

**YAPAY ZEKA METOTLARINI KULLANARAK
OTOMOTİV SEKTÖRÜNDEKİ ÖRNEK
PROBLEMLERİNİN ÇÖZÜMLERİNİN ARAŞTIRILMASI**

İlhan ÇEKİÇ



T.C.
BURSA ULUDAĞ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**YAPAY ZEKA METOTLARINI KULLANARAK OTOMOTİV
SEKTÖRÜNDEKİ ÖRNEK PROBLEMLERİNİN ÇÖZÜMLERİNİN
ARAŞTIRILMASI**

İlhan ÇEKİÇ
0000-0002-3439-4904

Prof. Dr. Kadir ÇAVDAR
(Danışman)

DOKTORA TEZİ
MAKİNA MÜHENDİSLİĞİ ANABİLİM DALI

BURSA – 2022
Her Hakkı Saklıdır

TEZ ONAYI

İlhan ÇEKİÇ tarafından hazırlanan “YAPAY ZEKA METOTLARINI KULLANARAK OTOMOTİV SEKTÖRÜNDEKİ ÖRNEK PROBLEMLERİNİN ÇÖZÜMLERİNİN ARAŞTIRILMASI” adlı tez çalışması aşağıdaki jüri tarafından oy birliği ile Bursa Uludağ Üniversitesi Fen Bilimleri Enstitüsü Makine Mühendisliği Anabilim Dalı’nda **DOKTORA TEZİ** olarak kabul edilmiştir.

Danışman : Prof. Dr. Kadir ÇAVDAR

- | | | |
|---------------|---|------|
| Başkan | : Prof. Dr. Kadir ÇAVDAR
0000-0001-9126-0315
Bursa Uludağ Üniversitesi,
Makine Mühendisliği Anabilim Dalı | İmza |
| Üye | : Prof. Dr. Ali DURMUŞ
0000-0003-2487-7344
Bursa Uludağ Üniversitesi,
Makine Mühendisliği Anabilim Dalı | İmza |
| Üye | : Dr. Öğr. Üy. Mehmet AKANSEL
0000-0002-4924-7587
Bursa Uludağ Üniversitesi,
Endüstri Mühendisliği Anabilim Dalı | İmza |
| Üye | : Prof. Dr. Ali ORAL
0000-0002-9144-3821
Balıkesir Üniversitesi,
Konstrüksiyon Ve İmalat Anabilim Dalı | İmza |
| Üye | : Doç. Dr. Alaattin TOKTAŞ
0000-0002-9902-6969
Balıkesir Üniversitesi,
Konstrüksiyon Ve İmalat Anabilim Dalı | İmza |

Yukarıdaki sonucu onaylarım

Prof. Dr. Hüseyin Aksel EREN
Enstitü Müdürü
30/5/2022

B.U.Ü. 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.

03/02/2022

İlhan ÇEKİÇ

ÖZET

Doktora Tezi

YAPAY ZEKA METOTLARINI KULLANARAK OTOMOTİV SEKTÖRÜNDEKİ ÖRNEK PROBLEMLERİNİN ÇÖZÜMLERİNİN ARAŞTIRILMASI

İlhan ÇEKİÇ

Bursa Uludağ Üniversitesi
Fen Bilimleri Enstitüsü
Makina Mühendisliği Anabilim Dalı

Danışman: Prof. Dr. Kadir ÇAVDAR

Otomotiv imalat sektöründe mevcut süreçlerde pek çok farklı hata modu ile karşılaşılmaktadır. Bu hataların giderilmesi için geçici ve kalıcı önlemler alınmaya çalışılır. Yapılan faaliyetlerde çoğu zaman, süreçlerin doğası gereği, sıfır hata koşulları oluşturulamamaktadır. Buradaki zafiyeti gidermek için insan inisiyatifinde olan %100 görsel kontrol ile hatanın bir sonraki sürece veya iç ve dış müşteriye gönderilmesini önlemek adına tedbir alınmaktadır. Buna karşın halen sahada hatalı parça taramalarında tespit edilemeyen hatalar nedeniyle, şiddetine bağlı olarak, son derece yüksek kalitesizlik maliyetleri ile karşılaşılmaktadır.

Modern yaklaşımda, hata tespitinde görsel kontroller yerine, makine öğreniminin farklı metotları kullanılarak, yüksek doğruluk oranları ile hata tespiti sağlanabilir. Örneğin üstün resim işleme, özellik çıkarma yeteneği nedeniyle, evrişimli sinir ağı (ESA), akıllı hata teşhisi alanında geniş çapta araştırılmış ve uygulanmış, diğer geleneksel makine öğrenme yöntemlerine kıyasla üstün performansı kanıtlanmıştır. İlave olarak, proses parametrelerinin belirlenmesinde, mevcut saha verilerinden yararlanarak, yapay sinir ağları (YSA) metodunu kullanarak, en ideal parametre sonuçları elde edilebilir.

Bu çalışmada, imalat süreçlerindeki hata tespitine izin veren yenilikçi bir yaklaşım geliştirilmiştir. Örnek çalışmalarda punta kaynak parametrelerinin belirlenmesinde, yapay sinir ağları (YSA) kullanarak, mevcut parametreler ile çekirdek çapı tahmini yapılmıştır. Burada farklı regresyon analizi neticelerine göre karşılaştırmalı sonuçlar çıkarılmıştır. Ayrıca punta ve gazaltı kaynak hataları, sac çatlak hataları ve araç görsel hatalarının tespit edilmesi için, makina öğrenmesindeki evrişimli sinir ağları (ESA) kullanarak, yüksek doğruluk oranları elde edilmiştir.

Anahtar Kelimeler: Makina Öğrenmesi, Yapay Sinir Ağları, Evrişimli Yapay Sinir Ağları, Punta Kaynak Hatalar, Gazaltı Kaynak Hatalar, Sac Yırtık Hatalar, Görsel Hatalar

2022, xi + 112 sayfa.

ABSTRACT

PhD Thesis

INVESTIGATION OF SOLUTIONS OF SAMPLE PROBLEMS IN THE
AUTOMOTIVE INDUSTRY USING ARTIFICIAL INTELLIGENCE METHODS

İlhan ÇEKİÇ

Bursa Uludağ University
Bursa Uludag University Institute of Science
Department of Machine Engineering

Supervisor: Prof. Dr. Kadir ÇAVDAR

Many different defect modes are encountered in the current processes in the automotive manufacturing sector. Temporary and permanent measures are tried to be taken to eliminate these defects. Most of the time, due to the nature of the processes, zero defect conditions cannot be created in the activities performed. In order to eliminate the weakness here, measures are taken to prevent the error from being sent to the next process or to the internal and external customers with 100% visual control at the human initiative. However, due to the defects that cannot be detected in the field defect scans, extremely high costs of poor quality are encountered, depending on the severity.

In the modern approach, defect detection with high accuracy rates can be achieved by using different methods of machine learning instead of visual controls in defect detection. For example, due to its superior image processing, feature extraction capability, convolutional neural network (CNN) has been widely researched and applied in the field of intelligent defect diagnosis and has gained superior performance compared to other traditional machine learning methods. In addition, in the determination of process parameters, the most ideal parameter results can be obtained by using the artificial neural networks (ANN) method by making use of the available field data.

In this study, an innovative approach has been developed that allows defect detection in manufacturing processes. In sample studies, In the determination of spot welding parameters, nugget diameter estimation was made with existing parameters using artificial neural networks (ANN). Here, comparative results are drawn according to the different regression analysis results. In addition, high accuracy rates have been achieved by using convolutional neural networks (CNN) in machine learning to detect spot and arc metal arc welding defects, sheet metal crack defects and vehicle visual defects.

Keywords: Machine Learning, Artificial Neural Networks, Convolutional Neural Networks, Spot Welding Defects, Arc Welding Defects, Sheet Crack Defects, Perceived Quality Defects.

2022, xi + 112 pages.

TEŐEKKÜR

Tez alıőmam boyunca destek ve yardımlarını esirgemeyen deęerli danıőman hocam Prof. Dr. Kadir AVDAR teőekkür ederim.

Sahada deneme alıőmalarında yardımlarını esirgemeyen, Tofaő Türk Otomobil Fabrikası A.Ő. ' ye ayrıca teőekkür ederim.

alıőmam süresince her türlü fedakarlıęa katlanan sevgili eőim Nergis EKİ'e ve sevgili kızım Duru Cennet EKİ'e, bugünlere gelmemde büyük emeęi olan aileme teőekkürü bor bilirim

İlhan EKİ
03/1/2022

İÇİNDEKİLER

	Sayfa
ÖZET	i
ABSTRACT	ii
ÖNSÖZ VE/VEYA TEŞEKKÜR.....	iii
SİMGELER ve KISALTMALAR DİZİNİ	vii
ŞEKİLLER DİZİNİ	ix
ÇİZELGELER DİZİNİ	xi
1. GİRİŞ	1
2. KAYNAK ARAŞTIRMASI.....	5
2.1. Yapay Zeka Yapısı.....	5
2.1.1. Öğrenme nedir?.....	6
2.1.2. Yapay Zeka Kullanım Alanları	7
2.1.3. Sinir Ağları	9
2.1.4. Tek Katmanlı ve Çok Katmanlı Sinir Ağı Modeli	11
2.1.4. Çok Katmanlı Algılayıcı Yapısı ve İşlevselliği	13
2.1.5. Aktivasyon Fonksiyonları.....	14
2.1.5.1. Doğrultulmuş lineer birim (Relu_ Rectified Linear Unit) Aktivasyon Fonksiyonu	15
2.1.5.2. Sigmoid Fonksiyonu.....	15
2.1.6. Kayıp (Loss) Fonksiyonu	16
2.1.7. Makine Öğrenmesi	19
2.1.7.1. Denetimli Öğrenme	20
2.1.7.1.1. Sınıflandırma.....	21
2.1.7.1.2. Regresyon	23
2.1.7.2. Denetimsiz Öğrenme	24
2.1.7.3. Derin Öğrenme.....	24
2.1.7.4. Pekiştirmeli Öğrenme.....	26
2.2. Performans Ölçütleri	29
2.3. Punta Kaynağında, Çekirdek Çapının Python Regresyon Modelleri ve Yapay Sinir Ağları İle Tahmini, Kaynak Araştırması.....	30
2.4. Punta Kaynak Hatalarının, Evrişimli Yapay Sinir Ağları (ESA) İle Tespit Edilmesi, Kaynak Araştırması	31
2.5. Gazaltı Kaynak Hatalarının, Evrişimli Yapay Sinir Ağları (ESA) İle Tespit Edilmesi, Kaynak Araştırması.....	39
2.6. Sac Metal Çatlaklarının Evrişimli Yapay Sinir Ağları (ESA) İle Tespit Edilmesi .	44
2.7. Araç Görsel Hataların Evrişimli Yapay Sinir Ağları (ESA) İle Tespit Edilmesi, Kaynak Araştırması	46
3. MATERYAL ve YÖNTEM.....	49
3.1. ESA İşlemleri.....	49
3.1.1. Veri Ön İşleme ve Veri Büyütme	50
3.1.2. Havuzlama Katmanı (Pooling)	51
3.1.3. Tamamen Bağlı Katman (Fully Connected Layer).....	52
3.2. Punta Kaynağında, Çekirdek Çapının Python Regresyon Modelleri ve Yapay Sinir Ağları İle Tahmini, Materyal ve Yöntem.....	53

3.3. Punta Kaynak Hatalarının, Evrişimli Yapay Sinir Ağları (ESA) İle Tespit Edilmesi, Materyel ve Yöntem	58
3.4. Gazaltı Kaynak Hatalarının, Evrişimli Yapay Sinir Ağları (ESA) İle Tespit Edilmesi, Materyel ve Yöntem.....	60
3.5. Sac Metal Çatlaklarının Evrişimli Yapay Sinir Ağları İle Tespit Edilmesi, Materyel ve Yöntem	62
3.5.1. Formlanabilme	64
3.5.2. Süneklilik Ölçümü.....	65
3.5.3 Şekillendirme Limit Diyagramı (ŞLD)	66
3.6. Araç Görsel Hataların Evrişimli Yapay Sinir Ağları İle Tespit Edilmesi.....	67
4. BULGULAR (BULGULAR VE TARTIŞMA)	70
4.1. Punta Kaynağında, Çekirdek Çapının Python Regresyon Modelleri ve Yapay Sinir Ağları İle Tahmini Bulguları.....	70
4.2. Punta Kaynak Hatalarının, Evrişimli Yapay Sinir Ağları (ESA) İle Tespit Edilmesi Bulguları.....	75
4.3. Gazaltı Kaynak Hatalarının, Evrişimli Yapay Sinir Ağları (ESA) İle Tespit Edilmesi Bulguları	78
4.4. Sac Metal Çatlaklarının Evrişimli Yapay Sinir Ağları İle Tespit Edilmesi Bulguları	81
4.5. Araç Görsel Hataların Evrişimli Yapay Sinir Ağları İle Tespit Edilmesi Bulguları	84
5. SONUÇ (TARTIŞMA ve SONUÇ).....	87
5.1.a. Araştırma Hipotezi 1: Otomotivde punta kaynağında, çekirdek çapının python regresyon modelleri ve yapay sinir ağları ile tahmininde kullanılabilir.	87
5.1.b. S1.1 Regresyon ve YSA metotları punta çekirdek çapı tahmininde kullanılabilir mi?	88
5.1.c. S1.2 Regresyon ve YSA teknikleri sınırları yeterli midir?	88
5.2.a. Araştırma Hipotezi 2: Otomotivde punta kaynak hatalarını, görüntü işleme ile kalite kontrol süreçlerinde yapay zeka ve makine öğrenmesi teknikleri kullanılabilir. .	88
5.2.b. S2.1 AI ve ML teknikleri punta kaynak hatalarının tespitinde kullanılabilir mi?	89
5.2.c. S2.2 AI ve ML tekniklerinin punta hataları sınırları için yeterli midir?	90
5.2.d. Araştırma Hipotezi 2: Otomotivde gazaltı kaynak hatalarını, görüntü işleme ile kalite kontrol süreçlerinde yapay zeka ve makine öğrenmesi teknikleri kullanılabilir. .	91
5.2.e. S2.1 AI ve ML teknikleri gazaltı kaynak hatalarının tespitinde kullanılabilir mi?	91
5.2.f. S2.2 AI ve ML tekniklerinin gazaltı hataları sınırları yeterli midir?	93
5.2.g. Araştırma Hipotezi 2: Otomotivde sac çatlak hatalarını Tespit etmede, görüntü işleme ile kalite kontrol süreçlerinde yapay zeka ve makine öğrenmesi teknikleri kullanılabilir.	93
5.2.h. S2.1 AI ve ML teknikleri sac çatlak hatalarının tespitinde kullanılabilir mi?	93
5.2.i. S2.2 AI ve ML tekniklerinin sac çatlak hataları sınırları yeterli midir?	95
5.2.i. Araştırma Hipotezi 2: Otomotivde araç görsel hatalarını Tespit etmede, görüntü işleme ile kalite kontrol süreçlerinde yapay zeka ve makine öğrenmesi teknikleri kullanılabilir.	95
5.2.j. S2.1 AI ve ML teknikleri araç görsel hatalarının tespitinde kullanılabilir mi?	95
5.2.k. S2.2 AI ve ML tekniklerinin araç görsel hataları sınırları yeterli midir?	96
5.3. Araştırma Hipotezi 3: Görüntü işlemede AI tekniklerinin kullanımı yeterli doğruluk değerine bizi ulaştırabilir.....	97

5.3.1. S3.1 Ulaşılabilecek en yüksek doğruluk deęerini belirleyen faktörler nelerdir?	97
5.3.2. S3.2 Alternatif yöntemler bulunabilir mi?.....	97
5.4. Araştırma Hipotezi 4: Yapay zekanın görüntü işlemede kullanılması için doğruluk faktörünü belirleyen en önemli kriter kütüphane büyüklüğüdür.	97
5.4.1. S4.1 Kütüphane büyüklüğü ile doğruluk deęeri arasında nasıl bir korelasyon bulunur? 98	98
5.4.2. S4.2 Kütüphane elemanlarını belirlerken nelere dikkat edilmelidir?.....	98
KAYNAKLAR.....	100
EKLER.....	100
ÖZGEÇMİŞ.....	112

SİMGELER ve KISALTMALAR DİZİNİ

Simgeler	Açıklama
Σ_j	Nöron girdilerinin ağırlıklı toplamı
Y_k	Nöron çıktısı
W_k	Ağırlık vektörü
x	Giriş vektörü
E	Toplam karesel hata
X_i	Öznitelik vektörü
Y_i	Hedef vektör
Y_i	Çıktı
f_j	Non lineer fonksiyon
w_{ji}	Ağırlık vektörü
$w^{(HI)}$	Ağırlık katmanı (genellikle non-lineer)
$w^{(HT)}$	Ağırlık katmanı (lineer ve non-lineer)
I	Girdi katmanı
O	Çıktı katmanı
$y^{(H)}$	Gizli örüntü vektörü
$y^{(O)}$	Çıktı örüntü vektörü
f	Eşik değeri fonksiyonu
$\varphi(x)$	Relu fonksiyonu
w_i	Sigmoid ağırlık fonksiyon
x	Sigmoid giriş verisi
z	Sigmoid noktasal çarpım
$\sigma(z)$	Sigmoid fonksiyonu
$l(y)$	Menteşe kaybı
D	Eğitim seti
X_i	Girdi değeri (denetimli öğrenme)
N	Örnek sayısı
C	Sınıf sayısı
\hat{y}	f fonksiyonunu tahmini
K	Küme sayısı
z_i	Eğitim setinde gizli bir değişken
N	YSA'da gizli nöron sayısı
I	YSA'da giriş katmanındaki nöron sayısı
C	Sınıflandırmada sınıf sayısı
D	Boyun vermenin başlangıç bölgesi
e_z	Kopma uzaması (%)
σ	Gerçek gerilme (MPa)
K	Mukavemet katsayısı
ε	Gerçek uzama
n	Uzama sertleşme katsayısıdır
R^2	Lineer korelasyon kararlılık katsayısı
R -Sq(adj.)	Düzeltilmiş lineer korelasyon kararlılık katsayısı

