



**ÇELİK ESASLI KAYNAKLARIN MEKANİK ÖZELLİKLERİNİN YAPAY
SİNİR AĞLARI İLE TAHMİNİ**

YÜKSEK LİSANS TEZİ

Sabrican DEMİR

Danışman

Prof. Dr. Şükrü TALAŞ

METALURJİ VE MALZEME MÜHENDİSLİĞİ ANABİLİM DALI

Ocak 2024

AFYON KOCATEPE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

YÜKSEK LİSANS TEZİ

ÇELİK ESASLI KAYNAKLARIN MEKANİK ÖZELLİKLERİNİN YAPAY
SİNİR AĞLARI İLE TAHMİNİ

Sabrican DEMİR

Danışman

Prof. Dr. Şükrü TALAŞ

METALURJİ ve MALZEME MÜHENDİSLİĞİ ANABİLİM DALI

Ocak 2024

TEZ ONAY SAYFASI

Sabirican DEMİR tarafından hazırlanan “Çelik Esaslı Kaynakların Mekanik Özelliklerinin Yapay Sinir Ağları İle Tahmini” adlı tez çalışması lisansüstü eğitim ve öğretim yönetmeliğinin ilgili maddeleri uyarınca .. / .. / 2024 tarihinde aşağıdaki jüri tarafından **oy birliği** ile Afyon Kocatepe Üniversitesi Fen Bilimleri Enstitüsü **Metalurji ve Malzeme Mühendisliği Anabilim Dalı’nda YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

Danışman : Prof. Dr. Şükrü TALAŞ

Başkan : Prof. Dr. Şükrü TALAŞ
Afyon Kocatepe Üniversitesi, Teknoloji Fakültesi

Üye : Dr. Öğr. Üyesi Mustafa ŞAHİN
Sağlık Bilimleri Üniversitesi,
Hamidiye Sağlık Hizmetleri Meslek Yüksekokulu

Üye : Dr. Öğr. Üyesi Ahmet ÇETKİN
Afyon Kocatepe Üniversitesi, Teknoloji Fakültesi

Afyon Kocatepe Üniversitesi
Fen Bilimleri Enstitüsü Yönetim Kurulu’nun
..... /..... /..... tarih ve
..... sayılı kararıyla onaylanmıştır.

.....

Prof. Dr. Bekir YALÇIN

Enstitü Müdürü

BİLİMSEL ETİK BİLDİRİM SAYFASI
Afyon Kocatepe Üniversitesi

Fen Bilimleri Enstitüsü, tez yazım kurallarına uygun olarak hazırladığım bu tez çalışmada;

- Tez içindeki bütün bilgi ve belgeleri akademik kurallar çerçevesinde elde ettiğimi,
- Görsel, işitsel ve yazılı tüm bilgi ve sonuçları bilimsel ahlak kurallarına uygun olarak sunduğumu,
- Başkalarının eserlerinden yararlanılması durumunda ilgili eserlere bilimsel normlara uygun olarak atıfta bulunduğumu,
- Atıfta bulunduğum eserlerin tümünü kaynak olarak gösterdiğimi,
- Kullanılan verilerde herhangi bir tahrifat yapmadığımı,
- Ve bu tezin herhangi bir bölümünü bu üniversite veya başka bir üniversitede başka bir tez çalışması olarak sunmadığımı

beyan ederim.

31 / 01 / 2024

Sabrice DEMİR

ÖZET

Yüksek Lisans Tezi

ÇELİK ESASLI KAYNAKLARIN MEKANİK ÖZELLİKLERİNİN YAPAY SİNİR AĞLARI İLE TAHMİNİ

Sabrican DEMİR

Afyon Kocatepe Üniversitesi

Fen Bilimleri Enstitüsü

Metalurji ve Malzeme Mühendisliği Anabilim Dalı

Danışman: Prof. Dr. Şükrü TALAS

Kaynaklı yapılar makine bina gemi gibi karmaşık sistemlerin bir araya getirilmesinde sıklıkla kullanılan endüstriyel bir yöntemdir. Kaynak metalini oluşturan elementler kaynağın mekanik özelliğini belirlerken bu etkiyi kaynak metalinin mikroyapısını değiştirerek gerçekleştirmektedir. Sinir ağları ile analiz birçok alanda rahatlıkla kullanılabilen gerek verim artışı ve gerekse iyi bir analiz yapmak için kullanılan oldukça yeni bir metodolojidir. Kaynak metal özelliklerinin sinir ağlarını kullanarak yapısal ve alaşım elementleri arasındaki ilişkilerini incelemek sinir ağları vasıtasıyla analiz etmek bu çalışmanın temel amacıdır. Bu araştırmada, Lavenberg-Marquardt algoritması (LM) kullanarak kaynak metalindeki fiziksel özellikleri yapay sinir ağları ile tahminini gerçekleştirmektedir. LM algoritması, yapay sinir ağlarının eğitim sürecinde kullanılan bir optimizasyon algoritması olup, bir tahmin fonksiyonu ile gerçek veri arasındaki farkı azaltmayı amaçlar. Geleneksel yöntemlerin zaman alıcı ve maliyetli olması nedeniyle, yapay zekâ tekniğiyle fiziksel özelliklerin hızlı ve doğru bir şekilde yapılması, endüstriyel üretim süreçlerinde zaman, maliyet ve işçilik açısından önemli bir avantaj sağlamaktadır. Araştırmanın başarı oranları asiküler ferrit için %93,135 sertlik için %95,923 akma noktası için %94,17 maksimum çekme mukavemeti için %96,324 olarak bulunmuştur.

2024, xi + 84 sayfa

Anahtar Kelimeler: Yapay zekâ, YSA, LM, Kaynak metal, Element oranı, Tahmin

ABSTRACT

M.Sc. Thesis

Prediction of Mechanical Properties of Steel Based Welds With Artificial Neural
Networks

Sabircan DEMİR

Afyon Kocatepe University

Graduate School of Natural and Applied Sciences

Department Of Metallurgical And Materials Engineering

Supervisor: Prof. Şükrü TALAŞ

Welded structures are industrial methods frequently employed in assembling complex systems such as machines, buildings, and ships. The mechanical properties of the welding metal are determined by the elements constituting the source, and this effect is achieved by altering the microstructure of the welding metal. Neural network analysis is a relatively new methodology widely applicable in various fields, aiming to enhance efficiency and facilitate thorough analysis. The primary objective of this study is to investigate the relationships between structural and alloy elements in welding metal using neural networks and analyze them through this innovative methodology. In this research, the Levenberg-Marquardt algorithm (LM) is utilized to predict the physical properties of welding metal through artificial neural networks. The LM algorithm is an optimization algorithm used in the training process of artificial neural networks, aiming to minimize the difference between a prediction function and actual data. Due to the time-consuming and costly nature of traditional methods, the application of artificial intelligence techniques for the rapid and accurate determination of physical properties offers a significant advantage in terms of time, cost, and labor in industrial production processes. The success rates of the research are found to be 93.135% for acicular ferrite, 95.923% for hardness, 94.17% for yield point, and 96.324% for maximum tensile strength.

2024, xi + 84 pages

Keywords: Artificial intelligence, ANN, LM, Welding metal, Element ratio, Prediction

TEŞEKKÜR

Çalışmamın her aşamasında bana destek olan bilgi ve deneyimleri ile yol gösteren kıymetli danışman hocam Sayın Prof. Dr. Şükrü TALAŞ'a ve bilgi ve tecrübesi ile yüksek lisans eğitim hayatımın tüm zorlu aşamalarında desteklerini esirgemeyen, tecrübeleri ile beni aydınlatan sevgili hocam Sayın Dr. Öğr. Üyesi Mustafa ŞAHİN'e ve öneri eleştirileriyle yardımlarını esirgemeyen Öğr. Gör. Ramazan GÖK ve Öğr. Gör. Ender OYMAN'a en içten teşekkürlerimi sunarım.

Ayrıca, tez yazım sürecinde benden desteklerini esirgemeyen babam Nurettin DEMİR'e, abim Fahrettin DEMİR'e ve bütün aile bireylerime sonsuz teşekkürlerimi sunarım.

Sabrican DEMİR
Afyonkarahisar 2024

İÇİNDEKİLER DİZİNİ

	Sayfa
ÖZET	i
ABSTRACT	ii
İÇİNDEKİLER DİZİNİ.....	iv
SİMGELER ve KISALTMALAR DİZİNİ	viii
ŞEKİLLER DİZİNİ.....	x
ÇİZELGELER DİZİNİ.....	xi
1. GİRİŞ.....	1
2. LİTERATÜR BİLGİSİ.....	2
2.1 Yapay Zekâ	2
2.1.1 Yapay Zekânın Tarihçesi	2
2.1.2 Yapay Zekânın Kullanım Alanları	7
2.1.2 Yapay Zekânın Sınıflandırılması	8
2.2 Yapay Sinir Ağları	9
2.2.1 Biyolojik Sinir Hücresi	10
2.2.2 Yapay Sinir Hücresi	10
2.2.3 Yapay Sinir Ağlarının Yapısı.....	11
2.3 Yapay Sinir Ağlarında İşlem Elemanları.....	12
2.3.1 Girdiler	12
2.3.2 Ağırlıklar	12
2.3.3 Birleştirme Fonksiyonu	12
2.3.4 Aktivasyon Fonksiyonu	13
2.3.5 Çıktı.....	16
2.4 YSA’da Öğrenme Çeşitleri	17
2.4.1 İzlenimli (Supervised) Öğrenme	17
2.4.2 İzlenimsiz (Unsupervised) Öğrenme.....	17
2.4.3 Yarı İzlenimli (Semi-Supervised) Öğrenme	18

2.4.4 Takviyeli (Reinforcement) Öğrenme	18
2.5 YSA'da Öğrenme Kuralları	18
2.5.1 Hebb Kuralı	18
2.5.2 Hopfield Kuralı	19
2.5.3 Kohonen Kuralı	19
2.5.4 Delta Kuralı	20
2.5.5 Levenberg-Marquart algoritması	21
2.5.6 Bayesian Regülasyonu	21
2.5.7 Scaled Conjugate Gradient Yöntemi	22
2.6 Yapay Sinir Ağlarının Katmanları	22
2.6.1 Tek Katmanlı Sinir Ağı (Single Layer Neural Networks)	23
2.6.2 Çok Katmanlı Sinir Ağı (Multi Layer Neural Networks)	25
2.7 Yapay Sinir Ağlarının Bağlantı Yapısı	25
2.7.1 İleri Beslemeli (Feedforward) Yapay Sinir Ağı	26
2.7.2 Geri Beslemeli (Backpropagation) Yapay Sinir Ağı	27
2.8 Yapay Zekâ Yazılımları	28
2.9 Yapay Sinir Ağı Performansının Değerlendirme Kriterleri	29
2.10 Kaynak (Welding)	30
2.10.1 ITAB Bölgesi (Isı Tesiri Altındaki Bölge)	31
2.11 Elektrik Ark Kaynağı (EAW)	33
2.12 Kaynak Arkı	33
2.12.1 Kaynak Elektrotları	33
2.12.1 Kaynak Havuzu	34
2.13 Kaynak Metalinin Özellikleri	34
2.13.1 Asiküler Ferrit (AF)	35
2.13.2 Sertlik (HRD)	35

2.13.3 Akma Dayanımı (YS)	39
2.13.4 Maksimum Çekme Dayanımı (UTS)	40
2.14 Alaşım Elementlerinin Kaynak Metaline Etkisi	41
2.14.1 Karbon (C) Elementinin Kaynak Metaline Etkisi	42
2.14.2 Silisyum (Si) Elementinin Kaynak Metaline Etkisi	42
2.14.3 Mangan (Mn) Elementinin Kaynak Metaline Etkisi	42
2.14.4 Titanyum (Ti) Elementinin Kaynak Metaline Etkisi.....	42
2.14.5 Alüminyum (Al) Elementinin Kaynak Metaline Etkisi	43
2.14.6 Niyobyum (Nb) Elementinin Kaynak Metaline Etkisi.....	43
2.14.7 Vanadyum (V) Elementinin Kaynak Metaline Etkisi	43
2.14.8 Molibden (Mo) Elementinin Kaynak Metaline Etkisi.....	44
2.14.9 Krom (Cr) Elementinin Kaynak Metaline Etkisi	44
2.14.10 Nikel (Ni) Elementinin Kaynak Metaline Etkisi.....	44
2.14.11 Bakır (Cu) Elementinin Kaynak Metaline Etkisi	45
2.14.12 Bor (B) Elementinin Kaynak Metaline Etkisi	45
2.14.13 Oksijen (O) Elementinin Kaynak Metaline Etkisi	45
2.14.14 Azot (N) Elementinin Kaynak Metaline Etkisi	45
2.15 Yapay Zeka Algoritmalarının Kaynak İşlemlerinde Kullanımına Dair Örnekler	46
3.MALZEME ve METOT	48
3.1 Veri Toplama İşlemi	48
3.2 Veri İşleme İşlemi.....	48
3.2.1 Normalizasyon İşlemi	48
3.3 Yapay Sinir Ağı Modelinin Oluşturulması	49
3.3.1 Girdi Parametreleri.....	50
3.3.2 Çıkış Parametreleri.....	51
3.4 Eğitim ve Test.....	53

4. BULGULAR ve TARTIŞMA	60
4.1 Asiküler Ferrit Tahmini	60
4.2 Sertlik Tahmini	60
4.3 Akma Dayanımı Tahmini	62
4.4 Maksimum Çekme Dayanımı Tahmini.....	64
5. SONUÇ ve ÖNERİLER	75
6.KAYNAKLAR.....	76
ÖZGEÇMİŞ	84



SİMGELER ve KISALTMALAR DİZİNİ

Simgeler

A	Alan
B	Bor
C	Karbon
Cp	Çentik Şekline Bağlı Düzeltme Faktörü
Cr	Krom
Cu	Bakır
D	Bilyanın Çapı
d	İz Çapı
F	Kuvvet
G	Gerçek Değer
HBW	Brinell Sertlik Değeri
HK	Knoop Sertlik Değeri
HR	Rockwell Sertlik Değeri
HV	Vickers Sertlik Değeri
L	Çentiğin Uzun Köşegeninin Uzunluğu
Mn	Mangan
Mo	Molibden
N	Veri Adeti
N	Azot
Nb	Niyobyum
Ni	Nikel
O	Oksijen
R	Korelasyon Değeri
r	Yarıçap
R2	Belirleme Katsayısı
Si	Silisyum
T	Tahmini Değer
Ti	Titanyum
V	Vanadyum
W	Modelin Paramesi Vektörü
X	Bağımsız Değişkenlerin Matrisi
λ	Ridge Regresyonu
π	Pi Değeri

Kısaltmalar

AF	Asiküler Ferrit
AI	Yapay Zekâ
Al	Alüminyum
BFG	BFGS Quasi Newton
BP	Geri Yayılım Algoritması
BR	Bayesian Regülasyonu
CGB	Conjugate Gradient Backpropagation
CT	Bilgisayarlı Tomografi
EAW	Elektrik Ark Kaynağı
ETH Zürih	Zürih Federal Teknoloji Enstitüsü)
FCAW	Özlü Ark Kaynağı
GAN	Çekişmeli Üretici Ağ
GMAW	Gaz Metal Ark Kaynağı
GPU	Grafik İşlem Birimi
GTAW	Koruyucu Gazaltı Tungsten Ark Kaynağı
HRD	Sertlik
ITAB	Isı Tesiri Altındaki Bölge
ITAB	Isı Tesiri Altındaki Bölge
LM	Levenberg-Marquardt
MAD	Ortalama Mutlak Sapma
MAG	Metal Aktif Gaz
MAPE	Ortalama Mutlak Yüzde Hatası
MATLAB	Matriks Laboratuvarı
MIG	Gaz Metal Ark Kaynağı
MSE	Ortalama Kare Hatası
NLP	Doğal Dil İşleme
NNT	Neural Network Toolbox
RMSE	Karesel Ortalama Hata Karekökü
RP	Resilient Backpropagation
SAW	Tozaltı Ark Kaynağı
SCG	Scaled Conjugate Gradient
SMAW	Korumalı Metal Ark Kaynağı
SOM	Self-Organizing Map
SSA	Sparrow Search Algoritması
SSE	Hatanın Karesel Toplamı
Tanh	Hiperbolik Tanjant Aktivasyonu
TIG	Koruyucu Gazaltı Tungsten Ark Kaynağı
UTS	Maksimum Çekme Dayanımı
XOR	Exclusive Or
YS	Akma Dayanımı
YSA	Yapay Sinir Ağı

ŞEKİLLER DİZİNİ

	Sayfa
Şekil 2.1 Yapay Zekânın Kronolojik Gelişimi	6
Şekil 2.2 Biyolojik Nöronun Yapısı	10
Şekil 2.3 Yapay Sinir Hücresi	11
Şekil 2.4 Doğrusal Aktivasyon Fonksiyonu	15
Şekil 2.5 Sigmoid Aktivasyon Fonksiyonu	15
Şekil 2.6 Tanjant Hiperbolik Aktivasyon Fonksiyonu	17
Şekil 2.7 Yapay Sinir Ağlarının Katman Yapısı	23
Şekil 2.8 XOR Problemi	24
Şekil 2.9 Çok Katmanlı Yapay Sinir Ağı.....	26
Şekil 2.10 ITAB Bölgesi	31
Şekil 2.11 Kaynak Çeşitleri	32
Şekil 2.12 Vickers Sertlik Deneyi	36
Şekil 2.13 Brinell Sertlik Deneyi	37
Şekil 2.14 Knoop sertlik testi elmas uç temas açısı görüntüsü	39
Şekil 2.15 Çekme Deneyi	41
Şekil 3.1 Kaynak Metalindeki Elementlerin Fiziksel Özelliklerinin Tahmin Uygulamasının Ağ Deseni.....	52
Şekil 3.2 Yapay Sinir Ağı/Veri Yöneticisi	53
Şekil 3.3 Ağ veya Veri Oluşturma	54
Şekil 3.4 Ağ araçları kullanarak ağların eğitilmesi	55
Şekil 3.5 Yapay Sinir Ağı Eğitim Regresyonu AF	56
Şekil 3.6 Yapay Sinir Ağı Eğitim Regresyonu HRD.....	57
Şekil 3.7 Yapay Sinir Ağı Eğitim Regresyonu UTS.....	58
Şekil 3.8 Yapay Sinir Ağı Eğitim Regresyonu YS	59
Şekil 4.1 Asiküler Ferrit Oranı Tahmini.....	61
Şekil 4.2 Asiküler Ferrit veri adeti bağlantısını gösteren R2 ilişkisi.....	61
Şekil 4.3 Sertlik Tahmini.....	62
Şekil 4.4 Sertlik tahmini veri adeti bağlantısını gösteren R2 ilişkisi.....	62
Şekil 4.5 Akma Dayanımı Tahmini	63
Şekil 4.6 YS veri adeti bağlantısını gösteren R2 ilişkisi	63
Şekil 4.7 Maksimum Çekme Dayanımı Tahmini	64
Şekil 4.8 UTS tahmini veri adeti bağlantısını gösteren R2 ilişkisi	65

ÇİZELGELER DİZİNİ

	Sayfa
Çizelge 2.1 Bazı Yapay Sinir Ağları Yazılımları	28
Çizelge 2.2 Rockwell Sertlik Ölçekleri	38
Çizelge 3.1 YSA modelinin oluşturulmasında kullanılan parametreler.....	50
Çizelge 3.2 Bazı Yapay Sinir Ağlarının Karşılaştırılması	50
Çizelge 3.3 Giriş Parametreleri	50
Çizelge 3.4 Çıkış Parametreleri.....	51
Çizelge 4.1 MAPE Başarı Oranları	60
Çizelge 4.2 Karbon Verileri.....	66
Çizelge 4.3 Silisyum Verileri.....	67
Çizelge 4.4 Mangan Verileri.....	67
Çizelge 4.5 Titanyum Verileri	68
Çizelge 4.6 Alüminyum Verileri	68
Çizelge 4.7 Niyobyum Verileri.....	71
Çizelge 4.8 Vanadyum Verileri.....	72
Çizelge 4.9 Molibden Verileri	72
Çizelge 4.10 Krom Verileri	73
Çizelge 4.11 Bakır Verileri	73
Çizelge 4.12 Nikel Verileri.....	74

1. GİRİŞ

Deneysel çalışmalarda kullanılan klasik yöntemler her ne kadar güvenilir sonuçlar verse bile, bu deneylerde kullanılan materyal ve zaman deneyin maliyetini arttırmaktadır. Bu durum yapılan araştırma ve bu deneyleri yapan araştırmacılar için bir dezavantaj olmaktadır. Günümüzde yapay zekâ alanındaki önemli gelişmeler; pek çok sektörde maliyet, işgücü ve zamandan tasarruf sağlama ihtimali sunmaktadır. Özellikle karmaşık ve verilere dayalı problemlerin çözümleri için, yapay zekânın kullanımı yaygınlaşmaktadır. Kaynak metalinin özellikleri kullanılacak olan ana metalin ve dolgu metalinin alaşım elementi içeriği ile doğrudan ilişkilidir. Ancak; kaynak metallerin özellikleri, kullanılan ana malzemenin kalınlığı, kaynak akımı, kaynak çekme süresi ve ana malzemenin büyüklüğü ile doğrudan ilişkilidir. Bu tür parametreler, kaynak metalinin özelliklerini araştırırken hesaplama zorluğu ortaya çıkarmaktadır. Bu nedenle bu tür parametrelerin sabit kaldığı, ancak bileşimin ana parametre olarak kullanıldığı bir çalışmayı kaynak metalinin mekanik ve fiziksel özellikleriyle ilişkilendirmek ve bunu güçlü bir analiz metodolojisiyle yapmak (örneğin yapay zekâ), oldukça faydalı sonuçlar çıkaracaktır. Kaynak metalinin sıklıkla kullanılan bileşimi (C, Mn, Si, Ti vd.), akma noktası, maksimum çekme dayanımı, sertlik ve asiküler ferrit oranı analiz için kullanılmıştır. Kaynak bileşimiyle diğer özellikler arasındaki ilişkiyi analiz etmek, bu çalışmanın temelini oluşturmaktadır. Bu çalışma, literatürde bulunan yöntemlerin yanı sıra, Levenberg-Marquardt (LM) algoritmasını kullanarak kaynak metalindeki element oranları ile yapay sinir ağı eğitilecek ve kaynak metalinin fiziksel özellikleri tahmin edilecektir. Yapılan tahmin yöntemleri karşılaştırılacak ve en uygun yöntem seçilecektir. Kaynak metalindeki element oranları, kaynağın fiziksel özelliklerini ve kaynaklanabilirliğini doğrudan değiştirdiği için, kaynak kalitesini etkilemektedir. Geleneksel yöntemlerle kaynak metalinin fiziksel özelliklerinin ölçülmesi hem zaman hem maliyet açısından külfetlidir. Bu nedenle, yapay zekâ teknikleri kullanarak bu tahmini hızlı ve doğru bir şekilde yapmak; maliyet ve zaman tasarrufu sağlamak açısından önemli bir avantaj sunmaktadır.

