

T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**ÇELİKHANE (BOF) TESİSİNDE YAPAY SİNİR AĞI
(ANN) UYGULAMALARI İLE KARBON (C) VE
FOSFOR (P) TAHMİNİ**

YÜKSEK LİSANS TEZİ

Selahattin OKUR

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

Enstitü Bilim Dalı : **ELEKTRONİK**

Tez Danışmanı : **Prof. Dr. Ayhan ÖZDEMİR**

Mayıs 2019

T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**ÇELİKHANE (BOF) TESİSİNDE YAPAY SİNİR AĞI
(ANN) UYGULAMALARI İLE KARBON (C) VE
FOSFOR (P) TAHMİNİ**

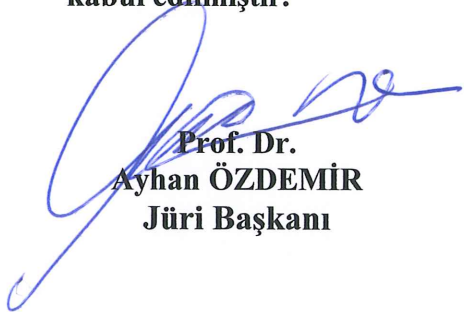
YÜKSEK LİSANS TEZİ

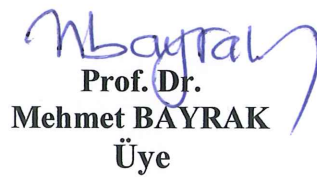
Selahattin OKUR

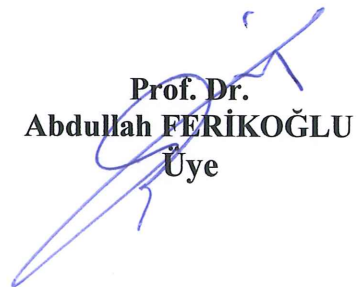
Enstitü Anabilim Dalı : **ELEKTRİK-ELEKTRONİK
MÜHENDİSLİĞİ**

Enstitü Bilim Dalı : **ELEKTRONİK**

Bu tez 27.05.2019 tarihinde aşağıdaki jüri tarafından oybirliği / oyçokluğu ile kabul edilmiştir.


Prof. Dr.
Ayhan ÖZDEMİR
Jüri Başkanı


Prof. Dr.
Mehmet BAYRAK
Üye


Prof. Dr.
Abdullah FERİKOĞLU
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.

Selahattin OKUR

27.05.2019

TEŐEKKÜR

Yüksek lisans eğitimin boyunca değerli bilgi ve deneyimlerinden yararlandığım, her konuda bilgi ve desteğini almaktan çekinmediğim, araştırmanın planlanmasından yazılmasına kadar tüm aşamalarında yardımlarını esirgemeyen, teşvik eden, aynı titizlikte beni yönlendiren değerli danışman hocam Prof. Dr. Ayhan ÖZDEMİR'e teşekkürlerimi sunarım. Tez çalışmalarımnda her zaman destek olan Elektronik Otomasyon Müdürümüz Dr. Hasan MAKAS'a, çelik üretiminin metalürjik konularında destek olan Çağrı Doğan BİLGİÇ'e ve çalışma arkadaşım Erdoğan BOZKURT'a teşekkürlerimi sunarım.

Ayrıca maddi manevi her zaman destekleyen bütün aileme, eşim Yaşam OKUR'a, sevgili babam Nizamettin OKUR'a, sevgili annem Fitnat OKUR'a ve oğlum Işık Alp OKUR'a teşekkür ederim.

İÇİNDEKİLER

TEŞEKKÜR	i
İÇİNDEKİLER	ii
SİMGELER VE KISALTMALAR LİSTESİ	v
ŞEKİLLER LİSTESİ	vii
TABLOLAR LİSTESİ	ix
ÖZET	x
SUMMARY	xi
BÖLÜM 1.	
GİRİŞ	1
BÖLÜM 2.	
KAYNAK ARAŞTIRMASI	3
2.1. BOF Çelik Üretim Süreci	6
2.1.1 Kütle ve enerji dengesi	5
2.1.2. BOF süreç reaksiyonları	7
2.1.2.1. Saflaştırma (refine) reaksiyonları	7
2.1.2.2. Karbon oksidasyonu	9
2.1.2.3. Silisyum oksidasyonu	11
2.1.2.4. Manganez oksidasyonu	11
2.1.2.5. Fosfor oksidasyonu	12
2.1.2.6. Kükürt tepkimesi	12
2.1.3. BOF çelik üretiminde cüruf oluşumu	13
2.1.4. Alttan karıştırma	14

2.2. Yapay Zekâ	15
2.2.1. Yapay sinir ağları	17
2.2.1.1. Yapay sinir ağlarının temelleri ve özellikleri	18
2.2.1.2. Yapay sinir ağlarının avantajları	20
2.2.1.3. Yapay sinir ağlarının problem çözme yetenekleri	21
2.2.1.4. YSA'ların sınıflandırılması	22
2.2.1.5. Geri yayılım ağı	23
2.2.1.6. Çok katmanlı sinir ağları	24
2.2.1.7. Makine öğrenme modelleri için çapraz doğrulama yöntemleri.....	27
2.2.1.8. Normalizasyon	29
2.3. Problem Tanımı ve Literatür	30
2.3.1. Erdemir'de BOF ile çelik üretimi	30
2.3.2. Problem tanımı	35
2.3.3. Literatürde yapılan çalışmalar	36
BÖLÜM 3.	
MATERYAL VE YÖNTEM	41
3.1. Kullanılan Veriler ve Filtreleme	41
3.1.1. Yöntem	44
3.1.2. Verilerin normalizasyonu	46
3.1.3. 10-k cross validation	46
3.1.4. YSA'nın ağ yapısı ve eğitim parametreleri	47
3.1.4.1. TSC karbon modeli verileri ve model özellikleri	52
3.1.4.2. TSC fosfor modeli verileri ve model özellikleri	53
3.1.4.3. TSO karbon modeli verileri ve model özellikleri	54
3.1.4.4. TSO fosfor modeli verileri ve model özellikleri	55
BÖLÜM 4.	
ARAŞTIRMA BULGULARI	56
4.1. TSC karbon modeli sonuçları	56
4.2. TSC fosfor modeli sonuçları	58

4.3. TSO karbon modeli sonuçları	60
4.4. TSO fosfor modeli sonuçları	61
BÖLÜM 5.	
TARTIŞMA VE SONUÇ	64
KAYNAKLAR	67
ÖZGEÇMİŞ	72

SİMGELER VE KISALTMALAR LİSTESİ

$ \Delta C $: Gerçek ve simülasyon , % ağırlık olarak, karbon değeri farkı
$ \Delta P $: Gerçek ve simülasyon, % ağırlık olarak, fosfor değeri farkı
\leq	: Küçük eşit
BOF	: Bazik Oksijen Fırını
BP	: Back propagation - geri yayılım
BPMLNN	: Back propagation multilayer neural network
C	: Karbon
CaO	: Kalsiyum oksit
CO	: Karbon monoksit
CV	: Cross validation
CO ₂	: Karbon dioksit
DCS	: Distributed Control System- dağıtık kontrol sistemi
dk.	: Dakika
EWM	: Entrophy Weight Method
Fe	: Demir
Fe ₂ O ₃	: Demir III Oksit
FeO	: Demir Oksit
GMDH	: Group Method of Data Handling
K	: Denge sabiti
LM	: Levenberg - Marquardt
log	: Logaritma
Logsig	: Logaritmik sigmoid
MgO	: Magnezyum oksit
Min-Max	: Minimum- Maximum
MLNN	: Multilayer neural network

MLR	: Multiple Lineer Regresyon
Mn	: Manganez
n	: Çok katmanlı ağlarda ara katman çıkışı
nntool	: Neural network toolbox
O	: Oksijen
P	: Fosfor
p	: Nöron girişi
p	: Nöron giriş matrisi
s	: Sinirsel ağlarda bir katmandaki nöron duyarlılığı
s	: Sinirsel ağlarda bir katmandaki nöron duyarlılıklarının matrisi
S	: Kükürt
Si	: Silisyum
PCA	: Principal Component Analysis
PLC	: Programamable Logic Control
SCADA	: Supervisory Control and Data Acquisition
SCG	: Scaled Conjugate Gradient
Si	: Silisyum
SiO ₂	: Silisyum oksit
Tanh	: Bir sayının hiperbolik tanjantı
TANSIG	: Sigmoid tanjant
Trainscg	: Matlab'de scaled conjugate gradient eğitim fonksiyonu
TSC	: Temperature Sample Carbon
TSO	: Temperatuer Sample Oxygen
wt.%	: Ağırlığın yüzdesi
w	: Sinirsel ağlarda bağlantının ağırlığı
W	: Sinirsel ağlarda bağlantıların ağırlık matrisi
YSA	: Yapay sinir ağı

ŞEKİLLER LİSTESİ

Şekil 2.1. BOF temel işlem adımları	4
Şekil 2.2. BOF'un girdi ve çıktıları	6
Şekil 2.3. Üflemenin ortasında BOF konvertörün fiziksel durum gösterimi ...	8
Şekil 2.4. BOF çelik üretiminde metal kompozisyon değişimi	9
Şekil 2.5. BOF çelik üretim sürecinde karbon giderimin zamana bağlı oranı gösterimi	10
Şekil 2.6. BOF çelik üretiminde cüruf kompozisyonundaki değişim	14
Şekil 2.7. Sinir Ağlarının alt grupları	16
Şekil 2.8. Bir sinir hücresi gösterimi	18
Şekil 2.9. Bir sinapsın görünümü	19
Şekil 2.10. Tek girişli genel nöron gösterimi	20
Şekil 2.11. YSA'nın çözüm ürettiği sorun grupları gösterimi	22
Şekil 2.12. Çok katmanlı ileri beslemeli ağ örneği	25
Şekil 2.13. Transfer fonksiyonların grafik gösterimi. Sırasıyla Log-Sigmoid, Tan-Sigmoid, Purelin	27
Şekil 2.14. 10-fold cross validation grafiksel gösterimi	28
Şekil 2.15. Konvertör tasarımı ve alttan karıştırma nozullarının yerleri	32
Şekil 3.1. Yapay sinir ağının iş akış gösterimi	45
Şekil 3.2. Veri setinin 10 folda bölünmesini sağlaması için yazılan Matlab kodu	47
Şekil 3.3. Bu çalışma için yapılmış YSA yazılımının ana kodu	49
Şekil 3.4. 10 farklı kümeye bölünmüş normalize verilerin sıra ile eğitim ve test seti haline getirildiği kod parçası	50
Şekil 3.5. Öğrenme algoritmasının ayarlandığı yazılım örneği	51
Şekil 3.6. TSC (üfleme içi) karbon değeri YSA modeli	52
Şekil 3.7. TSC (üfleme içi) Fosfor değeri YSA modeli	53

Şekil 3.8. TSO (üfleme sonu) karbon değeri YSA modeli	54
Şekil 3.9. TSO (üfleme sonu) Fosfor değeri YSA modeli	55
Şekil 4.1. TSC karbon simülasyon gerçek değer farkı hata aralığı histogram gösterimi	57
Şekil 4.2. TSC anı Karbon gerçek ve simulasyon verilerinin scatter plot gösterimi	58
Şekil 4.3. TSC fosfor simülasyon gerçek değer farkı hata aralığı histogram gösterimi	59
Şekil 4.4. TSC anı fosfor gerçek ve simülasyon verilerinin scatter plot gösterimi	59
Şekil 4.5. TSO karbon simülasyon gerçek değer farkı hata aralığı histogram gösterimi	60
Şekil 4.6. TSO anı karbon gerçek ve simülasyon verilerinin scatter plot gösterimi	61
Şekil 4.7. TSO fosfor simülasyon gerçek değer farkı hata aralığı histogram gösterimi	62
Şekil 4.8. TSO anı karbon gerçek ve simülasyon verilerinin scatter plot gösterimi	63
Şekil 5.1. Seviye 2 model performans başarı kabul şartları	66

TABLolar LİSTESİ

Tablo 2.1. Kalite, bazisite, üfleme zamanı ve üflenen oksijen hedefleri	33
Tablo 2.2. Hedef çeliğe bağlı girdiler ve kullanılan flux malzemeleri	33
Tablo 2.3. Analiz ve sıcaklık girdi ve hedef değerleri tablosu	33
Tablo 2.4. BOF konvertörde işlemler ve toplam zaman gösterim tablosu	34
Tablo 3.1. Trainscg Matlab algoritması parametreleri	48
Tablo 3.2. Trainscg için verilen parametre değerleri	52
Tablo 3.3. Trainscg için verilen parametre değerleri	53
Tablo 3.4. Trainscg için verilen parametre değerleri	54
Tablo 3.5. Trainscg için verilen parametre değerleri	55
Tablo 4.1. TSC anı karbon simülasyon sonuçlarının yakalama oran ve aralıkları.	57
Tablo 4.2. TSC anı fosfor simülasyon sonuçlarının yakalama oran ve aralıkları	58
Tablo 4.3. TSO anı karbon simülasyon sonuçlarının yakalama oran ve aralıkları	60
Tablo 4.4. TSO anı fosfor simülasyon sonuçlarının yakalama oran ve aralıkları	62

ÖZET

Anahtar kelimeler: bazik oksijen fırını, bof, üfleme sonu karbon tahmini, üfleme sonu fosfor tahmini, neural network, BPMLNN, yapay sinir ağları

Günümüz teknolojinde ürün kalitesinin sürekliliği ve verimli çalışma için süreçlerin nihai durumunu tahmin eden modeller geliştirilmekte ve kullanılmaktadır. Üzerinde çalışılan sistemin detayı ve tüm çalışma prensipleri bilindiğinde modeller daha güçlü yanlısız ve kesin olmaktadır. Çelik Üretim gibi sürecin bilinmesine rağmen modellenmenin zorlayıcı olduğu süreçlerde bulunmaktadır. Yüksek Fırın ve Basic Oxygen Furnace (BOF) gibi tesislerdeki sıvı, metal ve gaz tepkimelerinin yer aldığı ve nihai ürünün durumunu etkileyen birçok girdinin olduğu zorlu süreçlerde modelleme yapmak güçleşmektedir.

Bu çalışmamızda BOF konvertöründe üfleme sonu TSO ve üfleme içi TSC probu ile ölçüm yapma anlarındaki fosfor ve karbon değerlerinin tahmini için Matlab programı ile öğrenme algoritması Scaled Conjugate Gradient olan geri yayımlı çok katmanlı sinir ağı önerilmiştir. Giriş verisinin rastgeleliğinin ve doğruluğunun sağlanması için tek bir konvertörden tesis bazlı metalürjik etkileşimler, konvertörün alttan karıştırma durumu göz önüne alınarak veri seçimi ve homojen bir öğrenme ortamı için 10 Fold cross Validation tekniği kullanımı sağlanmıştır. Yapay sinir ağı modeli sonuçlarımızda TSC anı tahminlerinde $\pm 0,02$ hata aralığında %83 tutarlılıkla fosfor, $\pm 0,15$ hata aralığında %93 tutarlılıkla karbon değeri gözlemlenmiştir. TSO anı tahminlerinde ise $\pm 0,025$ hata aralığında %89.4 tutarlılıkla fosfor, $\pm 0,01$ hata aralığında %92 tutarlılıkla karbon değeri gözlemlenmiştir.

CARBON (C) AND PHOSPHORUS (P) PREDICTION IN STEEL SHOP (BOF) WITH ARTIFICIAL NEURAL NETWORKS

SUMMARY

Keywords: basic oxygen furnace inblow carbon and phosphorus content, end point phosphorus content, end point carbon content, neural network, BPMLNN

In today's technology, models are commonly developed and applied to predict and control the end point of any processes, due to obtaining sustainable product quality. The power of model and its usage will be more precise and accurate in case when the system is explained in detail and defined completely. Nevertheless, during the steelmaking process there are several plants that modelling becomes challenging. Blast Furnace (BF) and Converter process are the most difficult processes that can be modelled due to liquid, metal and gas reactions and a large number of input variables that can influence reaching the end point.

In this study, Feed Forward Back Propagation Multi-Layer Neural Network in Matlab with training function `Trainscg` is proposed for prediction of the phosphorus and carbon at blowing end (TSO phase) and inblow (TSC phase, %80 of blowing time) in BOF Converter. In order to ensuring and validating the randomness of input data, a single BOF plants data is collected. The data set is filtered with a strict limitation method according to the plant specific metallurgical interactions, bottom stirring effect and 10 Fold Cross Validation used for clustering in order to have homogenous learning process. The simulated results hit rate %92 within the error range $\pm 0,01$ for end-point carbon and %89.4 within the error range $\pm 0,025$ for end-point phosphorus are observed. For inblow the simulated results hit rate %83 within the error range $\pm 0,02$ for phosphorus and %93 within the error range $\pm 0,15$ are observed. The results showed that the output could be used in software to calculate P and C during the end of blowing and inblow without interrupting the blowing process like TSO or TSC measurement.

BÖLÜM 1. GİRİŞ

Yüksek verim ve tasarruf çelik endüstrisinde de diğer birçok endüstri dalında olduğu gibi çok önemli iki kıstastır. Müşterinin talep ettiği kalitede ürünü üretirken minimum zaman kaybı ve maksimum verim firmanın karlılığını ve müşteri memnuniyetini arttıracak önemli etkenlerdir. Bazik Oksijen Fırını (BOF) yüksek üretim verimi ve diğer metotlara göre düşük maliyeti ile üreticiler tarafından uzun yıllardır çok tercih edilen etkili bir çelik üretim yöntemidir. Dünyadaki çelik üretiminin %75'inin üretiminde BOF kullanılmaktadır [1].

Endüstriyel üretim hatlarında ve son kullanıcı ihtiyaçları kullanımı için çok çeşitli çelik kaliteleri kimyasal kompozisyonlarına göre gruplandırılmıştır ve bu grupların hedef değerlerine göre üretimleri yapılmaktadır. BOF yöntemi ile üretilen çeliğin kalitesini etkileyen: sıcak maden miktarı, sıcak maden element kompozisyonu, hurda miktarı, hurda element kompozisyonu, üflenen oksijen miktarı, şarj edilen malzemelerin tenör özellikleri gibi birçok etken bulunmaktadır. Bu kadar çok çeşitli girdi ve bilinmeyen olduğu bir ortamda nihai ürünün hedeflenen kalite şartlarını sağlayıp sağlamadığını takip etmek maliyet ve kalite açısından önem kazanmaktadır.

Geçmiş yıllarda teknik imkânsızlıklar yüzünden saklanmakta zorluk çekilen verilerin gelişen teknoloji ile uzun süreli ve istenilen miktarda saklanmaya başlanmıştır. Günümüzde bu saklanan verilerin arasındaki matematiksel olarak ifade edilebilen veya edilemeyen ilişkileri bulmak ve birçok disiplinde kullanmak için makine öğrenme yöntemlerinden biri olan yapay sinir ağları (YSA) oldukça revaç görmektedir. Finans piyasalarında ileri yönelik tahminlerden [2], robotik kontrollerin uygulamasına [3] birçok farklı alanda çalışmalarda kullanım örnekleri mevcuttur [4].

Yapay sinir ağıları çoğunlukla, bir prosesteki girdi ve çıktı parametreleri arasındaki karmaşık ve lineer olmayan bağlantıları yakalamaktaki yetenekleri nedeni ile kullanılmışlardır.

BOF çelik üretimi yönteminde oksijen üfleme ve atılan flux malzemeleri ile sıcak madenin içindeki karbon (C), fosfor (P), silisyum (Si), manganez (Mn) ve demir (Fe) gibi ürünün müşterinin siparişine uygunluğunu gösteren ve evrensel kalite göstergeleri olan elementlerin en verimli şekilde istenilen aralığa indirgenmesine çalışılır. Silisyum ve Manganez konvertörde ve konvertör sonrası süreçte alaşım ve doğal kimyasal tepkimelerle takibi ve düzenlemesi kolay elementler iken, karbon ve özellikle fosfor konvertördeki yüksek oksijene bağlı, konvertörün sürecinden en çok etkilenen ve ikincil metalürji istasyonlarında düzeltilmesi mümkün olmayan çeliğin kullanımını ve kalitesini çok etkileyen iki kritik elementtir. Karbonun ve fosforun konvertörde istenen limitlerde olmasının sağlanması çelik üretim sürecinde hem üretimi verimini ve kalitesini arttıracak hem de maliyetini düşürecektir.

BOF metodunda ana üfleminin %80'i civarı TSC Temperature (Sıcaklık)- Sample (Numune) – Carbon (Karbon) ve ana üfleminin sonunda TSO Temperature (Sıcaklık) - Sample (Numune)- Oxygen (Oksijen) adı verilen ve çelikleştirme işlemine ara verilip probe daldırma ile numune alınması sağlanmaktadır. Üretilen çeliğin kalitesini anlamak için metalürjistlerin yakından takip ettikleri iki element olan Karbon ve Fosfor ile diğer kimyasal kompozisyon değerlerinin resmi değerleri bu numunelerin laboratuvarında analizleri ile belirlenmektedir. Numune sonuçları yaklaşık 20 dk. süren tüm üfleme sürecine göre oldukça fazla olan 5-10dk arası alınmakta ve bu işlem çelikleştirme sürecini uzatmaktadır.

Bu çalışma TSC ve TSO anlarında, manuel ölçüm ya da standart matematiksel hesap metotları yerine, çeliğin kalitesi açısından kritik ve tahmini zor olan Karbon ve Fosfor elementlerinin kimyasal kompozisyon oranlarının tesisten alınan verilere dayalı oluşturulan Yapay Sinir Ağları ile modellenmesine çalışılmıştır. Böylece hızlı, üretimin fazlarını bölmeyen ve düşük maliyetli olarak Karbon ve Fosfor tahmini ile operatöre ve üretime yol gösterecek, işletme açısından tatmin edici sonuçlar alınmıştır.


