



İSKENDERUN TEKNİK

ÜNİVERSİTESİ

MÜHENDİSLİK VE FEN BİLİMLERİ ENSTİTÜSÜ

**YÜKSEK
LİSANS
TEZİ**

**ELEKTRİKLİ ARK OCAKLARI VE
SÜREKLİ DÖKÜM TESİSLERİNDE
YAPAY SİNİR AĞLARI
UYGULAMALARI**

Edip YILDIZ

**ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ
ANABİLİM DALI**

HAZİRAN 2019



**ELEKTRİKLİ ARK OCAKLARI VE SÜREKLİ DÖKÜM TESİSLERİNDE
YAPAY SİNİR AĞLARI UYGULAMALARI**

EDİP YILDIZ

**YÜKSEK LİSANS TEZİ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ
ANABİLİM DALI**

**İSKENDERUN TEKNİK ÜNİVERSİTESİ
MÜHENDİSLİK VE FEN BİLİMLERİ ENSTİTÜSÜ**

HAZİRAN 2019

Edip YILDIZ tarafından hazırlanan "ELEKTRİKLİ ARK OCAKLARI VE SÜREKLİ DÖKÜM TESİSLERİNDE YAPAY SİNİR AĞLARI UYGULAMALARI" adlı tez çalışması aşağıdaki jüri tarafından OY BİRLİĞİ ile İskenderun Teknik Üniversitesi Elektrik Elektronik Mühendisliği Anabilim Dalında YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Danışman: Dr. Öğr. Üyesi Ersin ÖZDEMİR

Elektrik Elektronik Mühendisliği Anabilim Dalı, İskenderun Teknik Üniversitesi
Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum.



.....
.....

Başkan: Doç. Dr. Serdar YILDIRIM

Bilgisayar Mühendisliği Anabilim Dalı, Adana Alparslan Türkeş Bilim ve Teknoloji Üniversitesi

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum.



.....
.....

Üye: Dr. Öğr. Üyesi Murat FURAT

Elektrik Elektronik Mühendisliği Anabilim Dalı, İskenderun Teknik Üniversitesi
Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum.



.....
.....

Üye: Dr. Öğr. Üyesi Ersin ÖZDEMİR

Elektrik Elektronik Mühendisliği Anabilim Dalı, İskenderun Teknik Üniversitesi
Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum.




.....
.....

Tez Savunma Tarihi: 21/06/2019

Jüri tarafından kabul edilen bu tezin Yüksek Lisans Tezi olması için gerekli şartları yerine getirdiğini onaylıyorum.

Prof. Dr. Tolga DEPCI
Mühendislik ve Fen Bilimleri Enstitüsü Müdürü



ETİK BEYAN

İskenderun Teknik Üniversitesi Mühendislik ve Fen Bilimleri Enstitüsü Tez Yazım Kurallarına uygun olarak hazırladığım bu tez çalışmada;

- Tez üzerinde Yükseköğretim Kurulu tarafından hiçbir değişiklik yapılamayacağı için tezin bilgisayar ekranında görüntülendiğinde asıl nüsha ile aynı olması sorumluluğunun tarafıma ait olduğunu,
- Tez içinde sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiğimi,
- Tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu,
- Tez çalışmada yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi,
- Kullanılan verilerde herhangi bir değişiklik yapmadığımı,
- Bu tezde sunduğum çalışmanın özgün olduğunu,

bildirir, aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi beyan ederim.


Edip Uluoğlu
21.06.2019

ELEKTRİKLİ ARK OCAKLARI VE SÜREKLİ DÖKÜM TESİSLERİNDE
YAPAY SİNİR AĞLARI UYGULAMALARI
(Yüksek Lisans Tezi)

Edip YILDIZ

İSKENDERUN TEKNİK ÜNİVERSİTESİ
MÜHENDİSLİK VE FEN BİLİMLERİ ENSTİTÜSÜ

Haziran 2019

ÖZET

Endüstriyel tesislerde gerçekleştirilen üretim veya hizmetlerin, klasik mantıksal algoritmaların kullanıldığı otomasyon sistemleri ile kontrol edilmesi esnasında, karşımıza çeşitli karmaşık hesaplamalar ve problemler çıkabilmektedir. Karşılaşılan bu problemlerin çözülmesi için sistemin modellenmesi önemlidir.

Bu çalışma ile demir çelik sektörü içerisinde önemli yer tutan elektrikli ark ocaklı hurda ergitme tesisi ve çelikhanede ergitilmiş sıvı çeliğin, SLAB yarı mamulüne dönüştürüldüğü sürekli döküm makinelerinde bulunan fonksiyonel ekipmanlarda daha kararlı şartların sağlanması ve yaşanan kronik problemlere daha etkin çözüm üretilebilmesi adına farklı mimarilerdeki Yapay Sinir Ağlarının fabrikadan alınan veri setleri ile eğitilmesi ve sonuçlarının karşılaştırılarak Yapay Sinir Ağlarının veri modellemesi ve tahmin özellikleri üzerinde durulmuştur.

Yapay Sinir Ağlarının, elektrikli ark ocakları elektrot kontrol modellemesinde %95 üzeri ve SLAB sürekli döküm makinası kalıp kanama tahmininde %98 üzeri başarı sağlanmıştır. Yapay sinir ağı tabanlı kontrol yazılımı, sürekli kalibrasyon ve parametre değişikliği gerektiren klasik mantıksal yazılıma göre kullanıcı açısından daha ergonomik kullanıma sahiptir. Klasik mantıksal yazılımın algılayamadığı kalıp kanama örneklerine Yapay Sinir Ağı tabanlı yazılım başarılı tahminlerde bulunabilmiştir.

Anahtar Kelimeler : Yapay sinir ağları, MLP, Elektrik Ark Ocağı, Slab Sürekli Döküm

Sayfa Adedi : 97

Danışman : Dr. Öğr. Üyesi Ersin ÖZDEMİR

APPLICATIONS OF ARTIFICIAL NEURAL NETWORKS
IN ELECTRIC ARC FURNACES AND CONTINUOUS CASTING FACILITIES
(M. Sc. Thesis)

Edip YILDIZ

ISKENDERUN TECHNICAL UNIVERSITY
ENGINEERING AND SCIENCE INSTITUTE

June 2019

ABSTRACT

Various complex calculations and problems may arise during the control of production or services performed in industrial plants by automation systems using classical logical algorithms. It is important to model the system in order to solve these problems. System modeling is to obtain an unknown system model based on the data obtained with various mathematical equations.

In this study, Artificial Neural Networks in different architectures in order to provide more stable conditions and to provide more stable conditions for the chronic problems experienced in electric arc furnace scrap melting plant which is important in iron and steel sector and continuous casting machines where molten liquid steel in meltshop is converted into SLAB semi-product. data modeling and estimation characteristics of Artificial Neural Networks were compared.

In Artificial Neural Networks, electric arc furnace electrode control modeling has achieved over 95% success, while SLAB continuous casting machine has achieved over 98% success in mold breakout prediction. Artificial neural network-based control software is more ergonomic for the user than conventional logical software that requires continuous calibration and parameter change. Artificial Neural Network-based software has been able to make successful predictions on patterns of breakout that cannot be detected by conventional logical software.

Key Words : Artificial neural network, MLP, Electrical arc furnace, Slab continuous casting
Page Number : 97
Supervisor : Asst. Prof. Ersin ÖZDEMİR

TEŐEKKÖR

Çalıőmanın gerekleőmesinde katkılarından dolayı deęerli hocam Sayın Dr. Ersin ÖZDEMİR'e, üniversite ve öncesindeki eęitim hayatım boyunca bana kazandırdıkları ve beni mesleki hayatımda söz sahibi yapan bilgilerle donatan hocalarıma, alıőma süresince kendilerine yeterli zaman ayıramadıęım halde bana karşı göstermiş oldukları sabır ve sevgi ile motivasyonumu saęlayan sevgili eőim Gülbin ve sevgili kızım Ada'ya ve benden hiçbir zaman desteęini esirgemeyen aileme sonsuz teőekkürlerimi sunarım.



İÇİNDEKİLER

	Sayfa
ÖZET	iv
ABSTRACT.....	v
TEŞEKKÜR.....	vi
İÇİNDEKİLER	vii
ÇİZELGELERİN LİSTESİ.....	x
ŞEKİLLERİN LİSTESİ.....	xi
SİMGELER VE KISALTMALAR.....	xiv
1. GİRİŞ.....	1
2. ÖNCEKİ ÇALIŞMALAR.....	4
2.1. YSA İçin Yapılan Çalışmaların Kronolojik Sıralaması	6
2.2. Yapay Sinir Ağları ve Modelleri.....	7
2.2.1. Tek katmanlı algılayıcılar	7
2.2.2. Çok katmanlı algılayıcılar	8
2.2.3. Girdi katmanı.....	9
2.2.4. Ara katmanlar.....	9
2.2.5. Çıktı katmanı	10
2.2.6. Öğrenme algoritmasına göre YSA sınıflandırması.....	10
2.2.7. Nöron dinamiği ve aktivasyon fonksiyonları	11
2.2.8. YSA ile hesaplamının özellikleri	15
2.3. Çok Katmanlı Algılayıcı Öğrenme Kuralı	16
2.3.1. İleri doğru hesaplama	16
2.3.2. Geriye doğru hesaplama.....	17
2.3.3. Öğrenmeyi etkileyen faktörler	17

	Sayfa
2.3.4. Yapay sinir ağlarının özellikleri.....	18
2.4. Yapay Sinir Ağlarının Kabiliyetleri	19
2.5. Yapay Sinir Ağlarının Uygulama Alanları	19
2.6. Yapay Sinir Ağlarının Uygulamaları	20
3. MATERYAL VE METOD	22
3.1. Elektrikli Ark Ocakları	22
3.1.1. Elektrik ark fırınına giren-çıkan maddelerin şematik gösterimi	23
3.1.2. Elektrik ark ocağı ve genel yapısı.....	24
3.1.3. EAF trafosunun genel yapısı ve reaktör.....	25
3.1.4. EAF genel yapısı ve enerji iletimi	28
3.1.5. EAF kısa devre hesabı.....	30
3.2. Veri Toplama, Ağ Eğitimi Ve Sınama	32
3.2.1. EAF plc'den verilerin alınması.....	34
3.2.2. YSA yapısının seçilmesi	36
3.2.3. YSA öğrenme algoritması ve aktivasyon fonksiyonu seçimi	37
3.2.4. Ara katman ve nöron sayılarının belirlenmesi.....	37
3.2.5. YSA için veri setlerinin oluşturulması	37
3.2.6. Oluşturulan veri setlerinin kullanımı	42
3.2.7. 3361 numaralı dökümden alınan veri örneklerinin YSA ile incelenmesi	45
3.3. Slab SDM Kalıp Kanama Sistemi YSA Uygulaması	57
3.3.1. Sürekli Döküm Makinesi Kalıp Yapısı.....	60
3.3.2. Mantıksal Programlamaya Dayalı Koparma Algılama Sistemi.....	61
3.3.3. Yapay Sinir Ağı Tabanlı Koparma Tahmin Sistemi	64
3.3.4. YSATB ile MY program çıktılarının karşılaştırılması.....	77

Sayfa

4. SONUÇ VE ÖNERİLER.....	84
KAYNAKLAR.....	85
EKLER.....	90
EK-1. Borland Delphi 7.0 ile hazırlanmış ara yüz.....	91
EK-2. SCL dilinde yazılmış basınç algoritması.....	92
EK-3. Kalıp kanama anı süreç verileri.....	94
EK-4. MY programının kalıp kanama problemini tespit edemediği süreç verileri-1	95
EK-5. MY programının kalıp kanama problemini tespit edemediği süreç verileri-2	96
ÖZGEÇMİŞ	97

ÇİZELGELERİN LİSTESİ

Çizelge	Sayfa
Çizelge 3.1. Elektrik ark ocağında üretilen örnek sıvı çelik analizi.....	23
Çizelge 3.2. EAF fırın transformatörü kademe bilgileri	27
Çizelge 3.3. EAF Reaktörünün test sonucunda elde edilmiş kademe bilgileri	28
Çizelge 3.4. Dışa aktarılan akım trendlerine ait veri setinden örnek	42
Çizelge 3.5. Ergitme aşamasına ait örnek veri seti	46
Çizelge 3.6. İzabe aşamasına ait örnek veri seti	52
Çizelge 3.7. YSA eğitiminde kullanılan örnek veri seti.....	71
Çizelge 3.8. YSATB çıktısının eğitim veri seti ile karşılaştırılması.....	74

ŞEKİLLERİN LİSTESİ

Şekil	Sayfa
Şekil 2.1. Tek katmanlı YSA modeli	7
Şekil 2.2. Çok katmanlı YSA modeli.....	9
Şekil 2.3. Öğreticili (Danışmanlı) öğrenme yapısı	10
Şekil 2.4. Xi girişli bir yapay nöronun grafik gösterimi	11
Şekil 2.5. Doğrusal veya Lineer fonksiyon grafiği	13
Şekil 2.6. Basamak fonksiyon grafiği	14
Şekil 2.7. Sigmoid fonksiyon grafiği	14
Şekil 2.8. Tanjant hiperbolik fonksiyon grafiği	15
Şekil 3.1. Elektrik ark fırınının şematik şekli ve fırına giren çıkan maddeler	24
Şekil 3.2. EAF genel yapısı.....	25
Şekil 3.3. EAF transformatörü ve dahili bağlantısı.....	26
Şekil 3.4. EAF elektrotları ve taşıma grubu.....	29
Şekil 3.5. Çalışmada kullanılan ocağa ait teknik veriler.....	30
Şekil 3.6. EAF elektrik eşdeğer devresi.....	31
Şekil 3.7. Hat reaktansları ve kompanzasyon gücü hesap cetveli.....	32
Şekil 3.8. EAF trafosundan analog akım bilgisinin alınması.....	33
Şekil 3.9. EAF ve diğer saha enstrümanlarının haberleşme ağı	34
Şekil 3.10. Iba analyzer programı ile bir döküme ait veri setlerinin görünümü	35
Şekil 3.11. Iba analyzer editöründe döküm numarası – zaman grafiği.....	39
Şekil 3.12. Iba analyzer editöründe veri seti seçilmesi	40
Şekil 3.13. 182 numaralı döküme ait veri setlerinin dışa aktarım işlemi.....	40
Şekil 3.14. Iba editöründe 3361 numaralı döküme ait akım trendleri	41
Şekil 3.15. Oluşturulan ara yüze verilerin aktarıldıktan sonraki görüntüsü	42

Şekil	Sayfa
Şekil 3.16. Eğitim işlemi gerçekleştirilmeden yapılan ileri hesaplama sonucu.....	43
Şekil 3.17. Eğitim işlemi gerçekleştirildikten sonra yapılan test sonucu	44
Şekil 3.18. 1000 iterasyon sonucu için yapılan test sonucu.....	45
Şekil 3.19. Eğitim devam ederken hata oranı 6,85 iken ara yüzde görüntü	47
Şekil 3.20. Eğitim devam ederken hata oranı 5,92 iken ara yüzde görüntü	47
Şekil 3.21. 3361 numaralı dökümün eğitime veri setine ait trend grafikleri	48
Şekil 3.22. Eğitim başlangıcındaki % hata oranı – zaman grafiği	49
Şekil 3.23. Farklı başlangıç ağırlıkları ile % hata oranı – zaman grafiği.....	49
Şekil 3.24. Eğitilen YSA'nın veri setine gösterdiği çıkışlar	50
Şekil 3.25. YSA'nın tanımlayamadığı veri aralığı.....	51
Şekil 3.26. İzabe aşaması döküm numarası, akım ve elektrot sinyal trendleri	53
Şekil 3.27. Yapılan manuel operasyonlara YSA'nın vermiş olduğu tepki	53
Şekil 3.28. Mevcut regülasyon algoritmasına YSA'nın göstermiş olduğu tepki.....	54
Şekil 3.29. YSA % hata oranı – zaman grafiği	55
Şekil 3.30. Elektrot basınç bilgileri için ünite üzerine yerleştirilen basınç çeviricileri ..	56
Şekil 3.31. YSA'nın deney seti ile karşılaştırılması	57
Şekil 3.32. SDM genel görünüm.....	58
Şekil 3.33. Kalıp içerisinde gerçekleşen süreç.....	59
Şekil 3.34. SDM Kalıbı üç boyutlu genel görünümü.....	60
Şekil 3.35. Su soğutmalı kalıbın açık şematik gösterimi	61
Şekil 3.36. Yapışan noktanın sıcaklık gradyanı.....	62
Şekil 3.37. Koparma alarm ve uyarı eşik değer – zaman diyagramı	63
Şekil 3.38. SDM kalıp şematik gösterimi ve IBA program editörü ekran görüntüsü.....	64

Şekil	Sayfa
Şekil 3.39. Kalıp kanama anı proses verileri	66
Şekil 3.40. Sıcaklık veri grafiği	68
Şekil 3.41. YSA tahmin bloğu (YSATB)	69
Şekil 3.42. Kalıp üzerinde YSA tahmin bloğu (YSATB) uzay dağılımı.....	70
Şekil 3.43. YSA eğitiminde kullanılan örnek verilere ait grafikler	72
Şekil 3.44. YSA eğitimi performans grafiği	75
Şekil 3.45. YSA eğitimi test verileri.....	78
Şekil 3.46. YSATB - MY program çıktılarının karşılaştırmaları	80
Şekil 3.47. Kalıp kanama anı süreç verileri	81
Şekil 3.48. YSATB-MY program çıktılarının problemlü döküm için karşılaştırması	83

SİMGELER VE KISALTMALAR

Bu çalışmada kullanılmış simgeler ve kısaltmalar, açıklamaları ile birlikte aşağıda sunulmuştur.

Simgeler

Açıklamalar

V	Volt
I	Akım
Z	Empedans
hz	Hertz
L	Henry
f	Frekans
α	Momentum katsayısı
λ	Öğrenme katsayısı katsayısı
p	Elektrot basıncı
P	Aktif güç
Q	reaktif güç
R	Direnç
W	Vektörel ağ ağırlıkları
X	Girdi vektörleri sayısı
Y	Çıktı vektörleri sayısı
\emptyset	Ağ eşik değeri
T	Akım trafosu
\emptyset	Ağ eşik değeri

Kısaltmalar

Açıklamalar

EAF	Elektrik ark ocağı
YSA	Yapay sinir ağı
SVC	Kompanzasyon sistemi
SDM	Sürekli döküm makinası
MLP	Çok katmanlı perseptron

Kısaltmalar**Açıklamalar**

BP	Geriye yayılım
RBF	Radyal tabanlı sinir ağı
ART	Adaptif rezonans teori ağları
SOM	Kendini düzenleyen haritalar
TKA	Tek katmanlı algılayıcılar
ÇKA	Çok katmanlı algılayıcılar
PLC	Programlanabilir lojik kontrolör
AC	Alternatif akım
DC	Doğru akım
CPU	Merkezi işlemci ünitesi
SCL	Yapısal kontrol dili
BPS	Kalıp kanama tahmin sistemi
MY	Mantıksal yazılım
YZ	Yapay zeka
YSATB	Yapay sinir ağı tahmin bloğu
RMSE	Hata Karelerinin Ortalamasının Karekökü
RMS	Hata Karelerinin Ortalaması

1. GİRİŞ

Günümüzde, sıvı çelik üretiminde elektrikli ark ocakları ve yüksek fırın süreçleri ana başlıkları oluşturmaktadır. Fakat sıvı çelik üretiminde elektrikli ark ocakları süreçlerinin esnekliğinden, yatırım ve işletme maliyetlerinin yüksek fırınlara göre daha düşük olmasından dolayı ilgiyi üzerlerine çekmektedirler.

Demir çelik sanayi, birbirini tamamlayan ve genellikle entegre özellikte sanayi sektörüdür. Bağımsız olarak çalışabilen ve çeşitli demir çelik ürünleri üreten alt sektörlerden oluşmaktadır. Demir çelik sanayi, hadde ürünleri, yassı mamul ürünleri, vasıflı çelik ürünleri, çelik borular ve ferro alaşım ürünleri için hammadde tedarikinde önemlidir. Demir çelik fabrikaları, inşaat, savunma, demiryolu, beyaz eşya, otomotiv sektörlerinin de içinde bulunduğu birçok üretim ve imalat sektörünün hammadde tedarikinde önem arz ettiğinden dolayı sanayileşmenin ve kalkınmanın temelinde önemi büyüktür.

Enerji kullanımı açısından, demir çelik sektörü en yoğun enerji kullanımına sahip sektörler arasında yer almaktadırlar. Zira dünyada üretilen toplam enerjinin yaklaşık %12'sinin bu sektörde kullanıldığı ifade edilmektedir. Elektrik ark fırınlarına dayalı çelik üretimi sektör içerisinde birim üretim başına en fazla enerji harcayan üretim biçimidir [1].

Dünyada kullanılan enerjinin yaklaşık %12'sinin Demir-Çelik sektöründe tüketilmesi, bu sektörde kullanılan enerjinin büyüklüğünü ortaya koymaktadır. Bununla birlikte, birim üretim başına tüketilen enerji miktarının azaltılmasına yönelik çalışmaların artması bu sektörde harcanan enerjinin büyüklüğünü gözler önüne sermektedir. Fakat çelik üretiminde kullanılan enerjinin yaklaşık %50'si çeşitli nedenlerle kayıp olmaktadır [1]. Bu kayıpların azaltılması için yapılan çalışmaların sonucunda da doğal olarak sağlanan tasarruf oranı yüksektir.

Eski dönem bilgisayarları basit aritmetik işlemlerin yapılması için tasarlanmış iken, günümüz teknolojilerine bağlı olarak birbirleri ile iletişim halinde olan, insanlar ile diyalog kurabilen, veri girdilerini değerlendirebilen ve öğrenebilen bilgisayarlar üzerine çalışmalar hızla devam etmektedir. İnsanoğlunun ihtiyaçları doğrultusunda çevre şartlarına göre karar vermeleri ve olayları öğrenmeleri, birçok donanım ve yazılım geliştirmeleri ile beraber

günümüze kadar gelmiştir. Gelişimini donanımsal olarak hızla sürdüren bilgisayarlar üzerinde çalışan yazılımların gelişimi de donanım gelişimine paralel olarak ilerlemekte ve teknolojiye ayrı bir ivme kazandırmaktadır.