2. LİTERATÜR BİLGİSİ

2.1 Yapay Zekâ

Yapay zekâ, "Artificial intelligence" teriminin baş harflerinin birleştirilerek "AI" şeklinde gösterilir (Gümüř 2023). Yapay zekâ, "İnsan zekâsının özelliklerini dijital bir bilgisayara veya bilgisayar kontrollü bir robota aktararak, makinelerin insana benzer zekâ yetenekleri gösterme becerisi kazanmasını sağlama" olarak tanımlanmaktadır (Sanalan 2022).

Başka bir tanım da ise yapay zekâ, "dijital bir bilgisayarın veya bilgisayar kontrollü bir robotun akıllı varlıkla birlikte görevleri yerine getirme yeteneđi" olarak ifade edilmektedir (Sanalan 2022).

McCarthy ise yapay zekâ kavramını "zeki makinelerin, özellikle zeki bilgisayar programlarının oluşturulmasıyla ilgilenen bir bilim ve mühendislik alanı" olarak tanımlamıştır (McCarthy vd. 2006).

2.1.1 Yapay Zekânın Tarihçesi

Yapay zekâ çalışmaları, Cezeri'nin robot çizimlerine kadar uzanabilse de modern anlamda bu çalışmalar, İkinci Dünya Savaşı ve sonrasında önem kazanmıştır (Çořkun ve Güllerođlu 2021). İngiliz matematikçi Alan Mathison Turing, İkinci Dünya Savaşında "Bombe" adını verdiđi ilk tam otomatik kod kırma makinesini icat ederek, savaşın gidişatını deđiřtirmiştir (Acar 2020). İkinci Dünya Savaşı'nın ardından, özellikle Alan Turing gibi İngiliz matematikçilerin önderliğinde birçok bilim insanı yapay zekâ üzerinde çalışmaya başlamıştır. Bu alanda ilk konferans 1947 yılında Alan Turing tarafından verilmiştir. Bu konferansta, İngiliz matematikçi yapay zekâ ve bilgisayar programlarının birleştirilerek, akıllı makinelerin geliştirilebileceđini ortaya koymuştur (McCarthy vd. 2007). Turing, 1950 yılında yayınladıđı bir makalesinde "Makineler düşünebilir mi?" sorusunu cevap aramıştır. "Makine" ve "düşünmek" kavramlarından hareketle yapay zekânın düşünsel temellerini kurmuştur (İnt. Kyn 1). Turing, yapay zekânın fikir babası olarak görölse de "yapay zekâ" terimi ilk defa 1956 yılında Dartmouth Koleji'nde John

McCarthy tarafından, yapay zekâ konulu bir çalıştayda kullanılmıştır (Dick 2019). Frank Rosenblatt, 1957 yılında Perceptron adlı iki katmanlı bir bilgisayar öğrenme ağına dayalı bir robot geliştirmiştir. New York Times gazetesinde yayınlanan bir makalede, bu robotun yakın bir zamanda konuşabilen, yürüyebilen, görebilen ve hatta yazabilen bir robot olacağı belirtilmiştir (Malsburg 1986). Perceptron'un ardından, makinelerin düşünebileceği fikri gelişti. John McCarthy, 1958 yılında yapay zekâ alanında kullanılan LIPS adlı programlama dilini geliştirdi ve ardından bu dilin uygulama sorunlarını çözen bir yöntem geliştirip, 1960 yılında yayınladı. LIPS programlama dili sayesinde, ses tanıma teknolojisi geliştirildi ve bu teknoloji kullanılarak iPhone 4s'nin kişisel asistan uygulaması ortaya çıktı. John McCarthy, 1971 yılında bilgisayar alanında en prestijli ödül olan Turing Ödülü'nü kazandı (Değirmenci 2018).

Carbonell tarafından 1970 yılında geliştirilen, Güney Amerika coğrafyasının sınırlı ve eğitim odaklı diyaloglarıyla şekillendirilen, coğrafya eğitimi alanında yapay zekâ kullanımıyla ilgili Scholar adlı bir yayın ortaya çıktı. Scholar, tarihteki ilk akıllı ders sistemi olarak tanınmaktadır (Morrison ve Rus 2013).

Japonya'da 1972 yılında insana benzeyen ilk robot WABOT-I yapılmıştır. 1974 ile 1980 yılları arasına “Yapay Zekâ Kışı” denmektedir. Bu zamana kadar yapılan harcamalar ve ödenekler karşılığindeki ilerlemenin az olmasından dolayı devletleri olumsuz etkilemiştir (Öztürk ve Şahin 2018). Japonya 1980-1985 yılları arasında, beşinci nesil bilgisayar sistemleri projesine başladı. Bu projenin amacı, konuşmayı sürdürebilen, dilleri tercüme edebilen, resimleri yorumlayabilen ve insan gibi sebepleri bulabilen bilgisayarlar geliştirmektir. Japonya'da 1980 yılında gerçekleştirilen WABOT-II adlı müzisyen robot, insanlarla iletişim kurabiliyor ve müzik notalarını okuyabiliyordu. Ernst Dickmanns liderliğinde, 1986 yılında Bundeswehr Üniversitesi'nde geliştirilen ilk otonom araç, kamera ve sensörlerle donatılmıştı ve boş sokaklarda saatte 55 mil hızla ilerleyebiliyordu. İngiliz yazılım mühendisi Rollo Carpenter tarafından, 1988 yılında geliştirilen Jabberwacky adlı sohbet botu; insan sohbetlerini ilginç, eğlenceli ve mizahi bir şekilde taklit edebilme yeteneğine sahiptir. IBM tarafından geliştirilen Deep Blue adlı yapay zekâ 1997 yılında, dünya satranç şampiyonu Garry Kasparov'u yenmesi bir dönüm noktasıdır. 2010 yılından sonra, yapay zekâ alanında önemli ilerlemeler yaşanmıştır. Örneğin, 2011

yılında IBM'nin geliştirdiği Watson adlı yapay zekâ, ünlü bilgi yarışması Jeopardy'de Rutter ve Jennings gibi şampiyonları yenmiştir. Aynı dönemde Apple, iPhone 4s üzerindeki kullanıcılarla buluşturulan akıllı asistan Siri'yi sunmuştur. Google 2012 yılında, milyonlarca kedi videosunu kullanarak, Google Brain adlı bilgisayar kümesini kedileri tanımak için eğitmiştir. Bu çalışma, derin öğrenme sürecini hızlandırmıştır ve Youtube üzerindeki kedi videolarının analizinde kullanılmıştır. Facebook ise 2013 yılında, beyin hücrelerinin süreçlerini inceleyerek geliştirdiği yapay zekâ ile 700 milyon kişinin verilerini analiz etmektedir. Bu çalışma, derin öğrenme sürecine önemli katkılar sağlamıştır. 2014 yılında, Facebook yüz tanıma konusunda insan zekâsı seviyesine ulaşan yeni bir teknoloji geliştirmiştir. 2015 yılı, yapay zekâ açısından verimli bir dönem olmuştur. ETH Zürih (Zürih Federal Teknoloji Enstitüsü) ve Cambridge Üniversitesi'nin ortak çalışmasıyla kendini geliştiren bir robot tasarlanmıştır. Bu projede "anne" robot, içinde motor bulunan 10 adet "bebek" robot oluşturarak bebek robotların performansını analiz etmiş ve yeni üretilen bebek robotların daha yetenekli olmasını sağlamıştır. Google ise bilgisayar oyunlarını kendi kendine oynayarak "öğrenen" bir yapay zekâ geliştirmiştir. Aynı yıl, Maryland Üniversitesi öğrencileri Youtube videolarını kullanarak yemek yapmayı öğrenen robotlar geliştirmişlerdir. Apple 2016 yılında, "Emotient" adlı yapay zekâyı tanıtmıştır. Bu yapay zekâ, gerçek zamanlı olarak duyguları tanıyabilme özelliğine sahiptir. Bu sayede, gerçek zamanlı hedefleme yaparak kişiye özel reklamlar gösterilebilmektedir. Nvidia şirketi 2017 yılında, "pilotNet" adını verdiği bir yapay sinir ağı geliştirmiştir. Bu yapay sinir ağı, insanları gözlemleyerek otomobil sürmeyi öğrenmiştir. Ayrıca, sürüş sırasında öncelik sıralamasını belirlemek için bir yöntem geliştirmiştir. DeepMind şirketi tarafından geliştirilen AlphaZero adlı yazılım, 2018 yılında oyunların kurallarını ve amacını tanımlamaktan başka, herhangi bir girdiye ihtiyaç duymadan kendi kendine öğrenmeye başladı. AlphaZero, sadece dört saatlik bir öğrenme süreci sonrasında, satranç oyununda bilgisayar satranç şampiyonu Stockfish'i hiçbir oyun kaybetmeden 28 galibiyet ve 72 beraberlikle yenmiştir (Kavuncu 2018). DeepMind şirketi 2019 yılında, AlphaStar adlı bir yazılımı geliştirdi. Bu yazılım, Starcraft II oyununu oynamak için tasarlandı ve oyunda ustalaşarak birçok oyuncuyu yenerek küresel sıralamada yükseldi (Kılıç 2021). 2020 yılında tanıtılan GPT-3, OpenAI tarafından geliştirilen doğal dil işleme modelidir ve 175 milyar parametreye sahiptir. GPT-3, birçok doğal dil işleme görevinde insan performansını aşarak, otomatik dil üretimi, çeviri ve

benzeri uygulamalarda büyük bir potansiyele sahiptir (Brown vd. 2020). Yapay zekâ COVID-19'un teşhisi, tedavisi ve yayılmasını takip etmek için kullanılmaya başlandı. Yapay zekâ CT taramalarını analiz edip hastaları teşhis ederek COVID-19'un tespit edilmesinde yardımcı oldu ve ayrıca pandeminin yayılmasını takip etmek için kullanılan modellerin geliştirilmesinde de kullanıldı (Vaisya vd. 2020). Aynı yıl yapay zekâ tarafından oluşturulan resimler ve videolar, GAN (Generative Adversarial Networks) olarak bilinen bir tür yapay sinir ağı kullanılarak üretildi. Bu teknik yapay zekânın sanat üretimindeki potansiyelini açığa çıkardı (Wang vd. 2021). Günümüzde, yapay zekâ hemen hemen her sektörde kullanılmaktadır. Örneğin; finans, sağlık, eğitim, tasarım, ulaşım gibi farklı alanlarda yapay zekâ kullanılarak iş süreçleri daha hızlı ve verimli hale gelmektedir.

Aşağıdaki Şekil 2.1'de, 1950'lerden günümüze kadar olan yapay zekâ gelişmelerini görebiliriz. Şekil 2.1'de, yapay zekânın tarihini dört ana başlık altında özetlemiştir. Bunlar yapay zekanın doğuşu, altın çağ, yapay zekâ kışı ve GPU çağı olarak sınıflandırılmıştır.

1943 ile 1956 yılları arasındaki "Yapay Zekânın Doğuşu" döneminde, yapay zekâ konseptinin ilk olarak ortaya atıldığı satranç ve dama gibi oyunlar hakkında yazılı programların geliştirildiği görülmektedir.

1956 ile 1974 yılları arasında "Altın Çağ" döneminde, Perceptron adı verilen eğitilebilir tek katmanlı sinir hücresi ve ilk endüstriyel robot şirketi gibi önemli gelişmeler yaşanmıştır.

1974 ile 1980 yılları arasında "Yapay Zekâ Kışı" döneminde, tek katmanlı sinir hücrelerinin çözemediği XOR problemi (eXclusive OR) ortaya çıkmış ve yapay zekâ alanında yavaşlama yaşanmıştır.

2012 yılı ve sonrası "GPU Çağı" olarak adlandırılan dönemde ise, yapay zekâ alanında büyük ilerlemeler kaydedilmiştir. Bu dönemde, yapay zekâ alanında önemli sıçramalar devam etmektedir.


Yapay Zeka Zaman Çizelgesi

Yapay Zekanın Doğuşu 1943-1956

Altın Çağ 1956-1974

Yapay Zeka Kışı 1974-1980

GPU Çağı 2012- Günümüz



Şekil 2. 1 Yapay Zekânın Kronolojik Gelişimi (İnt. Kyn. 2)

2.1.2 Yapay Zekânın Kullanım Alanları

Yapay zekâ, hayatın pek çok alanında farklı uygulamalarda kullanılmaktadır. En çok kullanılan uygulama alanlarından bahsetmek gerekirse bunlar görüntü işleme, doğal dil işleme, reklamcılık, otomotiv endüstrisi, sağlık hizmetleri, finans sektörü, sosyal medya gibi alanlardır. Bu alanları aşağıda belirtilmiştir.

a) Görüntü işleme

Görüntü işleme, dijital görüntü datasının belirli algoritmalar ile işlenip anlamlı bir sonuç elde edilmesidir. Özellikle tarım uygulamaları, araç otomasyonları, tasarım ve imalat uygulamaları gibi alanlarda kullanılmaktadır (Soydan ve Tekin 2021).

b) Doğal dil işleme

Doğal Dil İşleme (NLP) dil çevirisi, metin sınıflandırma, konuşma tanıma gibi alanlarda kullanılabilir (Sinan 2020).

c) Reklamcılık

Bu alanda kullanılan yapay zekâ uygulamaları arasında, müşteri davranışlarını analiz etmek ve hedef kitleye özelleştirilmiş reklamlar sunmak için kullanılan makine öğrenme algoritmaları, chatbotlar ve dijital asistanlar yer almaktadır. Bu uygulamalar sayesinde reklamcılık sektörü, daha etkili ve verimli bir şekilde müşterilere ulaşabilmekte ve onların ihtiyaçlarını karşılayacak ürün ve hizmetleri sunabilmektedir (Binbir 2021).

d) Otomotiv Endüstrisi

Günümüzde insan etkileşimine ihtiyaç duymadan, ya da çok az ihtiyaç duyarak pek çok sürüş ortamında yapay zekâ kullanılmaktadır (Gürtaş 2020).

e) Sağlık Hizmetleri

Yapay zekâ, sağlık hizmetleri alanında da kullanım potansiyeli taşır. Bu teknoloji, hastalıkların teşhisi, tedavisi ve hasta takibi gibi konularda kullanılabilir (Akalin ve Veranyurt 2020).

f) Finans Sektörü

Yapay zekâ, finans sektöründe de etkili bir rol oynar. Örneğin, kredi riski yönetimi, müşteri davranışlarının analizi, sahtecilik tespiti ve otomatik yatırım tavsiyeleri gibi alanlarda kullanılabilir (Yıldız 2022).

g) Sosyal Medya

Sosyal medya platformları, kullanıcıların büyük miktarda veri ürettiği bir alan olması nedeniyle, yapay zekâ teknolojileri tarafından yoğun bir şekilde kullanılmaktadır. Bu alanda yapay zekâ uygulamaları; kişiselleştirilmiş öneriler yapmak, kişiye yönelik reklamlar gibi alanlarda kullanılmaktadır (Karaman 2021).

h) Otonom Sistemler

Otonom sistemler; belirli görevleri yerine getirmek için insan müdahalesine ihtiyaç duymayan, kendi kendine karar verebilen sistemlerdir. Yapay zekâ algoritmaları, otonom sistemlerin işleyişinde önemli bir rol oynar. Bu algoritmaların tasarımında, etik kuralların ve yasal mevzuatın dikkate alınması gerekmektedir. Bu nedenle, yapay zekâ algoritmalarının otonom sistemlerde etik kurallarla uyumlu bir şekilde kullanılması için, standartlar oluşturulması gerekmektedir. Bu standartlar; yapay zekâ teknolojilerinin geliştirilmesi, kullanımı ve yönetiminde etik ve yasal yönleri ele almaktadır (Bryson ve Winfield 2017).

i) Robotik

Yapay zekânın robotik teknolojiler üzerinde kullanımı, üretim süreçlerinde akıllı robotik sistemler oluşturmak için bir yöntem olarak incelenmektedir. Bu yöntem, robotların çevresel faktörleri algılayarak ve çevrelerindeki nesnelerle etkileşim kurarak görevlerini daha verimli bir şekilde yerine getirmelerini sağlamayı hedeflemektedir. Bu amaçla, robot öğrenmesi ve diğer yapay zekâ teknikleri kullanılmaktadır (Liu vd. 2022).

2.1.2 Yapay Zekânın Sınıflandırılması

Yapay zekâ, geniş bir teknik yelpaze içermektedir. Bunlar arasında yapay sinir ağları, bulanık mantık ve sezgisel algoritmalar önemli bir yer tutmaktadır.

2.1.2.1 Yapay Sinir Ağları

Yapay sinir ağları, biyolojik sinir sistemlerinden esinlenerek geliştirilen ve paralel hesaplama yapabilen bir yapay zekâ tekniğidir. Bu teknik, öğrenme sürecinde ağırlıkların belirlenmesi yoluyla veriler arasındaki ilişkileri belirler. Yapay sinir ağları; sınıflandırma, tahmin, desen tanıma ve doğal dil işleme gibi birçok alanda kullanılmaktadır (Bishop ve Nasrabadi 2006).

2.1.2.2 Bulanık Mantık

Bulanık mantık, belirsiz ve karmaşık verilerin işlenmesinde kullanılan bir yapay zekâ tekniğidir. Bu teknik, belirsiz verileri sınıflandırmak ve kontrol etmek için kullanılan bir matematiksel modeldir. Bulanık mantık; görüntü işleme, robotik, trafik akışı yönetimi, tıbbi teşhis ve finansal analiz gibi birçok alanda kullanılmaktadır (Ross 2009).

2.1.2.3 Sezgisel Algoritmalar


Sezgisel algoritmalar, doğal bir evrim sürecine benzer şekilde problem çözmeye çalışan bir yapay zekâ tekniğidir. Bu teknik; genetik algoritma, yapay arı kolonisi, parçacık sürü optimizasyonu ve simüle edilen tavlama gibi algoritmaları içermektedir. Sezgisel algoritmalar; seyahat satışı, nesne yerleştirme, veri sınıflandırma ve tıbbi teşhis gibi birçok alanda kullanılmaktadır (Engelbrecht 2007).

2.2 Yapay Sinir Ağları

Yapay sinir ağları, insan beyninin çalışma prensiplerinden esinlenerek matematiksel modeller olarak tasarlanmıştır. Bu matematiksel modeller, birbirleriyle bağlantılı birçok yapay sinir hücresi (nöronlar) ve bu hücreler arasındaki bağlantıları (sinapslar) içerir. Bu ağlar, girdi verilerini işleyerek çıktı verileri üretir ve eğitim süreciyle örüntü tanıma, sınıflandırma, tahmin gibi işlemleri gerçekleştirebilir. Bu modeli daha iyi anlayabilmek için, öncelikle biyolojik sinir hücrelerinin çalışma mantığını anlamamız gerekmektedir (Öztürk ve Şahin 2018).

2.2.1 Biyolojik Sinir Hücresi

İnsan beyni, çevreden gelen sinyalleri işleyen ve yaklaşık 100 milyar nöron içeren karmaşık bir organdır. Bu milyarlarca nöron birbirleriyle etkileşim halindedir. Nöronlar, dendrit ağları aracılığıyla birbirlerine bağlıdır. Bir nöron sinyal gönderdiğinde, diğer nöronların dendritleri bu sinyali algılar ve hücre gövdesindeki soma bölgesine iletilir. Soma bu sinyalleri işler. Eğer sinyallerin toplamı belirli bir eşik değerini aşarsa, sinyaller akson yoluyla kayıpsız bir şekilde diğer nöronlara iletilir. Bu iletim işlemi, aksonların ucunda bulunan terminal düğmeler aracılığıyla gerçekleşir. Bu terminal düğmeler, diğer nöronlara sinaptik boşluk adı verilen küçük boşluklar aracılığıyla bağlanır. Bu sinaptik boşluklara sinaps denir. Bir nöronun sinapsı, diğer nöronun dendritine bağlıdır (Diler 2003) Şekil 2.2’de biyolojik nöronun yapısı gösterilmiştir.




Şekil 2.2 Biyolojik Nöronun Yapısı (Diler 2003)

2.2.2 Yapay Sinir Hücresi

Yapay sinir hücresi, insan vücudunda bulunan biyolojik sinir hücresinin çalışma biçimi simüle edilerek oluşturulmuş bilgi işleme sistemleridir. Şekil 2.3’te yapay sinir hücresi gösterilmektedir. Yapay sinir hücresi elemanları ve biyolojik sinir hücresi elemanları aşağıdaki gibi eşleşmektedir (Şahin 2010).

- Nöron=İşlemci eleman
- Dendrit= Girdi
- Hücre Gövdesi=Transfer Fonksiyonu
- Akson= Yapay Nöron Çıkışı
- Sinapslar= Ağırlık



Şekil 2.3 Yapay Sinir Hücresi (Öztürk ve Şahin 2018)

2.2.3 Yapay Sinir Ağlarının Yapısı

Yapay sinir ağı, birçok nöronun katmanlar halinde birbirine bağlanmasıyla oluşturulur. Girdiler ilk katmana verilir ve ardından ağından geçerek çıktıyı son katmanda üretir. Bu işlem, ağırlıkların belirlendiği öğrenme süreciyle gerçekleştirilir. Yapay sinir ağlarının yapısı, en az bir girdi katmanı, bir çıktı katmanı ve aralarında bir veya daha fazla gizli katman içerir. Her katman, bir veya daha fazla nöron grubunu barındırır. Katmanlar arasındaki bağlantılar ağırlıklarla belirlenir. Ağırlıklar, ağı öğrenme sürecinde belirlenir ve ağı davranışını etkiler. Bu bağlantılar aracılığıyla girdiler ağına iletilir, ağı içinde işlemler gerçekleştirilir ve sonuç olarak çıktı üretilir (Rumelhart vd.1986).

2.3 Yapay Sinir Ağlarında İşlem Elemanları

Yapay sinir ağlarındaki işlem elemanları; girdiler (input), ağırlıklar (weights), birleştirme fonksiyonu (transfer function), aktivasyon fonksiyonu (activation functions) ve çıktı (output) olarak sınıflandırılabilir.

2.3.1 Girdiler

Yapay sinir ağlarının işlem yapmak için kullandığı veriler, girdi öğeleridir ve genellikle sayısal veya kategorik değerlerden oluşurlar. Bu girdiler, ağın kullanım amacı ve veri tipine bağlı olarak; farklı boyutlarda ve formatlarda olabilir (Aggarwal 2018). Girdiler, ağın öğrenme sürecinde kullanılır. Bu öğrenme süreci, ağı verilerdeki desenleri tanımlamak ve bu desenleri kullanarak verileri sınıflandırmak, tahmin etmek veya diğer görevleri gerçekleştirmek için eğitir. Yapay sinir ağları, girdilerin işlenmesi için çeşitli matematiksel işlemler kullanır. Bu işlemler, girdiler arasındaki ilişkileri ortaya çıkarmaya ve ağın çıktısını üretebilmek için, öznelitliklerinin çıkarılmasına yardımcı olur (Chollet 2018). Girdilerin önemli bir özelliği boyutlarıdır. Boyut, girdi verilerindeki özellik sayısını temsil eder. Boyut; ağın tasarımında önemli bir rol oynar ve farklı türdeki ağlar, farklı boyutlardaki girdileri işlemek için tasarlanır (Nielsen 2015).