BÖLÜM 2. KAYNAK ARAŞTIRMASI

2.1. BOF Çelik Üretim Süreci

Bazık oksijen çelik üretim süreci karbonca zengin erimiş pik demir ve çeşitli hurdaların karışımının özel refrakter tuğlaları ile kaplı bir konvektör denilen yapı içerisinde, üzerlerine yüksek saflıkta oksijen üflenmesini içermektedir. Empürite denilen ve çeliğin içinde miktarları sınırlı tutulmaya çalışılan karbon, fosfor, manganez ve silisyum istenilen seviyelere getirilir. Çelik, konvertör kapasitesine bağlı olarak döküm adı verilen ayrı gruplar halinde üretilir. BOF ya da konvertör denilen fırın varil şeklinde, üstü açık, refraktör tuğlası örülü bir tür kazandır. Şekil 2.1.'de temel işlem adımları gösterilmiştir [5].

Bu sürecinin amacı pik demir içindeki karbon oranını soğutucu olarak hurda yardımı ile %4'ten %0,1'in altına, kükürt ve fosfor oranını minimum seviyeye indirmek ve üretilen çeliğin sıcaklığını 1680 °C civarına getirmektir [5]. Alüminyum, bakır, çinko, magnezyum gibi sıvı metallerin içerisindeki oksitli bileşiklerin, safsızlıkların ve istenmeyen elementlerin sıvı metal banyosundan uzaklaştırılması ve döküme uygun temiz metal haline getirilmesi ile ayrıca atmosferle temasının kesilmesi için flux şarj malzemeleri kullanılır. Kullanılan flux malzemeler aynı zamanda konvertörün refrakter aşınımını da azaltır. Kullanılacak sıcak maden, hurda, oksijen ve fluxların miktarının belirlenmesinde, girdi olan malzemelerin kimyasal kompozisyonu ve sıcaklığı, hedef çeliğin kimyasal kompozisyonu, ağırlığı ve sıcaklığı etkilidir. Sıcak maden, hurda ve fluxların sıcaklığını yükseltmek için gereken enerjiyi konvertörün içine şarj edilen çeşitli malzemelerin oksidasyonu sağlamaktadır. Karbon (C), Fosfor (P), Demir (Fe), silisyum (Si) ve manganez (Mn) üretilen çeliğin niteliğini belirleyen temel elementlerdir. Sıcak maden, hurda, fluxlar ve soğutucu ve ısıtıcı gibi ek malzemeler ise istenmeyen empüritelerin kaynağıdır. Sıcak maden silisyum, karbon,

manganez ve fosforun, hurdadan gelen az bir miktar ile neredeyse bütünüdür kaynağıdır.



Şekil 2.1. BOF temel işlem adımları [5].


Üfleme işlemi sırasında yüksek saflıktaki oksijen konvertörün tepe noktasından bir lans yardımı ile sıcak maden hurda karışımına çok güçlü şekilde püskürtülür. Güçlü oksijen püskürmesinin yoğun karıştırma ve sıvı pik demirin yüksek sıcaklığının etkisi ile büyük miktarlarda enerji ortaya çıkararak elementler hızlı oksitlenirler. Fluxların

silisyum, manganez, demir ve fosfor oksitleri ile karışımı sonucu sıvı cüruf oluşur. Oksijen püskürtülmesinden dolayı oluşan güçlü karıştırma etkisi çelik banyosu ve cüruf arasında hızlı bir reaksiyon ve enerji transferi olmasını sağlar. Karbonun oksidasyonu ile ortaya çıkan karbon dioksit süreci gaz formunda terk eder. Cüruf ve çeliğin karşılıklı etkileşimi köpüksü bir emülsiyon oluşturur. Yüksek sıcaklık, güçlü karışım ve çelik tanecikleri ile cürufun arasındaki geniş yüzey hızlı etkileşimlere ve elementlerin metalden gaz fazına hızlı kütle transferi yapmalarını sağlar [6]. Üfleme bittiğinde cüruf çelik banyosunun üzerinde yüzer haldedir ve döküm deliğinden dökülen çelikten cüruf ayrıştırılarak alınır. Süreç içerisinde sıvı madenin kimyasal kompozisyonunu anlamak adına üfleme arasında, üfleme sonunda manuel olarak elle ya da sublans denilen otomatik ölçüm aletleri ile numune alımları yapılabilir. Bazı üretim yerlerinde üfleme içinde de numune alınıp karbon gideriminin hızlandığı son faza da daha kontrollü davranılması durumu da olağandır.

2.1.1. Kütle ve enerji dengesi

Bazı oksijen çelik üretim sürecindeki giren ve çıkan malzemeler Şekil 2.2.'de gösterilmiştir [5]. BOF'un girdileri sıcak maden, hurda, fluxlar ve oksijendir. Fluxlar cüruf yapıcı, soğutucu ve ısıtıcı olacak şekilde gruplanabilir. Yanmış kireç, dolomitik kireç ve kireçtaşı ağırlıklı olarak cüruf yapıcı olarak kullanılır. Ferrosilikon ve antrasit kok ısıtıcı olarak kullanılırsa demir cevheri ve pelet soğutucu olarak kullanılmaktadır.

Sıcak maden, hurda ve demir cevheri yanmış kireç, dolomitik kireç gibi fluxlarla beraber fırının içine atılır. Bu karışımın üzerine oksijen lansından yüksek akış oranıyla oksijen enjekte edilir. CO, CO₂ gazları ve demir oksit dumanları (Fe₂O₃) konvertör ağzından yükselerek çıkar. İşlem sürecinin sonunda sıvı çelik ve cüruf geriye kalan ürünlerdir.



Şekil 2.2. BOF'un girdi ve çıktıları [5].

Oksijen üfleme esnasında ortaya çıkan enerji, sıcak madenin ısısını 1350 °C den istenilen hedef sıcaklığa (~1680 °C) çıkartmak için gereken enerjiden çok daha fazlasıdır. Ortaya çıkan fazla enerji fluxları ve hurdayı eritir ve demir cevherini metale indirir. Isının bir kısmı da iletim, yayınım ve ışıınım ile çevreye kaybedilir [5].

Yanmış ve dolomitik kireç gibi bazı fuxlar demir cevheri ile beraber üflemenin başlarında konvertörün içine şarj edilir. Bazı diğer fux şarj malzemeleri de soğutucu ve ısıtıcılarla beraber üflemenin sonraki adımlarında kullanılır. Bu durumlar üretilecek kalitenin tesis pratiklerine bağlı olarak ta değişebilmektedir.

İstenilen sıcaklık ve kompozisyonda üretim yapmak için kullanılan sıcak maden, hurda, demir cevheri ve oksijen gibi her girdinin miktarının, sıcaklığının ve kompozisyonunun takip edilebilir ve ayarlanabilir olması gerekmektedir. Miktarların ayarlanması her BOF tesisine göre değişmekle beraber bu hesaplamalar genel olarak kütle ve enerji denge hesaplarına dayanmaktadır.

2.1.2. BOF süreç reaksiyonları

2.1.2.1. Saflaştırma (Refine) reaksiyonları


Sıcak maden ve hurda konvertörün içine şarj edilir ve bu metal banyosu (metal bath) denilen karışımla reaksiyona girmesi için yüksek saflıktaki oksijen su soğutmalı bir lans içerisinden yüksek akış hızında üflenir. Metal banyosu içinde çözülmüş halde olan Karbon (C), silisyum (Si), manganez (Mn) ve fosfor (P) gibi istenmeyen içerikler (empüriteler) sıvı çelik üretim aşamasında oksidasyonlar ile uzaklaştırılır.

Oksijen üfleme işlemi tesisten tesise ve konvertör boyutlarına bağlı değişmek üzere 16 ile 25 dakika arası sürebilir ve oksidasyon sonucu CO, CO₂, SiO₂, P₂O₅, MnO ve demir oksitler ortaya çıkar. Flux malzemeleri ve genel olarak kireç (CaO) konvertöre eklenir ve oksitlerin çoğunluğu metalin içindeki kükürt (S) ve fosforun (P) sıvı madenden ayrılmasını sağlayan sıvı cüruf oluşturmak üzere çözünür. Gaz formundaki oksitler, yaklaşık %90 CO ve %10 CO₂, beraberlerinde az miktarda demir oksit ve kireç tozu taşıyarak konvertörün ağzından çıkar.

İşlemin geneli otojendir yani dışarıdan fazladan ısı kaynağına ihtiyaç duyulmaz. Fluxları ve hurdayı eritecek ve işlem sonunda hedeflenen sıcaklığı tutturmayı sağlayacak gerekli enerji oksidasyon reaksiyonlarından elde edilir.


Yüksek üretim oranlarında çeliği saflştırma BOF süreçlerinde yapılabilir. Çok geniş alana yayılabilen elverişli ve verimli reaksiyon alanı sayesinde çok yüksek hızda reaksiyonlar olabilmektedir.

Yüksek miktarda gaz, oksijen lansından gelen yüksek saflıktaki oksijen ile içinde karbon bulunan metal banyosu reaksiyona girmesi sonucu, dönüşür. Konvertör gazlarının dönüşümü ve lanstan gelen oksijen ile küçük metal damlacıkları ve sıvı cüruf köpüksü bir emülsiyon oluşturur. Şekil 2.3.'te görüleceği üzere, bu gaz-metal-cüruf (slag) emülsiyonu saflştırma reaksiyonlarının etkinliğini ve oranını arttıran geniş yüzey alanını sağlamaktadır.



Şekil 2.3. Üflemenin ortasında BOF konvertörün fiziksel durum gösterimi [5].

Karbon, silisyum, fosfor ve manganez gibi empüritelerin oksidasyonu, yeterli miktardaki üflenen oksijenin çelik banyosunu tutuşturmasıyla başlar. İhtiyaç duyulan oksijen miktarı dökümden döküme değişebilir. Oksijen üfleme sırasında BOF metal banyosundaki elementlerin yoğunluklarının değişimini alttaki Şekil 2.4.'te gösterilmektedir.



Şekil 2.4. BOF çelik üretiminde metal kompozisyon değişimi [6].

2.1.2.2. Karbon oksidasyonu

Karbon giderimi, diğer bir adıyla dekarburizasyon, oksijen üflenerek yapılan çelik üretimindeki en önemli reaksiyondur. Sıcak madendeki karbon oksijen ile tepkimeye girerek CO ve CO₂ oluşturur. Karbonun tepkimesi aşağıdaki denkleme göre oluşur (Denklem 2.1).



Cüruf maden tepkimeleri için, oksidasyon (Denklem 2.2) ve denge sabiti fonksiyonları (Denklem 2.3), sıra ile aşağıda verilmiştir.




$$K_{FC} = \frac{p_{CO}(\text{atm})}{[\%C] \cdot \alpha_{FeO}} \quad (2.3)$$

Karbon oksidasyonu büyük miktarda gaz haldeki CO ve CO₂'yi dönüştürdüğü ve bu dönüşümün de cüruf ve maden banyosunu tahrik ederek hidrojen, nitrojen ve metal

olmayan kalıntıların uzaklaştırılmasını sağladığı için en önemli saflaştırıcı reaksiyondur.

Cüruf, maden ve gaz emülsiyonu üflenen oksijenin basınçlı karıştırma etkisi sayesinde konvertörün içerisinde oldukça geniş bir tepkime yüzeyine sahip olur. Bu çok geniş tepkime alanı sayesinde karbonun oksidasyonu yüksek oranlara ulaşır kendi kendine hızlanır.

Oksijen üfleme esnasında karbon içeriğinde 3 farklı fazda ortaya çıkan değişim aşağıda gösterilmiştir (Şekil 2.5.) [6]. Üfleminin erken aşamalarında üflenen oksijenin büyük kısmı silisyum ile tepkimeye girer ancak bu aşamada dekarburizasyon yavaştır. Bir sonraki aşamada dekarburizasyonun yüksek oranı üflenen yüksek orandaki oksijen ile sağlanır. Dekarburizasyonun en yüksek oranı 0,20 ile 0,28 wt.%C arasındadır. Son faz karbon içeriğinin 0,14 wt.% değerinin altına düşmesinden sonra oluşur, burada dekarburizasyon kademeli olarak düşer. Fosfor, manganez, demirin oksidasyonu ile üflenen oksijenin tüketimindeki artış ve çelik banyosunda çözünen oksijen miktarındaki artış ile bu aşamada karbon oksidasyonu azalma eğitimi gösterir [6].



Şekil 2.5. BOF çelik üretim sürecinde karbon giderimin zamana bağlı oranı gösterimi [6].

2.1.2.3. Silisyum oksidasyonu

Silisyumun oksijen ile yüksek birleşme eğilimine bağlı olarak neredeyse bütün silisyumun oksidasyonu üflemenin ilk aşamasında cereyan eder. Silisyum oksidasyon denklemi (Denklem 2.4) ve K denge sabiti denklemi (Denklem 2.5) aşağıda verilmiştir.



$$K_{Si} = \frac{\alpha_{\text{SiO}_2}}{[\% \text{Si}] \times [\% \text{O}]^2} \quad (2.5)$$

K_{Si} 'nin sıcaklığa bağımlılığı aşağıdaki denklemde gösterilmiştir (Denklem 2.6)

$$\log K_{Si} = \frac{30,410}{T} - 11.59 \quad (2.6)$$

Silisyum oksijenle silikayı (SiO_2) oluşturmak üzere tepkimeye girer. Bu tepkime yüksek oranda exotermiktir ve çelik banyosunun sıcaklığını önemli ölçüde arttıracak ısının kaynağı olmaktadır. Bu tepkime, kireç ve dolomitik kireç gibi flux materyalleri ile tepkimeye girerek temel çelik üretim cürufunu meydana getirir. Silisyum miktarı ana ısı kaynağı olduğu için ne kadar hurda kullanıldığının belirlenmesinde oldukça etkindir. Sıcak maden içindeki silisyum içeriği ne kadar flux malzemesinin kullanılacağını dolayısıyla çelik üretim sürecinde ne kadar cüruf üretileceğini de etkilediği için ayrıca önem kazanmaktadır.

2.1.2.4. Manganez oksidasyonu

Üflemenin erken aşamasında Mn oksijenle yanar yani oksitlenir ve MnO 'yu oluşturur. Silisyum oksidasyonundan sonra manganez aşağıdaki denkleme (Denklem 2.7) göre metalin içine geri döner. İkinci denklem ile verilen (Denklem 2.8) denge katsayısı sıcaklığa ve cüruf kompozisyonuna bağlıdır.



$$K_{FeMn} = \frac{(\%MnO)}{(\%FeO) \times [\%Mn]} \quad (2.8)$$


Üfleme sonunda Şekil 2.4.'te gösterildiği üzere çelik banyosundaki manganez içeriği karbon giderimi daha az yoğun hale geldiği için giderek azalır.

2.1.2.5. Fosfor oksidasyonu

BOF içindeki oksitleyici ortam fosforun oksitlenmesini destekler. Şekil 2.4.'te çelik banyosu içerisinde fosfor içeriğinin nasıl değiştiği gösterilmiştir. Üfleminin başında fosfor içeriği aşağıdaki denkleme (Denklem 2.9) göre azalır.



Ana dekarburizasyon döneminde FeO indirgendiğinde fosfor metalin içine geri döner ve üfleme sonuna gelindiğinde içerik olarak düşer. Sıvı demir ile cüruf arasındaki fosfor giderimi, defosforizasyon, aşağıdaki denkleme (Denklem 2.10) göre çalışır.



Cüruf ve ergimiş metal arasındaki fosfor tepkimesi işletim sürecinin durumuna bağlıdır. Yüksek bazisite (CaO/SiO₂ oranı), cüruftaki yüksek FeO içeriği, yüksek cüruf akışkanlığı, cürufun düşük sıcaklığı ve iyi karıştırma ortamı fosforun giderimini arttıracaktır [5].

2.1.2.6. Kükürt tepkimesi

BOF sürecinde kükürt giderimi çok verimli değildir. Kükürt giderimi, desülfirizasyon, BOF'ta sıcak maden şarjından önce yapılır.

Üfleminin başında maden, karbon ve silisyum açısından zengin kükürt aktivitesi oldukça yüksektir. Konvertörün içinde lanstan üflenen oksijenin oluşturduğu türbülans ve oksitlenme ortamına ve düşük banyo sıcaklığına bağlı olarak çözülmüş kükürtün

bir kısmı direkt olarak gaz fazına aşağıdaki denklemde gösterildiği şekilde (Denklem 2.11) oksitlenerek geçer.



Kükürtün geri kalanı metal ve cüruf arasındaki aşağıdaki denkleme (Denklem 2.12) göre giderilir.



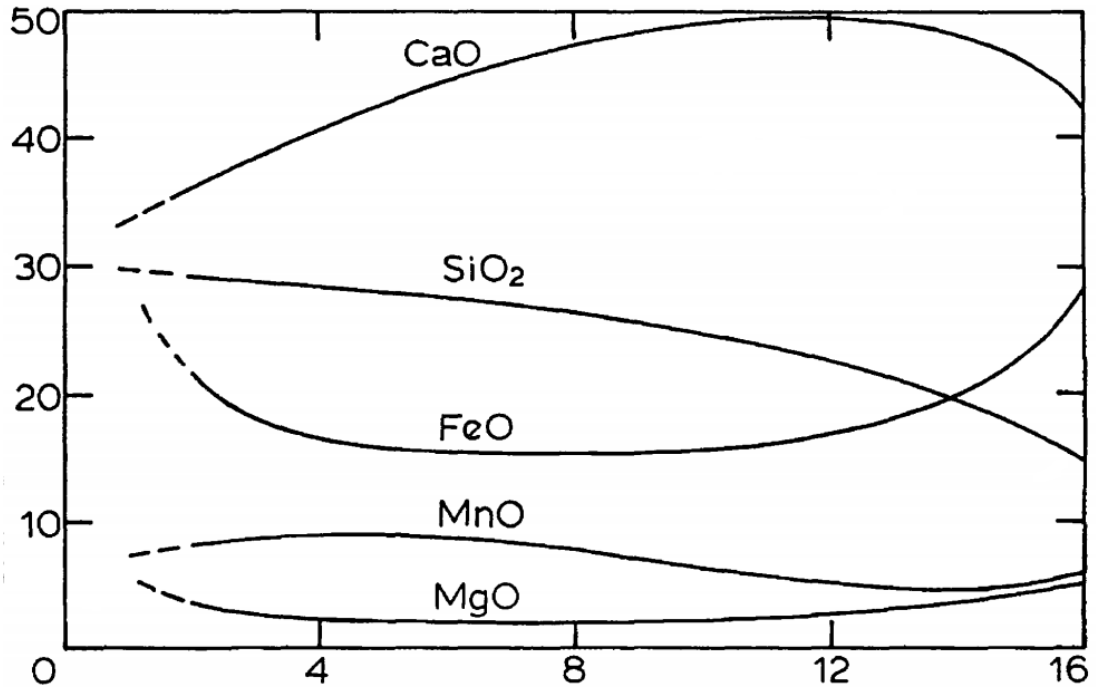
Yüksek cüruf bazisitesi, iyileştirilmiş banyo karışımı, yüksek sıcaklık ve yüksek cüruf akışkanlığı kükürt giderimini destekler [5].

2.1.3. BOF çelik üretiminde cüruf oluşumu

Oksijen kullanılan çelik üretim süreci esasında yüksek karbonlu sıcak metalin düşük karbonlu sıvı çeliğe oksidasyon işlemleri ile saflaştırılmasıdır. Metal banyosuna verilen oksijen, konvertörün içindeki banyoda bulunan sıvı demirin, metalik ve metalik olmayan empüritelerin okside olmalarını sağlar. Bu oksitler çeliğin kendisinden daha ağırdırlar ve çelik banyosunun üzerinde yüzeye çıkarlar. Cüruf konvertörün içindeki sıcak madenin saflaştırılması işlemi sırasında içinde bulunan Si'nin SiO₂'ye, Mn'nin MnO'ya, Fe'nin FeO'ya ve P'nin P₂O₅'e vs. dönüşmeleri ve eklenen fluxlar ile oluşur. Bu fluxlar bazıları CaO ve MgO açısından zengin olan yanmış kireç ve dolomitik kireçtir. Bu iki fluxın maden banyosunda çözünmesi yüksek bazikliğe sahip cüruf oluşumuna sebep olur. Üfleme döneminin sonrasında oluşan cüruf metal banyosunun üzerinde yüzer ve çelik konvertörden bir çelik potasına dökülürken çelikten ayrıştırılıp sonrasında konvertörden uzaklaştırılır.

Oksijen üflemenin başında oksijen lansı metalin yüzeyinden yukarıda yüksekte tutulur. Üfleme işleminin birinci aşamasında silisyum demir ile beraber oksitlenerek FeO ve SiO₂ açısından zengin bir cüruf oluşturur. Ciddi miktarlarda yanmış ve dolomitik kireç sürecin başında konvertörün içine şarj edilir. Üfleme devam ederken katı kireç sürekli

olarak sıvı cürufun içine çözünür ve toplam cüruf kütleini ve bazikliğini arttırır. Karbon giderimi devam ederken cüruf köpüksü yapıyı almaya başlar ve ortaya çıkan CO gazı cürufun içindeki FeO içeriğini azaltır. Bir sonraki şekilde (Şekil 2.6.), üfleme sırasında cüruf kompozisyonunda oluşan değişim gösterilmektedir. Üflemenin sonuna doğru karbon giderimi oranı düşerken demir oksidasyonu tekrar belirgin hale gelir [6].



Şekil 2.6. BOF çelik üretiminde cüruf kompozisyonundaki değişim [6].

2.1.4. Alttan karıştırma

Oksijen ile çelik üretim sürecinde kullanılmakta olan birçok tip konvertör bulunmaktadır. BOF ihtiyaç duyulan tüm oksijenin konvertörün tepesinden su soğutmalı bir lans sayesinde işleme sokulduğu tüm dünyada yaygın kullanıma sahip çelikleştirme sürecidir. Üretim aşamalarını geliştirmek için firmalar tarafından yeni tasarımlar ve değişiklikler yapılmaktadır. Bunun sebebi üretim maliyetlerini azaltırken üretim kalitesini arttırmaktır.

BOF sürecinde banyodaki hareketlilik temel olarak oksijen lansının konvertör banyosuna güçlü üflenmesi ile ve bu sırada oluşan CO oluşumuna dayanır. Üflemenin başlangıç aşamasında silisyumun oksidasyonundan dolayı CO oluşumu biraz zayıftır. Ana dekarburizasyon aşamasında ise yüksek miktarlarda olan CO oluşumu süreci ayakta tutar ve besler. Buna rağmen metal banyosunun harmanlanmasındaki, karıştırılmasındaki eksikliklerden dolayı konvertörün sınır bölgelerinde konsantrasyonda farklılıklar olan ölü alanlar oluşur. Karbon gideriminin son aşamalarında CO oluşumu oldukça azaldığı için döküm içinde yeterli hareket oluşturamamaktadır.

