bir fonksiyonlar kümesinin kapasitesini tanımlayan, minimize edilmiş VC-boyutu ile üretilir [67]. Eğer VC-boyutu düşükse, doğru orantılı olarak, bu

sınıflandırma hatasının beklenen olasılığı da düşüktür. Parametrelerinde herhangi bir ince ayar gerekmediği için SVM modelinin özellikle diğer istatistiksel yöntemlere göre daha iyi bir genelleme performansı sergilemektedir.

SVM yöntemi, yüksek doğruluk oranı, seçilen parametrelerin uygunluğuna göre iyi bir genelleme yeteneğine sahip olması, çok sayıda bağımsız değişkenle çalışabilme, karmaşık karar sınıflarını modelleyebilme gibi önemli avantajlara sahiptir. Bununla birlikte, hem doğrusal olarak ayrılabilen hem de ayrılamayan verilere uygulanabilme özelliği ve modelde kullanılan çekirdek fonksiyonlar nedeniyle verinin doğrusal olarak ayrılmasının sağlanabilmesi, aşırı uyum sorununun minimum seviyede görülmesi ve lokal minimumda tek çözüm sunması bu modelin önemli diğer avantajlardır. Ancak, çekirdek fonksiyonlarının ve parametrelerinin uygun seçiminin gerekliliği, eğitim ve test sırasında karşılaşılan hız ve boyut sorunları ile algoritmanın karışıklığı nedeniyle güçlü bilgisayar teknolojilerine ihtiyaç duyulması SVM modelinin başlıca dezavantajları olarak ortaya çıkmaktadır.

Özellikle pratik uygulamalardaki başarılı performansı ve basit fikirler üzerine kurulmuş olması nedeniyle kullanışlı bir yöntem olan SVM için kullanılacak örnek sayısı çok önemli değildir. Model eğitim sürecinde, genelleştirebilme yeteneğinin üstünlüğü sayesinde, görülmemiş verileri de düzgün olarak sınıflandırabilmektedir [65]. Modelin işleyişinde, problemlerin çözümlerini karakterize etme üzerinde yoğunlaşan, çözüm için gerekli ve yeter şartları sunan algoritmaların geliştirildiği optimizasyon teorisinden ve başlangıçta herhangi bir eşitsizlik sabiti olmayan optimizasyon problemlerine çözüm sunan Lagrange teorisinden yararlanılmaktadır. Bir ayırım, boşluk ya da mesafe olarak da adlandırılan marj terimi, bir hiperdüzlem tarafından tanımlanan iki sınıf arasındaki mesafe miktarı olarak tanımlanır ve geometrik olarak hiperdüzlem üzerindeki bir nokta ile en yakın veri noktaları arasında en küçük mesafe anlamına gelir. İki boyutlu bir girdi uzayı için sınıfları doğrusal olarak ayıran optimal hiperdüzlem ve marj ifadeleri Şekil 4.7’de gösterilmektedir.



Şekil 4.7. Doğrusal olarak ayrılabilen durumda optimal hiperdüzlemin gösterimi

Verilerin doğrusal olarak ayrılabilir olduğu durumlarda, w ifadesinin hiperdüzlemdeki ağırlık vektörü, b ifadesinin de yanlı (bias) terimi olduğu düşünülürse, hiperdüzlem şu şekilde tanımlanabilir:

$$w^T x + b = 0 \quad (4.14)$$

Herhangi bir x noktasından hiperdüzleme olan geometrik uzaklık şu ifade ile verilir:

$$r = \frac{g(x)}{\|w\|} \quad (4.15)$$

Burada $g(x) = w^T x + b$ ifadesi hiperdüzlem tarafından tanımlanan diskriminant fonksiyonudur ve w ile x verilmek üzere, x 'in fonksiyonel marjı olarak da isimlendirilir [68]. SVM modelinde optimal hiperdüzlem için ayırma marjı (ρ) ifadesini maksimize edebilmek için w ve b parametrelerinin bulunması hedeflenir. Ayırma marjı sırası ile iki sınıftan en kısa geometrik uzaklıklar olan r^* ifadesi yolu ile bulunur ve bu işlem maksimal marj sınıflandırma işlemi olarak adlandırılır.

Fonksiyonel marj ifadesi 1'e eşit olacak şekilde düzenlenmektedir ve verilen bir eğitime kümesi, $\{x_i, y_i\}_{i=1}^n \in \mathbf{R}^m \times \{\pm 1\}$ olmak üzere aşağıdaki denklemler elde edilir:

$$w^T x_i + b \geq 1, y_i = +1 \quad (4.16)$$

$$w^T x_i + b \leq -1, y_i = -1 \quad (4.17)$$

Bu denklemlerin ilk ve ikinci parçalardaki eşitlikleri sağlayan özel veri noktaları olan (x_i, y_i) destek vektörleri olarak isimlendirilir. Bu noktalar optimal hiperdüzleme en yakın olan veri noktalarıdır [68]. Destek vektör x^* 'ten optimal hiperdüzleme karşılık gelen geometrik uzaklık ise şu şekilde ifade edilir:

$$r^* = \frac{g(x)}{\|w\|} = \begin{cases} \frac{1}{\|w\|}, & \text{eğer } y^* = 1 \text{ ise} \\ -\frac{1}{\|w\|}, & \text{eğer } y^* = -1 \text{ ise} \end{cases} \quad (4.18)$$

Buna göre ayırma marjı ifadesi de şu şekilde hesaplanır:

$$\rho = 2r^* = \frac{2}{\|w\|} \quad (4.19)$$

Maksimum marjlı hiperdüzlemin bulunabilirliğinden emin olmak için SVM modeli w ve b değerlerine göre ρ ifadesini maksimize etmeye çalışır. Bu optimizasyonu daha kolay gerçekleştirebilmek için $\|w\|$ ifadesi yerine eşdeğer $\|w\|^2$ kullanılır:

$$\max_{w,b} \frac{2}{\|w\|} \text{ eşdeğeri} \rightarrow \min_{w,b} \frac{\|w\|^2}{2}, y_i(w^T x_i + b) \geq 1, i = 1, 2, \dots, n \quad (4.20)$$

Bu kısıtlara sahip optimizasyon probleminin çözümünde Lagrange çarpanları kullanılmaktadır. Burada i . eşitsizliğe göre Lagrange çarpanı α_i olmak üzere, problem şu hali alır:

$$L(w, b, a) = \frac{1}{2} w^T w - \sum_{i=1}^n \alpha_i [y_i(w^T x_i + b) - 1] \quad (4.21)$$

$L(w, b, a)$ ifadesinin w ve b 'ye göre diferansiyelini alırsak ve sonuçları sıfıra eşitlersek, aşağıdaki optimallik koşulları elde edilir:

$$\begin{cases} \frac{\partial L(w, b, a)}{\partial w} = 0 \\ \frac{\partial L(w, b, a)}{\partial b} = 0 \end{cases} \quad (4.22)$$

Diferansiyel işlemi sonrasında ifade aşağıdaki hali alır:

$$\begin{cases} w = \sum_{i=0}^n \alpha_i y_i x_i \\ \sum_{i=1}^n y_i x_i = 0 \end{cases} \quad (4.23)$$

Böylece elde edilen (35) denklemi, (33) ifadesindeki Lagrange fonksiyonuna yerleştirilirse, bu ifadeye karşılık gelen dual eşdeğer problem elde edilir:

$$\max_a W(a) = \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n \alpha_i \alpha_j y_i y_j x_i^T x_j \rightarrow \sum_{i=0}^n \alpha_i y_i = 0, \alpha_i \geq 0 \quad (4.24)$$

Bununla birlikte Karush-Kuhn-Tucker (KKT) tamamlayıcı koşulu şu şekilde gösterilir:

$$\alpha_i [y_i (w^T x_i + b) - 1] = 0, \quad i = 1, 2, \dots, n \quad (4.25)$$

Sonuçta sadece optimal hiperdüzleme en yakın veri noktaları ve maksimal marjı belirleyen destek vektörleri olan (x_i, y_i) sıfır olmayan α_i değerlerine karşılık gelir [64]. Yukarıdaki dual problem, tipik bir konveks kuadratik programlama optimizasyonu problemidir ve sıralı minimal optimizasyon gibi bazı tekniklerin kullanılması ile verimli bir şekilde global optimuma yakınsar [68]. Optimal Lagrange çarpanı olan α_i^* değeri ile optimal ağırlık vektörü w^* değeri (35) denkleminde yararlanılarak şu şekilde bulunur:


$$w^* = \sum_{i=1}^n \alpha_i^* y_i x_i \quad (4.26)$$

Pozitif destek vektörü x_s 'ten yararlanılarak, optimal bias değeri şu şekilde bulunur:

$$b^* = 1 - w^{*T} x_s, y_s = +1 \quad (4.27)$$

Gerçek hayattaki sınıflandırma ve regresyon problemleri büyük oranda doğrusal olarak ayrılamayan örnekleri içermektedir. Bu tür problemlerde marjların negatif olma durumu söz konusu olabilir ve bu durumda dual fonksiyon çözülmesi zor olan bir sınırsız amaç fonksiyonuna dönüşebilir. Bu sorun kullanılan iki yaklaşım ile çözülebilir. İlk yaklaşımda, matematiksel ifadelerdeki katı eşitsizlikleri gevşeterek, sözde soft marj optimizasyon problemi olarak adlandırılan bir yöntem kullanılabilir. Alternatif olarak ise doğrusal probleme çekirdek hilesi (kernel trick) olarak adlandırılan bir metodun uygulanmasıyla problemin doğrusal hale getirilmesi yöntemi kullanılabilir.

Çekirdek hilesi, doğrusal olarak ayrılamayan problemleri daha kolay çözebilmek için, veriler arası iç çarpıma dayalı uygun bir çekirdek fonksiyonunun tanımlanması ve giriş uzayından (input space), yüksek boyutlu öznelik uzayına (feature space) gerçekleştirilen bir dönüşüm olarak tanımlanmaktadır [66]. 1995 yılında Vapnik ve Cortes tarafından tanımlanmış bu işlem vasıtasıyla sistemin farklı bir uzaya taşınarak doğrusal olmayan unsurlarla birlikte adreslenmesi ve burada doğrusal sınıflandırıcı ile tekrar sınıflandırılması Şekil 4.8'de gösterildiği gibi mümkün olmaktadır.



Şekil 4.8. Verinin doğrusal olarak ayrılabilirdiği bir uzaya taşınması

Veriler seçilen çekirdek fonksiyonu yardımıyla, $\phi: X \rightarrow F$ olarak F uzayına taşınarak sınıflandırılacaktır. Doğrusal durumda SVM eğitiminde kullanılan ve yukarıdaki denklemlerde verilen $\langle \cdot, \cdot \rangle$ iç çarpım ifadesi yerine, taşınan verinin $\langle \cdot, \cdot \rangle$ formundaki iç çarpımı kullanıldığında elde edilen optimizasyon probleminin çözümü ile çok boyutlu uzay için SVM sınıflandırması gerçekleştirilmiş olur. Literatürde yaygın olarak kullanılan üç adet κ -çekirdek fonksiyonu \mathbb{N} ve \mathbb{R} fonksiyon parametreleri olmak üzere, şu şekilde tanımlanmaktadır [67]:

$$\begin{aligned}
 \text{Doğrusal Çekirdek} & \quad \kappa(x, y) = \langle x, y \rangle \\
 \text{Polinom Çekirdek} & \quad \kappa(x, y) = \langle x, y \rangle^p \\
 \text{Radyal Tabanlı Çekirdek} & \quad \kappa(x, y) = \exp(-\gamma \|x - y\|^2)
 \end{aligned} \tag{4.28}$$

4.4.1. Destek vektör regresyonu

SVM yöntemi, sınıflandırma problemleri için, belirleyici nitelik uzayındaki eğitim verilerine göre optimum ayırma düzlemini öğrenmeye çalışırken, regresyon problemlerinde ise eğitim verilerine göre giriş ve çıkış uzayları arasındaki haritalama fonksiyonunu öğrenmeye çalışır [65]. Destek Vektör Regresyonu (Support Vector Regression, SVR) prensip olarak gözlenen eğitim hatasını minimize etmek yerine genelleştirilmiş hata sınırını minimize etmeye çalışmaktadır. SVR modelinde kullanılmakta olan yaklaşım hatası değerinin sınıflandırma problemlerindeki karşılığı optimal ayırıcı bir hiperdüzlem ve destek vektörleri arasındaki marjdır. Genelleme hatası ise, eğitim hatası terimi ve hipotez uzayının karmaşıklığını kontrol eden düzeltme teriminin bir kombinasyonu olarak karşımıza çıkmaktadır.