Kısaltmalar	Açıklama
AL	Yapay Zeka
ML	Makina Öğrenmesi
MAE	Mutlak Ortalama Hata
MSE	Hata Karelerinin Ortalaması
MSLE	Ortalama Kareli Logaritmik Hata
EDK	Elektrik Direç Kaynağı
ESA	Evrışimli Sinir Ağları
YSA	Yapay Sinir Ağları
PCA	Temel Bileşen Analizi
BP	Geri Yayılım
MLP	Çok Katmanlı Algılayıcı
GD	Grandyant Azalan
UT	Ultrasonik Test
SFFL	Kesme Kırılma Oluşturma Sınırı
DFC	Sünek Kırılma Kriteri
FLC	Formlanabilme Limit Eğrisi
BP	Geliştirilmiş Geri Yayılım
sMAPE	Simetrik Ortalama Mutlak Yüzdesel Hata
SFFL	Kesme Kırılma Oluşturma Sınırı
DFC	Sünek Kırılma Kriteri
FLC	Formlanabilme Limit Eğrisi
BP	Geliştirilmiş Geri Yayılım
sMAPE	Simetrik Ortalama Mutlak Yüzdesel Hata
YAU	Yük Altında Uzama
ŞLD	Şekillendirme Limit Diyagramı
OLS	Sıradan En Küçük Kareler Yöntemi
DLİ	Doğal Dil İşleme
DP	Doğru Pozitif
YP	Yanlış pozitif
YN	Yanlış Negatif
DN	Doğru Negatif
ROC	Duyarlılık ve Seçicilik Arasındaki İlişkinin Grafıksel Gösterimi
AUC	ROC Eğrisi Altında Kalan Alan
ITAB	Isı Tesiri Altında Kalan Alan
MT	Manyetik Bağlantı
RSDD	Ray Yüzeyi Ayrık Kusurlar
CFD	Yol Çatlağı
RMSE	Kök Ortalama Kare Hatası
SVR	Destek Vektör Makinası
DT	Karar Ağacı
Knn	En Yakın Komşu Regresyonu

ŞEKİLLER DİZİNİ

	Sayfa
Şekil 2.1. Yapay zekanın kronolojik ilerlemesi.....	6
Şekil 2.2. Veri bilimi için gerekli olan diğer disiplinlerin şematik gösterimi.....	7
Şekil 2.3. Yapay zekanın teknolojiadaki kullanım alanları.....	8
Şekil 2.4. Yapay zeka, büyük veri ve veri bilimi kavramlarının şematik görünüşü.....	9
Şekil 2.5. McCulloch ve Pitts nöron yapısı.....	10
Şekil 2.6. Çok katmanlı sinir ağı yapısı.....	13
Şekil 2.7. Relu fonksiyonu.....	15
Şekil 2.8. Sigmoid fonksiyonun grafik gösterimi.....	16
Şekil 2.9. Menteşe kaybı.....	19
Şekil 2.10. Sınıflandırma örnekleri	22
Şekil 2.11. Derin öğrenme örneği.....	25
Şekil 2.12. Temsilcinin çevresi ile etkileşime girdiği pekiştirmeli öğrenme için temel ayar	27
Şekil 2.13. Makina algoritması ve derin öğrenmesinde performans-veri grafiği.....	28
Şekil 2.14. Ortalama doğruluk(kesinlik) değerinin yıllara göre ilerlemesinin grafiği....	29
Şekil 2.15. Karışıklık matrisi (Confusion matrix).....	29
Şekil 2.16. AUC eğrisi.....	30
Şekil 2.17. Tedarik edilen parçalarda yaşanan punta hatası değişimi.....	34
Şekil 2.18. Gazaltı uygunluk doğrulama kontrolü.....	39
Şekil 2.19. Tedarik edilen parçalarda yaşanan gazaltı hatası değişimi.....	41
Şekil 2.20. Tedarik edilen parçalarda karşılaşılan çatlak sayılarının değişimi.....	44
Şekil 2.21. Müşterinin bakış açısından değerlendirme (müşteri algısı değerlendirme) sonuçları.....	47
Şekil 3.1. Evrimsel sinir ağının genel mimarisi.....	50
Şekil 3.2. Veri ön-işleme ve veri çoğaltma	50
Şekil 3.3. 5x5x3 boyutta bir giriş görüntüsüne 3x3'lük filtrenin uygulandığı konvolüsyon işlemi	51
Şekil 3.4. Havuzlama katman prosesi.....	52
Şekil 3.5. Tam bağlı (fully connected) katman.....	53
Şekil 3.6. Kaynaklı numune ölçümleri(mm).....	53
Şekil 3.7. Deney tasarımı verilerinin sahada uygulaması	54
Şekil 3.8. Deney tasarımı verilerinin Minitabta analiz edilmesi.....	55
Şekil 3.9. Yapay sinir ağı (ESA) algoritması.....	57
Şekil 3.10. Punta uygunluk doğrulama kontrolleri.....	58
Şekil 3.11. Punta kaynak hataları.....	60
Şekil 3.12. Gazaltı kaynak hataları.....	62
Şekil 3.13. Gerilme-uzama grafiği.....	65
Şekil 3.14. Büyük ve küçük şekil değiştirmeler grafiği.....	67
Şekil 3.15. Görsel hataları değerlendirme alanı.....	68
Şekil 3.16. Görünürlük, boyut ve kontrast kriterleri detayı.....	68
Şekil 3.17. Algılana kalite değerlendirme bölgeleri.....	69
Şekil 4.1. Python programında regresyon sonuçlarının, döngü(epoch) değerine göre değişim grafiği.....	73
Şekil 4.2. Kayıp fonksiyonu-döngü grafiği.....	74
Şekil 4.3. <i>ytest</i> ve <i>ytahmin</i> değerlerine göre regresyon grafikleri	75
Şekil 4.4. Eğitim ve test verisi için bölünen hatalı punta parça örnekleri.....	76

Şekil 4.5. Eğitim ve test verisi için bölünen uygun punta parça örnekleri.....	76
Şekil 4.6. Eğitim ve test verisi için bölünen hatalı gazaltı parça örnekleri.....	79
Şekil 4.7. Eğitim ve test verisi için bölünen uygun gazaltı kaynaklı parça örnekleri.....	79
Şekil 4.8. Çatlak parça örnekleri.....	81
Şekil 4.9. Çatlak olmayan parçalar.....	82
Şekil 5.1. Punta çevrim oranı=2000, öğrenme oranı =0,0002 olan bir ESA modeli eğrileri	89
Şekil 5.2. Gazaltı çevrim oranı=2000, öğrenme oranı =0,0002 olan bir ESA modeli eğrileri	92
Şekil 5.3. Sac çatlak çevrim oranı=2000, öğrenme oranı =0,0002 olan bir ESA modeli eğrileri	94

ÇİZELGELER DİZİNİ

Sayfa

Çizelge 3.1. Görsel hataları puanlama kriterleri.....	69
Çizelge 4.1. 7 adet parametre ile OLS regresyon tablosu.....	71
Çizelge 4.2. Regresyon modelleri karşılaştırma -7 adet parametre ile.....	71
Çizelge 4.3. Regresyon modellerinin karşılaştırılması (5 adet parametre ile).....	72
Çizelge 4.4. Regresyon modelleri karşılaştırma -5 adet parametre ile.....	72
Çizelge 4.5. Veri dağılımı.....	75
Çizelge 4.6. Toplam veri seti dağılımı.....	76
Çizelge 4.7. Eğitim/test veri oranı- yüzde doğruluk karşılaştırması.....	77
Çizelge 4.8. Çevrim- yüzde doğruluk karşılaştırması.....	77
Çizelge 4.9. Öğrenme oranı- yüzde doğruluk oranı karşılaştırması.....	78
Çizelge 4.10. Veri dağılımı.....	78
Çizelge 4.11. Toplam veri seti dağılımı.....	79
Çizelge 4.12. Eğitim/test veri oranı- yüzde doğruluk karşılaştırması.....	80
Çizelge 4.13. Çevrim- yüzde doğruluk karşılaştırması.....	80
Çizelge 4.14. Öğrenme oranı- yüksek doğruluk oranı karşılaştırması.....	81
Çizelge 4.15. Veri dağılımı.....	82
Çizelge 4.16. Toplam veri seti dağılımı.....	82
Çizelge 4.17. Eğitim/test veri oranı- yüzde doğruluk karşılaştırması.....	83
Çizelge 4.18. Çevrim- yüzde doğruluk karşılaştırması.....	83
Çizelge 4.19. Öğrenme oranı- yüzde doğruluk oranı karşılaştırması.....	84
Çizelge 4.20. Görsel hata veri dağılımı.....	84
Çizelge 4.21. Görsel hata veri dağılımı.....	85
Çizelge 4.22. Eğitim/test veri oranı- yüzde doğruluk karşılaştırması.....	85
Çizelge 4.23. Çevrim- yüzde doğruluk karşılaştırması.....	85
Çizelge 4.24. Öğrenme oranı-yüzde doğruluk değeri karşılaştırması.....	86
Çizelge 5.1. Transfer fonksiyonların çıktı değerleri karşılaştırması.....	90
Çizelge 5.2. Transfer fonksiyonların özgüllük, kesinlik, duyarlılık, F1 skor ve AUC değerleri karşılaştırması.....	90
Çizelge 5.3. Transfer fonksiyonların çıktı değerleri karşılaştırması.....	92
Çizelge 5.4. Transfer fonksiyonların özgüllük, kesinlik, duyarlılık, F1 skor ve AUC değerleri karşılaştırması.....	92
Çizelge 5.5. Transfer fonksiyonların çıktı değerleri karşılaştırması (%100 veri ile).....	94
Çizelge 5.6. Transfer fonksiyonların özgüllük, kesinlik, duyarlılık, F1 skor ve AUC değerleri karşılaştırması.....	95
Çizelge 5.7. Transfer fonksiyonların çıktı değerleri karşılaştırması.....	96
Çizelge 5.8. Transfer fonksiyonların özgüllük, kesinlik, duyarlılık, F1 skor ve AUC değerleri karşılaştırması.....	96
Çizelge 5.9. Transfer fonksiyonların çıktı değerleri karşılaştırması (%50 veri ile).....	98

1. GİRİŞ

Günümüzde otomotiv imalat sektöründe pek çok kritik süreçler mevcuttur. Aynı zamanda, bu kritik süreçler için hatasız mükemmel sonuçlar yaratma beklentisi mevcuttur. Her geçen gün artan kalite göstergeleri iyileştirme baskısı ayrıca sektörde çalışanlar için önemli bir zorlayıcı etken olarak devam etmektedir. Bunun yanında şirketler için rekabetçi olabilme ve karlılığı direk etkilemesi nedeniyle, hataları en aza indirmek suretiyle kalitesizlik maliyetleri minimize edilmesi önem arz etmektedir. Saha mühendisleri, hataları minimize etmek ve hata tekrarının yaşanmaması amacıyla, problemin önceliğine göre optimum çözümleri bulmak ve devreye almak için çalışmalar yapmaktadır.

Her ne kadar en ideal çözümleri bulmaya çalışsalar da, sürecin doğası gereği hatanın yok edilmesi mümkün olmayan süreçler de mevcuttur. Bu süreçlerde, öncelikle operatörün her işlemde (pres, sabit punta, robot vb.) sonra gözle kontrol ederek hatayı tespit etmesi beklenmektedir. Burada hata belirlenmesi durumunda kalite duvarı uygulanarak, farklı operatörler tarafından %100 kontrol edilmesi beklenmektedir. Tüm bu çalışmalardan sonra bile hata tespit edilememekte ve sonuçta bu parçalar müşteride hata olarak ortaya çıkmaktadır. Tüm bu çalışmalar, aslında ürün üzerinde doğrudan etkisi olmayan katma değersiz işlerdir ve şirketler için ciddi maliyet oluşturmaktadır.

İlave olarak süreç parametrelerinin belirlenmesinde, genel olarak bazı parametreler sabit tutularak ve elimine edilerek birkaç ana parametre üzerinden deneme yanılma ve tecrübi değerler ile ayar işlemi yapılmaktadır. Ayrıca süreç üzerindeki değişkenlikleri absorbe etmesi amacıyla, parametreler bir üst seviyeden seçilmek suretiyle, süreç çıktısının değişkenliklerden minimum etkilenmesi hedeflenmektedir. Bu durumda, sistem fazla enerji, akı vb. kullanmaktadır ki bu da enerji maliyetlerinin gereksiz artışına neden olmaktadır.

Tez çalışmasında aşağıda verilen hipotezler ışığında sorulara çözümler bulunmuştur:

Araştırma Hipotezi 1: Otomotivde punta kaynağında, çekirdek çapının Python regresyon modelleri ve yapay sinir ağları ile tahmininde kullanılabilir.

S1.1 Regresyon ve YSA teknikleri punta çekirdek çapı tahmininde kullanılabilir mi?

S1.2 Regresyon ve YSA teknikleri sınırları yeterli midir?

Araştırma Hipotezi 2: Otomotivde görüntü işleme ile kalite kontrol süreçlerinde yapay zeka ve makine öğrenmesi teknikleri kullanılabilir.

S2.1 AI ve ML teknikleri punta kaynak, gazaltı kaynak, sac yırtık, araç görsel hatalarının tespitinde kullanılabilir mi?

S2.2 AI ve ML tekniklerinin sınırları yeterli midir?

Araştırma Hipotezi 3: Görüntü işlemede AI tekniklerinin kullanımı yeterli doğruluk değerine bizi ulaştırabilir

S3.1 Ulaşılabilecek en yüksek doğruluk değerini belirleyen faktörler nelerdir?

S3.2 Alternatif yöntemler bulunabilir mi?

Araştırma Hipotezi 4: Yapay zekanın görüntü işlemede kullanılması için doğruluk faktörünü belirleyen en önemli kriter kütüphane büyüklüğüdür.

S4.1 Kütüphane büyüklüğü ile doğruluk değeri arasında nasıl bir korelasyon bulunur?

S4.2 Kütüphane elemanlarını belirlerken nelere dikkat edilmelidir?

Çalışmanın *Kaynak Araştırması* bölümünde yapay zeka teknikleri hakkında kısa bilgiler verilmiştir. Öğrenme olayı incelenmiş ve yapay zeka alt bileşenleri detaylandırılmıştır. Punta kaynak uygulamasına etki eden parametreler incelenmiştir. Minitab programında, deney tasarımı kurulmasına ait bilgiler verilmiştir. Son olarak bu çalışmada kullanılan punta kaynak çekirdek çapı tespiti ile ilgili literatürde yapılmış çalışmalar özetlenmiştir. Punta kaynak hatalarının evrişimli sinir ağları ile tahmin edilmesi konusunda, punta kaynak hata tipleri nelerdir, bunların oluşma nedenleri ve punta kaynak hataların tespiti konusundaki literatürde yapılmış çalışmalar incelenmiştir. Gazaltı kaynak hatalarının evrişimli sinir ağları ile tespit edilmesi konusunda, gazaltı kaynak hata tipleri nelerdir, bunların sahada oluşma sebepleri nelerdir ve gazaltı kaynak hatalarının tespit edilmesi

konusundaki literatürde yapılmış çalışmalar incelenmiştir. Sac metal çatlak hatalarının evrişimli sinir ağları ile tespiti konusunda; sac metal çatlak nedir, hangi mekanik şartlarda oluşur, sahada oluşma ve tespit edilmeme nedenleri nelerdir ve sac metal çatlaklarının tespit edilmesi konusunda literatürde yapılmış çalışmalar incelenmiştir. Araç görsel hatalarının evrişimli sinir ağları ile tespit edilmesi konusunda, araç görsel hataları nedir, nasıl puanlanır, hataların tespit edilmeme nedenleri nelerdir ve araç görsel hatalarının tespit edilmesi konusunda literatürde yapılmış çalışmalar incelenmiştir.

Materyal ve Yöntem bölümünde ise öncelikle tasarlanan deneysel düzenek ve test çalışmaları ile ilgili bilgiler verilmiştir. Burada punta çekirdek çapı tahmininde, Minitab ile matematik model çıkarılmıştır. Yapay sinir ağları oluşturulmuş, ayrıca veri seti farklı regresyon modelleri ile analiz edilmiştir. Punta kaynak hatalarının evrişimli sinir ağları ile tespit edilmesinde, sahada süreci güvence garanti etmek amacıyla yapılan kontrol ele alınmıştır. Hatalı parçaları tespit edilememesi konusunda bilgiler paylaşılmış, sahada karşılaşılan punta hata tipleri sınıflandırılmıştır. Gazaltı kaynak hatalarının evrişimli sinir ağları ile tespit edilmesinde, özellikle sahada hatanın neden tespit edilemediğine ait bilgiler verilmiştir. Bu çalışma özelinde literatürde ele alınan konular ayrıntılı olarak incelenmiştir ve sahada karşılaşılan gazaltı hata tipleri tek tek sınıflandırılmıştır. Araç görsel hatalarının yapay sinir ağları ile tespitinde, ana sanayinde bu konunun nasıl ele alındığı, hangi kontrollerin yapıldığı ve puanlama sistematığı konularında da bilgiler sunulmuştur.

Bulgular ve tartışma bölümünde, tüm çalışma konularından elde edilen deneysel ve sayısal sonuçlar paylaşılmıştır. Punta çekirdek çapı tahmininde, parametrelerden matematik modele pozitif ve negatif etkileyenler belirlenmiştir. Burada tüm parametreler ve ideal parametreler ile yapılan regresyon ve yapay sinir ağlarına ait istatistiksel sonuçlar paylaşılmıştır. Ayrıca her bir regresyonun *ytest* ve *y tahmin* değerlerine göre regresyon grafikleri verilmiştir. Tüm diğer çalışma konularında, test oranı/öğrenme oranına göre doğruluk oranı, öğrenme oranına göre algoritmanın doğruluk oranı ve çevrim oranına değişimine göre de doğruluk oranı değişimleri hesaplanmıştır. Ayrıca farklı transfer

fonksiyonlarına göre de algoritmalar oluşturularak, bu veri seti çalıştırılmış ve doğruluk oranları hesaplanmıştır.

Sonuç bölümünde ise, hipotez ve sorulara ait çıktılar değerlendirilmiş ve yorumlara yer verilmiştir.