Banyonun karışımının iyileştirilmesi için alttan karıştırma kullanılmaktadır. Alttan karıştırma işleminde azot ve argon gibi soy gazlar veya CO ve CO₂ gibi gazlar BOF konvertörü içindeki erimiş metali karıştırma amacıyla kullanılır. Bu gazlar konvertörün altındaki kontrollü geçirim özelliği olan parçalar ile yapılır. Çelik üretiminin aşamasına bağlı olarak kullanılacak gaz miktarı değişkenlik göstermektedir. Silisyum giderimi ve dekarburizasyon aşamalarında dökümün içinde yeterince homojen bir sıcaklık ve kompozisyon dağılımı sağlamak için karıştırma ekipmanlarının kısıtlama olmaksızın açılması ayarlanır. Düşük oranda dekarburizasyon olan ana üflemenin sonu aşamasında ise karbonun reaksiyon bölgesine taşınımını sağlamak için alttan karıştırma akış hızı artırılır. Metal ve cüruf arasındaki iyileştirilmiş olan yüzey alanı sayesinde oluşan silisyum, manganez, fosfor ve demirin cüruflaşma reaksiyonlarında denge noktasına erişimi, alttan karıştırma destekler. Bunun sonucu olarak fluxların çözünümü alttan karıştırma ile hızlandırılır. Sürecin homojenize edilmesine ve hızlanmasına yardımcı olur [7].

2.2. Yapay Zekâ

İnsanların sanayideki üretim ortamında ve günlük hayatta ortaya çıkan hızlı sonuca ulaşma, maksimum verimlilik ve minimum hata kriterlerini yakalaması için insanüstü hesaplamalara ve tutarlılığa ihtiyaç duyması ile otomasyon doğdu. Yeni ihtiyaçları karşılamak için ortaya çıkan konulardan biri olan yapay zekâ ve makine öğrenmesi konusunun temel amacı, bilgisayarların tecrübelerine dayalı olarak kendi kendilerine

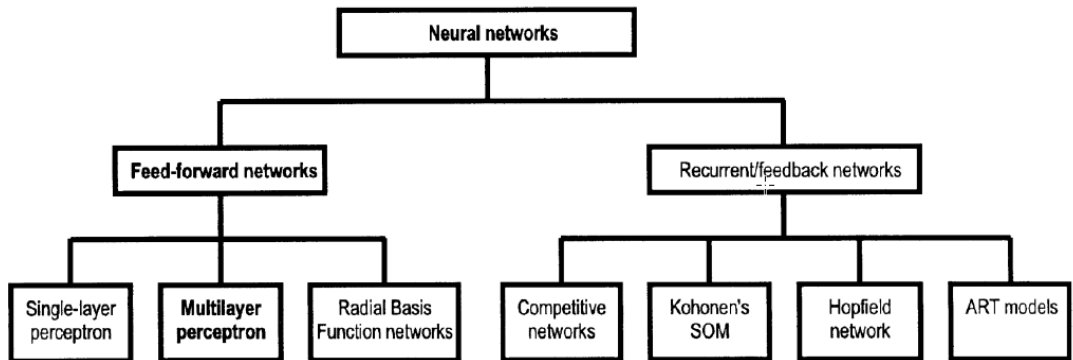
öğrenme süreçlerini iyileştirmeleri ve otomatize etmeleri böylece daha verimli bir çalışma ortamı yaratmaları. Makine Öğrenmesi sürecinin önemli ve ilk aşaması iyi kalitede öğrenme verisinin bulunması, sonrasında bu veri ve algoritmalarla makine öğrenme modelleri oluşturularak makinenin eğitilmesi ve sorunlu alanlarımızda bize çözüm üretmesi sağlanıyor.

Mühendislik alanlarında insan zihni için zorlu sorunların çözümleri için birçok yardımcı araç geliştirilmiştir. Bu araçlar bulanık mantık (fuzzy logic) , bilgi temelli sistemler (knowledge based systems), sinir ağları (neural networks) ve genetik algoritmalar olarak belirtilebilir [8].

Bilgi Temelli Sistemler IF-THEN kuralları ile bilinen bilgilerin yazılım içine entegre edilerek önceki tecrübeler ile sistemlerin çalıştırılmasıdır. Proses kontrolden, hata teşhisine, sinyal çözümlenmeye kadar birçok alanda kullanılmaktadır [8].

Bulanık Mantık ise niteliksel olup tam ve belirli bir teme oturmeyen verilerin olduğu konularda performans göstermektedir. Bir dezavantajı olarak bilgi ambarında bulunmayan konularda cevap verme gücü bulunmamakta [8].

Sinir ağları insan beyninin çalışma mantığının taklit edilerek modellenmesi ile ortaya çıkmıştır. Sinir ağı ile geliştirilen modeller birbirine basitçe paralel yapıda bağlanmış nöronlar gibi hesap yaparak çalışmaktadır [8]. Sinir ağlarının yapılanması Şekil 2.7.'de verilmiştir [9].



Şekil 2.7. Sinir ağlarının alt grupları [9].

Genetik algoritmalar ise doğal gelişimden ilham almıştır. Genetik algoritmaların en önemli yanı belirtilen soruna bağlı bilgi verilmeksizin karmaşık sorunlara çözüm bulabilmesidir. Sorunun tanımına atfen sayı dizileri verilmesi gerekir ki algoritma potansiyel çözümlere ulaşabilsin. Bu sayı dizileri kromozom olarak bilinir ve her birinin iyilik veya kötülük durumunu gösterir [8].

2.2.1. Yapay sinir ağları

Birçok alandaki karmaşık sorunları modellemek için yapay sinir ağları (YSA) ortaya çıkmıştır. YSA modelleri veri işlenmesi sırasında paralel hesaplama yapan birbirine bağlı yapılara sahiptir. YSA modellemenin arkasındaki asıl fikir biyolojik ağın karmaşık sorunları çözebilme yeteneğini kullanabilmesidir [10]. Biyolojik sistemlerin önemli özellikleri olan eş zamanlılık, hata toleransı, nonlineerlik, bulanık bilginin kullanımı ve genelleme yapma yeteneği aynı zamanda YSA sistemlerinde öne çıkan özellikleridir [11].

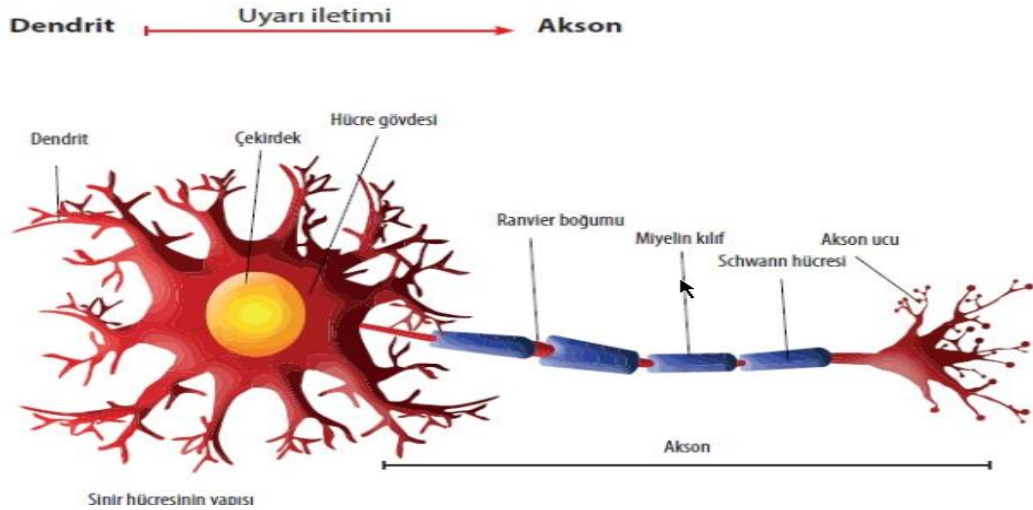
Tarihsel gelişim olarak, McCulloch ve Pitts'in 1940'lardaki çalışmaları ve 1943'te yayınladıkları makale ile yapay nöronlardan oluşan ağların herhangi bir aritmetik veya mantıksal fonksiyonu gerçekleyebileceğini göstermeleri ile sinirsel ağların modern bakışı başlamıştır [12]. Bunu daha sonra Donald Hebb 1949 yılındaki çalışması ile izlemiştir. Nöronlardaki öğrenme için Pavlov'un keşfettiği klasik koşullanmanında nöronların ayrı özelliklerinden kaynaklandığı bir mekanizma önermesinde bulunmuştur. Gelecekte Hebbian öğrenmesi olarak bilinen çalışmalarını, sonunda 1949 yılında yayınlamıştır. Rosenblatt'ın perceptron ağı ve ilişkilendirilmiş öğrenme kuralını buluşu ile Yapay sinir ağlarının ilk pratikte uygulamaları 1950'lerin sonlarına doğru ortaya çıkmıştır. Rosenblatt ve meslektaşları bir perceptron ağı ile örüntü tanımadaki yeteneği göstermişlerdir. Ancak sonrasında temel perceptron ağının sadece sınırlı problemleri çözebildiği gösterilmiştir [12].

1960'ların sonlarına doğru bilgisayar teknolojisinin hızlı ilerlemeyişi YSA için gelişme ortamı sağlayamamış ve sinirsel ağlara olan ilgi ve araştırmalar, 1980'lerde kişisel bilgisayarların hızlı gelişmesi ve güçlenmeleriyle tekrar önemli ölçüde


artmıştır. Fizikçi John Hopfield tarafından oluşturulan ve biriksel hafıza olarak kullanılabilen yinelenen ağların belirli bir sınıfının çalışmasını açıklamada istatistiksel mekaniğin kullanılmasıdır. Sinirsel ağların yeniden doğuşunda çok etkin olmuştur. [12]. Olasılıklı ağ olan, istenen herhangi bir davranış için eğitilebilen Boltzmann makinesinin geliştirilmesinin de tetikleyicisi olan Hopfield'ın bir ağın bir enerji fonksiyonu açısından analiz edilebileceğini önermesidir [13]. Aynı yıllardaki ikinci gelişme ise farklı araştırmacı tarafından keşfedilen çok katmanlı perceptron ağlarının eğitilmesi için geri yayılım algoritmasının geliştirilmesidir. 1986'daki Rumelhart ve McClelland tarafından yayınlanmış olanı geri yayılım algoritmasının en etkili yayımıdır.

2.2.1.1. Yapay sinir ağlarının temelleri ve özellikleri

Yapay sinir ağlarının daha iyi anlaşılabilmesi için temel bilgilerin aktarılması faydalı olacaktır. İlk olarak YSA'nın bağlantı mantığının anlaşılması adına biyolojik nöron bağlantısının gözden geçirilmesi gerekir. Şekil 2.8.'de bir sinir hücresi görülmektedir. Sinaps bir hücre aksonunun diğer hücre dendriti ile bağlantı noktasına denir. Sinirsel ağın işlevini belirleyen, karmaşık bir kimyasal tepkime ile her bir sinapsın gücü ve belirlenen nöronların düzenidir [12]. Bir sinaps yapısı Şekil 2.9.'da görülmektedir.



Şekil 2.8. Bir sinir hücresi gösterimi [14].



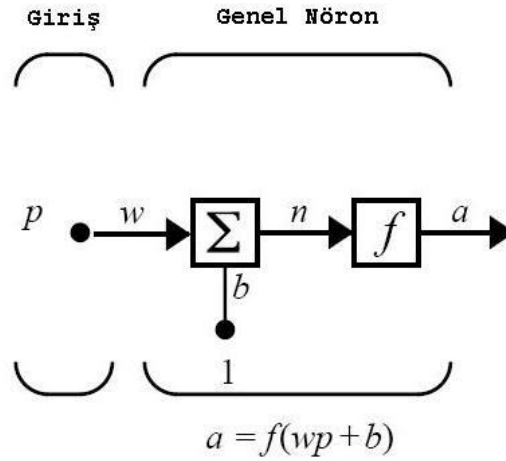
Şekil 2.9. Bir sinapsın görünümü [15].

Sinir hücresinin ana parçaları dendrit, akson ve hücre gövdesidir. Dendritler diğer hücrelerden aldıkları sinyalleri hücre gövdesine iletirler. Hücre gövdesi gelecek kullanımlar için gerekli olan bilgiyi bulundurur ve nöron için ekipman sağlar. Akson hücre gövdesinden gelen sinyali alır ve sinapsa taşır [11].

Biyolojik nöron ile yapay nöron arasında çok belli bir benzerlik vardır, yapay sinirdeki nodlar arası bağlantı dendritleri ve aksonları, bağlantıların ağırlıkları da sinapsların gücünü, hücre gövdesi toplama ve transfer fonksiyonunu andırmaktadır [11].

Bir tek girişli nöron Şekil 2.10.'da verilmiştir. Sayısal giriş p , sayısal ağırlık w ile çarpılarak toplayıcıya gönderilen giriş olan w_p 'yi oluşturur. 1 olan diğer giriş hata eğilim vektörü (bias) b ile çarpılarak toplayıcıya gönderilir [16]. Bias değeri, aktivasyon fonksiyonunu sağa veya sola ötelenmesini (shift) sağlar. Giriş sinyallerinin toplamı 0 olduğunda öğrenme gerçekleşmez, Çıkış değerleri hep 1 olan bias nöronları, nöronların giriş sinyallerinin sürekli sıfırdan farklı olmasını sağlar. Öğrenmeyi

hızlandırırken yerel optimum değerlere takılmayı güçleştirir. Ayrıca bias, nöronun tepki verme eşini belirler. Genelde net giriş olarak adlandırılan toplayıcı çıkışı n , sayısal nöron çıkışı a 'yı üreten bir f transfer fonksiyonuna girer. Nöron çıkışı Denklem 2.13 ile hesaplanabilir.



Şekil 2.10. Tek girişli genel nöron gösterimi [16].

Çıkışın denklemi aşağıda gösterilmektedir (Denklem 2.13)

$$a = f(wp + b) \quad (2.13)$$

Gerçek çıkış, denklemden de görülebileceği gibi seçilen transfer fonksiyonuna bağlıdır. w ve b nöronun ayarlanabilir sayısal parametreleridir. Genellikle transfer fonksiyonu tasarımcı tarafından seçilir ve w ve b parametreleri nöron giriş ve çıkışı arasındaki hedeflenen ilişkinin kurulması için bir öğrenme kuralı sonucunda ayarlanır [16].

2.2.1.2. Yapay sinir ağlarının avantajları

Yapay sinir ağları günümüzde en çok kullanılan modelleme tekniklerinden biridir. Geleneksel modellerle kıyaslandığında eski modellerin herhangi bir kabul olmaksızın giriş verisine ihtiyaç duymalarından dolayı birçok avantajı vardır [9]. Giriş ile çıkış

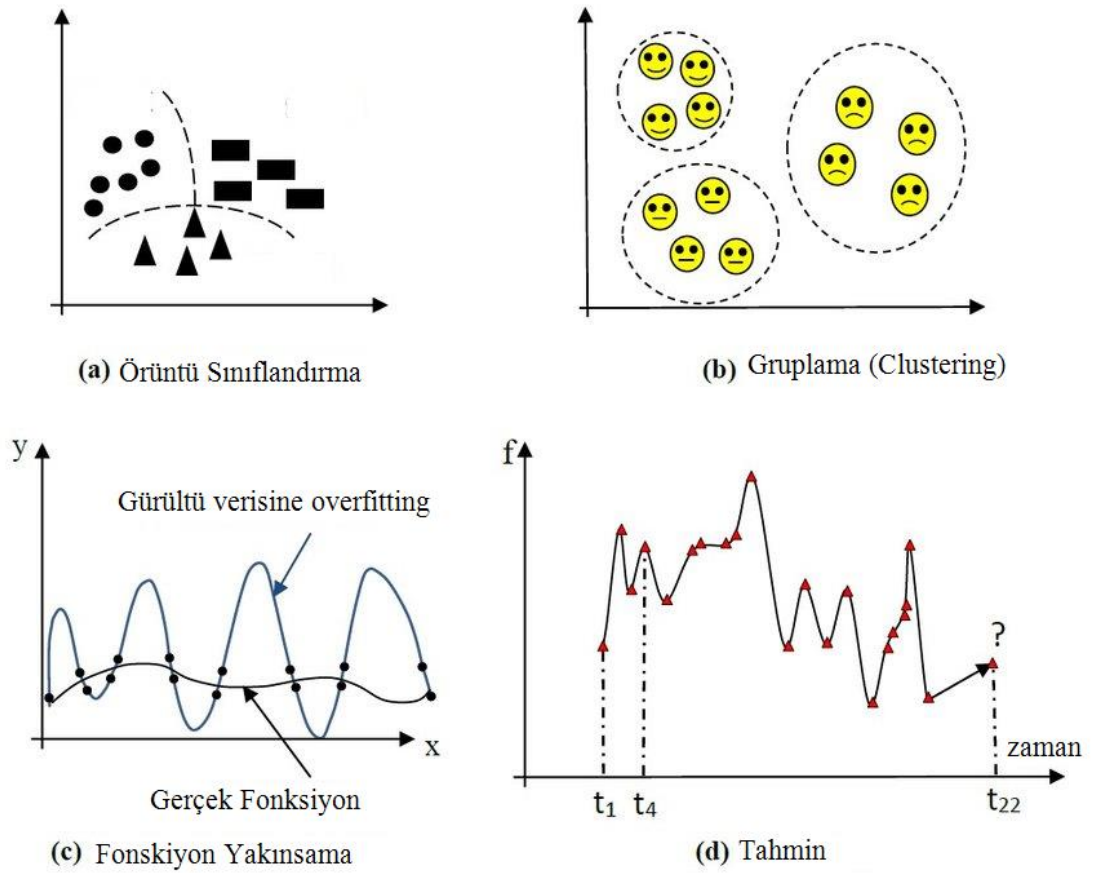
arasında ölçülebilen çok katmanlı fonksiyona yakınsamak uygun bağlantı ağırlıkları ve transfer fonksiyonları ile mümkündür [16,17]. Çok değişken kullanabilmesi ve değişik türdeki değişkenler arası ilişki kurabilmesi ile YSA'nın önemi gittikçe artmaktadır.

Birçok paralel yapılı YSA modelleri yoğun ayarlanabilir birbirine bağlı birimler içerir. Lineer olmayan sorunlara oluşturulan ağların uyum sağlamadaki başarısı en önemli karakteristik özelliğidir [18].

Bunun ötesinde YSA büyük ölçekteki veri kümelerini eğitebilir, işlem süresini belirgin şekilde azaltan paralel yapıları kullanabilir ve herhangi bir fiziksel sürecin lineer olmayan ve karmaşık alt karakteristiklerini yakalama kabiliyeti vardır [11]. YSA modelleri veri tahmini ve veri uyumlama konusunda özellikle veri nonlineerlik gösteriyorsa eski yöntemlere göre çok etkili olduğunu göstermiştir [19].

2.2.1.3. Yapay sinir ağlarının problem çözme yetenekleri

Model gelişimi esnasında 5 ana sorun tipi ile karşılaşmakta ve YSA bu sorunları çözmekte yetkin görünmektedir. Şekil 2.11.'de YSA'nın çözüm üretebildiği belli başlı sorunlar gösterilmiştir [11].



Şekil 2.11. YSA'nın çözüm ürettiği sorun grupları gösterimi [11].

Bu tezde YSA'nın elindeki verileri kullanarak gelecekte olacak değerleri öngörme becerisi kullanılmıştır. Modele girilen verilerin eğitimi ile herhangi bir senaryo durumunda gelecek verinin tahmini yapılmaktadır. Ağ hedef veriyi geçmiş verilerden öğrendiklerini kullanarak tahmin eder [11]. Bu durum YSA'nın genelleme özelliğini de kapsamaktadır.

2.2.1.4. YSA'ların sınıflandırılması

YSA'nın özelliklerine göre sınıflandırma birçok şekilde yapılabilir. Bu sınıflandırma modelleme amacına göre olan fonksiyona, nöronların bağlanma seviyesine, bilginin akış yönüne, öğrenme algoritmasının tipine ve YSA modellemenin eğitim aşamasındaki öğrenme kuralına göre yapılabilmektedir [11].

Öğrenme yöntemlerine göre üç ana sınıfa da ayrılabilirler. Bunlar:

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

En çok bilinen YSA modelleri Hopfield ağları, adaptif rezonans teorisi (ART) ağları, kohonen ağları, geri yayılım ağları (back propagation - BP), ters yayılım ağları ve radial temel ağlarıdır [11].

2.2.1.5. Geri yayılım ağı

Denetimli öğrenmede Geri Yayılım (BP- Backpropagation) ileri besleme algoritması YSA modellerinde kullanılan en ünlü öğrenme algoritmasıdır. BP Widrow-Hoff öğrenme kuralının çok katmanlı ağlara ve lineer olmayan transfer fonksiyonlarına genellenmesi ile oluşturulmuştur. Giriş vektörleri ve bunların karşılığı olan çıkış vektörleri bir ağ içinde bir fonksiyona yakınsayana kadar, giriş değerleriyle çıkış değerleri arasında bir bağlantı kurana kadar ya da giriş vektörlerini sizin tarafınızdan tanımlanmış kurallara bağlı olarak sınıflandırana kadar eğitilir. Bir bias, bir sigmoid katmanı ve bir lineer çıkış katmanı olan ağlar ile sonlu sayıda süreksiz veri girişi olan herhangi bir fonksiyona yakınsayabilir [20].