Yapay Zekâ (YZ) bu gelişmeye katkısı olan önemli konu başlıklarındandır. Bilgi yarışmasını kazanan Watson [2], GO zekâ oyununda dünya şampiyonunu yenen Google AI [3] gibi teknolojik gelişmeler günümüzde yapay zekânın becerilerini öne çıkarmaktadır.

Yapay sinir ağlarının (YSA) tarihçesi nörobiyoloji konusuna ilgi duyulması ve elde edilen bilgileri bilgisayar bilimine uygulaması ile başlamıştır. Yapay sinir ağları bilinen hesaplama yöntemlerinden farklı bir hesaplama yöntemi önermektedir. Buldukları ortama uyum sağlayan, adaptif, eksik bilgi ile çalışabilen, belirsizlikler altında karar verebilen, hatalara karşı toleranslı olan hesaplama yöntemini hayatın her alanında başarılı uygulamalarını görmek mümkündür [4].

Genellikle yapay sinir ağları, bir süreçte doğrusal olmayan, karmaşık girdi – çıktı verileri arasındaki ilişkiyi yakalama yeteneklerinden dolayı kullanılmaktadır. Klasik kontrol algoritmaları ile modellenmesi mümkün olmayan problemlerin YSA'lar ile çözümü YSA'ları üstün kılmaktadır. Bu sebeple YSA'lar, birçok sektörde farklı mühendislik dallarında ki uygulamalarla karşımıza çıkmaktadır. Beton basınç dayanımının tahmini [5], kirişsiz döşemeli betonarme binalarda oluşan yatay deplasmanın tahmini [6], yalıtım malzemelerinin kalınlık tahmini ve yer altı sularının davranış tahmini gibi çalışmaları [7], yapay zeka kullanarak ultrasonik NDT'de (Tahribatsız Muayene) yönteminde otomatik hata sınıflama [8], elektrik enerjisi tüketim tahmin analizi [9], endüstriyel proses arıza tespiti [10], makinalarda stator arıza tespiti [11], motor sürücülerinde harmoniklerin minimuma indirilmesi [12], hafif beton basınç dayanımının tahmini [13], rüzgar hızı tahmini [14], elektrik motorlarında durum izleme ve arıza teşhisi [15], üç fazlı ferrosilikon örtülü ark ocaklarında sistem kimliklendirme [16], akarsularda debinin modellenmesi [17], yıllara göre otomobil satış tahminleri [18], diyabet hastalığının teşhisi [19], betonarme binalarda ısı kayıpları ve enerji ihtiyacının hesaplanması [20], günlük yağış miktarının tahmini [21], parmak izi tanıma ve sınıflandırma [22], katı madde konsantrasyonunun tahmini [23], net enerji talep tahmini [24], ER valf-silindir sistemi pozisyon kontrolü [25], ikili karışımlardaki fenol izomerlerinin, çok değişkenli bir kalibrasyon olarak budama ile karbon fiber elektrot ve sinir ağı kullanarak diferansiyel darbe voltmetrisi ile eş zamanlı belirlenmesi [26], ark

kaynağı proses modellemesi ve kontrolü [27], Yapay zeka ile biyoaktif küçük moleküllerin De Novo tasarımı [28], akarsu havzalarında çözülmüş oksijen miktarının belirlenmesi [29], kimyasal sentezlerin planlanması [30], İMKB 100 endeks tahmini [31], DNA ipliği deplasman kaskadlarının hesaplanması [32], yüksek düzeyde antibiyotiğe dirençli bakterilerin geniş spektrumuna karşı etkili olan küçük peptid antibiyotiklerin tasarımı [33], deprem tahmin ve analizleri [34], veri madenciliği [35] gibi uygulamalar YSA'ların başarı ile sonuçlandığı mühendislik uygulamalarıdır.

Bu çalışmada yapay sinir ağı, demir ve çelik üretiminin önemli süreçlerinden biri olan elektrikli ark ocağının (EAF) elektrot regülasyon sisteminin, temin edilen veriler dahilinde hazırlanan girdi – çıktı ilişkisi ile ağı eğitilip modellenmesinde kullanılmaktadır.

Elektrikli ark ocakları sıvı çelik üretiminde ve çelik üretimi sırasında kullanmış olduğu elektrik enerjisi bakımından önemli bir yer tutmaktadır. Ayrıca elektrikli ark ocağının akım ve gerilim dengesinin düzensiz oluşu ise klasik algoritmalar ile modellenmesini oldukça zor hale getirmektedir. Bu sebeple çalışmada elektrot regülasyonunun daha etkin bir şekilde yapılarak gücün verimli ve kararlı olarak kullanımı için YSA ile EAF akım ve elektrot karakteristiğinin modellenmesi amaçlanmıştır.

Yapılan çalışmalarda EAF ile üretim yapan bir demir çelik fabrikasında farklı kalitede çeliklerden elde edilen veriler bilgisayarlara kurulan ara yüzler ile sabit disklere kaydedilerek YSA'ların öğrenme ve test aşamalarında kullanılmıştır. Oluşturulan veri tabanı içerisindeki akım, gerilim, empedans, reaktans, aktif güç, reaktif güç, görünür güç, güç faktörü, ark güçleri, ark dirençleri, elektrot basınçları gibi veriler çeşitli kombinasyonlar ile YSA'lara girilip elektrot ve akım davranışları incelenmiştir.

Çelik sektöründe sürecin ayrılmaz bir ekipmanı olan Sürekli Döküm Makinaları (SDM) üzerinde meydana gelen kalıp kanama problemi ve kalıp kanama önleme sisteminin YSA'lar ile kontrol edilmesi ileriki bölümlerde detaylı olarak incelenmiştir.

2. ÖNCEKİ ÇALIŞMALAR

Yapay sinir ağlarının Elektrikli Ark Ocakları üzerine etkileri ile ilgili çeşitli çalışmalar yapılmıştır.

Staib W. ve Staib R. tarafından yapılan çalışmalarda 80 tonluk elektrikli ark ocağında yapay sinir ağı kontrol sisteminin elektrot konumu ve fırın operasyonunun kararlılığı arasındaki ilişkileri tahmin etmeyi öğrenebileceğini göstermişlerdir. Bu sayede fırın içerisinde değişken koşullardaki operasyonlara gerçek zamanlı adaptasyonun, elektrot aşınmasını, fırın aşınmasını ve güç tüketimini azalttığını savunmuşlardır. Yapay Sinir Ağı kontrolünün sonucu, fırın başına yılda milyonlarca dolar tasarruf sağlayacağı yapılan test ve denemeler ile doğrulanmıştır [36].

British Gas plc ve SD-Scicon UK Limited şirketleri sinir ağlarının deneysel bir ocağın modele dayalı kontrol uygulanmasının araştırılmasını sağlamıştır. Bunun için SD-Scicon, British Gas tarafından sağlanan açık döngü test verilerini kullanan, genelleştirilmiş tahmine dayalı kontrol ve performans değerlendirmesi yapan bir sinir ağı modeli geliştirdi. Yapmış oldukları sıcaklık tahmininde yapay sinir ağının mükemmel performans sergilediğini göstermişlerdir [37].

King ve Nyman, önceki çalışmaların elektrik ark ocağı çalışma dinamiğinin düzensiz olduğunu dolayısıyla standart kontrol tekniklerinin etkili olmadığını ortaya koyması sebebi ve elektrikli ark ocaklarında insanın sezgisel kontrolü her gün kullanıldığını belirterek fırın operatörünün, fırın performansını değerlendireceğini, geçmiş deneyime ve sezgilere dayanarak çıkarımlar yapabileceğini belirtmiştir. Bu kontrolün etkinliğini arttırmak için fırının çalışma koşullarına ilişkin nitel bir anlayış gerektiğini savunmuşlardır. Yapay sinir ağlarının elektrik ark ocağının sistem dinamiklerini öğrenebileceğini belirterek yapay sinir ağı tarafından modellenen ocağın çıktısının daha sonra ark ocağının gelecekteki durumunu kontrol amacıyla tahmin etmekte kullanıldığını göstermişlerdir [38].

Lavers ve Sadeghian çalışmalarında elektrik ark ocaklarında karmaşık olan akım tahmini probleminin çözümüne adaptif nöro-bulanık ağ ile çözüm bulmaya çalışmışlardır. Çalışmalarının hedefi ileri beslemeli adaptif nöro-bulanık ağların kabiliyetini araştırmak ve elektrik ark ocakları gibi doğrusal olmayan, çok değişkenli, karmaşık sistemlerin v-i

karakteristiklerini tahmin etmek için uygulamalarını haklı çıkarmaktır. Bu çalışmanın yeniliği, uzun vadeli tahminler için uygun ileriye beslemeli sinirsel bulanık ağ yapısı önermektir. İleri beslemeli nöro-bulanık tahmincilerin başarılı uygulamaları ve adaptif nöro-bulanık ağlardan elde edilen sonuçlar ile kaydedilen veriler kullanılarak performansları gösterilmiştir [39].

Wang, Jinn ve Zhu'ya göre elektrik ark ocakları, elektrik enerjisi iletim ve dağıtım sistemlerinde en rahatsız edici yüklerden birini temsil eder. Bu nedenle, elektrik ark ocağının güç sistemi davranışını tanımlamak için pratik bir model oluşturmak gerektiğini belirtirler. Elektrik ark ocağındaki düzensiz elektrik dalgalanmalarının yarattığı modellemedeki zorluklara kaos teorisi ve sinir ağlarının birleşimini kullanarak çözüm getirmişlerdir. Bu çalışma ile radyal temel işlevli sinir ağının, ark ocağının ark voltajını bir adım ve çok adım ilerde tahmin etmek için kullanılacağı gösterilmiştir [40].

Hong, Sheng ve Li bulanık sinir ağına dayalı AC (Alternatif Akım) elektrik ark ocağı kontrol sistemini geliştirmişlerdir. Pratik çalışma sonuçları, bu sistemin yüksek kontrol hassasiyetine ve iyi güvenilirliğe sahip olduğunu, elektrotların aşağı yukarı hareket hızını ve pozisyon hassasiyetini arttırıp elektrotların yumuşak bir şekilde regülasyonu sağladığını, üç faz akım dengesini sağladığını ve EAF sıcaklığının kararlılığını göstermektedir [41].

Zhang ve Zheng, elektrik ark ocağının elektrot sisteminde RBF ters kimliklendirme tabanlı çift model kontrol uygulamasını gerçekleştirmişler ve Ma'anshan demir çelik fabrikasında başarı ile uygulanmıştır [42].

Hui ve Wang geliştirilmiş BP (Back Propagation) sinir ağı ile elektrik ark fırını akım tahmin modelini Matlab ile test edip sonuç olarak elektrotların etkili bir şekilde kontrol edildiğini göstermişlerdir [43].

Paranchuk, sürekli voltaj izleme temeline dayalı yapay sinir ağlarının yapısal ve parametrik sentezlerini gerçekleştirmiştir. Ark gerilim izleme sisteminin sayısal modeli oluşturulmuş ve anlık gerilim izlemenin kesinliği incelenmiştir. Gerilim ölçüm hassasiyetindeki artış kanıtlanmıştır [44].

Garcia-Segura, Castillo, Martell-Chavez, Longoria-Gandara ve Aguilar'a göre elektrikli ark fırınları küresel çelik üretiminin neredeyse üçte birine katkıda bulunuyor. Ark fırınları, hurda

veya indirgenmiş demiri işlemek için büyük miktarda elektrik enerjisi kullanır ve bu kapsamdaki tasarruf çalışmaları verimliliklerindeki küçük gelişmeler önemli miktarda enerji tasarrufu sağlaması nedeni ile önem arz ettiğini belirtip hem proses performansını hem de enerji tasarrufunu arttırmak için optimal kontrolörlerin tasarlanmasının önemini vurgulamışlardır. Elektrik arklarının rastgele ve düzensiz olması nedeniyle, sinir ağları ve diğer mantıksal hesaplama teknikleri EAF'lerin modellenmesinde kullanılmıştır. Bu çalışma, zamanla değişen ark uzunluğunu ark ocağı modeline uygun bir giriş parametresi olarak kabul eden EAF'lerin modellenmesi için bir yöntem önermektedir. Ark ocağından alınan gerçek zamanlı gerilimlere ve akım ölçümlerine dayanarak, ark ocağını sinir ağları kullanarak modellemek için uygun bir ark uzunluğunun tahmin edilebileceğini göstermişlerdir. Elde edilen sonuçlar, modelin yalnızca kararlı ark koşullarını değil, aynı zamanda gerçek bir ergitme işleminde tanımlanması zor olan kararsız ark koşullarını da tahmin ettiğini göstermektedir. Sunulan model, fırın verimliliğini ve enerji verimliliğini artırmak için kontrol sistemlerinin geliştirilmesi ve test edilmesinde uygulanabilir [45].

Jin, Ren, Shi, Liu, sürekli dökümde kombine sinir ağını temel alan bir koparma tahmin sistemi geliştirmiştir. Tek termokupl sıcaklık modeli ön tanısı için radyal taban fonksiyonlu (RBF) sinir ağını ve Takagi-Sugeno modeline dayalı bulanık sinir ağı kullanılır. Sonuçlar, kombine sinir ağına dayanan koparma tahmin sisteminin yanlış alarm oranını etkin bir şekilde azaltabileceğini ve tahmin doğruluğunu iyileştirebileceğini göstermiştir [50].

2.1. YSA İçin Yapılan Çalışmaların Kronolojik Sıralaması

İnsan beyninin nasıl çalıştığı ve fonksiyonları uzun yıllar araştırılmıştır. 1890 yılında beynin fonksiyonları hakkında bilgi veren ilk eser yayınlanmıştır [4]. Buna benzer çalışmaların bazılarını kronolojik olarak aşağıdaki gibi listelenebilir:

- 1890- İnsan beyninin yapısı ve fonksiyonları ile ilgili ilk yayının yazılması
- 1911- İnsan beyninin bileşenlerinin belirli bir düzenek ile sinir hücrelerinden (nöronlar) oluştuğu fikrinin benimsenmesi
- 1943- Yapay sinir hücrelerine dayalı hesaplama teorisinin ortaya atılması ve eşik değerli mantıksal devrelerin (threshold logic device) geliştirilmesi
- 1949- Biyolojik olarak mümkün olabilen öğrenme prosedürünün bilgisayarlar tarafından gerçekleştirilecek biçimde geliştirilmesi
- 1956–1962- Adaline ve Windrow öğrenme algoritmasının geliştirilmesi
- 1957–1962- Tek katmanlı algılayıcı (perceptron) geliştirilmesi
- 1965- İlk makine öğrenmesi kitabının yayınlanması

- 1967–1969- Bazı gelişmiş öğrenme algoritmalarının (Grosberg öğrenme algoritması gibi) geliştirilmesi
- 1969- Tek katmanlı algılayıcıların problemleri çözme yeteneklerinin olmadığı gösterilmesi
- 1969- DAPRA'nın yapay sinir ağlarının desteklemeyi durdurup diğer yapay zeka çalışmalarına destek vermesi
- 1969–1972- Doğrusal ilişkilendiricilerin geliştirilmesi
- 1972- Kolerasyon Matris belleğinin geliştirilmesi
- 1974- Geriye yayılım modelinin (Çok katmanlı algılayıcıların ilk çalışmaları) geliştirilmesi
- 1978- ART modelinin geliştirilmesi (Öğretmensiz öğrenme)
- 1982- Kohonen öğrenmesi ve Som modelinin geliştirilmesi (Öğretmensiz öğrenme)
- 1982- Hopfield ağlarının geliştirilmesi
- 1982- Çok katmanlı algılayıcının geliştirilmesi
- 1984- Boltzman makinesinin geliştirilmesi
- 1985- Çok katmanlı algılayıcıların (genelleştirilmiş Delta öğrenme kuralı ile) geliştirilmesi
- 1988- RBF modelinin geliştirilmesi
- 1988- PNN modelinin geliştirilmesi
- 1991- GRNN modelinin geliştirilmesi
- 1991'den günümüze birçok çalışma ve uygulama geliştirilmiştir.

2.2. Yapay Sinir Ağları ve Modelleri

Yapay sinir ağlarını, ağ yapılarına göre tek katman ve çok katmanlı algılayıcılar olmak üzere iki bölümde inceleyebiliriz.

2.2.1. Tek katmanlı algılayıcılar

Sadece girdi ve çıktı katmanlarından oluşur. Tüm çıktı üniteleri bütün girdi ünitelerine (X), bağlanmaktadır. Her bağlantının bir ağı vardır (W).



Şekil 2.1. Tek katmanlı YSA modeli

Şekil 2.1’de belirtildiği gibi iki girdi ve bir çıktıya sahip olan basit bir TKA modeli. Basit algılayıcı modellerine örnek verilirse;

1. Perseptron Modeli
2. Adaline Modeli
3. Madaline Modeli


Bu algılayıcıların en önemli problemleri, doğrusal olmayan olayları öğrenememeleridir. Bu nedenle yeni modeller oluşturulmuştur [46-48].

2.2.2. Çok katmanlı algılayıcılar

TKA’larda yaşanan doğrusal olmayan problemleri çözememe sorununu ortadan kaldırmak için Çok Katmanlı Algılayıcılar (ÇKA) geliştirilmiştir. Olayın doğrusallığı, çıktılar arasında doğru veya doğrular çizerek iki veya daha fazla sınıfa ayıramamak anlamına gelir. Buna en iyi örnek EXOR probleminin çözümlenmesidir.

Hemen hemen her kaynakta EXOR probleminden bahsedilmesinin nedeni, basit algılayıcıların bu probleme çözüm getiremediği ispat edilmiş ve yapay sinir ağlarının doğrusal olmayan problemlere çözüm üretmediği iddia edilerek bilimsel araştırmaların durdurulmasına neden olmuştur. Çünkü günlük olayların çoğu doğrusal olmayan nitelik taşımaktadırlar.

EXOR problemi yapılan araştırmalar neticesinde çok katmanlı algılayıcılar (Şekil 2.2) tarafından çözümlenmiştir. Bu model, günümüz mühendislik problemlerinin çoğuna çözüm getirebilecek niteliktedir. Özellikle tanıma, sınıflandırma ve genelleme yapmayı gerektiren problemler için önemli bir çözüm aracıdır. Bu model Delta Öğrenme Kuralı denilen bir öğrenme yöntemi kullanmaktadır [46].



Şekil 2.2. Çok katmanlı YSA modeli

2.2.3. Girdi katmanı

Dış dünyadan gelen girdileri (G_1, G_2, \dots, G_N) olarak ara katmana gönderir. Bu katmanda herhangi bir bilgi işleme olmaz. Birden fazla girdi olabilir. Bu katmandaki her proses elemanı bir sonraki katmandaki proses elemanının hepsine bağlıdır.

2.2.4. Ara katmanlar

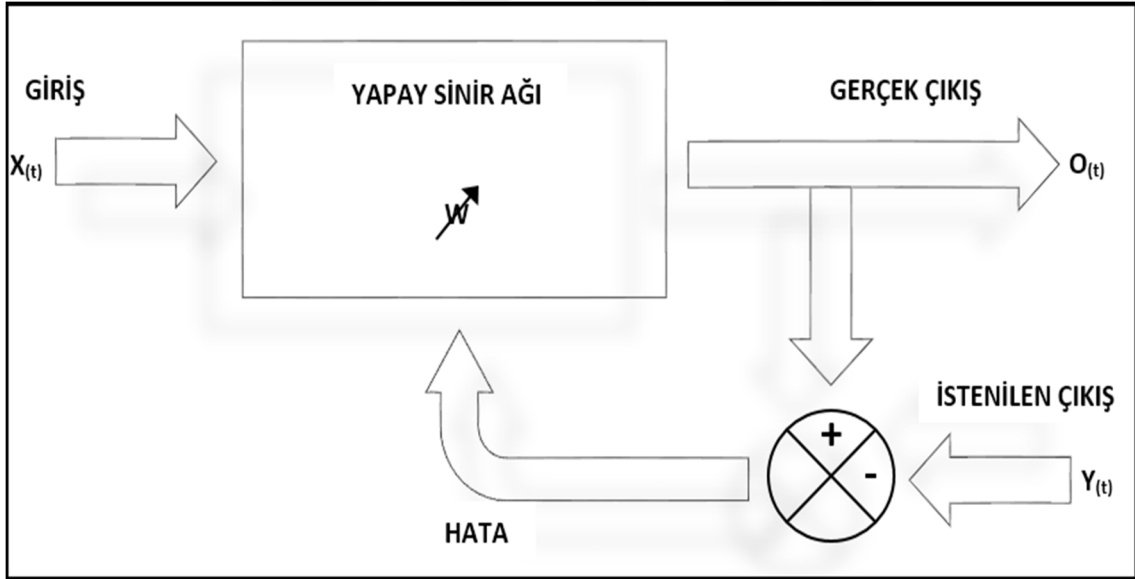
Bu katmanlar girdi katmanından gelen bilgileri işleyerek bir sonraki katmana gönderir. Bir ÇKA ağında birden fazla ara katman ve proses elemanı olabilir. Bu katmanda bulunan proses elemanları bir sonraki katmanda bulunan tüm proses elemanlarına bağlıdır ve proses eleman sayısı bakımından ise hiçbir bağıllığı yoktur. Ara katman sayısı ve ara katmanda bulunan proses elemanının sayısının fazla olması ağın hesaplama süresini ve işlem karışıklığını arttırmasına rağmen ağın daha karmaşık problemlerin çözümünde kullanılmasını sağlar.

2.2.5. Çıktı katmanı

Ağa girdi katmanından verilen girdilere karşın, ağın ürettiği çıktıları belirleyip dış dünyaya gönderen katmandır. Geri beslemeli ağlarda buradaki çıktı değerleri kullanılarak ağın yeni ağırlıkları hesaplanır.

2.2.6. Öğrenme algoritmasına göre YSA sınıflandırılması

Literatürde iki tip öğrenme stratejisinden bahsedilmektedir. Bunlar öğreticili öğrenme (Şekil 2.3) ve öğreticisiz öğrenme olarak isimlendirilmektedir [46]. İki sınıf arasındaki temel farklılık istenen çıkış değerinin mevcut olup olmamasıdır. Eğer bir eğitici, sistem çıkışlarının istenen değerini temin ediyorsa bu tip öğrenme (Şekil 2.3)'te gösterildiği gibi birinci grupta yer alır.