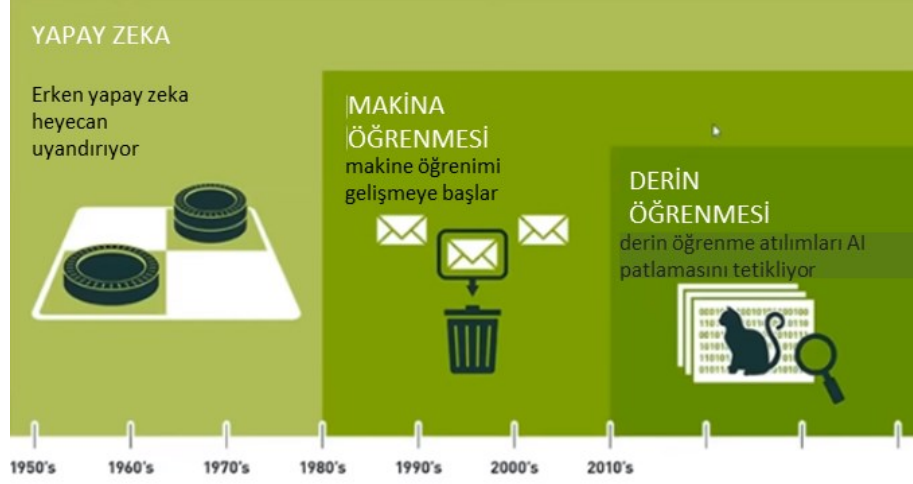
2. KAYNAK ARAŞTIRMASI

2.1. Yapay Zeka Yapısı

Yapay zeka, insan zekasına özgü olan algılama, öğrenme, kavramları bağlama, düşünme, fikir yürütme, sorun çözme, iletişim kurma, çıkarım yapma ve karar verme gibi yüksek bilişsel fonksiyonları veya otonom davranışları sergilemesi beklenen zeki etmenler/programlar yaratmak üzere yapılan tüm çalışmalarının toplandığı geniş bir alandır.

Yapay zeka beyinden ilham alır. Beynin işleyişini anlamayı amaçlayan bilişsel bilimciler ve sinir bilimciler yapay sinir ağlarının modellerini oluşturarak simülasyon çalışmaları yaparlar. Yapay zeka, bilgisayar biliminin bir parçasıdır ve amaç herhangi bir mühendislik alanında olduğu gibi, faydalı sistemler oluşturmaktır. Bilgisayarlara bir zamanlar "elektronik beyin" deniyordu, ancak bilgisayarların ve beynin çalışma prensipleri farklıdır. Bir bilgisayarın genellikle bir veya birkaç işlemcisi varken, beyin paralel olarak çalışan çok sayıda işlem birimi, yani nöronlardan oluşur. Detaylar tam olarak bilinmemekle birlikte, işlem birimlerinin bir bilgisayardaki tipik bir işlemciden çok daha basit ve daha yavaş olduğuna inanılıyor. Beyindeki nöronların on binlerce diğer nöronla sinaps adı verilen bağlantıları vardır ve hepsi paralel olarak çalışır. Bir bilgisayarda, işlemci aktiftir; bellek ayrı ve pasiftir. Ancak beyinde hem işlemenin hem de belleğin ağ üzerinde birlikte dağıtıldığına inanılmaktadır; işlem nöronlar tarafından yapılır ve hafıza nöronlar arasındaki sinapslarda oluşur.

Yapay zeka, makine öğrenmesi ve derin öğrenme (deep learning) kavramlarının kronolojik olarak ilerlemesi, Şekil 2.1'de verilen grafikte görülmektedir.




Şekil 2.1. Yapay zekanın kronolojik ilerlemesi (Anonim, 2016'dan değiştirilerek alınmıştır, <https://blogs.nvidia.com/blog/2016/07/29/whats-difference-artificial-intelligence-machine-learning-deep-learning-ai/>)

2.1.1. Öğrenme nedir?

Örneğin, bir yüz tanıyıcı için parametreler, bir kişinin bir dizi eğitim görüntüsünde en yüksek tahmin doğruluğunu elde etmemiz için ayarlanır. Bu öğrenme genellikle tekrarlayıcı ve artımlıdır. Öğrenme programı, birbiri ardına birçok örnek resim görür ve parametreler her örnekte biraz güncellenir, böylece zamanla performans kademeli olarak artar. Sonuçta öğrenme, bir görevi öğrendikçe o konuda daha iyi olma temeline dayanır.

Öğrenme, öğrenmeden farklı iş sonuçları çıkarma, bilgisayar bilimleri, istatistik, matematik ve alan/ iş bilgisi disiplinlerinde bilgi sahibi olmayı gerektirir. Bu bilime de veri bilimi denir ki günümüzde farklı kaynaklardan hızlı, kolay ve çoklu veri edilebilmesiyle önemi her geçen gün artmaktadır. Şekil 2.2'de veri biliminin temel alanları görülmektedir.



Şekil 2.2. Veri bilimi için gerekli olan diğer disiplinlerin şematik gösterimi

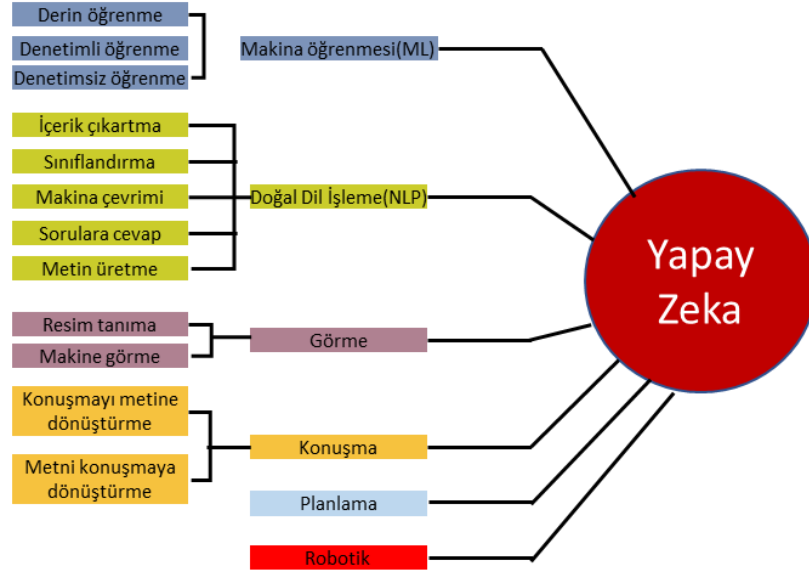
Yapay zeka, genel olarak üç temel esasa dayanır:

1. Veri
2. Programlama-hesaplatma (Computing)
3. Matematik

Yapay zeka konularında çalışabilmek için, bu üç disiplinin temel bilgilerine hakim olunması gerekir.

2.1.2. Yapay Zeka Kullanım Alanları

Günümüzde, yapay zekanın makine öğrenmesi, doğal dil işleme (NLP), uzman sistemler, görme sistemleri, konuşma, konuşma ve robotik kullanım alanları Şekil 2.3’de görülebilir.



Şekil 2.3. Yapay zekanın teknolojiadaki kullanım alanları (Villanueva ve Salenga L.M. 2018’değiştirilerek alınmıştır)

Son yıllarda, teknoloji ile ilgilenenlerin sıklıkla duyduğu kavramlar arasında büyük veri (big data) de yer almaktadır. İnternet kullanan her bireyin büyümesine ve gelişmesine katkı sağladığı büyük veri; gözlemlerden, araştırmalardan, arama motorlarından, bloglardan, forumlardan, sosyal medyadan ve diğer birçok kaynaktan elde edilen verilerin anlamlı ve işlenebilir hale getirilmiş biçimine denir. Büyük veri tamamen gerçek verilerin analizine dayandığı için maliyetleri düşürme, doğru kanallara reklam harcaması yapma, iş gücünden tasarruf sağlama ve beklentilere uygun ürün geliştirme gibi birçok farklı alanda doğru kararlar alınmasına olanak tanımaktadır. Yapay zeka, büyük veri ve veri bilimi kavramları iç içe girmiş kavramlar olarak Şekil 2.4’de görülmektedir.



Şekil 2.4. Yapay zeka, büyük veri ve veri bilimi kavramlarının şematik görünüşü (Anonim, 2020’değiştirilerek alınmıştır, <https://ai.plainenglish.io/data-science-vs-artificial-intelligence-vs-machine-learning-vs-deep-learning-50d3718d51e5>)

2.1.3. Sinir Ağları

Sinir ağları alanı, insanlığın, insan beynini anlama ve taklit etme hayranlığından, konuşma ve dil kullanımı gibi insan yeteneklerini kopyalamanın daha geniş sorunlarına, pratik ticari, bilimsel ve mühendisliğe kadar örüntü tanıma, modelleme ve tahmin disiplinleri, çeşitli kaynaklardan ortaya çıkmıştır.


Yapay sinir ağları üç ana bölümden oluşur:

1. Girdi Katmanı: Yapay sinir ağına dış dünyadan girdilerin geldiği katmandır. Bu katmanda, girdi sayısı kadar hücre bulunmaktadır ve girdiler herhangi bir işleme uğramadan gizli katmana iletilirler.
2. Gizli Katmanlar: Girdi katmanından aldığı bilgiyi işleyerek bir sonraki katmana iletir. Gizli katman sayısı ve gizli katmandaki hücre sayısı ağdan ağa değişebilir. Gizli katmanlardaki hücre sayıları, girdi ve çıktı sayılarından bağımsızdır.
3. Çıktı Katmanı: Gizli katmandan gelen bilgiyi işler ve girdi katmanına gelen girdiye uygun olarak üretilen çıktıyı dış dünyaya gönderir. Çıktı katmanındaki hücre sayısı birden büyük olabilir. Her bir çıktı hücresinin bir adet çıktısı vardır. Her bir hücre bir önceki katmandaki bütün hücrelere bağlıdır (Ünal T., 2019).

Mantıksal işleme için benzer bir model McCulloch ve Pitts (1943) tarafından, insan beynindeki nöronlarla benzerlikler taşıyan olası bir yapı olarak önerilmiştir ve modelin herhangi bir sonlu mantıksal ifade oluşturmak için kullanılabileceği gösterilmiştir. McCulloch-Pitts nöronu, Şekil 2.5’deki gibi, girdilerinin ağırlıklı toplamından ve ardından, başlangıçta bir eşik işlevi olan em aktivasyon işlevi adı verilen doğrusal olmayan bir işlevden oluşur.

$$y_k = \begin{cases} 1 & \text{eğer } \sum_j w_{kj} x_j - \mu_k \geq 0 \\ 0 & \text{aksi takdirde} \end{cases} \quad (2.1)$$

Sinir ağlarının işlevselliğinin, nöronlar arasındaki bağlantıların gücüne göre belirlendiği tespit edilmiştir. Hebb 1949’in öğrenme kuralı, ağ belirli bir girdiye istenen şekilde yanıt verirse, gelecekte benzer girdilere benzer bir yanıt verme olasılığını artırmak için ağırlıkların ayarlanması gerektiğini belirtir. Tersine, ağ bir girdiye istenmeyen şekilde yanıt verirse, ağırlıklar benzer bir yanıt olasılığını azaltmak için ayarlanmalıdır.



Şekil 2.5. McCulloch ve Pitts nöron yapısı (McCulloch ve Pitts, 1943’den değiştirilerek alınmıştır)

Örüntü tanımda, genellikle denetimli ve denetimsiz öğrenme arasında bir ayırım yapılır. İlki, eğitim verilerinin, çevredeki ölçümlerin olayın sınıfını belirten etiketlere eşlik ettiği

durumu açıklar veya daha genel olarak ölçümlere istenen bir yanıtı temsil eder. Bu, ampirik temelini oluşturanlar gibi sınıflandırma görevlerinde daha olağan bir durumdur.

Denetimsiz öğrenme, ölçümlere sınıf etiketlerinin eşlik etmediği durumu ifade eder. Ölçümdeki numunelerin yapısını modelleyebilen veya genellikle bir olasılık yoğunluk fonksiyonu açısından veya verileri küme merkezleri ve genişlikleri açısından temsil ederek uzay özniteliklerini modelleyebilen ağlar mevcuttur. Bu tür modeller, Gauss karışım modellerini ve Kohonen ağlarını içerir.

Bir model oluşturulduktan sonra, iki yoldan biri bir sınıflandırıcı olarak kullanılabilir. Birincisi, modeldeki her düğüm veya nöronun eğitim verilerindeki hangi model sınıfına en güçlü şekilde, en sık yanıt verdiğini belirlemektir. Görünmeyen veriler daha sonra her model için en güçlü aktivasyona sahip nöronun sınıf etiketine göre sınıflandırılabilir. Alternatif olarak, Kohonen ağı veya karışım modeli, bir dizi sınıf olasılığını hesaplamak için kullanılan müteakip bir ağırlık katmanı ile bir Radyal Temel Fonksiyon ağının ilk katmanı olarak kullanılabilir. Bu katmandaki ağırlıklar doğrusal bir tek seferlik öğrenme algoritması ile hesaplanır ve bu radyal temel işlemlere, denetimli öğrenme yöntemlerinin çoğu gibi doğrusal olmayan eğitim algoritmalarına göre bir hız avantajı sağlar. Bir Çapsal Tabanlı Fonksiyon (Radial Basis Function) ağının ilk katmanı, alternatif olarak, merkezleri kullanılacak eğitim veri noktalarının bir alt kümesi seçilerek başlatılabilir (Michie ve ark., 1994).

2.1.4. Tek Katmanlı ve Çok Katmanlı Sinir Ağı Modeli

Denetimli öğrenmede, bir öznitelik vektörü X_i ve bir hedef vektör Y_i içeren bir veri örneği mevcuttur. Hedef vektör Y_i ile aynı forma sahip bir çıktı y_i üretmek için X_i ' yi bir ağ ile işlenir.


Girişler ve hedefler arasındaki eşleşmeyi optimize etmek için değiştirilen ağ donanımının parametreleri, Denklem (2.1)'deki gibi tipik olarak toplam karesel hatayı en düşük düzeye indirecek biçimde belirlenir:

$$E = \frac{1}{2} \sum_i (y_i - Y_i)^2 \quad (2.1)$$

McCulloch-Pitts nöronunun aktivasyonu, Denklem (2.2)'deki gibi aşağıdaki şekilde genelleştirilebilir:

$$y_j = f_j \left(\sum_i w_{ji} X_i \right) \quad (2.2)$$

Burada aktivasyon fonksiyonu, f_j herhangi bir doğrusal olmayan fonksiyon olabilir. Düğümler, bir girdi katmanı I ve bir çıktı katmanı O olarak bölünmüştür. Eşik seviyesi veya Denklem (2.2)'in önyargısı, değeri 1'de sabit olan X vektöründeki fazladan bir bileşen varsayımıyla toplama dahil edilmiştir. Tek bir katmandaki nöron gruplarının yeteneklerini incelenebilir (Rosenblatt 1958). Bu yapı Sinir Ağı olarak adlandırılmıştır ve sınıflandırma problemleri için uygun ağırlıkları öğrenmek için Sinir Ağı Öğrenme Kuralı önerilir (Rosenblatt 1962). f bir sabit eşik fonksiyonu olduğunda yani, süreksiz bir şekilde bir alttan bir üst sınır değerine sıçradığında, Denklem (2.2) ile, öznelik uzayındaki bir hiper düzlem boyunca doğrusal olmayan bir işlevi tanımlar; bir eşik aktivasyon fonksiyonu ile nöron çıkışı, hiper düzlemin bir tarafında 1 ve diğer tarafında 0'dır. Bir algılayıcı yapısında birleştirildiğinde, nöronlar öznelik uzayını bölgelere ayırabilir ve bu, algılayıcı ağlarının sınıflandırma gerçekleştirme kapasitesinin temelini oluşturur (Şekil 2.6).



Şekil 2.6. Çok katmanlı sinir ağı yapısı (Michie ve ark. 1994'den değiştirilerek alınmıştır)

2.1.4. Çok Katmanlı Algılayıcı Yapısı ve İşlevselliği

Şekil 2.6' da, standart iki katmanlı bir algılayıcının yapısını göstermektedir. Girişler, ağı giriş giriş düğümlerini oluşturur; çıktılar çıktı düğümlerinden alınır. Orta katman ne girişler ne de çıkışlar tarafından görülebilen düğümlerin, sayısı gizli katman olarak adlandırılır ve giriş ve çıkış katmanlarının aksine, boyutu sabit değildir. Gizli katman genellikle bir darboğaz oluşturmak için kullanılır ve ağı daha önce görülmemiş kalıpları genelleştirme yeteneği ile verileri üreten sistemin basit bir modelini yapmaya zorlar.

Bu ağı işleyişi şu şekilde belirtilmiştir:

$$y_i^{(H)} = y_i^{(H)} \left(\sum_j w_{ij}^{(HI)} x_j \right) \quad (2.3)$$

$$y_i = y_i^{(T)} \left(\sum_j w_{ij}^{(TH)} y_j^{(H)} \right) \quad (2.4)$$

(2.3) ve (2.4) denklemlerinde, x girdi örüntü vektörünün, iki ağırlık katmanı $w^{(HI)}$ ve $w^{(HT)}$ tarafından parametrelendirilecek bir şekilde, gizli örüntü vektörü $y^{(H)}$ aracılığıyla çıktı örüntü vektörü $y^{(O)}$ ile nasıl eşlendiğini belirtir (Michie ve ark. 1994).

2.1.5. Aktivasyon Fonksiyonları

Aktivasyon fonksiyonları nöronların toplam fonksiyonunda üretilen çıktıların nasıl bir değişimden geçmesi gerektiğini belirler. Aktivasyon fonksiyonu olmayan bir yapay sinir ağı, verilerdeki kompleks yapıları öğrenip tespit etmekte çok zorlanacaktır, hatta çoğu zaman da yetersiz kalacaktır. Aktivasyon fonksiyonu içermeyen bir yapay sinir ağı, basit bir lineer regresyon modelinden farksız olacaktır. Bu yüzden mevcut yapay sinir ağının güçlü olması ve karmaşık verilerden isabetli sonuçlar çıkarması için bir aktivasyon fonksiyonu kullanmamız gereklidir.