Geri yayılım algoritması çok katmanlı sinir ağlarının eğitimi için kullanılmıştır [21]. Bir ağı eğitmekteki amaç ağırlıkların, bir giriş veri kümesine karşılık olarak özel işlevsel karakteristiği elde etmek için çıkışlar oluşturmak üzere ayarlanmasıdır. Eğitmenin tam olabilmesi için, her bir giriş vektörüne karşılık beklenen çıkış vektörünü gösteren bir hedef çıkış verisi vektörü olmalıdır. Bu giriş ve hedef çıkış vektörleri bir eğitim çiftini oluşturur. Bir geri yayılım ağındaki öğrenme aşağıdaki basamaklardan oluşur [22]:

1. Eğitim verisinden sıradaki eğitim çifti seçilir ve ağ girişine giriş vektörü olarak uygulanır.

2. Ağ çıkışı hesaplanır.
3. Ağın çıkışı ile istenen vektör (eğitimdeki hedef vektör) arasındaki hata hesaplanır.
4. Hata oranı küçültülecek şekilde ağın ağırlıkları ayarlanır.

Standart geri yayılım (BP) algoritması, Widrow-Huff öğrenme kuralı gereği, gradyan azalış (gradient descent) algoritmadır. Bu algorithmada performans fonksiyonunun gradyanının (değişim derecesi) eksi yönünde ağ üzerindeki ağırlıkların değerlerinin değişmesi sağlanır. Bu teknik yüzünden BPNN yavaş öğrenim yakınsaması gösterebilir ve lokal minimumda takılabilir [23]. Geri yayılım (BP) tabiri lineer olmayan çok katmanlı ağlarda gradyanın nasıl hesaplandığı bilgisini verir. Conjugate Gradient, Newton Methods, Scaled Conjugate Gradient gibi diğer standart optimizasyon teknikleri kullanarak BP'nin temel algoritmasında eksik görülen kısımların iyileştirilmesi için temel algoritmaya bağlı yeni oluşan çeşitli algoritmalar mevcuttur. Eşlenik Gradyan (Conjugate Gradient) algorithmada arama dik azalış aramasına göre daha hızlı yakınsama yapan eşlenikler yönünde yapılır [16][20].

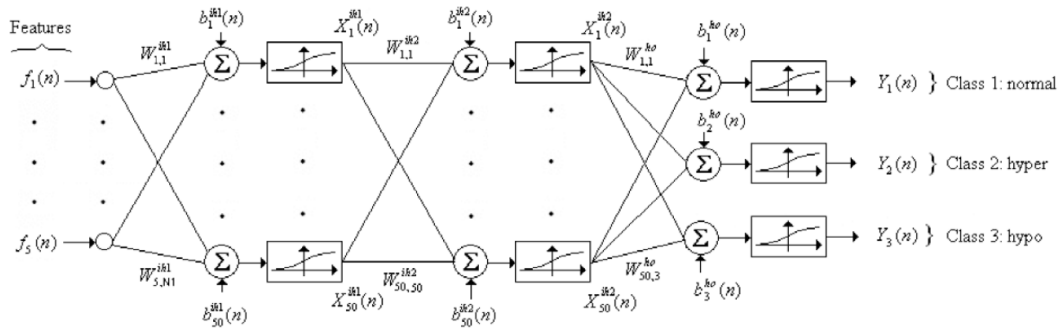
Ölçekli Eşlenik Gradyan algoritması (Scaled Conjugate Gradient – SCG) 1993'te Moller tarafından geliştirildi. Diğer eşlenik Gradyan algoritmalarında olan her iterasyonda bir satır araması yapılmalıdır. SCG'nin geliştirilmesinin amacı, bütün eğitim girişlerine olan ağ cevaplarını, her bir arama için tekrar tekrar maliyetli bir hesaplama ile yapılan satır arama işlemini daha hızlı bir yöntemle değiştirmektir. Bu algoritmanın temel fikri çok kullanılan başka bir öğrenme algoritması olan Levenberg-Marquardt (LM)'de de kullanılan model-güven alanı (model-trust region) yaklaşımını eşlenik gradyan yaklaşımı ile birlikte kullanmaktır. Matematiksel denklem açıklama detayları Moller'in makalesinde bulunabilir [24].

2.2.1.6. Çok katmanlı sinir ağları

Çok katmanlı sinir ağları (MLNN- Multi Layer Neural Networks) giriş katmanı, gizli katman ve çıkış katmanı olmak üzere üç çeşit katmandan oluşmaktadır. Sinir ağı

içerisindeki nöronlar arasındaki her bağlantı o nöronun o veriyi nasıl değerlendiğini belirtir ve bir rakamsal değeri vardır [25].

Transfer fonksiyon olarak sigmoid fonksiyon ve öğrenim algoritması olarak BP'nin standart algoritması olan gradyan descent yerine sayısal optimizasyon tekniği kullanılan algoritmalarından [20] biri olan Levenberg-Marquardt (LM) kullanılmış 5 giriş, 50 ilk gizli katman, 50 ikinci gizli katman ve 3 çıkışlı birçok katmanlı sinir ağı örneği altta Şekil 2.12.'de verilmiştir.



Şekil 2.12. Çok katmanlı ileri beslemeli ağ örneği [26].

İlk gizli katman nöronların çıkış denklemi (Denklem 2.14),

$$\vec{X}^{ih1}(n) = 1/(1 + \exp(W^{ih1}(n) * \vec{f}(n) + \vec{b}^{ih1}(n))) . \quad (2.14)$$

İkinci gizli katman nöronların çıkış denklemi (Denklem 2.15),

$$\vec{X}^{ih2}(n) = 1/(1 + \exp(W^{ih2}(n) * \vec{X}^{ih1}(n) + \vec{b}^{ih2}(n))) . \quad (2.15)$$

Ağın çıkışı Denklem 2.16 ile gösterilmiştir,

$$\vec{Y}(n) = 1/(1 + \exp(W^{ho}(n) * \vec{X}^{ih2}(n) + \vec{b}^{ho}(n))) . \quad (2.16)$$

Yukarıdaki denklemlerdeki $W^{ih1}(n)$ giriş ve ilk gizli katman arasındaki ağırlık verisidir, $\vec{b}^{ih1}(n)$ ilk gizli katmanın bias değerleridir, $W^{ih2}(n)$, ilk ve ikinci gizli


katman arasındaki ağırlık verisidir, $\vec{b}^{ih2}(n)$ ikinci gizli katmanın bias değerleridir. $W^{ho}(n)$ ikinci gizli ve çıkış katman arasındaki ağırlık verisidir, $\vec{b}^{ho}(n)$ çıkış katmanın bias değerleridir, $\vec{f}(n)$ giriş değerleridir, $\vec{Y}(n)$ çıkış değerleridir ve n eğitim grup indexini gösterir (her nöron da farklı eğitim parametresi kullanılabilir) [26].

Bir transfer fonksiyonu (aktivasyon ya da sistem fonksiyonu da denir) giriş ve çıkış arasındaki ilişkinin, uzay zaman frekansında, matematiksel gösterimidir. Transfer fonksiyonlar genelde sigmoid şekildedirler ve diğer lineer olmayan diğer step fonksiyonları gibi fonksiyonlar şeklinde de olabilir [27]. Bu fonksiyonlar genel olarak monoton olarak sürekli artan, süreklilik arz eden, türevi alınabilir (differentiable) ve sınırlandırılmıştır. Yapay sinir ağlarının bir özelliği olan “doğrusal olmama” aktivasyon fonksiyonlarının doğrusal olmama özelliğinden gelmektedir.

En çok kullanılan transfer fonksiyonlarından biri Şekil 2.13.’te gösterilen log-sigmoid (LOGSIG) fonksiyonudur. Bu transfer fonksiyonu eksi artı aralıkta herhangi bir değeri olan girişi alıp çıkışı 0 ve 1 aralığına sıkıştırır. Log-sigmoid transfer fonksiyonu genel olarak çok katmanlı sinir ağlarında geri yayılım algoritması kullanımında türevlenebilir olduğu için kullanılır.

Hiperbolik tanjant transfer fonksiyonu (TANSIG, Şekil 2.13.) sinir ağları bağlamında -1 den +1’e olan aralıkta çıkışı olan bipolar sigmoid fonksiyonuyla ilişkilidir. Tansig transfer fonksiyonu genel olarak matematiksel dengi olan tanh(n)’ye karşılık olarak kullanılır. Tanh den farkı daha hızlı olmasına rağmen sonuçlarda sadece küçük farklılıklar görülmektedir. BU fonksiyon hızın fonksiyonun genel şeklinden daha önemli olduğu durumlarda ihtiyacı iyi karşılamaktadır.

Birçok gerçek model lineer olmayan giriş ve çıkış özellikleri gösterir. Bazı modeller ise nominal parametrelerle çalıştırıldıklarında lineere çok yakın bir tavır sergiler. Bu tip durumlarda Purelin (Şekil 2.13.) transfer fonksiyonu bu tavrın bir temsilcisi olabilir [28].



Şekil 2.13. Transfer fonksiyonların grafik gösterimi. Sırasıyla Log-Sigmoid, Tan-Sigmoid, Purelin [28].

Probleme ve uygulama sırasında ortaya çıkan ihtiyaçlara bağlı olarak transfer fonksiyonlar, öğrenme algoritmaları ve nöron sayıları belirlenmektedir.

2.2.1.7. Makine öğrenme modelleri için çapraz doğrulama yöntemleri

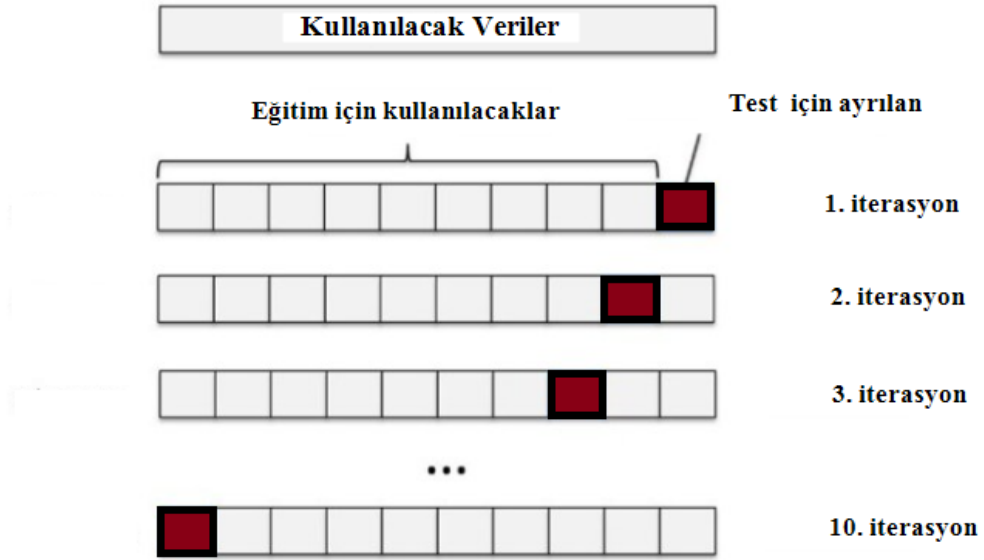
Genel olarak model doğrulama çok önemli ancak birçok model tabanlı metodoloji açısından tartışmalı görünen bir konudur. Model tabanlı yapılan çalışmalarda sonuçların doğrulanması direkt olarak modelin kendisinin doğrulanmasına bağlıdır [29].

Bir öğrenme metodunun genelleme performansı bağımsız test verilerindeki tahminleme yeteneğine bağlıdır. Seçilecek olan modelin kalitesinin ve öğrenme metodu ve modelin seçimine yönlendiren bu özelliğin değerlendirilmesi uygulamada çok önemlidir. Birçok doğrulama metodu mevcuttur ve büyük olasılıkla en kolay ve en çok kullanılan öngörü hatasını tahmin eden yöntem çapraz doğrulamadır (cross-validation). Bu metot direkt olarak, Denklem 2.5'te verilen, bir tahmin modeli $\hat{f}(X)$ 'in bağımsız test örneğine X (giriş vektör) ve Y (hedef değişkenleri) ortak dağılımı beklenen ekstra-örnek hatası olan ortalama genelleme hatasını tahmin eder [30].

$$Err = E[L(Y, \hat{f}(X))] \quad (2.5)$$

İdealde modelin eğitimi ve test çalışmaları için yeterince verimiz olsaydı eğer, doğrulama için seti bir kenara bırakır veriyi tahmin modelinin performansını değerlendirmek için kullanırdık. Verinin genellikle az olmasından dolayı bu anlatılanın yapılması mümkün olmuyor. Bu sorunun çözümü için k-Kat çapraz doğrulama(K-fold

Cross Validation) elimizdeki verinin bir kısmını modeli uydurmak için kullanırken farklı bir kısmını test için ayırır. Veriyi yaklaşık K eşit parçaya ayırırız. K=10 olduğunda alttaki Şekil 2.14.'teki gibi görünür.



Şekil 2.14. 10-fold cross validation grafiksel gösterimi.

Örnek olarak k. parça olarak 3. iterasyonu alırsak ana verinin diğer k-1 kısmını modele eğitim için uygularız ve k. parçanın modele test verisi olarak uygulandığı durumdaki çıkış hatası hesaplanır. Bu işlem her bir parça için teker teker yapılır $k=1,2,3,\dots,10$ ve k tane yakınsama hatası birleştirilir.

Daha detaylı bakarsak, $\kappa: \{1, \dots, N\} \mapsto \{1, \dots, K\}$ 'nın i inceleme adımında kullanılacak olan kısmın rastgele tahsis edildiği bir dizinleme fonksiyonu olduğunu düşünelim. $\hat{f}^{-\kappa(i)}(x)$ 'in ayrıştırılmış verinin k inci parçası ile çalıştırılmış tahmin modeli fonksiyonu olduğunu belirtelim. Bunun sonucunda CV öngörme hatasının yaklaşık sonucu Denklem 2.6'daki gibi bulunur,

$$CV(\hat{f}) = \frac{1}{N} \sum_{i=1}^N L(y_i, \hat{f}^{-\kappa(i)}(x)). \quad (2.6)$$

$K = N$ olduğu durumda görülmüştür ki çapraz doğrulama sadece ortalama hatayı tahmin etmektedir [30].

Farklı kaynaklarda benzer uygulamanın Breiman ve ark. ya da Kohavi gibi cross validation'ın tahmine ve modelleme üzerine değişik çalışmalar da mevcuttur m [31][32].

k için seçenek genellikle 5 veya 10'dur bunun için kesin bir kural yoktur. k sayısı büyüdükçe eğitim kümesi ile test kümesi arasındaki oransal farkta büyür. Farkın büyümesi veri kümesinin öğrenmede daha tarafsız olmasını dolayısı ile modelin genelleme kapasitesini arttıracığı görülmüştür [33].

2.2.1.8. Normalizasyon

YSA öğrenmesinde diğer giriş vektörlerinden daha geniş veya daha küçük olan bir aykırı giriş vektörü uzun öğrenme süresinin sorumlusu olabilir. Hataya cevap olarak Nöron (Perceptron) öğrenme kuralını uygulamak o andaki ağırlıklardan ve biastan giriş vektörünü çıkarmayı veya onlara eklemeyi gerektirir. Böylece giriş vektörlerinden diğerlerine göre büyük olan vektör, ağırlıklar ve biaslardaki olacak değişikliklerin küçük girişlere göre çok zaman almasına sebep olabilir.

Nöron (Perceptron) öğrenme kuralını az miktarda değiştirerek öğrenme süreleri, çok büyük veya küçük aykırı input vektörüne karşı hassas olmaktan kurtarılabilir. Alttaki Denklem 2.8'de ağırlıkların orijinal güncelleme kuralı bulunmaktadır.

$$\Delta w = (t - a)p^T = ep^T \quad (2.8)$$

a nöron cevabı, t hedef vektör, p giriş vektörü ve e error'ü temsil eder. p^T , p vektörünün transpozesidir. P vektörü ne kadar büyükse ağırlık vektörü w üzerinde o kadar fazla etkisi olacaktır. Bu yüzden eğer büyük içeriğe sahip bir giriş vektörü varsa küçük giriş vektörü bir etki göstermesi için sisteme birçok defa sokulmalıdır. Bu

soruna çözüm olarak her giriş vektörünün ağırlıklara etkisinin benzer büyüklükte olması için kuralı normalize etmektir, Denklem 2.9'da gösterildiği gibi [20].

$$\Delta w = (t - a) \frac{p^T}{\|p\|} = e \frac{p^T}{\|p\|} \quad (2.9)$$

Normalizasyon farklı veri tiplerini ve veri kümelerinin kıyaslanmasını sağlar, normalizasyon olmadığında ağ içinde birlikte bütün hesapları yapmak çok karmaşık hale gelecektir. Pratik nedenlerle girişleri normalize etmek YSA'da eğitimi hızlandırır ve lokal minimumda takılma şansını azaltır. Birçok normalizasyon teknikleri mevcuttur. Denklem 2.10'da gösterilen Min-Max normalizasyon tekniği bazı araştırmalarda diğerlerinden daha başarılı çıkmıştır [34].

$$n = \left[\frac{X_i - X_{\min}}{X_{\max} - X_{\min}} * (R_{\max} - R_{\min}) \right] + R_{\min} \quad (2.10)$$

Bu denklemde i tane gerçek değeri olan bir veri setinde, X_i i 'inci gerçek değeri, X_{\min} en küçük gerçek değeri, X_{\max} en büyük gerçek değeri R_{\max} ve R_{\min} normalize edilecek aralığın minimum ve maximum değerlerini ve n ise denklemin sonucu olarak normalize olmuş yeni değeri vermektedir.

YSA kullanıldıktan sonra ortaya çıkan yeni sonuçlar ve girdiler tekrar geri normalize edilerek gerçek hayat değerlerine döndürülmelidirler.


2.3. Problem Tanımı ve Literatür

2.3.1. Erdemir'de BOF ile çelik üretimi

Entegre Çelik üreticisi olan Ereğli Demir Çelik Fabrikalarında (Erdemir) birbirinin aynı olan 3 adet 120 ton çelik kapasiteli L-D / Bazık Oksijen Fırını tipi konvertör bulunmaktadır. BOF1, BOF2 ve BOF3 adı verilen konvertörler 1991, 1992 ve 1993 yıllarında kapasite artırımı projeleri kapsamında modernize edilmişlerdir. İlk tasarım kapasiteleri 2.8 milyon ton olmasına rağmen 3.8 milyon ton maksimum, son 5 yılın ortalaması olarak da 3.4 milyon ton üretim ile yoğun üretim hızıyla çalışmaktadırlar.

Konvertör duvarına çeşitli bölgelerde farklı kompozisyonda, konvertöre fırın özelliğini veren, karbona doymuş CaO refrakter döşenmiştir. Bu alanlar şarj alanı, döküm (tapping) alanı, muylu alanı ve taban alanı olarak geçmektedir. Refrakterler yaklaşık olarak 6500-7500 döküm de bir üretim programına ve konvertörün durumuna göre değiştirilmektedir. Refrakter ömrü cüruf sıçratma, gunning malzemeleri ve shut-crete material uygulamaları ile uzatılmakta. Oksijen üfleme miktarı ve süresinin uzun ve tekrar üfleme gibi durumların çok olması halinde refrakter ömrü azalmaktadır.

Su soğutmalı üfleme lansından konvertörün tepesinden %99.9 saflıkta oksijen içeriye verilmektedir. Konvertör tasarımında çelik banyo seviyesi, toplam oksijen üfleme zamanı gibi kritik tasarım parametrelerinden biriside üfleme lansının uç seçimidir. Genellikle 12 derece açıyla konumlandırılmış 5 delikli lans uçları oksijen üfleme için kullanılır. Değişik işlem fazında oksijen akışı farklılık gösterse de genelde 420 Nm³ kullanılmaktadır. Şekil 2.15.'te gösterildiği üzere aynı ebattaki 6 adet nozuldan konvertörün alt kısmından alttan karıştırma için argon ve azot gazı üflenmekte ve işlem homojenizasyonu ve ısıl dengesini kurmaya yardımcı olmaktadır. Multijet tipte 32 delikli nozulların 2500-3500 döküm arasında olmakta. Üretim kalitesini etkilemesinden dolayı alttan karıştırma kapalı veya açık durumuna göre işletme pratikleri farklılık göstermektedir.



Şekil 2.15. Konvertör tasarımı ve alttan karıştırma nozullarının yerleri.

Yüksek fırında üretilen pik demir torpidolarla kükürt giderme işleminin yapılacağı kükürt giderme istasyonuna getirilir. Pik demirin içindeki kükürt miktarına ve konvertörlerde çalışılan kalitelere bağlı olarak beklenen hedef kükürte kükürt giderme işlemi uygulanır. Sürekli dökümlerin ihtiyacı olan, oradaki bindirme döküm ihtiyacını karşılayacak ve üretim planlamanın yaptığı listeye göre hangi kalite için döküm oluşturulduysa o dökümlere göre sıcak metal çukurlarında, yaklaşık 140 ton sıcak maden taşıyan, torpidodan 100 tonluk sıcak metal potasına sıcak maden aktarılır. BOF içerisinde çelik üretim sürecin amaçları olan hedef çelik ağırlığı, hedef kalite kompozisyonundaki karbon (C), fosfor (P), silisyum (Si) ve manganez (Mn) ve hedef sıcaklığa göre şekillenir. İstenen nihai ürünün oluşması için ısıtıcı ve soğutucu flux malzemeler izin verilen limitler içerisinde kullanılır. Hedef baziklik olan 3.5'e ulaşmak için yanmış kireç ve dolomitik kireç cüruf yapıcı olarak kullanılır.

Süreç takibi ve hesaplamalar Seviye 2 Sistemi (Level 2) denilen otomasyon sistemi tarafından takip edilir. İlgili kalite bilgileri, malzeme kompozisyonları, önceki ve

sonraki tesislerde görülen işlemlere ait analiz ve işlem sonuçları bu sistem üzerinden takip edilir. Seviye 2 (SCADA) sistemi, Seviye 1 (Level 1, PLC systems) denilen alt otomasyon sisteminden aldığı oksijen akışı, şarj edilen malzeme, kantar ağırlıkları gibi saha bilgileri ve üst sistemlerden gelen yukarıda bahsi geçen malzeme tenörü denilen flux malzemelerin kompozisyon bilgisini, kalitenin bilgisini tutan ve Kalite Kontrol grubu tarafından belirlenen kalite kompozisyon ve sıcaklık bilgilerini alan ve işletme grubunun hazırladığı gene kaliteye bağlı işletme pratiği denilen hangi durumda hangi olay sonrasında ne yapılması gerektiğini belirten pratiklere bağlı olarak dökümün durumunu gösteren ve enerji dengesine bağlı olarak çalışan modelleri vasıtası ile operatöre yol gösteren sistemlerdir. Otomasyon prosedüründe kullanılan verilere örnek olarak göstermek için ve girdiler anlamında bir döküme ait özet bilgiler Tablo 2.1. , Tablo 2.2. ve Tablo 2.3.'te gösterilmiştir.