Şekil 2.3. Öğreticili (Danışmanlı) öğrenme yapısı

Bu tip öğrenmede, ağa örnek olarak setten bir çıkış verilir. İstenilen değer ile ağ çıktısı arasındaki farka (hataya) göre katmanlar arası ağırlık bilgileri istenilen çıkışa uygun olacak şekilde yeniden düzenlenerek güncellenir. Bu tip algoritmalarda ağın danışmana veya öğretmene ihtiyaç duymasının nedeni de budur. BP (Back Propagation) algoritması, delta kuralı danışmanlı öğrenmeye örnek olarak gösterilebilir.

Öğreticisiz öğrenme algoritmaları daha çok, sistemin geçmişte karşı karşıya kaldığı veri kümesinin içerdiği istatistiksel bilgilerin çıkarımını amaçlar. Böylelikle çok elemanlı veri kümeleri içerisinde deneyim yoluyla bilgi genelleştirmeleri yapılabilir. Bisiklet sürmeyi öğrenmeye çalışan bir çocuk önceki denemelerindeki yanlış hareketlerin sonuçlarını gözlemleyerek bir sonraki denemede bu deneyimlerden faydalanır. İstenen denge koşulları her ne kadar kuramsal olsa da çocuğun yaptıkları önceki hataları tekrarlamamaktan öteye gitmez. Bisiklet sürme, öğreticisiz öğrenmeye uygun bir örnektir. Öğreticili öğrenmede istenen bilginin temin edilebileceği bir kaynak mevcuttur [47]. ART (Adaptive Resonance Theory), SOM (Self Organizing Map) öğrenme kuralı danışmansız öğrenmeye örnek olarak verilebilir.

2.2.7. Nöron dinamiği ve aktivasyon fonksiyonları

Nöronlar sinir ağlarının oluşturan, tek başlarına ele alındıklarında çok basit işleve sahip işlemcilerdir. Bir nöron üç ana bölümden oluşmaktadır. Bunlar sırasıyla sinapslar, toplayıcı ve aktivasyon fonksiyonudur [47]. Şekil 2.4'te bir nöronun modeli gösterilmektedir.



Şekil 2.4. X_i girişli bir yapay nöronun grafik gösterimi

Bu şekilden de görülebileceği gibi nöron girdileri sinaptik bağlantılar üzerindeki ağırlıklar ile çarpılarak toplayıcıya uygulanmakta ve elde edilen toplam, nöronun aktivasyon fonksiyonundan geçirilerek çıkışlar hesap edilmektedir. Şekil 2.4'te x girişleri, y çıkışı, F fonksiyonu, p nöron giriş sayısını, n çıkış sayısını ve w ağırlıkları ifade eder. Girişler dış

kaynaklardan veya diğer işlemci elemanlarından gelen işaretlerdir. Bu işaretler, kaynağına göre kuvvetli veya zayıf olabileceğinden ağırlıkları da farklıdır.

YSA'da girilen giriş değerine önce toplama fonksiyonu uygulanır ve her bir işlem elemanının çıkış değeri y 'nin hesaplanması için öncelikle;

$$v = \sum_{k=1}^n x_i w_{ij} - \theta_i \quad (2.1)$$

bulunur. Burada;

x_i : i'inci giriş

w_{ij} : j'inci elemandan i'inci elemana bağlantı ağırlığını

θ_i : eşik değerini göstermektedir.

Bu çıkış değeri sigmoid bir aktivasyon fonksiyonuna uygulanırsa çıkış değeri;

$$y = F(v) = \frac{1}{1 + e^{-v}} \quad (2.2)$$

eşitliği ile bulunur. Çıkış değerinin hesaplanması işlemci eleman çıkışında kullanılan sigmoid fonksiyonuna göre hesaplanır. Bu işlemci elemanının çıkış değeri diğer işlemci elemanlarına giriş veya ağırlık çıkış değeri olabilir.

Aktivasyon fonksiyonları

Transfer veya aktivasyon fonksiyonları öğrenme eğrisi olarak da adlandırılmaktadır. Aktivasyon fonksiyonları bir YSA'da nöronun çıkış genliğini, istenilen değerler arasında sınırlar. Bu değerler çoğunlukla $[0,1]$ veya $[-1,1]$ arasındadır. Ayrıca bir yapay sinir ağına bir kutuplama (bias) değeri uygulanarak aktivasyon fonksiyonu arttırılabilir. Yapay sinir ağlarının doğrusal olmama özelliği aktivasyon fonksiyonlarının doğrusal olmamasından kaynaklanmaktadır [46,47].


Geri beslemeli ağlarda aktivasyon fonksiyonlarının türevi alındığı için türevi alınabilen ve süreklilik arz eden fonksiyonların kullanılması gerekmektedir. Transfer fonksiyonlarında ise genellikle tanjant hiperbolik fonksiyonu veya sigmoid fonksiyonu kullanılmaktadır. Bu

doğrusal olmayan fonksiyonların YSA’larda kullanımı matematiksel formüllerle modellenmesi güç ve karmaşık bir çok probleme uygulanabilmesine olanak sağlamıştır. YSA’nın kullanım amacına uygun olarak tek veya çift yönlü aktivasyon fonksiyonları da kullanılabilir. YSA’larda en çok kullanılan aktivasyon fonksiyonları doğrusal aktivasyon fonksiyonu, basamak aktivasyon fonksiyonu, sigmoid aktivasyon fonksiyonu, tanjant hiperbolik aktivasyon fonksiyonudur.

Doğrusal Fonksiyon

YSA’ların çıkış katmanında kullanılan aktivasyon fonksiyonlarından doğrusal fonksiyon işlemci elemanının girişini doğrudan işlemci elemanının çıkışı olarak yansıtır. Bu işlemci elemanı genellikle klasik işaret işleme ve istatistiksel regresyon analizinde kullanılır. Şekil 2.5’te doğrusal fonksiyon grafiği gösterilmektedir.

Plot:



Şekil 2.5. Doğrusal (Lineer) fonksiyon grafiği


Formülü ise;

$$y = Vx \quad (2.3)$$

Burada, V sabit katsayıdır.

Basamak Fonksiyon

Basamak fonksiyonu tek veya çift kutuplu olabilmektedir. Şekil 2.6’da da görüldüğü gibi sınırları belirlenmiş bir “x” aralığı için fonksiyon “1” yada “0” değerini almaktadır.




Şekil 2.6. Basamak fonksiyon grafiği

Sigmoid Fonksiyon

YSA uygulamalarında en çok kullanılan aktivasyon fonksiyonudur. Sigmoid fonksiyonun davranış eğrisi Şekil 2.7’de görüldüğü gibidir. Şekilden de anlaşılacağı gibi bu fonksiyonunu en aktif bölgesinin 0,2 ile 0,8 arasında olduğu görülmektedir. Formülü ise;

$$y = \frac{1}{1 + e^{-v}} = \frac{1}{2} (\tanh(v/2) + 1) \quad (2.4)$$




Şekil 2.7. Sigmoid fonksiyon grafiği

Tanjant Hiperbolik Fonksiyon

YSA uygulamalarında en çok kullanılan diğer aktivasyon fonksiyonlarından bir diğeri ise tanjant hiperbolik fonksiyondur. Literatürde çift kutuplu (bipolar) fonksiyon olarak da bilinir. Şekil 2.8’de fonksiyon grafiği verilmiştir. Daha geniş bir giriş uzayında çalışabilmeyi sağlayan aktivasyon fonksiyonudur. Formülü ise;

$$y = \tanh(v) = \frac{e^v - e^{-v}}{e^v + e^{-v}} \quad (2.5)$$



Şekil 2.8. Tanjant hiperbolik fonksiyon grafiği

Yapay Nöron (İşlemci Eleman)

YSA modelinin temelini oluşturan yapay nöron Şekil 2.8.’de gösterildiği gibi girişler dış kaynaklardan veya diğer işlem elemanlarından gelen işaretlerdir. Bu işaretlerin şiddeti kuvvetli veya zayıf olabileceğinden dolayı ağırlıkları da farklıdır. YSA giriş değerlerine Şekil 8.’de belirtildiği gibi önce toplama fonksiyonu uygulanır ve her bir işlem elemanı için çıkış değeri hesaplanır. Bu konu detaylı bir şekilde daha sonraki başlıklar altında incelenmektedir.

2.2.8. YSA ile hesaplamann özellikleri

YSA’nın hesaplama özelliklerini, paralel dağılmış yapısından, öğrenebilme ve genelleme yapabilme yeteneğinden aldığı bilinmektedir. Genelleme yapma özelliği YSA’ya, daha önce

veya örgenim süresi boyunca karşılaşmadığı girişlere uygun tepki verme avantajını kazandırmaktadır [48].

2.3. Çok Katmanlı Algılayıcı Öğrenme Kuralı

Çok katmanlı algılayıcılardan (ÇKA) oluşmuş ağlar öğretmenli öğrenme stratejisine göre çalışırlar. Yani bu ağlara eğitim sırasında hem girdiler hem de girdilere karşılık gelmesi gereken çıktılar gösterilir.

Ağın öğrenme kuralı ise genelleştirilmiş Delta Kuralına dayanır. Ağın öğrenmesi için örneklerden oluşan bir eğitim setine ihtiyacı vardır [49]. Genelleştirilmiş Delta Kuralı iki safhadan oluşur;

1. İleri doğru Hesaplama Safhası : Ağın çıktısı hesaplanır.
2. Geriye Doğru Hesaplama Safhası : Ağırlıkları değiştirme safhasıdır.

2.3.1. İleri doğru hesaplama

Girdi Katmanındaki k. Proses elemanının çıktısı C_k^i şu şekilde belirlenir.

$$Net_j^a = \sum_{k=1} A_k^j C_k^i \quad (2.6)$$

Burada A_k^j , k. Girdi katmanı elemanını, j. Ara katman elemanına bağlayan bağlantının ağırlık değerini gösterir (çok katmanlı ağ modeli örnek çizimi). j. Ara katman elemanının çıktısı ise bu net girdinin aktivasyon fonksiyonundan (genellikle sigmoid fonksiyondur) geçirilmesi ile hesaplanır [4,48,49].

$$Net_j^a = x, \beta_j^a = y \quad (2.7)$$

$$C_j^a = \frac{1}{1 + e^{-(x+y)}} \text{ şeklindedir.} \quad (2.8)$$

Burada β_j , ara katmanda bulunan j. elemana bağlanan eşik değer elemanın ağırlığını göstermektedir. Bu eşik değer ünitesinin çıktısı sabit olup 1'e eşittir. Ağırlık değeri ise sigmoid fonksiyonunun oryantasyonunu belirlemek amacı ile konulmuştur. Eğitim

esnasında ağ bu değeri kendisi belirlemektedir. Çıktıları bulununca ağın ileri hesaplama işlemi tamamlanmış olur.

2.3.2. Geriye doğru hesaplama

Ağa sunulan girdi için ağın ürettiği çıktı, beklenen çıktıları ile karşılaştırılır. Bunların arasındaki fark hata olarak kabul edilir. Amaç bu hatanın düşürülmesidir. Bu nedenle geriye doğru hesaplamada hata ağın ağırlık değerine dağıtılarak bir sonraki iterasyonda hatanın azaltılması sağlanır. Çıktı katmanındaki m'inci proses elemanı için oluşan hata (E_m).

$E_m = B_m - C_m$ olacaktır. Bu bir süreç elemanı için oluşan hatadır. Toplam hata ise;

$$TH = \frac{1}{2} \sum_m E_m^2 \quad (2.9)$$

ÇKA'nın (Çok Katmanlı Ağ) eğitilmesindeki amaç bu hatayı en aza indirmektir. Ağın ağırlığı iki şekilde değiştirilir.

- a. Ara katman ile çıktı katmanı arasındaki ağırlıkların değiştirilmesi
- b. Ara katmanlar arası veya ara katman girdi katmanı arasındaki ağırlıkların değiştirilmesi.

2.3.3. Öğrenmeyi etkileyen faktörler

Bu faktörler dikkatlice tasarımcı tarafından değerlendirilmeli ve problemin çözümü için en doğru yaklaşım kullanılmalıdır [4,46,47].

1. Örneklerin seçilmesi
2. Girdi ve çıktıların ağa sunulması
3. Girdi ve çıktıların sayısal gösterimi
4. Ağırlıkların başlangıç değerlerinin atanması
5. Öğrenme katsayısı (λ) ve momentum (α) katsayılarının belirlenmesi
6. Örneklerin ağa sunulması
7. Ağırlıkların değiştirilme zamanları

8. Girdi ve çıktıların ölçeklendirilmesi
9. Durdurma kriterinin belirlenmesi
10. Ağların büyütülmesi ve budanması

2.3.4. Yapay sinir ağlarının özellikleri

Yapay sinir ağlarını önemli kılan özelliklerin başında öğrenme ve öğrendiklerini genelleme yeteneği gelmektedir. Genelleme yeteneği, YSA'nın hiç görmediği örnekler karşısında dahi kabul edilebilir çıktı üretmesine yardımcı olur. Bu üstün özellikleri, YSA'nın birçok karmaşık problemler karşısında çözüm üretmesine neden olur. Günümüzde ise YSA'nın birçok bilim alanında kendine yer edinmesi aşağıda sıralanan özellikleri kendisinde barındırması ile mümkün olmuştur.

Doğrusal olmama

Temel işlev elemanı olan nöronun (Proses Elemanı) içerdiği doğrusal olmayan fonksiyonlardan dolayı YSA ağı da doğrusal olmamaktadır. Bu yetkinlik YSA'nın doğrusal olmayan karmaşık problemlere yaklaşımını da kolaylaştırmaktadır.

Öğrenme

YSA'nın istenen sonucu üretebilmesi için önceden nöronların birbirleri ile doğru ilişkilendirilmesi ve nöronlar arası ağırlıkların uygun şekilde başlangıç ayarlarının edilmesi gerekmektedir. Bu ayarlamalar ise YSA'nın önceden probleme ait herhangi bir örnek seti ile karşılaştırılıp uygun ağırlıkları üretmesi ile sağlanabilir.

Genelleme yapma

YSA'nın eğitiminin uygun koşullar sağlanıp tamamlanmasının ardından, eğitim seti içerisinde hiç görmediği bir probleme doğru sonuç üretebilmesi mümkündür.

Adaptasyon

YSA, karşılaştığı problemlerdeki değişikliklere göre ağırlıklarını ayarlayarak problemlerdeki değişikliklere adaptasyon sağlayabilir. Bu özelliği ile de YSA, sistem kimliklendirme, denetim, işaret işleme, otomatik kontrol, modelleme gibi bir çok alanda etkin olarak kullanılabilir.

Veri İşleme

YSA'da veriler, ağırlıklar üzerine paralel olarak dağıtılmış şekilde temsil edilmekte, korunmakta ve işlenmektedir. Ağırlıklar, herhangi bir anda YSA'nın problemle ilgili olarak sahip bulunduğu bilgiyi ifade eder. YSA da veri dağıtılmış birleşik hafıza yapısı kullanılır ve bilgi farklı formlara dönüştürülerek işlenebilir [47].

Hataya ve Gürültüye Karşı Duyarlılık ve Tolerans

YSA'nın genelleme yeteneği YSA'ya uygulanacak olan testlerle sınırlanır. Giriş katında sunulan verilerin bir veya bir kaçının eksik gelmesi ile ağ, doğru çıkış verilerini kabul edilebilir doğrulukta üretebilmektedir. YSA, kendi hesaplamalarından kaynaklanan hata toleransını sürekli yok etmeye çalışmaktadır. Bu özellik ağa klasik hesaplamalara göre üstünlük kazandırmaktadır. Klasik hesaplamalara göre hatayı daha iyi tolere edebilmektedirler.

2.4. Yapay Sinir Ağlarının Kabiliyetleri

Günümüzde, yapay sinir ağlarının güncel, çok kullanılabilir sınıflandırıcı ve örüntü tanıyıcı olarak kullanılmalarının nedeni eksik bilgiler ile çalışabilme ve eksik veri girişlerine rağmen beklenen çıkışları üretebilmeleridir. Bu özellik yapay sinir ağlarına bir çok endüstriyel alan ve sosyal hayat içerisinde kullanım imkânı vermekte ve YSA'ları bu alanlarda başarıya götürmektedir.

2.5. Yapay Sinir Ağlarının Uygulama Alanları

Yapay sinir ağlarının başarılı oldukları birçok uygulama incelendiğinde gürültülü, karmaşık, doğrusal olmayan, kesinliği belli olmayan, hata olasılığı yüksek, matematiksel bir model

üzerine oturtulamayıp kendine ait algoritması bulunmayan problemlerde kullanıldığı dikkat çekmektedir. YSA'ların uygulama alanlarını kısaca aşağıdaki gibi sıralayabiliriz.

- Tahmin etme
- Sınıflandırma
- Veri sıkıştırma
- Veri yorumlama
- Veri filtreleme
- Resim veya görüntü işleme
- Zaman serileri analizleri
- Doğrusal olmayan sinyalleri işleme
- Doğrusal olmayan sistem modelleme
- Optimizasyon
- Zeki ve doğrusal olmayan kontrol

2.6. Yapay Sinir Ağlarının Uygulamaları

Yapay sinir ağları uygulamalarını, genel bir sınıflandırma ile;

- Endüstriyel uygulamalar
- Ulaştırma ve havacılık
- Finans, borsa, kredi kartı uygulaması
- Tıp, biyomedikal ve ilaç sanayi uygulamaları
- İletişim sanayi uygulamaları
- Mühendislik uygulamaları olmak üzere 6 grupta toplayabiliriz. Bu gruptaki uygulamalardan karışık sıra ile bahsedecek olursak aşağıdaki maddeleri çıkarabiliriz:
- Veri madenciliği
- Optik karakter tanıma ve çek okuma
- Bankalardan kredi isteyen müracaatları değerlendirme
- Ürünün pazardaki performansını tahmin etme
- Kredi kartı hilelerini saptama
- Zeki araçlar ve robotlar için optimum rota belirleme
- Güvenlik sistemlerinde konuşma ve parmak izi tanıma
- Robot hareket mekanizmalarının kontrol edilmesi
- Mekanik parçaların ömürlerinin ve kırılmalarının tahmin edilmesi

- Kalite kontrolü
- İş çizelgeleme ve iş sıralaması
- İletişim kanallarındaki gereksiz ekoların filtrelenmesi
- Trafik yoğunluğunu kontrol etme ve anahtarlama
- Radar ve sonar sinyalleri sınıflandırma
- Üretim planlama ve çizelgeleme
- Kan hücreleri reaksiyonları ve kan analizlerini sınıflandırma
- Beyin modellenmesi çalışmaları
- Havacılık ve uzay alanlarında yüksek performanslı oto-pilot geliştirme çalışmalarında, uçuş kontrol sistemlerinde, ve simülasyon cihazlarında
- Otomotiv sektöründe oto-rehberlik uygulamaları geliştirmede
- Hedef tanıma, hedef izleme, silah oryantasyonu, sayısal görüntü işlemede
- Tıpta teşhis ve bioistatistiksel ilişkilerin aranmasında
- Yüzey modelleme, yol ve hız tahmininde
- Coğrafi bilgi sistemlerinde hareketli cisimlerin izlenmesi, konum ve durumlarının tahmininde
- Cad/Cam uygulamalarında yüzey interpolasyonu, yüzey izleme, yüzey modelleme uygulamalarında
- Meteorolojide hava tahmin algoritmalarının geliştirilmesinde, yağmur yükünün tahminlerinde ve daha birçok uygulamalarda başarıyla kullanılmaktadır.

3. MATERYAL VE METOD

Bu çalışma ile demir çelik sektörü içerisinde önemli yer tutan elektrikli ark ocaklı hurda ergitme tesisi (Çelikhane) ve çelikhane de eğitilmiş sıvı çeliğin slab yarı mamulüne dönüştürüldüğü Sürekli Döküm Makinelerinde (SDM) bulunan fonksiyonel ekipmanlarda daha kararlı şartların sağlanması ve yaşanan kronik problemlere daha etkin çözüm üretebilmek adına farklı mimarilerdeki YSA'ların çeşitli veri setleri ile eğitilmesi ve sonuçlarının karşılaştırılarak YSA'nın veri modellemesi ve tahmin özellikleri üzerinde durulmuştur.

3.1. Elektrikli Ark Ocakları

Tez içeriğinde sorun olarak ele alınan EAF elektrot regülasyonu için kullanılan elektrikli ark ocağının kapasitesi Türkiye'de bulunan ocaklar arasında orta sınıf ile üst sınıf arasına girmektedir. Çalışmayı yapmış olduğumuz makine, 160 ton kapasitede ve 156 MVA kısa devre özellikli trafoya sahip bir ocaktır. Ocağın elektrot tahrikini sağlayan valfler ise oransal kontrollü valflerdir. Her elektrot için ayrı olacak şekilde tasarımı yapılmıştır.

EAF elektrot kontrol sistemi ise Siemens marka S7 – 400 PLC ile kontrol edilmektedir. Valflere oransal çıkış bilgisi PLC'nin analog çıkışlardan (+10V) – (-10V) olacak şekilde gönderilmektedir. Her bir elektrotta ait akım, gerilim, aktif güç, reaktif güç Siemens enerji analizöründen profibus protokolü kullanılarak PLC tarafından okunmaktadır. Diğer yardımcı üniteler ise (hidrolik motorları, sistem korumaları, kontrol komutları v.b) dağıtılmış uzak giriş – çıkış modülleri ile profibus haberleşme protokolü üzerinden kontrol edilmektedirler.

EAF faz akımlarının, faz gerilimlerinin, elektrot tahrik silindirlerinin gerilimlerinin, programlanabilir lojik kontrolör (PLC) çıkışlarının, empedans verilerinin, çeşitli formattaki dosyalardan okunup grafiğe dönüştürülmesi için EK-1de görülen Borland Delphi 7.0'da hazırlanmış ara yüz ile birlikte IbaPDA client – server yazılımı kullanılmıştır. Daha sonra bu veriler, YSA'ların eğitilebilmesi için uygun formata çevrilip, ağın eğitim işlemi başlatılmaktadır.

IbaPDA yazılımının kurulu olduğu bilgisayar, Microsoft Windows XP Pro. SP3 işletim sistemi ile çalışmakla beraber Intel® Core™2 Quad CPU Q950 @ 3.00 GHz işlemci ve 2.99GHz, 8GB RAM ve 300GB HDD hafızaya sahip donanımlardan oluşmaktadır.