Aktivasyon fonksiyonu doğrusal olmamalıdır. Doğrusal aktivasyon fonksiyonları ile oluşturulmuş yapay sinir ağları genel olarak tek katmanlı yapay sinir ağları gibi davranır. Yani karmaşık problemlerin çözümünde iyi bir performans sergilemez.

Aktivasyon fonksiyonu türevlenebilir olmalıdır. Yapay sinir ağ eğitimi minimum kayıp (Loss) değerini veren parametreler, geri yayılım algoritması (Back Propagation) ile belirlenir. Eğer türevlenebilir olmazsa, geri yayılım da olmaz, yani mükemmel modeli kuracak parametreler hiçbir zaman öğrenilemez.

Aktivasyon fonksiyonunun, alt ve üst sınırları olmalıdır. Sınırları olmayan bir aktivasyon fonksiyonunda bazı durumlarda sonuç alamama durumları ortaya çıkabilir. Monoton artan veya azalan olmalıdır. Aktivasyon fonksiyonunun monoton artan ve azalan olması, minimum ve maksimum noktasının bulunmasını garantiler. Orijin noktasında kendine yakınsamalıdır. Bir aktivasyon fonksiyonunun orijin noktasında kendine yakınsaması, rastgele ağırlık değerleriyle başlatılmış bir modelin eğitimini kolaylaştırır.

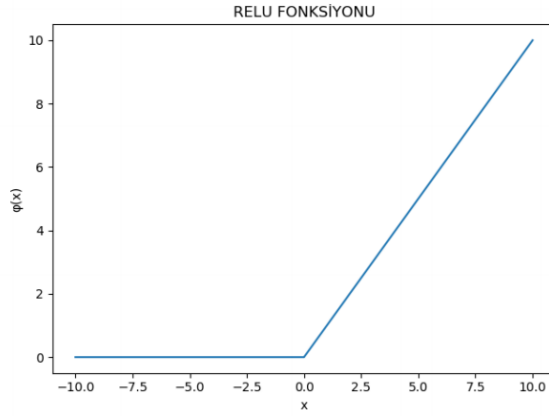
Relu (Doğrultulmuş lineer birim, rectified linear unit) fonksiyonu, sigmoid fonksiyonu, hiperbolik tanjant fonksiyonu, sızıntı (leaky) relu fonksiyonu, softmax fonksiyonu örnek birer aktivasyon fonksiyonudur. En çok kullanılanlara birer örnek aşağıda verilmiştir (Ünal T. 2019).

2.1.5.1. Doğrultulmuş Lineer Birim (Relu_Rectified Linear Unit) Aktivasyon Fonksiyonu

$$\varphi: \mathbb{R} \rightarrow [0, \infty)$$

$$x \rightarrow \varphi(x) = \begin{cases} x, & x \geq 0 \\ 0, & x < 0 \end{cases} \quad (2.5)$$

Denklem (2.5)'deki fonksiyonuna relu (rectified linear unit) aktivasyon fonksiyonu denir. Grafiği Şekil 2.7'deki gibidir. Doğrultulmuş lineer birim (Relu) doğrusal olmayan bir fonksiyondur. Relu fonksiyonu negatif girdiler için 0 değerini alırken, x pozitif girdiler için x değerini almaktadır.



Şekil 2.7. Relu fonksiyonu (Ünal T. 2019)

2.1.5.2. Sigmoid Fonksiyonu

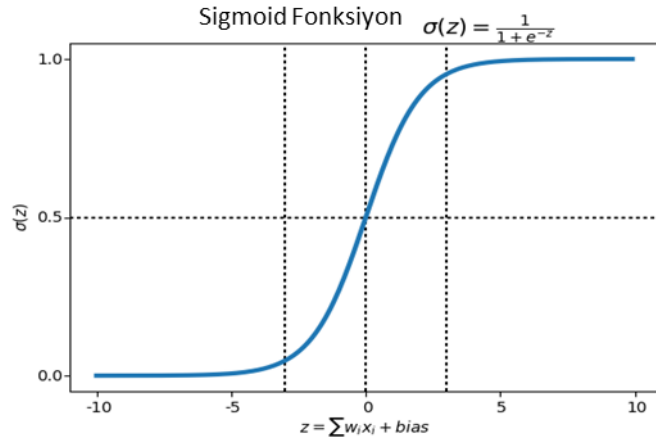
Keras, makine öğrenimi platformu TensorFlow üzerinde çalışan, Python'da yazılmış bir derin öğrenme uygulama programlama ara yüzüdür. Sigmoid, makine öğrenmesi platformu olan Keras kütüphanesinde en önemli aktivasyon fonksiyonlarından biridir.

$$z = \sum_{i=1}^m w_i + x_i + bias \quad (2.6)$$

$$\sigma(z) = \frac{1}{1+e^{-z}} \quad (2.7)$$

(2.6) ve (2.7) denklemlerinde, w ağırlık fonksiyonu, x giriş verisi, z de noktasal çarpım sonucudur ve bias gerçek değerlerden tahmin edilen değerlerin ne kadar uzak olduğudur. Burada w ağırlık fonksiyonu, x giriş verisi, z de noktasal çarpım sonucudur ve bias gerçek değerlerden tahmin edilen değerlerin ne kadar uzak olduğudur.

Sigmoid işlevi, çıktının 0 ile 1 arasında olması nedeniyle adım işlevine benzer sonuçlar üretir. Eğri, $z=0$ 'da 0,5'i geçer; bu, etkinleştirme işlevi için kurallar konulabilir. Örneğin Sigmoid nöronun çıkışı, veya 0,5'e eşit, 1 çıktı verir; çıkış Sigmoid fonksiyonunun eğrisinde bir sarsıntı yoktur. Şekil 2.8'da görüldüğü gibi, düzgündür ve eğri üzerinde her yerde farklılaşabilen çok güzel ve basit bir $\sigma(z) * (1-\sigma(z))$ türevine sahiptir.



Şekil 2.8. Sigmoid fonksiyonun grafik gösterimi (Anonim, 2017, <https://towardsdatascience.com/multi-layer-neural-networks-with-sigmoid-function-deep-learning-for-rookies-2-bf464f09eb7f>)

2.1.6. Kayıp (Loss) Fonksiyonu

Kayıp (Loss) fonksiyonu, tahmin edilen değer, gerçek değerinden ne kadar uzak olduğunu hesaplar. İdeal durum bu değeri sıfıra yaklaştırmaktır. En aza indirildiğinde,

bu maliyet fonksiyonu, kayıp fonksiyonu veya hata fonksiyonu olarak isimlendirilebilir. Ardından optimizasyon ile model kendini günceller.

Kayıp fonksiyonunun seçimi, oluşturulan YSA katmanlarındaki çıktıyı da direkt etkilemektedir. Bu sebeple tasarımın doğru yapılması gerekmektedir. Seçilecek kayıp fonksiyonunu iyi değerlendirebilmek için problemi iyi tanımak gerekmektedir.

Regresyon için kayıp fonksiyonları:

- L1 Kayıp (Loss) /Ortalama mutlak hata (MAE): Ortalama Mutlak Hata (L1 kaybı da denir), regresyon modelleri için kullanılan en basit ancak sağlam kayıp işlevlerinden biridir. n , veri kümesindeki toplam veri noktası sayısı olan bir veri noktası x_i ve onun tahmin edilen değeri y_i için, ortalama mutlak hata Denklem (2.8)'deki şu şekilde tanımlanır,

$$MAE = \frac{\sum_{i=1}^N |y_i - x_i|}{n} \quad (2.8)$$

- L2 Kayıp (Loss) / Hata karelerinin ortalaması (Mean Squared Error- MSE): Kayıp fonksiyonları söz konusu olduğunda hemen hemen her veri bilimcinin tercihidir. Bunun nedeni, çoğu değişkenin bir Gauss dağılımına modellenebilmesidir. Ortalama Kare Hatası, gerçek ve tahmin edilen değerler arasındaki kare farklarının ortalamasıdır. Bir veri noktası Y_i ve bunun tahmin edilen değeri \hat{Y}_i için, burada n , veri kümesindeki toplam veri noktası sayısıdır, ortalama hata karesi Denklem (2.9)'deki şekilde tanımlanır:

$$MSE = \frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 \quad (2.9)$$

- Kök Ortalama Kare Hata (Root Mean Square Error): Bir makine öğrenmesi modelinin, Denklem (2.10)'da tahminleyicinin tahmin ettiği değerler ile gerçek

değerleri arasındaki uzaklığın bulunmasında sıklıkla kullanılan, hatanın büyüklüğünü ölçen kuadratik bir metriktir. RMSE tahmin hatalarının (kalıntıların) standart sapmasıdır. Kalıntılar, regresyon hattının veri noktalarından ne kadar uzakta olduğunun bir ölçüsüdür; RMSE ise bu kalıntıların ne kadar yayıldığına bir ölçüsüdür. Başka bir deyişle, verilere en iyi uyan çizgi etrafında o verilerin ne kadar yoğun olduğunu söyler. RMSE değeri 0'dan ∞ 'a kadar değişebilir. Negatif yönelimli puanlar yani daha düşük değerlere sahip tahminleyiciler, daha iyi performans gösterir. RMSE değerinin sıfır olması modelin hiç hata yapmadığı anlamına gelir. RMSE, büyük hataları daha fazla cezalandırmanın avantajına sahiptir, bu yüzden bazı durumlara daha uygun olabilir. RMSE, birçok matematiksel hesaplamada istenmeyen mutlak değer kullanılmamasını engeller (Anonim, 2017, <https://veribilimcisi.com/2017/07/14/mse-rmse-mae-mape-metrikleri-nedir/>)

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}} \quad (2.10)$$


Sınıflandırma için kayıp (loss) fonksiyonları:

- Kategorik çapraz entropi kaybı (Categorical cross entropy loss) : Kategorik çapraz entropi kaybı işlevi, Denklem (2.11)'de toplamı hesaplayarak bir örneğin kaybını hesaplar. Burada \hat{y}_i , model çıktısındaki i-inci dereceden skaler değeri, y_i karşılık gelen hedef değer, ve çıktı boyutu, model çıktısındaki skaler değerlerin sayısıdır.

$$Kayıp = - \sum_{i=1}^{boyutu} y_i \cdot \log \hat{y}_i \quad (2.11)$$

- Mentşe kaybı (Hinge Loss): Mentşe kaybı/hatası işlevi, sinir ağları bağlamında kullanılabilmesine rağmen, destek vektör makineleri bağlamında ikili sınıflandırma için kullanılan tipik kayıp işlevidir (ancak çok sınıflı

sınıflandırmaya da genişletilebilir). Şekil 2.9'da X eksenini, herhangi bir tek örneğin sınırına olan mesafeyi temsil eder ve y eksenini, mesafesine bağlı olarak fonksiyonun maruz kalacağı kayıp boyutunu veya cezayı temsil eder.



Şekil 2.9. Mentese kaybı (Anonim, 2020'den değiştirilerek alınmıştır, <https://ichi.pro/tr/destek-vektor-makineleri-icin-mentese-kaybina-dair-kesin-bir-aciklama-188487008614641>)

$$l(y) = \max(0, 1 - t \cdot y) \quad (2.12)$$

Denklem (2.12)'de, $t = \{-1, 1\}$ etikettir (bu nedenle, etiketler $\{0, 1\}$ kümesindeyse, önce onları $\{-1, 1\}$ ile eşleştirmek gerekir. y , sınıflandırıcının çıktısıdır (örneğin, w ve b 'nin hiper düzlemin parametresi olduğu doğrusal destek vektör makinası (SVM) bağlamında, $y = w \cdot x + b$)

2.1.7. Makine Öğrenmesi

Makine öğrenmesi esas olarak 1959 yılında, bilgisayar biliminin yapay zekada sayısal öğrenme ve model tanıma çalışmalarından geliştirilmiş bir alt dalıdır. Makine öğrenmesi, yapısal işlev olarak öğrenilen ve veriler üzerinden tahmin yapabilen algoritmaların çalışma ve oluşturulmasını araştıran bir sistemdir. Bu tür algoritmalar statik program talimatlarını harfiyen takip etmek yerine örnek girişlerden veri tabanlı tahminleri ve kararları gerçekleştirebilmek amacıyla bir model inşa ederek çalışırlar.

Özellikle, makine öğrenimini, verilerdeki kalıpları otomatik olarak algılayabilen ve daha sonra ortaya çıkarılan kalıpları gelecekteki verileri tahmin etmek veya belirsizlik altında diğer karar verme türlerini gerçekleştirmek için, daha fazla verinin nasıl toplanacağını planlama gibi) kullanan bir dizi yöntem olarak tanımlanır (Murphy 2012).

Makine öğrenimi genellikle 3 ana türe ayrılır:

2.1.7.1. Denetimli Öğrenme

Denetimli öğrenmede, veri kümesinin ne olduğu ve bu verilerden istediğimiz çıktının ne olması gerektiği öngörülebilir. Denetimli öğrenme, verileri ve o verilerden çıkan sonuçları makineye tekrar baştan vererek bu bilgilerden bir fonksiyon (giriş verileri ile sonuç verileri arasında bir eşleşme) çıkartılmasının sağlamaktadır. Böylece makine veriler arasındaki ilişkiyi öğrenmektedir.

Denetimli öğrenme problemleri “regresyon” ve “sınıflandırma” olarak ikiye ayrılır. Bir regresyon probleminde, sonuçları sürekli bir çıktı içinde tahmin etmeye çalışılır.

Bir sınıflandırma probleminde, girdi değişkenleri ayrı kategorilere atanır. Sonuç ayrı ayrı çıktılarda tahmin etmeye çalışılır.

Denetimli öğrenme; sisteme eğitim veri seti ve test veri setinin yüklenmesi, veri setinde her bir veri için gerekli etiketlenmenin yapılması ve bu sayede girdi veri seti ile çıktı veri seti arasında ilişki kurulması mantığına dayanır. Temel amaç sonuçları bilinen veri setinden yapılan sınıflandırmadan hareketle sonuçları bilinmeyen veri setine dair etkili tahminler yapabilmektir.

Denetimli öğrenme problemlerinde, ilgili doğru etiketlere sahip eğitim örneklerini içeren bir veri seti ile başlanır. Örneğin, el yazısıyla yazılmış rakamları sınıflandırmayı öğrenirken, denetlenen bir öğrenme algoritması, her resmin temsil ettiği doğru sayıyı

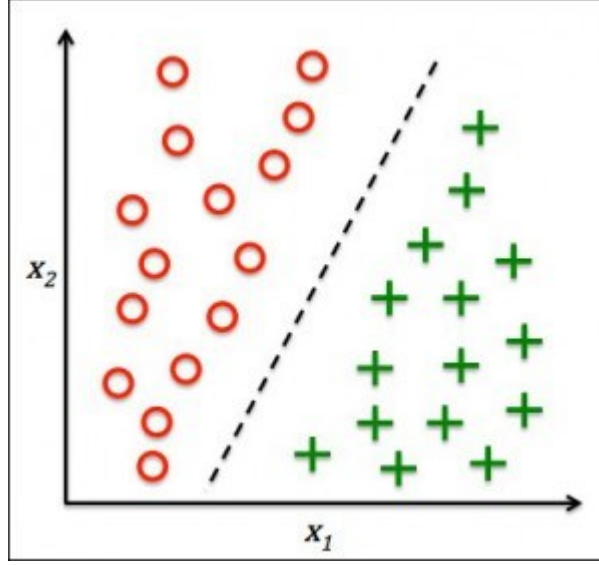
içeren etiketlerle birlikte, el yazısı rakamların binlerce resmini çeker. Algoritma daha sonra görüntüler ile ilişkili sayılar arasındaki ilişkiyi öğrenecek ve makinenin daha önce görmediği tamamen yeni görüntüleri (etiketsiz) sınıflandırmak için öğrenilen ilişkiyi uygulayacaktır.

Denetimli öğrenmede, makine, bir öğrenme algoritması aracılığıyla etiketli eğitim verilerini çalıştırarak, gelir ve eğitim arasındaki ilişkiyi sıfırdan öğrenmeye çalışır. Bu öğrenilmiş fonksiyon, Y olarak bilinmeyen insanların gelirlerini tahmin etmek için kullanılabilir. Başka bir deyişle, oluşturulmuş model Y'yi tahmin etmek için etiketlenmemiş test verilerine uygulanabilir.

Denetimli öğrenmenin amacı, Y'nin bilindiği ve Y'nin bilinmediği yeni örnekler verildiğinde Y'yi mümkün olduğunca doğru bir şekilde tahmin etmektir. (Anonim, 2017, <https://veribilimcisi.com/2017/07/12/denetimli-ogrenme>).

2.1.7.1.1. Sınıflandırma

Verilerin algoritmalar sayesinde sınıflandırması veya kategorilere ayrılması işlemine denir. Makine öğreniminde sınıflandırma, öğeleri önceden kategorize edilmiş bir eğitim veri kümesine göre kategorilere ayırma sürecidir. Şekil 2.10'da gösterildiği gibi, verilerin birbirine yakın özellikte olanları, farklı matematik algoritmalar kullanılarak, belirli alanlarda kümelenmeye çalışılır. Sınıflandırma, denetimli bir öğrenme algoritması olarak kabul edilir. Sınıflandırma algoritmaları, yeni bir öğenin tanımlanan kategorilerden birine girme olasılığını hesaplamak için eğitim verilerinin kategorizasyonunu kullanır.



Şekil 2.10. Sınıflandırma örnekleri (Anonim, 2018, <https://yavuz.github.io/denetimli-ogrenme/>)

Sınıflandırma örnekleri olarak aşağıdaki örnekler verilebilir:

- Elma, portakalları rengi ve büyüklüğüne göre ayırt edilmesi
- Sıcaklık, nem, rüzgârı değerleri verilerek havanın güneşli, yağmurlu vs. tahmin edilmesi
- Bir mailin spam veya spam olmadığını çözümlmek

Bu sınıflandırmalar aşağıda bazıları verilen sınıflandırma algoritmaları kullanılır:

- Naif Bayes Sınıflandırılması (Naive Bayes Classifier)
- Karar Ağacı Sınıflandırılması (Decision Tree Classifier)
- KNN / K - En Yakın Komşu (K-nearest neighborhood)
- Destekçi Vektör Makinesi (Support Vector Machine)

(Anonim, 2018, <https://yavuz.github.io/denetimli-ogrenme/>)

2.1.7.1.2. Regresyon

Regresyon, sürekli bir hedef değişkeni (Y) öngörür. Bu, girdi verileri X'e dayanarak, konut fiyatları veya insan ömrü gibi bir değeri tahmin etmeyi sağlar.