2.3.2 Ağırlıklar

Ağırlık, yapay sinir ağının çıktısını giriş verilerine yakınsayan ayarlanabilir değişkenlerdir. Bu değişkenler, rastgele oluşturulabileceği gibi veri tipine göre de oluşturulabilir (Kavuncu 2018). Ağırlıklar, ağın öğrenme sürecinde ayarlanarak optimum çıktıyı elde etmek için optimize edilir (Russel 2010).

2.3.3 Birleştirme Fonksiyonu

Ağırlıklar ile birleşen giriş verileri, birleştirme fonksiyonu ile toplanır. Birleştirme fonksiyonu, ağ yapısına göre maksimum ya da minimum alan veya çarpım fonksiyonu olabilir (Yetkin 2014).

2.3.4 Aktivasyon Fonksiyonu

Aktivasyon fonksiyonu, sinir ağının çıktısının hesaplanmasında kullanılan bir matematiksel fonksiyondur. Bu fonksiyon, nöronların aldıkları girdileri belirli bir çıktı aralığına sıkıştırarak, ağın daha iyi öğrenmesini sağlar. Aktivasyon fonksiyonları genellikle, nöronların çıkışını bir non-lineer şekle sokmak için kullanılır. Bu sayede ağ, daha geniş bir veri kümesinde daha iyi sonuçlar verebilir (Geron 2022). Aktivasyon fonksiyonlarının kullanımı, nöronların hangi bilgiyi ilettiğini belirler ve aynı zamanda nöronların arasındaki ilişkileri de belirler. Aktivasyon fonksiyonları arasında sigmoid, ReLU, tanh gibi farklı seçenekler bulunmaktadır (Goodfellow vd. 2016).

En çok kullanılan aktivasyon fonksiyonları;

- Doğrusal Aktivasyon Fonksiyonu
- Sigmoid Aktivasyon Fonksiyonu
- Tanjant Hiperbolik Aktivasyon Fonksiyonu 'dur.

2.3.4.1 Doğrusal Aktivasyon Fonksiyonu

Doğrusal aktivasyon fonksiyonu, girdi değerlerinin ağırlıklı toplamını hesaplayan ve sonucu döndüren basit bir fonksiyondur. Genellikle regresyon problemlerinde, sürekli bir değer tahmini yapmak için kullanılan çıkış katmanında kullanılır. Doğrusal fonksiyon, herhangi bir girdiyi alabilir ve negatif ile pozitif sonsuzluk arasında herhangi bir değer çıktısı verebilir (Goodfellow vd. 2016). Doğrusal aktivasyon fonksiyonunun kullanımının en büyük avantajı, girdi ve ağırlıklar arasında basit bir nokta çarpımı yapılması nedeniyle hesaplama açısından verimli olmasıdır. Avantajı, giriş-çıkış ilişkisindeki doğrusallığın korunmasıdır ve bu bazı uygulamalarda faydalı olabilir (Rumelhart vd. 1986). Ancak, doğrusal aktivasyon fonksiyonunun bir dezavantajı, girdi ve çıktı arasındaki doğrusal olmayan ilişkileri modelleyememesidir ve bu birçok uygulama için önemli olabilir (Goodfellow vd. 2016). Ayrıca doğrusal aktivasyon fonksiyonu, etiketleri belirleyen sınıflandırma problemleri gibi durumlarda uygun değildir. Sınırlamalarına rağmen doğrusal aktivasyon fonksiyonu, özellikle regresyon problemlerinde belirli durumlarda kullanışlı bir araç olabilir. Basitliği ve verimliliği, özellikle büyük veri kümeleriyle


çalışırken avantajlı bir seçenektir (Goodfellow vd. 2016). Sonuç olarak doğrusal aktivasyon fonksiyonu, özellikle regresyon problemlerinde basit ancak etkili bir araçtır. Basitliği ve hesaplama verimliliği avantajlarına sahip olsa da doğrusal olmayan modellerle çalışan daha karmaşık uygulamalar için uygun olmayabilir. Şekil 2.4'te doğrusal aktivasyon fonksiyonunun grafiği görülmektedir. Doğrusal aktivasyon fonksiyonu Eşitlik (2.1) ile ifade edilir (Yetkin 2014).

$$y=ax \quad (2.1)$$


2.3.4.2 Sigmoid Aktivasyon Fonksiyonu

Sigmoid fonksiyonu, herhangi bir girdi değerini 0 ile 1 arasında bir değere eşleyen ve özellikle ikili sınıflandırma problemlerinde, gizli katmanlarda sıklıkla kullanılan bir aktivasyon fonksiyonudur (Goodfellow vd. 2016). Sigmoid aktivasyon fonksiyonunun bir avantajı, karmaşık ilişkileri yakalayabilen nonlinear bir karar sınırı oluşturabilmesidir. Geriye yayılım tabanlı öğrenme algoritmaları için kullanışlı olması, türevlenebilir olmasından kaynaklanmaktadır (Rumelhart vd. 1986). Ancak, sigmoid aktivasyon fonksiyonunun bir dezavantajı, gradientin aşırı girdi değerleri için çok küçük hale gelerek "kaybolan gradient" sorunu yaşamasıdır. Bu, sigmoid aktivasyon fonksiyonları kullanılarak derin sinir ağlarının eğitimi zorlaştırabilir, çünkü gradyanlar yararlı olacak kadar küçük olamazlar (Bengio vd. 2013). Bu kısıtlamaya rağmen, sigmoid aktivasyon fonksiyonu birçok sinir ağı uygulamasında hala popüler bir seçimdir, özellikle ikili sınıflandırma problemlerinde yaygın olarak kullanılır. Sigmoid aktivasyon fonksiyonu, girdi ve çıktı arasındaki karmaşık ilişkileri yakalamak için uygun bir yapıya sahiptir (Goodfellow vd. 2016). Sinir ağlarındaki kullanımının yanı sıra, sigmoid fonksiyonu ayrıca lojistik regresyon ve olasılık teorisi gibi diğer alanlarda da uygulanmaktadır (Bishop ve Nasrabadi 2006). Genel olarak sigmoid aktivasyon fonksiyonu, özellikle ikili sınıflandırma problemleri için güçlü bir araçtır. Kaybolan gradient sorunu yaşamasına rağmen, girdi ve çıktılar arasındaki nonlinear ilişkileri yakalayabilmesi onu, birçok uygulamada değerli bir araç haline getirmektedir. Sigmoid aktivasyon fonksiyonu sadece pozitif değerler üretir ve Eşitlik (2.2) ile ifade edilir (Yetkin 2014). Şekil 2.5'te sigmoid aktivasyon fonksiyonunun grafiği görülmektedir.

$$f(x) = \frac{1}{1+e^{-x}} \quad (2.2)$$



Şekil 2.4 Doğrusal Aktivasyon Fonksiyonu



Şekil 2.5 Sigmoid Aktivasyon Fonksiyonu

2.3.4.3 Tanjant Hiperbolik Aktivasyon Fonksiyonu

Hiperbolik tanjant (tanh) aktivasyon fonksiyonu, herhangi bir girdi değerini -1 ile 1 arasında bir değere dönüştüren nöral ağlarda popüler bir seçimdir. Sürekli bir

fonksiyondur. Girdi ve çıktılar arasındaki karmaşık ilişkileri yakalamak için özellikle gizli katmanlarda sıklıkla kullanılır (Goodfellow vd. 2016). Tanh aktivasyon fonksiyonunun bir avantajı, farklılaştırılabilir olması ve gradyanının her yerde sıfırdan farklı olmasıdır, bu da backpropagation tabanlı öğrenme algoritmaları için uygun olmasını sağlar (Rumelhart vd. 1986). Ek olarak, sigmoid fonksiyonuna kıyasla vanishing gradient problemine daha az duyarlı olması, daha derin nöral ağlar için daha iyi bir seçimdir (Bengio vd. 2013). Ancak, tanh aktivasyon fonksiyonunun potansiyel bir dezavantajı, sigmoid ve ReLU fonksiyonları gibi diğer aktivasyon fonksiyonlarından hesaplama açısından daha pahalı olmasıdır. Başka bir potansiyel sorun, tanh fonksiyonunun çıktısının her zaman sıfıra yakın olmasıdır, bu da ağa giren veriler her zaman pozitif veya negatifse bir sorun olabilir (Nair ve Hinton 2011). Bu potansiyel sınırlamalara rağmen, tanh aktivasyon fonksiyonu, özellikle çıktıların -1 ile 1 arasında sınırlandığı problemlerde birçok nöral ağ uygulamasında popüler bir seçim olmaya devam etmektedir (Goodfellow vd. 2016).


Nöral ağlardaki kullanımının yanı sıra, tanh fonksiyonunun istatistik ve fizik gibi diğer alanlarda da uygulamaları vardır (Bishop ve Nasrabadi 2006). Genel olarak, tanh aktivasyon fonksiyonu, özellikle çıktıların -1 ile 1 arasında sınırlandığı problemlerde nöral ağ modellemesinde güçlü bir araçtır. Diğer aktivasyon fonksiyonlarına göre hesaplama açısından daha karmaşık olsa da girdi ve çıktılar arasındaki doğrusal olmayan ilişkileri yakalama yeteneği, birçok uygulamada onu değerli bir araç haline getirir. Şekil 2.6'da tanjant hiperbolik aktivasyon fonksiyonunun grafiği görülmektedir. Tanjant hiperbolik aktivasyon fonksiyonunun formülü Eşitlik (2.3)'te verilmiştir (Yetkin 2014).

$$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (2.3)$$

2.3.5 Çıktı

Yapay sinir ağları elemanlarından çıktı, ağın işlemesi sonucunda elde edilen sonuçtur ve genellikle bir hedef değeri ya da bir sınıflandırma sonucunu ifade eder. Çıktı, aktivasyon fonksiyonları kullanılarak hesaplanır ve ağın amacına bağlı olarak farklı türlerde olabilir. Örneğin, regresyon problemlerinde çıktı değerleri sürekli sayısal değerlerdir,

sınıflandırma problemlerinde ise çıktılar, genellikle sınıf etiketleri ya da olasılık dağılımları şeklinde olur (Bishop 1995).



Şekil 2.6 Tanjant Hiperbolik Aktivasyon Fonksiyonu

2.4 YSA'da Öğrenme Çeşitleri

Yapay sinir ağlarında temel olarak dört adet öğrenme çeşidi vardır. Bunlar izlenimli öğrenme, izlenimsiz öğrenme, yarı izlenimli öğrenme ve takviyeli öğrenmedir.

2.4.1 İzlenimli (Supervised) Öğrenme

Eğitim verileriyle birlikte verilen etiketlerin (label) doğru sınıflandırma sonuçlarına göre ağırlıklarının güncellendiği öğrenme türüdür. Bu tür öğrenme yöntemi genellikle sınıflandırma ve regresyon problemlerinde kullanılır (Heaton vd. 2018).

2.4.2 İzlenimsiz (Unsupervised) Öğrenme

Verilerin yapısal özellikleri ve benzerliklerini öğrenmeye yönelik, etiketlenmemiş veriler kullanılarak gerçekleştirilen öğrenme türüdür. Bu tür öğrenme yöntemi, genellikle veri

kümesindeki desenlerin tanımlanmasında ve veri boyutunun azaltılmasında kullanılır. (Heaton vd. 2018).

2.4.3 Yarı İzlenimli (Semi-Supervised) Öğrenme

Bir kısmı etiketlenmiş ve bir kısmı etiketlenmemiş verilerin kullanıldığı öğrenme türüdür. Bu tür öğrenme yöntemi, özellikle büyük veri kümelerinde etiketleme işleminin zorluğunu azaltmak için kullanılır (Heaton vd. 2018).

2.4.4 Takviyeli (Reinforcement) Öğrenme

Ağ, bir görevi gerçekleştirmek için çevresiyle etkileşim halinde olur ve davranışına göre bir ödül veya ceza alır. Bu tür öğrenme yöntemi, özellikle oyun ve robotik gibi alanlarda kullanılır (Sutton ve Barto 2018).

2.5 YSA'da Öğrenme Kuralları

Yapay sinir ağları için öğrenme kuralları, ağın belirli bir problemi çözmek için verilen girdileri işleyerek, sonuçları oluşturduğu matematiksel işlemleri, yapay olarak öğrenmesini sağlayan bir dizi kuraldır. Bu kural setleri, ağı eğitmek için kullanılır ve ağın çıktısıyla gerçek çıktı arasındaki hatayı azaltmayı amaçlar. Bazı öğrenme kuralları arasında delta kuralı, Hebb kuralı, Hopfield kuralı, Kohonen kuralı, Levenberg-Marquardt algoritması vb. bulunur (Ogiela ve Jain 2012).

2.5.1 Hebb Kuralı

Hebb kuralı, nörobilimdeki sinirsel öğrenme prensiplerinden biridir. Bu kural, sinir hücreleri (nöronlar) arasındaki bağlantıların (sinapslar) güçlenmesi veya zayıflaması yoluyla öğrenmeyi açıklar. Hebb kuralına göre, "aynı anda aktif olan nöronlar birlikte ateşlenirler" ve "bir nöron diğerinin ateşlemesine neden olduysa, bu nöronların arasındaki bağlantı güçlenir". Yani, iki nöron arasındaki sinaps gücü, bu iki nöron arasındaki aktivasyon paterninin tekrarlanması sonucunda artar. Hebb kuralı, sinir ağı modellerinde

öğrenme algoritmalarının geliştirilmesinde önemli bir rol oynamıştır. Bu kural, nöronlar arasındaki bağlantıların güncellenmesinde kullanılır ve sinir ağların belirli bir görevi öğrenmesini sağlar. Ancak, Hebb kuralı sadece belirli tipteki öğrenme görevleri için geçerlidir ve bazı durumlarda aşırı uyuma (overfitting) neden olabilir (Hebb 2005).

2.5.2 Hopfield Kuralı

Hopfield kuralı, sinir ağlarındaki hafıza ve hatırlama süreçlerini açıklamak için kullanılan bir algoritmadır. Hopfield ağları, nöronların birbirine bağlı olduğu bir sinir ağı modelidir. Bu ağlar, öğrenme ve hatırlama işlemlerinde kullanılır. Hopfield kuralı, bir Hopfield ağındaki nöronlar arasındaki bağlantıların güncellenmesini sağlar. Hopfield kuralı, "asenكرون çakışma" (asynchronous updating) olarak bilinen bir süreçle çalışır. Bu süreçte, nöronlar tek tek güncellenir ve nöronların değerleri, diğer nöronların yeni değerlerine göre hesaplanır. Hopfield kuralı, nöronların birbirine bağlı olduğu bir ağda, her bir nöronun kendisi ile bağlantılı olan nöronların, değerlerinin çarpımının toplamı şeklinde ifade edilen bir enerji fonksiyonuna dayanır. Bu enerji fonksiyonu, Hopfield ağının hatırlama sürecindeki amaç fonksiyonu olarak kullanılır. Hopfield kuralı, bu enerji fonksiyonunu minimize etmek için kullanılır. Enerji fonksiyonu minimum değere ulaştığında, Hopfield ağındaki nöronlar öğrendikleri bilgiyi hatırlamış olur. Hopfield kuralı, ağdaki nöronların arasındaki bağlantıların güncellenmesinde kullanılır. Bu kural, ağın enerjisini minimize etmek için nöronların değerlerini günceller. Bu güncelleme süreci, nöronların yeni değerlerine bağlı olarak, bağlantıların güncellenmesiyle gerçekleşir (Hopfield 1982).

2.5.3 Kohonen Kuralı

Kohonen kuralı veya Kohonen haritası (Self-Organizing Map-SOM), sinir ağı modellerinde kullanılan bir öğrenme algoritmasıdır. SOM, yüksek boyutlu verilerin düşük boyutlu bir harita üzerinde gösterilmesini sağlar. Bu algoritma, 1982 yılında Finlandiyalı bilim adamı Teuvo Kohonen tarafından geliştirilmiştir. Kohonen kuralı, özyinelemeli (recursive) bir şekilde çalışır ve birbirine yakın olan nöronlar arasındaki bağlantıların güçlenmesi veya zayıflaması yoluyla öğrenme gerçekleştirir. SOM, yüksek

boyutlu verilerin düşük boyutlu bir harita üzerinde gösterilmesini sağlar. Bu harita, nöronların birbirlerine olan benzerliklerine göre oluşur. Yani benzer verilerin, benzer nöronlara atanması sağlanır. Kohonen kuralı, nöronların birbirine olan benzerliklerine göre güncellenmesi esasına dayanır. Bu kurala göre, bir veri örneği ağı verildiğinde, bu örnek ağıdaki en yakın nörona atanır. Daha sonra, bu nöronun çevresindeki nöronların da benzerliği güncellenir. Bu güncelleme işlemi, nöronların kendilerine en yakın olan verileri temsil etmelerini sağlar. Kohonen kuralı, öğrenme işleminin sonunda, ağıdaki nöronların verilere göre konumlandırıldığı bir harita oluşturur. Bu harita, verilerin birbirleriyle olan ilişkilerini gösterir ve veri analizi, görselleştirme gibi işlemlerde kullanılır (Kohonen 1982).

2.5.4 Delta Kuralı

Delta kuralı, sinir ağlarında ağırlıkların ve bias'ın güncellenmesinde kullanılan bir yöntemdir. Delta kuralı, geri yayılım algoritmasının bir parçası olarak kullanılır, hata fonksiyonunun ağırlık ve biaslara göre türevlerini hesaplar. Bu türevler, ağırlıkların ve bias'ın güncellenmesinde kullanılır. Delta kuralı, 1960'ların sonunda Widrow ve Hoff tarafından tanıtıldı, yaygın olarak kullanılan bir yöntem haline geldi. Delta kuralı, birçok sinir ağı modelinde kullanılabilir, eğitim sürecinde ağırlıkların ve bias'ın doğru bir şekilde ayarlanmasına yardımcı olur (Widrow ve Hoff 1960). Bias, sinir ağı modellerindeki nöronların aktivasyon fonksiyonlarının hesaplanmasında kullanılan sabit bir terimdir. Bu terim, nöronun aktivasyon işleminin bir sonucu olarak elde edilen çıkış değerine eklenir. Bias terimi, nöronun aktivasyon eşiğini temsil eder ve ağırlıklarla birlikte nöronun çıkışını belirler. Eğitim sürecinde, bias değerleri ağırlıklarla birlikte uygun bir şekilde ayarlanır ve hata fonksiyonunun azaltılması için optimize edilir (Goodfellow vd. 2016). Delta kuralının formülü, ağırlık ve biasların güncellenmesinde kullanılan delta değerinin hesaplanması için kullanılır. Delta değeri, hata fonksiyonunun ağırlık ve biaslara göre türevinin çarpımıdır. Delta kuralı, hata fonksiyonu türevlerinin hesaplanmasını gerektirir ve bu hesaplama, birçok farklı teknik kullanılarak yapılabilir (Bishop 1995). Delta kuralı, birçok farklı sinir ağı modelinde kullanılır. Özellikle, çok katmanlı perceptron, geri yayılım ağı ve Hopfield ağı gibi sinir ağı modellerinde kullanılır. Delta kuralı, sinir

ağlarının eğitim sürecinde kullanılarak, modelin doğruluğunu ve performansını arttırmaya yardımcı olur (Widrow ve Hoff 1960).

2.5.5 Levenberg-Marquardt algoritması

Levenberg-Marquardt (LM) algoritması, en küçük kareler (nonlinear least squares) problemlerinin çözümü için kullanılan bir iteratif algoritmadır. Bu algoritma, en küçük kareler yöntemine dayanır ve genellikle ağırlıklı regresyon, sınırlandırılmış en küçük kareler ve parametre tahmini gibi uygulamalarda kullanılır (Levenberg 1944). LM algoritması, 1960'larda Kenneth Levenberg ve Donald Marquardt tarafından bağımsız olarak geliştirildi. Bu algoritma, Gauss-Newton yöntemi ve Newton-Raphson yöntemi gibi diğer iteratif en küçük kareler çözücülerinden farklıdır. LM algoritması, hesaplama sırasında Gauss-Newton yönteminin avantajlarını ve Newton-Raphson yönteminin kararlılık avantajlarını birleştirir (Marquardt 1963). LM algoritması, iteratif bir yöntemdir ve her bir adımda ağırlık vektörüne göre fonksiyonun türevi hesaplanır. Hesaplanan türevler, hatanın azaltılması için ağırlık vektörünün güncellenmesinde kullanılır. LM algoritması, güncelleme işleminin isteğe bağlı olarak düzenlenmesine olanak tanır ve böylece çözümün kararlılığını artırır. LM algoritması, birçok farklı matematiksel problemin çözümünde kullanılır. Özellikle ağırlıklı regresyon, sistem kimliği, örüntü tanıma ve optimizasyon gibi uygulama alanlarında yaygın olarak kullanılır (Levenberg 1944).

2.5.6 Bayesian Regülasyonu

Bayesian Regularization (BR), makine öğrenmesi algoritmalarında aşırı uyum (overfitting) problemini çözmek için kullanılan bir yöntemdir. Bu yöntemde, model parametrelerinin olası değerleri üzerine bir olasılık dağılımı belirlenir ve bu dağılım modelin eğitim verilerine uyumunu etkiler. Bayesian Regularization, aynı zamanda Ridge Regression olarak da bilinir. Bu yöntem, geleneksel en küçük kareler (least squares) yöntemine bir L2 normu ekleyerek çalışır. Bu eklenen L2 normu, modelin parametrelerini büyük değerler almaktan kaçınmaya teşvik eder ve böylece aşırı uyumu önler. Matematiksel olarak, Bayesian Regularization, aşağıdaki denklem (2.4)'i minimize eder.

$$\min ||Y - Xw||^2 + \lambda ||w||^2 \quad (2.4)$$

Bu denklemde Y: bağımlı değişkenlerin vektörü

X: bağımsız değişkenlerin matrisi

W: modelin parametrelerinin vektörü

λ : Ridge Regresyonun bir hiper parametresini ifade etmektedir.


2.5.7 Scaled Conjugate Gradient Yöntemi

Scaled Conjugate Gradient (SCG), makine öğrenmesi algoritmalarında kullanılan bir optimizasyon yöntemidir. SCG, en küçük kareler yöntemi (least squares) gibi doğrusal olmayan regresyon problemlerinde kullanılabilir. SCG, diğer gradyan tabanlı yöntemlerden farklı olarak, özellikle yüksek boyutlu parametre uzayları için daha etkili olabilen bir ölçekleme (scaling) stratejisine dayanır. Bu ölçekleme, gradyanın yönünü ve büyüklüğünü değiştirir, böylece algoritma daha hızlı ve daha doğru bir şekilde minimuma yaklaşabilir. SCG algoritması, iteratif bir yöntemdir, her adımda gradyan hesaplanır ve ölçeklenir. Ardından, bir arama yönü belirlenir ve en küçük hatayı veren parametreler arasında bir adım yapılır. Bu adımlar, minimuma doğru yaklaşıma kadar tekrarlanır. SCG, diğer gradyan tabanlı yöntemlerden daha hızlı çalışır; en küçük kareler yöntemi, yapay sinir ağları ve destek vektör makineleri gibi birçok makine öğrenmesi algoritmasında kullanılabilir (Moller 1993).