Sınıflandırma problemlerinde olduğu gibi regresyon problemlerinde de sınır üzerindeki optimum genelleme ifadesine erişilmeye çalışılmaktadır. Dolayısı ile sonlu bir gürültülü örnek kümesi üzerinde bilinmeyen bir sürekli fonksiyonun tahminlenmesi hedeflenmektedir. SVR yönteminde ana fikir, marjini olabildiğince büyüten hiperdüzlem vasıtasıyla hatanın minimize edilmesidir, ancak hata kısmen tolere edilebilmektedir. Regresyon modelinde, sınıflandırma algoritmasına da benzer olarak, doğrusal öğrenme metotları ve çekirdek hilesinin (kernel trick) kullanılması ile

doğrusal olmayan yapıdaki fonksiyonlar elde edilmektedir ve bu fonksiyonlardan yararlanılarak maksimum marj metodunun temel özelliklerinin araştırılması amaçlanmaktadır [68].

Regresyon problemleri için, gürültünün (additive noise) ardındaki dağılım uzun bir uzantıya sahip olduğu durumlarda regresörde meydana gelen kötü performansa sahip olan verilerin bulunması halinde, geleneksel en küçük kareler tahmin edicisi (least-square estimator) uygulanamayabilir [66]. Bu nedenle, model içerisindeki ufak değişikliklere duyarsız olan bir ε - duyarsız kayıp fonksiyonu tanımlanır. Bu kayıp fonksiyonu; \mathbb{R}^n 'te reel değerli bir fonksiyon olarak şu şekilde gösterilir:

$$\rho(\varepsilon) = \begin{cases} \varepsilon^2 & \text{if } |\varepsilon| \leq 1 \\ 2|\varepsilon| - 1 & \text{if } |\varepsilon| > 1 \end{cases} \quad (4.29)$$

Bu fonksiyon, sapma miktarı ε değerine eşit ya da küçükse 0 değerini alır, aksi takdirde sapma miktarından ε değerinin çıkartılması ile elde edilen değeri alır. Doğrusal olmayan, $\rho(\varepsilon)$ değerinin gürültü olarak adlandırıldığı, $\mathbb{R}^n \times \mathbb{R}^m \rightarrow \mathbb{R}$ ile tanımlanan bir regresyon modelinde hedef, \mathbb{R}^m hedef fonksiyonunu \mathbb{R}^n değerine olabildiğince yaklaştırmak hedeflenmektedir. Dolayısı ile ana problem aşağıdaki ifadedeki gibi temsil edilmektedir:

$$\min_{\mathbf{w}} \sum_{i=1}^n \rho(\mathbf{w}^T \mathbf{x}_i - y_i) \quad (4.30)$$

$$\text{subject to } \mathbf{w} \in \mathbb{R}^n \quad (4.31)$$

$$\mathbf{w}^T \mathbf{x}_i - y_i \leq 1 \quad \forall i \quad (4.32)$$

Lagrange çarpanlarının benzer metodu kullanıldığında, dual problem aşağıdaki hali alır:

$$\begin{aligned} \max_{\alpha} \quad & \sum_{i=1}^n \alpha_i (y_i - 1) \\ \text{subject to } & \sum_{i=1}^n \alpha_i \mathbf{x}_i = \mathbf{0} \\ & \alpha_i \geq 0 \quad \forall i \end{aligned} \quad (4.33)$$

$$\sum_{i=1}^n (\hat{\alpha}_i - \alpha_i) = 0, \quad 0 \leq \hat{\alpha}_i, \alpha_i \leq C, \quad i = 1, \dots, n \quad (4.34)$$

Destek vektör regresyonunda, destek vektör sınıflandırmasına göre, ekstra olarak ifadesi denklem içerisinde yer alır. Doğrusal olmayan veriler için, sınıflandırma problemlerinde olduğu gibi çekirdek fonksiyonları kullanılarak öznitelik uzayına geçilir ve böyle doğrusallaştırma işlemi yapılmış olur. SVR modelinde kayıp fonksiyonu ve %penaltı parametreleri, başlangıçta kullanıcı tarafından yapılan bir atama ile seçilmektedir. Bu parametreler regresyon işlemi için karmaşıklığı direk olarak etkilemektedir. Bu nedenle daha iyi bir yaklaşım fonksiyonu elde edebilmek için ve %parametrelerinin optimum değerleri bulabilmek için deneme yanılma metodunun kullanılması gerekmektedir.

BÖLÜM 5. YÖNTEM, UYGULAMA VE BULGULAR

Endüstriyel tesislerin günlük operasyonlarını anlatabilmek için kullanılan matematiksel modellerin doğruluğu, sistemde kullanılan kritik parametrelerin bu modeller içerisinde uygun bir şekilde kullanılmasına bağlıdır. Normalde karmaşık yapıya sahip bu matematiksel modellerin gereğinden fazla proses değişkeni içermesi durumunda, çok fazla sayıda iterasyon ve dolayısıyla zaman sıkıntısına neden olmaktadır. Bu nedenle özellikle yapay sinir ağları gibi yapay zeka uygulamaları, matematiksel modellerin kullanımındaki sıkıntılara bir alternatif olması bakımından önemli bir yere sahiptir.

Bu çalışmada yapay sinir ağı uygulamaları ile birlikte kullanılan istatistiksel modeller, sonuçların birbiriyle karşılaştırılması ve seçilen proses parametrelerinin hedef olarak seçilen çıkış parametresinin değişimini etkilemekteki uygunluğunun tespiti için önerilmektedir. Çalışmada üç farklı tesisin seçili proses parametrelerinin geçmiş değerleri kullanılarak, bu parametrelere karşılık tespit edilen bağımlı değişken parametresinin yüksek bir doğrulukla kestirimi öngörülmektedir. Kullanılan her bir giriş parametresinin seçimi, bağımlı çıkış değişkenine kritik etkisi nedeniyle son derece önemlidir.

Çalışmanın ilk bölümünde kullanılan veriler, Ereğli Demir ve Çelik Fabrikası'na bağlı Elektronik Otomasyon Müdürlüğü'nden, ikinci bölümde kullanılan veriler İÇDAŞ'a ait kömür yakıtlı termik santralin Elektrik ve Otomasyon Bakım Müdürlüğü'nden ve son bölümde kullanılan çimento fabrikasına ait veriler ise Kocaeli İl Çevre Müdürlüğü'nden temin edilmiştir. Çalışmalarda, Windows 7 Enterprise 64-bit işletim sistemi, Intel Core i7-2620M 2.70 GHz CPU ve 4 GB RAM hafıza özelliklerine sahip bir kişisel bilgisayar kullanılmıştır.

5.1. Alev Sıcaklığı Kestirimi

Yüksek Fırımlar, günümüz demir ve çelik fabrikalarının vazgeçilmez yarı mamulü olan sıcak pik maden üretiminin gerçekleştiği endüstriyel tesislerdir. Yüksek fırın prosesi, çok fazla sayıdaki değişken parametreye bağlı olarak sürekli değişen ve doğrusal olmayan bir yapıya sahiptir. Fırın içi dengesi ve sıcaklık dağılımının olabildiğince dış etkilerden bağımsız ve kararlı olarak yürütülebilmesi için alev sıcaklığı değerinin takip altında tutulması çok önemlidir. Alev sıcaklığındaki ani değişimler fırın işletmesinin bozulduğunu gösteren hayati bir veri olarak düşünülmektedir.

Erdemir II. Yüksek Fırınının proses parametrelerinin geçmiş verilerine dayanılarak gerçekleştirilen ve fırın içi alev sıcaklığını kestirmeye hedefleyen bu çalışmaya baz oluşturan giriş parametreleri, sırasıyla soğuk hava akışı, soğuk hava sıcaklığı, ilave oksijen oranı, ilave buhar oranı, pulverize kömür enjeksiyon oranı ve fırın basıncı olarak seçilmiştir. Çalışmada kullanılan bu parametrelerin seçili verilerinin minimum, maksimum ve ortalama değerleri ile mühendislik birimleri Tablo 5.1’de verilmektedir.

Tablo 5.1. Alev sıcaklığı kestiriminde kullanılan giriş parametreleri

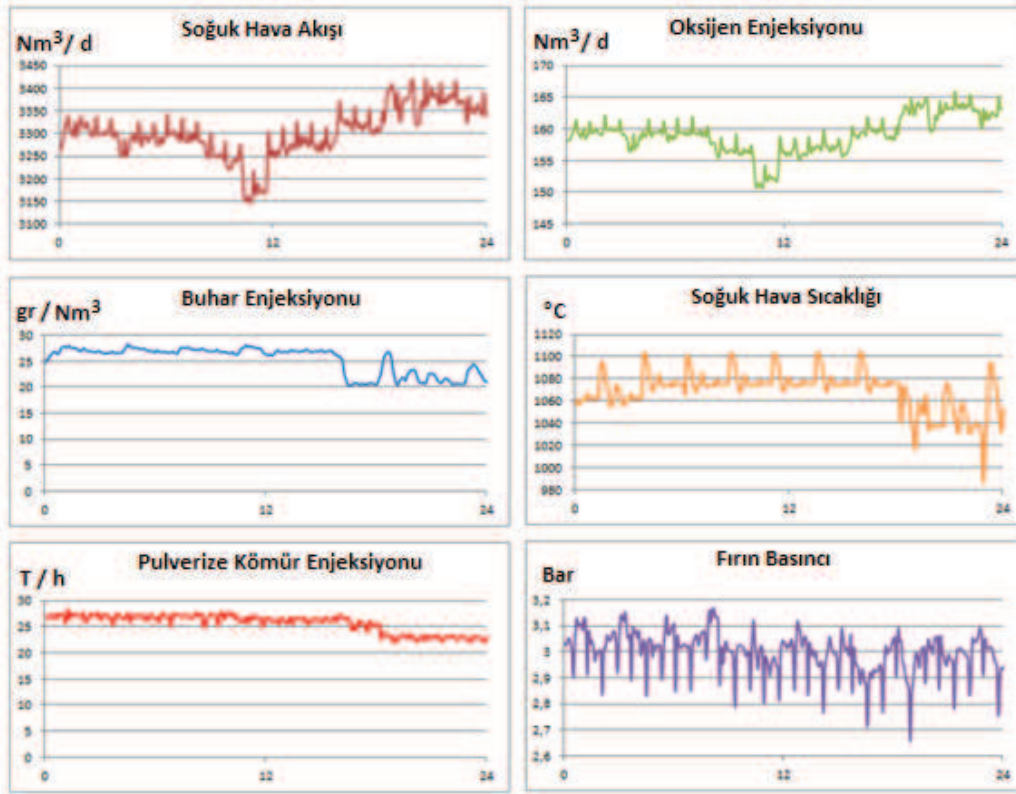
SEÇİLEN GİRİŞ PARAMETRELERİ	MİNİMUM DEĞER	MAKSİMUM DEĞER	ORTALAMA DEĞER	BİRİM
Soğuk Hava Akışı	2561,90	3612,25	3379,18	Nm ³ /min
Soğuk Hava Sıcaklığı	984,05	1113,62	1071,59	°C
İlave Oksijen Oranı	106,92	178,05	163,86	Nm ³ /min
İlave Buhar Oranı	18,61	28,33	21,93	g/Nm ³
Pulverize Kömür Enj. Oranı	13,84	35,45	27,63	T/h
Fırın Basıncı	1,94	3,17	2,93	Bar

Tabloda gösterilen giriş parametrelerine karşılık olarak gelen alev sıcaklığı parametresinin değerleri bir dosyada sınıflandırılmıştır. Çalışmada her bir parametrenin 5 dakika aralıklarla derlenen 1728 adet ölçüm değeri gözönüne alınmıştır. Mathworks Matlab R2009b yazılımında yapay sinir ağı araç kutusunun kullanılması ile gerçekleştirilecek bu çalışmanın öncesinde, giriş ve çıkış parametreleri normalize edilmiştir. Verilerin normalize edilmesi işlemi ile işlemci elemanlarında verilen kümülatif toplamaların oluşturduğu olumsuzluklar engellenir [69].