Burada, hedef değişken, tahmin etmedilmesi beklenen bilinmeyen değişken anlamına gelir ve sürekli araçlar, Y'nin alabileceği değerlerde boşluklar (süresizlikler) değildir. Bir kişinin ağırlığı ve yüksekliği sürekli değerlerdir. Öte yandan, kesikli değişkenler sadece sınırlı sayıda değer alabilirler. Örneğin, birisinin sahip olduğu çocuk sayısı kesikli bir değişkendir.

Gelir tahmini, klasik bir regresyon problemidir. Girdi verileri X, veri setindeki bireyler hakkında, eğitim yıllarını, çalışma yıllarını, iş unvanını veya posta kodu gibi, geliri tahmin etmek için kullanılacak tüm ilgili bilgileri içerir. Bu nitelikler, sayısal (örnek olarak iş tecrübesi) veya kategorik (örneğin, iş unvanı veya çalışma alanı) olabilen özellikler olarak adlandırılır.

Bu özellikleri mümkün olduğunca hedef çıktıya Y ile ilişkilendiren birçok eğitim gözlemi istenir, böylece oluşturulmuş model X ve Y arasındaki ilişkiyi öğrenebilir.

Veriler bir eğitim veri seti ve bir test veri seti olarak ayrılmıştır. Eğitim seti etiketlere sahiptir, bu nedenle modeliniz bu etiketli örneklerden öğrenebilir. Test kümesinde etiket yok, yani henüz tahmin etmeye çalışılan değer henüz bilinmiyor. Modelin, test verilerinde iyi performans gösterebilmesi için daha önce karşılaşılmadığı durumlara genelleştirilebilmesi önemlidir (Anonim, 2018, <https://devhunteryz.wordpress.com/2018/03/18/denetimli-ogrenme-yontemleri-bolum-1/>).

2.1.7.2. Denetimsiz Öğrenme

Denetimsiz öğrenme, verilerimizden elde etmek istenilen çıktının nasıl görüldüğü hakkında çok az ya da hiç fikir sahibi olmadığımızda kullanılan yaklaşımdır. Burada veri kümesinde toplanan verilerin etiketi yoktur. Değişkenlerin etkisini bilinmeyen veriden model oluşturulabilir.

Veriyi değişkenler arasındaki ilişkilere dayalı olarak kümeleyerek çeşitli modeller, yapılar oluşturabiliriz. Algoritma öğrendiğinde müdahale edilmemektedir.

Elde edilen bu modeller, öğeleri kategorize edilmesi veya aralarında bir ilişkinin bulunması gerektiğinde faydalıdır. Ayrıca, verilerdeki anormalliklerin ve kusurların tespit edilmesine de yardımcı olabilirler.

Veri kümesi etiketlenmediğinden, verilerin sıralanma yöntemini elde etmenin bir yolu yoktur. Giriş verileri bilinmediğinden ve makineyi yapan insanlar tarafından etiketlendiğinden daha az doğru olabilirler. Algoritma tarafından elde edilen bilgiler her zaman istenilen çıktı sınıfına karşılık gelmeyebilir. Kullanıcı, elde edilen çıktıyı ilgili etiketlerle anlamalı ve eşlemelidir (Anonim, 2019, <https://ichi.pro/tr/denetimsiz-ogrenme-nedir-ve-nasil-calisir-71091020868708>).

2.1.7.3. Derin Öğrenme

Makine öğrenme sistemleri, genel olarak, tek katmandan oluşan veriyi işleyerek öğrenirken, derin öğrenme sistemi, çok geniş veri setleri ve çoklu katmanları kullanarak, analiz ederek öğrenir. Derin Öğrenmede, makine, büyük miktarda veriyi farklı katmanlarda işleyerek, nasıl öğreneceğini de kendisi öğrenmektedir.

Normal makine öğrenimi uygulaması yapılırken modele yüklenen veri, o verinin bakılması istenen özellikleriyle beraber verilir. Model de hangi özelliğin sonuca ne kadar

etki ettiğini öğrenerek, bir fonksiyon üretir. Derin öğrenmede özellikler kullanıcı tarafımızdan belirlenmez; model hangi özelliklere bakacağına kendi karar verir ve daha sonra da hangi veriye fonksiyonda ne kadar ağırlık vereceğini bulur.

Bu öğrenmenin gerçekleşmesi için, büyük verileri işleyebilecek güçlü bilgisayar donanımlara ihtiyaç vardır. Önceden makine öğreniminde, CPU (Merkezi İşlem Ünitesi) ile yapılan veri analizleri artık çok daha hızlı olan GPU (Grafik İşleme Ünitesi) ile onlarca hatta yüzlerce kat daha hızlı ve güvenli bir şekilde yapılmaktadır.

Derin öğrenmenin en önemli ayrıntısı, bir verinin gösterimindeki farklı katmanları kullanmasıdır. Bu farklı katmanlardaki verilerin hepsi önceden eğitilmiştir (Şekil 2.11). Klasik makine öğrenimine göre daha başarılı sonuçlar vermektedir.



Şekil 2.11. Derin öğrenme örneği (Anonim, 2020, <https://t24.com.tr/yazarlar/hayri-cem-haftalik/derin-ogrenme-nedir,29220>)

- Giriş Katmanı: Bir görüntünün pikselleri incelenerek, resimde köpek, sopa ve doğa olduğu algılanır.
- Ara (Gizli) Katman: Genellikle yapay sinir ağı eğitilirken, etiketlerin/bilgilerin kullanımına değişik ağırlıklar verilir ve bunlar "Öğrenilen Ağırlıklar" olarak bilinir. Bu katmanda, bu veriler arasındaki ilişki, daha önceki girdiler yardımıyla analiz edilir.
- Çıktı Katmanı: Son katman, size, ağınıza girdiğiniz verilerin bir tahminini verir. Örneğimizdeki tahmini çıktı; "Doğada sopayla oyun oynayan köpekler" olarak

verilir (Anonim, 2020, <https://t24.com.tr/yazarlar/hayri-cem-haftalik/derin-ogrenme-nedir,29220>).

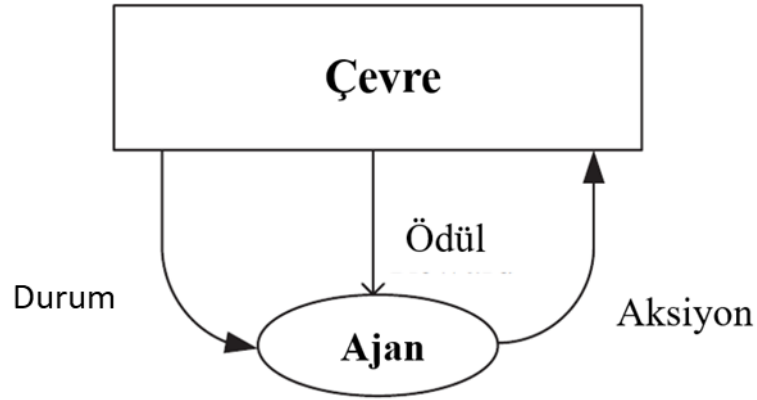
2.1.7.4. Pekiştirmeli Öğrenme

Pekiştirmeli öğrenme olarak bilinen ve biraz daha az kullanılan üçüncü bir makine öğrenimi türü vardır. Bu, ara sıra ödül veya ceza işaretleri verildiğinde, nasıl davranacağını veya davranmayacağını öğrenmek için kullanışlıdır.

Satranç oynamayı öğrenen bir makine yapılmak istenildiği varsayalım. Tahtadaki taşların, oyuncularını görmek için bir kamera olduğunu varsayın ve hedef olarak oyunu kazanmak için hamlelere karar vermek seçilebilir.

Bu durumda, iki nedenden ötürü denetimli bir öğrenici kullanılmaz. Birincisi, kullanıcıyı pek çok oyuna götürecek ve her tahta durumu için en iyi hareketi gösterecek bir öğreticiye sahip olmak çok maliyetlidir. İkincisi, çoğu durumda en iyi hamle diye bir şey yoktur. Bir hareketin ne kadar iyi olduğu, takip eden hamlelere bağlıdır. Tek gerçek geri bildirim, oyunun sonunda oyunu kazanıldığında ve kaybedildiğinde olur.

Bir ortama yerleştirilen, aracı olarak adlandırılan bir karar verici vardır (Şekil 2.12). Satranç tahtası, oyun oynayan temsilcinin ortamıdır; herhangi bir zamanda, ortam belirli bir durumdadır, yani sırasıyla tahtadaki taşların konumu anlamına gelir. Karar vericinin olası bir dizi eylemi vardır: Satranç tahtası üzerindeki taşların kurallara uygun hareketi. Bir eylem seçilip uygulandığında durum değişir.




Şekil 2.12. Temsilcinin çevresi ile etkileşime girdiği pekiştirmeli öğrenme için temel ayar (Alpaydın E. 2016'dan değiştirilerek alınmıştır)

Ortamın herhangi bir durumunda, aracı bir eylemde bulunur ve eylem, durumu değiştirir ve bir ödül verebilir veya vermeyebilir. Görevin çözümü bir dizi eylemi gerektirir ve ödül şeklinde geri bildirim alınır. Öğrenmeyi zorlaştıran şey, ödülün nadiren gelmesidir ve genellikle sadece tüm sıralama tamamlandıktan sonra uzun bir hamle dizisinin ardından oyunu kazanılır veya kaybedilir. Ödül, görevin amacını tanımlar ve öğrenmek isteniyorsa gereklidir. Temsilci, görevi çözmek için en iyi eylem sırasını öğrenir; burada "en iyi", maksimum ödülü mümkün olan en kısa sürede döndüren eylemler dizisi olarak değerlendirilir. Bu, pekiştirme öğreniminin ortamıdır.

Pekiştirmeli öğrenme, birkaç açıdan diğer öğrenme yöntemlerinden farklıdır. Denetimli öğrenmede sahip olunan bir öğretici ile öğrenmenin aksine, buna "eleştirmenle öğrenme" denir. Eleştirmen, ne yapacağımızı değil, geçmişte ne kadar iyi yapıldığını söylemesi bakımından öğretmenden farklıdır. Eleştirmen asla önceden haber vermez. Eleştirmenden gelen geri bildirim azdır ve geldiğinde geç gelir. Birkaç eylem yaptıktan ve ödülü aldıktan sonra, geçmişte yapılan bireysel eylemleri değerlendirmek ve ödülü kazanılmasına neden olan hamleleri bulmak isteniyorsa, böylece onları daha sonra kaybedebilir ve hatırlanabilir.

Makina algoritmalarında, veri sayı artmasıyla başlangıçta performans artar. Fakat belirli bir seviyeden sonra, veri büyüklüğü artmasına karşın, ezberleme durumu vb. kritikler


nedeniyle performansta deęişiklik olmamaktadır. Derin öğrenmede ise veri miktarı artışı ile performans da artmaya devam etmektedir (Şekil 2.13).



Şekil 2.13. Makina algoritması ve derin öğrenmesinde performans-veri grafięi (Kraus ve ark. 2020’den deęiştirilerek alınmıştır)

Nesne algılamada, makina öğrenmesinin etkisinin zamanla deęişim aşıęıdaki grafikte görülmektedir. Özellikle 2013’den sonra derin öğrenme ile ek potansiyel iyileşme deęerleri görülmüş ve %90’nın üzerinde kesinlik deęerleri görülmektedir (Şekil 2.14).

Nesne Tesbit Etme: Derin Öğrenmenin Etkisi



Şekil 2.14. Ortalama doğruluk(kesinlik) deęerinin yıllara göre ilerlemesinin grafięi (Anonim, 2020’den deęiştirilerek alınmıştır, <https://towardsdatascience.com/how-does-ai-detect-objects-technical-d8d63fc12881>)

2.2. Performans Ölçütleri

Makine öğrenmesinde kullanılan sınıflandırma modellerinin performansını değerlendirmek için hedef niteliğe ait tahminlerin ve gerçek değerlerin karşılaştırıldığı hata matrisi sıklıkla kullanılmaktadır (Şekil 2.15).

		GERÇEK DURUM	
		POZİTİF	POZİTİF
TAHMİN	POZİTİF	DP	YP (Tip 1 Hata)
	NEGATİF	YN (Tip 2 Hata)	DN

Şekil 2.15. Karışıklık matrisi (Confusion matrix)

Bu çalışmada başarımlar ölçütleri olarak doğruluk, duyarlılık, özgüllük, kesinlik, F1-skor ve yanlış pozitif oranları kullanılmıştır. Bu performans ölçütleri ile ilgili matematiksel ifadeler, Denklem (2.14-19)' da aşağıda verilmiştir.

$$\text{Doğruluk} = \frac{DP+DN}{DP+DN+YP+YN} \quad (2.14)$$

$$\text{Özgüllük} = \frac{DN}{DN+YP} \quad (2.15)$$

$$\text{Kesinlik} = \frac{DP}{DP+YP} \quad (2.16)$$

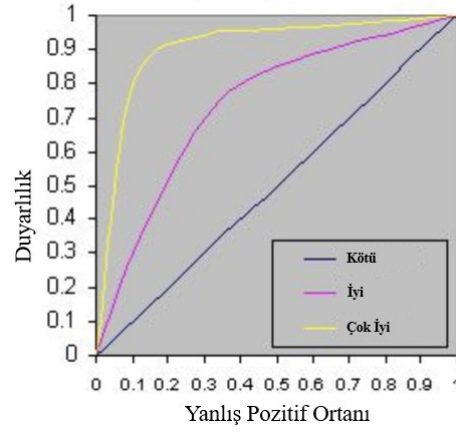
$$\text{Duyarlılık} = \frac{DP}{DP+YN} \quad (2.17)$$

$$\text{F1 Skor} = 2 * \frac{\text{Duyarlılık} * \text{Kesinlik}}{\text{Duyarlılık} + \text{Kesinlik}} \quad (2.18)$$

$$\text{Yanlış Pozitif Oranı} = \frac{YP}{YP+DN} \quad (2.19)$$

ROC eğrisi duyarlılık ve seçicilik arasındaki ilişkinin grafiksel bir gösterimidir. Eğriler yardımı ile bir tanı testi için en iyi eşik değeri saptanarak en uygun modele karar verilebilir. Ayrıca farklı tanı testlerinin doğru klinik tanı koymadaki başarısının karşılaştırılmasına olanak sağlarlar. ROC analizi; karar sürecinin uzun zaman alacağı,

maliyetin yüksek, özel yöntem-ekipman ve nitelikli insan gücüne gereksinim duyulacağı durumlarda; kısa zamanda, düşük maliyetle, kolay elde edilebilen belirteçler için uygun kesim noktalarını belirleyerek karar verme sürecine önemli katkı sağlayacak bir analiz yöntemidir. ROC bir olasılık eğrisidir ve altında kalan alan olan AUC (Eğri altında kalan alan) ayrılabilirliğinin derecesini veya ölçüsünü temsil eder. ROC eğrisinde X ekseninde Yanlış Pozitif Oran ve Y ekseninde ise Duyarlılık bulunmaktadır (Şekil 2.16).



Şekil 2.16. AUC eğrisi (Anonim, 2020'den değiştirilerek alınmıştır, <https://medium.com/@gulcanogundur/do%C4%9Fruluk-accuracy-kesinlik-precision-duyarl%C4%B1l%C4%B1k-recall-ya-da-f1-score>)

Eğrinin altında kalan arttıkça sınıflar arasında ayırt etme performansı artmaktadır. AUC Modelin sınıfları ne kadar başarılı ayırt edebildiğini anlatır. AUC arttıkça, model 0'ları 0 ve 1'leri 1 olarak tahmin etmede daha iyidir. Örneğin hasta olan ve olmayan kullanıcıların olduğu bir veri setinde AUC ne kadar yüksekse, model hastalığı olan ve olmayan hastaları ayırt etmekte daha iyi performans gösterir.

2.3. Punta Kaynağında, Çekirdek Çapının Python Regresyon Modelleri ve Yapay Sinir Ağları ile Tahmini

Günümüzde bir otomobil üretilirken, 7.000-12.000 adet punta kaynağı kullanılmaktadır. Elektrik direç kaynağı (EDK) genel olarak bilgisayar kontrollü robotlar ile yapılmaktadır. EDK'nın kalitesi, otomotiv endüstrisinde son derece önemli bir konudur. Manuel kaynak

parametreleri hesaplamaları, operatör tecrübeleri ve teknisyen uzmanlığı ile yapılan parametre ayarlarının doğruluğu ve tutarlığı uygun olmayabilmektedir. Her bir makinenin ve noktanın kaynak parametre ayarı, pek çok hassas faktör olması nedeniyle zor bir işlemdir. Punta kaynağı yapılacak her noktanın optimum değerini bulmak için çok sayıda malzeme ile çok sayıda deneme yapılması gerekir ki bu da çok maliyetli olduğundan yapılamaz. Bu nedenle, EDK punta kaynak sürecinde, kaynak kalite iyileştirme gereksinimlerini, verim tahmini ve uygun parametre optimizasyonu ile sağlayabilmek önemlidir.

Genel olarak literatür incelendiğinde, sadece kaynak zamanı, akım ve kuvvet alınarak, tek bir sac kalınlığı üzerinde çalışmalar yapılmıştır (Pereda ve ark. 2015, Sheikhi ve ark. 2017, Duric ve ark. 2019, Aslanlar ve ark. 2008, Hayat 2011, Kim ve ark. 2005).