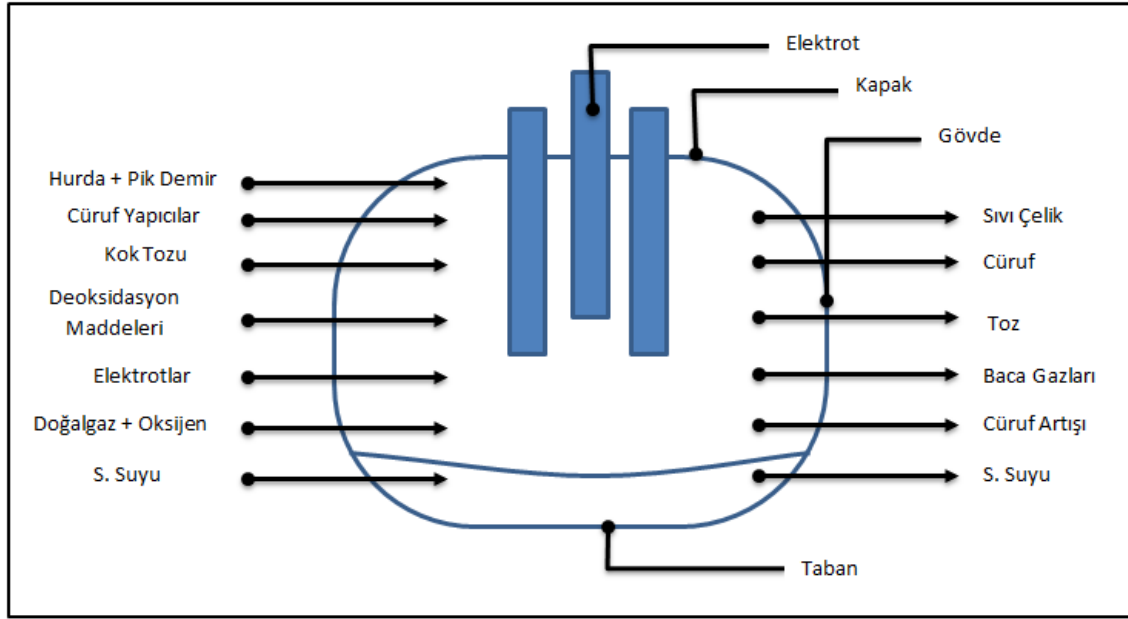
3.1. Elektrik Ark Fırınına Giren-Çıkan Maddelerin Şematik Gösterimi

Elektrik ark fırınından karbon çeliği üretimi için gerekli maddelerin birim miktarları Çizelge 3.1’de verilmiştir.

Çizelge 3.1 Elektrik ark ocağında üretilen örnek sıvı çelik analizi

Kimyasal Yapısı	Yüzde (%mi / mtop)	Üretilen Miktar (kg)	Birim Şarj Başına Çelik Miktarı (kg / kg)
Fe	98,863	55,116	0,8424
C	0,1	56	0,0009
Si	0,05	28	0,0004
Mn	0,36	201	0,0031
P	0,015	8	0,0001
S	0,04	22	0,0003
Cr	0,15	83	0,0013
Ni	0,123	69	0,0011
Mo	0,089	50	0,0008
Cu	0,21	117	0,0018
Toplam	100	55,75	0,8522

Fırına şarj edilen maddelerin toplam miktarı yaklaşık 65 tondur. Elektrik enerjisi, fırında arkın oluşmasını sağlayarak çeliğin ergitilmesinde önemli bir maliyet kalemidir.




Şekil 3.1. Elektrik ark fırınının şematik şekli ve fırına giren çıkan maddeler.

Fırına giren ve çıkan maddeler Şekil 3.1'den de anlaşılacağı gibi hurda, pik demir, cüruf yapıcı maddeler, deoksidasyon maddeleri, karbon elektrotlar, doğal gaz, oksijen, soğutma suyu giren maddeler olarak belirtilmekte, sıvı çelik, cüruf, toz, baca gazları, soğutma suyu ise çıkan maddeler olarak belirtilmektedir.

Kimyasal enerji, proses süresince yüksek sıcaklıklarda meydana gelen egzotermik reaksiyonlar sonucu açığa çıkan ısı enerjisidir.

3.1.2. Elektrik ark ocağı ve genel yapısı

EAF genel yapısı Şekil 3.3'te görüldüğü üzere elektrot (E1,E2,E3), Trafo (T) ile elektrotları tutan bakır barayı birleştiren hareketli kablo (C), Hidrolik aktüatör (H)'den oluşmaktadır.



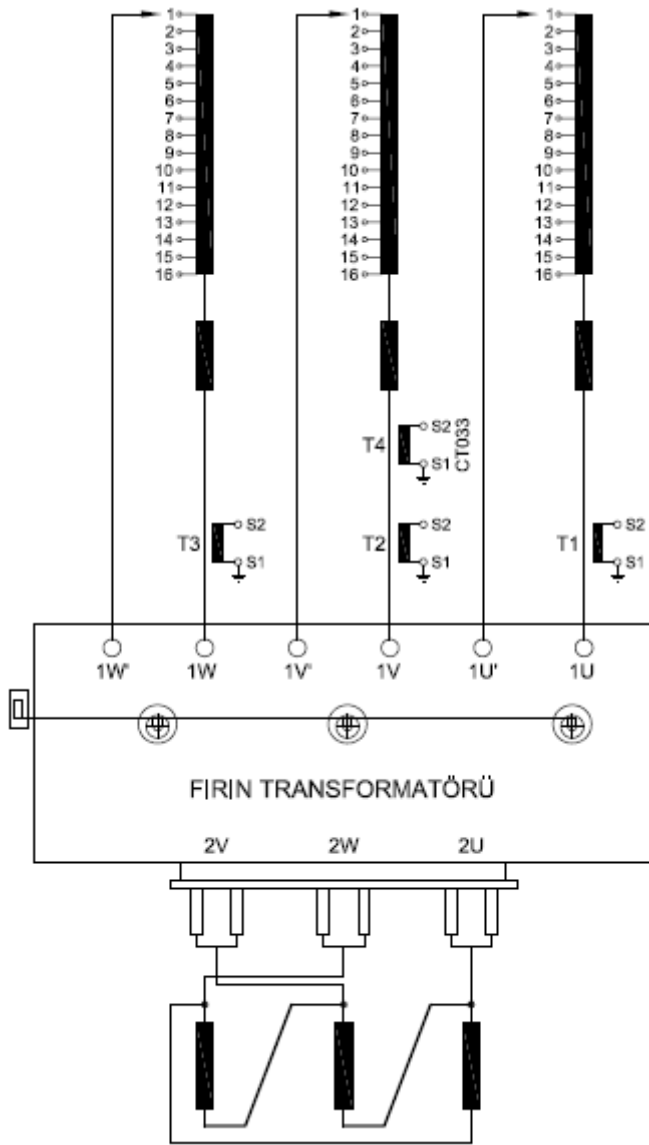
Şekil 3.2. EAF genel yapısı

Regülasyon sırasında hidrolik aktüatörler (H), elektrotların dikey hareketini sağlayarak ark boyunun ayarlanmasına yardımcı olurlar. Trafo sekunder sargılarının direncini ayarlayan yükte kademe değiştiriciler (J), kontrol sisteminden gelen bilgiler doğrultusunda pozisyonunu değiştirerek sekunder gerilimi ayarlar.

3.1.3. EAF trafosunun genel yapısı ve reaktör

Belirtilen EAF trafosu 3 fazlı, Dd0 bağlantı grubuna sahip, 16 kademeye sahip kademe değiştirici şalteri bulunan özel tip trafodur (Şekil 3.4). Şekilde görülen (T1, T2, T3) akım trafolarını, (T4) sargı sıcaklığını ölçen termometreyi, (1W-1W', 1U-1U', 1V-1V') yüksek gerilim sargı uçlarını, 2W, 2U, 2V ise alçak gerilim sargı uçlarını simgelemektedir. 1-16 arası rakamlar kademe pozisyon bilgisini çıkış uçları, S1 ve S2 ise akım trafolarının çıkış uçlarıdır.

Önceden set edilen set değerler PLC'de işlendikten sonra PLC'den gelen bilgiler doğrultusunda bir taraftan regülasyon işlemi gerçekleştirilirken, diğer taraftan senkron bir şekilde prosese uygun trafo kademesi seçilerek yükte gerilim değiştirilir.



Şekil 3.3. EAF transformatörü ve dahili bağlantısı

Trafo kademelerinin yükte değiştirilebilmesi, trafo yapısının ve kontak dizaynının bu operasyona uygun olmasından kaynaklanmaktadır. EAF transformatörünün kademe değerleri her kademe için Şekil 3.3.'te gösterilmiştir.

Çizelge 3.2. EAF fırın transformatörü kademe bilgileri

TRAFO DEĞERLERİ							
Tap	MVA	Ip/ A	Usec / kV	Isec / A	Ratio	%Uk	Xtr (sec) mohm
1	116,36	1947	0,848	79095,2	40,665	23,25	2,38
2	120,31	2013	0,877	79095,2	39,334	22,28	2,20
3	123,98	2075	0,904	79095,2	38,168	21,38	2,05
4	127,98	2140	0,932	79095,2	37,001	20,48	1,90
5	132,06	2210	0,953	79095,2	36,209	19,58	1,76
6	136,5	2284	0,995	79095,2	34,666	18,69	1,63
7	141,25	2364	1,030	79095,2	33,498	17,82	1,50
8	146,35	2449	1,087	79095,2	31,739	16,95	1,38
9	151,02	2527	1,101	79095,2	31,332	16,16	1,27
10	156	2611	1,137	79095,2	30,332	15,38	1,17
11	156	2611	1,170	76487,8	29,485	14,15	1,08
12	156	2611	1,211	74318,38	28,501	13,17	1,00
13	156	2611	1,247	72142,04	27,666	12,26	0,94
14	156	2611	1,286	69968,81	26,834	11,40	0,87
15	156	2611	1,319	68230,51	26,166	10,70	0,82
16	156	2611	1,353	66492,2	25,501	10,06	0,77

Trafo 16 kademeli olup her kademenin görünür gücü, primer akımı, sekonder akımı, primer gerilimi, sekonder gerilimi, çevirme oranı, gerilim düşümü ve reaktansı farklıdır. Bu değerler regülasyon hesabının yapılabilmesi için önemlidir. Hurdaya uygun güç transferinin yapılabilmesi için uygun kademenin seçilmesi, hesaplanmış empedans değerinin seçimi ve trafoda olduğu gibi reaktörde de uygun kademenin seçilmiş olması gerekmektedir. Bu parametrelere ek olarak stabil güç çekilebilmesi için regülasyon hızının da uygun değerlerde olması ekipman sağlığı ve enerji verimliliği açısından oldukça önemlidir.

Reaktör içinde trafoya benzer özellikleri sıralayabiliriz. Kullandığımız reaktör 12 kademeye sahip olup birinci kademe direk kısa devredir. Yani reaktörün primeri ile sekonderini kısa devre etmektedir. Başka bir deyişle reaktörü devre dışı bırakmaktadır. Bu kademenin bize sağladığı avantaj, ertitmeden sonraki aşamada (izabe) ocak içerisindeki çelik sıvı hali almış olduğundan regülasyon kararlı bir şekilde elektrotları hareket ettirecektir. Dolayısıyla ertitme esnasındaki kararsız elektrot hareketliliği yerini daha fazla güç ihtiyacına bırakacaktır. Reaktör kısa devre edilip bu ihtiyaç karşılanmaktadır. Ayrıca izabe aşamasında, ertitme aşamasına göre trafoyu etkileyecek harmoniklerin oranı da daha düşüktür.

Çizelge 3.3. EAF reaktörünün test sonucunda elde edilmiş kademe bilgileri


REAKTÖR DEĞERLERİ		
Tap	MVA _r	X _{reaktör}
1	0,00	0,00
2	6,69	1,07
3	13,25	2,10
4	17,50	2,80
5	20,63	3,30
6	24,06	3,85
7	27,68	4,43
8	31,68	5,07
9	35,62	5,70
10	40,00	6,40
11	45,00	7,20
12	50,00	8,03

Bilindiği gibi bobin, iletken telin üst üste veya yan yana sarılması ile üretilen devre elemanıdır. Birimi Henry (H), simgesi ise L'dir. Bobine AC akım uygulandığında, akımın yönü sürekli değiştiğinden dolayı bobin kendi etrafında manyetik alan oluşturur. Bu manyetik alan akıma karşı ek bir direnç gösterdiğinden AC devrelerde bobinin akıma karşı gösterdiği direnç artar. DC devrelerde ise bu direnç sargının üretilmiş olduğu metal özelliklerinden kaynaklanan omik dirençtir. AC ark ocaklarında kullanılan reaktörlerde AC olacağından dolayı kullanacağımız reaktörde trafo gibi ocak dizaynına uygun ve kademeli olmalıdır. Reaktörlerde nüvenin cinsi, tel kesiti, sarım sayısı, AC akımın frekansı bobinin indüktansını değiştiren faktörlerdir. Bobine AC akım uygulandığında bobinin indüktansına bağlı olarak değişen karşı koyma şiddetine indüktif reaktans denir. EAF'ta kullanılan reaktör de kademeli tip reaktör olup kademelerin değiştirilmesi ile indüktif reaktans ayarlanır. Nominal gerilimi 34.5 kV'tur. EAF fırın reaktörüne ait kademe bilgileri ve reaktansları Çizelge 3.3'te gösterilmiştir.

3.1.4. EAF genel yapısı ve enerji iletimi

Elektrikli ark ocakları, çanak, gövde, kapak ve mekanizması, gantry (Kapağı sağa sola hareket ettiren mekanizma), elektrot ve hareket grubu olmak üzere 5 ana parçadan oluşmaktadır. Çanak içerisine refrakter tuğla (Yüksek sıcaklığa dayanıklı malzeme) örülerek taban sıcaklığa karşı direnç kazandırılır. Sıvı çeliğin biriktiği yerdir. Gövde ocak içerisine alınan çelik hacmini arttırmaktadır. Soğuması su ile sağlanmaktadır. Gantry (Kızak) mekanizmasının görevi ise kapağın sağa açılma veya sola açılma hareketini sağlamaktır.

Kapakta gövde ile aynı şekilde yani su ile soğutulmaktadır. Kapağın üzerinde elektrotların ocak içerisinde çalışabilmesi için yürek denilen kısım bulunur. Elektrot grubu ise zemine yatay olarak yerleştirilen bakır taşıyıcı ve ucunda elektrotu kavrayan penselerden oluşur (Bkz. Şekil 3.4).



Şekil 3.4. EAF elektrotları ve taşıma grubu

Elektrotların ucundan pense aracılığı ile yatay bakır kolonlara, buradan da yüksek akım kabloları aracılığı ile duvar üzerindeki bağlantı gruplarına ve bağlantı gruplarından esnek baralar ile trafonun sekonder sargılarına bağlantı sağlanır. Duvar üzeri bağlantı elemanları ile trafo sekonder sargılarının irtibatı ise esnek baraların yardımı ile yapılmaktadır.

EAF reaktansının hesabında trafo çıkışı, yüksek akım kabloları, elektrot kolları ve kullanılan elektrot'a ait fazlar arasındaki merkezden merkeze uzaklıkların geometrik ortalaması, pitch circle iletken kesitleri, iletken çapları, iletken uzunlukları, şebeke frekansı, malzemenin cinsi

önemli parametrelerdir. EAF reaktansı hesaplanırken örnek ocağımızın verileri Şekil 3.5’de gösterilmektedir.

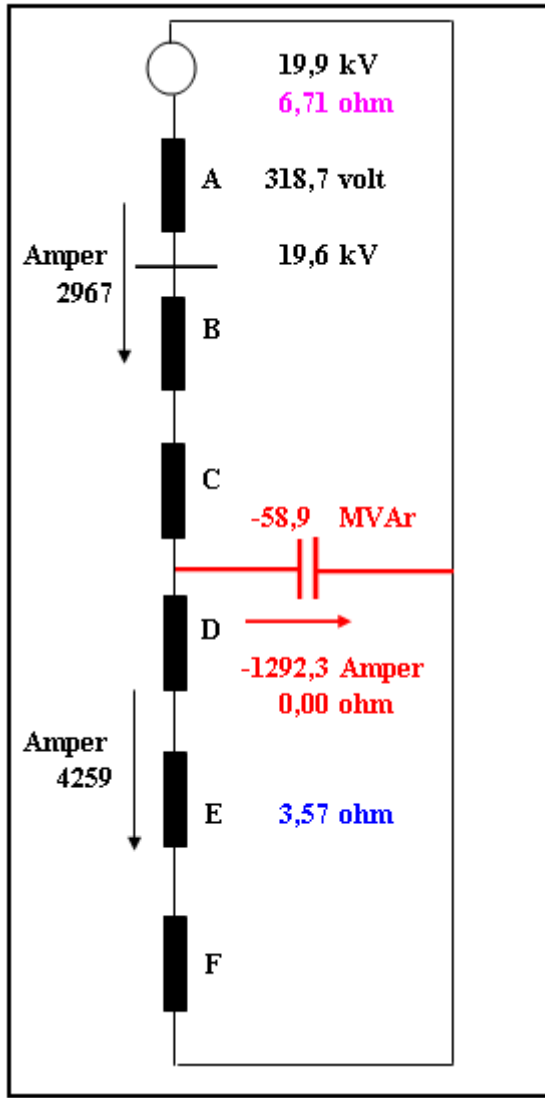
EAF REAKTANS HESABI									
		Trafo Çıkışı		Yüksek Akım		Elektrod Kolları		Elektrod	
Fazlar Arasındaki Merkezden Merkeze Uzaklık	d ₁₂	mm	1400	800	1169	585			
	d ₁₃	mm	1400	1600	1169	1169			
	d ₂₃	mm	1400	800	1169	585			
Geometrik ortalama	l _{geo}	mm	1400	1008	1169	737			
Pitch circle	PCD	mm	1670		1394				
İletken Kesiti	A	mm ²	17840	17840	17840	16665	292246		
İletken Çapı	R	mm	150,7	150,7	150,7	610,0			
İletken uzunluğu	l	cm	200	1360	651	361			
Şebeke frekansı	f	Hz	50	50	50	50			TOPLAM
Malzeme Cinsi			Cu	Cu	Cu	3	C		
İletkenin selfi	L	µH	1,269	4,643	2,416	-0,003	8,32		
İletkenin reaktansı	X	mOhm	0,399	1,459	0,759	-0,001	2,62		
İletkenin Direnci	R	µOhm	2,0	13,6	6,5	61,8	83,89		

Şekil 3.5. Çalışmada kullanılan ocağa ait teknik veriler

Burada hesaplanan ocağın reaktans değeri kademe analizlerinin yapılabilmesi için gereklidir.

3.1.5. EAF kısa devre hesabı

Kısa devre hesabı için öncelikle şalt tesisi yüksek gerilim trafolarından başlayarak elektrot ucuna kadar olan reaktanslar belirlenir ve bunlara göre kısa devre güçleri bulunur. Eşdeğer elektrik devresi Şekil 3.6’de gösterildiği gibidir.



Şekil 3.6. EAF elektrik eşdeğer devresi

Elektrik şebekesi tarafında (yüksek gerilim trafo primeri) kısa devre reaktansı (A), yüksek gerilim trafosunun sekonder tarafı reaktansı (B), yüksek gerilim trafo sekonderi ile EAF reaktörü arasındaki hat reaktansı (C), reaktör reaktansı (D), EAF trafosu primer tarafının reaktansı (E), EAF reaktansı (F), kırmızı hat ise SVC (Kompanzasyon Sistemi) olarak belirtilmiştir.

Primer gerilimi, şebeke kısa devre gücü, şebeke kısa devre gücünün verildiği gerilim, şebeke trafo primer gerilimi, şebeke trafo sekonder gerilimi, şebeke trafo gücü, şebeke trafo gerilim düşümü, hat uzunluğu, paralel hat sayısı, reaktör reaktansı, EAF trafo primer gerilimi, EAF trafo sekonder gerilimi, EAF trafo gücü, EAF trafo gerilim düşümü, EAF reaktansı, ortak

bağlantı noktası maksimum gerilim düşümü değerleri referans alınarak yapılan hesaplamada reaktanslar ve kompanzasyon gücü hesap edilir (Şekil 3.7).


Baz alınan noktanın gerilimi			kV	34,5	Vfnötür		19918,6 V	
Elek. Şebeke				X	Xt	Ikđ	Skđ	
A	Şebeke Kısa devre gücü	MVA	11080					
	Şebeke Kısa devre gücünün verildiği gerilim	kV	380	0,107	0,107	185421,48	11080,00	
B	Şebeke trafo primer gerilimi	kV	380					
	Şebeke trafo Sekonder gerilimi	kV	34,5					
	Şebeke trafo Gücü	MVA	125					
	Şebeke trafo gerilim düşümü %uk		15,4	1,466	1,574	12656,27	756,29	
C	Hat uzunluğu	km	0,65					
	Paralel hat sayısı		5	0,015	1,589	12535,13	749,05	
D	Reaktör reaktansı	ohm	2,8	2,800	4,389	4538,27	271,19	
E	EAF trafo primer gerilimi	kV	34,5					
	EAF trafo Sekonder gerilimi	kV	1,353					
	EAF trafo Gücü	MVA	156					
	EAF trafo gerilim düşümü %uk		10,06	0,768	5,157	3862,75	230,82	
F	EAF reaktans	mohm	4,31	2,802	7,959	2502,68	149,55	
TOPLAM REAKTANS			ohm		7,959			
KOMPANSASYON HESABI								
Ortak Bağ. Nok. Maksimum gerilim düşümü			%	1,6				
O.B.N da İstenilen Gerilim düşümü				318,7				V
Kompanzasyon gücü			Qc	26,44796885				MVAR
Şebekeden çekilen akım			Il	2966,743644				A
Şebeke ile komp. Arası Gerilim düşümü			Voc	4714,218798				V
Kompanzasyon noktasının gerilimi Faz			Vkomp	15204,4				V
Fabrika tarafı çekilen akım			I2	2386,910857				A
Kompanzasyon Akımı			Ic	579,832787				A
Şebekeden bakıldığındaki empedans			Z1	6,713955325				ohm
Komp sonrası eşeğer empedans			Z2	6,369892467				ohm
Komp empedansı			Zc	26,22198301				ohm

Şekil 3.7. Hat reaktansları ve kompanzasyon gücü hesap cetveli

3.2. Veri Toplama, Ağ Eğitimi ve Sınama

Elektrik ark ocağı elektrot tahrik silindirlerinin oransal valfleri +10V ile -10V arasında gerilim ile kumanda edilmekte bu gerilimler ile elektrotların hızları ve yönleri kontrol edilmektedir. Bu oransal valflere kumanda bilgileri Siemens marka S7-400 417 – 2DP tipi CPU'ya (Central Prosesor Unit) sahip PLC tarafından üzerinde modüler olan 8x13Bit


analog çıkış (AO) kartlarından gönderilmektedir. Aynı şekilde elektrotların sekonder akımları da 8x14Bitlik analog giriş (AI) kanalından okunup CPU’da gerekli scale ve hesaplama işlemlerinden sonra değerlendirilmektedir.