2.6 Yapay Sinir Ağlarının Katmanları

Yapay sinir ağları, birçok farklı şekilde tasarlanabilir ve bu tasarımların en temel farklılıklarından biri, katman sayısıdır. En basit haliyle tek katmanlı bir yapay sinir ağı, sadece girdi katmanı ve çıktı katmanı olmak üzere iki katmandan oluşur. Girdi katmanı, verilerin ağı girildiği yerdir, çıktı katmanı ise ağın sonuçlarını ürettiği yerdir. Bu tür basit yapay sinir ağları genellikle sınıflandırma problemleri için kullanılır. Ancak; daha karmaşık problemleri çözmek için, çok katmanlı yapay sinir ağları kullanılır. Bu ağlar, en az üç katmana sahiptir; bir girdi katmanı, bir çıktı katmanı ve arada kalan bir veya daha

fazla gizli katmandan oluşur. Gizli katmanlar, verilerin işlendiği ve ağıın öğrenme sürecindeki ağırlıkların ayarlandığı yerlerdir. Çok katmanlı yapay sinir ağıları, özellikle derin öğrenme teknikleri ile birlikte kullanıldığında, görüntü, metin ve ses gibi büyük karmaşık veri kümeleri üzerinde yüksek performans gösterirler (Heaton vd. 2018). Şekil 2.7’de yapay sinir ağlarının katman yapısını görüyoruz.



Şekil 2.7 Yapay Sinir Ağlarının Katman Yapısı (Yetkin 2014).

2.6.1 Tek Katmanlı Sinir Ağı (Single Layer Neural Networks)


Tek katmanlı sinir ağıları, aynı zamanda perceptron olarak da bilinen yapay sinir ağlarının sadece bir katmanına sahip olduğu bir türdür. Bu ağılar, ilk olarak Frank Rosenblatt tarafından 1950'lerin sonlarında tanıtılmıştır (Rosenblatt 1958). Bu ağılar genellikle, bir girişin iki sınıfın birine ait olup olmadığını belirleme gibi ikili sınıflandırma problemleri için kullanılırlar (Duda ve Hart 1973). Tek katmanlı sinir ağı, çok katmanlı ağlara göre nispeten daha basittir. Giriş katmanı, giriş katmanını çıkış katmanına bağlayan bir ağırlık kümesi ve bir çıkış katmanı bulunur (Haykin 1994). Çıkış katmanındaki nöronlar, girdileri iki olası sınıflardan birine gruplandırmak için bir eşik fonksiyonu kullanır. Tek katmanlı sinir ağlarını eğitmek için en iyi bilinen algoritmalarından biri, perceptron

öğrenme kuralıdır (Rosenblatt 1958). Perceptron öğrenme kuralı, tahmin edilen çıktı ile gerçek çıktı arasındaki farka dayanarak ağıdaki ağırlıkları ayarlar. Bu işlem, ağ girdilerini doğru bir şekilde sınıflandırabilene kadar devam eder. Tek katmanlı sinir ağlarının karmaşık problemleri çözmek için yetenekleri sınırlıdır. Örneğin, XOR işlevini öğrenemezler (Minsky ve Papert 1969).

Ancak, basit sınıflandırma görevleri için faydalı olur ve daha karmaşık ağlar için bir yapı taşı görevi görür.

2.6.1.1 XOR Problemi

Elamanın I_1 ve I_2 olmak üzere iki özelliği (feature) olduğunu varsayalım. XOR problemi, bu özelliklerin doğrusal olarak ayrılabilir olmadığı bir sınıflandırma problemidir. Bu, tek bir doğrusal sınıflandırıcı ile, doğru bir şekilde sınıflandırılmayacağı anlamına gelir. Bunun yerine, en az iki katman gerektiren bir yapay sinir ağı kullanmak gereklidir. İlk katman, girdi özelliklerinin ayrıntılarını öğrenirken, ikinci katman bu özellikleri bir araya getirerek son sınıflandırmayı yapar. Bu problem, ilk olarak Minsky ve Papert tarafından 1969 yılında yayınlanan "Perceptrons" adlı kitapta tanıtılmıştır (Naguib ve Sherbet 2001).



Şekil 2.8 XOR Problemi (İnt Kyn 3)

Şekil 2.8'de giriş parametreleri olan I_1 ve I_2 değer değişimlerini ve buna bağlı çıkış değerlerini görüyoruz. Bu çıkış değerleri 0 ve 1 olmak üzere iki çeşittir. AND (Ve) problemi ve OR (Veya) problemi iki boyutlu I_1 ve I_2 uzayında tek bir çizgi ile


bölünebilirken, XOR probleminde bölebilmek için bir çizgiye daha ihtiyaç duyulmaktadır. Bu durum, tek katmanlı sinir ağları ile çıktı değerinin hesaplanamaması demek olduğu için, başka bir hesaplama yöntemi geliştirilmesine ve çok katmanlı algılayıcıların geliştirilmesinde rol oynamıştır.

2.6.2 Çok Katmanlı Sinir Ağı (Multi Layer Neural Networks)

Çok katmanlı sinir ağları, aynı zamanda derin sinir ağları olarak da bilinen ve birden fazla katmandan oluşan yapay sinir ağı türüdür. Görüntü tanıma, doğal dil işleme ve konuşma tanıma gibi birçok alanda kullanılırlar. (Bengio ve Vincent 2013). Çok katmanlı sinir ağ yapısı, tek katmanlı bir ağı göre daha karmaşıktır. Bir giriş katmanı, bir veya daha fazla gizli katman ve bir çıkış katmanı içerir. Her katmanın, bir sonraki katmana bağlanan bir ağırlık kümesi vardır ve her katmandaki sinir hücreleri, çıktı üretmek için bir aktivasyon fonksiyonu kullanır (Goodfellow vd. 2016). Çok katmanlı bir sinir ağ eğitimi, kayıp fonksiyonunu en aza indirmek için her katmandaki ağırlıkların ayarlanmasını içerir (Rumelhart vd. 1986). Bu genellikle geri yayılım algoritması kullanılarak yapılır. Geri yayılım, kayıp fonksiyonunun ağırlıklara göre gradyanını hesaplar ve buna göre ağırlıkları günceller. Çok katmanlı sinir ağlarının avantajlarından biri, giriş ve çıkışlar arasındaki karmaşık doğrusal olmayan ilişkileri öğrenebilme yetenekleridir (Bishop 1995). Ayrıca, ham girdi verilerinden özellikleri otomatik olarak çıkarabilme yetenekleri, görüntü tanıma gibi uygulamalarda faydalı olabilir (LeCun vd. 2015). Ancak, derin sinir ağları eğitimi, hesaplama açısından maliyetli olabilir ve büyük miktarda veri gerektirir (Goodfellow vd. 2016). Ayrıca aşırı uyum sorunu, ağı eğitim verilerine çok sıkı bir şekilde ezberlemesi ve yeni verilerde kötü performans göstermesi, bir zorluk olabilir. Bu zorluklara rağmen çok katmanlı sinir ağları, makine öğrenmesinde popüler bir araç haline gelmiş ve birçok görevde en iyi performansı sağlamıştır (Krizhevsky vd. 2017). Şekil 2.9’da çok katmanlı sinir ağı gösterilmektedir.

2.7 Yapay Sinir Ağlarının Bağlantı Yapısı

Bağlantı çeşidine göre yapay sinir ağları, ileri beslemeli (Feedforward) ve geri beslemeli (Backpropagation) olarak ikiye ayrılırlar.



Şekil 2.9 Çok Katmanlı Yapay Sinir Ağı

2.7.1 İleri Beslemeli (Feedforward) Yapay Sinir Ağı

İleri beslemeli yapay sinir ağları, çok katmanlı algılayıcılar olarak da bilinen, girdiden çıktıya doğru tek yönlü bir şekilde bilgi işleyen yapay sinir ağı türüdür. Desen tanıma, sınıflandırma ve regresyon gibi makine öğrenmesi uygulamalarında yaygın bir şekilde kullanılmaktadırlar (Goodfellow vd. 2016). İleri beslemeli yapay sinir ağlarının temel mimarisi, bir girdi katmanı, bir veya daha fazla gizli katman ve bir çıktı katmanından oluşur. Her katman, bitişik katmanlardaki sinir hücreleri ile bağlantılı olan birden fazla yapay sinir hücresinden oluşur. Girdi katmanı girdi verilerini alır, gizli katmanlar tarafından işlenir ve çıktı katmanı ağın çıktısını üretir. (Rumelhart vd. 1986). İleri beslemeli bir sinir ağında sinir hücreleri, önceki katmandan aldıkları girdi sinyalini bir

aktivasyon fonksiyonu kullanarak bir sonraki katmana iletmek için kullanırlar (Bishop 1995). Sinir hücreleri arasındaki bağlantılarla ilişkili ağırlıklar, etiketli örneklerin bir veri kümesindeki ağın eğitilmesi süreciyle öğrenilir ve geriye doğru yayılım gibi yöntemler kullanılır (Rumelhart vd. 1986). İleri beslemeli sinir ağlarının temel avantajlarından biri, girdi ve çıktılar arasındaki doğrusal olmayan ilişkileri öğrenebilme yetenekleridir (Bishop 1995). Ayrıca, yeterli sayıda sinir hücresi ve katman sağlandığında, herhangi bir sürekli fonksiyonu istenilen doğruluk derecesine kadar yaklaşık olarak hesaplayabilirler (Hornik vd. 1989). Ancak, ileri beslemeli sinir ağları, zamanla değişen veya ardışık verilerle başa çıkamama gibi bir dezavantaja sahiptirler ve bu tür verileri işlemek için farklı bir sinir ağı mimarisi, örneğin tekrarlayan sinir ağları gerekir. Ayrıca, aşırı öğrenmeye (overfitting) yatkın olabilirler. Yani ağ, eğitim verilerinde iyi performans gösterirken, yeni ve görülmemiş verilerde kötü performans gösterebilir (Goodfellow vd. 2016). Bu sınırlamalara rağmen, ileri beslemeli yapay sinir ağları, karmaşık doğrusal olmayan ilişkileri modellemedeki basitliği, esnekliği ile etkin olarak kullanılmaktadır.

2.7.2 Geri Beslemeli (Backpropagation) Yapay Sinir Ağı

Geri beslemeli sinir ağları, ileri besleme sinir ağlarını eğitmek için kullanılan bir denetimli öğrenme algoritmasıdır (Rumelhart vd. 1986). Geri beslemeli sinir ağlarının amacı, ağın çıktısının belirli bir girdiyi istenilen çıktıya uyması için, ağıdaki nöronlar arasındaki bağlantılara ilişkin ağırlıkları ayarlamaktır (Bishop 1995). Geri beslemeli sinir ağlarının algoritması, hatayı çıktı katmanından ağına geriye doğru yayılım yaparak işlemekte ve her katmandaki ağırlıkları hata büyüklüğüne bağlı olarak güncellemektedir. Algoritma, hata türevini hesaplamak için matematikteki zincir kuralını kullanır ve hatayı en aza indiren yönde ağırlıkları ayarlar (Rumelhart vd. 1986). Geri beslemeli sinir ağları genellikle gradyan inişi optimizasyon algoritması ile birlikte kullanılır. Algoritma, geri beslemeli sinir ağları algoritması tarafından hesaplanan gradyanları kullanarak ağıdaki ağırlıkları günceller. Stokastik gradyan inişi gibi birçok farklı geri beslemeli sinir ağları varyasyonu vardır. Bunlar, her iterasyonda eğitim verilerinin rastgele bir alt kümesine dayanarak ağırlıkları günceller. (Bishop 1995). Geri beslemeli sinir ağlarının avantajlarından biri, daha karmaşık ve soyut girdi verilerinin temsil edilebildiği çoklu gizli katmanlı sinir ağlarını eğitebilmesidir. (Rumelhart vd. 1986). Ancak, geri beslemeli

sinir ağıları yerel minimumlara takılmaya da eğilimli olabilir ve bu da ağın alt-optimal performansına yol açabilir (Bishop 1995). Sınırlamalarına rağmen geri beslemeli sinir ağıları; görüntü tanıma, doğal dil işleme ve konuşma tanıma gibi birçok farklı alanda başarıyla uygulanmış eğitim algoritmalarından biridir (LeCun vd. 2015).

2.8 Yapay Zekâ Yazılımları

Çizelge 2.1 Bazı Yapay Sinir Ağları Yazılımları

Yazılımlar	Özellikleri
MATLAB	Matlab yapay sinir ağı araç kutusu, çoklu katmanlı algılayıcılar (MLP), geri beslemeli ağlar (RNN), destek vektör makineleri (SVM) ve radial taban fonksiyonları (RBF) dahil olmak üzere birçok yapay sinir ağı algoritmasını içerir.
PyTorch	Facebook tarafından geliştirilen açık kaynak kodlu bir yapay zekâ kütüphanesi ve derin öğrenme programıdır. Hem araştırmacılar hem de endüstriyel uygulamalar için kullanılabilecek birçok araç sunar.
Caffe	Berkley Vision and Learning Center tarafından geliştirilen açık kaynak kodlu bir derin öğrenme programıdır. Hızlı eğitim süreleri için optimize edilmiştir ve görüntü ve video sınıflandırma gibi uygulamalar için popülerdir.
TensorFlow 2.0	Google tarafından geliştirilen açık kaynak kodlu bir kütüphane ve platformdur. Yapay Sinir Ağları için pek çok araç ve API'ler sunar.
Theano	Yapay sinir ağlarının oluşturulması, eğitilmesi ve değerlendirilmesi için açık kaynak kodlu bir derin öğrenme programıdır. GPU'lar ve CPU'lar üzerinde çalışabilir ve Python dilinde yazılmıştır.

Piyasada yapay sinir ağları için geliştirilen ücretli ve ücretsiz pek çok yazılım bulunmaktadır. Çizelge 2.1'de bu yazılımlardan bazıları gösterilmiş ve genel bilgiler verilmiştir.

2.9 Yapay Sinir Ağı Performansının Değerlendirme Kriterleri

Bir yapay sinir ağı performansının değerlendirilmesi, tahminlerin gerçek verilerle ne kadar uyumlu olduğunu belirleyen bir ölçüttür. Bu ölçüt, gerçek ve tahmin edilen veriler arasındaki farka dayanır. Literatürde birçok performans değerlendirme yöntemi bulunmaktadır. En sık kullanılan yöntemler aşağıda sıralanmıştır. (Visalakshi ve Thangavel 2009). Bunlar karesel ortalama hata karekökü (RMSE), ortalama mutlak yüzde hatası (MAPE), ortalama kare hatası (MSE), ortalama mutlak sapma (MAD) ve hatanın karesel toplamıdır. (SSE)

- a) Karesel Ortalama Hata Karekökü (Root Mean Squared Error, RMSE)

$$RMSE = \sqrt{\frac{\sum G-T}{N}} \quad (2.5)$$

- b) Ortalama Mutlak Yüzde Hatası (Mean Absolute Percentage Error, MAPE)

$$MAPE = \frac{\sum \frac{|G-T|}{G}}{N} \cdot 100(\%) \quad (2.6)$$

- c) Ortalama Kare Hatası (Mean Squared Error, MSE)

$$MSE = \frac{\sum (G-T)^2}{N} \quad (2.7)$$

- d) Ortalama Mutlak Sapma (Mean Absolute Deviation, MAD)

$$MAD = \frac{\sum |G-T|}{N} \quad (2.8)$$

- e) Hatanın Karesel Toplamı (Sum of Squared Error, SSE)

$$SSE = \sum (G-T)^2 \quad (2.9)$$

Bu denklemlerde;

- N veri sayısını,
- G gerçek deęerini,
- T tahmin edilen deęeri ifade etmektedir.


2.10 Kaynak (Welding)

Kaynak, genellikle metaller, termoplastikler gibi iki veya daha fazla malzemenin ısı ile işlemle birleştirilmesi ve soęutulması yoluyla kalıcı bir baę oluřturulması işlemidir. Bu işlem inřaat, imalat, tařımacılık gibi biręok endüstride kullanılmaktadır. Boru hatları, basınçlı kaplar, köprüler gibi çeřitli uygulamalarda da kullanılır (Cary ve Helzer, 2019). Metallerin birleřtirmesi için yöntemler binlerce yıldır bilinmektedir, ancak bu süre boyunca kaynak işlemi genellikle demirciler tarafından yapılan dövme kaynak ile sınırlıydı. 19. yüzyılın sonunda, direnç kaynaęı ve ark kaynaęı için yeterli elektrik akımı üretilebilmesiyle beraber yeni kaynak prensipleri ortaya çıktı. Bemados tarafından geliştirilen karbon elektrotlar kullanılarak, önce ark kaynaęı geręekleřtirildi ve kısa bir süre sonra elik ubukların kullanımı bařladı. O dönemde geliştirilen bařka bir kaynak yöntemi de gaz kaynaęıydı. 20. Yüzyılda yeni yöntemler geliştirildi. O zamana kadar tüm metal ark kaynakları, manuel olarak geręekleřtiriliyordu. Sürekli tel kullanarak, süreci otomatikleřtirmeye yönelik girişimler yapıldı. En bařarılı işlem, tozaltı ark kaynaęı (SAW) 'dır. 1940'da inert gazlarla arkın korunmasına yönelik deneyler yapıldı. Bunun sonucunda tungsten bir elektrot kullanarak, elektrotu eritmeden ark akmak mümkün hale geldi. Bu durum, dolgu maddesiyle veya dolgu maddesi olmadan kaynak yapmayı mümkün hale getirdi. Bu yönteme TIG kaynaęı denmektedir. Birkaç yıl sonra, MIG kaynak işlemi geliştirildi ve sürekli beslenen bir tel ile elektrot kullanıldı. Bařlangıta inert gaz olarak helyum veya argon gazı kullanıldı. Fakat daha sonra, kullanılan koruyucu gazı daha kolay temin edilebilen karbondioksit ile deęiřtirmeye alıřtılar. Nispeten daha reaktif olan karbondioksit veya karıřık gazlar kullanılan bu yönteme, MAG kaynaęı denmektedir. Enerji ıřın işlemleri (Power Beam Process) 1958 yılına dayanmaktadır. İlk olarak havacılık ve nükleer enerji endüstrilerinde kullanılmıřtır. Enerji ıřın işlemlerinden olan elektron ıřını ve lazer kaynaęı, en yoğun ısı girdilerine sahiptir. Bazı aılardan lazer


kaynağı ideal özelliklere sahiptir. Lazer ışını yoğunlaştırılmış bir ısı kaynağıdır. Bu sayede çok az bozulma ile çalışma parçasını birleştirebilir (Weman 2011). Otomotiv sektöründe sıkça kullanılan direnç nokta kaynağı, farklı kalınlıklarda ve farklı malzemelerden oluşan kombinasyonları kaynaklayabilmektedir (Doruk E vd. 2015).

2.10.1 ITAB Bölgesi (Isı Tesiri Altındaki Bölge)

ITAB, kaynak işlemi sırasında yüksek ısı nedeniyle mikroyapıda değişikliğe uğrayan bir bölgedir. Ark kaynağı sırasında, kaynak noktası boyunca ilerlerken baz metal hızla ısınır ve ardından soğur. Kaynak sırasında, kaynak dikişine uygulanan enerjiye bağlı olarak hızlı bir şekilde ısınır, kalınlığa ve ön ısıtmaya bağlı olarak soğur. Eğer bu soğuma hızı kullanılan çeliğin kritik soğuma hızından daha yüksekse; sert, kırılkan ve tanecik boyutu büyümüş bir bölge oluşur (Mercan 2019).



Şekil 2.100 ITAB Bölgesi (İnt Kyn4)



Şekil 2.111 Kaynak Çeşitleri (Weman 2011)

2.11 Elektrik Ark Kaynağı (EAW)

Elektrik ark kaynağı, elektrot (bir metal dolgu teli) ve ana malzeme arasında elektrik arkı oluşturarak iki metali birleştirmek için kullanılan bir kaynak işlemidir. Elektrik arkının yarattığı ısı, elektrotu ve ana malzemeyi eritir ve daha sonra soğurarak iki metal arasında sağlam bir bağ oluşturur.

Kaynak işlemi farklı türlerde gerçekleştirilebilir. Kaplanmış elektrot kullanılarak elektrik arkı üreten ve erimiş metal ile birleştiren kaplamalı elektrot kaynağı (SMAW), sürekli bir tel elektrot ve atmosferden kaynağı koruyan bir koruyucu gaz kullanan gazaltı kaynağı (GMAW), akışkan bir çekirdekli tel ve bir koruyucu gaz kullanarak gerçekleştirilen özlü ark kaynağı (FCAW), tungsten elektrot ve koruyucu gaz kullanarak yüksek ısı kontrolü ile mükemmel kaynak yapılabilen gaz tungsten ark kaynağı (GTAW) gibi çeşitli elektrik ark kaynağı yöntemleri mevcuttur. (Weman 2011).

2.12 Kaynak Arkı

Kaynak işlemi sırasında, kaynak akımı iki kablo aracılığıyla iletilir. Bir kablo iş parçasına, diğer kablo ise elektroda bağlanır. Elektrot iş parçasına temas etmediği sürece, iş parçası ile elektrot arasındaki hava direnci yüksek olduğundan devreden akım geçmez. Ancak elektrot iş parçasına temas ettiğinde, hareketi engelleyen bir direnç olmadığı için akım devrede hareket etmeye başlar. Temas noktasında ideal bir temas olmadığından elektrik direnci diğer kısımlardan daha yüksek olur. Bu durum, temas noktasında ısı kaybına yol açar, temas noktası ısınır ve metal buharı ve iyonizasyon oluşur. Metal buharı, bulunduğu bölgeyi iletken hale getirir. Bu sırada elektrot biraz geri çekilirse, oluşan akım metal buhar aracılığıyla akışını sürdürür ve elektrot ile iş parçası arasında bir "ark" oluşur. Arkın gücü, akım şiddetiyle doğru orantılı olarak artar (Özdemir 2006).

2.12.1 Kaynak Elektrotları

Elektrik ark kaynağında kullanılan elektrotlar iki ana gruba ayrılır. Bunlardan, ergimeyen elektrotlar, yapısal bütünlüğünü koruyan ve kaynak esnasında erimeyen elektrotlardır.

Elektrot, kaynak sırasında oluşan yüksek sıcaklığa dayanacak şekilde tasarlanmış olup, elektriksel iletimi sağlarlar. Ergiyen elektrotlar ise kaynak işlemi sırasında eriyen ve kaynak havuzuna katkı sağlayan elektrotlardır. Bu elektrotlar kendi arasında çıplak, örtülü ve özlü olmak üzere üç gruba ayrılır (Özdemir 2006).