Tablo 2.1. Kalite, bazisite, üfleme zamanı ve üflenen oksijen hedefleri

Grade	Bazisite Hedef	Üfleme Zamanı	Üflenen Oksijen
7***K	3,5	14,8 dk.	5400Nm ³

Tablo 2.2. Hedef çeliğe bağlı girdiler ve kullanılan flux malzemeleri

Hedef Çelik Tonajı	Çelik Ağırlığı	Sıcak Maden	Hurda	Demir Cevheri	Yanmış Kireç	Dolomitik Kireç	Deox Alümin.
120 Ton	122 Ton	107 Ton	25 Ton	661 kg	5450 kg	769 kg	227 Kg

Tablo 2.3. Analiz ve sıcaklık girdi ve hedef değerleri tablosu

	Sica.	Oppm	Nppm	C	Mn	P	S	Si	Cr	Ti	Cu
Sıcak Maden	1375		22	4,085	0,238	0,09	0,009	0,534	0,029	0,027	0,015
Üfleme İçi	1603		25	0,444	0,209	0,017	0,009	0,003	0,029	0,001	0,027
Üfleme Sonu	1678	747	38	0,04	0,092	0,008	0,009	0,004	0,018	0,001	0,028
Döküm Hedef	1675		60	0,03	0,2	0,018	0,012	0,030	0,080	0,010	0,12

BOF konvertörü içine hurda ve sıcak maden şarjından sonra oksijen üflenmesine başlanır. İşlem adımları ve yaklaşık zamanları Tablo 2.4.'te verilmiştir. Ateşlemenin başlamasından sonra flux malzemeleri boşaltma kantarından konvertöre boşaltılır. Toplam işlem süresi genel olarak kaliteye bağlı değişse de yaklaşık 15 dakikadır. Oksijen üfleme sırasında oksijen üfleme lansına yakın duran sublans ile üfleme içi ölçümü yapılır. Üfleminin yaklaşık %80 inde oksijen üfleme kesilir ve sublans sıcak madene dalarak anlık sıcaklık ölçümü ve numune alımı yapılır. Kısaca TSC denilen sıcaklık-numune-karbon (temperature-sample-carbon) ölçümü için kullanılan ölçüm probu kullanılır. Üfleme içi alınan ölçüm üfleme modelinde üfleme sonu karbon ve sıcaklık hedeflerine ulaşmak için düzeltme yapılmasını sağlar.

Üfleme sonunda sublans ikinci kez dalar ve üfleme sonu (EOB- end of blow) ölçümü yapılır. Bu end-point adı da verilen üfleme sonu ölçümü için TSO denilen sıcaklık-numune-oksijen (temperature-sample-oxygen) tipi bir ölçüm probu sublansın ucunda kullanılır. Bu probe çelik sıcaklığını ve aktif oksijenini ölçer bunun yanında çeliğin nihai kompozisyonun anlaşılması için bir numune alır. Ortalama 15 dakikalık toplam üfleme süresinin %80 inde yani yaklaşık 12 inci dakikada alınan TSC numunesinin de laboratuvar analiz sonucu yaklaşık olarak üfleme sonunda gelir ve numune sonucu, sıcaklık, karbon/oksijen değerlerine bakılarak hızlı döküme ya da tekrar üfleme kararı verilir. Üfleme içi karbon tahmini çeliğin liquidus denilen sıcaklığına ve ölçüm yapılan proba bağlıdır ancak liquidus sıcaklığı çeliğin içindeki karbon miktarı ile tanımlanır ve çeliğin içindeki diğer elementler bu liquidus sıcaklığını bozabilir.

Tablo 2.4. BOF konvertörde işlemler ve toplam zaman gösterim tablosu

DURUM	Kümülatif Zaman dk.
Konvertör Boş	0
Hurda Şarjı	3
Sıcak Maden Şarjı	5
Dolu Bekleme	5,5
Oksijen Üfleme - Ateşleme	6
Oksijen Üfleme – Üfleme içi	18
Oksijen Üfleme – Üfleme Sonu	21

Tablo 2.4. (Devamı)

DURUM	Kümülatif Zaman dk.
Oksijen Üfleme – Poststirring	22
Oksijen Üfleme – Tekrar Üfleme	24
Döküm – Başlangıcı	25
Döküm - Sonu	31
Cüruf Ayırma	34
Cüruf Sıçratma	36

2.3.2. Problem tanımı

BOF çelik üretimi yönteminde, oksijen üfleme ve atılan flux malzemeleri ile sıcak madenin içindeki karbon (C), fosfor (P), silisyum (Si), manganez (Mn) ve demir (Fe) gibi ürünün müşterinin siparişine uygunluğunu gösteren ve evrensel kalite göstergeleri olan elementlerin, en verimli şekilde istenilen aralığa indirgenmesine çalışılır. Silisyum ve Manganez konvertörde ve konvertör sonrası süreçte alaşım ve doğal kimyasal tepkimelerle takibi ve düzenlemesi kolay elementler iken, karbon ve özellikle fosfor konvertördeki yüksek oksijene bağlı, konvertörün sürecinden en çok etkilenen ve ikincil metalürji istasyonlarında düzeltilmesi mümkün olmayan çeliğin kullanımını ve kalitesini çok etkileyen iki kritik elementtir. Karbon çelik olma kriterlerini belirlerken çeliğin içindeki fosfor, ürünün esnekliğini ve yıpranma direnci gibi daha yüksek mekanik performans kriterlerini yerine getirir. Karbonun ve fosforun konvertörde istenen limitlerde olmasının sağlanması çelik üretim sürecinde hem üretimin verimini ve kalitesini arttıracak hem de maliyetini düşürecektir

Çelik üretim süreci içerisinde pek çok ölçüm yöntemi kullanılmakla beraber her sistemin eksikleri bulunmaktadır. TSC ile karbon ölçümü yapıldığında hem üfleme ara verilip değerli işletme zamanı alınmakta hem de liquidus sıcaklığının veya numune alınan noktanın uygun olmaması sonucu yanlış ölçümler yapılabilmektedir. Fosfor değeri için ise hiçbir teknoloji firması tam olarak güvenilen bir model veya matematiksel hesap ortaya koyamamıştır. Kullanılmakta olan otomasyon sistemlerindeki dökümün kalitesine bağlı verilerin de doğruluğunun sağlanamadığı durumlarda bu matematiksel hesaplar konvertör işletme operatörlerini yanlış

yönlendirip hem BOF hem de diğer ikinci planda ürün bekleyen sürekli dökümler gibi tesislerin durmasına ve üretim maliyetlerinin artmasına sebep olabilmektedir.

TSC ve TSO problemleri ile alınan numuneler ilgili ürünün künyesi olmakta müşteriye verilen belgeler arasında yerini almakta ve kontrol edilmektedir. Numune alındığı anda hemen laboratuvara gönderilse bile oradaki işlemlerden dolayı numune alınması ve cevap dönüşünün Seviye 2 sisteminde görünmesi arasında yaklaşık 5-10 dk. bulunmaktadır. Toplam üfleme süresinin 15, toplam işlem süresinin de yaklaşık 35 dk. olduğu BOF tesisinde bu süre çok fazladır. TSC numunesinin bile bazı durumlardan döküm BOF tesisinden çıktıktan sonra geldiği bile olabilmektedir.

Bu şartlar altında düşük maliyetli son kullanıcı açısından kullanımı ve anlaması kolay ürünler ortaya koyduğu görülen yapay sinir ağlarının kullanımı ile dökümün üretilmesi aşamasındaki verileri kullanan hem TSC hem de TSO numune alınması anlarında özellikle takip edilen karbon ve fosfor elementlerinin anlık değerlerini tahmin eden ve numune sonuçları gelmeden operatörün karar almasına destek olabilecek yapay sinir ağı kurulması bu çalışmanın konusudur.

2.3.3. Literatürde yapılan çalışmalar

Akademisyenlerin yapay sinir ağları ile yaptığı çalışmalar en iyi ısı pompası tasarımı [35], sağlıkta göğüs kanseri [36], tiroit hastalıkları teşhisinden [26], günlük hayattaki hava tahminine [37] kadar birçok alanda kendine yer edinmiştir. İstenen sonuçların bulunması için her birinde YSA'nın yıllar içinde gelişen teknik ve metotları farklı farklı kullanılmıştır.

BOF Çelik üretiminde de makine öğrenme ve yapay zekâ ile BOF prosesinin süreç kontrolünü içeren çok çeşitli çalışmalar yapılmıştır örnek olarak C.Kubat ve ark.'larının bulanık mantık metodunu kullanarak [38], M.Han ve ark.'nın ise Adaptive-Neuro-Fuzzy-System ve robust relevance vector machine kullanarak [39] yaptıkları çalışmalar verilebilir. Karbon ve üfleme sonu sıcaklığı konvertöre çelikleşme sürecinin sonunu gösteren, çeşitli canlı ölçüm (TSC probu) ve hesap teknikleri ile de desteklenen

iki büyük kriter olduğu için üzerlerinde farklı metotlarla çok çalışma yapılmıştır. Keza üfleme içi ve sonu fosfor miktarını da laboratuvar sonucu gelmeden hesaplayan ve yüksek doğruluğu yakalayan ticari bir ürün olmadığı için literatürde birçok örnekleri bulunmaktadır. Üfleme sonunda Karbon ve fosfor tahmini için ve yapay sinir ağları içerisinde kullanılan mekanizmalar hakkında yapılmış olan çalışmaların bazıları aşağıda özetlenmiştir.

Xie ve Chai (1999) [40] BOF tesisinde end-point denilen üfleme sonu karbon ve sıcaklığı tahmin etmek için yaptıkları çalışmada Grey (1,1) denilen bir kısmı bilenen ve bir kısmı da bilinmeyen gri alan sistemlerini hedef alan bir metot ve lineer regresyon kullanmışlardır. Sıcaklık ve karbon için çalışmaları sonucunda en iyi sonuç olarak $|\Delta T| \leq 20$ °C ve $|\Delta C| \leq 0,05$ hata aralıklarında %80 hedef yakalama oranı (hitting rate) bulmuşlardır.

Gonzalez ve Barron (2002) [41] yaptıkları çalışmada off-gas denilen üfleme sırasında konvertörün tepesinden dışarı atılan gaz içindeki karbon monoksitin (CO) ölçümlerinin prodesteki şartlar altında gürültü taşıdığını belirtmiş ve bu gürültünün giderilip indirgenme reaksiyonlarında CO ya bağlı olan çelik içindeki karbon (C) miktarı için bir yakınsama modeli önermiştir.

Kiş, Uncuoğlu (2005) [42] yaptıkları çalışmada 3 farklı geri yayılım eğitim algoritmasını akarsu akışı ve kohezyonsuz topraklarda lateral stress saptanması iki farklı deney setinde denemişlerdir. Bu çalışmalarında üç algoritma eğitimde yakınsama hızları ve test ortamındaki performansları ile kıyaslanmışlardır. Eğitim aşamasındaki testlerde LM algoritması diğerlerine göre daha hızlı yakınsama yapmış olsa da resilient BP algoritması test aşamasında çok daha iyi sonuç vermiştir. Bu çalışmalarına rağmen sonuç kısmında verilen sorunlar karşısında hangi algoritmanın daha iyi sonuç vereceği kesin olarak bilinemez demektirler. Seçimin sorun karmaşıklığı, giriş verileri sayısı, ağlardaki ağırlıklar ve bias seçimleri ile birebir bağlı ve değişken olduğunu belirtmişlerdir.

Li, Zhao ve Yi (2011) [43] yaptıkları çalışmada MATLAB yazılımını kullanarak normalize edilmiş verilerin kullanıldığı geleneksel geri yayılım sinir ağını (BP-MLNN) Levenberg-Marquardt (LM) öğrenme algoritması yardımı ile optimize ederek konverjansını (yakınsamasını) hızlandırmış ve sonucunda $|\Delta C| \leq 0,025$ hata farkı aralığında %80 hedef yakalama oranı (hitting rate) bulmuşlardır.

Dorofki ve ark. (2012) [28] yağış-akış simülasyonunda yapay sinir ağlarının transfer fonksiyonlarının yeteneklerini kıyaslama çalışması yapmışlardır. Standart normal dağılıma yakın akış verisi olduğu durumlarda neredeyse bütün yağış-akış modellerinin iyi performans verdiğini belirtmişlerdir. Çalışmalarının amacı ekstrem akış durumlarını simüle edecek en iyi yapay sinir ağı transfer fonksiyonunu bulmaktır. Bu amaçla girişleri sızma ve yağış olan iki giriş ve çıkış olarak akış olan bir YSA oluşturulmuştur. Çalışmalarının sonucunda kullanılan yapay sinir ağında ve veri kümesinde minimum ve normal akışlarda Log-Sigmoid'in en iyi olduğunu ancak Purelin transfer fonksiyonunun da maximum yağış durumlarında en iyi sonucu verdiğini belirtmişlerdir.

Wang, Xu, Ai, Tian (2012) [44] BOF'taki ergimiş çelik içinde üfleme sonunda fosfor içeriğini tahmin etmek için kümeleme ve öngörme aşamaları için hibrit bir metot önermişlerdir. Kümeleme aşamasında weighted K-means algoritması kullanılarak homojen dağılımlı kümelerin oluşması sağlanmıştır. Sonuç hedefe tesir eden faktörlerin ağırlıklarını EWM (Entropy Weight Method) ile hesaplamışlardır. Tahmin etme aşamasında ise her bir küme için ayrı GMDH (Group Method of Data Handling) polinom sinir ağı oluşturulmuştur. Oluşturulan bütün GMDH polinom sinir ağlarının hibrit metodu oluşturmak için birleştirilmiştir. Hibrit metot, GMDH polinom sinir ağı ve BP sinir ağı bir kıyasa sokulmuş ve sonuçları gözlemlenmiştir. Önerilen GMDH polinom sinir ağının diğer iki ağdan daha iyi sonuç verdiği gösterilmiştir.

Wang ve ark. (2013) [45] üfleme sonu çeliğin içindeki fosforun çeliğin kalitesi üzerinde büyük etkisi olduğunu ve müşterilerin bu konuda daha sıkı limitlerde ürün talep ettiklerini belirtip fosforun çelik içerisindeki cüruftaki FeO ile olan termodinamik ilişkileri analiz edilmiştir. Geniş çaplı veri kümesi üzerinde

multivariate regresyon analiz'i ile multi-level recursive regresyon'u birleřtirerek multi level recursive regresyon modeli geliřtirerek üfleme sonu fosforun tahmini $|\Delta P| \leq 0,005$ hata farkı aralığında %84 hedef yakalama oranı (hitting rate) ile bulmuşlardır.

Nawi ve ark. (2013) [46] yaptıkları çalışmada geri yayımlı yapay sinir ağlarında eğitilen multi layer perceptronların performansının kullanılan verilerin boyutundan ve veri öniřlemlerinden çok etkilendiğinden, sinir ağının yakınsamasının veri öniřleme teknikleri ile ne kazanabileceği incelenmiştir. Özellikle Min-Max, Z-Score ve Decimal Scaling gibi normalizasyon teknikleri kullanılmıştır. Simülasyon sonuçları veri öniřleme yapılan sinir ağlarının daha iyi sonuçlar verdiğini göstermiştir.

Wang, Cai ve Feng (2014) [47] üfleme sonu fosfor modeli oluşturmak için iki aşamalı Hibrit bir metot geliřtirmişlerdir. İlk aşamada homojen dağılıma sahip veri kümeleme (clustering) yapmak için ağırlıklı k-ortalama-kümeleme (weighted k-means clustering) işlemleri yapılmış. İkinci aşama olan tahmin etme sürecinde ise her bir küme üzerinde bulanık mantık yapay sinir ağı kullanılmış ve en sonunda bütün kümelerin sonuçları birleřtirilip hibrit metodun sonucu olarak ortaya konmuştur. Sonuç olarak hibrit yöntemin sadece bulanık sinir ağı kullanılarak erişilen sonuçlardan daha iyi bir tahminleme yaptığı görülmüştür. Yapay sinir ağlarında test ve öğrenme süreçlerinde kullanılacak verilerin kümelenmesinin veya gruplanmasının oluşturulan veri uzayının yapay sinir ağının sonuçlarındaki etkileri anlamında güzel bir çalışma olmuştur.

Liu, Wang ve Xiong (2014) [48] tarafından BOF'taki çelik üretimin üfleme sonrası end-point e geldiğini bilgisayar görme ve genel regresyon YSA (computer vision and general regression neural network) yöntemleri ile bulunması için çalışmışlardır. Üfleme sonundaki alev görüntüleri toplanıp, üfleme sonunu belirleyen 3 deęer olarak ele alınan karbon (C) , fosfor (P) ve sıcaklık (T) bilgileri ile ilişki kuran bir model geliřtirilmiş ve modelin üfleme durumunu hızlıca bulabildiği sonucuna varmışlardır.

He ve Zhang (2018) [49] yaptıkları çalışmada BOF metalürjik işleminde ve üretim verisi ile PCA (Principal Component Analysis) ve geri yayılım (BP) yapay sinir ağı kullanarak üfleme sonu (end-point) fosfor miktarının tahmini için bir model

önermişlerdir. PCA giriş değerleri arasındaki ilişkileri inceleyerek girdilerin çok boyutluluğunu azaltıp gerçek ana girdileri bulup onları kullanarak sinir ağının beslenmesini sağlamak için kullanılan bir yöntemdir. PCA-BP sinir ağı ile yapılan çalışma aynı verilerle oluşturulan MLR (multiple lineer regresyon) ve BP sinir ağı sonuçları ile kıyaslanarak PCA-BP ağının en yüksek yakalama oranına sahip olduğunu göstermişlerdir. Bu geliştirilen PCA_BP sinir ağı ile yazılım geliştirilmiş ve gerçek saha değerleri ile fosfor tahmininde $|\Delta P| \leq 0,004$ hata farkı aralığında %86,67 hedef yakalama oranı (hitting rate) , $|\Delta P| \leq 0,005$ hata farkı aralığında %93,3 hedef yakalama oranı (hitting rate) yakalamışlardır.

BÖLÜM 3. MATERYAL VE YÖNTEM

3.1. Kullanılan Veriler ve Filtreleme

BOF çelik üretim sürecinde çeliğin müşterinin siparişine uygunluğu her adımda takip edilmeye çalışılmaktadır. Yüksek fırından itibaren üretilen pik demirin ve BOF'tan işlem sonrası çıkıp ikincil Metalürji istasyonlarına giden çeliğin her aşamada işletme mühendis ve operatörlerinin dökümün durumunu, istasyonlarda örnek olarak Kükürt Giderme İstasyonunda hangi malzemeler hangi miktarda atılarak hangi kükürt (S) miktarına indirildiğini, alınmışsa numune analiz sonuçlarını ve sıcak maden tonaj bilgilerini, Erdemir'de kullanılan otomasyon yapısı içinde ilgili tesisin Seviye 1 PLC veya DCS sistemlerinden, laboratuvar sisteminden ve diğer tesislerin Seviye 2 sistemlerinden otomatik olarak, Seviye 2 otomasyon sistemi üzerinde çalışan ayrı programlar sayesinde alınarak, Seviye 2 izleme ekranlarında anlık izlenebilmektedir. Bu anlık veriler Seviye 2 üzerinde veri tabanlarında biriktirilip uzun süreli saklanmak üzere üst otomasyon katmanı olan Seviye 3 sistemine oradan da siparişlerle üretilen ürünlerin denkliliğine bakılan Seviye 4 sistemine aktarılır.

Konvertörler de de üretilecek çelik için üretim planlamanın ve o anda sürekli dökümlerin durumuna göre karar verilmekte ve Seviye 2 üzerindeki üretim planından seçim yapılmaktadır. Döküm BOF ta ilk oluşturulurken Yüksek Fırından çıkan ve torpedo denilen içi sıcak madenin 1400 °C civarındaki sıcaklığına dayanıklı özel refrakter kaplı taşıyıcılarla taşınarak kükürt giderme istasyonunda işleme alınır. Bu tesiste üretim planındaki ürünlerin kalitesine göre önceden belirlenen ve Seviye 2 siteminde görülen S seviyesine göre yapılan işlem sonunda BOF ta işleme alınacak çeliğin ilk girdileri olan sıcak maden numunesi alınır ve analiz sonuçlarıyla girdi olacak sıcak maden kompozisyonu elimizde olur. İstenen torpidodaki analize ve

istenen plan siparişe göre hurda miktarı hurda sahasında hazırlanır ve BOF ta işlem başında hem sıcak maden hem de Hurda hazırlanmış olur. Konvertörde 2. Bölüm de anlatılan sıcak maden saflaştırma işlemleri oksijen üflenerek ve kompozisyon dengesi için flux malzemeleri atılarak tamamlanır. Ortalama 15 dk. süren üfleminin yaklaşık %80'inde TSC numunesi ve sonunda da TSO numunesi alınır. Bu sonuçların alındıkları andan itibaren Seviye 2 sisteminde görünmeleri 5-10 dk. arası değişmektedir. Bu süreçlerde yapılan manuel işlem veya malzeme şarjları da operatör tarafından elle Seviye 2 sistemine girilmektedir.

Sonuç itibariyle otomasyon sisteminde ilgili döküme ait kükürt giderme istasyonunda ve BOF tesisinde yapılan bütün işlem hareketlerinin ve numune laboratuvar sonuçlarının verisi mevcuttur.

Araştırma konusu olan Fosfor ve Karbon elementleri tahmini için işletme mühendisleri ile çalışma yapılmış ve bu çalışmanın sonucunda yapay sinir ağının verimli çalışması için hem hangi verilen gerekli olduğuna hem de bu verilerin olması gereken değer aralıklarına karar verilmiştir.