Şekil 3.8 EAF trafosundan analog akım bilgisinin alınması

Yukarıdaki şekilden de anlaşılacağı gibi EAF baralarında bulunan 1000/100V çevrim oranlı akım trafolarından (T1, T2, T3) alınan analog bilgi, ADC (Analog dijital çevirici) haberleşme kartında dijital bilgiye çevrilip profibus protokolü (Siemens Seri Haberleşme) kullanılarak regülasyon bilgisayarına aktarılmaktadır. Regülasyon bilgisayarı ile elektrot tahrik sistemlerinin oransal valflerini kontrol eden PLC arasındaki haberleşme TCP/IP (Ethernet) protokolü kullanılarak sağlanmıştır. Hidrolik ekipmanlar ve saha prosesi ve güvenliğini sağlayan diğer enstrümanların kontrolü ise dağıtılmış uzak giriş - çıkışlar ile

profibus üzerinden CPU'ya taşınmakta ve kontrolü sağlanmaktadır. Şekil 3.9'de haberleşme ağına ait diyagram gösterilmektedir.

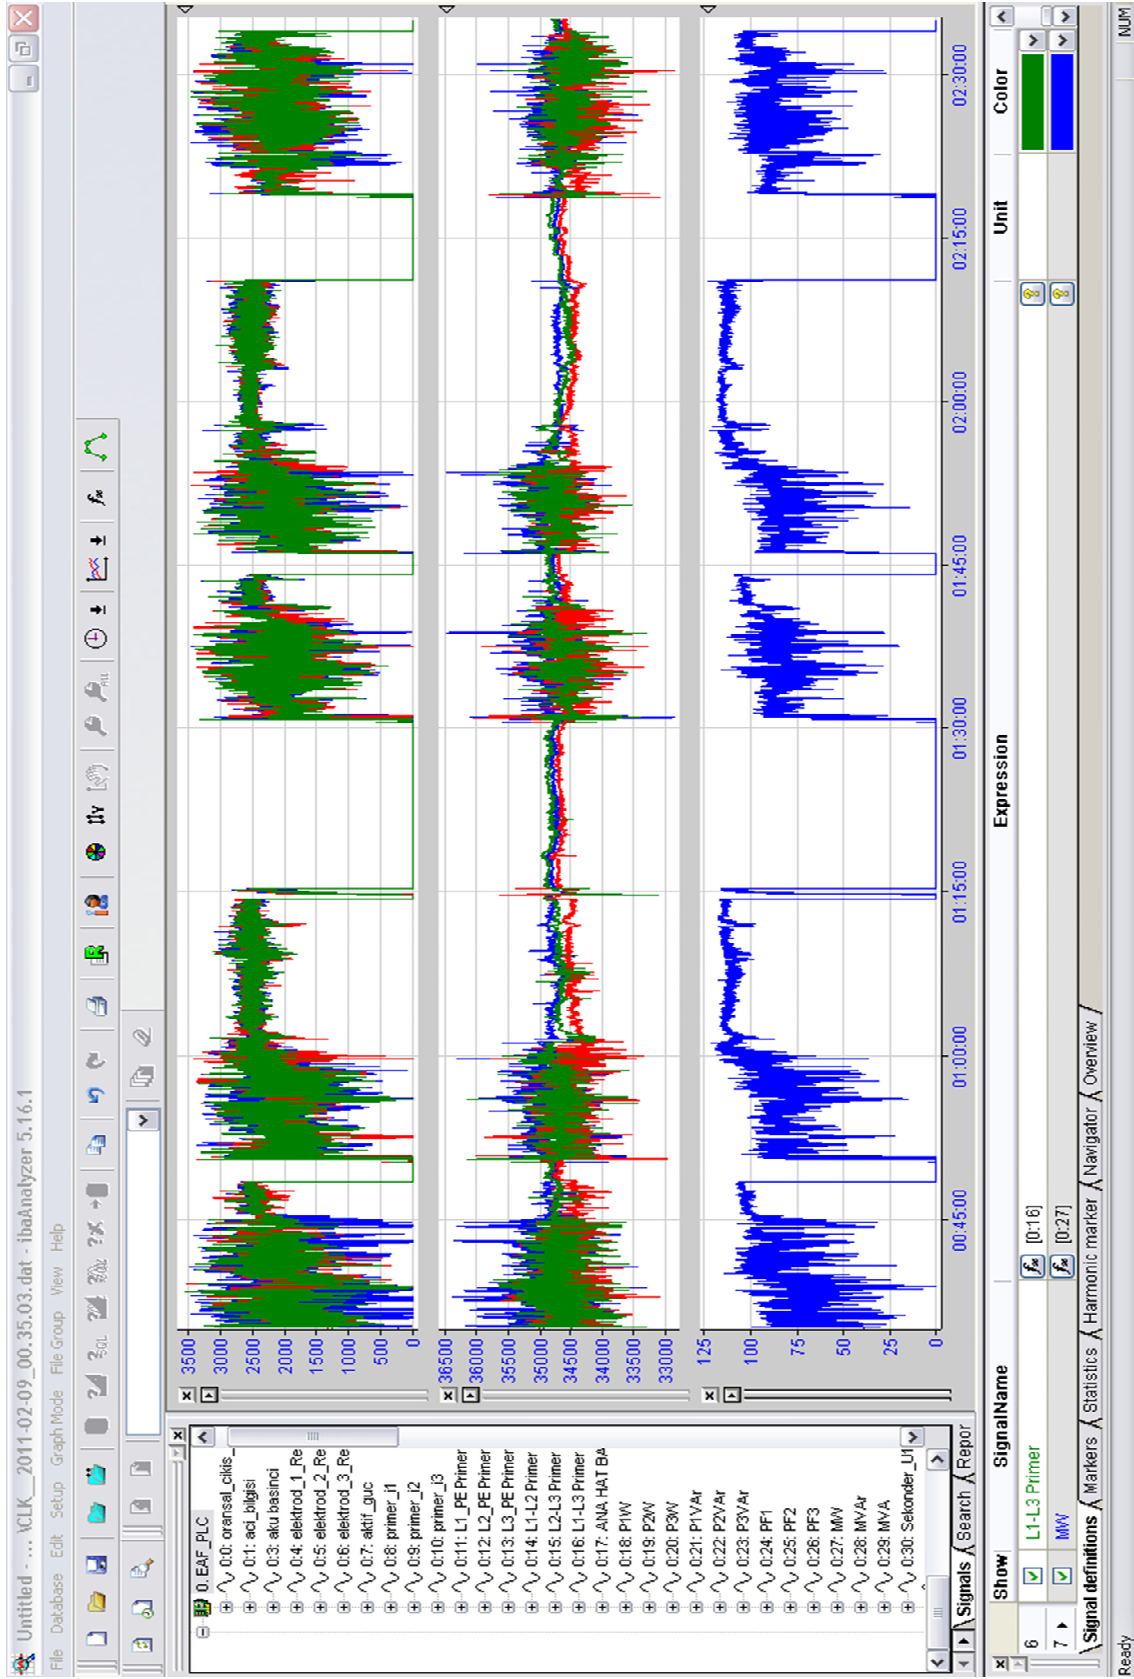


Şekil 3.9. EAF ve diğer saha enstrümanlarının haberleşme ağı

Şekil 3.9'deki resimde pembe renkli hat profibus ağını, yeşil renkli ağ ise ethernet ağını belirtmektedir.

3.2.1. EAF plc'den verilerin alınması

EAF PLC'den YSA'da inceleyip veri setlerinin oluşturulabilmesi amacıyla dataların alınması için EAF PLC'sinin ethernet ağına iba sunucu isimli bilgisayar ve bu bilgisayara kurulu ibaPDA Analyzer isimli yazılım bulunmaktadır. Bu bilgisayar, PLC verilerini 10 msn örnekleme zamanı ile izleyebilme imkânı sağlamaktadır. Fakat S7 400 CPU'nun ortalama 1 örnekleme süresi 200 msn'dir. Dolayısıyla bu yazılımın kurulmuş olduğu bilgisayar, veri kaydının yüksek doğrulukta incelenmesini mümkün kılmaktadır. Şekil 3.10'de bir döküme ait bazı veri grafiklerinin iba analyzer programı ile birlikte resmi gösterilmektedir.



Şekil 3.10. Iba analyzer programı ile bir döküme ait veri setlerinin görünümü

Kayıt bilgisayarında EAF'a ait şu bilgiler kayıt altında tutulmaktadır;

- Ocak devirme için oransal çıkış
- Ocak açılı bilgisi
- Hidrolik Akü basıncı
- Elektrotlara ait referans çıkışları
- Aktif güç
- Reaktif güç
- Görünür güç
- Primer akımlar
- Sekonder akımlar
- Faz-Faz, Faz-Nötr gerilimler
- Ana hat hidrolik basınçları
- Güç faktörü
- Trafo kademeleri
- Reaktör kademeleri
- Elektrot basınçları
- Döküm numaraları
- Karbon, oksijen, doğal gaz miktarları
- Elektrotların altına gelen yalıtkan malzeme sayısı
- Döküm başladı ve döküm bitti
- Elektrotlar döküm pozisyonu
- Hidrolik yağ seviyeleri ve diğer ön şartlar da olmak üzere bizim konu içerisinde kullanacaklarımızı sıralayabiliriz

İba analyzer programı ile bilgisayarın sabit diskine kaydedilen veriler, yine aynı program ile açılıp incelenebilmekte ve grafikler üzerinde yorum yapılabilmektedir. Ayrıca gereken durumlarda grafiklere matematiksel işlemlerde uygulanabilmektedir. Grafiğe ait 3D wireframe ve surface görünüm elde edilebilmekte, sinyaller filtrelenebilmekte, grafikler zaman bazlı ve fast fourier bazlı dönüştürülebilmektedir.

3.2.2. YSA yapısının seçilmesi

Uygun YSA yapısının veya mimarisinin seçilmesi uygulanacak olan problemin içeriğine göre değişkenlik göstermektedir. Bunun için hangi tip YSA yapılarının ne tür problemlerde

başarı gösterdiğini bilmek bizim açımızdan faydalı olacaktır. Daha önceki bölümlerde YSA uygulama alanlarından bahsedilmişti. MLP yapılarının bu çalışmada yapılan denemeler sonucunda yüksek performans gösterdikleri görülmektedir. Genellikle karmaşık uygulamalarda MLP mimarisinin başarılı sonuçlar verdiği de bilinmektedir.

3.2.3. YSA öğrenme algoritması ve aktivasyon fonksiyonu seçimi

YSA'nın başarısını yüksek oranda etkileyen faktörlerden biride öğrenme algoritmasıdır. YSA algoritmasının seçimi, problemin çözümü açısından belirlenmesi güç parametrelerden biridir. Öğrenme algoritmasının seçimi ağ mimarisi ile de ilişkilidir.

Aktivasyon fonksiyonu, YSA'lara doğrusal olmama özelliği kazandıran bu özellikleri sayesinde YSA'lara karmaşık problemlere uygulanabilme avantajı kazandıran önemli bir diğer parametredir. Probleme uygun olarak seçilen aktivasyon fonksiyonu, problemin çözümünde başarı oranını artmasında yüksek önem derecesine sahiptir.

3.2.4. Ara katman ve Nöron Sayılarının Belirlenmesi

Herhangi bir YSA mimarisinin verimli çalışabileceği nöron ve ara katman sayısının belirlenebilmesi için literatürde belirlenmiş bazı yaklaşımlar bulunmaktadır. Fakat bunun ilkel ve en kısa yolu deneme yaparak en uygun yapı ve nöron sayısının bulunmasıdır. Literatürde her türlü problemin maksimum iki ara katman kullanılarak çözülmesi gerektiği ile ilgili ispatlar da bulunmaktadır [47].

3.2.5. YSA için veri setlerinin oluşturulması

YSA için veri setlerinin oluşturulması ve bu setlerin YSA için uygun hale getirilmesi gerekmektedir. YSA'da kullandığımız aktivasyon fonksiyonu sigmoid fonksiyon olduğu için tüm veri setlerinin $[0 - 1]$ aralığına normalize (ölçeklendirme) edilmesi gerekmektedir. Bir "X" veri setinin, $[0 - 1]$ arasına ölçeklendirebilmek için o veri setinin X_{max} , X_{min} aralığı bulunur ve aşağıdaki formüle göre ölçeklendirme yapılır.

$$X_{yeni} = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (3.1)$$

Eğer ölçeklendirme, [-1.0 – 1.0] arasına çekilmek isteniyorsa aşağıdaki formül kullanılabilir.

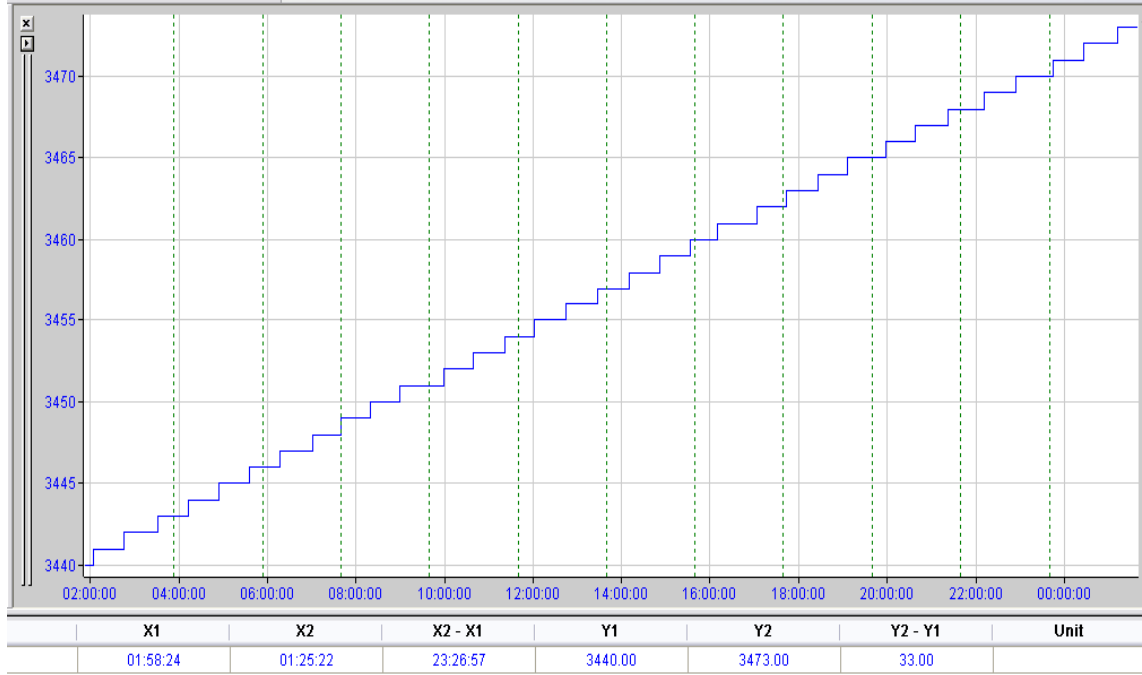
$$X_{yeni} = 2 \frac{X - X_{min}}{X_{max} - X_{min}} - 1 \quad (3.2)$$

Eğer veri seti, herhangi bir [a – b] aralığına ölçeklendirilmek isteniyorsa;

$$X_{yeni} = \frac{X - X_{min}}{X_{max} - X_{min}} (b - a) + a \quad (3.3)$$


formülü kullanılabilir. Eğitim esnasında bu işlemler sonucu elde edilen normalize edilmiş giriş – çıkış veri seti kullanılır. İşlem tamamlandıktan sonra ise değerleri gerçek değerine çevirebilmek için ise YSA sonuçlarına ters normalize işlemi uygulanmalıdır.

EAF dökümlerinin sistemde kaydı birden başlayıp yılsonu itibari ile ulaşmış olduğu son döküm sayısı ile ilişkilendirilerek tutulmaktadır. Ortalama gün içerisinde 30 döküm alınabilmektedir. Şekil 3.11’te Döküm numarası – Zaman grafiği gösterilmektedir. 20 Mayıs 2011 tarihli döküm numarası – zaman grafiğinde döküm numaraları -Y- ekseninde gösterilmiş olup 3440 ile 3473 sayıları arasında seyretmektedir. Tez içerisinde yapmış olduğumuz çalışmalar, farklı döküm numarası ve dolayısıyla farklı çelik kaliteleri ile yapılmış olup yapmış olduğumuz yazılımın performansının farklı kaliteler için de ne şekilde cevap verdiği test edilmiştir.

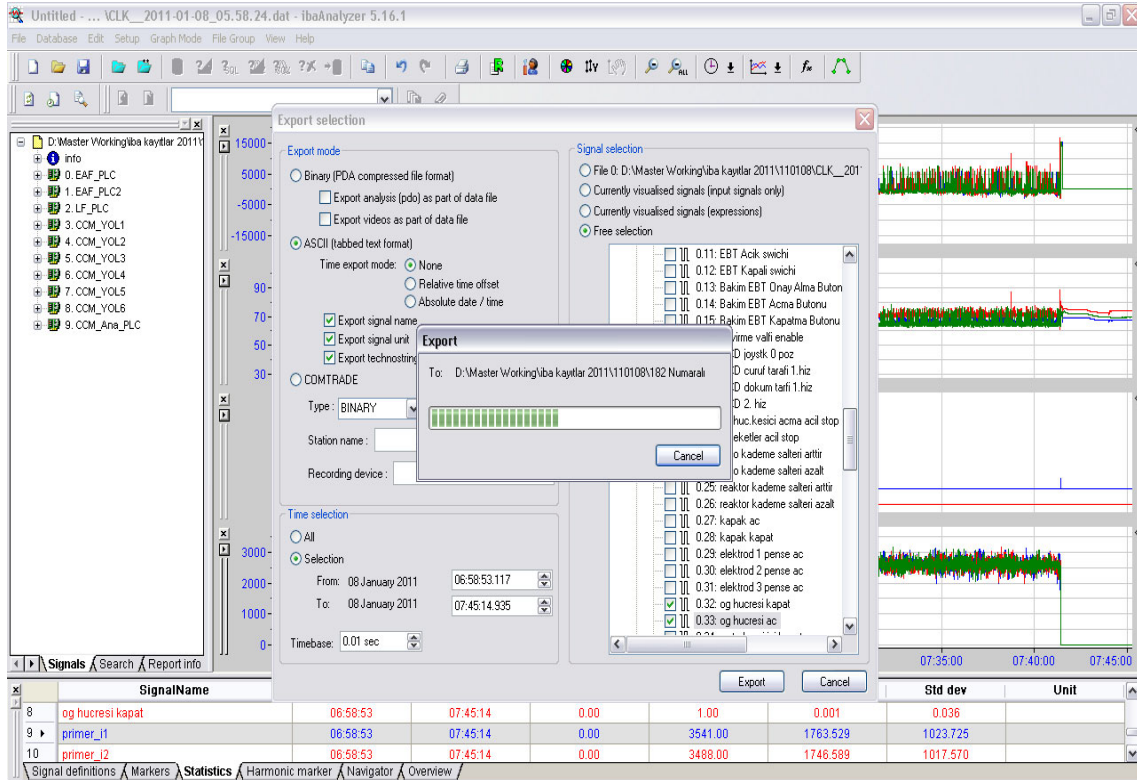


Şekil 3.11. Iba analyzer editöründe döküm numarası – zaman grafiği

Iba analyzer da 182 numaralı döküme ait verilerin YSA'da kullanılabilmesi için, YSA da oluşturulan mimaride kullanılacak giriş – çıkış katmanlarındaki nöron sayılarına göre seçilip dışa aktarımının yapılması Şekil 3.12, Şekil 3.13'te görülebilmektedir.




Şekil 3.12. Iba analyzer editöründe veri seti seçilmesi



Şekil 3.13. 182 numaralı döküme ait veri setlerinin dışa aktarım işlemi

Verilerin dışa aktarımı tamamlandıktan sonra YSA eğitimine sunabilecek YSA mimarisi ile uyuşabilecek veri setin eğitim işlemi için elde edilmiştir. 3361 numaralı döküme ait sekonder i1, i2, i3 akımlarının veri setlerinin YSA’da kullanılabilmesi için Iba Analyzer editörü ile yapılması gereken işlemler aşağıdaki satırlarda adım adım incelenmiştir. Öncelikli olarak aynı yazılım kullanılarak prosesteki verileri IbaPDA bilgisayarının sabit diskine kaydedilmiş olan veri seti editör içerisinde açılmıştır (Şekil 3.14).



Şekil 3.14. Iba editöründe 3361 numaralı döküme ait akım trendleri

Sonrasında ise editörden çağrılan trendleri editörün “File” menüsünden dışa aktarım (Export) seçeneği tıklanarak açılan pencerede dışa aktarım işlemine ait özel ayarlar yapılmıştır. Bu pencerede yapılan en önemli ön ayar, trendlerin doğru seçimi, kullanılacak data'lara ait zaman aralığı ve zaman çözünürlüğüdür. Bu dökümden zaman çözünürlüğü 10 milisaniye olarak ayarlanıp prosesteki değişimden daha hızlı veri transferi yapıldığını, dolayısıyla veri kaybının olmadığı gösterilmiştir. Dışa aktarım sonucu elde edilen veriler Çizelge 3.4’te gösterilmektedir. Proseste, eğitim aşamasında elektrotlardaki değişim hızı izabe anındaki değişim hızına göre çok fazladır. Bundan dolayı test, eğitim aşamasından alınan örneklerle yapılmıştır. Iba analyzer’den dışa aktarılan ve excel formatına dönüştürülen data’lar incelendiği takdirde prosesten aynı değerlerin tekrarlı bir şekilde


alınmış olduğu görülmektedir. Başka bir deyişle prostedeki deęişim hızı yaklaşık 30 – 120 milisaniye arasında deęişmektedir.