2.12.1 Kaynak Havuzu

Elektrik ark kaynağı yöntemlerinde kaynak bölgesi, sıvı metal hacmini temsil eder ve bu miktar, kaynak parametrelerine bağlı olarak değişir. Kaynak metal hacmi, kaynak akımının artmasıyla birlikte büyürken, kaynak hızının artmasıyla azalır. Kaynak bölgesi ile ısıtılma sonrası sertlik (ITAB) arasında bir ilişki bulunmaktadır. Sıvı metal miktarı arttıkça, kaynak bölgesinin soğuma hızı azalır ve bu da sertlikte bir düşüşe neden olur. Ayrıca, kaynak metal hacminin artmasıyla mukavemet de azalır. Kaynak metalinin kimyasal bileşimi, kaynak metal havuzunda yüksek sıcaklıklarda gerçekleşen kimyasal reaksiyonlar tarafından kontrol edilir. Ayrıca, kaynak metalindeki deoksidasyon reaksiyonları, kaynak metalinin kimyasal bileşimini, son mikroyapıyı ve mekanik özellikleri etkiler.

Kaynak havuzu iki bölümden oluşur. Bunlar, sıcak bölge ve soğuk bölgedir. Sıcak bölgede sıcaklıklar 1800 derecenin üzerindedir. Bu bölgede, sıvılaşmış metalin oksidasyonu ve deoksidasyonu gerçekleşir. Yüksek türbülans, çökelen cürufu yüzeye çıkarır. Kaynak havuzunun görece soğuk bölgesinde sıcaklık 1800 derecenin altındadır. Türbülans düşük olduğu için cüruf kaynak metalinden ayrılmaz (İnt Kyn 5).

2.13 Kaynak Metalinin Özellikleri

Kaynak metalinde en önemli özellikler tokluk ve dayanımdır. Kaynak metalinin özellikleri baz metalin tokluk ve dayanımından yüksek olmalıdır. Akma ve çekme dayanımları her zaman yüksek olmalıdır. Kaynak metalinin özellikleri; çökme, oluşan tanecik boyutu, ITAB bölgesi ve mikroyapıdan etkilenir.

2.13.1 Asiküler Ferrit (AF)

Asiküler ferrit, genellikle soğuma sürecinde düşük alaşımlı çeliklerin kaynak metalinde oluşur. Bu yapı, 650 derece altındaki soğuma koşullarında gelişir ve tokluk ile dayanımının artmasını etkiler. Asiküler ferrit, iğne benzeri bir yapıya sahiptir, ancak üç boyutlu olarak mercimek tanelerini andıran levhalara benzer. Kaynaklı yapı çeliklerinin mikroyapısı, ITAB bölgesinin mikroyapısından farklıdır.

Asiküler ferrit, kaynak metalllerinde ilk oluşan yapıdır ve mikro alaşımlı çeliklerde haddeleme sonrasında kaynak metalllerinde oluşur. Asiküler ferrit, kaynak metalllerinde, ferrit oksidik inklüzyonların heterojen çekirdeklenmesi sonucunda oluşur. Kaynak metalinin düşük sıcaklıklarda yeterli tokluğa sahip olabilmesi için oksijen içeriği 300-500 ppm aralığında olmalıdır. Oksijen içeriği düşük olduğunda, küresel oksidik inklüzyonların oranı azalırken, asiküler ferrit miktarı önemli ölçüde azalır (İnt Kyn 5).


2.13.2 Sertlik (HRD)

Sertlik, malzemenin yüzeyine sert ve batıcı bir uç ile uygulanan kuvvete karşı gösterdiği dirençtir (Brice, 2003). Bu direnç, oluşan izin deformasyonu ile ölçülür. Kaynak metalinin sertliği, kaynaklı birleşimin mekanik özelliklerini ve performansını doğrudan etkileyen önemli bir karakteristik özelliktir (Lippold 2014). Kaynak metalinin sertliğini etkileyen birçok faktör vardır. Kaynak işlemi sırasında soğutma hızı, önemli bir faktördür. Hızlı soğutma, daha ince bir mikroyapının oluşması nedeniyle daha yüksek bir sertliğe yol açar. Öte yandan, daha yavaş soğutma hızları daha kaba tane yapısı ve daha düşük sertlik ile sonuçlanabilir. Isı girişi ve kaynak hızı da soğutma hızını ve ardışık olarak kaynak metalinin sertliğini belirlemede rol oynar (Kou 2003).

Kaynak metalinin sertliğini etkileyen bir başka faktör, baz ve dolgu metalllerinin kimyasal bileşimidir. Dolgu metalinde bulunan alaşım elementleri, sertliği önemli ölçüde etkileyebilir. Örneğin; çelik dolgu metallere karbon eklenmesi sertliği artırırken, krom ve molibden gibi belirli alaşım elementlerinin varlığı kaynak metalinin sertleşebilirliğini artırır (John 2001). Kaynak metalinde aşırı sertlik, özellikle yüksek stresli uygulamalarda

çatlama eğilimini artırır. Bu nedenle, sertlik ve tokluk arasında uygun bir dengeyi sağlamak, kaynaklı birleşimin bütünlüğü ve güvenilirliği için önemlidir (Lippold 2014). Kaynak metalinin sertliği, baz metalin kompozisyonu, dolgu metali ve kaynak işlem parametreleri gibi çeşitli faktörlerden etkilenir. Kaynaklı birleşimin mekanik özellikleri üzerinde doğrudan bir etkiye sahiptir. Sertlik ve tokluk arasında uygun bir denge sağlanması, kaynaklı birleşimin bütünlüğünü ve güvenilirliğini sağlamak için önemlidir (Lippold 2014). Sertlik ölçüm yöntemlerinden bazıları aşağıda verilmiştir.

Vickers sertlik testi 1921 yılında Robert L. Smith ve George E. Sandland tarafından malzemelerin sertlik değerini belirlemek amacıyla Brinell metoduna alternatif olarak keşfedilmiştir (Smith, Sandly 1922). Bu test, çentik oluşturan ucun boyutlarından bağımsız olarak sertlik hesaplaması yapabilmesi ve test edilecek malzemenin sertliğine bakılmaksızın tüm malzemelerde kullanılabilmesi nedeniyle, diğer yöntemlere kıyasla daha kolay bir işlem sunar. Vickers sertlik testi, malzeme endüstrisinde yaygın olarak tercih edilen bir sertlik ölçüm yöntemidir. Bu test yönteminde kullanılan elmas ucun her bir kenarının yatayla yapmış olduğu açı 22° olarak tasarlanmıştır (İnal, 2016). Şekil 2.12’de vikers sertlik deneyi gösterilmiştir. Vickers sertlik formülü 2.10’olu denklemde gösterilmiştir.




Şekil 2.12 Vickers Sertlik Deneyi

$$HV = \frac{F}{A} \approx \frac{1.8544F}{d^2} \quad (2.10)$$

Bu denklemde:

- HV Vickers Sertlik Deęeri,
- F uygulanan kuvveti,
- A ise alanı temsil etmektedir.

Brinell sertlięi, sert bir malzemeden yapılmıř belirli bir aptaki bilyanın, belirli bir yk ile malzemeye belirli bir srede uygulanmasıyla elde edilen izin apının llmesiyle bulunur. Brinell sertlik deęeri uygulanan kuvvetin ve oluřan izin, kresel yzey alanına orantısıdır. Bu yntem yaygın kullanılan bir sertlik lm yntemidir (Kuzu, 2006). řekil 2.13’de brinell sertlik deneyi gsterilmiřtir.



řekil 2.13 Brinell Sertlik Deneyi

Brinell sertlik deęeri 2.11’nolu denklemde gsterilmektedir.

$$HBW = \frac{2F}{\pi D \cdot (D - \sqrt{D^2 - d^2})} \quad (2.11)$$

Bu denklemde:

- HBW Brinell Sertlik Değeri,
- D bilyanın çapı,
- d oluşan izin çapı
- F ise uygulanan kuvveti ifade etmektedir.


Çizelge 2.2 Rockwell Sertlik Ölçekleri (Kuzu, 2006)

Rockwell Sertlik Ölçeği	Sertlik Sembolü	Kullanılan Uç	Ön Yük (N)	Ek Yük (N)	Toplam Yük (N)	Uygulama Alanı (Rockwell Sertlik Testi)
A	HRA	Elmas Uç	98,07	490,3	588,4	20HRA-88HRA
B	HRB	1,5875mm Bilya Uç	98,07	882,6	980,7	20HRB-100HRB
C	HRC	Elmas Uç	98,07	1373	1471	20HRC-70HRC
D	HRD	Elmas Uç	98,07	882,6	980,7	40HRD-77HRD
E	HRE	3,175mm Bilya Uç	98,07	882,6	980,7	70HRE-100HRE
F	HRF	1,5875mm Bilya Uç	98,07	490,3	588,4	60HRF-100HRF
G	HRG	1,5875mm Bilya Uç	98,07	1373	1471	30HRG-94HRG
H	HRH	3,175mm Bilya Uç	98,07	490,3	588,4	80HRH-100HRH
K	HRK	3,175mm Bilya Uç	98,07	1373	1471	40HRK-100HRK
15N	HR15N	Elmas Uç	29,42	117,7	147,1	70-94 HR15N
30N	HR30N	Elmas Uç	29,42	264,8	294,2	42-86 HR30N
45N	HR45N	Elmas Uç	29,42	411,9	441,3	20-77 HR45N
15T	HR15T	1,5875mm Bilya Uç	29,42	117,7	147,1	67-93 HR15T
30T	HR30T	1,5875mm Bilya Uç	29,42	264,8	294,2	29-82 HR30T
45T	HR45T	1,5875mm Bilya Uç	29,42	411,9	441,3	10-72 HR45T

*Bilya uç kullanılan sertlik ölçeklerinde yukarıda verilen sembollere, paslanmaz çelik bilya kullanıldığında "S", sertleştirilmiş çelik kullanıldığında ise "W" harfleri eklenir.

Rockwell sertlik testi (HR), genellikle metaller için kullanılan çok önemli bir sertlik ölçme yöntemidir. Rockwell sertliği batma derinliğine karşılık gelen birimsiz bir sayıdır. Elmas koni veya çelik bilya yardımıyla önce sabit belirli bir ön yük uygulanarak, meydana gelen başlangıç izinin derinliği ölçülür. Daha sonra hangi malzemede ölçüm yapılmak isteniyorsa, ona uygun yük uygulanır. Başlangıç yüküne geri dönülüp, oluşan son izin derinliği ölçülür. Oluşan son izin, başlangıç izine olan farkı okunarak seçilen kuvvet değerlerine uygun tablodan nereye denk geldiği bulunur. Çizelge 2.2'de uygulanan yük ve kullanılan uçlar gösterilmiştir. (Kuzu, 2006).

Knoop sertlik testi, bir mikro sertlik testidir. Bu test genellikle çok kırılğan malzemelerin veya ince kesitlerin sertliğinin belirlenmesinde kullanılır. Bu test, parlatılmış malzemenin yüzeyine piramit şeklindeki elmas ucun belirlenen bir yük ile uygulanması sonucunda oluşan izin ölçülmesi ile bulunur (İnal, 2016). Şekil 2.14'te Knoop sertlik testini görmekteyiz.



Şekil 2.14 Knoop sertlik testi elmas uç temas açısı görüntüsü

HK veya KHN olarak adlandırılan Knoop sertliği formülü:

$$HK = \frac{F}{C_p L^2} \quad (2.12)$$

Bu denklemde:

- HK Knoop Sertlik Değeri,
- C_p Çentiğin şekline bağlı düzeltme faktörü, ideal olarak = 0.070279
- L çentiğin uzun köşegenin uzunluğu olarak ifade edilmektedir.

2.13.3 Akma Dayanımı (YS)

"Yield Strength" terimi, Türkçede "Akma Dayanımı" olarak ifade edilir. Bu, kaynaklı metalin plastik deformasyona geçtiği ve kalıcı gerilmelerin başladığı gerilim seviyesini ifade eder. Kaynaklı metalin yük altında deformasyona karşı direnme yeteneğini

karakterize eden önemli bir mekanik özelliktir. Kaynak metalinin akma dayanımı, baz metalin ve dolgu metalinin bileşimi, kaynak işlem parametreleri, ısı girişi ve kaynak sonrası ısıtma işlemi gibi çeşitli faktörlerden etkilenebilir (Lippold 2014). Kaynak metalinin akma dayanımı genellikle çekme testiyle belirlenir. Bu testte, bir deney numunesi plastik deformasyon meydana gelene kadar aşamalı olarak artan çekme gerilimine maruz bırakılır. Gerilmelerin orantılı bir artışa kıyasla belirgin şekilde arttığı bir nokta, kaynak metalinin akma noktasını gösterir. Bu akma noktası, kaynak metalinin akma dayanımını temsil eder (Lippold 2014). Baz metalin ve dolgu metalinin bileşimi, kaynak metalinin akma dayanımını belirlemede kritik bir rol oynar. Karbon, mangan ve silikon gibi alaşım elementleri, dayanım özelliklerini önemli ölçüde etkiler. Genellikle yüksek karbon içeriği artan dayanıma yol açarken, alaşım elementlerinin eklenmesi kaynak metalinin dayanımını ve sertleşebilirliğini artırır (Kou 2003).


Isı girişi ve soğutma hızı gibi kaynak işlem parametreleri, kaynak metalinin akma dayanımını da etkiler. Yüksek ısı girişi ve daha yavaş soğuma hızları, genellikle daha kaba yapılar ve daha düşük dayanım ile sonuçlanırken; düşük ısı girişi, hızlı soğuma ve daha ince yapılar ile daha yüksek dayanıma sebep olur (John 2001).

Stres giderme veya temperleme gibi kaynak sonrası ısıtma işlemi, kaynak metalinin akma dayanımını daha da değiştirir. Isıtma işlem süreçleri, kalıntı gerilmeleri azaltmaya ve akma dayanımı dahil olmak üzere genel mekanik özellikleri iyileştirmeye yardımcı olur (Lippold 2014). Kaynak metalinin akma dayanımını, kaynaklı yapıların tasarımında ve değerlendirilmesinde dikkate almak önemlidir. Çünkü, bu doğrudan yük taşıma kapasitesini ve yapısal bütünlüğü etkiler. Akma dayanımını etkileyen faktörleri anlamak; istenen mekanik özellikleri elde etmek için uygun kaynak malzemelerini, işlem parametrelerini ve kaynak sonrası işlemleri seçmede yardımcı olur (Lippold 2014).

2.13.4 Maksimum Çekme Dayanımı (UTS)

"Ultimate Tensile Strength" terimi, Türkçede "Maksimum Çekme Dayanımı" olarak ifade edilir. Bu, kaynaklı metalin gerilme altında gösterdiği dayanıklılığı ve direnci karakterize eden önemli bir mekanik özelliktir. Kaynak dolgu metalinin ve baz metalin bileşimi,

kaynaklı metalin maksimum çekme dayanımını belirlemede önemli bir rol oynar. Alaşım elementleri, karbon, silisyum, mangan ve diğerleri gibi, mukavemet özelliklerini büyük ölçüde etkiler. Yüksek karbon içeriği genellikle artan dayanıklılığa yol açarken, belirli alaşım elementlerinin eklenmesi kaynaklı metalin dayanıklılığını ve sertleşebilirliğini artırır (Kou 2003). Kaynak işlem parametreleri, ısı girişi ve soğutma hızı, kaynaklı metalin maksimum çekme dayanımını etkiler. Genellikle daha yüksek ısı girişi ve daha yavaş soğuma hızı, daha büyük mikroyapılar ve daha düşük dayanıklılık ile sonuçlanırken; daha düşük ısı girişi ve daha hızlı soğuma hızı daha ince mikroyapıları ve daha yüksek dayanıklılığı teşvik eder (John 2001).



Şekil 2.15 Çekme Deneyi (Sadki vd. 2016)

2.14 Alaşım Elementlerinin Kaynak Metaline Etkisi

Kaynak elektrodunun performansını ve özelliklerini belirlemede alaşım elementleri büyük bir öneme sahiptir. Bu elementler elektrodun bileşimine eklenerek, kaynaklı metalin çeşitli özelliklerini belirgin bir şekilde etkileyebilir. Farklı alaşım elementleri,

istenen sonuç ve özel kaynak uygulamalarının spesifik gereksinimleri dikkate alınarak seçilir. Bu şekilde, kaynaklı birleşimlerin istenen mekanik özellikleri, dayanıklılık, sertlik ve diğer performans kriterleri karşılanabilir.

2.14.1 Karbon (C) Elementinin Kaynak Metaline Etkisi

Karbon içeriği, kaynak metalinin dayanıklılığını ve sertliğini etkiler. Yüksek karbon içeriği genellikle artan dayanıklılık ve sertlik sağlar; bu da yüksek mekanik özellikler gerektiren uygulamalar için uygundur. Karbonun doğru oranda kullanılması, kaynaklı birleşimin istenen mukavemet ve sertlik seviyelerini elde etmek için önemlidir (Kou 2003).

2.14.2 Silisyum (Si) Elementinin Kaynak Metaline Etkisi

Silisyumun kaynak elektrotunda bir alaşım elementi olarak kullanılması, kaynaklı metalin özellikleri ve performansı üzerinde önemli etkilere sahiptir. Elektrotun silisyum içeriği, kaynak birleşiminin çeşitli özelliklerini etkiler. Silisyum, kaynak havuzunun akıcılığını ve ıslanma özelliklerini iyileştirerek daha iyi bir çekirdek şekli oluşturur ve kaynak sürecinin kontrolünü artırır. Ayrıca, silisyum kaynaklı metalin sıcak çatlama hassasiyetini azaltmada yardımcı olur ve korozyona karşı direncini artırır (Kou 2003).

2.14.3 Mangan (Mn) Elementinin Kaynak Metaline Etkisi

Mangan, kaynak elektrotlarında yaygın olarak deoksitleyici ve temizleyici olarak kullanılır. Sıvı metaldeki oksijen ve sülfür ile reaksiyona girerek, gözenek oluşumunun riskini azaltır ve kaynağın temizliğini iyileştirir. Ayrıca mangan; kaynak sırasında arkın istikrarını, çekirdek şeklini, penetrasyonu ve kontrol kolaylığını etkileyen faktörlerdir. (Lippold ve Kotecki 2005).

2.14.4 Titanyum (Ti) Elementinin Kaynak Metaline Etkisi

Titanyum, kaynak elektrotlarında yaygın olarak deoksitleyici ve tane inceltici olarak kullanılır. Katılaşma sürecinde tane büyümesini kontrol ederek kaynak metalinin yapısal özelliklerini iyileştirir. Oksijenle reaksiyona girerek titanyum oksit oluşturur ve kaynağın

gözenek oluşumunu azaltır. Bu, kaynağın dayanıklılığını ve çatlak direncini artırır. Titanyum, belirli kirlilik maddeleriyle reaksiyona girerek stabil titanyum nitritler veya titanyum karbonitritler oluşturabilir. Bu, kaynak metalinde zararlı bileşiklerin oluşumunu kontrol eder ve kaynak kalitesini artırır. Ayrıca titanyum, korozyona karşı direnci artırmak için kaynak metalinin yüzeyinde koruyucu bir oksit tabakası oluşturur (Kou 2003).

2.14.5 Alüminyum (Al) Elementinin Kaynak Metaline Etkisi

Alüminyum, kaynak elektrotlarında yaygın olarak deoksitleyici olarak kullanılır. Sıvı metal havuzdaki oksijenle reaksiyona girerek gözenek oluşumunun riskini azaltır ve kaynağın bütünlüğünü artırır. Ayrıca mekanik özelliklerin ve çatlak direncinin iyileşmesine katkıda bulunur. Alüminyum içeren elektrotlar, belirli uygulamalarda artırılmış korozyon direnci sağlayabilir. Alüminyum, kaynak metalinin yüzeyinde koruyucu bir oksit tabakası oluşturarak korozyona karşı direncini artırır. Bu sayede kaynak malzemesi uzun ömürlü ve dayanıklı kalır (Kou 2003).

2.14.6 Niyobyum (Nb) Elementinin Kaynak Metaline Etkisi

Niyobyum, kaynak elektrodundaki ana metal ve diğer alaşım elementleriyle birleşerek, katı çözeltileri oluşturur. Bu, mekanik özelliklerin geliştirilmesine ve deformasyon ile çatlama direncinin artmasına yol açar. Aynı zamanda niyobyum, yüksek sıcaklıklarda iyi bir dayanıklılığa sahiptir, bu nedenle yüksek sıcaklık isteyen kaynak uygulamalarında tercih edilir. Zorlu koşullar altında bile kaynak metalinin istenen mekanik özelliklerini korumaya yardımcı olur (Kou 2003). Niyobyum ayrıca kaynak elektrotlarında deoksitleyici olarak işlev görebilir. Oksijenle reaksiyona girerek kaynakta gözenek oluşumunun riskini azaltır. Bu özellik, kaynak metalinin kalitesini artırır ve gözeneklilik gibi kusurların oluşumunu önler (Kou 2003).

2.14.7 Vanadyum (V) Elementinin Kaynak Metaline Etkisi

Vanadyum, yüksek sıcaklıklarda stabilitesi yüksek olan bir elementtir, bu da yüksek sıcaklıkta gerçekleştirilen kaynak uygulamaları için uygundur. Ayrıca, zorlu koşullar altında bile kaynak metalinin istenen mekanik özelliklerini korumaya yardımcı olur.

Vanadyum, kaynak elektrodundaki baz metal ve diğer alaşım elementleriyle birleşerek katı çözeltileri oluşturur. Bu da mekanik özelliklerin geliştirilmesine ve deformasyon ile çatlaklara karşı direncin artmasına yol açar. Bu özellikleri sayesinde vanadyum, yüksek sıcaklıkta gerçekleştirilen kaynak uygulamalarında tercih edilen bir elementtir (Kou 2003).

2.14.8 Molibden (Mo) Elementinin Kaynak Metaline Etkisi

Molibden, yüksek sıcaklıklara dayanıklılık gösteren bir elementtir, bu nedenle yüksek sıcaklık gerektiren uygulamalarda kullanım için uygundur. Zorlu koşullar altında bile kaynak metalinin istenen mekanik özelliklerini sağlar ve uzun ömürlü bir performans sergiler. Ayrıca, kaynak metalinin yüzeyinde koruyucu bir oksit tabakası oluşturarak korozyona karşı direncini artırır. Bu özellikleri sayesinde molibden, yüksek sıcaklık gerektiren uygulamalarda tercih edilen bir elementtir (Kou 2003).