Genel olarak verilerin normalizasyonu $[0, 1]$ ya da $[-1, 1]$ aralığında yapılmaktadır. Bu çalışmada normalizasyon aralığı olarak $[0, 1]$ seçilmiştir. Normalizasyon işlemi, x_i parametresinin normal değerini, x_{min} parametrenin bulunduğu tüm veri grubu içerisindeki en küçük değeri, x_{max} tüm veri grubu içerisindeki en büyük değeri, x_i^{scaled} değeri ise parametrenin normalize edilmiş halini gösterecek şekilde aşağıdaki ifade ile hesaplanmaktadır:

$$x_i^{scaled} = \frac{x_i - x_{min}}{x_{max} - x_{min}} \quad (5.1)$$

Tüm parametrelere ait veriler normalize edildikten sonra bir sonraki aşamada, giriş parametreleri ile çıkış parametresinin Matlab programına yüklenir. İleri beslemeli geri yayımlı yapay sinir ağının seçildiği bu uygulamada, sinir ağları arayüzü kullanılarak sırasıyla eğitimde, doğrulamada ve testlerde kullanılacak verilerin yüzdesi tanımlanır. Bununla birlikte seçilen tek gizli katmanda kullanılacak gizli nöron sayısı deneme yanılma yöntemi ile optimize edilir. Eğitim algoritması seçildikten sonra da hesaplamalar gerçekleştirilir. Tez çalışmasında yüksek fırın alev sıcaklığının kestiriminde kullanılan seçili giriş parametrelerinin 24 saatlik değişimi Şekil 5.1'de referans olarak gösterilmektedir.



Şekil 5.1. Seçili fırın parametrelerinin değişiminin 24 saat süresince gösterimi


Ereğli Demir ve Çelik Fabrikası 2. Yüksek Fırına ait verilerden derlenen ve 6 adet giriş parametresine ait 1728 adet veri, ortalama 3 aylık bir çalışma dönemine ait değerler arasından elde edilmiştir. Sinir ağının modellenmesinde Mathworks firmasının yazılımı olan Matlab 2009R paket programı ve bu yazılımın nftool isimli araç kutusu kullanılmıştır. Sinir ağı modeli olarak belirlenen ileri beslemeli geri yayımlı sinir ağı, literatür taraması sonucunda kestirim problemlerindeki yüksek başarımlı nedeniyle seçilmiştir. Bununla birlikte başka bir kritik parametre olan eğitim algoritmasının seçimi de gerçekleştirilen birkaç deneme sonrasında optimize edilmiştir.

Literatürde de sıkça görüldüğü gibi Levenberg-Marquardt algoritmasının hem hız hem de başarımlı açısından optimum seçim olduğu gerçekleştirilen denemelerde de görülmüştür. Çalışmada ayrıca Gradient Descent eğitim algoritmasının kullanıldığı sinir ağına ait çıktılar karşılaştırma tablosunda yer almaktadır. Çalışmada gizli katman sayısı 1 olarak seçilmiştir. Deneme yanılma metodu ile gerçekleştirilen denemeler sonrasında gizli katmanda kullanılan gizli nöron sayısı da 4 olarak seçilmiştir. Eldeki

verilerin %60'i eğitimde, %15'i doğrulamada ve %25'i de test girdisi olarak kullanılmıştır.

Yapay sinir ağ modeli ile gerçekleştirilen kestirim çalışmalarında göz önünde bulundurulması gereken bir başka değişken parametre de kullanılacak aktivasyon fonksiyonunun seçimidir. Ağ parametrelerinin sabit tutulması ile Lineer ve Sigmoid aktivasyon fonksiyonları kullanılarak yapılan deneylerde, Sigmoid aktivasyon fonksiyonunun kullanıldığında elde edilen test seti hatasının, diğer fonksiyonların kullanımına göre daha düşük seviyelerde olduğu görülmektedir.


Bu nedenle optimum performansı sağlayan Sigmoid fonksiyonu tez çalışmasında kullanılan tüm yapay sinir ağ yapılarında aktivasyon fonksiyonu olarak seçilmiştir. Çalışma sonucunda en iyi performansı gösteren ağ yapısına ilişkin, elde edilen 432 adet alev sıcaklığı kestirim verisi ile bu verilerin gerçekteki değerleri ile karşılaştırılması Şekil 5.2'de gösterilmektedir.



Şekil 5.2. Kestirilen alev sıcaklıkları ve gerçek değerlerin karşılaştırılması

Çalışma çıktılarına bakıldığında, gerçek alev sıcaklığı değerleri ile model sonucu elde edilen kestirilmiş alev sıcaklığı değerlerinin birbirini takip ettiği gözlenmektedir. Özellikle alev sıcaklığı değerinin yukarı ya da aşağı yönlü hareketlerinin model tarafından başarılı bir şekilde yakalandığı görülmektedir. Maksimum kestirim hatası

değeri 23,14 °C olarak bulunmuştur ve hata değerlerinin özellikle -10 ile 10 °C aralığına yoğun olarak dağıldığı gözlenmiştir. Şekil 5.3'te, 432 adet örneğe ilişkin gerçek ve kestirilen alev sıcaklığı değerleri arasındaki hata dağılımı gösterilmektedir.



Şekil 5.3. Kestirilen alev sıcaklığı değerlerinin hata terimi gösterimi

İlk ANN modelinde Levenberg-Marquardt öğrenme algoritmaları uygulama çıktıları göz önünde bulundurulduğunda, alev sıcaklığı değeri ile giriş parametrelerinin arasındaki regresyon değeri 0,964 olarak bulunmuştur. Bu model sonucunda elde edilen RMSE hatası ise 7,203 olarak elde edilmiştir. Eğitim algoritmasının Gradient Descent olarak seçildiği ve aynı parametreler ile aynı veri setinin kullanıldığı ikinci çalışmada da gizli nöron sayısı 4 olarak seçilmiştir.

Bu modele ilişkin uygulama sonucunda, R^2 değeri 0,945 ve RMSE parametresinin ise 7,405 olarak elde edilmiştir. İlk ANN modeline göre daha düşük performans gösteren bu model için, eğitim algoritmasının özelliği nedeniyle ortalama 8 kat civarında ekstra bir hesaplama süresine gerek duyulmuştur. Eğitim fonksiyonu olarak Levenberg-Marquardt algoritmasının, aktivasyon fonksiyonu olarak Sigmoid fonksiyonunun kullanıldığı ANN modelinde, gizli nöron sayılarının değiştirilmesi ile gerçekleştirilen çalışmalara ilişkin R^2 performans değerleri Tablo 5.2'de karşılaştırmalı olarak özetlenmektedir.

Tablo 5.2. İlk ANN modelindeki gizli nöron sayılarının performansa etkisi

GİZLİ NÖRON SAYISI	R ² DEĞERİ
5	0,961
10	0,962
15	0,963
20	0,958
25	0,954
30	0,962

Alev sıcaklığı kestirimi çalışmasında bir sonraki aşamada MLR modelinin uygulaması üzerinde çalışma yapılmıştır. IBM SPSS paket programında gerçekleştirilen bu çalışmada yine 6 giriş parametresine karşılık bağımlı değişken olan alev sıcaklığı değeri göz önünde bulundurulmuştur. Yine 1728 adet verinin kullanıldığı bu modelde belirlilik katsayısı değeri 0,892 olarak bulunmuştur. Bir başka karşılaştırma parametresi olan RMSE değeri ise 8,789 olarak elde edilmiştir. Çalışmanın bir sonraki aşamasında ise ARIMA modeli yine IBM SPSS yazılımı kullanılarak uygulanmıştır. Tüm p, d ve q parametrelerinin “1” olarak seçildiği ARIMA(1,1,1) modelinde, diğerlerinde de olduğu gibi 1728 adet veri testlerde kullanılmıştır ve belirlilik katsayısı değeri 0,907 olarak elde edilmiştir. Verilere ARIMA modeli uygulandığında elde edilen RMSE değeri ise 8,789 olarak bulunmuştur.

Alev sıcaklığı kestirimi konusunda gerçekleştirilen son çalışmada kullanılan SVR modeli Matlab R2009b programı kullanılarak modellenmiştir. 6 adet giriş parametresine ait 1728 veri ile gerçekleştirilen çalışmada, 432 adet veri testlerde kullanılmıştır. Modelleme sırasında çekirdek (kernel) fonksiyonu olarak Lineer ve Radyal Temelli Fonksiyon (RBF) kullanılmıştır. Geri kalan tüm model parametrelerinin sabit tutulduğu deneylerde, çekirdek fonksiyonu olarak en iyi başarımın RBF fonksiyonu ile sağlandığı gözlenmiştir. Deneylerde standart olarak ϵ parametresi 0,1 olarak, C parametresi de 10 olarak seçilmiştir. RBF çekirdek fonksiyonu ile yapılan deneylerde de en iyi performansın, γ parametresinin 0,2 olarak

seçildiği durumda elde edildiği gözlenmiştir. SVR modelinin kullanıldığı tüm çalışmalar sonucunda en iyi performans gösteren model için belirlilik katsayısı 0,941 ve RMSE değeri 7,622 olarak elde edilmiştir.

Levenberg-Marquardt öğrenme algoritmasının kullanıldığı ANN modeli çalışma sonucunda en iyi performansı sağlayan model olarak gözlenmiştir. Diğer modeller için başarımlar ise sırasıyla Gradient Descent öğrenme algoritmasının kullanıldığı ANN modeli, SVR modeli, ARIMA modeli ve MLR modeli olarak sıralanmaktadır. Tüm bu çalışmalara ilişkin sonuçlar Tablo 5.3'te özetlenmektedir.

Tablo 5.3. Model çıktılarının değerlendirilmesi

KARŞILAŞTIRMA PARAMETRELERİ	ANN - 1 MODEL	ANN - 2 MODEL	SVR MODEL	ARIMA MODEL	MLR MODEL
R²	0,964	0,945	0,941	0,907	0,892
RMSE	7,203	7,405	7,622	8,274	8,789

5.2. Termik Santral Çıkış Jenaratör Gücü Kestirimi

Termik santrallerin en kritik ekipmanı olarak adlandırılan kazanların ve türbin-jeneratör grubunun matematiksel modeller yardımı ile analitik olarak tanımlanması oldukça zor bir işlemdir. Özellikle daha iyi bir operasyon için çok sayıda deney gerçekleştirmek ya da kontrol sistemi verilerinin istatistiksel optimizasyon metodları vasıtasıyla çözümü optimum işletme şartlarına ulaşabilmek için büyük önem taşımaktadır. Diğer taraftan enerji santrallerinin daha önceki dönemlerdeki çalışma şartlarını gösteren ve kayıt altına alınan geçmiş verilerini kullanarak bir takım kestirim ve tahminleme çalışmaları yapılabilmektedir [70]. Matematiksel modellere göre daha az işletme parametresinin gözönüne alınarak kullanıldığı bu çalışmalar, enerji santrali çıkışında üretilen enerji miktarını belirlemeye yönelik önemli bir çalışma alanıdır.