Çizelge 3.4. Dışa aktarılan akım trendlerine ait veri setinden örnek

Örnekleme Zamanı	i1 sec	i2 sec	i3 sec	Dokum_No
10 msn	0	76,8956	77,4906	3361
20 msn	0	76,8956	77,4906	3361
30 msn	0	76,8956	77,4906	3361
40 msn	0	76,8956	77,4906	3361
50 msn	0	76,8956	77,4906	3361
60 msn	0	78,0006	79,0772	3361
70 msn	0	78,0006	79,0772	3361
80 msn	0	78,0006	79,0772	3361
90 msn	0	78,5106	79,9272	3361
100 msn	0	78,5106	79,9272	3361

3.2.6 Oluşturulan veri setlerinin kullanımı


Daha önceden IbaPDA ile hazırlanmış veriler, Borland Delphi 7.0 kullanarak oluşturulan ara yüzdeki (Akıllı EAF) “Veri Setini Aç” butonu tıklanarak uygulama başlatılır, “Veri Atama” butonu ile de tüm veri seti, ara yüz içerisinde işlenmek üzere hafıza alanlarına yazılır (Şekil 3.15).



Şekil 3.15. Oluşturulan ara yüze verilerin aktarıldıktan sonraki görüntüsü

Eğer daha önceden uygun görülen katsayı ve parametreler kullanılacak ise “Parametre Yükle” butonu ile önceden kaydedilen parametreler kullanılabilir. Veri seti ve parametre yükleme işlemi tamamlandıktan sonra “Eğit” butonu ile ağ eğitme işlemi belirtilen iterasyona kadar başlatılmış olur.

Yazılımda eğitim işlemi gerçekleştirilmeden “Test Et” butonuna basıldığında ise hazırda bulunan başlangıç parametreleriyle ileri hesaplama gerçekleştirilir ve hata oranı ise %70’ler civarındadır (Şekil 3.16).




Şekil 3.16. Eğitim işlemi gerçekleştirilmeden yapılan ileri hesaplama sonucu

Hata oranı, iterasyon sayısına, parametrelere ve daha önceki bölümlerde incelenen YSA'yı etkileyen diğer faktörlere bağlı olarak değişmektedir. Eğitim işlemi 10 iterasyon için gerçekleştirilmiş sonuç ve hata oranı Şekil 3.17'da gösterilmiştir.



Şekil 3.17. Eğitim işlemi gerçekleştirildikten sonra yapılan test sonucu

1000 iterasyon sayısı için hata oranı aşağıdaki şekilde gösterilmiştir.



Şekil 3.18. 1000 iterasyon sonucu için yapılan test sonucu

Veri setinin hazırlanması, yapay sinir ağına gösterilmesi, eğitilmesi işlemlerinden sonra önceden belirlenen ve problemsiz olan dökümler ile bu çalışmalar tekrarlandıktan sonra soruna uygulanıp sonuçlar incelenmiştir. Ağa farklı girişler içeren setler sunulup sonuçlar diğer sonuçlar ile karşılaştırılmıştır. Momentum katsayılarının, öğrenme katsayılarının ağ için nedenli önemli olduğu ve ne tür değişikliklere neden olduğuna ileriki bölümlerde değinilmiştir.

3.2.7. 3361 Numaralı dökümden alınan veri örneklerinin YSA ile incelenmesi

3361 numaralı döküme ait sekonder I1, I2, I3 akımlarından oluşan giriş ve valflere gönderilen çıkış verilerinden oluşan, başka bir deyişle 3 giriş, 1 çıkıştan oluşan veri seti YSA'ya yüklenmiştir. Set içerisindeki verilere ait en küçük, en büyük değerler, alfa ve momentum katsayıları, sinir ağının katman sayısını belirledikten sonra eğitim işlemine başlanmıştır. İlgili dökümden de daha önceden belirtildiği gibi ocak aşamaları iki ana bölümde incelenmiştir. Eğitim ve izleme olarak gerçekleşen aşamalara ilave olarak döküm aralarında operatörler tarafından elektrotlara yapılan manuel operasyonları da kapsayacak şekilde veri setleri YSA yazılımına girilmiştir. Eğitim aşamasından alınmış olan örnek veri seti Çizelge 3.5'te görülmektedir.


Çizelge 3.5. Ergitme aşamasına ait örnek veri seti

Sıra No	i1 sec	i2 sec	i3 sec	Elektrod_1_Ref
1	56,4652	56,6136	57,9908	-2367
2	56,5807	56,6301	57,496	-2412,33
3	56,6796	56,358	57,026	-2435
4	56,2508	56,1271	56,6466	-2435
5	56,0364	56,0116	56,457	-2435
6	55,4426	55,8879	56,2838	-2472,33
7	55,022	57,026	56,5064	-2491
8	54,8241	58,0156	56,6879	-2491
9	54,8159	58,898	56,8528	-2491
10	55,22	59,8546	56,9105	-2640
11	55,7312	59,9371	56,5312	-2640
12	55,8632	59,3763	56,1353	-2640
13	55,9292	58,766	55,7395	-2640
14	55,9622	58,4609	55,5416	-2767,33
15	54,6014	57,2981	54,8241	-2831
16	53,785	56,8775	54,4777	-3001
17	53,5376	56,8116	54,387	-3086
18	53,0098	56,6714	54,1974	-3086
19	52,8449	56,6466	54,1644	-3140
20	52,647	56,6301	54,1314	-3167
21	52,3748	56,2838	54,552	-3167
22	52,3254	56,1601	54,6757	-3198,33
23	53,0181	55,9869	54,8736	-3214
24	54,4448	55,624	55,2035	-3214
25	54,8241	55,2447	55,4674	-3214
26	55,1705	54,7251	55,789	-3195,33
27	55,2694	54,1809	56,1023	-3186
28	55,0963	53,5624	56,457	-3186
29	54,7911	53,1335	56,4817	-3167,33
30	54,6757	52,8202	56,3827	-3158
31	54,3046	52,1522	56,1271	-3158
32	53,7355	51,9295	56,0281	-3158
33	53,1913	51,7811	55,9622	-3169,33
34	52,5068	51,4759	55,4261	-3175
35	51,1378	50,8657	54,354	-3259,67


Bu döküme ait tüm veri seti Çizelge 3.5'te görülebilir. YSA'ya girmemiz gereken değerler aşağıda belirtildiği gibidir.

Giriş seti, başka bir deyişle sekonder akım verilerinin en büyük değeri 112.295, en küçük değeri 0'dır. Çıkışa ait veri seti (Elektrot pozisyon referansı) için en büyük değer 19906, en küçük değer ise -9953. Çıkış veri seti PLC programlanırken simatic manager ile en küçük değeri -10 V (-27648) ve en büyük değeri +10 V (27648) olacak şekilde scale edilmiştir. Scale edilmiş değerlere bakacak olursak 19906 yaklaşık +7.2 Volt gerilime, -9953 değeri ise

-3.6 Volt gerilime karşılık gelmektedir. Tüm hazırlıklar tamamlandıktan sonra ağ eğitme işlemine başlanabilir. Hata oranı istenilen seviyeye gelene kadar eğitime devam edilmiştir.




Şekil 3.19. Eğitim devam ederken hata oranı 6,85 iken ara yüzde görüntü



Şekil 3.20. Eğitim devam ederken hata oranı 5,92 iken ara yüzde görüntü


%5'lik hata kabul edilebilir sayılıp eğitim tamamlandığında YSA'nın performansı test edilmektedir. Yapılan YSA eğitimi sadece ark ocağının "ergitme" aşamasından alınan veri setleri ile yapılmıştır.



Şekil 3.21. 3361 numaralı dökümün ergitme veri setine ait trend grafikleri


YSA'ya eğitim için gösterilen veri setine ait trenler yukarıdaki şekilde gösterilmektedir. Mavi renkte gösterilen trend i1'in, kırmızı renkte i2, yeşil renkte i3'ün, en son sıradan bir üstte olan ve yine kırmızı renkte gösterilen trend elektrot1, en altta mavi renkli trend ise döküm numarasının veri dizisini göstermektedir.

Eğitim başlangıcındaki ve sonundaki hata oranı – zaman grafiği Şekil 3.22'te gösterilmektedir.




Şekil 3.22. Eğitim başlangıcındaki % hata oranı – zaman grafiği

Eğitim başlangıcında yaklaşık %50 olan hata oranı, eğitim tamamlandığında %1,5 seviyelerine düşmüştür.




Şekil 3.23. Farklı başlangıç ağırlıkları ile % hata oranı – zaman grafiği

Daha düşük itersyon sonrası YSA öğrenimini tamamlamıştır. YSA, eğitimi %1,2 hata oranını ile tamamlamıştır. YSA'nın performansı Şekil 3.24.'da görülmektedir.



Şekil 3.24. Eğitilen YSA'nın veri setine gösterdiği çıkışlar



Şekil 3.25. YSA'nın tanımlayamadığı veri aralığı


Yukarıdaki şekilde görüldüğü gibi YSA'nın tanımlayamadığı bir aralık görülmektedir. Bu aralık 0,5 Volt gerilim seviyesine denk gelmektedir. Regülasyon yazılımında, hesaplandıktan sonra elektrotlara gönderilen değer "Death Band" aralığında ise yani 0,5 V ve daha küçük ise elektrotların pozisyonunu koruması istenmiştir. Bu klasik yazılım algoritmasını tanımlayacak herhangi bir girdi, YSA girişlerinde yer almadığından dolayı yukarıdaki şekilden de görüldüğü üzere YSA tepkisiz kalmıştır. İleriki bölümlerde bu problem, YSA'nın yapısal değişiklikleri yapılarak giderilmiştir.

İzabe aşamasına ait örnek veri seti Çizelge 3.6'da gösterilmektedir.

Çizelge 3.6. İzabe aşamasına ait örnek veri seti


Sıra No	i1 sec	i2 sec	i3 sec	Elektrod_1 Ref
1	55,138	59,3429	40,1745	-1550
2	54,7009	59,464	39,7638	-1924
3	54,4981	59,1902	40,2851	-2149,7
4	55,1064	59,3482	42,0677	-2178,3
5	56,3992	60,2197	42,6233	-1920
6	57,1259	60,0591	41,9861	-1678,9
7	55,97	58,8268	41,025	-1505,4
8	55,346	58,1264	41,0698	-1657,8
9	55,5092	58,3029	40,5537	-1785
10	55,3749	59,1744	40,1482	-1862
11	56,1938	60,612	43,2973	-1851,2
12	57,3207	60,9411	43,8634	-1779,3
13	58,7057	61,3019	45,014	-1775
14	59,7642	62,018	48,0578	-1529
15	60,9332	61,0833	46,9546	-1445
16	62,2392	60,3698	49,7271	-1157,3
17	62,4735	60,9359	50,783	-1000,1
18	62,1286	62,8395	50,4064	-938
19	61,5836	64,5431	51,7256	-880
20	61,0201	64,9881	51,1542	-851,2
21	60,4066	63,9454	48,9478	-761
22	59,959	63,0028	47,5365	-733
23	59,1507	61,997	45,4169	-808,6
24	57,8316	62,234	45,0746	-937
25	57,2865	65,6648	46,6017	-1153,9
26	58,2449	69,4194	48,0446	-1293,7
27	59,2481	71,023	48,982	-1282
28	59,1033	71,4258	48,9293	-1129,3
29	59,2139	71,6601	47,9788	-1168
30	60,0117	72,0946	50,9357	-1248,6
31	60,0696	71,9761	51,2859	-1272
32	61,6415	70,9334	50,3459	-1313
33	64,5168	72,2605	55,583	-1036,3
34	64,5984	72,8898	56,4071	-751
35	65,9491	71,6338	57,3708	-397

İzabe aşamasına ait IbaPDA görseli aşağıdaki Şekil 3.26'de gösterilmiştir.




Şekil 3.26. İzabe aşaması döküm numarası, akım ve elektrot sinyali trendleri

Yukarıdaki şekilde sarı renkle işaretlenmiş operasyonlar, elektrotlara operatörler tarafından verilen hareketlerdir. Sarı renk ile işaretlenmiş bölümlerin büyütülmüş görselleri ise ok işaretleri ile gösterilmektedir. Bu probleme karşı YSA'nın eğitiminden sonra yapılan testte YSA'nın probleme verdiği tepki aşağıda ki incelenmektedir.




Şekil 3.27. Yapılan manuel operasyonlara YSA'nın vermiş olduğu tepki

Normal şartlarda regülasyon esnasında YSA'nın regülasyona vermiş olduğu tepki ise aşağıdaki şekillerle gösterilmektedir.



Şekil 3.28. Mevcut regülasyon algoritmasına YSA'nın göstermiş olduğu tepki



Şekil 3.29. YSA % hata oranı – zaman grafiği

Buradan da YSA'nın, mevcut regülasyon algoritmasını iyi bir şekilde modellediği ve mevcut regülasyondan 100 milisaniye daha erken tepki gösterdiği halde hata oranının % 1 – 2 gibi yüksek değerlerde çıkmasının nedeni manuel operasyonlardan kaynaklanmaktadır. Problemin tanımı detaylandırıldığında YSA girişlerine uygulanan akım bilgileri ağın regülasyonu modelleyebilmesine yeterli gelmiş fakat operatörler tarafından yapılan ve klasik regülasyon algoritmasında yer almayan harici operasyonları anlamlandırabilmesine yeterli gelmemiştir. YSA'nın bu probleme çözüm getirebilmesi için ağın manuel operasyonları anlamasının ve diğer girişler ile aralarında yorum yapabilmesini sağlayacak farklı veri girişlerine ihtiyacı olduğu görülmektedir. Mevcut ağ yapısı ile ağın bu problemi çözememesi üzerine manuel operasyonu tanımlamaya yardımcı olabilecek ve içerisinde elektrotlara ait basınç bilgisini de içeren yeni YSA ağ yapısı ve veri seti oluşturulmuştur. Bu veri setinde de giriş olarak i_1 , i_2 , i_3 akım değeri ve p_1 , p_2 , p_3 basınç değerleri ağa sunulmuş, çıkış olarak ta elektrot referansı kullanılmıştır. Daha önce yapılan çalışmalarda akım bilgileri ve buna karşılık çıkışlarda da elektroda gönderilecek olan gerilim bilgisi ele alınmıştır.

Kullanılan basınç çeviricileri siemens marka olup ağır şartlarda kullanıma uygun seçilmiştir. Çeviriciler her bir elektrot için ayrı olmak üzere elektrotlara tahrik gücü sağlayan hidrolik ünite üzerine yerleştirilmişlerdir. Şekil 3.30'de basınç çeviricisine ait temsili resim

görülmektedir. Basınç bilgileri, EAF PLC kontrolörünün analog giriş donanımına 4 – 20 mA fiziki sinyal olarak bağlanmıştır. Kullanılan basınç çeviricilerinin basınç ölçüm aralığı 0 – 250 bar'dır. Bu aralık için 4 mA (0) bar'a, 20 mA (250) bar'a denk gelmektedir. Simatic editöründe bu şekilde sinyalin boyutlandırma işlemi kısa bir kodla yapıldıktan sonra analog sinyal dijital sinyale çevrilip kullanıma hazır hale getirilmiştir.




Şekil 3.30. Elektrot basınç bilgileri için ünite üzerine yerleştirilen basınç çeviricileri

Simatic manager ile SCL (Structural Control Language) dilinde yazılan, basınç çeviricilerinden gelen bilgi ile operatör panelinden girilen basınç bilgilerinin karşılaştırılması ve elektrotların altına yalıtkan malzeme geldiğinin tespitine olanak sağlayan yazılım algoritması EK-2 de görülmektedir. Yazılan algoritmanın;

- Birinci bölümü, basınç çeviricisinden almış olduğumuz bilgiyi ""Data".E1_Pressure" isimli hafıza alanına yazıyor.
- İkinci bölümü, operatör panelinden girmiş olduğumuz basınç set değeri ile çeviriciden gelen değeri karşılaştırıyor. Eğer operatör panelinden girmiş olduğumuz set değerinden küçük ise 500 milisaniye bekledikten sonra daha önce operatör panelinden set edilmiş elektrot geri kaçma hızını, elektrot hafıza alanına boyutlandırmak üzere yazıyor.
- Üçüncü bölümde boyutlandırma yapılıyor. Elektrot valflerine gönderilecek hız bilgisi şekillendiriliyor.
- Dördüncü bölümde ise şekillendirilmiş bilgi analog çıkış kartlarına gönderilmiştir.


Bir önceki girişlere ilave olarak YSA ara yüz programında, girişlere elektrot basınç bilgileri de eklenmiştir. Bir önceki veri seti ile eğitilmiş olan YSA, manuel operasyonları modellemede iyi bir performans gösterememişti. İçerisinde elektrot basınç bilgilerinin de olduğu yeni veri seti ile eğitilen YSA'nın probleme göstermiş olduğu tepki ve performans Şekil 3.31'te gösterilmektedir. Basınç ve empedans bilgileri ağa gösterilmeden önceki izabe aşamasına giriş ve devirme öncesine ait akım trendleri ve manuel operasyonların trendleri önceki bölümlerde gösterilmişti (Bkz. Şekil 3.26).



Şekil 3.31. YSA'nın deney seti ile karşılaştırılması

3.3. Slab SDM Kalıp Kanama Sistemi YSA Uygulaması

Dünyanın sıvı çelik üretiminin yaklaşık yüzde 55'i sürekli döküm tesislerinde katılaştırılır. Slab döküm makinesi, ark ocağından pota ile gelen sıvı çeliğin katılaştırılarak slab denilen ürüne dönüştürüldüğü yerdir. Genel makine şeması Şekil 3.32'te görüldüğü gibidir.




Şekil 3.32. SDM genel görünüm

Döküm kalıbı tandiş adı verilen ve üzeri reoksidasyonu önleme amaçlı kapak ile kapalı olan sıvı çelik havuzundan beslenir. Tandiş, refrakter malzeme ile örülü olan taret ya da transfer arabası üzerine oturtulan içi sıvı çelik dolu potalardan beslenmektedir. Yaygın olarak kullanılan bu sistem, dikey olarak konumlandırılmış su ile soğutulan bakır kalıplar ile dikey ekseninde belirli frekansta hareket ettirilerek sıvı çeliğin katılaşması sağlanmaktadır. Yukarı aşağı yönde yapılan sallama işlemi, katılaşmış kabuğun kalıp duvarına yapışmasını önlemek için yapılmaktadır. Buna ek olarak döküm tozları ile yapışma ve çeliğin hava ile teması önlenmiş olur. Döküm tozu genellikle çeşitli mineral ve karbon bileşenleri içeren dökülecek olan çelik kalitesine göre uyarlanmış bir karışımdır. Kalıbın salınımıyla beraber döküm tozu çelik ile kalıp arasında ki boşluğa ulaşarak ısının yayılmasını kontrol ederek yağlama görevi de görür. Bu işlem doğru bir şekilde gerçekleşmediği takdirde kabuk kopması ve dolayısıyla kalıp kanaması meydana gelir. Kalıp, yüksek ısı iletkenliğinden dolayı bakırdan imal edilmiştir. Sürekli dökümün önemli parametrelerinden biri sıvı çeliğin kalıptan çıkma

hızdır. Çekme işlemi ise çekme-doğrultma adı verilen elektrik motor tahrikli silindirler tarafından gerçekleştirilir. Sıvı çelik, üzerinde kabuk oluşmuş şekli ile kalıptan çıkar ve birden çok püskürtme uçlarından (Nozzle) oluşan soğutma bölgesine girer. Kabuğun sağlamlığı ve mukavemetine göre maksimum döküm hızı belirlenir.

Sürekli döküm makinesinde karşılaşılan önemli sorunlardan biri erimiş kalıp içerisinde katılaşmakta olan çeliğin kabuğunun kopmasıdır.



Şekil 3.33. Kalıp içerisinde gerçekleşen süreç


Şekil 3.33'de görüldüğü üzere (1) Yağlama olmaması durumunda ilk tabaka kabuk yüzeyi kalıp bakır plakasına yapışır. (2) Kalıbın salınımıyla beraber çekme merdaneleri tarafından çekilen kabuk bakır kalıp yüzeyi ile tekrar temas eder ve katılaşır. (3) Kabuk ters yönlü kalıp hareketi ile kapanan kabuk tekrar açılır. (4) Yırtılan kabuk yüzeyi kalıp salınımı ve çekme merdaneleri ile kalıp içerisinde, kalıptan çıkıncaya kadar uzamaya devam eder. (5) Yırtılan kabuk yüzeyi kalıp soğutma bölgesinden çıktığında kopma meydana gelir ve kabuk içerisindeki sıvı çelik dışarıya akar.

Kalıp içerisinde meydana gelen yırtılma erken algılandığı takdirde döküm hızı yavaşlatılarak yırtılan bölgede daha kalın bir şerit kabuk oluşumu sağlanarak kopma engellenebilmektedir. Kopma, döküm makinesinde kalıbın altında bulunan merdane, hidrolik hortumlar, elektrik motoru gibi birçok ana ve yardımcı ekipmanların zarar görmesine, iş gücü kaybına, emniyetsiz ortam koşullarının oluşmasına neden olmaktadır. Birçok endüstriyel işletmede bu olumsuz durumu öngörebilmek için mantıksal (Lojik) programlamaya dayalı koparma


tahmin sistemleri (BPS) kullanılmaktadır [50-52]. Mantıksal programlamaya dayalı bu yazılımların (MY), yanlış alarm üretme, alarm üretmemeye, ekipmana ve kalibrasyon ayarlarına bağımlı olma gibi dezavantajları bulunmaktadır. Bu nedenle bu çalışmada geri yayılım algoritmasına sahip yapay sinir ağı kullanılmıştır. YSA'dan beklenen, yapacağı etkili tahminler ile hatalı üretilen alarmların önüne geçmek, ekipman güvenilirliğini arttırmak dolayısıyla üretim kayıplarını ve iş güvenliği risklerini azaltabilmektir.

3.3.1. Sürekli döküm makinesi kalıp yapısı

Sürekli döküm makinelerinde sıvı çeliğin katılaştığı ve koparma tahmin yazılımlarının çalışabilmesi için önem arz eden ısı sensörlerinin dizilimleri Şekil 3.34 ve Şekil 3.35'te gösterilmektedir.



Şekil 3.34. SDM Kalıbı üç boyutlu genel görünümü




Şekil 3.35. Su soğutmalı kalıbın açık şematik gösterimi

Şekil 3.35’de kalıbın şematik gösteriminin altında belirtilen harf ve rakamdan oluşmuş kodlar, IBA analiz programına tanımlanmış sensör kodlarını birebir temsil etmektedir.