2.14.9 Krom (Cr) Elementinin Kaynak Metaline Etkisi

Krom içeren kaynak elektrotları, özellikle paslanmaz çelik kaynaklarında daha yüksek korozyon direnci sunar. Kromun varlığı, kaynak metalinin korozyona karşı dayanıklılığını artırarak ömrünü ve performansını iyileştirir. Kaynak metalinin yüzeyinde koruyucu bir oksit tabakası oluşturur ve gözeneklilik ile diğer kusurların oluşumunu azaltır. Krom, kaynak elektrodu içerisinde bulunan karbonla karbürler oluşturabilir. Bu karbürler, kaynak metalinin sertleşmesine ve güçlenmesine katkıda bulunur, aşınma direncini ve dayanıklılığını artırır. Bu, kaynak metalinin daha uzun süre dayanabilen ve daha sağlam bir yapıya sahip olmasını sağlar (Kou 2003).

2.14.10 Nikel (Ni) Elementinin Kaynak Metaline Etkisi

Nikel, kaynak metalinin yüzeyinde koruyucu bir oksit tabakası oluşturarak korozyona karşı direncini artırır. Nikel, kaynak elektrotunda bulunan temel metal ve diğer alaşım elementleriyle katı bir çözeltileri oluşturur, bu da mekanik özelliklerin artmasıyla sonuçlanır. Nikel, kaynak metalinin süneklik ve dayanıklılığını artırarak çatlama ve deformasyona

karşı daha dirençli hale getirir. Bu, kaynak metalinin daha esnek ve dayanıklı olmasını sağlar (Kou 2003).

2.14.11 Bakır (Cu) Elementinin Kaynak Metaline Etkisi

Bakır, mükemmel bir ısı iletkenidir. Kaynak elektrotlarına eklenerek, ısıyı etkin bir şekilde dağıtarak aşırı ısınma ve kaynak deformasyonunu engeller. Aynı zamanda, bakır yüksek elektriksel iletkenliğe sahip olduğundan, istikrarlı bir ark oluşumunu destekler ve böylece kaynak kalitesini artırır (Kou 2003). Bakır, kaynak metalinin sünekliğini artırarak çatlama ve deformasyona karşı daha dirençli hale getirir. Bu, kaynak metalinin daha dayanıklı ve esnek olmasını sağlar (Kou 2003).

2.14.12 Bor (B) Elementinin Kaynak Metaline Etkisi

Bor, kaynak metalinin sertleşebilirliğini artırabilir. Katılaşma sırasında, bor ince taneli yapılar oluşturarak sertlik ve dayanıklılığı artırmaya yardımcı olur. Ayrıca, bor tane inceltici olarak işlev görür. Bu ince tane yapılanması, mekanik özelliklerin, özellikle dayanıklılık ve çatlak direncinin iyileştirilmesine katkı sağlar (Kou 2003).

2.14.13 Oksijen (O) Elementinin Kaynak Metaline Etkisi

Oksijen, kaynak metalinde genellikle istenmeyen etkilere sahiptir. Yüksek oksijen seviyeleri, kaynak metalinin mekanik özelliklerini olumsuz yönde etkileyebilir. Oksijen, baz metal ile reaksiyona girerek oksit oluşumuna neden olabilir ve bu da kaynağın dayanıklılığını, tokluğunu ve şekillenebilirliğini azaltır (Kou 2003). Oksijenin olumsuz etkilerini önlemek için genellikle koruyucu gazlar kullanılır. Bu gazlar, kaynak bölgesini oksijenin etkilerinden korur ve daha iyi bir kaynak kalitesi sağlar (Kou 2003).

2.14.14 Azot (N) Elementinin Kaynak Metaline Etkisi

Azot, kaynak metalinde çözülebilir ve katı çözeltiler oluşturarak mekanik özelliklerin gelişmesine katkıda bulunur, örneğin mukavemet ve sertlik artar. Ancak, azotun yüksek

seviyelerde bulunması mekanik özelliklerin azalmasına neden olur (Kou 2003). TIG kaynak gibi bazı işlemlerde, azot yaygın şekilde gaz koruması olarak kullanılır. Bu şekilde, kaynak bölgesi atmosferik kirlilikten korunur ve kaynak işlemi için uygun bir ortam sağlanır (Kou 2003).

2.15 Yapay Zeka Algoritmalarının Kaynak İşlemlerinde Kullanımına Dair Örnekler

Rajkumar ve Murugan (2012) çalışmalarında 2205 Dupleks çeliği kullanmış ve kaynak çekirdek geometrisinin tahminini yapmışlardır. Bu çalışmada MATLAB 7.0 Neural network Toolbox kullanılmış öğrenme algoritması olarak back propagation (BP) algoritması kullanılmış ve %97,63 başarılı tahmin yapılmıştır.

Genel (2004) çalışmasında 73 adet çeliğin yorulma yaşam döngüsü yapay zekâ ile tahmin etmiştir. Yapay sinir ağı C++ ile programlanmıştır. Yorgunluk dayanım katsayısı %99 ve yorgunluk şekil değiştirme katsayısı %98 olarak bulunmuştur.

Jianming Hu vd. (2022) çalışmalarında iyileştirilmiş sparrow search algoritması ile direnç nokta kaynaklarının kalitesi tahmin etmiştir.

Güler (2007) çalışmasında çinko alüminyum alaşımlarının korozyon davranışına alaşım elementlerinin etkisini yapay sinir ağları ile tahmin edilmiştir. Bu çalışmada geriye doğru hesaplama algoritmalarından Resilient Propagation, Levenberg-Marquardt, Polak-Ribiere Conjugate-Gradient, Scaled conjugate gradient, gradient descent variable learning rate ve one step secant algoritmaları kullanılmıştır.

Yetkin (2014) çalışmasında tanker şamandıra bağlama sistemlerinin yapay sinir ağlar ile optimizasyonu hedeflemiştir. MATLAB yazılımı kullanılarak 1000 ayrı çevre durumu için yapay sinir ağı simülasyonu yapılmış ve OrcaFlex yazılımı ile %91 doğruluk oranı bulunmuştur.

Dhas vd. (2012) çalışmalarında sürtünme kaynağının proses parametrelerinin optimuma yakın koşulları bulmada genetik algoritma kullanmıştır. Bu çalışmada proses

parametreleri yani giriş verileri takımın dönüş hızı, takım profili ve takım ilerleme hızı çıkış parametreleri çekme dayanımı, akma dayanımı, uzama miktarı ve sertliktir.

Casalino vd. (2016) çalışmalarında 6mm kalınlığında alüminyum alaşımlı levhaların lazer ile kaynaklanması sonucu kaynak çekirdek özelliklerinin tahmini yapılmıştır.

Şık vd. (2023) yaptığı çalışmalarında ise toza altı kaynağının kaynak genişliğini taguchi yöntemi ile başarılı bir şekilde tahmin etmişlerdir.

Acherjee vd. (2011) çalışmalarında termoplastik levhaların lazer ile kaynaklandığında oluşan kaynak mukavemeti ve kaynak boyutları açısından kaynak kalitesinin belirlenmesi için sinir ağlarının kullanılma olasılığını göstermektedir. Bulunan sonuçlar sinir ağının bu sistemlerde alternatif bir yol olarak kullanılabileceğini göstermektedir.

Kurt vd. (2018) çalışmalarında paslanmaz çeliklerin kaynak parametrelerini yapay sinir ağı ve taguchi yaklaşımları kullanılarak çekme deneyi sonuçları istatistiksel olarak incelemişlerdir. Yapay sinir ağı sonuçları, deney sonuçları ile başarılı bir uyum ve düşük hata oranlarıyla yüksek güvenilirliğe sahip olarak bulmuşlardır. Yapay sinir ağı ve Taguchi yöntemleri kullanılarak eklemelerin UTS'si sırasıyla %96,97 ve %78,31 doğrulukla tahmin etmişlerdir.

Thekkuden vd. (2019) yaptıkları araştırmada, gaz metal ark kaynağı işlemi sırasında kaynak kalitesinin değerlendirilmesi için yapay sinir ağı kullanmışlardır. Eğitim sürecinde genel sınıflandırma doğruluğu %94,7 olarak bulmuşlardır. Kullandıkları yapay sinir ağı, test kaynaklarının kalitesini %90,9 oranında doğru bir şekilde tahmin etmişlerdir.

3.MALZEME ve METOT

Bu çalışmada, kaynak metalinde bulunan C, Si, N, Mn, Al, Ti, Nb, V, Mo, Cr, Ni, Cu, B ve O elementlerinin oranlarının değişimi ile AF (Asiküler Ferrit) miktarı, HRD (sertlik), YS (Akma dayanımı) ve UTS (Çekme dayanımı) gibi özellikler arasındaki ilişkiyi incelemiştir. Bu verileri kullanarak, kaynak metalinin bileşimi hakkında tahminler yapmak için yapay sinir ağları metodu kullanmıştır. Söz konusu veriler ile YSA ağı eğitilmiş ve eğitilen bu değerler ile tahminler yapılmıştır. Araştırma metodolojisi aşağıdaki adımları içermektedir:

- Veri Toplama
- Veri İşleme
- Yapay Sinir Ağı Modelinin Oluşturması
- Eğitim ve Test İşlemleri

3.1 Veri Toplama İşlemi

G. M. Evans'ın çalışmasından, kaynak metalinin içerisindeki C, Si, N, Mn, Al, Ti, Nb, V, Mo, Cr, Ni, Cu, B ve O elementlerinin oranlarını içeren bir veri seti toplanmıştır. Bu veri setinde ayrıca AF, HRD, YS ve UTS gibi özellikler de bulunmaktadır.

3.2 Veri İşleme İşlemi

Toplanan veri seti MATLAB programında işlenmiştir. Veriler normalize edilmiş, gereksiz öznitelikler çıkarılmış ve özellikler arasındaki ilişkiyi daha iyi anlayabilmek için gerekli dönüşümler yapılmıştır.

3.2.1 Normalizasyon İşlemi

Yapay sinir ağı eğitimi için veri hazırlarken, veri havuzunda beklenenden büyük veya küçük değerler gözlemlenebilir. Bu değerler, ağın eğitiminde kullanıldığında net girdilerin hesaplanması sırasında ağı yanıltabilir. Bu nedenle, eğitimde kullanılacak tüm

verilerin 0 ile 1 aralığına normalize edilmesi önemlidir. Bu normalizasyon işlemi, veri havuzundaki büyük veya küçük değerlerin ağ üzerindeki etkisini azaltır. Yapay sinir ağının öğrenme başarısını artırmak için normalizasyon işlemi, YSA'nın eğitim aşamasına geçilmeden önce uygulanmalıdır. (Şahin 2014). Bu çalışmada, Min-Max normalizasyon tekniği kullanılarak veriler normalize edilmiştir. Bu teknikte, bir verinin en düşük değeri minimum olarak, en yüksek değeri ise maksimum olarak ifade edilir. Verileri 0 ile 1 aralığına düşürmek için denklem 2.10'da kullanılmıştır. Bu şekilde, verilerin ölçekleri birbirine uyumlu hale getirilmiş ve yapay sinir ağının doğru şekilde eğitime olanak sağlanmıştır.

$$X' = \frac{X_i - X_{\min}}{X_{\max} - X_{\min}} \quad (2.10)$$

Bu denklemde;

X' = Normalize edilmiş değeri,

X_i = Veri havuzundaki normalize edilecek değeri,

$X_{\max}$ = Veri havuzundaki en büyük girdiyi,

$X_{\min}$ = Veri havuzundaki en küçük girdiyi belirtmektedir (Jassim vd. 2022).

3.3 Yapay Sinir Ağı Modelinin Oluşturulması

Yapay sinir ağları, kaynak metalinin bileşimi ile AF, HRD, YS ve UTS gibi özellikler arasındaki ilişkiyi modellemek için kullanılmıştır. Modelin doğru çalışabilmesi için girdi ve çıktı katmanları, gizli katmanlar ve uygun aktivasyon fonksiyonları belirlenmiştir. Bu çalışmada, ileri beslemeli geri yayımlı ağ yapısı tercih edilmiştir. Bu ağ yapısının seçilmesinin temel nedeni, gizli katman tarafından öğrenme performansının geliştirilebilmesi avantajına sahip olmasıdır. Ağın eğitiminde Lavenberg-Marquardt algoritması (LM) kullanılmıştır. Ayrıca veriler ve diğer parametreler korunarak başka YSA modelleri ile de deney tekrarlanmış ve sonuçlar karşılaştırılmıştır. Çizelge 3.2'de çalışmada kullanılan YSA modelleri ve bu modellerin genel başarıları karşılaştırılmıştır. Öğrenme fonksiyonu olarak Learngdm, aktivasyon fonksiyonu olarak ise Tanjant-Sigmoid aktivasyon fonksiyonu seçilmiştir. Oluşturulan YSA'nın başarısını

değerlendirmek için MAPE performans ölçütü kullanılmıştır. Çizelge 3.1’de çalışmada kullanılan YSA modelinin oluşturulmasında kullanılan parametreler özet halinde verilmiştir.

Çizelge 3.1 YSA modelinin oluşturulmasında kullanılan parametreler

Ağ Türü	Gradyan Tabanlı Ağ
Eğitim Algoritması	TRAINLM
Aktivasyon Fonksiyonu	TANSIG
Öğrenme Fonksiyonu	LEARNGDM
Nöron Sayısı	20
Performans Değerlendirme Fonksiyonu	MAPE

Çizelge 3.2 Bazı Yapay Sinir Ağlarının Karşılaştırılması

	AF	HRD	YS	UTS
LM	%93,135	%95,923	%94,17	%96,324
SCG	%73,917	%86,366	%93,64	%93,723
BR	%87,259	%96,837	%97,437	%99,200
CGB	%94,656	%93,558	%94,422	%92,661
RP	%75,263	%70,844	%95,935	%76,982
BFG	%99,623	%95,172	%99,671	%45,85

3.3.1 Girdi Parametreleri

İlgili çalışmada verilen girdi parametrelerine ait bilgiler aşağıdaki tabloda belirtilmiştir.

Çizelge 3.3 Giriş Parametreleri

Giriş Parametreleri	Veri Adedi
C	94
Si	94
Mn	94
Ti	94
Al	94
Nb	94
V	94
Mo	94
Cr	94
Ni	94
Cu	94
B	94
O	94
N	94

Çizelge 3.3 incelendiğinde her bir çıkış parametresinin 94 adet veriden oluştuğu görülmektedir. Toplam giriş parametre adeti 1316 adet veriden oluşmaktadır.

3.3.2 Çıkış Parametreleri


İlgili çalışmada verilen girdi parametrelerine ait bilgiler aşağıdaki tabloda belirtilmiştir.

Çizelge 3.4 Çıkış Parametreleri

Çıkış Parametreleri	AF	HRD	YS	UTS
Veri Adeti	94	94	94	94

Çizelge 3.2 incelendiğinde çıkış parametreleri ve veri adedi bilgileri görülmektedir. Çizelge 3.2 ye göre çalışmada AF çıkış parametresi 94 adet, HRD çıkış parametresi 94 adet, YS çıkış parametresi 94 adet ve UTS çıkış parametresi 94 adet veriden oluşmaktadır. Toplam girdi parametresindeki veri sayısı 376 adet veriden oluşmaktadır.


Çalışmada kullanılan ağ topolojisi Şekil 3.1’de verilmiştir



Şekil 3.1 Kaynak Metalindeki Elementlerin Fiziksel Özelliklerinin Tahmin Uygulamasının Ağ Deseni


3.4 Eğitim ve Test

MATLAB programında Neural Network Toolbox (NNT) kod yazmadan YSA kullanmak için tasarlanmış bir araçtır. Öncelikle MATLAB programına giriş ve çıkış değerlerimiz tanıtıldıktan sonra komut penceresine “nntool” yazılarak “Neural Network/Data Manager” penceresine ulaşılır (Şekil 3.2).



Şekil 3.2 Yapay Sinir Ağı/Veri Yöneticisi

Daha sonra programa tanıttığımız verilerden Input Data bölümüne 94 adet giriş, Target Data bölümü için 4 adet hedef değerlerimizi seçilir. New komutuna basarak “Creating Network or Data” penceresine ulaşılır (Şekil 3.3). Şekil 3.3’de gözüktüğü üzere YSA modelinin oluşturulmasında, network tipi olarak ileri beslemeli geri yayılım, aktivasyon fonksiyonu olarak tansig aktivasyonu, öğrenme algoritması olarak Lavenberg-Marquardt algoritması (LM) seçilmiştir. Şekil 3.4’te gözüktüğü üzere denemeler sonucunda en verimli katman sayısı 13 ve nöron sayısı 20 olarak bulunmuştur. Denemeler sonucunda, hata oranı en aza ulaşıncaya kadar eğitilmiştir. En az hata oranına AF, sertlik, akma dayanımı ve maksimum çekme dayanımı için 6. iterasyonda ulaşılmış ve oluşturulan ağ MATLAB programında kaydedilmiştir.




Şekil 3.3 Ağ veya Veri Oluşturma




Şekil 3.4 Ağ araçları kullanarak ağların eğitilmesi

Eğitilen yapay sinir ağı modeli kullanılarak, verilmemiş bileşim verileri üzerinde kaynak metalinin AF, HRD, YS ve UTS gibi özelliklerden yola çıkarak kaynak metali bileşenlerinin oranı tahmin edilmiştir.




Şekil 3.5 Yapay Sinir Ağı Eğitim Regresyonu AF

Şekil 3.5'te görüldüğü üzere YSA eğitim sonuçları AF için eğitim verileri %91,598 doğrulama verileri %96,037 test verileri %98,297 ve tüm sonuçlarda veriler %93,135 olarak bulunmuştur.




Şekil 3.6 Yapay Sinir Ağı Eğitim Regresyonu HRD

Şekil 3.6’da görüldüğü üzere sertlik için eğitim verileri %91,755 doğrulama verileri %98,206 test verileri %98,783 ve tüm sonuçlarda veriler %95,923 olarak bulunmuştur.



Şekil 3.7 Yapay Sinir Ağı Eğitim Regresyonu UTS

Şekil 3.7’de ise maksimum çekme dayanımı için eğitim verileri %92,267 doğrulama verileri %99,089 test verileri %98,036 ve tüm sonuçlarda veriler %94,17 olarak bulunmuştur.



Şekil 3.8 Yapay Sinir Ağı Eğitim Regresyonu YS

Şekil 3.8’de görüldüğü üzere akma dayanımı için ise eğitim verileri %95,439 doğrulama verileri %99,038 test verileri %97,286 ve tüm veriler %96,324 bulunmaktadır.

4. BULGULAR ve TARTIŞMA

Bu bölümde, G. Evans'ın deney sonuçları tablolar olarak verilmiş ve bu tablodaki sonuçlar yorumlanmıştır. Lavenberg-Marquardt algoritması (LM) ile elde edilen tahmin sonuçları ile gerçek veriler grafiksel olarak sunulmuş ve analiz edilmiştir. MAPE (mean absolute percentage error) yöntemi ve R^2 ile ağ performansı değerlendirmiştir. Çizelge 4.1 de MAPE performans oranları verilmiştir.

Çizelge 4.1 MAPE Başarı Oranları (Şahin, 2014)

MAPE	%10 altı	%10-%20	%20-%50	%50 üstü
	Çok İyi	İyi	Kabul Edilebilir	Başarısız


4.1 Asiküler Ferrit Tahmini

Şekil 4.1’de Asiküler Ferrit yüzdesi ve veri adetleri görülmektedir. Bu grafikte tahmini değerler turuncu renkle gerçek değerler ise mavi renk ile gösterilmektedir. Toplam 94 adet verideki asiküler ferrit yüzde oranları tahmin edilmiş tahmini ve gerçek veriler arasındaki MAPE değeri “31,465” olarak bulunmuştur. Bu değer hata oranının %31,455 olduğunu gösterir. Çizelge 4.1 de bahsedildiği üzere MAPE değerinin %20 ile %50 arasında olması tahmin başarısının kabul edilebilir olduğunu göstermektedir. Şekil 4.2’de görüldüğü üzere R^2 değerinin ise 1’e yakın olması tahmin değerinin başarılı olduğunu göstermektedir (Gök 2023). 7’nolu numunede asiküler ferrit çok düşük bir oranda rapor edilmiş olması nedeniyle tahmin edilen değere göre büyük fark ortaya çıkmıştır. Bu kadar yüksek oranda fark ortaya çıkması MAPE algoritmasındaki tahmin edilen değer TRAINLM tarafından üretilmesi sırasında bu grupta bulunan eğitilen değerlere göre çok düşük olarak analiz edilmesi olabilir. Genel olarak LM algoritması çok yüksek ve çok düşük değerlerin minimize edilip istatistiki olarak daha gerçekçi değer elde etmeye dayanmaktadır.


4.2 Sertlik Tahmini

Şekil 4.3’de sertlik verisinin tahmini ve gerçek değerleri görülmektedir. Şekil 4.3’de tahmini değerler turuncu renkle gerçek değerler ise mavi renk ile gösterilmektedir.


Toplam 94 adet verideki sertlik verileri tahmin edilmiş tahmini ve gerçek veriler arasındaki MAPE değeri “2,730” olarak bulmaktayız. Bu hata değerinin %2,73 olduğunu göstermektedir. Çizelge 4.1 de bahsedildiği üzere MAPE değerinin %10 altı olması tahmin başarısının çok güçlü olduğunu göstermektedir. Şekil 4.4’ te görüldüğü üzere R^2 değerinin ise 1’e yakın olması tahmin değerinin başarılı olduğunu göstermektedir.




Şekil 4.1 Asiküler Ferrit Oranı Tahmini



Şekil 4.2 Asiküler Ferrit veri adeti bağlantısını gösteren R^2 ilişkisi



Şekil 4.3 Sertlik Tahmini




Şekil 4.4 Sertlik tahmini veri adeti bağlantısını gösteren R2 ilişkisi


4.3 Akma Dayanımı Tahmini

Şekil 4.5’de akma dayanımının tahmini ve gerçek değerleri görülmektedir. Grafikteki tahmini değerler turuncu renkle gerçek değerler ise mavi renk ile gösterilmektedir. Toplam 94 adet verideki akma dayanımı tahmin edilmiş tahmini ve gerçek veriler

arasındaki MAPE değeri “2,606” olarak bulmaktayız. Yani hata oranı %2,606 olmaktadır. Çizelge 4.1 de bahsedildiği üzere MAPE değerinin %10 olması tahmin başarısının çok güçlü olduğunu göstermektedir. R^2 değerinin ise 1’e yakın olması tahmin değerinin başarılı olduğunu göstermektedir.




Şekil 4.5 Akma Dayanımı Tahmini




Şekil 4.6 YS veri adeti bağlantısını gösteren R^2 ilişkisi

4.4 Maksimum Çekme Dayanımı Tahmini

Şekil 4.7’de maksimum çekme dayanımı tahmini ve gerçek değerleri görülmektedir. Grafikteki tahmini değerler turuncu renkle gerçek değerler ise mavi renk ile gösterilmektedir. Toplam 94 adet verideki maksimum çekme dayanımının MPa değerleri tahmin edilmiş tahmini ve gerçek veriler arasındaki MAPE değeri “2,347” olarak bulmaktayız. Çizelge 4.1 de bahsedildiği üzere MAPE değerinin %10 altı olması tahmin başarısının çok güçlü olduğunu göstermektedir. Şekil 4.8’te görüldüğü üzere R^2 değerinin ise 1’e yakın olması tahmin değerinin başarılı olduğunu göstermektedir. 93’nolu numunede UTS çok düşük bir oranda rapor edilmiş olması nedeniyle tahmin edilen değere göre büyük fark ortaya çıkmıştır. Bu kadar yüksek oranda fark ortaya çıkması TRAINLM algoritmasındaki tahmin edilen değer bu grupta bulunan eğitilen değerlere göre çok düşük olarak analiz edilmesi olabilir.