Enerji santrali prosesi ve kontrol sistemi binlerce deęişkenin düzenli olarak izlendięi, kontrol edildięi ve saklandığı kritik bir sürece sahiptir. Bu deęişkenlerin bir kısmı santral çıkışında üretilen elektrik enerjisi miktarını direk olarak etkilemekteyken, bir kısmı da herhangi bir etkiye sahip deęildir. Bu tez çalışmasında 600 MWe'lik kömür yakıtlı termik enerji santralinin üretimini yoğun olarak etkiledięi düşünölen 37 adet deęişken gözönüne alınmıştır. Bu deęişken parametrelerin seçiminde, ilgili santralde görev yapan mühendis ve yetkililerin tavsiyesi ile literatürde yer alan bazı çalışmalardan yararlanılmıştır. Çalışmada kullanılan 37 adet giriş parametresine ilişkin tanımlamalar, bu parametrelerin veri kümesi içerisindeki ortalama deęerleri ve mühendislik birimleri Tablo 5.4'te referans olarak gösterilmektedir.

Tablo 5.4. Termik santral gücünün kestiriminde kullanılan giriş parametreleri

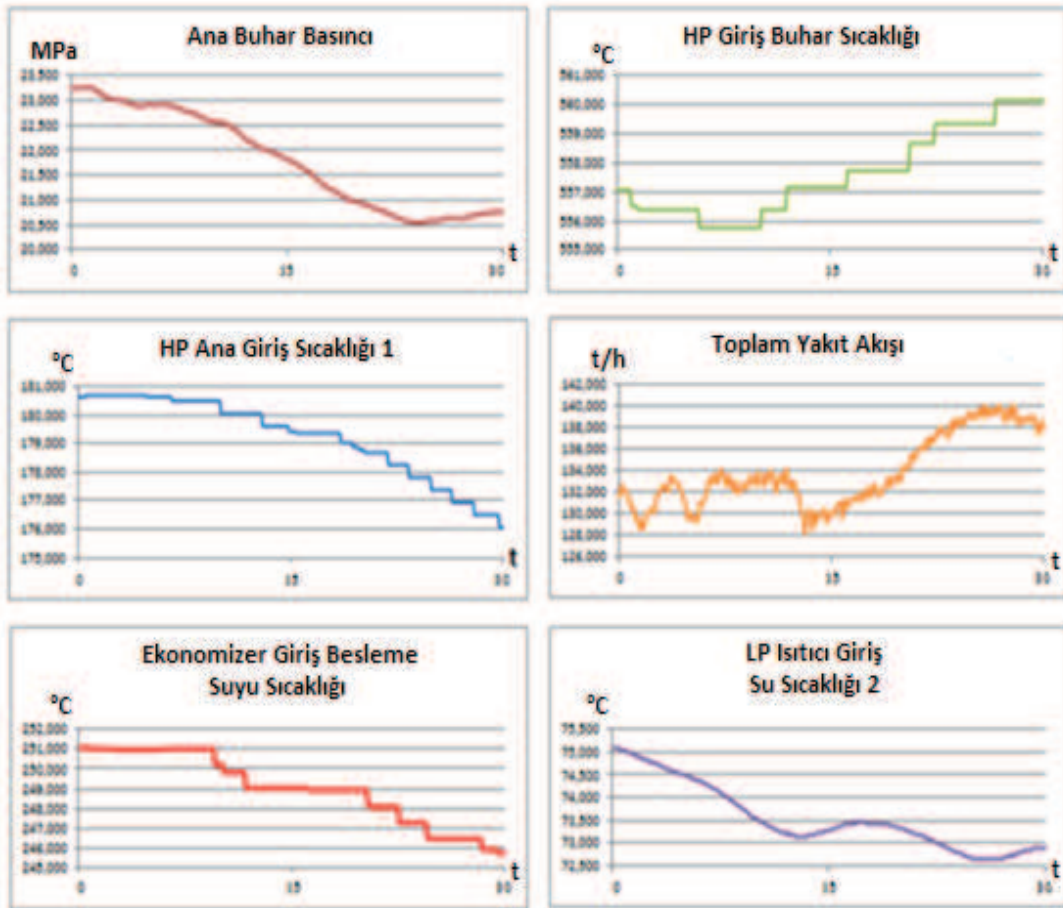
SEÇİLEN GİRİŞ PARAMETRELERİ	ORTALAMA DEĞERLERİ	MÜHENDİSLİK BİRİMLERİ
Ana Buhar Basıncı	23,86	MPa
HP Giriş Buhar Sıcaklığı	560,27	°C
Toplam Yakıt Akışı	213,83	t/h
Toplam Hava Akışı	2147,39	t/h
Sıcak RH Basıncı	3,84	MPa
IP Giriş Buhar Sıcaklığı	561,69	°C
Fırın Basıncı	-82,74	Kpa
Kazan Besleme Suyu Akışı	1746,28	t/h
Ortalama Buhar Sıcaklığı	415,63	°C
Su / Yakıt Oranı	8,09	-
Atık Gaz Çıkış Basıncı	2,88	Bar
Atık Gaz Giriş Vakum	-5,63	Bar
Atık Gaz Akış Deęeri	1616389	m3/h
Atık Gaz Giriş Sıcaklığı	32,04	°C
Atık Gaz Giriş Nem Oranı	-16,92	%

Tablo 5.4. Termik santral gücünün kestiriminde kullanılan giriş parametreleri (devamı)

Kondenser B Vakum	-96,35	Kpa
Kondenser A Sirkülasyon Giriş Su Sıcaklığı	19,83	°C
Kondenser B Sirkülasyon Çıkış Su Sıcaklığı	31,19	°C
IP Silindir Giriş Buhar Sıcaklığı	561,24	°C
IP Silindir Giriş Buhar Basıncı	3,85	MPa
Ekonomizer Giriş Besleme Suyu Sıcaklığı	273,69	°C
Kondenser A Sirkülasyon Su Çıkış Sıcaklığı	22,13	°C
Kondenser Giriş Su Sıcaklığı	2,88	°C
LP Isıtıcı Giriş Kondenser Su Sıcaklığı	31,43	°C
LP Isıtıcı Giriş Su Sıcaklığı 1	38,47	°C
LP Isıtıcı Giriş Su Sıcaklığı 2	81,12	°C
LP Isıtıcı Giriş Su Sıcaklığı 3	98,41	°C
Hava Ayrıştırıcı Isıtıcı Giriş Su Sıcaklığı	134,96	°C
HP Ana Giriş Sıcaklığı 1	181,22	°C
HP Ana Giriş Sıcaklığı 2	207,74	°C
HP Ana Giriş Sıcaklığı 3	249,27	°C
SH Sprey Su Akışı	273,89	t/h
RH Sprey Su Akışı	89,22	t/h
Ekonomizer Çıkış Besleme Suyu Sıcaklığı	13,67	°C
SH Su Hidrolik Basıncı	305,33	Mbar
RH Su Basıncı	28,94	Mbar
RH Su Sıcaklığı	10,65	°C

Termik santralde saha sensörlerinden ve enstrümanlarından gelen ve modern otomasyon sistemleri tarafından kayıt altında tutulan bu parametrelere ilişkin değerler, proses şartlarına bağlı olarak anlık olarak değişmektedir. Bu değişimlerin kontrol altında tutulabilmesi için dalgalanmaların olabildiğince minimum seviyelerde olması ve muhtemel ani dalgalanmaların önceden kestirilebilmesi ya da prosesin bir sonraki aşamasının tahminlenebilmesi gerekmektedir.

Şekil 5.4'te bu bölümde gerçekleştirilen modelleme çalışmasına konu olan 600 MWe kapasiteli kömür yakıtlı termik santrale ilişkin altı adet giriş parametresinin 30 dakika boyunca değişimi referans olarak gösterilmektedir. Bu parametrelerin trendleri incelendiğinde santral prosesinin anlık ve hızlı olarak bir takım dalgalanmaların yaşandığı gözlenmektedir.

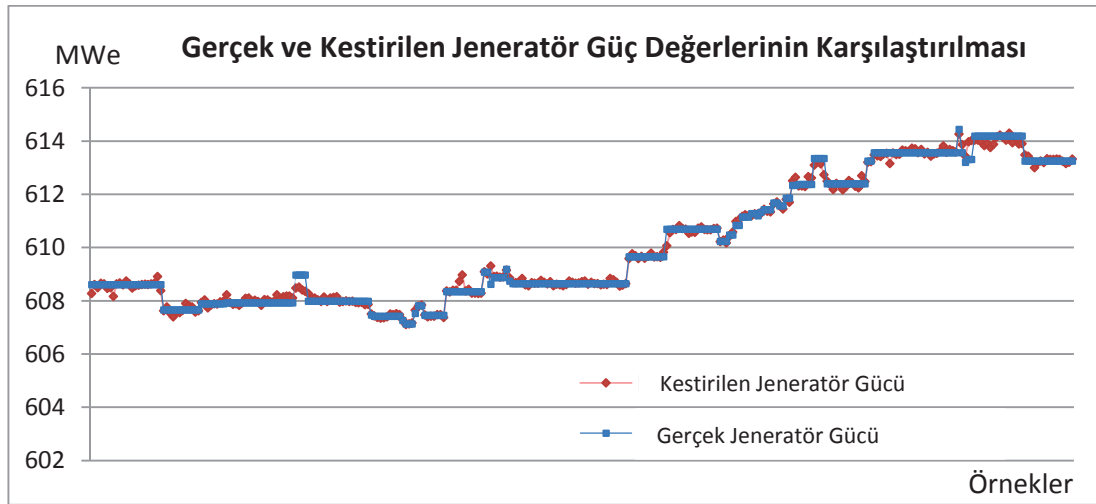


Şekil 5.4. Bazı seçili giriş parametrelerinin 30 dakikalık trendlerinin gösterimi

Seçilen 37 adet giriş parametresi, matematiksel olarak jeneratör çıkış gücü değerini en iyi tanımlayan değerler olduğu düşünülmüştür. Çalışmada her bir parametreye ait her 5 saniyede bir değişen 1570 adet veri kümesinin kullanılması ile toplamda 61230 adet veri işlenmiştir. ANN modeli Matlab R2009b yazılımı kullanılarak test edilirken, ARIMA ve MLR modelleri için SPSS 17.0 yazılımı kullanılmıştır. Matlab yazılımı özellikle transfer fonksiyonlarının, eğitilen ve test edilen nöron sayılarının ve eğitim algoritmalarının değişimini kolay bir şekilde sağladığından, yapay sinir ağı modeli için oldukça uygundur. Bununla birlikte SPSS yazılımı da, istatistiksel deneyler için sunduğu kullanıcı dostu grafik arayüzü nedeniyle çok kullanışlıdır.

Bu çalışmada kullanılan ANN modeli, ileri beslemeli geri yayılım ağı yapısında seçilmiştir. Bir önceki çalışmada, literatürle de uyumlu olarak, Gradient Descent algoritmasının düşük performans göstermesi nedeniyle sadece Levenberg-Marquardt eğitim algoritması kullanılmıştır. Aktivasyon fonksiyonu olarak daha önceki deneylerde hata performansının optimum olduğu görülen Sigmoid fonksiyonu seçilmiştir.


Kullanılan veri setinin %70'i öğrenme, %10'u doğrulama ve geriye kalan %20'si ise test amaçlı kullanılmıştır. Gizli katman sayısı bu çalışmada "1" olarak seçilmiştir ve deneme-yenilme metodu kullanılarak gerçekleştirilen çok sayıda deney sonucunda optimum gizli nöron sayısı ise 12 olarak bulunmuştur. Çalışmada, 314 adet test edilmiş jeneratör çıkış gücü değeri Şekil 5.5'te kırmızı renk ile, gerçek güç değerleri ise mavi renk ile gösterilerek, birbirleri ile karşılaştırmalı olarak sunulmaktadır.