3.3.2. Mantıksal programlamaya dayalı koparma algılama sistemi

Mantıksal programlama temeline dayalı koparma tahmin sistemlerine göre Şekil 3.35’de görülen ısı sensörlerinden gelen bilgiler çeşitli matematiksel modellemelerle Şekil 3.37’de gösterildiği gibi zamana göre uyarı eşiği ve alarm eşiği set değerleri ile karşılaştırılarak koparma alarmını üretmektedir. Çalışmaların yapıldığı makine kalıbında toplamda ön kısımda 18, arka kısımda 18, yanlarda 4’er tane olmak üzere toplamda 44 adet ısı sensörü (Termocouple) bulunmaktadır. Isı sensörlerinin geometrisi birbirlerinin altında olacak şekilde düzenlenmiştir. Öncelikle sıcaklıklar normal olarak ilerler iken kalıp içerisindeki sıvı çeliğin ortalama sıcaklığı kalıbın üst kenarından döküm yönüne gidildikçe azalmaktadır. Sonuç olarak kalıp içerisinde ortalama sıcaklık zamana göre değişkenlik gösterir. Kopmanın gerçekleştiği bölgede her ne kadar kabuk oluşumu gerçekleşse de sıvı çeliğin kalıp duvarına temas ettiği bölgede belirli süre ısı artışı meydana gelir ve normal seviyesine doğru tekrar düşer. Geometrik yerleşimleri sebebi ile aynı karakteristikte ki eğri alt satırda bulunan diğer sensörlerde de gecikmeli olarak meydana gelir. Şekil 3.36’de kalıp yüzeyine yapışarak ilerleyen noktanın zamana göre sıcaklık gradyanı görülmektedir.



Şekil 3.36. Yapışan noktanın sıcaklık gradyanı

Mantıksal modellemeye göre eğrilerin kesiştiği noktada bir alarm sinyali üretilir.




Şekil 3.37. Koparma alarm ve uyarı eşik değer – zaman diyagramı

- Gecikme süresine ulaşamadığı için alarm yada uyarı üretilmeyecektir.
- Sıcaklık eğrisi, daha önceden tanımlanan zaman aralığında uyarı eşliğini geçtiğinden dolayı uyarı sinyali üretilecek fakat gereken süre tamamlandığı için alarm sinyali üretilmeyecektir.
- Sıcaklık eğrisi, tanımlanmış zaman aralığında uyarı ve alarm eşliğini aştığı için koparma alarmı üretilecektir.

Alarm sinyalinin üretilmesinin ardından döküm hızı, önceden set edilmiş daha küçük bir değere düşürülerek yeterli kalınlıkta kabuğun oluşması ve buna bağlı olarak kanamanın önlenmesi hedeflenir.

3.3.3. Yapay sinir ağı tabanlı koparma tahmin sistemi

YSA için uygun veri seti oluşturulması, katmanların belirlenmesi, veri setlerinin YSA'da kullanılması önceki bölüm başlıkları altında incelenmişti.




Şekil 3.38. SDM kalıp şematik gösterimi ve IBA program editörü ekran görüntüsü

Şekil 3.38'ta ise kalıp ve üzerindeki sensör yerleşim geometrisi, Şekil 3.39'de IBA analiz ekran görüntüsünde alarm bilgisi, döküm bilgisi, kalıp seviye ve kalıp içerisinde çift sıra halinde bulunan ısı sensörleri bilgisi, sıvı çelik akış yönü döküm yönünde ilerler iken görülen kopma ve kopma anındaki ısı karakteristiği, görülmektedir.

Birçok döküme ait gerçek zamanlı olarak IBA ile bilgisayar sabit diskine kaydedilmiş koparma anına ait veriler ile mantıksal programlama yazılımının algılayamadığı fakat reel olarak gerçekleşen verilerden oluşmuş veri setleri ile YSA tabanlı yazılım eğitilmiş olup sonuçları karşılaştırılmıştır.


1001 döküm numaralı çeliğe ait döküm hızı, mantıksal yazılım alarm durum bilgisi, kalıp sıvı çelik seviye bilgisi, döküm numarası ve yapışmanın olduğu sıcaklık sensörlerinin bilgileri dikkate alındığında meydana gelen kanama, mantıksal koparma algılama yazılımı tarafından geç tespit edildiğinden dolayı sistem kanamayı önleyememiştir (Şekil 3.39).



Şekil 3.39. Kalıp kanama anı proses verileri

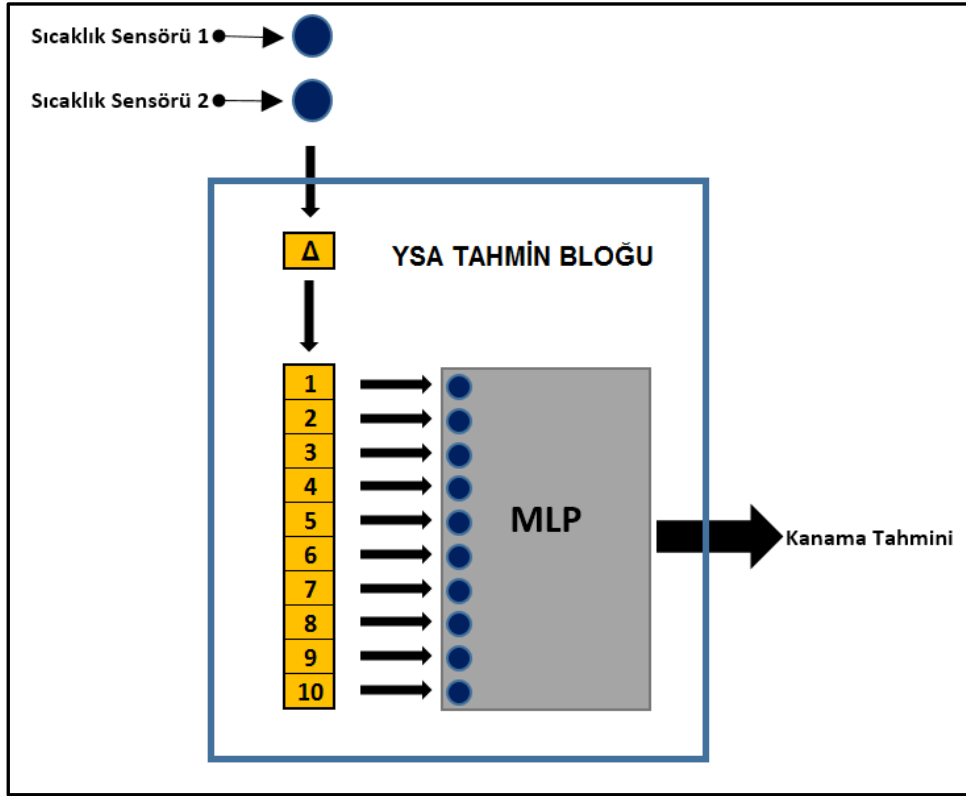
YSA eğitimi için hazırlanan veri seti, kalıp içerisine belirli geometride dizilmiş olan sıcaklık sensörlerinin farkından oluşmaktadır. Şekil 3.39’de Left_A1, LeftA2 sıcaklık verileri ve bunların farkı olan DeltaLeftA verisi görülmektedir. Şekil 3.35’de kalıbın açılmış görüntüsünden de görüldüğü üzere DeltaLeftA sıcaklık verisi, kalıbın sol kenarında ve alt alta olacak şekilde yerleştirilmiş sensör çiftinin farkından oluşmaktadır. DeltaLeftA sıcaklık verisi YSA yazılımı için girişlerden (Nöron) birini oluşturmaktadır. YSA’nı eğitmek için oluşturulmuş veri seti, gerçekleşmiş ve doğruluğu kabul edilmiş olan kanama verilerinin kanama gerçekleşmeden önceki 30 saniye zaman aralığındaki verilerinden oluşmaktadır (Şekil 3.40). Bu şekilde problemi içeren ve normal düküm anından oluşturulan veri setleri YSA öğrenimi için kullanılmıştır.



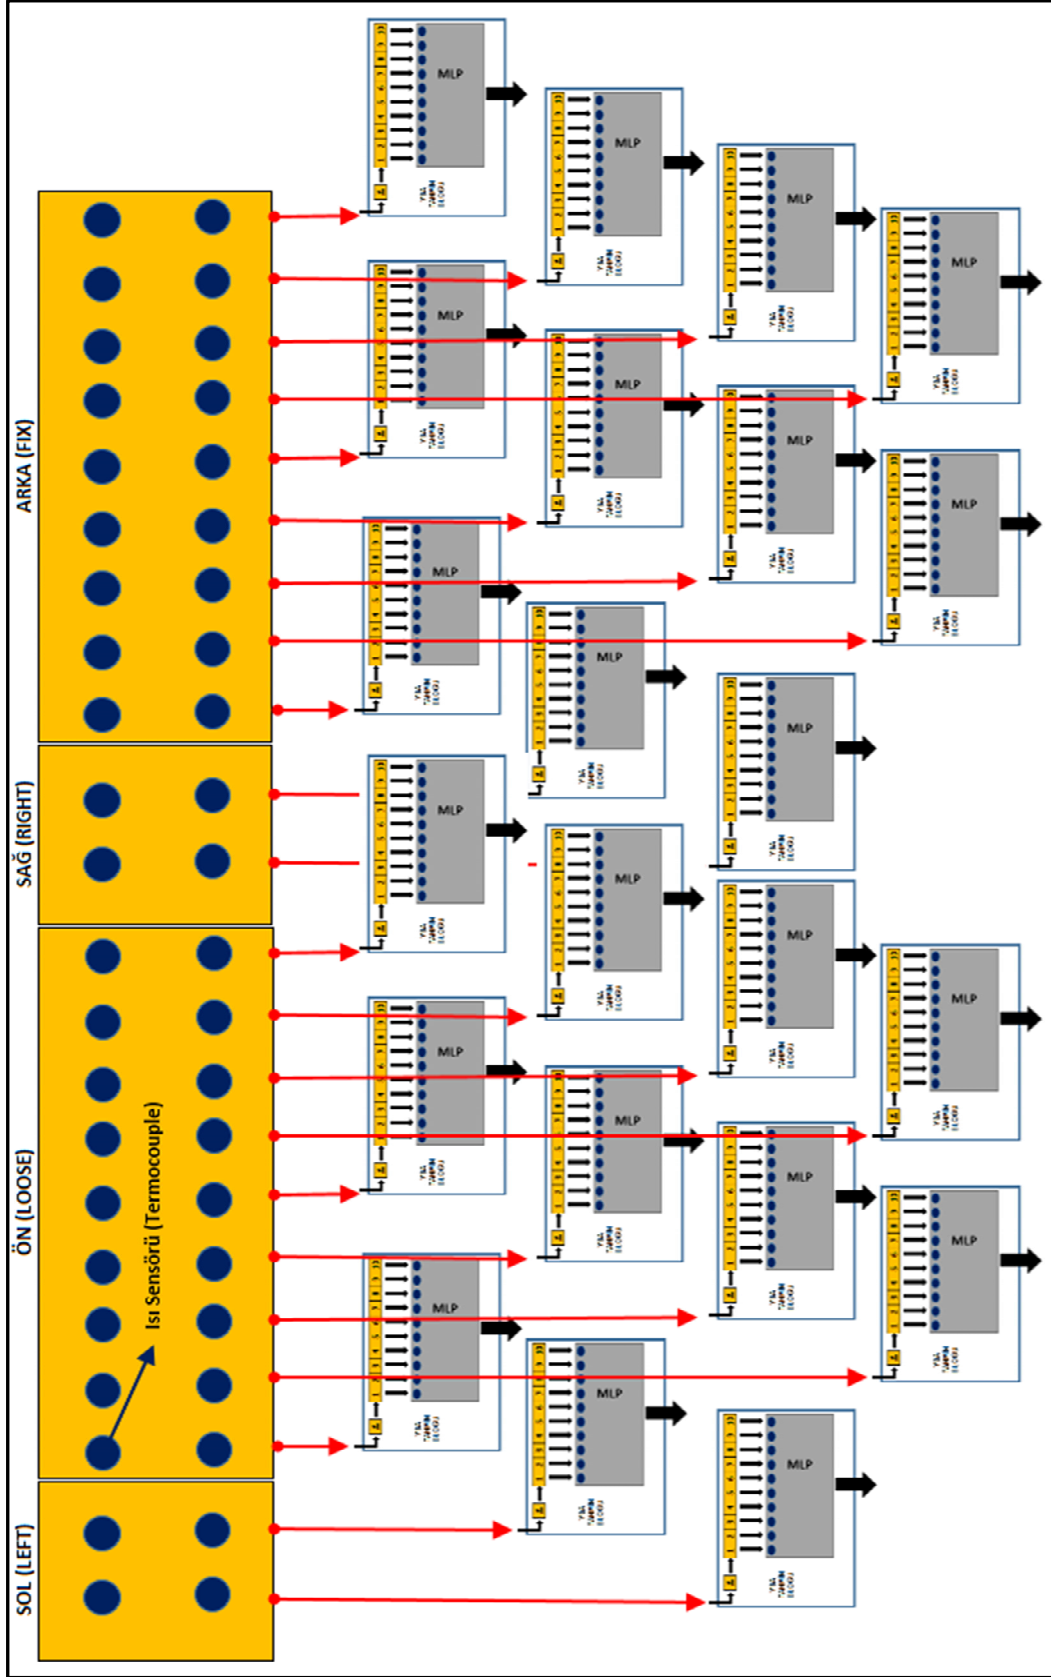


Şekil 3.40. Sıcaklık veri grafiği

YSA tahmin blođu (YSATB), Őekil 3.40'de grldđg zere ara katmanlar hari 10 giriŐ ve 1 ıkıŐa sahip 11 adet nronlardan oluŐmaktadır. Kalıp zerinde bulunan her sensr stununa ait bir YSATB bulunmaktadır (Őekil 3.41).



Őekil 3.41. YSA tahmin blođu (YSATB)



Şekil 3.42. Kalıp üzerinde YSA tahmin bloğu (YSATB) uzay dağılımı

Şekil 3.42’te görüldüğü gibi YSATB, sıcaklık sensörlerinden aldığı sıcaklık fark bilgilerini yorumlayarak kalıp kanama ile ilgili tahminlerde bulunur. YSA eğitimi için hazırlanmış örnek veri setlerinden biri Çizelge 3.7’de görülmektedir.

Çizelge 3.7.YSA eğitiminde kullanılan örnek veri seti

Sıcaklık Trendi / YSA Nöronları	X1	X2	X3	X4	X5	X6	X7	X8	X9	X10	Alarm Bilgisi
[DeltaLooseD]	11,667	9,900	8,800	8,300	7,800	8,300	9,600	12,000	5,600	-9,000	2
[DeltaLooseE]	2,467	2,600	2,800	3,000	3,600	3,900	1,100	-4,800	-11,900	-17,500	2
[DeltaLooseF]	5,433	5,200	5,500	5,300	5,500	6,000	7,100	7,100	7,300	6,400	0
[DeltaFixH]	10,950	10,600	10,100	10,000	10,400	11,100	11,800	12,400	12,900	13,100	0
[DeltaLeftA]	7,567	8,100	8,400	8,100	7,900	7,700	7,800	8,500	8,900	9,300	0

Çizelge 3.7. içeriğindeki verilerden oluşan ve YSA eğitiminde kullanılan verilerin trendi Şekil 3.43’de görülmektedir.



Şekil 3.43. YSA eğitiminde kullanılan örnek verilere ait grafikler


Eđitimde kullanılan her bir YSATB için çeřitli mimarideki yapılar denenmiř olup en iyi sonu veren mimari ile alıřmaya devam dilmiřtir. YSATB ile yapılan alıřmalarda sırası ile bir, iki ve u ara katman denenmiř, her deneme ise ara katman nron sayısı kendi ierisinde sayıları 1 - 100 arasında deđiřen nronlardan oluřmuřtur. Őekil 3.43'te farklı nron sayılarına sahip ara katmanlar ile denenmiř sonuların grafik karřılařtırılması grlmektedir. İyi sonu veren rneklerden birinin ađ yapısı ve katsayıları ařađıda grlmektedir.

- Giriř proses elemanı sayısı : 10
- Ara katman sayısı : 2
- ıkıř proses elemanı sayısı : 1
- Birinci ara katman proses elemanı sayısı : 7
- İkinci ara katman proses elemanı sayısı : 4
- đrenme katsayısı (λ) : % 41
- Momentum katsayısı (α) : % 70
- Performans lt RMSE (Root Mean Square Error) : 0,005
- đrenme sayısı : 200 000

Eđitilen YSATB'nin eđitim performansını gsteren eđitim seti ile YSATB'nin ıktılarının karřılařtırılması izelge 3.8'de grlmektedir. YSATB, kendisine gsterilen rnekleri %98 - %100 arası dođrulukta đrenmiřtir. Eđitim performansına ait RMS grafiđi ise Őekil 3.44'da grlmektedir.

Çizelge 3.8 YSATB çıktısının eğitim veri seti ile karşılaştırılması

DATA	X1	X2	X3	X4	X5	X6	X7	X8	X9	X10	HEDEF DEĞER	YSATB TAHMİN DEĞERİ
DATA 01	14,400	15,200	15,400	15,200	15,600	15,600	15,300	14,600	13,600	9,400	2	1,997
DATA 02	8,200	8,700	8,000	8,100	5,700	-0,800	-6,500	-9,800	-10,100	-9,800	2	1,998
DATA 03	11,000	11,500	12,100	11,700	11,200	10,600	10,400	10,800	10,400	9,800	0	0,015
DATA 04	4,800	5,500	6,100	6,900	7,000	8,100	9,900	10,000	7,800	3,100	2	1,997
DATA 05	17,100	17,100	16,800	17,000	16,800	17,400	16,200	16,400	17,900	17,700	0	0,003
DATA 06	18,600	19,300	18,400	18,700	19,400	19,500	19,200	19,200	19,300	19,900	0	0,003
DATA 07	5,433	5,200	5,500	5,300	5,500	6,000	7,100	7,100	7,300	6,400	0	0,006
DATA 08	10,950	10,600	10,100	10,000	10,400	11,100	11,800	12,400	12,900	13,100	0	0,003
DATA 09	7,567	8,100	8,400	8,100	7,900	7,700	7,800	8,500	8,900	9,300	0	0,003
DATA 10	-5,267	-2,000	-0,800	-0,300	-1,000	-2,500	-4,800	-6,000	-5,500	-3,900	0	0,003
DATA 11	7,367	5,700	7,200	9,100	9,600	7,900	5,400	4,700	7,300	11,700	0	0,003
DATA 12	6,700	6,600	6,700	7,200	7,200	6,500	6,400	6,000	6,100	6,500	0	0,007
DATA 13	1,167	0,800	1,000	1,700	2,300	3,500	3,900	4,500	3,000	2,900	0	0,018
DATA 14	8,733	8,600	7,900	7,600	7,800	9,000	9,500	10,400	10,200	10,300	0	0,003
DATA 15	-1,867	-1,000	-1,500	-2,000	-2,200	-2,000	-1,800	-1,000	-0,800	-1,200	0	0,003
DATA 16	29,400	30,300	31,700	32,600	33,000	32,300	32,400	32,900	33,300	33,800	0	0,003
DATA 17	7,200	4,000	2,100	0,800	-0,400	-2,100	-2,600	-1,400	0,000	-0,100	2	1,988
DATA 18	3,400	4,300	5,300	6,200	6,900	7,100	7,400	6,600	5,500	4,000	2	1,979
DATA 19	6,500	6,300	5,000	3,900	2,900	1,600	0,200	0,000	-0,100	-0,600	2	1,996
DATA 20	-0,800	-1,500	-1,800	-2,100	-2,800	-3,300	-3,600	-4,300	-5,500	-6,100	2	1,996



Şekil 3.44. YSA eğitimi performans grafiği

Eđitimi tamamlanan YSATB'nin daha önce hiđ görmemiř olduđu veriler ile test edildikten sonraki YSATB ıktıları ve beklenen ıktıların karřılařtırılması ise izelge 3.8'de grlmektedir.

izelge 3.8. YSATB'nin test veri seti ile karřılařtırılması


DATA	X1	X2	X3	X4	X5	X6	X7	X8	X9	X10	HEDEF DEĐER	YSATB TAHMİN DEĐERİ
Data01	12,933	21,200	16,700	0,900	-11,900	-21,100	-25,600	-27,800	-28,100	-27,600	2	1,973
Data02	8,500	7,600	7,200	7,000	7,200	7,000	6,600	7,300	7,900	7,500	0	0,005
Data03	4,700	5,000	5,500	5,000	4,300	4,200	4,200	4,400	4,800	5,500	0	0,003
Data04	12,100	13,100	13,000	16,300	15,400	11,500	4,100	-2,700	-6,500	-7,300	2	1,998
Data05	1,4	0,199997	-1,1	-2,5	-3,4	-4,4	-5,1	-4,7	-3,7	-2	0	0,009
Data06	-0,300	1,400	2,700	3,800	4,100	3,500	2,600	2,300	2,600	3,000	0	0,005
Data07	3,400	4,300	5,300	6,200	6,900	7,100	7,400	6,600	5,500	4,000	2	1,979
Data08	0,899999	-3,5	-6,1	-7,5	-7,5	-6,3	-4,8	-3,4	-2,3	-1,9	0	0,005
Data09	-2,000	-2,600	-2,700	-2,700	-2,700	-2,200	-1,200	0,200	1,800	2,700	0	0,003
Data10	3,200	3,100	2,700	3,000	3,100	3,200	3,700	4,400	4,700	4,600	0	0,003
Data11	11,233	10,200	9,500	7,500	4,400	1,600	-1,600	-4,100	-4,800	-5,300	2	1,998
Data12	-6,600	-8,300	-9,900	-10,400	-9,700	-8,500	-6,200	-2,500	2,200	5,700	0	0,003
Data13	6,5	6,3	5	3,89999	2,9	1,6	0,200005	0	-0,10001	-0,6	2	1,996
Data14	-1,900	-4,000	-3,900	-2,900	-2,000	-1,100	-0,400	0,500	0,600	0,600	0	0,003
Data15	-0,8	-1,5	-1,8	-2,1	-2,8	-3,3	-3,6	-4,3	-5,5	-6,1	2	1,996
Data16	-0,700	-1,200	-2,700	-3,700	-4,800	-4,500	-2,600	-0,200	-1,200	-3,000	0	0,048
Data17	3,167	2,200	2,000	1,000	0,000	0,400	1,800	3,800	3,900	2,100	0	0,006
Data18	-1,56667	-3,1	-3,6	-3,2	-3	-3	-1,5	1,2	1	-0,5	0	0,003
Data19	19,333	19,300	18,700	14,500	10,400	10,600	11,700	13,600	14,900	17,900	0	0,003
Data20	9,16667	9,2	8,7	8,2	6,7	4,8	2,3	1,8	3,8	5	0	0,011
Data21	13,233	12,800	12,100	11,500	9,000	6,800	4,100	3,800	7,900	9,700	0	0,003
Data22	7,550	7,200	6,800	6,400	4,700	2,800	-0,100	-1,300	1,700	3,500	0	0,006
Data23	-1,13333	-0,6	-1,10001	-1,8	-3,1	-5,1	-5,1	-3,5	-1,2	-2,4	0	0,003
Data24	14,367	13,500	12,600	11,500	10,200	8,700	7,000	7,300	9,300	10,100	0	0,007
Data25	15,2667	16,4	15,2	16,5	19,7	19,2	17,1	18,1	17,5	11,8	2	1,997

Test veri seti, eğitim veri setinde de olduğu gibi gerçekleşen ve kalıp kanamanın olduğu örnekler ile normal döküm anına ait verilerden oluşmaktadır. Çizelge 3.8’de görüldüğü üzere YSATB, ortalama %99,822 doğruluk oranı ile testi tamamlamıştır.