Modelin elde edilmesinin ardından, Python programında, regresyon algoritmaları ve yapay sinir ağları çıkartılır. Deneylerden elde edilen veriler burada eğitim ve test verileri olarak bölünmüş ve veriler normalize edilerek ön işleme yapılmıştır. Sonrasında deneysel verilerden yola çıkılarak, regresyon ve yapay sinir ağlarında, punta çekirdek çaplarının tahmin edilmesi sağlanmıştır (Pashazadeh ve ark. 2016, Brown ve ark. 1998, Sambath ve ark. 2011, Boersch ve ark. 2018, Thongchai ve ark. 2014, Sun ve ark. 2017, Mani ve Omkar 2002, Kim ve Ahmet 2018, Hiba ve ark. 2019, Wan ve ark. 2017, Eşme ve ark. 2007, Satonaka ve ark. 2004). Bu elde edilen veriler aynı zamanda, Minitab yazılımına aktarılarak regresyon grafikleri ve matematik modelleri çıkarılmış, R^2 ve R^2_{adj} değerleri hesaplanarak sistemin doğruluğu araştırılmıştır.

2.4. Punta Kaynak Hatalarının Evrişimli Yapay Sinir Ağları (ESA) ile Tespit Edilmesi

EDK'nın kalitesi, otomotiv endüstrisinde son derece önemli bir konudur. Punta kaynağının avantajları; nispeten temiz ve çevreci bir proses, otomasyona uygun ve kolay uygulanabilir bir yöntem olması, dolgu metaline ihtiyacın olmaması, kazalara ve

yaralanmalara neden olabilecek açık alevin bulunmaması ve kaynak işleminin uzman operatör gerektirmemesi şeklinde sıralanabilir.

Genel olarak otomotiv sektöründe vardiya başında, puntalar için tahribatlı kontrol, ultrasonik kontrol ve yarı tahribatlı kontrol ile onay verilerek, vardiya üretimine başlanmaktadır.

Vardiya içerisinde meydana gelen değişkenlikler nedeniyle punta hataları meydana gelebilmektedir. Bu değişkenlikleri aşağıdaki şekilde sıralamak mümkündür:

- Proje hataları (punta yerlerinin hatalı seçilmesi (birbirine yakın punta, kenara yakın punta), elektrotun ulaşamayacağı/şase yapacağı kritik yere punta noktaları verilmesi, radyus üzerine punta verilmesi, referans bölgesine punta verilmesi, çok esnek parçalara çok sık aralıkla punta verilmesi (taban sacları gibi vb.)
- Robot ekipman sistemi (yetersiz ve eksik bakım, penselerin kuvvetlerinin yetersiz olması, robot elektrot sıfırlamasının hatalı olması nedeniyle elektrotta oluşan delta kuvvetler, penselerin şase yapması, şönt devrelerinde meydana gelen elektrik kaybı, robot eksenlerinin hatalı olması vb.)
- Malzeme hataları (malzemeleri toz, paslı ve yağlı olarak kullanılarak punta yapılması, parçalar arası boşluk değerinin uygun olmaması, parçalarda deformasyon olması, parçalarda ölçüsel sapma olması, parçalarda kesme çapakları bulunması vb.)
- Elektrot hataları (elektrotların 90° basmaması, hatalı elektrot seçilmesi, hatalı ve eksik frezeleme, elektrotların değişim frekansının hatalı seçilmesi, elektrot değişim zamanında değişim yapılmaması, elektrot değişiminin uygun ekipman ile yapılmaması nedeniyle elektrot tutucu hatası, elektrot frezeleme tertibatı hataları, soğutma suyu borusu ve elektrotta hasar oluşması vb.)
- Aparat hataları (aparatin tasarımının hatalı olması, referansların hatalı ve eksik seçilmesi, pnömatik hatalar nedeniyle parçanın stabilitesinin sağlanamaması, parçanın hatalı konumlanabilmesi, aparat üzerinde parça algılayıcı sensör

eksiklikleri, aparat bakımları sonrası aparat ve proses onayının tekrarlanmaması vb).


Proses hataları (her punta noktası için ayrı program yapılmaması, punta parametrelerinin hatalı seçilmesi, parça akışının hatalı olması, ok ve nok parçaların karışması için poka yoke olmaması, aynı hatta farklı versiyonlu parça üretimde tip yönetiminin uygun planlanmaması, robot hataya geçtiğinde reset butonunun herkese açık olması/şifre olmaması, seri imalatta arıza bir hata çıktığında(robot, aparat, elektrik kesilmesi, tekil sac parça hatası tespiti, frekansiyel tahribatlı/ultrason kontrollerinde herhangi bir hata tespitinde tüm lotun karantinaya alınması ve %100 tarama ile kontrolünün sağlanmaması, punta parametrelerinin hatalı seçilmesi, parametrede optimizasyon çalışması yapılırken tüm sürecin takibinin eksik yapılması ve parçaların karantinaya alınmaması, puntalama sıralamasının hatalı seçilmesi vb.)

İnsan hataları (operasyon detay bilgisini verilmeden işe başlatılması, gereksiz yere inisiyatif kullanarak hataya neden olunması, uygun olmayan parçaların ıskarta kasasına konulmayıp kenarda bırakılması, robot/ aparat arıza ve eksiklikleri amirine bildirilmeyip sürece devam edilmesi, ultrason ölçümlerinde eğitim eksiklikleri, operatörün punta ultrason kontrolünde veya tam tahribatlı kontrolde eksik yorum yapması ve üretim durdurulması gereken yerde ilk amirine bilgi vermemesi vb.)

Burada onay verildikten sonra, operatörden her bir parça üzerinde yukarıda belirtilen bir veya farklı kök neden ile meydana gelebilen punta hatalarını, %100 göz kontrolü ile kontrol edip hata kaçırmaması beklenmektedir. Bu durum operatörün hata kaçırmaması, farklı nedenler nedeniyle gelebilir:

- Operatörün hata modları konusunda eğitim verilmemesi, eğitim eksikliği
- Operatörün ergonomik nedenlerle sürekli aynı parçaya bakması nedeniyle işletme körlüğü oluşması
- Operatöre %100 göz kontrolü için yeteri kadar operasyon süresi verilmemesi

- Operatörün gereksiz inisiyatif kullanması
- Operatörün hatalı parçayı hemen ıskarta kasasına atmaması nedeniyle, hatalı parçanın bir şekilde sevk kasasına karışması vb.



Şekil 2.17. Tedarik edilen parçalarda yaşanan punta hatası değişimi (FCA Tofaş uygulamadan alınmıştır)

Şekil 2.17’de görülen hata miktarları tedarikçiden ana sanayiye sevk edilen adetler olup, firmanın kendi içerisinde tespit edilen iç ıskarta ve parça taramalarda çıkan adetler bunlara dahil değildir. Bu değerlerin, çok daha fazla olacağı tecrübi olarak açıktır. Punta hata tespiti ve yakalanması ile ilgili farklı çalışmalar yapılmıştır:

Punta kaynağının görünümü, kaynak kalitesini büyük ölçüde yansıtır. Bu çalışmada, sinir ağına dayalı elektronik bileşenlerde kaynak kusurları tanıyan bir görsel denetim sistemi geliştirildi. Çalışmalar sonunda 407 test örneği altında %95,82 doğruluk elde edilmiştir. Fakat bu çalışmada kullanılan punta kaynak resimleri, ana sanayi ve yan sanayinde punta resimlerinden sahadaki durumdan çok farklıdır. Bakır alaşımlı uç elektrot punta kaynağı üzerine yapışmış hatta kullanılan elektrot malzemesi de pirinç malzemeye benzemektedir. Burada kullanılan elektrotta soğutma yetersiz. Soğutma yetersiz olduğu için bakır ya da pirinç alaşımlı malzeme kaynak yapılan metal malzemeye göre ergime sıcaklığı düşük olduğu için, çeliğin ergime sıcaklığında hızlı bir şekilde deforme olup eridiği görülmektedir. Bu bağlamda, elektrot soğutma debisini arttırıp, hata modlarını tekrar düzenlenmesi gerekir (Ye ve ark. 2017).

Direnç kaynağı noktasının görüntülerini sınıflandırmak için evrişimli sinir ağı tabanlı bir yöntem kullanılabilir. Direnç kaynağı noktalarının özellikleri çok karmaşık ve çeşitlidir, bu da eşik kullanarak iyi ve kötü olanları ayırmayı zorlaştırır. Eğitim için 10000 etiketli görsel, ağı test etmek için 300 görsel kullanılabilir. Sonuç olarak, test görüntülerinde %99,01 doğruluk elde edilebiliyor ki bu da insan denetiminden %97,70 daha iyidir. Buna göre soğutma debisi ve elektrot malzeme tipi değişimi yapılması uygun olacaktır (Guo ve ark. 2017).

Dört çeşit paslanmaz çelik direnç nokta kaynağının ultrasonik yankı sinyalleri, yani başarısız kaynak, nüfuziyetsiz kaynak, iyi kaynak ve gaz gözenekli kusurlu kaynak dalgacık paket dönüşümüne dayalı zaman alanı, frekans alanı ve zaman frekansı alanında analiz edilebilir. Doğruluk kusurların sınıflandırılması ve tanımlanması ile %96 oranında doğrulukla yapabilmektedir. Bu çalışma, sahada ultrasonik ölçüm yapan operatörlerin, birbirinin içerisine girebilen hata modlarında, operatörlerin işini kolaylaştırabilir. Punta hatalarının diğer modlarını da yaygınlaştırması uygun olacaktır (Liu ve ark. 2016).

Punta çapı boyut tahmin modeli, yapay sinir ağının geri yayılma (BP) algoritmasına dayalı olarak oluşturulabilir. Modelin girdi parametreleri, elektrot yer değiştirme eğrisinden alınan iki karakteristik sayıdır. Çıktı modelin parametresi punta çapı boyutudur. Ölçülen değer ve tahmin değeri karşılaştırmalı yöntemle analiz edilebilir. Sonuç olarak, tanıma doğruluk oranının %94,3'e kadar çıktığını gözlemlenebilir. Bu çalışmada kullanılan, elektrot yer değiştirme sinyalinin sahada aktif olarak kullanılan bir parametre olmaması nedeniyle, sahada çalışmalarında etkinliği sınırlı olacaktır (Yongyan ve ark. 2012).

Punta kaynak sinyalinin yüksek hızlı toplama ve yönetim sistemi, A/D dönüşümünü ve veri toplamayı sağlayabilir. Daha sonra sırasıyla veri toplama ve bellek modülü, rakamlı sinyal modülünün dalgacık filtreleme, voltaj akım U-I eğrileri ve enerji analiz modülü ile işlenebilir. Sonuçlar, kriterin kaynak sıçramasını ve gevşek kaynak kusurunu doğru bir

şekilde çözebileceğini kanıtlanabilir. Bu çalışma daha çok laboratuvar şartlarında, pek çok faktör sabit tutulmuş veya elenmiş şekilde ele alınabilir. Sahada U-I eğrilerine bakılarak, punta kalitesine karar verilebilmektedir. Ayrıca sadece düşük nüfuziyet veya çapak harici kaynak hata modları da mevcuttur (Ru-xiong ve ark. 2009).

Akustik mikroskop kullanılarak, punta kaynak hataları değerlendirilmesi bir başka çalışmada ele alınabilir. İki sınıf alüminyum plakadan EN AW5754 H24 ve EN AW6005 T606'dan yapılabilir ve bunlar daha sonra akustik mikroskop kullanılarak tahribatsız testlere ve geleneksel ışık mikroskobu teknikleri kullanılarak geleneksel tahribatlı testlere tabi tutulabilir. Ek olarak, çalışma endüstriyel koşullarda bulunan tipik kirleticilerin, kaynak birleştirme kalitesi üzerindeki etkisini incelenebilir. Burada diğer kaynak yöntemleri ile kullanım kolaylığı, doğruluk (tüm hata modlarında) ve atölye ortamında kullanılabilirliği gibi maddelerde mukayeseli karşılaştırma yapılması faydalı olacaktır (Korzeniowki ve ark. 2016).

Ultrasonik test ile kaynak kalitesinin doğrulanması incelenebilir. Mevcut ultrasonik inceleme yöntemlerinin, kaynak kusurlarından biri olan yapışma/eksik kaynak hatası için ideal bir sonuç elde edilmesi zordur. Farklı nokta kaynak kusurlarının yankı karakteristiklerinin kalitatif analizinden sonra, birçok optimum karakteristik parametrenin seçilmesi ve doğrulanması yoluyla, özellikle soğuk kaynak (çekirdek yok) kaynak kusurunu hızlı ve verimli bir şekilde tanımlamak için bir tepe değeri işaretleme algoritması geliştirilebilir. Sonuçlar, bu hızlı tanımlama yönteminin %95'e doğruluk oranına ulaşabileceğini göstermektedir. Sahada UT kontrollerinde, yankı karakteristiklerinin değerlendirmesi yetkin operatör tarafından yapılmaktadır ve ses yankı piklerinin göre punta uygunluğuna manuel karar verilmektedir. Bu çalışma ile süreç otomatik hale getirilebilir (Zhao ve ark. 2006).

Ultrasonik dalgaların iki benzer paslanmaz çelik ve galvanizli paslanmaz çelik levhalar ve iki farklı paslanmaz çelik levha ve farklı kalınlıklarda galvanizli paslanmaz çelik levhalarda yayılması araştırılabilir. Bu test ultrasonik daldırma yöntemi ile

gerçekleştirilmiş ve ortaya çıkan kusur dalgalarının reaksiyonunun şiddeti ve genliği ile sonuçlara etkisi incelenebilir. Çekirdek çapı için ultrasonik test değerleri, gözenek olması, çatlak çapı ve çatlak uzunluğu radyografik, metalografi ve simülasyon deneylerinde ölçülenlerle uyum içindedir. Burada suya daldırma yöntemi ile özellikle çatlak ve gözenek oluşumu incelenebilir (Mirmahdi ve ark. 2020).

DP780 çeliğinin dirençli punta kaynağındaki kaynaklı ek yerlerinin mekanik özellikleri test edilebilir ve üç farklı kaynak çatlağı türü optik mikroskop, taramalı elektron mikroskobu ve elektron geri saçılmış kırınımı ile incelenebilir. Son olarak, kesme gerilme testinde kaynaklı bağlantıların göçme modu tartışılabilir. Kaynaklı bağlantıdaki iç çatlak ise transgranüler kırılma ve elektro baskının kenarındaki yüzey çatlağı, ön ısıtma eklenerek iyileştirilebilir. Burada sadece punta iç ve kenar çatlak konusu ele alınmıştır. Diğer hata modları ele alınması gerekir (Wangi ve ark. 2016)

Punta hatalı parçayı tespit edilmesi ile ilgili sorunlar tüm yan sanayilerde ve ana sanayilerde sıklıkla görülmektedir. Bunu engellemek adına her robot hücresinde ve/veya sabit punta makinalarında operatör her parçayı %100 görsel kontrol yaparak uygun olanları kasaya atması ve uygun olmayan parçayı red kasasına atması istenir. Burada saha ergonomi şartları (ışık şiddeti yetersizliği, sürekli aynı parça inceleme nedeniyle işletme körlüğü oluşması), parçanın aşırı büyük olması ve dar kesitte kalan zor algılanan bölgede hatalı punta olması, operatörün tecrübe eksikliği, punta hatasının çok spesifik olup algılanmasının zor olması, büyüteç ile algılanabilecek kadar küçük olması vb. nedenler ile punta hatası gözden kaçmaktadır.

Bu durum, punta hatalarının tespit edilmesini ve robot hücresini veya sabit punta makina hattını durduracak uygulamaların, hatayı tahmin edilmesini mümkün kılan uygulamalara olan ihtiyacı artırmaktadır. Bu tür uygulamalar olması, punta hatalarının yakalanması işini operatör inisiyatifinden çıkararak, çok yüksek bir oranda yakalanmayı mümkün kılacaktır. Özellikle robot hücreleri, farklı hata modlarında PLC ekranlarında farklı hata mesajları(logları) vermektedir. Fakat mevcutta, tüm hata kodları için geçerli değildir. Bu

hata modlarının tek tek analiz edilerek, hatanın kök nedeninin bulunarak ortadan kaldırılması beklenir. Fakat üretim adet miktarı yetiştirme kaygıları veya değişkenliklerin önemsenmemesi nedeniyle genel olarak bu hata mesajları (logları) reset düğmesine basılarak geçiştirilmektedir. Bu durumda, operatörün %100 göz kontrolü ile hatayı yakalaması, vardiyada frekansiyel yapılan tahribatlı kontrol ve ultrason kontrol ile prosesin güvenliği garanti altına alınmaya çalışılmaktadır.

Punta hataları özellikle kendilerine has hatalar olup, özellikle seri imalat parçalar için görülme frekansı değişkenlik gösterir. Hatalar tekil (punta delik, çapak vb.) olabileceği gibi, çoğul hatada da görülebilmektedir. Burada yukarıda belirtilen pek çok kök neden biri ve/veya birkaçı bir araya gelince hata görülebilmektedir. Hatanın görülme frekansı da, bu kök nedenlerini tekilliği/çoğulluğu, anlık veya kalıcı görülmesi vb. nedenlerine göre farklılık arz eder.

Seri imalatta, 10 yıl boyunca bir defa görülebilen ve sonrasında bir daha karşılaşılmayan durumlar ile de sıklıkla karşılaşılır. Hata analizi yapıldığında, proses şartları ağırlaştırılarak (aparatta parça kaydırma, uç frezelemeye geç gönderme, parametre değişimi vb.) hata simüle edilmeye çalışıldığında, hatanın tekrar oluşmadığı pek çok kez defa tecrübe edilmektedir.

Literatürde, punta hataları yakalama konularında genel olarak ultrason üzerinde odaklanıldığı görülmektedir. Evrişimsel sinir ağları kullanarak punta analizi ile ilgili çalışmalar, laboratuvar koşullarında, benzer parçalar üzerine odaklanılarak yapılmış olmasının gelişmeye açık nokta olduğu açıktır.

Evrişimli sinir ağları (ESA) için en önemli konu ise, pek çok varyasyonu içeren çoklu öğrenme verilerin ve resimlerin toplanmasıdır. Fakat sürecin kendi doğası gereği bu zaman, maliyet, pek çok hatanın tekilliği ve teknolojik kısıtlar nedeniyle çok kolay olmayacaktır. Bu yüzden literatürde, punta hatasının ESA ile yakalanması hakkında, çoklu ve farklı veri seti ile yapılmış çalışmalar sınırlıdır. Bu makalede, gerçek atölye

çalışması yanında, yıllar boyunca yaşanmış tedarikçi hatalarından da eğitim verisi olarak da yararlanarak, öğrenmesi yüzdesi arttırılmıştır.