Şekil 5.5. Kestirilen alev sıcaklığı değerlerinin gerçek değerlerle karşılaştırılması

ANN modelinin kullanıldığı bu çalışmada, gerçek değerler ile kestirim sonucu elde edilen değerlerin birbiri ile çok uyumlu olduğu ve düşük bir hata oranı ile birbirlerini takip ettiği gözlenmektedir. Şekilde jeneratör çıkış değerlerinin yukarı ya da aşağı yöndeki hareketlerinin model tarafından yüksek bir doğruluk oranı ile algılandığı ve yüksek bir başarımın sağlandığı görülmektedir. ANN model çıktıları incelendiğinde maksimum mutlak kestirim hatasının 613,32 MWe güç üretilirken 0,718 MWe mertebesinde olduğu görülmüştür. Şekil 5.6'da, gerçek proses değerleri ile kestirim

çalışması sonucunda elde edilen proses değerleri arasındaki hata bilgisi gösterilmektedir.



Şekil 5.6. Kestirilen çıkış gücü değerlerinin hata terimi gösterimi

Gerçek ve kestirim hatalarının gösterildiği grafik incelendiğinde ise hata terimlerinin birkaç pik değer dışında -0,2 ile 0,2 MWe aralığında yoğunlaştığı gözlenmektedir. Model sonucunda R^2 terimi 0,992 gibi çok yüksek bir değer elde edilmiştir. RMSE hatası değeri ise 0,1642 bulunmuştur. Sonuç olarak test edilen bu termik santralin ANN modeli ile yüksek doğrulukta modellenilebildiği gösterilmektedir.

Çalışmanın ikinci aşamasında ise sırasıyla MLR ve ARIMA modelleri SPSS yazılımı vasıtasıyla termik santral prosesine uygulanmıştır. ANN modelinde olduğu gibi bağımlı değişken olarak kullanılan jeneratör çıkış gücü değerine karşılık bağımsız 37 değişkene ait 1570'er adet veri kümesi kullanılmıştır. MLR modeli uygulanması sonucunda R^2 değeri 0,927 ve RMSE değeri de 0,3353 olarak bulunmuştur.

ARIMA modeli uygulaması da iki aşamada gerçekleştirilmiştir. İlk çalışmada p, d, q değerlerinin tümü "1" olarak seçilmiş, diğer çalışmada ise p ve q değerleri "1" olarak seçilmiş, ancak d parametresi "0" seçilerek modelin ARMA modele dönüşümü sağlanmıştır. ARIMA model çıktılarına göre R^2 değeri 0,977 ve RMSE değeri ise 0,1903 olarak elde edilmiştir. ARMA modelinde ise R^2 değeri yine 0,977 ve RMSE değeri ise 0,1879 olarak bulunmuştur. Tablo 5.5'te, bu bölümde yapılan tüm çalışmalara ilişkin özet bir tablo karşılaştırmalı olarak gösterilmektedir.

Tablo 5.5. Model çıktılarının değerlendirilmesi

KARŞILAŞTIRMA PARAMETRELERİ	ANN MODELİ	MLR MODELİ	ARIMA MODELİ	ARMA MODELİ
R²	0,992	0,927	0,977	0,977
RMSE	0,1642	0,3353	0,1903	0,1879

5.3. Termik Santral Baca Çıkışındaki Emisyon Kestirimi

Son yıllarda teknolojik gelişmelerin çevre ve insan hayatına yansıttığı olumsuzluklar nedeniyle özellikle gelişmiş ülkelerde başlayıp tüm dünyaya yayılan bir takım regülasyon ve yaptırımlar söz konusudur. Özellikle nükleer ve termik santraller başta olmak üzere konvansiyonel tipteki enerji santrallerinin doğaya atık gaz salınımları, radyasyon, gürültü ve çevre kirliliği etkileri son derece hassas bir tartışma konusu olarak kamuoyunu etkilemektedir.

Kömür yakıtlı kazanların kullanıldığı termik santrallerin atık değerlerinin istenilen değerleri aşması durumunda firmaların karşı karşıya kalacağı cezai yaptırımlar nedeniyle, de-NO_x sistemlerinin kullanımı, enstrüman ve kontrol sistemlerinin modernizasyonu, gelişmiş emisyon sistemlerinin kullanımı, proses optimizasyonu gibi yatırımlar gerçekleştirilmektedir. Ancak çevresel etkileri minimize etmeye yönelik bu yöntemler öncesinde emisyon izleme sistemlerinin doğru, güvenilir ve sürekli ölçüm yapmasının sağlanması elzemdir.

Çalışmanın bu bölümünde, Kocaeli il sınırlarında kurulu bulunan ve kömürle çalışan 180 MWe gücündeki bir termik enerji santralinin prosesi ve baca emisyon verileri modellenmektedir. Santralin 15 dakikalık ortalama emisyon ölçümleri ile bu değerleri etkilediği düşünülen parametrelerin kombine edilmesi ortaya konulan bu çalışmada, ANN, MLR ve ARIMA yöntemleri kullanılmıştır. Enerji santrallerindeki otomasyon sistemleri saha sensör ve enstrümanlarından gelen yüzlerce bilgiyi işler ve değerlendirir.

Bu verilerin bir kısmı baca emisyon değerlerini direkt olarak etkilerken, bir kısmı da ya limitli bir etkiye sahiptir ya da herhangi bir etkisinin olmadığı düşünülmektedir. Bu çalışmada, aşağıdaki tabloda verilen 8 adet parametrenin baca atık NO_x değerini etkilediği düşünüldüğünden modellemede kullanılmaktadır. Tablo 5.6'da, söz konusu giriş parametrelerinin minimum, maksimum ve ortalama değerleri ile mühendislik birimleri gösterilmektedir.

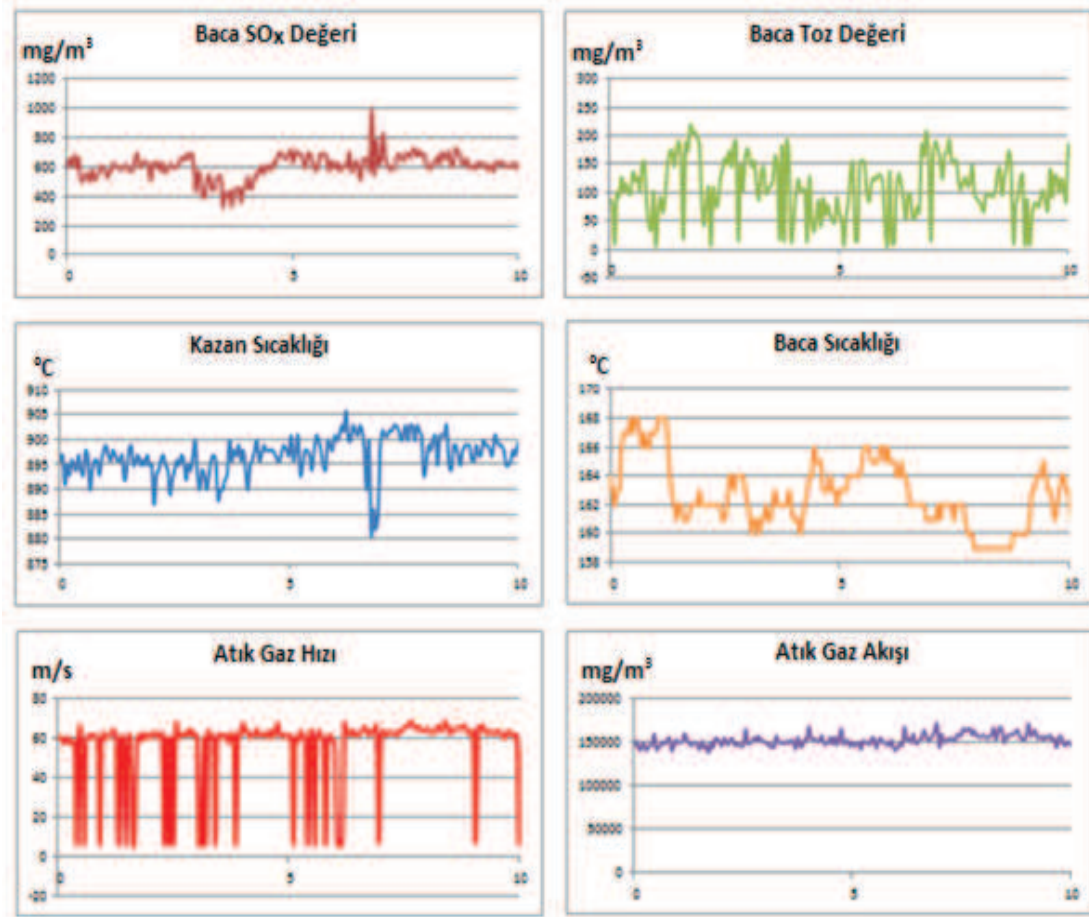
Tablo 5.6. Emisyon kestiriminde seçili model parametreleri

SEÇİLİ GİRİŞ PARAMETRELERİ	MAKSİMUM DEĞERLER	ORTALAMA DEĞERLER	MİNİMUM DEĞERLER	BİRİMLER
Baca Sıcaklığı	176,4	161,9	77,8	°C
Atık Gaz Akışı	143153,8	86913,1	55551,3	m ³ /h
Baca Toz Değeri	306,2	125,2	8,4	mg/m ³
Atık Gaz Çıkış Hızı	91,2	51,1	4,7	m/s
Kazan Çıkış Sıcaklığı	949,5	895,2	177,8	°C
Baca O ₂ Miktarı	167,2	48,6	5,8	mg/m ³
Baca SO _x Miktarı	1050,7	586,7	150,4	mg/m ³
Baca CO ₂ Miktarı	954,2	63,6	16,7	mg/m ³

180 MWe'lik termik enerji santralinde kurulu bulunan sürekli emisyon izleme sistemine ait veritabanından ve santrale ait DCS otomatik kumanda sisteminden elde edilen bu parametreler 15 dakika aralıklarla kaydedilmektedir. Bu zaman dilimi içinde anlık olarak yaklaşık 1-1,5 saniyede mertebesinde anlık ölçümler gerçekleştirilir. Hem emisyon izleme yazılımı hem de DCS sistemi anlık olarak ölçülen her bir parametreyi veritabanına kaydeder.

Elde edilen tüm kayıtların her 15 dakikada bir ortalama değerleri alınır ve ilgili veritabanı dosyasına kaydedilir. Dolayısı ile çalışmada bu 15 dakikalık aralıklarla kaydedilmiş parametrelerin değerleri kullanılmaktadır. Şekil 5.7'de 6 adet giriş parametresinin 10 günlük değişimleri referans olarak gösterilmektedir. Söz konusu

parametrelerin özellikle belli dönemlerde hızlı bir şekilde yukarı ve aşağı yönlü hareket ettikleri görülmektedir. Termik santraldeki proses şartları dolayısı ile yaşandığı düşünülen bu dalgalanmalar baca atık gazı kompozisyonlarını etkilemektedir. O nedenle baca atık gazı yoğunluğunu etkileyen parametrelerin sürekli olarak takibi ve bu prosesin modellenerek ileriki dönemlerde alacağı değerlerin tahminlenmesi işletme için büyük önem taşımaktadır.




Şekil 5.7. Seçili giriş parametrelerinin 10 günlük değişimi

Çalışmada seçilen 8 adet giriş parametresinin, baca gazı NO_x değerlerini matematiksel olarak en iyi tanımlayan değerler olduğu düşünüldüğü için seçilmiştir. Her bir parametreye ait her 15 dakikada bir değişen 2000 adet veri kümesinin kullanılması ile toplamda 19000 adet veri işlenmiştir. Bu çalışmada da ANN modeli Matlab R2009b yazılımı kullanılarak test edilirken, ARIMA ve MLR modelleri için SPSS 17.0 yazılımı kullanılmıştır.

Çalışmada kullanılan ANN modeli, ileri beslemeli geri yayılım ağı yapısında seçilmiştir. Alev sıcaklığı kestirimi çalışmasında, literatürle de uyumlu olarak, Gradient Descent algoritmasının düşük performans göstermesi nedeniyle sadece Levenberg-Marquardt eğitim algoritması kullanılmıştır. Aynı şekilde aktivasyon fonksiyonu olarak da daha önce optimum sonuçların elde edildiği Sigmoid fonksiyonu seçilmiştir.