Öğrenmeyi tamamlayan YSATB’nin, farklı dökümlere vermiş olduğu tahmin çıktıları ile aynı döküm numarası için, mantıksal yazılım (MY) çıktıları karşılaştırıldığında YSATB’nin güçlü olduğu yönleri ile karşılaşılmaktadır. Örneklerin genelinde YSATB’nin, MY programına göre kalıp kanama alarmını daha önce ürettiği ve bazı kalıp kanamanın gerçekleştiği örneklerde ise MY programının tespit edemediği dolayısıyla alarm üretmediği hataları tespit edip alarm ürettiği görülmektedir.

3.3.4. YSATB ile MY program çıktılarının karşılaştırılması


Şekil 3.45’de MY programının kalıp kanama için üretmiş olduğu alarm ve diğer verilerin IBA ekran görüntüsü görülmektedir. X2 zaman işaretçisinin saat 06:28:54’ü gösterdiğinde MY programı alarm sinyali üretmiştir. Kalıp kanama anı süreç verilerini içeren detay EK-3 de gösterilmektedir.




Şekil 3.45. YSA eğitimi test verileri

Eđitim ve test ařamasında YSATB'nin karřılařmadığı veriler, MY programı ve YSATB'ye gősterildiğinde YSATB, MY programına gőre yaklaşık 30 saniye őrcesinde ilk alarm sinyalinin őrretmiř ve MY programının alarm sinyalinin őrrettiđi zaman aralıđında ikinci alarm sinyalinin őrretmiřtir (řekil 3.46). Buradan őrıkan sonu YSATB, MY programına gőre olası ihtimaller karřısında daha erken alarm sinyalinin őrterek olası kalıp kanamanın őrnlenebilmesi iin zaman kazandırmaktadır.






Şekil 3.46. YSATB - MY program çıktılarının karşılaştırmaları



Şekil 3.47. Kalıp kanama anı süreç verileri

Şekil 3.47’de ise MY programının kalıp kanama problemini algılayamaması nedeni ile kaybedilen döküme ait süreç verilerinin IBA ekran görüntüsü görülmektedir. Kanamanın olduğu an alarm bilgisinin (AlarmStatus), döküm bilgisinin (CastStatus) döküm hızının (CastSpeed), sıcaklık sensörlerinin (Loose_D1,Loose_D2,...v.s), kalıp seviyesinin (Mold Level) ani trend düşüşü göze çarpmaktadır. Şekil 3.47’deki IBA ekran görüntüsünün detay çıktısı EK-4 te gösterilmektedir. EK-3 ve EK-5 te görülen kalıp kanama anının (X1 zaman işaretçisi: 14:44:10.9) 30 saniye öncesini kapsayan zaman aralığındaki veriler YSATB’ye gösterildikten sonra bu sonuca ait YSATB’nin ürettiği çıktı Şekil 3.48’de gösterilmektedir.





Şekil 3.48. YSATB-MY program çıktılarının problemlı döküm için karşılaştırması

4. SONUÇ VE ÖNERİLER

Ülkemizde çeşitli sektörlerde hammadde tedarikinde bulunan ve endüstride önemli payı bulunan demir çelik fabrikalarının ana üniteleri olan ark ocakları ve sürekli döküm tesisleri ile ilgili yapılan bu modelleme çalışmaları, ülkemizde faaliyet gösteren bir demir çelik tesisine ait veri setleri ile gerçekleştirilmiştir.

Yapay Sinir Ağı Tahmin Bloğu, öğrenme ve performans testi için probleme göre uygun veri seti hazırlanması, ağ mimarisinin doğru seçilmesi (Ara katman ve proses elemanları), α ve λ katsayılarının doğru sonuca yaklaştıracak şekilde ayarlanması ile problemi doğru öğrenebilmiş ve daha önce karşılaşmadığı örneklere yüksek hassasiyetle cevap verebilmiştir.

Klasik Mantıksal Yazılımının problemi algılayamadığı veya geç algıladığı örnekleri doğru tahmin ederek kalıp kanama probleminin önüne geçmiştir. Kalıp kanama için kanamanın vermiş olduğu hasar şiddetine bağlı olarak üretim hattında 11 saatlere varan uzun kesintilere neden olmaktadır. Ayrıca meydana gelen hasarın maddi ve işçi sağlığı ve iş güvenliği boyutu da önem arz etmektedir.

Yapılan test ve denemeler, sürekli döküm makinalarında ve fırın içerisinde değişken koşullardaki operasyonlara gerçek zamanlı adaptasyonu ile elektrot ve fırın refrakter aşınmasını, fırın güç tüketimini azalttığı göz önünde bulundurulduğunda Yapay Sinir Ağlarının, demir çelik sektöründeki kontrol sistemlerinde etkin bir şekilde kullanımının yaygınlaştırılması önerilmektedir. Farklı ağ mimarileri denenerek daha etkin sonuçların alınabileceği öngörülmüştür.

Ark ocağı için deney düzeneği kurularak buradan elde edilebilecek verilerin, farklı denemelerde kullanılabilmesi ile elektrikli ark ocaklarının içerisine atılan çeşitli katkı malzemelerinin ne zaman ve ne miktarda olması gerektiğini belirleme, dökümün sonlandırılmasında önemli parametrelerden olan sıvı çelik sıcaklık tahmini gibi konularında araştırmalar genişletilebilir.

KAYNAKLAR

1. Çamdalı, Ü., Tunç, M. (2004). Elektrik Ark Fırınında Fiziksel Ekserji. *Trakya Univ Fen Bilg Derg*, 5(1), 53–61.
2. İnternet: Watson. (2013). Watson. URL: <http://www.cs.tut.fi/~elomaa/teach/watson2013.pdf>, Son Erişim Tarihi: 21.01.2019.
3. İnternet: Kılınç, Şahin. Google'ın Yapay Zekası, Satrançtan Bin Kat Daha Zor GO Oyununda Dünya Şampiyonunu Yendi! URL: <https://www.webtekno.com/google-in-yapay-zekasi-satranctan-bin-kat-daha-zor-go-oyununda-dunya-sampiyonunu-yendi-h29312.html>, Son Erişim Tarihi: 21.01.2019.
4. Öztemel, E. (2006). *Yapay Sinir Ağları* (İkinci Baskı). İstanbul: Papatya Yayıncılık.
5. Çakıroğlu, A. M., Terzi, S., Kasap, S., Çakıroğlu, G. M. 2010. Beton Basınç Dayanımının Bulanık Mantık Yöntemiyle Tahmin Edilmesi. *Yapı Teknolojileri Elektronik Dergisi*, 6(2), 1–8.
6. Özsoy, İbrahim; Fırat, M. (2004). Kirişsiz Döşemeli Betonarme Bir Binada Oluşan Yatay Deplasmanın Yapay Sinir Ağları İle tahmini. *Dokuz Eylül Üniversitesi Mühendislik Fakültesi Fen ve Mühendislik Dergisi*, 6(14), 51–63.
7. Terzi, Ö. (2006). Yapay Sinir Ağları Metodu ile Eğirdir Gölü Su Sıcaklığının Tahmini. *Süleyman Demirel Üniversitesi, Fen Bilimleri Enstitüsü Dergisi*, 10(2), 297–302.
8. Sambath, S., Nagaraj, P., and Selvakumar, N. (2011). Automatic defect classification in ultrasonic NDT using artificial intelligence. *Journal of nondestructive evaluation*, 30(1), 20-28.
9. Mat Daut, M. A., Hassan, M. Y., Abdullah, H., Rahman, H. A., Abdullah, M. P., and Hussin, F. (2017). Building electrical energy consumption forecasting analysis using conventional and artificial intelligence methods. *Renewable and Sustainable Energy Reviews*. <https://doi.org/10.1016/j.rser.2016.12.015>
10. Hussain, M. A., Hassan, C. R. C., Loh, K. S., Mah, K. W. (2007). Application of Artificial Intelligence Techniques in Process Fault Diagnosis. *Journal of Engineering Science and Technology*, 2(3), 260–270.
11. Siddique, A., Yadava, G. S., and Singh, B. (2003, August). Applications of artificial intelligence techniques for induction machine stator fault diagnostics. In *4th IEEE International Symposium on Diagnostics for Electric Machines, Power Electronics and Drives, 2003. SDEMPED 2003*. (pp. 29-34). IEEE
12. Mahajan, V., Agarwal, P., and Om Gupta, H. (2014). dSPACE implementation of cascaded H-bridge inverter for harmonics minimization using artificial-intelligence. *COMPEL: The International Journal for Computation and Mathematics in Electrical and Electronic Engineering*, 33(6), 2053-2081.

13. Topçu, İ. B., Uygunoğlu, T., and İnce, H. H. (2010). Hafif Beton Basınç Dayanımının Yapay Sinir Ağlarıyla Tahmini Prediction of Lightweight Concrete Compressive Strength Using Artificial Neural Networks. *Yapı Teknolojileri Elektronik Dergisi* Cilt, 6(1), 19–29.
14. Öğüt, V. (2014). Rüzgar Hızının Sinirsel Bulanık Yöntemle Tahmini, Yüksek Lisans Tezi, *İstanbul Üniversitesi Fen Bilimleri Enstitüsü*, İstanbul.
15. Nandi, S., Toliyat, H. A., and Li, X. (2005). Condition monitoring and fault diagnosis of electrical motors—A review. *IEEE transactions on energy conversion*, 20(4), 719–729.
16. Hauksdóttir, A. S., Soderstrom, T., Thorfinnsson, Y. P., and Gestsson, A. (1995). System identification of a three-phase submerged-arc ferrosilicon furnace. *IEEE Transactions on Control Systems Technology*, 3(4), 377–387.
17. Gemici, E., Ardiçoğlu, M., Kocabaş, F. (2013). Akarsularda debinin yapay zekâ yöntemleri ile modellenmesi. *Erciyes Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 29(2), 135–143.
18. Karaatlı, M., Helvacıoğlu, Ö. C., Ömürbek, N., ve Tokgöz, G. (2012). Yapay sinir ağları yöntemi ile otomobil satış tahmini. *Uluslararası Yönetim İktisat ve İşletme Dergisi*, 8(17), 87–100.
19. Güler, İ., Übeyli, E. (2006). Çok Katmanlı Perseptron Sinir Ağları İle Diyabet Hastalığının Teşhisi. *Gazi Üniversitesi Mühendislik-Mimarlık Fakültesi Dergisi*, 21(2).
20. Kelesoglu, Ö. (2008). Betonarme Bir Binada Yıllık Isı Kaybı Ve Enerji İhtiyacının Yapay Sinir Ağları İle Belirlenmesi. *Engineering Sciences*, 3(2), 381–390.
21. Saplıoğlu, K , Çimen, M . (2010). YAPAY SİNİR AĞLARINI KULLANARAK GÜNLÜK YAĞIŞ MİKTARININ TAHMİNİ. *Mühendislik Bilimleri ve Tasarım Dergisi*, 1 (1), 14-21.
22. Parlakyıldız, Ş. (2014). Yapay Sinir Ağları Kullanarak Parmak İzi Tanıma ve Sınıflandırma, Yüksek Lisans Tezi, *Gazi Üniversitesi Fen Bilimleri Enstitüsü*, Ankara.
23. Doğan, E. (2009). Katı Madde Konsantrasyonunun Yapay Sinir Ağlarını Kullanarak Tahmin Edilmesi. *İMO Teknik Dergi*, 4567–4582.
24. ES, H. A., KALENDER, F. Y., ve HAMZAÇEBİ, C. (2014). Yapay sinir ağları ile Türkiye net enerji talep tahmini. *Gazi Üniversitesi Mühendislik-Mimarlık Fakültesi Dergisi*, 29(3).
25. Choi, S. B., Cheong, C. C., Jung, J. M., and Choi, Y. T. (1997). Position control of an ER valve-cylinder system via neural network controller. *Mechatronics*, 7(1), 37–52.

26. De Carvalho, R. M., Mello, C., and Kubota, L. T. (2000). Simultaneous determination of phenol isomers in binary mixtures by differential pulse voltammetry using carbon fibre electrode and neural network with pruning as a multivariate calibration tool. *Analytica chimica acta*, 420(1), 109-121.
27. Andersen, K., Cook, G. E., Karsai, G., and Ramaswamy, K. (1990). Artificial neural networks applied to arc welding process modeling and control. *IEEE Transactions on Industry Applications*, 26(5), 824–830.
28. Merk, D., Friedrich, L., Grisoni, F., and Schneider, G. (2018). De Novo Design of Bioactive Small Molecules by Artificial Intelligence. *Molecular informatics*.
29. Yılmaz, B. (2015). Akarçay havzasında çözünmüş oksijen değerlerinin yapay sinir ağları ile belirlenmesi, Yüksek Lisans Tezi, Gazi Üniversitesi, Ankara.
30. Segler, M. H., Preuss, M., and Waller, M. P. (2018). Planning chemical syntheses with deep neural networks and symbolic AI. *Nature*, 555(7698), 604.
31. Atak, M., Akçayol, A., ve Ok, Y. (2011). Yalın Sinirsel Bulanık Bir Model İle İmkb 100 Endeksi Tahmini a Simple Neuro Fuzzy Model for Ise 100 Index Prediction. *Gazi Üniv. Müh. Mim. Fak. Der.*, 26(4), 897–904.
32. Qian, L., Winfree, E., and Bruck, J. (2011). Neural network computation with DNA strand displacement cascades. *Nature*, 475(7356), 368.
33. Cherkasov, A., Hilpert, K., Jenssen, H., Fjell, C. D., Waldbrook, M., Mullaly, S. C., Hancock, R. E. W. (2009). Use of artificial intelligence in the design of small peptide antibiotics effective against a broad spectrum of highly antibiotic-resistant superbugs. *ACS Chemical Biology*, 4(1), 65–74.
34. Tuzcuoğlu, H. (2003). Yapay Zeka Teknikleri, Depremde Kullanılması Ve Küme Kuramları. *Fen ve Mühendislik Dergisi*, 5(1), 73–88.
35. Özhan, E. (2016). Yapay Zeka ve Veri Madenciliği Uygulamalarında Yüksek Başarılı Hesaplama Yazılımları High Performance Computing Software in Artificial Intelligence and Data Mining Applications. In *International Conference on Computer Science and Engineering*.
36. Staib, W. E., and Staib, R. B. (1992, June). The intelligent arc furnace controller: a neural network electrode position optimization system for the electric arc furnace. In *[Proceedings 1992] IJCNN International Joint Conference on Neural Networks* (Vol. 3, pp. 1-9). IEEE
37. Sheppard, C. P., Gent, C. R., and Ward, R. M. (1992, June). A neural network based furnace control system. In *1992 American Control Conference* (pp. 500-504). IEEE.
38. King, P. E., and Nyman, M. D. (1996). Modeling and control of an electric arc furnace using a feedforward artificial neural network. *Journal of Applied Physics*, 80(3), 1872–1877.

39. Sadeghian, A. R., and Lavers, J. D. (2000). Application of feedforward neuro-fuzzy networks for current prediction in electric arc furnaces. In *Proceedings of the IEEE-INNS-ENNS International Joint Conference on Neural Networks. IJCNN 2000. Neural Computing: New Challenges and Perspectives for the New Millennium* (Vol. 4, pp. 420-425). IEEE.
40. Wang, F., Jin, Z., and Zhu, Z. (2005, May). Modeling and prediction of electric arc furnace based on neural network and chaos theory. In *International Symposium on Neural Networks* (pp. 819-826). Springer, Berlin, Heidelberg.
41. Hong, Z., Sheng, Y., Li, J., Kasuga, M., and Zhao, L. (2006, June). Development of AC electric arc-furnace control system based on fuzzy neural network. In *2006 International Conference on Mechatronics and Automation* (pp. 2459-2464). IEEE.
42. Zhang, S., and Zheng, X. (2007, August). Application of double model control scheme based on RBF inverse identification in electrode system of electrical arc furnace. In *2007 IEEE International Conference on Automation and Logistics* (pp. 485-489). IEEE.
43. Hui, Z., Wang, X., and Wang, X. (2009, July). Prediction model of arc furnace based on improved BP neural network. In *2009 International Conference on Environmental Science and Information Application Technology* (Vol. 3, pp. 664-669). IEEE.
44. Paranchuk, Y. S., and Paranchuk, R. Y. (2016). Neural network system for continuous voltage monitoring in electric arc furnace. *Naukovyi Visnyk Natsionalnoho Hirnychoho Universytetu*, (2), 74–80.
45. Garcia-Segura, R., Castillo, J. V., Martell-Chavez, F., Longoria-Gandara, O., and Aguilar, J. O. (2017). Electric Arc furnace modeling with artificial neural networks and Arc length with variable voltage gradient. *Energies*, 10(9).
46. Elmas, Ç. (2007). *Yapay Zeka Uygulamaları* (Birinci Baskı). Ankara: SEÇKİN Yayıncılık.
47. Sağiroğlu, Ş., Beşdok, E., ve Erler, M. (2003). Mühendislikte Yapay Zeka Uygulamaları-I Yapay Sinir Ağları. *Kayseri: Ufuk Kitap Kırtasiye Yayıncılık*.
48. Erdem, M. (2007). Motorlu taşıtlarda yavaşlatıcı etkilerinin deneysel analizi ve yapay sinir ağları ile modellenmesi, Doktora Tezi, *Gazi Üniversitesi Fen Bilimleri Enstitüsü*, Ankara.
49. Guzel, T. (2010). Filyos hisarönü dalga verilerinin yapay sinir ağları, ARIMA modelleri ve melez modeller ile tahmini , Yüksek Lisans Tezi, *Gazi Üniversitesi Fen Bilimleri Enstitüsü*, Ankara.
50. Jin, X., Ren, T., Shi, X., Jin, R., and Liu, D. (2012). Breakout Prediction System Based on Combined Neural Network in Continuous Casting. In *Advances in Computer Science and Information Engineering* (pp. 349-355). Springer, Berlin, Heidelberg.


51. Kussul, E., Baidyk, T., and Wunsch, D. C. (2010). Applications of Neural Networks in Micromechanics. In *Neural Networks and Micromechanics* (pp. 195-203). Springer, Berlin, Heidelberg.
52. Mugwagwa, L., Nyanga, L., and Mhlanga, S. (2012). Neural Network Breakout Prediction Model for Continuous Casting. *International Journal of Engineering and Advanced Technology (IJEAT)*, 2(2), 380–383.





EKLER

EK-1. Borland Delphi 7.0 ile hazırlanmış ara yüz



EK-2(a). SCL dilinde yazılmış basınç algoritması


- L "E1P"
T "Data".E1_Pressure
NOP 0
- A(
AN "act".CONTROL.E1.Man
A(
L "Data".E1_Pressure
L "Setup".SETPOINTS.Pressure_E1
<I
)
L S5T#500MS
SF T 300
NOP 0
NOP 0
NOP 0
A T 300
)
JNB _018
L "s e t u p".SPEED.NonConductive
T "act".VALVE.OUT_E1
SET
SAVE
CLR
_018: A BR
= "act".CONTROL.E1.Non_Conductive
- A "1"
= L 10.0

EK-2(b). SCL dilinde yazılmış basınç algoritması


```
BLD 103  
CALL "UNSCALE"  
IN := "act".VALVE.OUT_E1  
HI_LIM := -1.000000e+002  
LO_LIM := 1.000000e+002  
BIPOLAR := L10.0  
RET_VAL := #RETURN  
OUT := MW358  
NOP 0
```

- L MW 358
T "E1PROP"
NOP 0


EK-3. Kalıp kanama anı süreç verileri



EK-4. MY programının kalıp kanama problemini tespit edemediği süreç verileri-1



EK-5. MY programının kalıp kanama problemini tespit edemediği süreç verileri-2



ÖZGEÇMİŞ

Kişisel Bilgiler

Soyadı, adı : YILDIZ, Edip
 Uyuğu : T.C.
 Doğum tarihi ve yeri : 15.02.2980, Hatay
 Medeni hali : Evli
 Telefon :
 Faks :
 e-mail : edipyildiz186@hotmail.com



Eğitim

Derece	Eğitim Birimi	Mezuniyet Tarihi
Yüksek lisans	İskenderun Teknik Üniversitesi / Elektrik-Elektronik Mühendisliği	2019
Lisans	Mustafa Kemal Üniversitesi / Elektrik-Elektronik Mühendisliği	2005
Lise	İskenderun Lisesi	1993

İş Deneyimi

Yıl	Yer	Görev
2017-Halen	OYAK Denizcilik ve Liman İşlt. A.Ş.	Bakım Müdürü
2013-2017	Limak Uluslararası Liman İşlt. A.Ş.	Teknik Müdür

Yabancı Dil

İngilizce

Yayınlar

- Esnek Geri Yayılımlı ve Geliştirilmiş Geri Yayılımlı Sinir Ağları Performanslarının Elektrikli Ark Ocaklarında Karşılaştırılması
- Kalıp kanama Sisteminde Klasik Kontrol Algoritmaları Ve Yapay Sinir Ağlarının Performans Karşılaştırması



TEKNOVERSITE



teknoversite **AYRICALIĞINDASINIZ**

İSTE