Bu çalışmalar sonucunda, Yapay Sinir Ağları ile çalışma yapılması sırasında daha sağlıklı bir veri uzayı sağlayacağına tesisteki çalışma şartlarına bağlı saha ve metalürjik tecrübe ile:

- Tek bir konvertöre ait veriler kullanılması ve böylece tesisler arası farklılıkların YSA sistemini etkilemesinin önüne geçilmesine,
- BOF işleminde homojenliği sağlama açısından önemi büyük olan alttan karıştırmanın verimli çalıştığı dönemde üretilen dökümlerin seçilmesi. Bunun içinde alttan karıştırmanın etkinliğini gösteren üfleme sonu numune sonucundaki C ve O değerlerinin çarpımı olan C*O değerinin 16-22 arası olanların alınmasına,
- Sıcak maden tonajı 100-110 ton olan dökümlerin alınmasına,
- Sıcak maden S değeri 0,007 – 0,015 arası olanların alınmasına,
- Sıcak maden C değerinin 3,8 – 4,3 arası olan dökümlerin alınmasına,
- Sıcak maden P değerinin 0,07 – 0,12 arası olan dökümlerin alınmasına,

- Sıcak maden Si değerinin 0,4 – 0,7 arası olan dökümlerin alınmasına,
- Hurda şarj miktarı 20-28 ton arası olan dökümlerin alınmasına,
- Üfleme sonu O₂ değerinin 300-1200 ppm arası olan dökümlerin alınmasına,
- TSC numunesinde C değerinin 0,15 – 0,6 arası olan dökümlerin alınmasına,
- TSO numunesinde C değerinin 0,025 – 0,07 arası olan dökümlerin alınmasına,
- Kalite bilgisinin kalite gruplarına bağlı yapılan işletme pratiklerinin YSA tarafından öğrenilmesinin sağlanması için veri listesinde olması gerektiğine,
- TSC ve TSO anlarında toplam üflene oksijen miktarının veri listesinde olması gerektiğine,
- TSC karbon ve fosfor tahmini YSA'larında girdi olarak: Sıcak maden numune analizlerindeki C, P, Mn, Si, S değerlerinin, kalite bilgisinin, sıcak maden ağırlığının, hurda miktarının ve TSC probu dalması ile kesilen o andaki toplam oksijen miktarlarının bahsi geçen kalemlerin hem karbon hem de fosfor dengesinde etkin olmalarından dolayı kullanılmasına. Ancak kullanılan fluxlardan Demir Cevheri, Antrasit(ısıtma) , Yanmış Kireç ve Dolomitik Kireç miktarlarının TSC anındaki miktarlarının Seviye 2 sisteminden üst raporlama sistemine çıkartılmadığı için bulunamayacaklarından dolayı kullanılmamalarına,
- TSC karbon ve fosfor tahmini YSA larının çıktısı olarak ta TSC probu ile üfleme içi (üflemenin yaklaşık %80) alınan numunelerinin karbon ve fosfor değerlerinin kullanılmasına,
- TSO karbon ve fosfor tahmini YSA'larında girdi olarak: Sıcak maden ve TSC probu ile alınan numune analizlerindeki C, P, Mn, Si, S değerlerinin, kalite bilgisinin, sıcak maden ağırlığının, hurda miktarının ve üfleme sonu toplam oksijen miktarlarının bahsi geçen kalemlerin hem karbon hem de fosfor dengesinde etkin olmalarından dolayı kullanılmasına. Üfleme sonu itibariyle atılan tüm fluxlardan C ve P sürecinde etkin olan Demir Cevheri, Antrasit(ısıtma) , Yanmış Kireç ve Dolomitik Kireç miktarlarının kullanılmasına,
- TSC karbon ve fosfor tahmini YSA larının çıktısı olarak ta TSO probu ile alınan üfleme sonu numunelerinin karbon ve fosfor değerlerinin kullanılmasına,

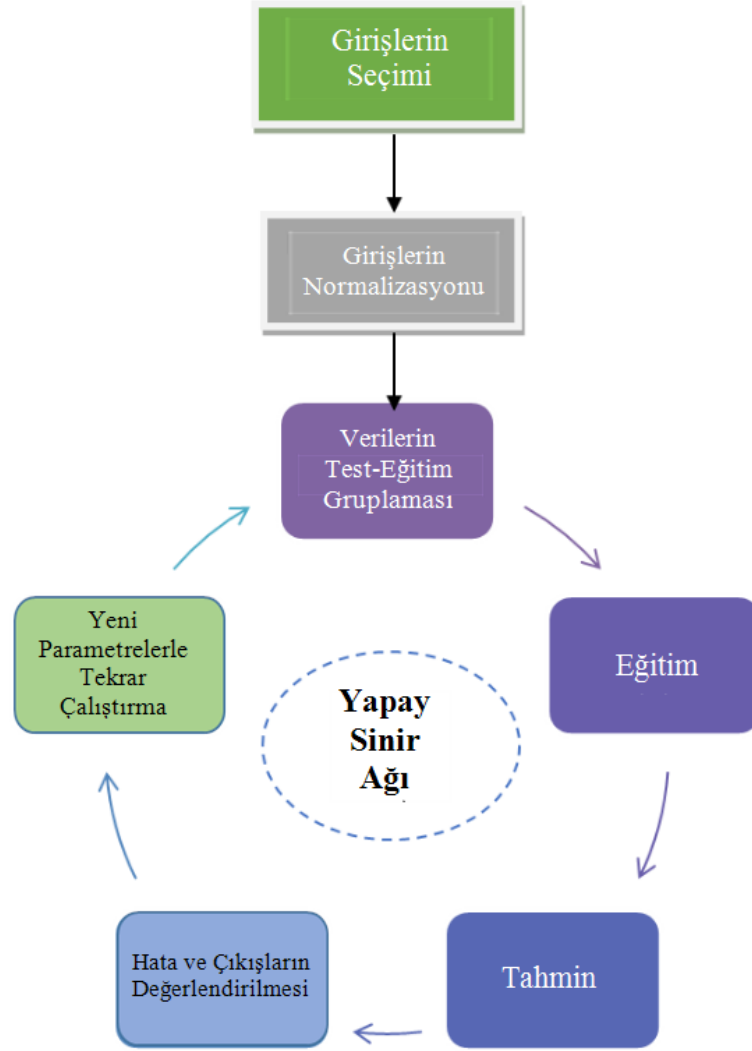
karar alınmıştır.

Dönemsel seçilen dökümler arasında yukarıdaki seçim kriterleri uygulanarak veri uzayı 720 ayrı döküm indirgenmiştir. Bulunan 720 dökümün 109 farklı kaliteye sahip olduğu görülmüştür bu da veri uzayının YSA'nın geniş bir kalite yelpazesini öğrenebileceği anlamına gelmektedir.

3.1.1. Yöntem

İstenen TSO ve TSC anlarındaki karbon ve fosfor elementlerinin içerik tahminini yapacak yapay sinir ağı için Şekil 3.1.'de gösterilen ANN WorkFlow olarak ta bilinen yapay sinir ağı iş akışı yöntem olarak kullanılmıştır.

Bu yöntemde önce girişlerin ne olacağı seçilir, arkasından seçilen girişler sinir ağının daha hızlı ve verimli çalışması için seçilen bir normalizasyon yöntemi ile belirlenen çalışma aralığına indirgenir. Sistemi oluşturacak olan veri girişlerinin içinden hangi değerlerin testte hangi değerlerin öğrenme aşamasında kullanılacakları bir metotla ya da doğrudan ayırıştırma ile seçilir. Seçilen veriler YSA da kullanım için düşünülen eğitim algoritmasının parametrelerinin ayarlanması sonucu eğitilir ve sonuçta ortaya istenen bir konuya genelleme yapabilecek bir yapay sinir ağı ortaya çıkmış olur. Ortaya çıkan yapay sinir ağı modeli test setler ile simüle edilir. Simülasyon sonuçları incelenip hata oranları ortaya çıkarılır eğer gerekli görünüyorsa yapay sinir ağı öğrenme algoritması parametreleri güncellenir ve sistem döngü adımları izlenerek bir daha çalıştırılır. Hata payı istenen düzeye inene kadar işlemler tekrarlanır.



Şekil 3.1. Yapay sinir ağının iş akış gösterimi.

Makine öğrenmesinin birçok alt dalında olduğu gibi Yapay Sinir Ağları çalışmalarında da seçilen networkteki kullanılan node sayısı arttıkça hesaplar yapılması ve dokümanite edilmesi imkânsız hale gelmektedir bu aşamada birçok yardımcı program kullanılmaktadır.

Bu amaçla kullanılan programlardan bir olan MATLAB in R2014a sürümü ile gelen Sinirsel Ağ Deneme Aracı - Neural Network Tool (nntool), BP eğitim algoritmasının birçok değişik varyasyonunu destekleyen ileri beslemeli sinirsel ağların yazılım içinde fonksiyonlarla da kullanımını oldukça kolaylaştıran bir araçtır.

Bu bilgiler ışığında bu çalışmada, kullanım kolaylığı, modelleme işleminden önce ve sonra sağladığı veri işleme olanakları nedeni ile Excel programıyla beraber Matlab programında çalıştırılmak üzere konuya özel kod parçaları yazılarak nntoolbox'ın sahip olduğu fonksiyonlar kullanılmıştır.

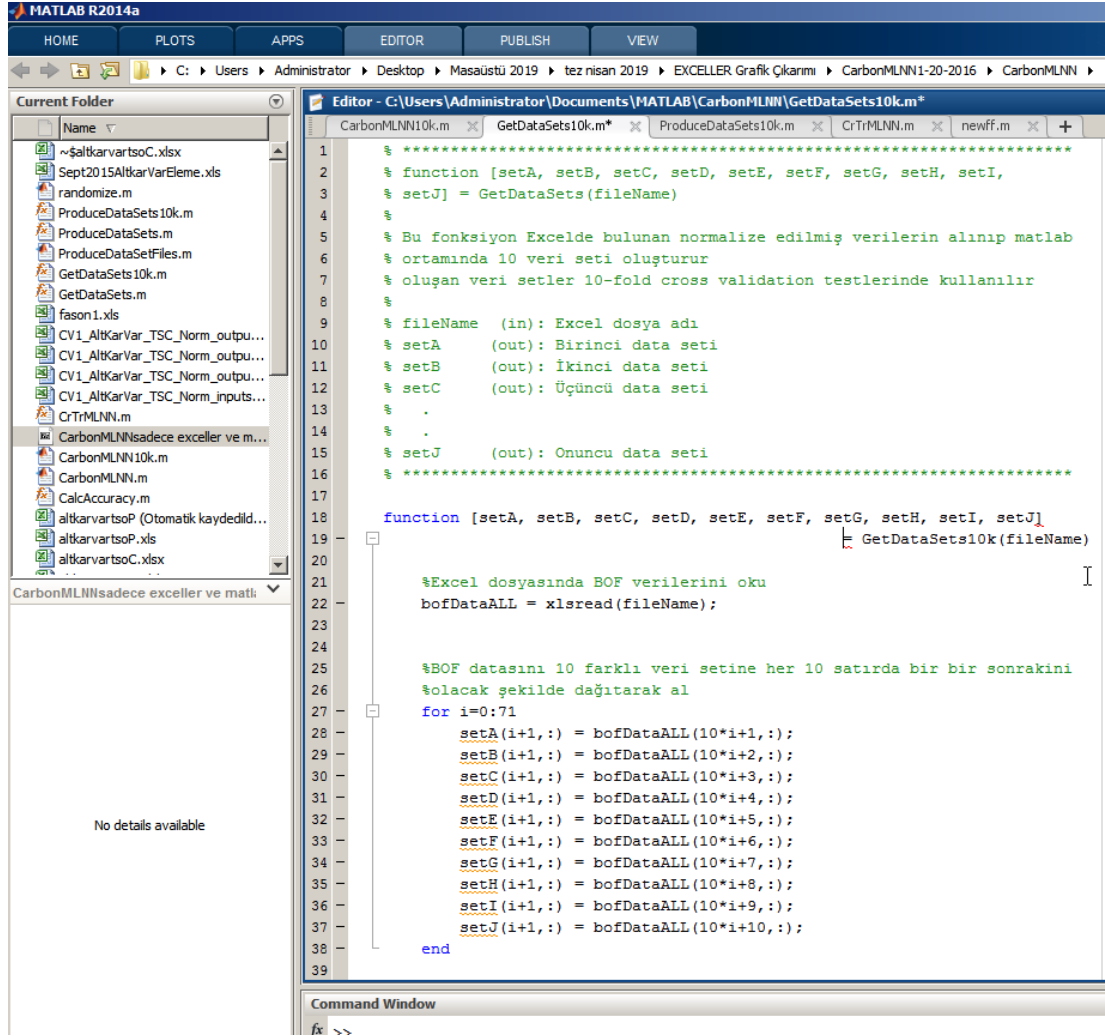
3.1.2. Verilerin normalizasyonu

Kullanılacak model için seçilen veriler uzayında çok farklı tipte ve boyutta olan verilerin öğrenme aşamasında ve hesap aşamasında daha rahat çalışıp lokal minimum noktasında takılma ihtimalinin azaltılması için giriş değerlerinin ve çıkış değerlerinin hepsi Min-Max normalizasyon kuralına göre normalize edilmişlerdir. Bu kural tanımındaki Denklem 2.7 de verilmiştir. Bu çalışmada kullanılan normalizasyonda aralık değeri olarak $[Rmin Rmax] = [0,01 0,97]$ alınmıştır.

Normalizasyon işlemleri Excel dosyasında tutulmakta olan bilgilerin üzerinde Excel'in formülleri kullanılarak yapılmıştır. Daha sonra yeni oluşan bu Excel verileri Matlab'deki fonksiyonların kullanabilmesi için sadece Matlab'de kullanılabilen kaynak kod yazılımı yapılmıştır.

3.1.3. 10-k cross validation

Bu tezin çalışmasında da verilerin homojen dağılımının sağlanması için k-fold cross validation tekniğindeki veri dağılımı kullanılmıştır. Bu tekniğin Matlab ortamına aktarımı için özel bir yazılım parçası hazırlanmıştır. Bu parça kod bütün sinir ağının oluşturulduğu ana kod parçasından istendiğinde çağırılmak için yazılmıştır. Kodun Matlab görünümü ve text dosya okuyucu ile daha büyük görünümü alttaki Şekil 3.2.'de verilmiştir.



Şekil 3.2. Veri setinin 10 folda bölünmesini sağlaması için yazılan Matlab kodu.

3.1.4. YSA'nın ağ yapısı ve eğitim parametreleri

Literatür çalışmalarından da görüleceği üzere birçok hesaplama yöntemleri ile çözüm bulunması zor sisteme YSA ile çözüm bulunabilmektedir. Ancak gene görüleceği üzere bu çözüm aşamasında hangi soruna hangi YSA'nın ya da hangi YSA'da hangi öğrenme algoritmasının ve hangi transfer fonksiyonunun kullanılması gerektiğini ortaya koyan kesin bir bilgi yoktur. Araştırmacılar yayınlarında kendi sistemlerini ve sorunlarını anlatarak olası benzer durumda olan kişileri yol göstermektedirler.

Literatürdeki benzer çalışmalardan farklı olarak bu çalışmada geri yayılım çok katmanlı yapay sinir ağı sisteminde öğrenme algoritması olarak hem BP'nin standart algoritmasını iyileştiren LM algoritmasına benzeyen hem de ondan daha hızlı olduğu

belirtilen SCG (Scaled Conjugate Gradient), Matlab’de `Trainscg` olarak gösterilen, öğrenme algoritması seçilmiştir. Transfer fonksiyonları içinse girdilerimizin çıktılarıyla ve birbirleri ile indirgeme reaksiyonlarında etkisi ile nispeten lineer ilişki içinde olduğu düşünülerek Purelin transfer fonksiyonu ile çalışılmıştır.

`Trainscg` Matlab SCG algoritmasının bu çalışmada kullanılan 4 adet parametresi vardır ve bunlar Tablo 3.1.’de verilmiştir.

Tablo3.1. `Trainscg` Matlab algoritması parametreleri

Parametre	Açıklama
<code>trainParam.min_grad</code>	Minimum performans gradyanı
<code>trainParam.epochs</code>	Maximum devir sayısı
<code>trainParam.sigma</code>	İkinci türev yaklaşımı için ağırlıktaki değişim
<code>trainParam.lambda</code>	Hessian belirsizliğini düzenleme parametresi

Bu seçimlerin kullanımı için Matlab programında geri yayılım yapay sinir ağını (BPMLNN) oluşturan *newff* fonksiyonu ve öğrenme algoritması olarak Scaled Conjugate Gradient in Matlab karşılığı olan `Trainscg` kullanılmıştır. Yapıyı oluşturan yazılım kodları aşağıdaki Şekil 3.3.’te YSA’nın katman bilgisinin girildiği, hangi Excel dosyasındaki normalize verilerinin kullanılacağına seçileceği ana rutin `CarbonMlnn10k.m` gösterilmiştir.

```

1 % Following codes make 10-fold cross validation tests to a multi layer
2 % feed-forward backpropagation neural network (MLNN)
3
4 clear all
5 %Determine number of neurons in layers. Use zero for unused layers.
6 N = [50 50 30 0 0];
7
8 %Load BOF data (all normalized values)
9 BOFDataFile = 'AltKarvarMalzemesizTscP2016.xls'; %'altkarvarTscP.xls'; % 'AltKarvarMalzemesizTscP.xls'; %'altkarvar
10 %Create set A, B to J 10 data set
11 [ntDataSetA,ntDataSetB,ntDataSetC,ntDataSetD,ntDataSetE,ntDataSetF,ntDataSetG,ntDataSetH,ntDataSetI,ntDataSetJ] =
12 GetDataSets10k(BOFDataFile);
13
14 % 1st calculation out of 10
15 %Calculate normalized input and normalized target values
16 %Use set A to I for train and set J for test. 10th parameter is always the test set.
17 % [pTrainSetBC,npTrainSetBC,tTrainSetBC,pTestSetA,npTestSetA,tTestSetA] = ...
18 [npTrainSetAll1,ntTrainSetAll1,npTestSetJ,ntTestSetJ] = ...
19 ProduceDataSets10k(ntDataSetA,ntDataSetB,ntDataSetC,ntDataSetD,ntDataSetE,ntDataSetF,ntDataSetG,ntDataSetH,ntDat
20 ntDataSetI,ntDataSetJ);
21 net1 = CrTrMLNN(N, npTrainSetAll1, ntTrainSetAll1);
22 SimtTestSetJ = sim(net1, npTestSetJ);
23
24 SimTestSets= [ transpose(SimtTestSetJ) ];
25 TestSets = [ transpose( ntTestSetJ)];
26
27
28 % 2nd calculation out of 10
29 %Calculate normalized input and normalized target values
30 %Use set A to J for train and set I for test. 10th parameter is always the test set.
31 % [pTrainSetBC,npTrainSetBC,tTrainSetBC,pTestSetA,npTestSetA,tTestSetA] = ...
32 [npTrainSetAll2,ntTrainSetAll2,npTestSetI,ntTestSetI] = ...
33 ProduceDataSets10k(ntDataSetA,ntDataSetB,ntDataSetC,ntDataSetD,ntDataSetE,ntDataSetF,ntDataSetG,ntDataSetH,ntDat
34 net2 = CrTrMLNN(N, npTrainSetAll2, ntTrainSetAll2);
35 SimtTestSetI = sim(net2, npTestSetI);
36
37 SimTestSets= [SimTestSets ; transpose(SimtTestSetI) ];
38 TestSets = [TestSets ; transpose( ntTestSetI)];

```

Şekil 3.3. Bu çalışma için yapılmış YSA yazılımının ana kodu.

Ana rutinin içinden ilk çağrılınca Cross Validation yöntemi ile verilerin 10 gruba ayıran rutin GetDataSets10k.m Şekil 3.2.'de gösterilmiştir. Sonraki rutin ProduceDataSets10k.m bu ayrılmış normalize veri setlerini Şekil 3.4.'te görüleceği üzere girdi sayısına göre eğitim ve test gruplarına bölmektedir, böylece ana rutin içinde cross validation uyarınca her sınır ağında farklı eğitim ve test kümeleri kullanılacaktır.

```

1  % *****
2  % function [pTrainSet,npTrainSet,tTrainSet,pTestSet,npTestSet,tTestSet]=...
3  %   ProduceDataSets(dataSet1,dataSet2,dataSet3)
4  %
5  % This fuction creates training data set by adding first to nine sets
6  % and uses the tenth set as test set. Produce normalized input and target
7  % values both for train and test sets
8  %
9  % dataSet1   (in): First data set
10 % dataSet2   (in): Second data set
11 % dataSet3   (in): Third data set
12 % .
13 % .
14 % dataSet10  (in): Tenth data set
15 % pTrainSet  (out): Input of train set
16 % tTrainSet  (out): Target of train set
17 % pTestSet   (out): Input of test set
18 % tTestSet   (out): Target of test set
19 %
20 % *****
21
22 function [pTrainSet,tTrainSet,pTestSet,tTestSet] = ...
23   ProduceDataSets10k(dataSet1,dataSet2,dataSet3,dataSet4,dataSet5,dataSet6,dataSet7,dataSet8,dataSet9,dataSet10)
24
25 %Create training data set by adding first and second sets
26 dataSet1to9 = [dataSet1; dataSet2; dataSet3; dataSet4; dataSet5; dataSet6; dataSet7; dataSet8; dataSet9];
27
28 %Get input and target matrixes for training set TSC 'AltKarvarMalzemesizTsc.xls'
29 pTrainSet = (dataSet1to9(:, 1:8))';
30 tTrainSet = (dataSet1to9(:, 9:9))';
31
32 %Get input and target matrixes for test set
33 pTestSet = (dataSet10(:, 1:8))';
34 tTestSet = (dataSet10(:, 9:9))';
35
36 % %Get input and target matrixes for training set TSO 'altkarvarso.xls'
37 % pTrainSet = (dataSet1to9(:, 1:17))';
38 % tTrainSet = (dataSet1to9(:, 18:18))';
39 %

```

Şekil 3.4. 10 farklı kümeye bölünmüş normalize verilerin sıra ile eğitim ve test seti haline getirildiği kod parçası.