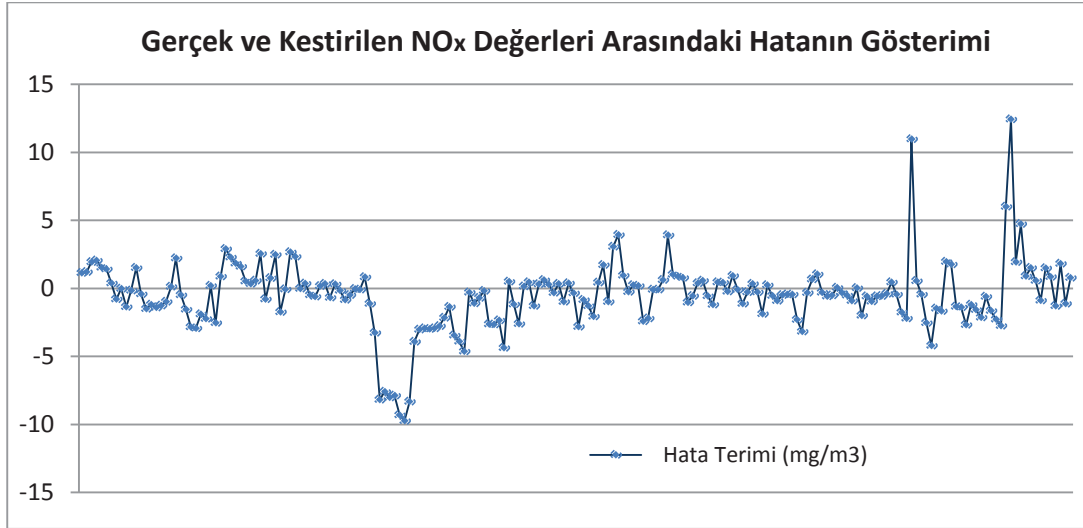
Elimizdeki veri setinin %80'i öğrenme, %10'u doğrulama ve geriye kalan %10'u ise test amaçlı kullanılmıştır. Gizli katman sayısı bu çalışmada "1" olarak seçilmiştir ve deneme-yanılma metodu kullanılarak gerçekleştirilen çok sayıda deney sonucunda optimum gizli nöron sayısı ise 24 olarak bulunmuştur. Çalışmada, 200 adet test edilmiş atık NO_x gazı emisyon değeri Şekil 5.8'de kırmızı renk ile gösterilmektedir. Bununla birlikte santralin gerçek NO_x gazı emisyon değerleri ise mavi renk ile gösterilmektedir ve bu değerlerin birbirleri ile etkileşimleri karşılaştırmalı olarak sunulmaktadır.



Şekil 5.8. Gerçek ve kestirilen NO_x değerlerinin gösterimi

Bu sinirsel ağ modeline ilişkin benzetim sonuçları incelendiğinde, gerçek değerler ile kestirim sonucu elde edilen değerlerin birbirleri ile uyumlu olduğu gözlenmektedir. Özellikle gerçek NO_x değerlerinin aşağı yukarı hareketlerinin model tarafından yüksek doğruluk ile algılanabildiği görülmektedir.

ANN model çıktılarına göre, maksimum mutlak kestirim hatasının 130 mg/m^3 mertebelerindeki NO_x değeri için $12,41 \text{ mg/m}^3$ olduğu görülmüştür. Dolayısı ile çalışma sonucunda görülen en büyük hata değeri %9,5 olarak kaydedilmiştir. Şekil 5.9'da, gerçek proses değerleri ile kestirim çalışması sonucunda elde edilen proses değerleri arasındaki hata bilgisinin değişimi gösterilmektedir.



Şekil 5.9. Gerçek ve kestirilen NO_x değerleri arasındaki hata değerleri

Gerçek değerlerin ve kestirim hatalarının gösterildiği grafik incelendiğinde ise hata terimlerinin birkaç pik değer dışında -5 ile 5 mg/m^3 aralığında yoğunlaştığı gözlenmektedir, ancak az da olsa 10 mg/m^3 değerini aşan pik değerlere de rastlanmıştır. Gerçek NO_x değerlerindeki dalgalanmaların, santralin hammadde kalitesizliği, işletme sırasındaki problemler ya da geçiş dönemlerindeki sıcaklık ve basınç dalgalanmalarından kaynaklandığı düşünülmektedir. Model sonucunda R^2 terimi $0,949$ olarak elde edilmiştir ve RMSE hata değeri ise $0,819$ bulunmuştur. Sonuç olarak bu termik santrale ilişkin emisyon değerlerinin ANN modeli ile başarılı olarak ve nispeten yüksek doğrulukla modellenilebildiği gösterilmektedir.

Çalışmanın ikinci aşamasında ise sırasıyla MLR ve ARIMA modelleri yine SPSS yazılımı vasıtasıyla ilgili termik santral prosesine uygulanmıştır. ANN modelinde olduğu gibi bağımlı değişken olarak kullanılan baca gazı NO_x emisyon değerine karşılık bağımsız 8 değişkene ait 2000'er adet veri kümesi kullanılmıştır. MLR modeli uygulanması sonucunda R^2 değeri $0,735$ ve RMSE değeri de $9,679$ olarak

bulunmuştur. ARIMA modeli uygulamasında ise p, d, q değerlerinin tümü “1” olarak seçilmiştir. ARIMA model çıktılarına göre R^2 değeri 0,862 ve RMSE değeri ise 5,134 olarak elde edilmiştir.

ARIMA modeli MLR modeline göre daha iyi performans göstermekteyken, ANN modelinin bu iki modele göre oldukça başarılı olduğu gözlenmektedir. Tablo 5.7, bu bölümde yapılan çalışmaların karşılaştırmalı bir özeti olarak sunulmaktadır.

Tablo 5.7. Model çıktılarının değerlendirilmesi

KARŞILAŞTIRMA PARAMETRELERİ	ANN MODELİ	ARIMA MODELİ	MLR MODELİ
R^2	0,949	0,862	0,735
RMSE	0,819	5,134	9,679

BÖLÜM 6. SONUÇLARIN DEĞERLENDİRİLMESİ VE ÖNERİLER

Endüstriyel tesislerde veri madenciliği uygulaması olarak planlanan bu tez çalışmasında, yüksek fırın alev sıcaklığı, termik santral jeneratör çıkış gücü ve bir başka termik santrale ilişkin baca gazı NO_x emisyon değeri parametreleri, günümüzde yaygın bir şekilde kullanılan yapay zeka tekniği olan Yapay Sinir Ağları yöntemi ile modellenmiştir. Bu çıkış parametrelerini etkilediği düşünülen giriş parametrelerinin seçimi ve söz konusu tesislere ait geçmiş proses verileri kullanılarak gerçekleştirilen testlerde, Yapay Sinir Ağı modelinin gayet başarılı sonuçlar verdiği tespit edilmiştir. Ayrıca, Çoklu Doğrusal Regresyon ve Otoregresif Entegre Kayan Ortalama modelleri de, Yapay Sinir Ağı modeli çıktıları ile karşılaştırmak üzere referans amaçlı olarak kullanılmıştır. Alev sıcaklığı değerinin kestirimi çalışmasında, ek olarak, Destek Vektör Regresyonu modeli ile de benzer testler gerçekleştirilmiştir.

Çalışmanın ilk aşamasında, Ereğli Demir ve Çelik Fabrikası, 2. Yüksek Fırın tesisinin geçmiş verileri kullanılarak önemli bir proses parametresi olan alev sıcaklığı değerlerinin kestirilmesi hedeflenmiştir. Alev sıcaklığı parametresini yüksek oranda etkilediği düşünülen 6 adet giriş parametresinin kullanıldığı bu modelleme çalışması, sırasıyla ANN, MLR, ARIMA ve SVR yöntemleri kullanılarak gerçekleştirilmiştir. Alev sıcaklığı değerindeki dalgalanmalar çok kritik bir prosese sahip olan yüksek fırının işletmesine direkt olarak etki etmektedir. O nedenle bu parametrenin kontrol edilmesi ve artma ya da azalma yönündeki hareketinin takibi işletme yönetimi anlamında çok kritik bir öneme sahiptir. Bu parametrenin tahminlenmesi ile operatörlerin ilave oksijen miktarı, kömür enjeksiyonu, buhar ilavesi, soğuk hava sıcaklığı, vb. parametreleri kontrol ederek fırının doğru bir şekilde yönetimi sağlanacaktır.

Yapılan simülasyon çalışmaları sonucunda önerilen modellerin bu parametreyi hızlı, doğru ve güvenli bir şekilde tahmin edebildiği ve en önemlisi alev sıcaklığındaki

dalgalanma yönlerinin başarılı bir şekilde kestirilebildiği gösterilmiştir. Deneysel çalışmalar sonucunda, gerçek alev sıcaklığı değerleri ile kestirilen değerler arasındaki mutlak farkın oldukça düşük olduğu ve fırının ısı rejiminin çok düşük bir hata oranı ile tahminlenebildiği gözlenmiştir. Özellikle yapay sinir ağı modeli ile yapılan ve Levenberg-Marquardt eğitim algoritmasının kullanıldığı çalışmada, 10 °C'lik hata oranı için, tahminleme doğruluğunun %99,93 oranında olduğu gösterilmiştir. Aşağıda sıralanan maddeler, yapılan çalışmaların spesifik bir özeti olarak ortaya konulmaktadır.

- a. ANN modeli, SVR, MLR ve ARIMA modeline göre, performans kriteri olarak seçilen R^2 and RMSE anlamında daha iyi bir başarıyı göstermiştir,
- b. Levenberg-Marquardt eğitim algoritmasının kullanıldığı sinir ağı modeli, literatürdeki çalışmalara uygun olarak, Gradient Descent algoritmasına göre hem daha başarılı sonuçlar vermiştir hem de test süresi bakımından oldukça hızlı performansa sahip olduğu görülmüştür,
- c. Alev sıcaklığı değerinin ANN modeli kullanılarak başarılı ve yüksek doğruluk ile tahmin edilebildiği gösterilmiştir.
- d. ANN modelinin özellikle ani sıcaklık dalgalanmalarını hızlı ve doğru bir şekilde kestirebildiği gösterilmiştir,
- e. Gauss çekirdek fonksiyonunun kullanıldığı SVR modelinin çıktıları başarılıdır, ancak bu model her iki ANN modeline nazaran daha düşük bir performans göstermiştir,
- f. MLR ve ARIMA modelleri birbirine yakın ve olumlu sonuçlar vermiştir. Ancak başarımları ANN ve SRV modeline göre daha düşük mertebelerde kalmıştır,
- g. Alev sıcaklığı değerinin tahminlenmesinde önerilen 6 adet giriş parametresinin bu parametre ile yüksek bir regresyon ilişkisine sahip olduğu gösterilmiştir.

Dolayısı ile 6 adet parametrenin seçimindeki kriterin doğru olduğu gözlenmektedir,

- h. Alev sıcaklığının izlenmesi ve kestirimi yüksek başarımla sağlanması ile operatörlerin farkındalığının, fırın verimliliğinin ve kararlılığının artmasına büyük katkı sunacağı gösterilmektedir.

Çalışmanın ikinci bölümünde, Türkiye’de Çanakkale bölgesinde kurulu bulunan İÇDAŞ’a ait 600 MWe gücündeki kömür yakıtlı bir termik santral prosesi sırasıyla ANN, MLR ve ARIMA modelleri kullanılarak modellenmiştir. Çalışmada santralin çıkış gücü, giriş değerleri olarak kullanılan 37 adet proses parametresinin yardımı ile kestirilmiştir. Özellikle Levenberg-Marquardt öğrenme algoritmasının kullanıldığı sinirsel ağ modelinde 613,3 MWe’lik jeneratör çıkış gücü değeri için maksimum 0,717 MWe’lik bir hata oranı ile tahminlemenin yapılabildiği gösterilmiştir. ANN modeli kullanılarak yapılan çalışmalarda, gerçek çıkış gücü ile kestirilen güç değerleri arasındaki hata oranının yoğun bir şekilde -0,2 MWe ile 0,2 MWe aralığına dağıldığı gözlenmiştir. Yapılan deneysel çalışmaların ve model çıktılarının spesifik bir özeti, aşağıda maddeler halinde listelenmektedir.