2.5. Gazaltı Kaynak Hatalarının, Evrişimli Yapay Sinir Ağları (ESA) ile Tespit Edilmesi

Gazaltı kaynak işlemi, günümüzde yaygın olarak kullanılan birleştirme yöntemlerindedir. Bu nedenle, kaynaklı parçaların emniyetinin sağlanması, birleştirmelerin kullanıldığı tüm yapının güvenilirliği açısından büyük önem taşır. Kaynak işlemi, özellikle de ark kaynağı; plazma-metal etkileşimleri, metal/gaz/toz reaksiyonları, kaynak banyosu akışkan akışı, elektromanyetik hareket, faz dönüşümü, ısı transferi, kaynak metali kimyası, ısının tesiri altında kalan bölge (ITAB) mikro yapısı, artık gerilmeler, mekanik özellikler vb. gibi anlaşılması zor fiziksel, kimyasal ve mekanik olguların etkileşimini içeren kompleks bir işlemdir. Bu doğrultuda, kaynak işlemine ait parametrelerin anlaşılması ve etkileri göz önüne alınarak ilgili prosese ait uygun parametrelerin belirlenmesi oldukça önemlidir.

Gazaltı kaynak kalitesi, otomotiv endüstrisinde son derece önemli bir konudur. Gazaltı için tahribatlı ve tahribatsız kontroller olmasına karşın, bunlar kullanım yeri ve ihtiyaca göre farklılık arz eder. Genel olarak otomotiv sektöründe vardiya başında ve sonunda, gazaltı için tahribatlı kontrol ile penetrasyon kontrolü yapılmaktadır (Şekil 2.18).



Şekil 2.18. Gazaltı uygunluk doğrulama kontrolü

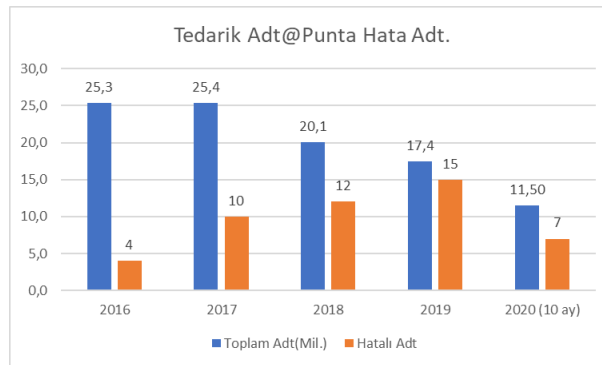
Ancak vardiya içerisinde meydana gelen deęişkenlikler nedeniyle, gazaltı hataları meydana gelebilmektedir. Bu deęişkenlikleri ařaęıdaki řekilde sıralamak mümkündür:

- Proje hataları: Gazaltı yerlerinin hatalı seęilmesi, kaynak yapılacak malzemenin hatalı seęilmesi (malzeme kaplama ve sac kalınlığının ince olması), dik köşe-kenar ve bindirme kaynak metodlarının projede hatalı seęilmesi.
- Robot ekipman sistemi: Yetersiz ve eksik bakım, torç seęim hatası olması, robot konum sıfırlama ünitesinin olmaması, robot eksenlerinin hatalı olması vb.
- Malzeme hataları: Malzemelerin tozlu, paslı ve yağlı řekilde kaynak edilmesi, parçalar arası boşluk deęerinin uygun olmaması, parçalarda deformasyon olması, parçalarda ölçüsel sapma olması, sac kalınlığını yetersiz kalması vb.
- Aparat hataları: Aparatın tasarımının hatalı olması, referansların hatalı ve eksik seęilmesi, pnömatik hatalar nedeniyle parçanın stabilitesinin sağlanamaması, parçanın hatalı konumlanabilmesi, aparat üzerinde parça algılayıcı sensör eksiklikleri, aparat bakımları sonrası aparat ve proses onayının tekrarlanmaması vb.
- Proses hataları: Metodik kaynak olması gereken yerlerde sürekli kaynak atılması, koruyucu gazın hatalı seęilmesi, gazın debisinin yeterli olmaması, kaynak telinin hatalı olması, tel tutucunun torç içerisinde eşmerkezli olmaması, her gazaltı noktası için ayrı program yapılmaması, gazaltı parametrelerinin hatalı seęilmesi, parça akışının hatalı olması, ok ve nok parçaların karışmaması için poka yoke olmaması, aynı hatta farklı versiyonlu parça üretimde tip yönetiminin uygun planlanması, robotu hataya geçtiğinde reset butonunun herkese açık olması/şifre olmaması, seri imalatta arıza bir hata çıktığında (robot, aparat, elektrik kesilmesi, tekil sac parça hatası tespiti), frekansiyel tahribatlı kontrollerinde herhangi bir hata tespitinde tüm lotun karantinaya alınmaması ve %100 tarama ile kontrolünün sağlanamaması, gazaltı parametrelerinin hatalı seęilmesi, parametrede optimizasyon çalışması yapılırken tüm sürecin takibinin eksik yapılması ve parçaların karantiya alınmaması, gazaltı nokta sıralamasının hatalı seęilmesi vb.

İnsan hatalarından bazıları (operasyon detay bilgisi verilmeden işe başlatılması, gereksiz yere inisiyatif kullanarak hataya neden olunması, uygun olmayan parçaların ıskarta kasasına konulmayıp kenarda bırakılması, robot/aparat arıza ve eksiklikleri amirine

bildirilmeyip sürece devam edilmesi, operatörün tam tahribatlı kontrolde eksik yorum yapması ve üretim durdurma gerektiğinde ilk amirine bilgi vermemesi vb.) şeklinde sıralanabilir. Burada onay verildikten sonra, operatörden her bir parça üzerinde yukarıda belirtilen bir veya farklı kök neden ile meydana gelebilen gazaltı hatalarını, %100 göz kontrolü ile kontrol edip hata kaçırmaması beklenmektedir. Hata kaçırma olayı farklı nedenlerle oluşabilir:

- Operatöre hata modları konusunda eğitim verilmemesi, eğitim eksikliği
- Operatörün sürekli aynı parçaya bakması nedeniyle işletme körlüğü oluşması
- Operatöre %100 göz kontrolü için yeteri kadar operasyon süresi verilmemesi
- Operatörün gereksiz insiyatif kullanması
- Operatörün hatalı parçayı hemen ıskarta kasasına atmaması nedeniyle, hatalı parçanın bir şekilde sevk kasasına karışması vb.



Şekil 2.19. Tedarik edilen parçalarda yaşanan gazaltı hatası değişimi (FCA Tofaş uygulamasından alınmıştır)

Şekil 2.19’de görülen hata miktarları tedarikçiden ana sanayiye giden adetler olup, firmanın kendi içerisinde tespit edilen iç ıskarta ve parça taramalarda çıkan adetler bunlara dahil değildir. Bu değerlerin çok daha fazla olacağı tecrübi olarak açıktır. Gazaltı kaynağında hata tespiti ve yakalanması ile ilgili literatürde farklı çalışmalar görmek mümkündür.

Dijital görüntü işleme, belirli bir görüntü kümesinden desen ve özellik çıkarmak için çözümler sağlamaya odaklanan yöntemi, gazaltı çalışmalarında da kullanılabilir. Kenarları belirlemeye yönelik bu teknik, kaynak kalitesinin belirlenmesinde ve dolayısıyla bakım maliyetinin düşürülmesinde rol oynayabilir. Sonuçlara göre, laboratuvar testlerinden elde edilen numunelerin, referans iyi kaynaklara kıyasla sadece %25 eşleşme kalitesine sahip olduğu görülmektedir. Bu çalışma sadece laboratuvar çalışmasıyla sınırlı olup sahada çoklu denemeler ile doğrulanması gerekir (Senthil ve Poluru 2020).

Seri kaynak hataları tespiti plazma optik spektroskopi metodu ile yapılabilir. Plazma elektron sıcaklığı, profiller ve dikişlerdeki kusurların görünümü arasındaki bilinen korelasyon göz önüne alındığında, kaynak teşhisi için çıktı izleme parametresi olarak yaygın şekilde kullanılır. Hat üzerinde kaynak teşhisi için hattın süreklilik yöntemi kullanılmasına izin veren optimum spektral bandın seçimine ilişkin belirsizliği çözmek amacıyla, bir özellik seçme metodolojisi önerilebilir. Ancak hattan çıkan parçalardaki başarı yüzdesi ve diğer gazaltı kaynak metodlarına göre hangi avantaj ve dezavantajların olabileceği açık değildir (Garcia-Allende ve ark. (2009).

Kaynak esnasındaki arkı termal olarak görüntüleyerek, hata yakalama çalışması yapılabilir. Burada evrimsel sinir ağları (CNN) ve evrimsel sinir ağları- uzun-kısa vadeli hafıza ağları (CNN- Long Short-Term Memory Networks) metotları kullanılarak, online olarak hata yakalanabilmesi araştırılabilir. %99,7 gibi doğruluk oranı ile hata yakalanabildiği görülebilir. Bu çalışmada sadece 4 adet hata modundan bahsedilmekte ancak seri imalatta daha farklı hata modları görülmektedir (Fernandez ve ark. 2020).

Evrimsel sinir ağları (ESA) ve kaynak görüntülerini kullanarak, robotik ark kaynağında alüminyum alaşımı için derin öğrenmeye dayalı hat içi hata tespiti için kullanılabilir. ESA modelinin sağlamlığını ve genelleme yeteneğini geliştirmek için, ESA modeli için farklı kaynak akımı ve besleme hızından kaynak görüntüleri yakalanabildiği gösterilmektedir. ESA modeli, geleneksel yolla olduğu gibi ark ışığından kaynaklanan paraziti azaltmak

yerine, tamamlayıcı özellikleri oluşturmak için bunları çeşitli şekillerde birleştirerek bu ark ışıkları tam olarak kullanılabilirdiğini ispat edilebilir. Test sonuçlarına göre, ESA modelinin %99,38 ortalama sınıflandırma doğruluğu elde edildiğini gözlemlenebilir (Fernandez ve ark. 2019).

Görüntülerdeki özellikleri öğrenmek ve sınıflandırmak için evrişimli sinir ağına (ESA) dayalı bir sınıflandırıcı kullanılabilir. ESA mimarisi ve eğitim parametreleri optimize edilebilir. Sonuç olarak sınıflandırıcı, test setlerinden %95,93 genel doğruluk değeri elde edilebilir ve bunun manuel görsel denetim doğruluğundan çok daha iyi olduğu görülebilir (Zhang ve ark. 2018).

Kaynak parçasının stabilitesini ve MIG / MAG kaynak işleminin transfer modunu izleyen düşük maliyetli bir sistemde hatalar tespit edilebilir. Süreci gerçek zamanlı olarak izlemek ve analiz etmek için elektrik arkının ürettiği ses sinyalini yapay sinir ağı (YSA) kullanan bir çözüm kullanılabilir. Sonuçlar, yalnızca elektrik arkının ürettiği sese bakarak kaynak işlemindeki süreksizlikleri belirlemenin mümkün olduğunu göstermektedir. Bu çalışma sonucunda, %90,4 doğruluk oranı elde edildiğini görülmektedir (Pernambuco ve ark. 2019).


Temel bileşen analizi (PCA) ve yapay sinir ağının (YSA) birleşik kullanımına dayalı olarak otomatik kaynak hatası tespitine ve sınıflandırmasına izin veren yeni bir yaklaşım önerilebilir. Spektroskopik analizi, kaynak işlemi sırasında üretilen plazma spektrumları, ortaya çıkan kaynak dikişlerinin kalitesini izlemek için iyi bilinen bir tekniği uygulanabilir. Tasarlanan YSA ile, uygun bir veri eğitim setinin seçilmesi, kaynak hatalarının otomatik olarak tespit edilmesini sağladığını görülebilir (Mirapeix ve ark. 2007).

Plazma anahtar delik şekli ark kaynağında kaynak kusurlarının oluşum süreci, kaynak havuzu içinde girdap oluşumuna bağlı olduğu gözlemlenebilir. Bu ilişkiyi ispatlamak için

gelişmiş bir X ışını görselleştirme sistemi kullanan deneysel bir yaklaşım kullanılabilir (Nguyen ve ark. 2020).

2.6. Sac Metal Çatlaklarının Evrışimli Yapay Sinir Ağları (ESA) ile Tespit Edilmesi

Günümüz otomobilinde pek çok sac parça kullanılmaktadır. Bu parçalar üretilirken, hat sonunda operatörler tarafından göz kontrolü ile bu hataların tespit edilmesi hedeflenir. Göz ile kontrol edilerek, operatör dikkatsizliği, çatlak çizgisinin görünmez olması, hat içi ışıklandırmanın yetersiz olması vb. nedenler ile çatlak hataları tanımlanamayabilir. Ürünün teslim edildiği son noktada tespit edilen hataların yerine göre (malzeme giriş, hatyanı, yarı mamul ve mamul), azdan başlayarak katlanarak artan parça ayıklama/tarama ve ıskarta/kalitesizlik maliyetleri oluşmaktadır. Bu durum firmaları hem maliyet hemde firma kalite hedefleri açısından ciddi olarak etkilemektedir. Şekil 2.20’de gerçek bir uygulamada karşılaşılan ve tedarik edilen parçalardaki çatlak oluşum miktarları görülmektedir. Buradaki hata miktarları tedarikçiden ana sanayiye gönderilen adetler olup, firmanın kendi içerisinde tespit edilen iç ıskarta ve parça taramalarda çıkan adetler bunlara dahil değildir. Bu miktarların ilave edilmesi ile bu değerler sürekli artacaktır. Bu çalışmanın amacı, sac üzerindeki çatlakların tespit edilebilirliğinin araştırılmasıdır.



Şekil 2.20. Tedarik edilen parçalarda karşılaşılan çatlak sayılarının değişimi (FCA Tofaş A.Ş. üretim verilerinden alınmıştır)

Sac form verme mekaniği, çekme testi, form verme esnasında meydana gelen şekil değişikliği ve çatlak oluşumu ele alınabilir (Gedney (2002)).

Tüm şekillendirme sınır diyagramının tahmini için fenomenolojik bir model geliştirilebilir. Fenomenolojik model, boyun verme ve sünek hasar teorilerine dayanmaktadır. Önerilen modelde, boşluk çekirdeklenmesi, eşdeğer plastik şekil değiştirmenin bir fonksiyonu olarak tanımlanmaktadır ve boşluk büyümesi, gerilim üç eksenliliğinin bir fonksiyonudur. Önerilen fenomenolojik modelden hesaplanan şekillendirme sınırı eğrileri, çift eksenli gerilimi C-Mn 440 çeliği, geçişsiz 340 çeliği ve geçişsiz çelik levhalar üzerinde oluşturulan deneysel biçimlendirme sınır eğrileri ile dengelemek için tek eksenli gerilim bölgesinde oldukça iyi eşleştiği görülebilir (Paul 2013).

Lazer dalgaları ile yüzey tarayarak, plaka üzerinde çatlak benzeri bir kusurun varlığı, ya ultrasonik dalga biçimindeki ani bir değişiklikle ya da lazer ışını doğrudan çatlak üzerine yansıdığı dalga biçiminin frekans içeriğindeki bir artışla saptanabileceğini test edilebilir. Lazerle oluşturulan ışık dalgaları, kırınım yoluyla çatlakların etrafında ve ayrıca çatlakların altında açıkça yayılabilmektedir. Bunun meydana gelme derecesinin, frekansa ve levha kalınlığına bağlı olduğu gözlemlenebilir (Dixon ve ark. 2011).

Elektromanyetik kaynaklı yüksek yoğunluklu düşük akım darbesi tarafından üretilen akustik emisyon sinyali sayesinde, tüm yapıyı yüklemeyen belirli alanları incelemek için ince duvarlı yapılarda küçük kusurları veya çatlakları, tahribatsız bir şekilde tespit edildiği görülmektedir (Jin ve ark. 2010).

Sac kararsızlık sınıflarını karakterize etmek için, form verme sırasındaki malzeme davranışının analizi yapılarak, Nakajima testlerinin sonuçları bir optik ölçüm sistemi kullanılarak incelenebilir ve formlanabilme limit eğrisi (FLC) belirleme için sınıfların tanımlanması için uzman görüşlerinin sonuçları da dikkate alınarak doku özelliklerine dayalı, geleneksel bir desen tanıma yaklaşımı kullanılarak, çatlak tespiti yapılabildiği gözlemlenebilir (Affronti ve ark. 2018).

Kırılma mekaniğinde mod I ve mod II tarafından çatlak-açılma yoluyla kırılma arasındaki geçiş bölgesindeki göçme lokusları araştırılabilir. Geleneksel sac metal testleri ile kesme kırılması oluşturma sınırı (SFFL) farklı kalınlıkta malzemeler için belirlenebilir. Kırılma lokusları, tek noktadan deforme olan basit ve karmaşık geometrilerle doğrulanabilir. Bu farklı geometriler, kırılmalı ve kırılmısz farklı gerinim yolları (düzlem gerinimi, kayma ve iki eksenli deformasyon) elde etmeye izin vererek, çatlak analizi yapılabildiği gözlenebilir (Jawale ve ark. 2018).

Malzeme parametrelerinin şekillendirme limiti üzerindeki etkilerini dikkate alan, yeni bir akuple edilmemiş sünek kırılma kriteri (DFC) geliştirilmesi üzerinde çalışılabilir. Eğriler (FLC'ler) ve sonlu eleman kodlarında kolayca uygulanabilir. Kırılma tahmini için elde edilen sonuçları değerlendirmek, yeni DFC ile iki farklı bünye modeli kullanılabilir. Yeni kriteri doğrulamak için çeşitli deneysel testler yapılabilir ve sonuçları da diğer iyi bilinen bağlanmamış DFC'lerle karşılaştırılarak çatlak analizleri olarak değerlendirilebilir (Dizajia ve ark. 2018).

Delikli sacların üretimi ve yüksek düzeyde mekanik stres ve deformasyonunu ele alınabilir. Bu tür gerilim seviyeleri işlenmiş tabakalarda çatlak oluşumuna yol açmaktadır. Yüksek frekanslı elektromanyetik alan kullanılarak bu çatlakların tespit edilebildiğini gözlenebilir (Dizajia ve ark. 2018).