Şekil 3.5.'te ise oluşturulmuş eğitim setleri ile çalıştırılacak sinir ağını oluşturan rutin olan CrTrMLNN.m yazılım kod parçası görünmektedir. Bu kod parçası içinde *newff* fonksiyonu ile oluşturulacak ağıın öğrenme fonksiyonu olan *train* 'in parametreleri gösterilmektedir. Bu fonksiyon her bir YSA için yeniden ayarlanabilmekte ve tekrar çalıştırılmaktadır.


```

1  % *****
2  % function mlnnNet = CrTrMLNN(N, np, t)
3  %
4  % This fuction creates and trains a multi layer feed-forward
5  % backpropagation neural network (MLNN)
6  %
7  % N      (in): Number of neurons in each layer (max. 5 layers)
8  % np     (in): Matrix for normalized input vectors
9  % t      (in): Matrix for output vectors
10 % mlnnNet (out): Trained MLNN
11 %
12 % *****
13
14 function mlnnNet = CrTrMLNN(N, np, t)
15
16     %Choose activation function
17     tF = 'purelin';
18     %Choose training function
19     trainF = 'trainscg';
20     %Determine training parameters
21     minGrad = 10^-30;
22     sigma = 5.0000e-005; %Change in weight for second derivative appr.
23     lambda = 5.0e-5;    %Parameter for regulating the indef.of the Hessian
24
25     %Get layer data
26     nLayer = 0;
27     for i=1:5
28         if N(i) > 0
29             nLayer = nLayer + 1;
30         end
31     end
32     S = N(1:nLayer);
33
34     %Create MLNN
35     switch nLayer
36     case 1
37         mlnnNet=newff(minmax(np), [S 1], {tF,tF}, trainF);
38     case 2
39         mlnnNet=newff(minmax(np), [S 1], {tF,tF,tF}, trainF);
40     case 3
41         mlnnNet=newff(minmax(np), [S 1], {tF,tF,tF,tF}, trainF);
42     case 4
43         mlnnNet=newff(minmax(np), [S 1], {tF,tF,tF,tF,tF}, trainF);
44     case 5
45         mlnnNet=newff(minmax(np), [S 1], {tF,tF,tF,tF,tF,tF}, trainF);
46     end
47
48     %Set training parameters
49     mlnnNet.trainParam.epochs=30000; %tsc 15000 %tso 25000
50     mlnnNet.trainParam.min_grad = minGrad;
51     mlnnNet.trainParam.sigma = sigma;
52     mlnnNet.trainParam.lambda = lambda;
53
54     %Make training
55     mlnnNet = train(mlnnNet, np, t);
56

```

Şekil 3.5. Öğrenme algoritmasının ayarlandığı yazılım örneği.


Bu çalışma kapsamında TSC anı Karbon tahmini, TSC anı Fosfor tahmini, TSO anı karbon tahmini ve TSO anı fosfor tahmini olarak 4 farklı YSA modeli oluşturulmaya çalışılmıştır. Modellerin detay bilgileri aşağıda verilmiştir. Bu çalışma sonrasında deneysel çalışmaların yazılıma dökülmesi ve gerçek ortamda çalışması ihtimaline

karşılık yazılım kolaylığı sağlaması açısından değişken ve öğrenim parametreleri birbirine yakın tutulmaya çalışılmıştır.

3.1.4.1. TSC karbon modeli verileri ve model özellikleri

TSC anındaki karbonu tahmin etmek için tasarımlanan YSA modelinin girdileri: Sıcak maden numune analizlerindeki C, P, Mn, Si, S değerlerinin, kalite bilgisinin, sıcak maden ağırlığının, hurda miktarının ve TSC probu dalması ile kesilen o andaki toplam oksijen miktarı olacak şekilde 9 değişkendir. Çıktısı da TSC numunesi sonucu olan karbon laboratuvar analiz değeri olmak üzere bir tanedir.

Ara gizli katmanlar ilk gizli katman 50 nöron nodu, ikinci gizli katman 50 nöron nodu ve son gizli katmanda 50 nöron olacak şekilde 3 gizli katmandan oluşmaktadır, Şekil 3.6. genel görünümünü vermektedir.



Şekil 3.6. TSC (üfleme içi) karbon değeri YSA modeli.

Burada oluşturulan YSA da öğrenme algoritması TRAINSCG için kullanılan parametreler Tablo 3.2.'de verilmiştir. Transfer fonksiyonu olarak logsig kullanılmıştır.


Tablo 3.2. Trainscg için verilen parametre değerleri

Parametre	Değeri
trainParam.min_grad	10^{-30}
trainParam.epochs	20000
trainParam.sigma	5.0000e-005
trainParam.lambda	5.0e-5

3.1.4.2. TSC fosfor modeli verileri ve model özellikleri

TSC anındaki karbonu tahmin etmek için tasarımılanan YSA modelinin girdileri: Sıcak maden numune analizlerindeki C, P, Mn, Si, S değerlerinin, kalite bilgisinin, sıcak maden ağırlığının, hurda miktarının ve TSC probu dalması ile kesilen o andaki toplam oksijen miktarı olacak şekilde 9 değişkendir. Çıktısı da TSC numunesi sonucu olan fosfor laboratuvar analiz değeri olmak üzere birer tanedir.

Ara gizli katmanlar ilk gizli katman 50 nöron nodu, ikinci gizli katman 50 nöron nodu ve son gizli katmanda 30 nöron olacak şekilde 3 gizli katmandan oluşmaktadır, Şekil 3.7. genel ağ görünümünü vermektedir.



Şekil 3.7. TSC (üfleme içi) Fosfor değeri YSA modeli.

Burada oluşturulan YSA da öğrenme algoritması TRAINSCG için kullanılan parametreler Tablo 3.3.'te verilmiştir. Transfer fonksiyonu olarak Purelin kullanılmıştır.


Tablo 3.3. Trainscg için verilen parametre değerleri

Parametre	Değeri
trainParam.min_grad	10^{-30}
trainParam.epochs	15000
trainParam.sigma	$5.0000e-006$
trainParam.lambda	$5.0e-5$

3.1.4.3. TSO karbon modeli verileri ve model özellikleri

TSO anındaki karbonu tahmin etmek için tasarımılanan YSA modelinin girdileri TSC girdilerinden farklı olarak: Sıcak maden ve TSC probu ile alınan numune analizlerindeki C, P, Mn, Si, S değerlerinin, kalite bilgisinin, sıcak maden ağırlığının, hurda miktarının ve üfleme sonu toplam oksijen üfleme sonu itibariyle atılan tüm fluxlardan C ve P sürecinde etkin olan Demir Cevheri, Antrasit(ısıtma) , Yanmış Kireç ve Dolomitik Kireç toplam 18 değişkendir. Çıktısı da TSO numunesi sonucu olan karbon değeri olmak üzere bir tanedir.

Ara gizli katmanlar ilk gizli katman 50 nöron nodu, ikinci gizli katman 50 nöron nodu ve son gizli katmanda 50 nöron olacak şekilde 3 gizli katmandan oluşmaktadır, Şekil 3.8. ağıın genel görünümünü vermektedir.



Şekil 3.8. TSO (üfleme sonu) karbon değeri YSA modeli.

Burada oluşturulan YSA da öğrenme algoritması TRAINSCG için kullanılan parametreler Tablo 3.4.'te verilmiştir. Transfer fonksiyonu olarak Purelin kullanılmıştır.


Tablo 3.4. Trainscg için verilen parametre değerleri

Parametre	Değeri
trainParam.min_grad	10^{-30}
trainParam.sigma	5.0000e-006
trainParam.epochs	30000
trainParam.lambda	5.0e-5

3.1.4.4. TSO fosfor modeli verileri ve model özellikleri

TSO anındaki fosforu tahmin etmek için tasarımlanan YSA modelinin girdileri: Sıcak maden ve TSC probu ile alınan numune analizlerindeki C, P, Mn, Si, S değerlerinin, kalite bilgisinin, sıcak maden ağırlığının, hurda miktarının ve üfleme sonu toplam oksijen üfleme sonu itibariyle atılan tüm fluxlardan C ve P sürecinde etkin olan Demir Cevheri, Antrasit(ısıtma) , Yanmış Kireç ve Dolomitik Kireç olmak üzere toplam 18 değişkendir. Çıktısı da TSO numunesi sonucu olan karbon değeri olmak üzere bir tanedir.

Ara gizli katmanlar ilk gizli katman 50 nöron nodu, ikinci gizli katman 30 nöron nodu olacak şekilde 2 gizli katmandan oluşmaktadır (Şekil 3.9.).



Şekil 3.9. TSO (üfleme sonu) Fosfor değeri YSA modeli.

Burada oluşturulan YSA da öğrenme algoritması TRAINSCG için kullanılan parametreler Tablo 3.5.'te verilmiştir. Transfer fonksiyonu olarak Purelin kullanılmıştır.

Tablo 3.5. Trainscg için verilen parametre değerleri

Parametre	Değeri
trainParam.min_grad	10^{-30}
trainParam.sigma	5.0000e-006
trainParam.epochs	30000
trainParam.lambda	5.0e-5

BÖLÜM 4. ARAŞTIRMA BULGULARI

Matlab programı içinde her bir model için sırayla oluşturulan YSA öğrenim ve simülasyon işlemlerinden sonra ortaya çıkan sonuçlar bir Excel dosyası içine alınmış tekrar denormalize edilmiş ve ortaya çıkan 4 farklı YSA simülasyon ve gerçek sonuçların grafiksel kıyas sonuçları aşağıda sırasıyla: belirtilen hata aralıklarına giren örnek sayısı ve bu sayının hedef yakalama oranı (hitting rate) olarak gösterimi, 2.grafikler hata aralıklarının bu aralıktaki örnek sayısına göre histogram gösterimi ve en son olarak ta scatter plot grafiği ile gerçek ve simülasyon değerlerin ilişkisi gösterilmiştir.

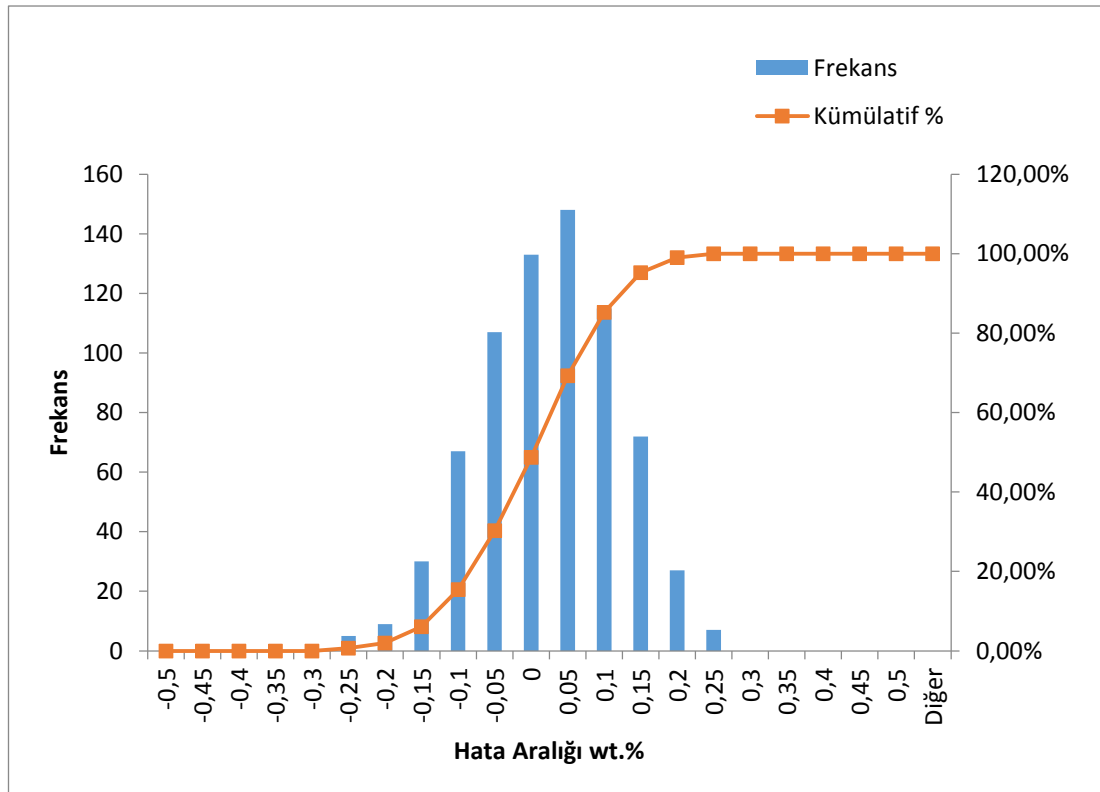
4.1. TSC karbon modeli sonuçları

720 adet döküme ait veri oluşturulan Matlab yazılımı ile TSC karbon modeli için, karbon çıkışları kullanılarak eğitilmiş ve sonrasında da test verileri ile simülasyon sonuçları alınmıştır.

Tablo 4.1.'de gerçek değer ile simülasyon birbirinden çıkartılıp bu hata aralığındaki oluşturulan listedeki fark gruplarına göre yakalama oranı (Hitting rate) listelenmiştir. Şekil 4.1. ve Şekil 4.2. TSC anındaki bilgilerle oluşturulan YSA ile yapılan simülasyon ve gerçek karbon değerlerinin grafiksel kıyas ve gösterimini içermektedir.


Tablo 4.1. TSC anı karbon simülasyon sonuçlarının yakalama oran ve aralıkları

Hata Aralığı	Aralıktaki Örnek Sayısı	Yakalama Oranı
±0,1	570	%79
±0,15	672	%93
±0,2	708	%98



Şekil 4.1. TSC karbon simülasyon gerçek değer farkı hata aralığı histogram gösterimi.

Şekil 4.1.'de Frekans ilgili hata aralığında kaç tane örnek olduğunu göstermektedir, kümülatif ise $x = -1$ den $x = +1$ e giderken hata aralıklarındaki örneklerin toplamının göstergesidir. Şekil 4.2.'de Y eğim fonksiyonunu, R^2 ise hatanın karesini göstermektedir.



Şekil 4.2. TSC anı Karbon gerçek ve simülasyon verilerinin scatter plot gösterimi.

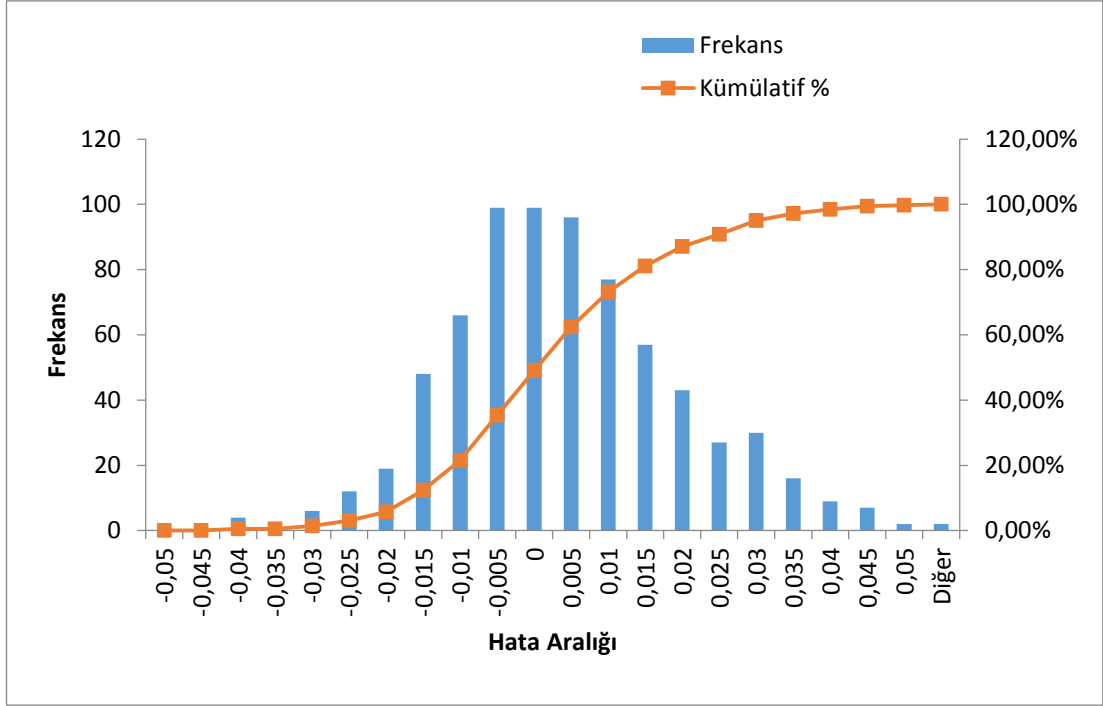
4.2. TSC fosfor modeli sonuçları

720 adet döküme ait veri oluşturulan Matlab yazılımı ile TSC fosfor modeli için fosfor çıkış değerleri ile eğitilmiş ve sonrasında da test verileri ile simülasyon sonuçları alınmıştır.

Tablo 4.2.'de gerçek değer ile simülasyon birbirinden çıkartılıp oluşturulan listedeki fark gruplarına göre yakalama oranı (Hitting rate) listelenmiştir. Şekil 4.3. ve Şekil 4.4. TSC anındaki bilgilerle oluşturulan YSA ile yapılan simülasyon ve gerçek fosfor değerlerinin grafiksel kıyas ve gösterimini içermektedir.


Tablo 4.2. TSC anı fosfor simülasyon sonuçlarının yakalama oran ve aralıkları

Hata Aralığı	Aralıktaki Örnek Sayısı	Yakalama Oranı
±0,015	542	%75,3
±0,02	604	%83,3
±0,025	643	%89,3



Şekil 4.3. TSC fosfor simülasyon gerçek değer farkı hata aralığı histogram gösterimi.

Şekil 4.3.'te Frekans ilgili hata aralığında kaç tane örnek olduğunu göstermektedir, kümülatif ise $x = -1$ den $x = +1$ e giderken hata aralıklarındaki örneklerin toplamının göstergesidir. Şekil 4.4.'te Y eğim fonksiyonunu, R^2 ise hatanın karesini göstermektedir.



Şekil 4.4. TSC anı fosfor gerçek ve simülasyon verilerinin scatter plot gösterimi.

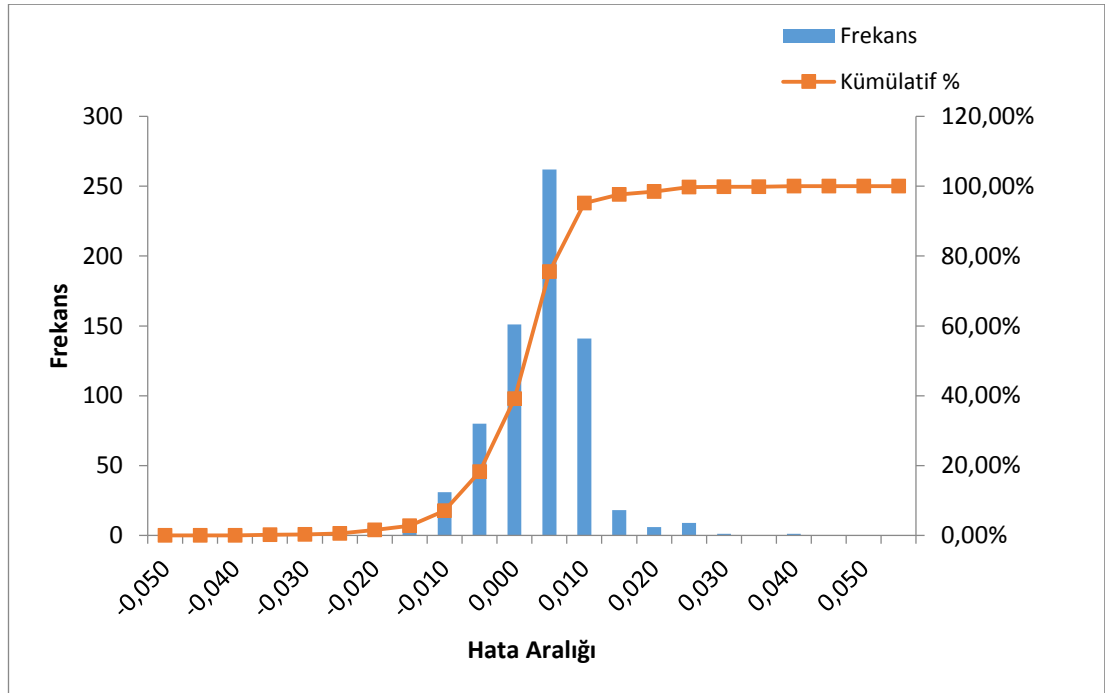
4.3. TSO karbon modeli sonuçları

720 adet döküme ait veri oluşturulan Matlab yazılımı ile TSO karbon modeli 18 giriş değeri ve karbon çıkış değerleri için eğitilmiş ve sonrasında da test verileri ile simülasyon sonuçları alınmıştır.

Tablo 4.3.'te gerçek değer ile simülasyon birbirinden çıkartılıp oluşturulan listedeki fark gruplarına göre yakalama oranı (Hitting rate) listelenmiştir. Şekil 4.5. ve Şekil 4.6. TSO probu anındaki bilgilerle oluşturulan YSA ile yapılan simülasyon ve gerçek karbon değerlerinin grafiksel kıyas ve gösterimini içermektedir.