Şekil 4.7 Maksimum Çekme Dayanımı Tahmini



Şekil 4.8 UTS tahmini veri adeti bağlantısını gösteren R2 ilişkisi

Çizelge 4.2’de C ve Mn yüzde oranları değiştirilerek elde edilmiştir. Karbon oranı arttıkça sertlik, akma dayanımı, maksimum çekme dayanımı ve asiküler ferrit oranı artmaktadır. Artan karbon oranı arkın başlamasını zorlaştırır ve kırılabilirliğini artırır. Bu olumsuz etkileri azaltmak için mangan takviyesi artırılmıştır. Çizelge 4.3’de silisyum ve mangan yüzde oranları değiştirilerek elde edilmiştir. Silisyum oranının artırılması sertlik, asiküler ferrit oluşumu, akma dayanımı ve maksimum çekme dayanımını arttırmıştır.

Çizelge 4.4’de mangan ve karbon yüzde oranları değiştirilerek elde edilmiştir. Mangan, kaynak sırasında arkın istikrarını, çekirdek şeklini, penetrasyonu ve kontrol kolaylığını arttırdığı için karbonun artmasının getirdiği dezavantajları azaltmıştır. Asiküler ferrit, sertlik, akma dayanımı ve maksimum çekme dayanımında artma yaşanmıştır. Bütün mekanik özelliklerde artma yaşanmasına rağmen bu durum kaynak metalindeki karbon artışının bir sonucudur.

Çizelge 4.5’de titanyum yüzde oranı değiştirilerek elde edilmiştir. Asiküler ferrit, akma dayanımı, maksimum çekme dayanımı gözle görülür oranda artmıştır. Sertlik çok az bir miktarda artmıştır. Titanyum kaynak metalinde istenmeyen maddeler ile tepkimeye girerek stabil titanyum nitritler veya titanyum karbonitritler oluşturur. Bu çökeltme tepkileri kaynak metalinin mikroyapısını etkileyip mekanik özelliklerini iyileştirmektedir..

Çizelge 4.2 Karbon Verileri

C	Si	Mn	Al	Ti	Nb	V	Mo	Cr	Ni	Cu	B	O	N	AF	HRD	YS	UTS
0,045	0,3	0,65	0,0005	0,0035	0,0005	0,0005	0,0005	0,0005	0,0005	0,0005	0,0005	0,039	0,0075	0	171	405	462
0,059	0,33	0,6	0,0005	0,0035	0,0005	0,0005	0,0005	0,0005	0,0005	0,0005	0,0005	0,039	0,0075	2	182	406	482
0,099	0,35	0,65	0,0005	0,0035	0,0005	0,0005	0,0005	0,0005	0,0005	0,0005	0,0005	0,039	0,0075	3	190	418	510
0,0147	0,4	0,63	0,0005	0,0035	0,0005	0,0005	0,0005	0,0005	0,0005	0,0005	0,0005	0,039	0,0075	5	202	465	558
0,044	0,32	0,98	0,0005	0,0035	0,0005	0,0005	0,0005	0,0005	0,0005	0,0005	0,0005	0,039	0,0075	40	185	420	480
0,063	0,35	1	0,0005	0,0035	0,0005	0,0005	0,0005	0,0005	0,0005	0,0005	0,0005	0,039	0,0075	48	202	448	515
0,098	0,32	1,05	0,0005	0,0035	0,0005	0,0005	0,0005	0,0005	0,0005	0,0005	0,0005	0,039	0,0075	38	210	460	550
0,0152	0,41	1	0,0005	0,0035	0,0005	0,0005	0,0005	0,0005	0,0005	0,0005	0,0005	0,039	0,0075	34	214	475	586
0,044	0,32	1,32	0,0005	0,0035	0,0005	0,0005	0,0005	0,0005	0,0005	0,0005	0,0005	0,039	0,0075	56	200	455	518
0,06	0,37	1,35	0,0005	0,0035	0,0005	0,0005	0,0005	0,0005	0,0005	0,0005	0,0005	0,039	0,0075	65	208	468	548
0,096	0,3	1,29	0,0005	0,0035	0,0005	0,0005	0,0005	0,0005	0,0005	0,0005	0,0005	0,039	0,0075	62	218	492	586
0,148	0,38	1,4	0,0005	0,0035	0,0005	0,0005	0,0005	0,0005	0,0005	0,0005	0,0005	0,039	0,0075	70	225	505	612
0,045	0,3	1,72	0,0005	0,0035	0,0005	0,0005	0,0005	0,0005	0,0005	0,0005	0,0005	0,039	0,0075	68	225	490	556
0,07	0,33	1,77	0,0005	0,0035	0,0005	0,0005	0,0005	0,0005	0,0005	0,0005	0,0005	0,039	0,0075	72	229	510	586
0,093	0,33	1,65	0,0005	0,0035	0,0005	0,0005	0,0005	0,0005	0,0005	0,0005	0,0005	0,039	0,0075	70	242	535	608
0,141	0,36	1,76	0,0005	0,0035	0,0005	0,0005	0,0005	0,0005	0,0005	0,0005	0,0005	0,039	0,0075	76	255	612	685

Çizelge 4.3 Silisyum Verileri

C	Si	Mn	Al	Ti	Nb	V	Mo	Cr	Ni	Cu	B	O	N	AF	HRD	YS	UTS
0,06	0,2	0,6	0,0005	0,0035	0,0005	0,0005	0,0005	0,0005	0,0005	0,0005	0,0501	0,0055	0,0075	19	160	391	453
0,07	0,38	0,66	0,0005	0,0035	0,0005	0,0005	0,0005	0,0005	0,0005	0,0005	0,0452	0,0055	0,0075	36	173	423	491
0,065	0,61	0,65	0,0005	0,0035	0,0005	0,0005	0,0005	0,0005	0,0005	0,0005	0,0405	0,0055	0,0075	32	202	444	505
0,07	0,95	0,64	0,0005	0,0035	0,0005	0,0005	0,0005	0,0005	0,0005	0,0005	0,0351	0,0055	0,0075	46	212	476	548
0,064	0,2	1,4	0,0005	0,0035	0,0005	0,0005	0,0005	0,0005	0,0005	0,0005	0,0436	0,0055	0,0075	69	205	451	513
0,066	0,36	1,41	0,0005	0,0035	0,0005	0,0005	0,0005	0,0005	0,0005	0,0005	0,0415	0,0055	0,0075	68	214	494	548
0,073	0,62	1,44	0,0005	0,0035	0,0005	0,0005	0,0005	0,0005	0,0005	0,0005	0,0366	0,0055	0,0075	71	226	519	582
0,063	0,92	1,38	0,0005	0,0035	0,0005	0,0005	0,0005	0,0005	0,0005	0,0005	0,0343	0,005	0,0075	73	230	515	603

Çizelge 4.4 Mangan Verileri

C	Si	Mn	Al	Ti	Nb	V	Mo	Cr	Ni	Cu	B	O	N	AF	HRD	YS	UTS
0,035	0,3	0,66	0,0005	0,0035	0,0005	0,0005	0,0005	0,0005	0,0005	0,0005	0,0005	0,049	0,007	23	178	392	468
0,038	0,3	1	0,0005	0,0035	0,0005	0,0005	0,0005	0,0005	0,0005	0,0005	0,0005	0,046	0,01	41	189	413	498
0,049	0,34	1,42	0,0005	0,0035	0,0005	0,0005	0,0005	0,0005	0,0005	0,0005	0,0005	0,041	0,009	62	215	568	551
0,051	0,34	1,82	0,0005	0,0035	0,0005	0,0005	0,0005	0,0005	0,0005	0,0005	0,0005	0,039	0,009	72	233	514	588

Çizelge 4.5 Titanyum Verileri

C	Si	Mn	Al	Ti	Nb	V	Mo	Cr	Ni	Cu	B	O	N	AF	HRD	YS	UTS
0,074	0,33	1,45	0,0005	0,0006	0,0005	0,0005	0,0005	0,0005	0,0005	0,0005	0,0005	0,0408	0,009	5	214	463	537
0,073	0,34	1,49	0,0005	0,0016	0,0005	0,0005	0,0005	0,0005	0,0005	0,0005	0,0005	0,0396	0,0084	62	228	482	548
0,071	0,36	1,46	0,0005	0,0022	0,0005	0,0005	0,0005	0,0005	0,0005	0,0005	0,0005	0,04	0,0085	72	218	497	563
0,061	0,33	1,36	0,0005	0,0028	0,0005	0,0005	0,0005	0,0005	0,0005	0,0005	0,0005	0,0419	0,0081	70	212	474	538
0,07	0,32	1,48	0,0005	0,0055	0,0005	0,0005	0,0005	0,0005	0,0005	0,0005	0,0005	0,0373	0,0075	64	218	488	549
0,068	0,32	1,38	0,0005	0,0077	0,0005	0,0005	0,0005	0,0005	0,0005	0,0005	0,0005	0,0376	0,0074	58	216	468	542
0,068	0,35	1,51	0,0005	0,01	0,0005	0,0005	0,0005	0,0005	0,0005	0,0005	0,0005	0,0351	0,0087	62	215	499	569
0,065	0,39	1,53	0,0005	0,014	0,0005	0,0005	0,0005	0,0005	0,0005	0,0005	0,0005	0,0351	0,0083	70	225	513	579
0,07	0,48	1,64	0,0005	0,021	0,0005	0,0005	0,0005	0,0005	0,0005	0,0005	0,0005	0,029	0,00102	74	232	515	592
0,071	0,29	1,75	0,0005	0,0255	0,0005	0,0005	0,0005	0,0005	0,0005	0,0005	0,0005	0,0272	0,0056	76	232	588	654

Çizelge 4.6 Alüminyum Verileri

C	Si	Mn	Al	Ti	Nb	V	Mo	Cr	Ni	Cu	B	O	N	AF	HRD	YS	UTS
0,069	0,3	1,36	0,0005	0,0037	0,0005	0,0005	0,0005	0,0005	0,0005	0,0005	0,0005	0,0432	0,0067	72	205	468	529
0,08	0,33	1,41	0,0078	0,0043	0,0005	0,0005	0,0005	0,0005	0,0005	0,0005	0,0005	0,0432	0,0061	67	201	478	540
0,076	0,37	1,36	0,019	0,0036	0,0005	0,0005	0,0005	0,0005	0,0005	0,0005	0,0005	0,0422	0,0054	77	205	485	549
0,078	0,44	1,3	0,034	0,0036	0,0005	0,0005	0,0005	0,0005	0,0005	0,0005	0,0005	0,0431	0,0052	72	210	491	564
0,076	0,51	0,3	0,049	0,0043	0,0005	0,0005	0,0005	0,0005	0,0005	0,0005	0,0005	0,0423	0,005	63	220	485	560
0,079	0,57	1,32	0,061	0,0038	0,0005	0,0005	0,0005	0,0005	0,0005	0,0005	0,0005	0,0422	0,0048	50	210	491	570

Çizelge 4.6'de Alüminyum yüzde oranları değiştirilerek elde edilmiştir. Alüminyum oranının artışı asiküler ferrit oranının azalmasına sertlik, akma dayanımı ve maksimum çekme dayanımının bir miktar artmasına sebep olmuştur. Alüminyum kaynak havuzunda oksijen ile tepkimeye girerek gözenek oluşumunu azaltmaktadır. Bu durum kaynak kalitesini arttırıp mekanik özelliklerin iyileşmesine neden olur. Asiküler ferrit oranının azalmasının sebebi ise kaynak havuzunda alüminyum ile karbonun tepkimeye girerek karbür oluşturmastır.

Çizelge 4.7'da Niyobyum, Mangan, Azot ve Oksijen yüzde oranları değiştirilerek elde edilmiştir. Niyobyum artışı kaynak metalinde çatlama riskini arttırdığı için kaynak kalitesinin arttırılması açısından Mangan ve Azot oranları değiştirilmiştir. Niyobyum oranı arttıkça sertlik, akma dayanımı, maksimum çekme dayanımı artmıştır. Asiküler ferrit oluşumunun niyobyum elementi ile bir orantısı bulunmamaktadır. Azot ve oksijen değişimi asiküler ferrit oranını değiştirmektedir.

Çizelge 4.8'de Vanadyum, Mangan ve Krom yüzde oranları değiştirilerek elde edilmiştir. Vanadyum oranı tabloda aşağı doğru inerken genellikle azalmaktadır. Buna rağmen asiküler ferrit oranı, sertlik, akma dayanımı ve maksimum çekme dayanımı artmıştır. Bunun sebebi krom ve mangan oranlarının artmasından kaynaklanmaktadır. Krom kaynak metalinin mekanik özelliklerini arttırırken, mangan kaynak kalitesini arttırmaktadır.

Çizelge 4.9'de Molibdenin yüzde oranı değiştirilerek elde edilmiştir. Artan Molibden oranı asiküler ferrit, sertlik, akma dayanımı ve maksimum çekme dayanımının olumlu yönde arttırmıştır.

Çizelge 4.10'de Krom, Karbon ve Mangan yüzde oranları değiştirilerek elde edilmiştir. Krom oranının artması doğrudan asiküler ferrit oluşunun azaltmış hatta bir noktada yok etmiştir. Tabloda krom oranının 0,0005 olduğu iki satırı karşılaştırdığımızda artan karbon ve mangan oranının sertlik, akma dayanımı ve maksimum çekme dayanımı gibi mekanik özelliklerinin yükselmesine sebep olduğu açıkça görülmektedir. Kromun bu mekanik

özelliklere etkisi olsada bunların asıl yükselmesindeki neden artan karbon oranı ve mangan oranıdır.

Çizelge 4.11’de Bakır yüzde oranı değiştirilerek elde edilmiştir. Kaynak metalindeki bakır yüzdesinin artması asiküler ferrit oluşumunu azaltmıştır. Sertlik, akma dayanımı ve maksimum çekme dayanımını ise arttırmıştır. Bu artışların sebebi bakırın elektrik iletiminin yüksek olmasından dolayı ark oluşumu ve sürekliliğini desteklediği için kaynak kalitesini arttırmasındandır. Ayrıca kaynak metalinin sünekliliğini arttırdığı için çatlak oluşunu azaltmaktadır. Bu durum kaynak metalinin dayanıklılığını ve esnekliğini arttırmaktadır.

Çizelge 4.12’da Nikel, Karbon ve Mangan yüzde oranları değiştirilerek elde edilmiştir. Asiküler ferrit, sertlik, akma dayanımı ve maksimum çekme dayanımı gibi mekaniksel özellikler nikel ve karbon ile doğru orantılı olarak artmıştır. Nikel, kaynak metalinin süneklilik ve dayanıklılığını artırarak çatlama ve deformasyona karşı daha dirençli hale getirir. Buna bağlı olarak kaynak metali içerisindeki karbon oranı arttırılabilmektedir. Bu durum ise kaynağın mekaniksel özelliklerinin artmasına sebep olmaktadır.

Çizelge 4.7 Niyobyum Verileri

C	Si	Mn	Al	Ti	Nb	V	Mo	Cr	Ni	Cu	B	O	N	AF	HRD	YS	UTS
0,073	0,35	0,64	0,0005	0,0038	0,0005	0,0003	0,0005	0,0005	0,0005	0,0005	0,0005	0,0428	0,0077	25	175	402	494
0,073	0,34	0,64	0,0005	0,0041	0,012	0,0003	0,0005	0,0005	0,0005	0,0005	0,0005	0,0431	0,008	11	199	450	532
0,075	0,33	0,62	0,0005	0,0042	0,022	0,0003	0,0005	0,0005	0,0005	0,0005	0,0005	0,0429	0,0085	12	200	474	553
0,07	0,33	0,64	0,0005	0,0042	0,045	0,0007	0,0005	0,0005	0,0005	0,0005	0,0005	0,0413	0,0085	12	212	522	580
0,074	0,33	0,64	0,0005	0,0039	0,088	0,0003	0,0005	0,0005	0,0005	0,0005	0,0005	0,046	0,011	13	216	549	614
0,077	0,31	1,33	0,0005	0,0038	0,0006	0,0004	0,0005	0,0005	0,0005	0,0005	0,0005	0,0419	0,008	70	210	463	541
0,079	0,33	1,37	0,0005	0,0034	0,0105	0,0004	0,0005	0,0005	0,0005	0,0005	0,0005	0,0417	0,0097	62	218	505	586
0,076	0,3	1,36	0,0005	0,0033	0,0235	0,0004	0,0005	0,0005	0,0005	0,0005	0,0005	0,037	0,0084	58	220	540	597
0,077	0,34	1,39	0,0005	0,0032	0,0455	0,0005	0,0005	0,0005	0,0005	0,0005	0,0005	0,0409	0,0099	61	226	586	641
0,076	0,3	1,36	0,0005	0,0033	0,094	0,0004	0,0005	0,0005	0,0005	0,0005	0,0005	0,0432	0,0091	49	230	610	685

Çizelge 4.8 Vanadyum Verileri

C	Si	Mn	Al	Ti	Nb	V	Mo	Cr	Ni	Cu	B	O	N	AF	HRD	YS	UTS
0,073	0,35	0,64	0,0005	0,0038	0,0005	0,0038	0,0005	0,0003	0,0005	0,0005	0,0005	0,0428	0,007	25	175	402	494
0,071	0,36	0,63	0,0005	0,0043	0,0005	0,0043	0,0005	0,021	0,0005	0,0005	0,0005	0,0435	0,0078	40	184	436	513
0,071	0,4	0,64	0,0005	0,0036	0,0005	0,0036	0,0005	0,0435	0,0005	0,0005	0,0005	0,0411	0,0088	49	184	478	546
0,074	0,36	0,63	0,0005	0,0031	0,0005	0,0031	0,0005	0,0635	0,0005	0,0005	0,0005	0,0432	0,0075	55	201	488	548
0,072	0,36	0,64	0,0005	0,0034	0,0005	0,0034	0,0005	0,0815	0,0005	0,0005	0,0005	0,0436	0,0084	55	205	490	563
0,077	0,31	1,33	0,0005	0,0038	0,0005	0,0038	0,0005	0,0004	0,0005	0,0005	0,0005	0,0419	0,008	70	210	463	541
0,072	0,33	1,22	0,0005	0,0029	0,0005	0,0029	0,0005	0,019	0,0005	0,0005	0,0005	0,0447	0,0085	72	212	486	545
0,077	0,26	1,36	0,0005	0,0029	0,0005	0,0029	0,0005	0,0425	0,0005	0,0005	0,0005	0,041	0,0079	72	218	536	590
0,078	0,3	1,35	0,0005	0,003	0,0005	0,003	0,0005	0,0595	0,0005	0,0005	0,0005	0,0405	0,0076	75	220	521	589
0,076	0,26	1,36	0,0005	0,0029	0,0005	0,0029	0,0005	0,1	0,0005	0,0005	0,0005	0,0407	0,0083	81	225	599	638

Çizelge 4.9 Molibden Verileri

C	Si	Mn	Al	Ti	Nb	V	Mo	Cr	Ni	Cu	B	O	N	AF	HRD	YS	UTS
0,037	0,31	1,03	0,0005	0,0035	0,0005	0,0005	0,0005	0,0005	0,0005	0,0005	0,0005	0,039	0,0065	40	199	413	498
0,038	0,32	1,03	0,0005	0,0035	0,0005	0,0005	0,27	0,0005	0,0005	0,0005	0,0005	0,039	0,0065	56	218	458	530
0,039	0,29	0,95	0,0005	0,0035	0,0005	0,0005	0,52	0,0005	0,0005	0,0005	0,0005	0,039	0,0065	72	234	501	571
0,044	0,35	1	0,0005	0,0035	0,0005	0,0005	1,11	0,0005	0,0005	0,0005	0,0005	0,039	0,0065	64	246	618	684

Çizelge 4.10 Krom Verileri

C	Si	Mn	Al	Ti	Nb	V	Mo	Cr	Ni	Cu	B	O	N	AF	HRD	YS	UTS
0,037	0,31	1,03	0,0005	0,0035	0,0005	0,0005	0,0005	0,0005	0,0005	0,0005	0,0005	0,039	0,0065	40	206	413	498
0,041	0,32	1,01	0,0005	0,0035	0,0005	0,0005	0,0005	0,24	0,0005	0,0005	0,0005	0,039	0,0065	48	201	463	532
0,043	0,31	0,95	0,0005	0,0035	0,0005	0,0005	0,0005	0,53	0,0005	0,0005	0,0005	0,039	0,0065	55	218	494	545
0,045	0,32	0,97	0,0005	0,0035	0,0005	0,0005	0,0005	1,04	0,0005	0,0005	0,0005	0,039	0,0065	62	228	531	592
0,046	0,3	0,93	0,0005	0,0035	0,0005	0,0005	0,0005	2,38	0,0005	0,0005	0,0005	0,039	0,0065	6	268	655	722
0,045	0,33	1,85	0,0005	0,0035	0,0005	0,0005	0,0005	0,0005	0,0005	0,0005	0,0005	0,039	0,0065	70	228	514	588
0,048	0,33	1,85	0,0005	0,0035	0,0005	0,0005	0,0005	0,26	0,0005	0,0005	0,0005	0,039	0,0065	68	232	567	622
0,051	0,33	1,83	0,0005	0,0035	0,0005	0,0005	0,0005	0,52	0,0005	0,0005	0,0005	0,039	0,0065	86	266	617	674
0,052	0,33	1,81	0,0005	0,0035	0,0005	0,0005	0,0005	1,1	0,0005	0,0005	0,0005	0,039	0,0065	84	276	692	723
0,054	0,33	1,72	0,0005	0,0035	0,0005	0,0005	0,0005	2,36	0,0005	0,0005	0,0005	0,039	0,0065	0	324	808	865

Çizelge 4.11 Bakır Verileri

C	Si	Mn	Al	Ti	Nb	V	Mo	Cr	Ni	Cu	B	O	N	AF	HRD	YS	UTS
0,074	0,36	1,51	0,0005	0,004	0,0005	0,0005	0,0005	0,0005	0,0005	0,02	0,0005	0,04	0,0065	89	182	484	563
0,075	0,36	1,48	0,0005	0,004	0,0005	0,0005	0,0005	0,0005	0,0005	0,11	0,0005	0,039	0,0065	88	182	502	548
0,074	0,32	1,42	0,0005	0,004	0,0005	0,0005	0,0005	0,0005	0,0005	0,19	0,0005	0,038	0,0065	82	185	488	549
0,076	0,33	1,48	0,0005	0,004	0,0005	0,0005	0,0005	0,0005	0,0005	0,35	0,0005	0,04	0,0065	80	186	504	572
0,068	0,32	1,49	0,0005	0,004	0,0005	0,0005	0,0005	0,0005	0,0005	0,66	0,0005	0,39	0,0065	81	211	513	607
0,076	0,36	1,49	0,0005	0,004	0,0005	0,0005	0,0005	0,0005	0,0005	1,4	0,0005	0,41	0,0065	84	248	568	673