- a. Tek gizli katman, 12 gizli nöron, 1570 örnek veri ve Levenberg-Marquardt eğitim algoritmasının kullanıldığı ANN modeli için, elde edilen hata değerleri mükemmel yakın sonuçlar vermiştir,
- b. ANN modeli, MLR ve ARIMA modeline göre, performans kriteri olarak seçilen R^2 ve RMSE anlamında daha iyi bir başarımla göstermiştir,
- c. ARIMA, ARMA ve MLR modellerinin de yüksek performans gösterdiği gözlenmiştir. Özellikle seçilen giriş parametrelerinin hedef parametre ile olan yüksek regresyonu, bu parametrelerinin optimuma yakın olarak seçildiği sonucunu ortaya çıkarmaktadır,

- d. ARIMA ve MLR modelleri için simülasyon sürelerinin birbirine çok yakın olduğu ve özellikle ANN modeline göre yaklaşık üç kat hızlı sonuç verdikleri gözlenmiştir,
- e. Proses değerlerindeki pik değerlerin, kömür kalitesi, kazan verimliği ya da işletme anormallikleri dönemlerinden kaynaklı sıcaklık ve basınç dalgalanmalarından ötürü yaşandığı düşünülmektedir. Ancak ANN modelin, testlerde karşılaşılan bu dalgalanmaların yönünü ve şiddetini yüksek oranda yakalayabildiği gözlenmiştir,
- f. Sunulan ANN modelinin yüksek başarımı nedeniyle santralin DCS sistemine entegre edilmesi önerilmektedir. Dolayısı ile operatörlerin, yakıt, su ve buhar akışları, sıcaklık ve basınç değerlerini değiştirerek türbin çıkış gücünü optimize edebileceği düşünülmektedir.

Çalışmanın son bölümünde ise, Türkiye’de Kocaeli bölgesinde kurulu bulunan 180 MWe nominal gücündeki kömür yakıtlı bir termik santralin NO_x emisyon parametresi sırasıyla ANN, MLR ve ARIMA modelleri kullanılarak modellenmiştir. Çalışmada santralin emisyon değerlerini etkilediği düşünülen 8 adet proses değeri giriş parametresi olarak seçilmiş ve simülasyonlarda kullanılmıştır. ANN modeli kullanılarak yapılan çalışmalarda, gerçek NO_x değerleri ile kestirilen NO_x değerleri arasındaki hata oranının yoğun bir şekilde -5 mg/m³ ile 5 mg/m³ aralığına dağıldığı gözlenmiştir. Gerçekleştirilen çalışmaların ve model çıktılarının spesifik bir özeti, aşağıda maddeler halinde listelenmektedir.

- a. ANN modeli, MLR ve ARIMA modeline göre, performans kriteri olarak seçilen R² and RMSE anlamında daha iyi bir başarımlı göstermiştir,
- b. Tek gizli katman, 24 gizli nöron, 2000 örnek veri ve Levenberg-Marquardt eğitim algoritmasının kullanıldığı ANN modeli için, elde edilen hata değerleri oldukça başarılı sonuçlar vermiştir. Ortalama hata değerlerinin %0,6 mertebesinde olduğu bulunmuştur,

- c. ANN modeli sonuçları değerlendirildiğinde, 13 mg/m^3 ve -10 mg/m^3 mertebelerindeki pik değerler görülmüştür. Bu durumun, test verilerinin bulunduğu işletme şartlarında yaşanan bazı anormallikler, ani basınç ve sıcaklık dalgalanmalarından ya da santralin yük alma - yük atma operasyonundan kaynaklandığı düşünülmektedir,
- d. ARIMA modelinin nispeten iyi performans gösterdiği ve seçilen giriş parametrelerinin hedef parametre ile olan regresyonunun yüksek olduğu görülmüştür,
- e. MLR modeli çıktılarının, NO_x değerlerini tahmin etmede çok başarılı olmadığı görülmüştür,
- f. ARIMA ve MLR modelleri için simülasyon sürelerinin birbirine çok yakın olduğu ve özellikle ANN modeline göre yaklaşık dört kat hızlı sonuç verdikleri gözlenmiştir,
- g. ANN modelinin santral kontrol sistemine bir simülatör olarak entegre edilmesi önerilmektedir. Böylelikle, NO_x değerlerinin anlık olarak izlenmesi vasıtasıyla sistem parametrelerinin optimal kontrolü sağlanabilecektir. Bu işlemler ile, termik santralde yanma işlemi tam olarak sağlanacaktır, kazanın ömrü uzayacaktır ve daha düşük emisyon değerleri elde edilebilecektir.

Gerçekleştirilen her üç çalışmanın sonucunda, sunulan modellerin, yüksek fırınlarda alev sıcaklığı parametresi, termik santrallerin çıkış gücü parametresi ve termik santral NO_x emisyon parametresini yüksek başarımla kestirebildiği gösterilmiştir. Literatüre sunulan bu çalışma ile, özellikle yapay sinir ağı modelinin, tesis otomasyon sistemine entegre edilmesi ve proses optimizasyonu sağlayacak gerçek zamanlı bir simülatör olarak kullanılması önerilmektedir.

Bununla birlikte, gerçek zamanlı verileri işlenmesi ile, tesislerin ilgili işletme parametre kontrollerine anlık olarak önerilerde bulunabilecek bir Seviye-2 uzman sistem (Level-2 expert system) yazılımı geliştirilebilir. Bu çalışmaya alternatif olarak

ise, sistem başarımını arttırmaya yönelik, farklı doğrusal olmayan matematiksel modeller, bulanık mantık tabanlı yöntemler ya da iki yöntemin birbirine entegre edilmesiyle elde edilecek hibrit modeller kullanılabilir. Ayrıca yüksek fırınlar ve termik santral proseslerinde kullanılan farklı parametrelere ilişkin kestirim ve tahminleme çalışmaları da gerçekleştirilebilir.

KAYNAKLAR

- [1] BHAMBRE K.S., MITRA S.K., GAITONDE U.N., Modeling of a coal-fired natural circulation boiler, ASME Journal of Energy Resources Technology, Vol. 129, pp. 159-167, 2007.
- [2] USTAOGU B., CIGIZOGLU H.K., KARACA M., Forecast of Daily Mean, Maximum and Minimum Temperature Time Series by Three Artificial Neural Network Methods. Meteorological Applications, Vol. 15, pp. 431-445, 2008.
- [3] ZHOU M., GAUTHIER J.E.D., A new method for adiabatic flame temperature estimations of hydrocarbon fuels, Fuel, Vol. 78, Issue 4, pp. 471-478, March 1999.
- [4] MASHUGA C.V., CROWL D.A, Flammability zone prediction using calculated adiabatic flame temperatures, Process Safety Progress, Vol. 18, Issue 3, pp. 127-134, 2004.
- [5] HELLBERG P., JONSSON T.L.I., JONSSON P.G., SHENG D.Y., A Model of Gas Injection into a Blast Furnace Tuyere. Fourth International Conference on CFD in the Oil and Gas Metallurgical & Process Industries: SINTEF / NTNU Norway, Vol. 1, Issue 1, 2005.
- [6] DE MEDERIOS F.T.P., NOBLAT S.J.X, FILETI A.M.F., Reviving traditional blast furnace models with new mathematical approach, Ironmaking & Steelmaking, Vol. 34, Issue 5, pp. 410-414, September 2007.
- [7] ASL Z.M., SALEM A., Investigation of the flame temperature for some gaseous fuels using artificial neural network, International Journal of Energy and Environmental Engineering, Vol. 1, Issue 1, pp. 57-63, 2010.
- [8] HOONEY P.L., BODEN A., WANG C., GRIP C., JANSSON B., Design and Application of a Spreadsheet based Model of the Blast Furnace Factory, ISIJ International, Vol. 50, Issue 7, pp. 924-930, 2010.
- [9] GEERDES M., TOXOPEUS H., GALIS G., On the future of blast furnace ironmaking, Proceedings of the 8th Ironmaking Conference IAS'2011, Rosario, Santa Fe, Argentina, pp. 183-191, 2011.

- [10] BHATTACHARJEE D., DASH S.K., DAS A.K., Application of Artificial Intelligence in Tata Steel, Tata Search 1999, 1999.
- [11] 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.
- [12] DE S., KAIADI M., FAST M., ASSAIDI M., Development of an artificial neural network model for the steam process of a coal biomass cofired combined heat and power (CHP) plant in Sweden, Energy, Vol. 32, Issue 11, pp. 2099–2109, November 2007.
- [13] SMREKAR J., PANDIT D., FAST M., ASSAIDI M., DE S., Prediction of power output of a coal-fired power plant by artificial neural network, Neural Computing and Applications, Vol. 19, Issue 5, pp. 725-740, 2010.
- [14] SURESH M.V.J.J., REDDY K.S., KOLAR A.K., ANN-GA based optimization of a high ash coal-fired supercritical power plant, Applied Energy, Vol. 88, Issue 12, p. 4867–4873, December 2011.
- [15] BEKAT T., ERDOGAN M., INAL F., GENC A., Prediction of the bottom ash formed in a coal-fired power plant using artificial neural networks, Energy, Vol. 45, Issue 1, pp. 882-887, September 2012.
- [16] LIA G., NIUA P., WANGA H., LIUA Y., Least Square Fast Learning Network for modeling the combustion efficiency of a 300MW coal-fired boiler, Neural Networks, Vol. 51, pp. 57-66, 2014.
- [17] YAO H.M., VUTHALURU H.B., TADE M.O., Djukanovic D., Artificial neural network-based prediction of hydrogen content of coal in power station boilers, Fuel, Vol. 84, Issues 12–13, pp. 1535–1542, September 2005.
- [18] LIU Y.P., WU M.G, QIAN J.X., Predicting coal ash fusion temperature based on its chemical composition using ACO-BP neural network, Thermochemica Acta, Vol. 454, Issue 1, pp.64-68 , February 2007.
- [19] SMREKAR J., ASSAIDI M., FAST M., KUSTRIN I., DE S., Development of artificial neural network model for a coal-fired boiler using real plant data, Energy, Vol. 34, Issue 2, pp. 144-152, February 2009.
- [20] FOLEY A.M, LEAHY G., MARVUGLIA A., MCKEOGH E.J., Current methods and advances in forecasting of wind power generation, Renewable Energy, Vol. 37, Issue 1, pp. 1-8, January 2012.
- [21] SHI J., Forecasting Power Output of Photovoltaic Systems Based on Weather Classification and Support Vector Machines, IEEE Transactions on Industry Applications, Vol. 48, Issue 3, pp. 1064-1069, 2012.