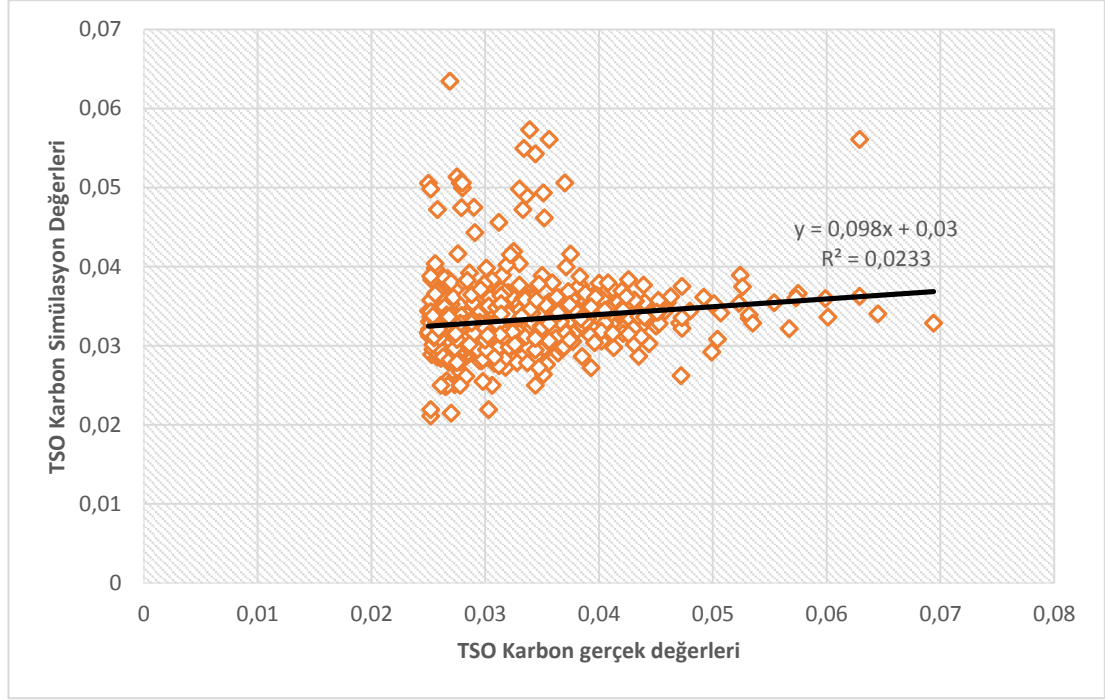
Tablo 4.3. TSO anı karbon simülasyon sonuçlarının yakalama oran ve aralıkları

Hata Aralığı	Aralıktaki Örnek Sayısı	Yakalama Oranı
$\pm 0,01$	665	% 92,36
$\pm 0,015$	692	%96,11
$\pm 0,020$	705	%97,92



Şekil 4.5. TSO karbon simülasyon gerçek değer farkı hata aralığı histogram gösterimi

Şekil 4.5.'te Frekans ilgili hata aralığında kaç tane örnek olduğunu göstermektedir, kümülatif is $x = -1$ den $x = +1$ e giderken hata aralıklarındaki örneklerin toplamını göstergesidir. Şekil 4.6.'da Y eğim fonksiyonunu, R^2 'de hatanın karesini göstermektedir.



Şekil 4.6. TSO anı karbon gerçek ve simülasyon verilerinin scatter plot gösterimi

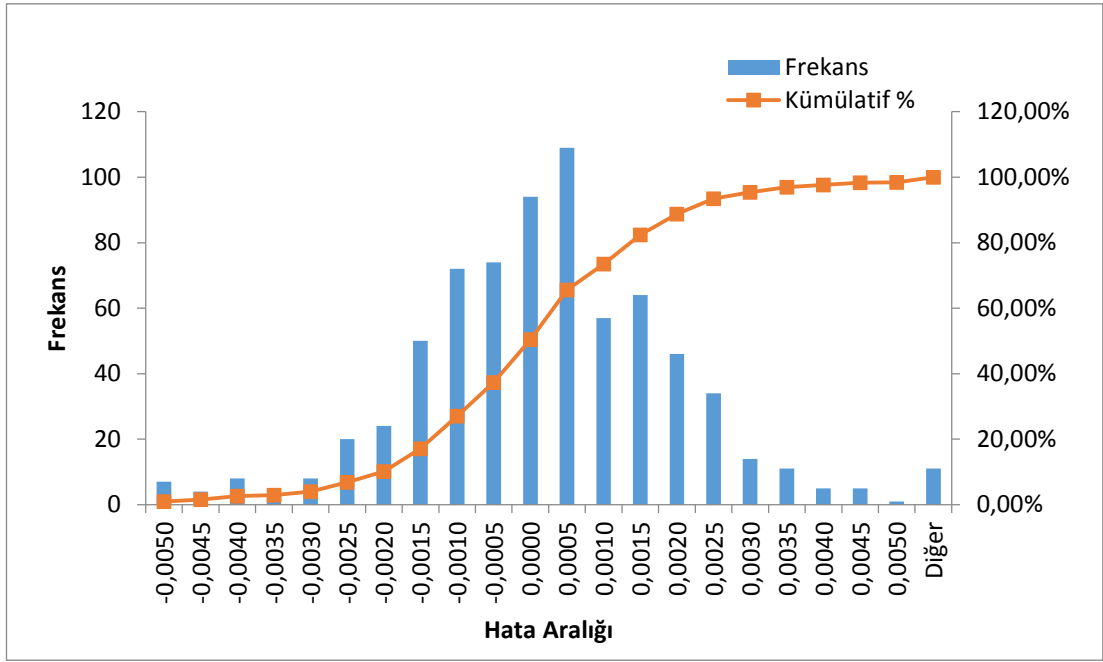
4.4. TSO fosfor modeli sonuçları

720 adet döküme ait veri oluşturulan Matlab yazılımı ile TSO Fosfor modeli için eğitilmiş ve sonrasında da test verileri ile simülasyon sonuçları alınmıştır.

Tablo 4.4.'te gerçek değer ile simülasyon birbirinden çıkartılıp oluşturulan listedeki fark gruplarına göre yakalama oranı (Hitting rate) listelenmiştir. Şekil 4.7. ve Şekil 4.8. TSO probu anındaki bilgilerle oluşturulan YSA ile yapılan simülasyon ve gerçek fosfor değerlerinin grafiksel kıyas ve gösterimini içermektedir.


Tablo 4.4. TSO anı fosfor simülasyon sonuçlarının yakalama oran ve aralıkları

Hata Aralığı	Aralıktaki Örnek Sayısı	Yakalama Oranı
$\pm 0,015$	520	%72,2
$\pm 0,002$	590	%81,9
$\pm 0,0025$	644	%89,4



Şekil 4.7. TSO fosfor simülasyon gerçek değer farkı hata aralığı histogram gösterimi.

Şekil 4.7.'de Frekans ilgili hata aralığında kaç tane örnek olduğunu göstermektedir, kümülatif is $x = -1$ den $x = +1$ e giderken hata aralıklarındaki örneklerin toplamını göstergesidir. Şekil 4.8.'de Y eğim fonksiyonunu, R^2 'de hatanın karesini göstermektedir.



Şekil 4.8. TSO anı karbon gerçek ve simülasyon verilerinin scatter plot gösterimi

BÖLÜM 5. TARTIŞMA VE SONUÇ

Bu tez çalışmasında BOF tesisinin ve tüm çelikhanenin üretim hızını arttırabilecek, sıcak madenin kalitesini çok etkileyen karbon ve fosforun üfleme içi (TSC) ve üfleme sonu (TSO) anlarında değerlerini tahmin etmek üzere 720 örnekle 4 farklı YSA modeli üzerinde çalışılmıştır.

LD tipi bir Bazik Oksijen Fırınında ürünün, tesisteki hayatında iki kritik nokta olarak görülen oksijen üfleminin %80'inde yapılan üfleme içi ölçüm anı olan TSC probu ile ölçüm yapıldığı için TSC anı diyebileceğimiz anda alınan numune ve üfleme sonu denilen BOF'taki işlemin bitirildiği andaki TSO probuyla alınan numune laboratuvar sonuçları ürünün müşterinin talebine uygunluğunu gösteren resmi karnesi gibidir. Ancak her numune alındıktan ancak 5-10 dk. arasında sonuç bilgisi gelmektedir.

Bu analizlerin sonuçları dökümün plandan sapma yapıp yapmadığına yani zarara ya da çelik kompozisyonunun istenilen limitlere gelmesi için gereken malzeme ve tekrar üfleme durumlarını belirlemektedir. Sürecin üretimi hızının artması için üretimin bu analiz değerlerini beklemeden ilerlemesi gerekmektedir.

Çalışmamızda TSO anı için olan YSA üretim süreci içinde TSC analiz sonucu geldiği anda TSO analizini beklemeden $\pm 0,0025$ hata aralığında %89 tutarlılıkla fosfor değerini ve $\pm 0,01$ hata aralığında %92 tutarlılıkla karbon değerini operatöre bildirerek ihtiyaç duyulan tekrar üfleme veya işlem sonu kararlarının alınmasında yönlendirici olarak verimi arttırabilir.

TSC anı için olan çalışmamız ise girdi olarak Sıcak maden numune analizlerindeki C, P, Mn, Si, S değerlerinin, seçilecek kalite bilgisinin, sıcak maden ağırlığının, hurda miktarının ve TSC probu dalması ile kesilen o andaki toplam oksijen miktarı olacak

şekilde 9 deęişken kullanmaktadır. YSA alıřmaları da $\pm 0,02$ hata aralıęında %83 tutarlılıkla fosfor, $\pm 0,015$ hata aralıęında %96 tutarlılıkla karbon deęeri tahmini yapmıřtır. Üfleme sonu sıcaklık ve karbon tahmini deęeri için Seviye 2 otomasyon yazılımı yapan bir firmanın örnek performans teklifi Şekil 5.1.'de görölmektedir, bu teklifte farklı karbon limitlerinde $\pm 0,015$ ve $\pm 0,02$ yakınsama oranları için %85 hitting rate şeklindedir.

Göröleceęi üzere konvertör tesisinde yeni bir döküm için ilk atamalar yapılırken kullanılan deęerlerden farklı olarak sadece üfleneni oksijeni deęerinin bilinmedięi bir denklem karřımıza ıkıyor. Sonuç olarak konvertörde ilgili plana yani kaliteye sıcak maden seçildięinde hurda miktarını ve yaklaşık üflenecek oksijen miktarını operatör elle girdięi bir sistemde bu model daha dökümün bařında TSC anındaki karbon ve fosforu tahmin edebilecektir. Ya da üflemenin, örnek olarak %70 inden sonra sürekli otomatik alıřtırılarak operatöre anlık sonuç verecek bir modele evrilebilir.

alıřılan 4 YSA'da literatürdeki benzer alıřmalardan farklı olarak Scaled Conjugate Gradient (SCG) öęrenme algoritması kullanılarak yapılmıř ve bu öęrenme algoritmasının da konvertörlerde karbon ve fosfor tahminleme sorunlarına özüm verebildięi görölmüřtür. İleri alıřma olarak daha bařarılı bir sonuç arařtırması için aynı veri seti üzerinde dięer öęrenme algoritmaları, kümeleme metotları denenebilir.



8.4.2 Hitting Ratio for subblance operation

BOF operation	Carbon Range Group	Number of Tests	Guarantees		
			Parameter	Target Window	Hitting Ratio [%]
The hitting rates below are based on successful subblance measurement (T,C), bottom stirring and L2 operation		60 heats in total			
Group specific	C _{end} ≥ 0.020% to C _{end} < 0.050% (Group 1)	20 heats	C	± 0.015 %	85
			T	± 14 °C	85
	C _{end} ≥ 0.050% to C _{end} < 0.070% (Group 2)	20 heats	C	± 0.020 %	85
			T	± 14 °C	85
	C _{end} ≥ 0.070% to C _{end} < 0.100% (Group 3)	20 heats	C	± 0.025 %	80
			T	± 14 °C	80

Deviation is defined as:

Actual value (lab result C / T measurement) – model on-line prediction (C / T) after blow end.

For each C group the guarantee figures for C and T hitting as given in the table above are individual guarantee items.

The hitting ratio test shall be performed on one converter only.

Preconditions as listed up above.

Şekil 5.1. Seviye 2 model performans başarı kabul şartları

KAYNAKLAR

- [1] <https://www.worldsteel.org/about-steel.html> , Eriřim Tarihi: 25.03.2018.
- [2] Kutsurelis, J., Forecasting Financial Markets Using Neural Networks: An Analysis Of Methods And Accuracy, Master of science in management thesis, Naval Postgraduate School, pp.1-13, 1998.
- [3] Teixeira, R., Braga, A., Menezes, B., Control Of A Robotic Manipulator Using Artificial Neural Networks With On-Line Adaptation, Neural Processing Letters, 12, pp.19-31, 2000.
- [4] Zilouchian, A., Jamshidi, M., Intelligent Control Systems Using Soft Computing Methodologies, CRC Press, Chapter 4, USA, 2001.
- [5] Miller, T.W., Jimenez, J., Sharan, A., Goldstein, D.A. CH. 9 Oxygen Steelmaking Processes. The Making, Shaping and Treating of Steel 11th Ed., 475–524, 1998.
- [6] Turkdogan, E.T., Fruehan, R.J., Fundamentals of Iron and Steelmaking. Steelmaking and Refining Volume, i, 13–157, 1998.
- [7] Bilgiç, Ç.D., Effect Of Bottom Stirring On Basic Oxygen Steelmaking, ODTU Metalurji Ve Malzeme Mühendislięi Bölümü, Yüksek Lisans Tezi, 2016.
- [8] Pham, D.T., Pham, P.T.N., Artificial Intelligence In Engineering, International Journal of Machine Tools and Manufacture, 39(6), 937-949, 1999.
- [9] Gardner, M. W., Dorling, S. R., Artificial Neural Networks (The Multilayer Perceptron) A Review Of Applications In The Atmospheric Sciences, Atmospheric Environment, 32(14–15), 2627-2636, 1998.
- [10] Rozlach, Z., Data-driven Modelling in River Channel Evolution Research: Review of Artificial Neural Networks, J. Int. Environmental Application & Science, Vol. 10(4), 384-398, 2015.

- [11] Basheer, I. A. and Hajmeer, M., Artificial Neural Networks: Fundamentals, Computing, Design, And Application, Journal of Microbiological Methods, 43(1), 3-31, 2000.
- [12] Hagan, M. T., Demuth, H. B., Beale, M., Neural Network Design, PWS Publishing, ch.1-12, 1996.
- [13] Tebelskis, T., Speech Recognition Using Neural Networks, Doctoral Thesis, Carnegie Mellon University, Pennsylvania, pp.27-48, 1995.
- [14] <https://www.yenibiyoloji.com/sinir-hucresinin-noronun-yapisi-gorevleri-ve-noron-cesitleri-1556/>. Erişim Tarihi: 25.03.2019.
- [15] <https://www.yenibiyoloji.com/sinaps-ve-impuls-3542/>. Erişim Tarihi: 25.03.2019.
- [16] Demuth, H., Beale, M., Neural Network Toolbox For Use With Matlabuser's Guide, Mathworks Inc., 2002.
- [17] Hornik, K., Stinchcombe, M., White, H., Multi Layer Feedforward Networks Are Universal Approximators, Neural Netw. 2, 359–366, 1989.
- [18] Zurada, J.M., Introduction to Artificial Neural Systems, WestPublishing Company, Mumbai, India, 1997.
- [19] Bourquin, J., Schmidli, H., Van Hoogevest, P., Leuenberger, H., Advantages of Artificial Neural Networks (ANNs) As Alternative Modelling Technique For Data Sets Showing Non-Linear Relationships Using Data From A Galenical Study On A Solid Dosage Form, European Journal of Pharmaceutical Sciences, 7(1): 5-16, 1998.
- [20] Demuth, H., Beale, M., Neural Network Toolbox for Use with MATLAB® Users Guide Version, 4,14-330, 2002.
- [21] Haykin, S., Neural Networks: A Comprehensive Foundation, Second ed. Pearson Education Inc., New Delhi, India, 2001.
- [22] Yumuşak, N., Güç Sistemi Devre Elemanlarının Elektriksel Özelliklerinin Elde Edilmesinde Yapay Sinir Ağı Tabanlı Algoritmaların Kullanılması, Doktora Tezi, SAÜ, Fen Bilimleri Enstitüsü, Sayfa 6-33., 1998.
- [23] Rumelhart, D.E., Hinton, G.E., Williams, R.J., Learning Internal Representations By Error Propagation. In D. E. Rumelhart & J.L. McClelland Eds, Cambridge, MA: MIT Press, 1986.

- [24] Moller, M.F., A Scaled Conjugate Gradient Algorithm for Fast Supervised Learning, *Neural Networks*, Vol. 6, pp. 525–533, 1993.
- [25] Wang, S.C., *Artificial Neural Network*, The Springer International Series in Engineering and Computer Science, Volume 743, 81-100, 2003.
- [26] Temurtas, F., *Expert Systems with Applications 36*, A Comparative Study On Thyroid Disease Diagnosis Using Neural Networks, 944–949, 2009.
- [27] Wilby, R.L., Wigley, T.M.L., Conway, D., Jones, P.D., Hewitson, Main, J., Wilks, D.S., *Statistical Downscaling Of General Circulation Model Output: A Comparison Of Methods. Water Resources Research.*34(11): 2995-3008, 1998.
- [28] Dorofki, M., Elshafie, A.H., Jaafar, O., Karim, O.A, Mastura, S., *Comparison of Artificial Neural Network Transfer Functions Abilities to Simulate Extreme Runoff Data*, International Conference on Environment, Energy and Biotechnology IPCBEE vol.33,IACSIT Press, Singapore, 2012.
- [29] Barlas, Y., *Formal Aspects Of Model Validity And Validation In System Dynamics*, *System Dynamics Review* Vol. 12, no. 3, : 183-210, 1996.
- [30] Hastie, T., Tibshirani, R., Friedman, J., *The Elements Of Statistical Learning*. New York, NY: Springer-Verlag; 240-260, 2008.
- [31] Breiman, L., Friedman JH, Olshen RA., Stone CJ, *Classification and regression trees*. Monterey, CA: Wadsworth & Brooks/ Cole Advanced Books & Software; 1984
- [32] Kohavi R., *A Study Of Cross-Validation And Bootstrap For Accuracy Estimation And Model Selection*. The Fourteenth International Joint Conference on Artificial Intelligence (IJCAI))San Francisco, CA: Morgan Kaufman; p. 1137—45, 1995.
- [33] Kuhn, M., Johnson,K., *Applied Predictive Modeling*,Springer,P 70, 2013.
- [34] Pandey, A., Jain, A., *Comparative Analysis of KNN Algorithm Using Various Normalization Techniques*, *I. J. Computer Network and Information Security*, 11, 36-42, 2017.
- [35] Arat, H., Arslan,O., *Optimization Of District Heating System Aided By Geothermal Heat Pump: A Novel Multistage With Multilevel ANN Modelling* *Applied Thermal Engineering* 111 , 608–623, 2017.

- [36] Floyd, CE. Jr., Lo, JY., Yun, AJ., Sullivan DC., Cancer. Prediction Of Breast Cancer Malignancy Using An Artificial Neural Network. Dec 1;74(11):2944-8, 1994.
- [37] Narvekar, M., Fargose, F., Daily Weather Forecasting using Artificial Neural Network ,International Journal of Computer Applications (0975 – 8887) Volume 121 – No.22, 9 , 2015.
- [38] Kubat, C., Taşkın, H., Artır, R., Yılmaz, A., Bofy-fuzzy logic control for the basic oxygen furnace (BOF) Robotics and Autonomous Systems 49 193–205, 2004.
- [39] Han, M., Zhao,Y., Dynamic Control Model Of BOF Steelmaking Process Based On ANFIS And Robust Relevance Vector Machine .Expert Systems with Applications 38 14786–14798, 2011.
- [40] Xie, S., Chai, T., Prediction Of Bof Endpoint Temperature And Carbon Content, IFAC 14th Triennial World Congress Beijing. P.R. China, 1999.
- [41] Gonzalez, J., Barron M.A., Carbon Estimation Of Steel In A Bof With Noise Attenuation, 15th Triennial World Congress, Barcelona, Spain, 2002.
- [42] Kişi, Ö., Uncuoğlu, E., Comparison Of Three Backpropagation Training Algorithms For Two Case Studies , Indian Journal of Engineering & Material Sciences Vol 12 434-442, 2005.
- [43] Li C., Zhao, H, Yin, Q., Prediction model of End-Point Carbon Content for BOF Based on LM BP Neural Network, Advanced Materials Research Vols 189-193, 4446-4450, 2011.
- [44] Wang, H., An-jun, X., Li-xiang, A., Nai-yuan, T. , Prediction of Endpoint Phosphorus Content of Molten Steel in BOF Using Weighted K-Means and GMDH Neural Network, Journal Of Iron And Steel Research. International.19(1): 11-16, 2012.
- [45] Wang, Z., Xie, F., Wang, B., Liu, Q., Lu, X., Hu, L.N., Cai, F., The Control and Prediction of End-Point Phosphorus Content During BOF Steelmaking Process, Steel Research Int. 85 No. 4, 2014.
- [46] Nawi, N.M., Atomi, W.H., Rehman, M. Z, The Effect of Data Pre-Processing on Optimized Training of Artificial Neural Networks, Procedia Technology 11 32 – 39, 2013.

- [47] Wang,, H., Cai, J., Feng, K., Predicting the Endpoint Phosphorus Content of Molten Steel in BOF by Two-stage Hybrid Method, Journal of Iron and Steel Research, International, 21 (Supplement 1), 2014.
- [48] Aktürk, Ö., Zencefil Ve Domatesin Antioksidan Özellikleri Üzerine Çeşitli Kurutma Yöntemlerinin Etkisi. Sakarya Üniversitesi, Fen Bilimleri Enstitüsü, Gıda Mühendisliği Bölümü, Yüksek Lisans Tezi, 2013.
- [49] He,F., Zhang, L., Prediction Model Of End-Point Phosphorus Content In Bofsteelmaking Process Based On PCA And BP Neural Network. Journal of Process Control 66 , 51–58, 2018.

ÖZGEÇMİŞ

Selahattin OKUR, 03.02.1978'de Tarsus'ta doğdu. İlk, orta ve lise eğitimini Kdz.Ereğli'de tamamladı. 1996 yılında Kdz.Ereğli Anadolu Lisesi'nden mezun oldu. 1997 yılında başladığı İstanbul Üniversitesi İngilizce Elektronik Mühendisliği Bölümü'nü 2001 yılında bitirdi. 2002 yılında Ereğli Demir ve Çelik Fabrikaları Elektronik Otomasyon Müdürlüğü'nde mühendis olarak çalışmaya başladı. 2004 yılında askerlik görevine yaptı. 2011 yılında Sakarya Üniversitesi Elektrik-Elektronik Mühendisliği Anabilim Dalı Elektronik Mühendisliği Bölümü'ne yüksek lisansa başladı. 2016 yılında Elektronik Otomasyon Müdürlüğü'nde Başmühendis olarak atandı. Evli ve bir çocuk babası olan Selahattin OKUR halen aynı görevi yürütmektedir.