Çizelge 4.12 Nikel Verileri

C	Si	Mn	Al	Ti	Nb	V	Mo	Cr	Ni	Cu	B	O	N	AF	HRD	YS	UTS
0,037	0,31	1,03	0,0005	0,0035	0,0005	0,0005	0,0005	0,0005	0,0005	0,0005	0,0005	0,039	0,0065	40	181	413	498
0,039	0,33	1,01	0,0005	0,0035	0,0005	0,0005	0,0005	0,0005	0,49	0,0005	0,0005	0,039	0,0065	39	201	464	522
0,038	0,33	1	0,0005	0,0035	0,0005	0,0005	0,0005	0,0005	1,1	0,0005	0,0005	0,039	0,0065	38	215	475	541
0,041	0,31	0,96	0,0005	0,0035	0,0005	0,0005	0,0005	0,0005	2,38	0,0005	0,0005	0,039	0,0065	42	220	489	567
0,037	0,31	0,98	0,0005	0,0035	0,0005	0,0005	0,0005	0,0005	3,46	0,0005	0,0005	0,039	0,0065	46	229	525	605
0,045	0,33	1,85	0,0005	0,0035	0,0005	0,0005	0,0005	0,0005	0,0005	0,0005	0,0005	0,039	0,0065	70	235	514	588
0,049	0,33	1,85	0,0005	0,0035	0,0005	0,0005	0,0005	0,0005	0,51	0,0005	0,0005	0,039	0,0065	68	232	547	618
0,053	0,35	1,83	0,0005	0,0035	0,0005	0,0005	0,0005	0,0005	1,06	0,0005	0,0005	0,039	0,0065	73	250	566	641
0,048	0,32	1,81	0,0005	0,0035	0,0005	0,0005	0,0005	0,0005	2,33	0,0005	0,0005	0,039	0,0065	77	276	621	684
0,51	0,35	1,79	0,0005	0,0035	0,0005	0,0005	0,0005	0,0005	3,42	0,0005	0,0005	0,039	0,0065	67	302	692	753

5. SONUÇ ve ÖNERİLER

Kaynak metalinin bileşimi kaynaklı bağlantının genel özelliklerini ciddi olarak etkilemektedir. Bu nedenle bileşim özellik ilişkisi arasındaki etkileşim uygun yöntemlerle irdelendiğinde çok daha farklı çıktılara sebep olabilecektir. Buna örnek olarak kaynak özelliklerinin modellenmesinin doğruluğu özellikle MSE, MAPE, MAD gibi değişik teknikler kullanılarak mümkün olabilir. Ağların başarısının ölçülmesinde MAPE, R ve R2 performans parametreleri kullanılmıştır. Ağların ürettiği tahmini değerler ile ölçüm değerleri arasındaki R değeri asiküler ferrit için 0,931 sertlik için 0,959 akma dayanımı için 0,941 ve maksimum çekme dayanımı için 0,963 olarak hesaplanmıştır. Bu da ağların AF için %93,135, sertlik için %95,923, akma dayanımı %94,17 ve maksimum çekme dayanımı %96,324 başarılı olduğunu göstermektedir. R2 değerleri ise sırasıyla 0,8674 0,9201 0,9278 ve 0,8868 olarak bulunmuştur. R2 değerlerinin 1'e yakın olması ağın güçlü bir tahmin yaptığını göstermektedir. MAPE değerleri ise akma dayanımı için 31,253 olarak bulunmaktadır. Bu ise hata payının %31,25 olduğunu göstermektedir. Çizelge 4.1'de belirtildiği üzere, MAPE değerinin %50'nin altında olması oluşturulan ağın tahmin gücünün kabul edilebilir olduğunu göstermektedir. Sertlik için ise MAPE değeri 2,73 olarak bulunmuştur. Bu ise hata payının %2,73 olduğunu gösterir. Akma dayanımı için MAPE değeri 2,6 yani hata payı %2,60 olmaktadır. Maksimum çekme dayanımı için ise MAPE değeri 2,34 olmaktadır yani %2,34'lük bir hata payı vardır. Sertlik, akma dayanımı ve maksimum çekme dayanımı için MAPE değerleri %10 altındadır. Yani bu değerler için ağların tahmin başarıları çok iyidir. Bu sonuçlara göz önüne alındığında oluşturulan ağların yapmış olduğu tahmin değerlerinin gayet güvenilir ve tutarlı olduğu söylenebilir. Bu doğrultuda kaynak metalinin içindeki elementlerin yüzde oranları verildiğinde AF, sertlik, akma dayanımı ve maksimum çekme kuvvetleri çok başarılı bir şekilde tahmin edilebilmektedir. Bu sayede kaynak bileşimine bağlı yukarıda sayılan özellikler önceden tahmin edilebildiği için, çeliklerin kaynağı sırasında ve öncesinde kaynak metalinin istenen özelliklere sahip olması için alınacak tedbirlerin başarılı bir şekilde uygulanması ve bu şekilde maliyet, zaman ve işçilik giderlerinin azaltılmasına fayda sağlayacaktır. Ayrıca çelik ürünlerinin üretimi sırasında, uygun özelliklerin elde uygulanabilirliği de mümkün olabilecek ve tokluğu, sertliği, akma dayanımı ve maksimum çekme dayanımı kontrol edilebilen çeliklerin üretiminde bu konuda faydalar sağlanabilecektir.

6.KAYNAKLAR

- Acar O, 2020, Yapay zekâ fırsat mı yoksa tehdit mi?. İstanbul: Kriter Yayınevi.
- Acherjee B, Mondal S, Tudu B, Misra D, 2011, Application of artificial neural network for predicting weld quality in laser transmission welding of thermoplastics. Applied soft computing, 11(2), 2548-2555.
- Aggarwal C. C, 2018, Neural networks and deep learning. Springer, 10(978), 3.
- Akalın B, Veranyurt Ü, 2020, Sağlıkta Dijitalleşme Ve Yapay Zekâ. SdÜ Sağlık Yönetimi Dergisi, 2(2), 128-137.
- Aydın İ. H, Değirmenci C. H, 2018, Yapay Zekâ, İstanbul: Girdap Yayınları.
- Bağcı B, 2018, Bulanık Esnek Kümelere Dayalı Birleştirilmiş Bir Tahminleme Yaklaşımı, Hitit Üniversitesi, Sosyal Bilimler Enstitüsü, Yüksek Lisans Tezi, 161s, Çorum.
- Bengio Y, Courville A, Vincent P, 2013, Representation learning: A review and new perspectives. IEEE transactions on pattern analysis and machine intelligence, 35(8), 1798-1828.
- Binbir S, 2021, Pazarlama Çalışmalarında Yapay Zekâ Kullanımı Üzerine Betimleyici Bir Çalışma. Yeni Medya Elektronik Dergisi, 5(3), 314-328.
- Bishop C. M, 1995, Neural networks for pattern recognition. Oxford university press.
- Bishop C. M, Nasrabadi N. M, 2006, Pattern recognition and machine learning (Vol. 4, No. 4, p. 738). New York: springer.
- Brice L, 2003, 'The influence of indenter characteristics on hardness measurements ', IMEKO-XVII World Congress, June 22-27.
- Brown T, Mann B, Ryder N, Subbiah M, Kaplan J. D, Dhariwal P, Amodei D, (2020). Language models are few-shot learners. Advances in neural information processing systems, 33, 1877-1901.
- Bryson J, Winfield A, 2017, Standardizing ethical design for artificial intelligence and autonomous systems. Computer, 50(5), 116-119.

- Cary H. B, Helzer S. C, 2019, Modern Welding Technology. Pearson.
- Casalino G, Facchini F, Mortello M, Mummolo G, 2016, ANN modelling to optimize manufacturing processes: The case of laser welding. IFAC-PapersOnLine, 49(12), 378-383.
- Chollet F, 2018, Deep learning mit python und keras: das praxis-handbuch vom entwickler der keras-bibliothek. MITP-Verlags GmbH & Co. KG.
- Coşkun F, Gülleroğlu H. D, 2021, Yapay zekânın tarih içindeki gelişimi ve eğitimde kullanılması. Ankara University Journal of Faculty of Educational Sciences (JFES), 54(3), 947-966.
- Dhas J. E. R, Dhas S. J. H, 2012, A review on optimization of welding process. Procedia Engineering, 38, 544-554.
- Dick S, 2019, Artificial intelligence. Harvard Data Science Review, 1(1), 1-8. doi: 10.1162/99608f92.92fe150c.
- Diler A. İ, 2003, İmkb ulusal-100 endeksinin yönünün yapay sinir ağıları hata geriye yayma yöntemi ile tahmin edilmesi. Türkiye’de Bankalar, Sermaye Piyasası Ve Ekonomik Büyüme: Koentegrasyon Ve Nedensellik Analizi (1989-2000), 81.
- Doruk E, Pakdil M, Çam G, Durgun İ, Kumru U. C, 2015, Otomotiv Sektöründe Direnç Nokta Kaynağı Tofaş Uygulamaları.
- Duda R. O, Hart P. E, 1973, Pattern classification and scene analysis (Vol. 3, pp. 731-739). New York: Wiley.
- Engelbrecht A. P, 2007, Computational intelligence: an introduction. John Wiley & Sons.
- Evans G.M, 1982, OERLIKON SchweiBmitt., 40(99), p.17.
- Evans G.M, 1986, OERLIKON SchweiBmitt., 44(110), p.19).
- Evans G.M, 1987 OERLIKON SchweiBmitt., 45(115), p.10.
- Evans G.M, 1989, OERLIKON SchweiBmitt., 47(120), p.17.
- Evans G.M, 1990a, OERLIKON SchweiBmitt., 48(122), p.18.
- Evans G.M, 1990b, OERLIKON SchweiBmitt., 48(123), p.15.
- Evans G.M, 1991a, OERLIKON SchweiBmitt., 49(124), p.15.

- Evans G.M, 1991b, OERLIKON SchweiBmitt., 49(125), p.22.
- Evans G.M, 1991c, OERLIKON SchweiBmitt., 49(126), p.18.
- Evans G.M, 1991d, OERLIKON SchweiBmitt., 49(127), p.24.
- Evans G.M, Bailey N, 1999, Metallurgy of Basic Weld Metal. Cambridge: Abington.
- Genel K, 2004, Application of artificial neural network for predicting strain-life fatigue properties of steels on the basis of tensile tests. International Journal of Fatigue, 26(10), 1027-1035.
- Géron A, 2022, Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow. " O'Reilly Media, Inc."
- Goodfellow I, Bengio Y, Courville A, 2016, Deep learning. MIT press.
- Gök R, 2023, Spor Salonları Aydınlatma Sistemlerinin Parıltı Değerlerinin Yapay Sinir Ağları Kullanılarak Tahmini, Afyon Kocatepe Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, 170s, Afyonkarahisar.
- Güler H, 2007, Çinko-alüminyum alaşımlarının korozyon davranışına alaşım elementlerinin etkisinin yapay sinir ağıyla tahmini, Sakarya Üniversitesi, Fen Bilimleri Enstitüsü, Doktora Tezi, 245s, Sakarya.
- Gümüş E, 2023, Yapay zekâ ve robot hemşireler hakkında hekim, hemşire ve hasta görüşleri, İstanbul Üniversitesi, Cerrahpaşa Lisansüstü Eğitim Enstitüsü, Doktora Tezi, 100s, İstanbul.
- Gürtaş S, 2020, Otonom araç sürüş destek sistemleri ve yapay zekâ uygulamaları, Bursa Uludağ Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, 122s, Bursa.
- Haykin S, 1998, Neural networks: a comprehensive foundation. Prentice Hall PTR.
- Heaton J, 2018, Ian Goodfellow, Yoshua Bengio, and Aaron Courville: Deep learning: The MIT Press, 2016, 800 pp, ISBN: 0262035618. Genetic Programming and Evolvable Machines, 19(1-2), 305-307.
- Hebb D. O, 2005, The organization of behavior: A neuropsychological theory. Psychology press.

- Hopfield J. J, 1982, Neural networks and physical systems with emergent collective computational abilities. *Proceedings of the national academy of sciences*, 79(8), 2554-2558.
- Hornik K, Stinchcombe M, White H, 1989, Multilayer feedforward networks are universal approximators. *Neural networks*, 2(5), 359-366.
- Hu, J, Bi J, Liu H., Li Y, Ao S, Luo Z, 2022, Prediction of Resistance Spot Welding Quality Based on BPNN Optimized by Improved Sparrow Search Algorithm. *Materials*, 15(20), 7323.
- İnal S, 2016, Mikro-sertlik Deney Föyü, K.T.Ü Maden Mühendisliği Bölümü – Maden İşletme Laboratuvarı.
- James G, Witten D, Hastie T, Tibshirani R, 2013, An introduction to statistical learning (Vol. 112, p. 18). New York: springer.
- Jassim M S, Coşkuner G, Zontul M, 2022, Comparative Performance Analysis of Support Vector Regression and Artificial Neural Network for Prediction of Municipal Solid Waste Generation, *Waste Management & Research*, 40(2), 195-204.
- John G. Hicks, 2001, Welded design: theory and practice. Woodhead Publishing.
- Karaman Ö, 2021, Yapay Zekâ Destekli Kişiselleştirme Algoritmalarının Tüketici Zihninde Filtre Balonu Yaratma Etkisinin İncelenmesi. *Süleyman Demirel Üniversitesi Vizyoner Dergisi*, 12(32), 1339-1351.
- Kavuncu S. K, 2018, Makine öğrenmesi ve derin öğrenme: Nesne tanıma uygulaması, Kırıkkale Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, 170s, Kırıkkale.
- Kılıç Ü. G, 2021, Güç sistemlerinin yük tahmini analizinde uzun kısa süreli bellek metodunun kullanılması ve uygulaması, Bilecik Şeyh Edebali Üniversitesi, Lisansüstü Eğitim Enstitüsü, Yüksek Lisans Tezi, 78s, Bilecik.
- Kohonen T, 1982, Self-organized formation of topologically correct feature maps. *Biological cybernetics*, 43(1), 59-69.
- Kou S, 2003, Welding metallurgy. New Jersey, USA, 431(446), 223-225.

- Krizhevsky A, Sutskever I, Hinton G. E, 2017, Imagenet classification with deep convolutional neural networks. *Communications of the ACM*, 60(6), 84-90.
- Kul S, 2020, Türkçe Ders Anlatan Yapay Zekâya Giden Yolda Doğal Dil İşleme. *Yönetim Bilişim Sistemleri Dergisi*, 6(2), 43-56.
- Kurt, HI, Oduncuoğlu, M., Yılmaz, NF, Ergül, E. ve Asmatulu, R. (2018). ANOVA analizi ile yapay sinir ağı ve Taguchi yaklaşımları kullanılarak östenitik paslanmaz çeliklerin kaynak parametrelerinin etkisi üzerine karşılaştırmalı bir çalışma. *Metaller* , 8 (5), 326.
- Kuzu C, 2006, Birincil seviyeli rockwell sertlik standardı makinesi tasarımı, Kocaeli Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, 61s, Kocaeli.
- LeCun Y, Bengio Y, Hinton G, 2015, Deep learning. *nature*, 521(7553), 436-444.
- Levenberg K, 1944, A method for the solution of certain non-linear problems in least squares. *Quarterly of applied mathematics*, 2(2), 164-168.
- Lippold J. C, Kotecki D. J, 2005, Welding metallurgy and weldability of stainless steels (p. 376).
- Lippold J. C, 2014, Welding metallurgy and weldability. John Wiley & Sons.
- Liu Z, Liu Q, Xu W, Wang L, Zhou Z, 2022, Robot learning towards smart robotic manufacturing: A review. *Robotics and Computer-Integrated Manufacturing*, 77, 102360.
- Marquardt D. W, 1963, An algorithm for least-squares estimation of nonlinear parameters. *Journal of the society for Industrial and Applied Mathematics*, 11(2), 431-441.
- McCarthy J, 2007, From here to human-level AI. *Artificial Intelligence*, 171(18), 1174-1182. <https://doi.org/10.1016/j.artint.2007.10.009>.
- McCarthy J, Minsky M. L, Rochester N, Shannon C. E, 2006, A proposal for the dartmouth summer research project on artificial intelligence, august 31, 1955. *AI magazine*, 27(4), 12-12.
- Mercan S, 2019, Kaynak Bağlantılarında Hasar Analizi . *International Journal of Innovative Engineering Applications* , 3 (2) , 67-75.

- Minsky M, Papert S, 1969, An introduction to computational geometry. Cambridge tiass., HIT, 479, 480.
- Møller M. F, 1993, A scaled conjugate gradient algorithm for fast supervised learning. Neural networks, 6(4), 525-533.
- Morrison D. M, Rus V, 2013, The SCHOLAR Legacy: A New Look at the Affordances of Semantic Networks for Conversational Agents in Intelligent Tutoring Systems. In *AIED Workshops*.
- Naguib R. N, Sherbet G. V (Eds.), 2001, Artificial neural networks in cancer diagnosis, prognosis, and patient management. CRC press.
- Nair V, Hinton G. E, 2010, Rectified linear units improve restricted boltzmann machines. In Proceedings of the 27th international conference on machine learning (ICML-10) (pp. 807-814).
- Nielsen M. A, 2015, Neural networks and deep learning (Vol. 25, pp. 15-24). San Francisco, CA, USA: Determination press.
- Ogiela M. R, Jain L. C, 2012, Recent Advances in Pattern Classification. Computational Intelligence Paradigms in Advanced Pattern Classification, 1-4.
- Özdemir E, 2006, Örtülü elektrolarda gaz ve partikül emisyonunun incelenmesi (Doctoral dissertation).
- Öztürk K, Şahin M, 2018, Yapay sinir ağları ve yapay zekâya genel bir bakış. Takvim-i Vekayi, 6(2), 25-36.
- Rajkumar G. B, Murugan N, 2012, Prediction of Weld Bead Geometry Using Artificial Neural Networks on 2205 Duplex Stainless Steel. European Journal of Scientific Research, Issn, 85-92.
- Rosenblatt F, 1958, The perceptron: a probabilistic model for information storage and organization in the brain. Psychological review, 65(6), 386.
- Ross T. J, 2009, Fuzzy logic with engineering applications. John Wiley & Sons.
- Rumelhart D. E, Hinton G. E, Williams R. J, 1986, Learning representations by back-propagating errors. nature, 323(6088), 533-536.
- Russell S. J, 2010, Artificial intelligence a modern approach. Pearson Education, Inc..

- Sadki A, Hattali M. L, Bradai M. A, Younes R, Mesrati N, 2016, Characterization and modeling of the mechanical behavior of aeronautical alloy based composite. Univ J Chem, 4(1), 10-19.
- Sanalan A, 2022, Yapay zekâ ve büyük veri teknolojilerinin mimari tasarım sürecindeki rolü, TC Maltepe Üniversitesi, Lisansüstü Eğitim Enstitüsü, Yüksek Lisans Tezi, 114s, İstanbul.
- Smith R. L, Sandly G. E, 1922, An accurate method of determining the hardness of metals, with particular reference to those of a high degree of hardness. Proceedings of the Institution of Mechanical Engineers, 102(1), 623-641.
- Soyhan İ, GUREL S, Tekin S. A, 2021, Yapay Zekâ Tabanlı Görüntü İşleme Tekniklerinin İnsansız Hava Araçları Üzerinde Uygulamaları. Avrupa Bilim ve Teknoloji Dergisi, (24), 469-473.
- Sutton R. S, Barto A. G, 2018, Reinforcement learning: An introduction. MIT press.
- Şahin M, 2010, Yapay Sinir Ağları İle Dâhili Ortamlardaki Aydınlik Düzeyinin Analizi, Marmara Üniversitesi Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, 118s, İstanbul.
- Şahin M, 2014, Farklı Teknik ve Fiziksel Özelliklerdeki Ortamların Bakım Katsayılarının Belirlenmesi ve Aydınlik Düzeylerini Yapay Sinir Ağları ile Tahmin Edilmesi, Marmara Üniversitesi, Fen Bilimleri Enstitüsü, Doktora Tezi, 283s, İstanbul.
- Şık A, Akay A, Bingöl T, 2023, Tozaltı Ark Kaynak (Saw) Yönteminde Kaynak Genişliğinin Taguchi Metoduyla Optimizasyonu. Eskişehir Osmangazi Üniversitesi Mühendislik Ve Mimarlık Fakültesi Dergisi, 31(1), 558-571.
- Thekkuden, D. T., & Mourad, A. H. I. (2019). Investigation of feed-forward back propagation ANN using voltage signals for the early prediction of the welding defect. SN Applied Sciences, 1, 1-17.
- Vaishya R, Javaid M, Khan I. H, Haleem A, 2020, Artificial Intelligence (AI) applications for COVID-19 pandemic. Diabetes & Metabolic Syndrome: Clinical Research & Reviews, 14(4), 337-339.

- Van Der Malsburg. C, 1986, Frank rosenblatt: Principles of neurodynamics: Perceptrons and the theory of brain mechanisms. In Brain Theory: Proceedings of the First Trieste Meeting on Brain Theory, October 1–4, 1984 (pp. 245-248). Springer Berlin Heidelberg.
- Visalakshi N. K, Thangavel K, 2009, Impact Of Normalization İn Distributed K-Means Clustering, International Journal of Soft computing, 4(4), 168-172.
- Wang Z., She Q, Ward T. E, 2021, Generative adversarial networks in computer vision: A survey and taxonomy. ACM Computing Surveys (CSUR), 54(2), 1-38.
- Weman K, 2011, Welding processes handbook. Elsevier.
- Widrow B, Hoff M. E, 1960, *Adaptive switching circuits*. Stanford Univ Ca Stanford Electronics Labs.
- Yetkin M, 2014, Tanker-şamandıra Bağlama Sistemlerinin Yapay Sinir Ağları Tekniğiyle Optimizasyonu, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, 79s, İstanbul
- Yıldız A, 2022, Finans Alanında Yapay Zekâ Teknolojisinin Kullanımı: Sistematik Literatür İncelemesi. Pamukkale Üniversitesi Sosyal Bilimler Enstitüsü Dergisi, (52), 47-66.

İnternet Kaynakları

- 1- <https://academic.oup.com/mind/article/LIX/236/433/986238> 03.03.2023
- 2- <https://turkiye.ai/kaynaklar/yapay-zekâ-zaman-cizelgesi/> 20.03.2023
- 3- <https://flipdazed.github.io/blog/python%20tutorial/introduction-to-neural-networks-in-python-using-XOR> 03.05.2023
- 4- https://www.materialwelding.com/what-is-heat-affected-zone-or-haz-in-welding-haz-width/?utm_content=expand_article 19.05.2023
- 5- https://www.academia.edu/6799174/KAYNAK_METALURJ%C4%B0S%C4%B0_ADEM_KURT 20.05.2023