- [22] LI K., Thompson S., Peng J., Modelling and prediction of NO_x emission in a coal-fired power generation plant, *Control Engineering Practice*, Vol. 12, Issue 6, pp. 707-723, June 2004.
- [23] ZHENG L., YU M., YU M., Monitoring NO_x Emissions from Coal Fired Boilers Using Generalized Regression Neural Network, *The 2nd International Conference on Bioinformatics and Biomedical Engineering (ICBBE 2008)*, pp. 1916-1919, May 2008.
- [24] ZHENG L.G., ZHOU H., CEN K.F., WANG C.L., A comparative study of optimization algorithms for low NO_x combustion modification at a coal-fired utility boiler, *Expert Systems with Applications*, Vol. 36, Issue 2, Part 2, pp. 2780-2793, March 2009.
- [25] SHAKIL M., ELSHAFEI M., HABIB M.A., MALEKI F.A., Soft sensor for NO_x and O₂ using dynamic neural networks, *Computers & Electrical Engineering*, Vol. 35, Issue 4, pp. 578-586, July 2009.
- [26] ZHENG L., ZHOU H., WANG C., CEN K., Combining Support Vector Regression and Ant Colony Optimization to Reduce NO_x Emissions in Coal-Fired Utility Boilers, *Energy Fuels*, Vol. 22, No. 2, pp. 1034-1040, 2008.
- [27] ZHOU H., ZHOU J.P., ZHENG L.G., WANG C.L., CEN K.F., Modeling NO_x emissions from coal-fired utility boilers using support vector regression with ant colony optimization, *Engineering Applications of Artificial Intelligence*, Vol. 25, Issue 1, pp. 147-158, February 2012.
- [28] YU T., ZHU H., Multi-objective Optimization of Coal-fired Boiler Combustion Based on NSGA-II, *Journal of Networks*, Vol. 8, no. 6, pp. 1300-1306, June 2013.
- [29] BUNYAMIN M.A., YAP K.S., ABDULAZIZ N.L.A., TIONG S.K., WONG S.Y., KAMAL M.F., A hybrid genetic algorithm and linear regression for prediction of NO_x emission in power generation plant, *4th International Conference on Energy and Environment (ICEE 2013): IOP Conf. Series: Earth and Environmental Science*, no. 16, doi:10.1088/1755-1315/16/1/012101, 2013.
- [30] LI J., ZHANG X., YANG W., BLASIAK W., Effects of Flue Gas Internal Recirculation on NO_x and SO_x Emissions in a Co-Firing Boiler, *International Journal of Clean Coal and Energy*, vol. 2, no. 2, pp. 13-21, 2013.
- [31] WU S.C., JO Y.M., PARK Y.K., Effect of Heat Recovery from Flue Gas on the Local Humidity and NO_x Dispersion in a Thermal Power Station, *Aerosol and Air Quality Research*, Vol. 14, pp. 840-849, 2014.

- [32] SAIT.K., REDDY K.A., Measurement of Control of NO_x emissions using Soft Computing in a Thermal Power Plant, Recent Advances in Engineering and Computational Sciences (RAECS), pp. 1-6, 6-8 March 2014.
- [33] BOZKURT E., Yüksek Fırın Analizi ve Yapay Sinir Ağları ile Modellenmesi, Yüksek Lisans Tezi, Sakarya Üniversitesi, Haziran 2007.
- [34] ASLAN Ö., Demir Çelik Alanında Doğrusal ve Doğrusal Olmayan Model Yapıları Tabanlı Model Öngörümü Denetleyici Uygulamaları, Yüksek Lisans Tezi, Karaelmas Üniversitesi, Haziran 2009.
- [35] PEACEY J.G., DAVENPORT W.G., The iron blast furnace theory and practice, Pergamon Press, Oxford, pp.1-29, 1979.
- [36] GARCIA F.A., CAMPOY P., MOCHON J., RUIZ-BUSTINZA I., VERDEJA L.F., DUARTE R.M., A New “User-friendly” Blast Furnace Advisory Control System Using a Neural Network Temperature Profile Classifier, ISIJ International, Vol. 50, No. 5, pp. 730–737, 2010.
- [37] AYDIN Ö., Yüksek Fırın İşletmeciliğinde Optimizasyon, Yüksek Lisans Tezi, Yıldız Teknik Üniversitesi, İstanbul 2005.
- [38] TURAN A., Cüruf Oranının Yüksek Fırın Üretimine Etkisi, 1. Demir Çelik Sempozyumu Bildirileri, Sayı 57, Sayfa 520-524, 2001.
- [39] DANFORTH G. W., An elementary outline of mechanical processes, The United States Naval Institute, 2nd edition, 1917.
- [40] HORROCKS K., MCCARTHY K., THOMPSON A., ZULLI P., Pulverised Coal Injection in Ironmaking Blast Furnaces, Australian Coal Review, pp. 42-46, October 1996.
- [41] DİKE Ö.S., Pulvarize Kömür Enjeksiyonu Kullanımının Yüksek Fırın Çalışmasına Etkileri, Yüksek Lisans Tezi, Çukurova Üniversitesi, Adana 2008.
- [42] http://www.enerji.gov.tr/yayinlar_raporlar/Mavi_Kitap_2013.pdf, Erişim Tarihi: 19.08.2014.
- [43] BAYRAK S., Bir Termik Santralde Entropi Üretiminin Enerji Verimliliğine Etkisinin İncelenmesi, Yüksek Lisans Tezi, Gazi Üniversitesi, Ankara, Haziran 2013.
- [44] ÖZDEMİR Y., Afşin-Elbistan Termik Santrallerinin Çevresel Etkileri: Mesafe Tabanlı Algı Analizi, Yüksek Lisans Tezi, Kahramanmaraş Sütçü İmam Üniversitesi, 2013.

- [45] KEMAL M., SEMERKANT O., Türkiye Linyit Kömürü Potansiyeli ve Kullanım Olanığı, Türkiye 4. Kömür Kongresi, pp. 17-31, Zonguldak, 1984.
- [46] ÇAM N.F., YAPRAK G., GÜR F., CANDAN O., BAYRAM A., ONAT B., TANIL H., MERT A., Batı Anadolu'daki Termik Santraller Çevresindeki Doğal Radyonüklid (226Ra, 232Th, 40K ve 210Pb) Emisyonundan Kaynaklanan Radyoaktif Kirliliğin İncelenmesi ve Radyolojik Risk Tahmini, Tübitak, Çaydağ 103Y057, İzmir, 2006.
- [47] FRANKLIN G., POWELL J.D., EMAMI-NAEINI A., Feedback control of dynamic systems, Prentice-Hall, 4th edition, 2002.
- [48] LJUNG L., System Identification: Theory For The User, New Jersey: Prentice Hall, 1996.
- [49] LAROSE D. T., Discovering knowledge in data: an introduction to data mining, John Wiley, pp. 1-25, New Jersey, 2004.
- [50] MEŞE M., Ege Bölgesi Akarsularının Akım Karakteristiklerinin Havza Fizyografik Parametreleri ile Belirlenmesi, Yüksek Lisans Tezi, Pamukkale Üniversitesi, pp. 85, Mayıs 2012.
- [51] YURTOĞLU H., Yapay Sinir Ağları Metodolojisi ile Öngörü Modellemesi: Bazı Makroekonomik Değişkenler için Türkiye Örneği, Uzmanlık Tezi, Devlet Planlama Teşkilatı, 113 sayfa, Şubat 2005.
- [52] GÜLBAĞ A., Yapay Sinir Ağı ve Bulanık Mantık Tabanlı Algoritmalar ile Uçucu Organik Bileşiklerin Miktersal Tayini, Doktora Tezi, Sakarya Üniversitesi, pp. 165, 2006.
- [53] COCHOCKI A., UNBEHAUEN R., Neural Networks for Optimization and Signal Processing, John Wiley & Sons, Inc. New York, NY, USA, 1st Issue, 1993.
- [54] AÇMALI F., Diyabet Hastalığının Yapay Sinir Ağları Kullanılarak Sınıflandırılması, Yüksek Lisans Tezi, Sakarya Üniversitesi, Sakarya, Ocak 2010.
- [55] ÖZTEMEL E., Yapay Sinir Ağları, Papatya Yayınları, Türkiye, pp. 232, 2003.
- [56] YILMAZ E.C., Bir Atıksu Arıtma Tesisinin Girişindeki Biyolojik Oksijen İhtiyacının Yapay Sinir Ağları Kullanılarak Modellenmesi, Yüksek Lisans Tezi, Sakarya Üniversitesi, pp. 49, Haziran 2009.

- [57] MONTGOMERY A.C., PECK E.A., VINING G.G., Introduction to Linear Regression Analysis, Wiley Series in Probability and Statistics, 4th edition Student Solutions Manual, 2007.
- [58] DEMİRCEYLAN S., Erzurum’da Doğalgaz Tüketim Miktarının Yapay Sinir Ağı Algoritması Kullanılarak Tahmin Edilmesi, Yüksek Lisans Tezi, Atatürk Üniversitesi, pp. 100, 2012.
- [59] MADALLA G.S., Introduction to Econometrics, Macmillan Publishing Company, Second Edition, New York, 1992.
- [60] GUJARATI D., Basic Econometrics, The McGraw-Hill Companies, Fourth Edition, 2004.
- [61] SUBAŞI D.B., Enflasyonun ARIMA Modelleri ile Tahminlenmesi: 1995-2004 Türkiye Uygulaması, Yüksek Lisans Tezi, Dumlupınar Üniversitesi, Kütahya, pp.113, 2005.
- [62] YAMAN K., SARUCAN A., ATAK M., AKTÜRK N., Dinamik Çizelgeleme için Görüntü İşleme ve ARIMA Modelleri Yardımıyla Veri Hazırlama, Gazi Üniv. Müh. Mim. Fak. Der., Cilt 16, No. 1, pp. 19-40, 2001.
- [63] POO J.M.R., Computer Aided Introduction to Econometrics, Springer Verlag GmbH & Co. KG , New York, 2003.
- [64] KUZHEY C., Veri Madenciliğinde Destek Vektör Makinaları ve Karar Ağaçları Yöntemlerini Kullanarak Bilgi Çalışanlarının Kurum Performansı Üzerine Etkisinin Ölçülmesi ve Bir Uygulama, Doktora Tezi, İstanbul Üniversitesi, pp. 341, 2012.
- [65] AKŞEHİRLİ Ö., Tıbbi Araştırmalarda Destek Vektör Makinelerinin Kullanımı, Yüksek Lisans Tezi, Düzce Üniversitesi, pp. 145, Düzce, 2012.
- [66] KAYTEZ F., En Küçük Kareler Destek Vektör Makineleri İle Türkiye’nin Uzun Dönem Elektrik Tüketim Tahmini ve Modellemesi, Doktora Tezi, Gazi Üniversitesi, pp. 145, Ekim 2012.
- [67] ABE S., Support Vector Machines for Pattern Classification, Springer, New York, 2005.
- [68] CHRISTIANINI N., SHAWE-TAYLOR J., An Introduction to Support Vector Machines and Other Kernel-Based Learning Methods, Cambridge University Press, 2000.
- [69] SARAOĞLU H.M., Beyin sinyallerinin geri yaymalı yapay sinir ağı ile eğitilmesi, haritalanması, Doktora Tezi, Sakarya Üniversitesi, Sakarya, 1998.

- [70] CHU J., SHIEH S., JANG S.S., CHIEN C., WAN H., KO H., Constrained optimization of combustion in a simulated coal-fired boiler using artificial neural network model and information analysis, *FUEL*, Vol. 82, No. 6, pp. 693-703, April 2003.

ÖZGEÇMİŞ

Yasin Tunçkaya, 10.10.1979 tarihinde Zonguldak'ın Devrek ilçesinde doğdu. 1990 yılında Devrek Fatih İlkokulu'ndan, 1993 yılında Bartın Ulus Ortaokulu'ndan ve 1997 yılında Zonguldak Mehmet Çelikel Lisesi'nden mezun oldu. Lisans öğrenimini Yıldız Teknik Üniversitesi Elektronik ve Haberleşme Mühendisliği bölümünde, 2001 yılında, tamamladı. Yüksek lisans öğrenimini ise Bülent Ecevit Üniversitesi'nde 2009 yılında tamamladı ve aynı yıl Sakarya Üniversitesi Elektrik-Elektronik Mühendisliği bölümünde doktora öğrenimine başladı. 2003 – 2009 yılları arasında Ereğli Demir ve Çelik Fabrikaları'nda elektronik otomasyon mühendisi, kısa dönem askerlik hizmeti sonrasında, 2010 – 2012 yıllarında Gama Güç Sistemlerinde I&C proje mühendisi olarak çalışmıştır. 2012 yılından beri Çalık Enerji'de yurtdışı enerji santrali projelerinde I&C mühendisi olarak çalışmaya devam etmektedir.