Gerilim durumu parametrelerini, çeşitli yükleme modları altında çatlak yayılma koşullarını keşfetmek için uygulanabilir. Farklı gerilme durumlarında çatlak büyümesi ve kırılmasının özellikleri simüle edilir ve çatlak büyüme yönleri ve modlarının gerilme durumu parametreleri ile ilişkileri doğrulanabilir (Xue ve ark. 2013).

2.7. Araç Görsel Hataların Evrişimli Yapay Sinir Ağları (ESA) ile Tespit Edilmesi

Günümüz otomobilinde, görsel olarak değerlendirebileceğimiz birçok parça bulunmaktadır. Bu parçalar ayrıca araç gövdesinin dış yüzey panel sacları veya

tedarikçiler tarafından üretilen görsel olarak değerlendirilen birçok torpido gözü, konsol parçaları, koltuklar, tamponlar vb. birçok parça olabilir. Buradaki hatalar, müşteri tarafından kolaylıkla algılanıp-algılanamayacak şekilde sınıflandırılmakta ve hatayı tespit ettikten sonra dahi müşteri tarafından görmezden gelinmekte, müşteride memnuniyetsizlik yaratabilmekte ya da mertebesinde olabilmektedir. Bazı durumlarda, müşterinin aracı satın almayı reddedebileceği şekilde önem derecesi de olabilmektedir. Bu sınıflandırmaya göre, frekansını bir katman olarak puanlanacak bir metodoloji takip etmektedir. Bu puanlama metodu ile araç, belirli sıklıkta yapılan toplantılarla değerlendirilir ve düzeltici aksiyonlar, sevkiyatın durdurulması, üretimin durdurulması ve bayilerde tarama yapılması gibi sonuçlar değerlendirilir.

Ana sanayide üretimin farklı aşamalarında ve müşteriye göndermeden önce özel eğitilmiş kişiler tarafından göz kontrolü yapılarak bu hataların tespit edilmesi amaçlanmaktadır. Bu değerlendirme, özel olarak aydınlatılmış araçlar üzerinde, çevre koşullarının etkileri en aza indirilerek yapılmaktadır. Burada tespit edilen hatalar, hatanın kaynağı (pres, gövde, boya, montaj vb.), parça tasnif/tarama ve düşükten başlayıp katlanarak artan hurda/düşük kalite maliyetlerine neden olabilmektedir. Bu durum ana sanayi ve tedarikçi firmalarda, hem maliyet hem de firma kalite hedefleri açısından ciddi şekilde etkilemektedir. Şekil 2.21’ de, gerçek bir uygulamada karşılaşılan hataların miktarı görülmektedir.



Şekil 2.21. Müşterinin bakış açısından değerlendirme (müşteri algısı değerlendirme) sonuçları (FCA uygulamasından alınmıştır)

Öncelikle hatta üretim operatörlerinin ürettikleri parçada bu hataları göz ile kontrol ederek yakalaması beklenmektedir. Sonrasında varsa hat sonunda müşteri gözü ile %100 kontrol ederek, görsel hataları tespit etmesi beklenmektedir. Eğitimli dahi olsa, görsel hataların değerlendiren kişiye bağlı olması ve hata tespiti ile kalitesizlik maliyetleri nedeni ile, bu çalışmayı gerekli kılmıştır.

Her kusurlu görüntünün, görüntü segmentasyon algoritması ile elde edildiğinde, kusur hedefinin sınıflandırılması üzerinde çalışılabilir. Sinir ağı, esas olarak, bellek ve öğrenme işlevleriyle girdiden çıktıya doğrusal olmayan bir haritalama süreci uygular ve karmaşık sistem tanımlamasında çok doğru tanıma sonuçları elde edebildiğini göstermektedir. Araç gövdesi yüzey kusurlarının sınıflandırma yöntemini incelemek için, geliştirilmiş geri yayılım (BP) sinir ağı algoritmasını kullanılabilir (Xing ve ark. 2020).

Farklı otomotiv far camları için esnek denetim sistemleri tasarlamak ve oluşturmak için bileşen tabanlı bir metodolojinin kullanımı üzerinde çalışılabilir. Bilgisayarla görerek ve endüstriyel bir ortamda kullanılacak farklı unsurları hesaba katarak, bu tür parçalar için endüstriyel denetim sistemlerini kolayca tasarlamak ve oluşturmak için bileşen tabanlı bir mimari kullanılabilir. Bu mimari içinde, her bir yazılım veya donanım ögesi, önceden tanımlanmış bir giriş / çıkış düzenine sahip bir bileşende kapsülendir ve daha sonra görev inceleme gereksinimleri dikkate alınarak kullanılabilir. Bu çalışmada, hem laboratuarda hem de üretim hattında test edilen endüstriyel bir prototip oluşturarak başarıyla izlenebilir (Martinez ve ark. 2011).

Döküm parçalarındaki kusurların (inklüzyonlar, hatalı kalıp doldurması ve hatalı işlemler) tespiti için yeni bir segmentasyon yaklaşımı kullanılabilir. Yüzeydeki bu kusurları, dökümde olası hatalı bölgeleri işaretleyen ve ardından bölgelerin kusurlu olup olmadığını belirlemek için toplu sınıflandırma teknikleri uygulanabilir. Bu sınıflandırıcıların etiketleme çabasını azaltırken, yüksek hassasiyet oranları elde edildiğini görülebilir (Pastor-L'opez ve ark. 2013).

Otomatik algılama ekipmanında gerçek zamanlı yüksek verimli bir hata algılama algoritması geliştirme üzerine odaklanılabilir. Bir görüntünün hedef bölgesinde kusurun varlığını doğrulamak için kompakt evrişimli sinir ağına (ESA) dayalı yeni bir algılama algoritması uygulanarak, % 96,85 algılama doğruluğuna ulaşılabilir (Zhou ve ark. 2020).

Yüzey kusur tespiti için derin özellik füzyonuna dayalı bir piksel seviyesinde segmentasyon ağı kullanılabilir. Sonuçlar, önerilen yöntemin, kesinlik ve duyarlılık değerinin harmonik ortalaması olan F ölçümü ve birleşmenin kesişimi açısından karşılaştırılan diğer yöntemlerden daha iyi performans görülebilir. (Cao ve ark. 2021).

Deflektometri tabanlı verimli yarı speküler yüzey kusur tespit sistemi geliştirilebilir. Bu sistem, bir robotik kol ile entegre edildiğinde, araba tamponu gibi geniş ve çok çeşitli topolojik yüzeylerdeki kusurları tespit edebilmektedir. Özel filtreler ayrıca kenarlar ve akut eğrilik değişikliklerinden kaynaklanan sahte kusurları ortadan kaldırmak için tasarlanabilir. Geliştirilen sistem, çeşitli kusurlarını tutarlı bir şekilde tespit etmede, başarılı olduğu görülebilir (Tandiya ve ark. 2018).


3. MATERYAL ve YÖNTEM

Bu bölümde, yapay zeka metodolojisi ile otomotivde yaşanan kronik hatalara ve çalışmalara materyal ve yöntem detaylandırılacaktır:

3.1. ESA İşlemleri

ESA, görüntü sınıflandırma, anlamsal bölümlenme, nesne algılama ve özellik çıkarma için kullanılan derin öğrenmede bir yöntemdir. Yüksek ağ derinliği nedeniyle derin sinir ağı türüne dahildir ve yaygın olarak görüntü verilerine uygulanır. ESA, görüntü sınıflandırması veya nesne tespiti için kullanılır. Nesne algılama işlemi, ESA ile bilgisayarın bilgi alması ile evrişim sürecini kullandığı için gerçekleştirilebilir. Evrişimli sinir ağı iki ana bölüme ayrılmıştır: Çıkarma katmanı özelliği ve tamamen bağlı katman


(Şekil 3.1). Özellik çıkarma, bir evrişimli katman ve bir havuz katmanından oluşur. Diğerlerinin yanı sıra ESA'daki işlemler aşağıda sıralanmıştır :



Şekil 3.1. Evrişimsel sinir ağının genel mimarisi (İnik ve Ülker 2017)

3.1.1. Veri Ön İşleme ve Veri Büyütme


ESA, görüntü sınıflandırma, anlamsal bölümlenme, nesne algılama ve özellik çıkarma için derin öğrenmede kullanılan bir yöntemdir. Yüksek ağ derinliği nedeniyle derin sinir ağı türüne dahildir ve yaygın olarak görüntü verilerine uygulanır. ESA, genellikle görüntü sınıflandırması veya nesne tespiti için kullanılır. Nesne algılama işlemi, ESA ile bilgisayarın bilgi almasını sağlayan evrişim sürecini kullanması ile gerçekleştirilebilir. Diğerlerinin yanı sıra ESA'daki işlemler, aşağıda verilen bölümlerde sıralanmıştır.



Şekil 3.2. Veri ön-işleme ve veri çoğaltma A) orijinal B) döndürme oranı, enin değişmesi, akma oranı, yaklaşma-uzaklaşma oranı, yatay çevirme, doldurma modu gibi farklı

parametrelerin uygulandığı örnekler (bu çalışma oluşturulan algoritmanın çıktısından alınmıştır)

Bu katman, filtre ile görüntü arasında evrişim sürecini yürüterek görüntüdeki dokuyu / deseni bulmaya yarar. ESA'nın temelini oluşturan bu katman dönüşüm katmanı olarak da bilinir. Bu dönüşüm işlemi belirli bir filtrenin tüm görüntü üzerinde dolaştırılması işlemine dayanmaktadır. Filtreler 2x2, 3x3, 5x5 gibi farklı boyutlarda olabilir. Filtreler, bir önceki katmandan gelen görüntülere konvolüsyon işlemi uygulayarak çıkış verisini oluştururlar. Bu konvolüsyon işlemi sonucu aktivasyon haritası (özellik haritası) oluşur.




Şekil 3.3. 5x5x3 boyutta bir giriş görüntüsüne 3x3'lük filtrenin uygulandığı konvolüsyon işlemi (İnik ve Ülker 2017)

3.1.2. Havuzlama Katmanı (Pooling)

Havuzlama temel amacı, sonraki konvolüsyon katmanı için giriş boyutunu (genişlik x yükseklik) azaltmaktır. Bu işlem veride derinlik boyutunu etkilemez. Havuzlama katmanı, birkaç parçayı kare şeklinde bölme şeklinde işlemi gerçekleştirir. Bundan sonra

havuzlama katmanının sonuçlarının bölümünün maksimum değeri alınacaktır. Bu katman, maksimum havuz filtresini 2x2 kullanarak ve 1 adım atarak veya filtreyi 1 kaydırarak maksimum değeri bulacaktır (Şekil 3.4).




Şekil 3.4. Havuzlama katman prosesi (İnik ve Ülker 2017)

Havuzlama katmanının sonuçları en önemli değerleri elde etti. Bu katmanın sonuçları bir sonraki sürece, tamamen bağlı katmana geçecektir.

3.1.3. Tamamen Bağlı Katman (Fully Connected Layer)


Bu katmandaki tüm nöronlar bir dizi şeklinde görünür. Katmandaki nöronların tamamı bu katmana bağlı önceki katmandaki aktivasyonların hepsine tam bağlı durumdadır. Tam bağlı katmanın özelliği önceki katmana bağlı olarak ortaya çıkar. Nesneyi belirleyecek olan özelliklerin hangi sınıfla ilişkili olduğu belirlenir. Bir örüntü ele alınacak olursa; örüntüdeki bir insanın tespit edilmesini sağlayan özellikler aktivasyon haritalarında yüksek değere sahip nöronda yer alacaktır. Bir tam bağlı katman bir sınıfla ilişki derecesi yüksek olan yüksek seviyeli özelliklere bakar. Bu özellikleri belirten ağırlıkların olduğu nöronlara bakılarak hangi sınıfa ait olduğu ortaya çıkmış olur (Lin ve ak. 2013, LeCun ve Bengio 1995). Şekil 3.5’de tam bağlı katman yapısı örneği görülmektedir.




Şekil 3.5. Tam bağlı (full connected) katmanı

3.2. Punta Kaynağında, Çekirdek Çapının Python Regresyon Modelleri ve Yapay Sinir Ağları ile Tahmini

Bu araştırmada, Şekil 3.6’de görülen test numunesi, Ünis Makina 100 kVA ve 100 Hz sabit punta kaynak makinesi ile gerçek koşullar altında EDK süreci gerçekleştirilmiştir. 0,6-3 mm arasında değişen sac kalınlıklarında 6 ve 8 mm bakır alaşımlı uç kullanılarak deneyler yapılmıştır. Kaynak parametreleri; kaynak zamanı, kuvvet, soğuma, yaklaşma, baskı ve sac kalınlığı şeklinde belirlenmiş ve tam faktöriyel deney tasarımı kullanılarak kaynak çekirdek çapı çıktısı araştırılmıştır.



Şekil 3.6. Kaynaklı numune ölçüleri (mm)




Şekil 3.7. Deney tasarımı verilerinin sahada uygulaması **A)** Çekiç ve keski kopartma işlemi **B)** Kaynak uygulaması **C)** Deney numuneleri **D)** Kopartma yapılmış numuneler

EK 1’de deney tasarımı ile elde edilen, tam faktöriyel giriş parametrelerine karşılık, sahada yapılan deneyler sonucunda elde edilen punta çekirdek çapları görülmektedir. EK 2’de giriş parametrelerinin ve onların ikili-üçlü kombinasyonlarının sistem üzerinde etkili olduğu görülmektedir.

Minitab\Stat\DOE\Factorial\AnalysiFactorialDesign\Stepwise\backward elimination yapılarak, tüm giriş parametrelerinde ideal olasılık katsayısı olan $P > 0,05$ değerleri otomatik olarak çekilmeye çalışılmıştır. P (Probability; Olasılık) değeri istatistiksel anlamlılığın varlığının ve var olan farklılığın kanıtının düzeyinin belirlenmesi amacı ile kullanılan bir değerdir. Her istatistiksel testin sonucunda kullanılan teste ait bir P değeri hesaplanır. Bu P değeri “ilgili hipotez testi sonucunda anlamlı fark vardır” denileceği durumda hatalı karar verme olasılığının ne olduğunu gösterir. P değerinin 0,05’ten küçük olması literatüründe “istatistiksel olarak anlamlı” kabul edilir. Burada, kaynak zamanı en büyük etkiye sahip parametredir. EK 2’de görüldüğü üzere tüm parametreler ve onların kombinasyonları çekirdek çapını etkilemektedir. Burada; $R-Sq = 99,53\%$ $R-Sq(adj) = 96,69$ olup sistemin doğruluk değeri oldukça yüksektir. Aşağıda Şekil 3.8.A’da görüldüğü üzere, kaynak zamanı tüm sistem üzerinde en büyük etkiye, baskı ise en az etkiye sahip giriş parametresidir. Ayrıca sistem üzerinde etken parametreler ve kombinasyonları yüzde olarak Şekil 3.8.B’de ve çekirdek çapı için hangi parametrelerin, alt ve üst değerlerine göre, ortalama değerleri Şekil 3.8.C’de etkileşimli olarak verilmiştir.

Bu çalışmada, Minitab programında deney tasarımı çalışması çıktılarında da görüleceği üzere, soğuma zamanı, yaklaşma ve baskı zamanı etkileri, farklı sac kalınlıklarında, tam


faktöriyel deney tasarımı yapılarak denenmiştir. Sonrasında $y=f(x)$ şeklinde sistemin matematik modeli çıkartılmıştır.



Şekil 3.8. Deney tasarımı verilerinin Minitab'ta analiz edilmesi **A)** Standardize edilmiş etkilerin pareto çizelgesi **B)** Standardize edilmiş etkilerin normali grafiği **C)** Punta kaynak çapı için etkileşim grafiği

Sinir ağı, beynin işleme yeteneğini taklit etmek için tasarlanmıştır. Nöron temel kurucu kısımdır. Sinir ağı analizi maliyet etkin, kolay anlaşılır ve üretim sürecinde kullanılmıştır. Geri yayılma, sinirsel ağ eğitimin özüdür. Önceki dönemde elde edilen hata oranına bağlı olarak bir sinir ağının ağırlıklarının ince ayarlanması yöntemidir. Ağırlıkların uygun şekilde ayarlanması, hata oranlarının azaltılmasına ve genelleştirmeyi artırarak modelin daha güvenilir hale gelmesine olanak tanır. Geri çoğaltma, "hataların geriye doğru yayılması" için kısa bir formdur. Yapay sinir ağlarını eğitmek için standart olan bu yöntem, ağıdaki tüm ağırlıklara göre bir kayıp fonksiyonunun gradyanını hesaplamaya yardımcı olur. Geri yayımlı ağlar (Back Propagation-BP) algoritmasını kullanan yapay sinir ağları, Çok Katmanlı Algılayıcı (MLP, multi layer perceptron) ağının verimliliğini artırmak için paralel eğitim gerçekleştirir. Geri yayılım, belirtildiği gibi hata eğrisinin gradyanını aşağı doğru hareket ettirerek ağın hatasını en aza indirmeye çalışan grandyant azalan (Gradient descent-GD) yöntemine dayanan denetimli bir öğrenme tekniğidir. Bir giriş katmanı, bir veya daha fazla gizli katman ve bir çıkış katmanı ile çok katmanlı ileri besleme yapısına sahiptir. Bu algoritmada, 3 adet katman vardır: Çıktı katmanı, giriş katmanı ve giriş- çıkış katmanları arasında gizli katman. Giriş katmanında, giriş nöronları sayısı her çalışma esnasında, çıkış katmanı olan punta çekirdek seviyesine göre

değerlendirilerek, kaynak parametreleri seviyelerine geri beslenir. YSA çok katmanlı bir ileri besleme algoritması kullanarak giriş verileri olarak kaynak parametrelerini ve çıkış katmanı olarak punta çapını tahmin edecek şekilde tasarlanmış ve YSA geri yayılım algoritması tarafından eğitilmiştir (Şekil 3.9). Burada anaconda\spyder\keras modeli kullanılarak YSA yapay sinir ağı oluşturulmuştur. Kerasta nöronları ilklendirmede rastgele_uniform (random uniform), aktivasyon fonksiyonu olarak düzleştirilmiş fonksiyon (relu=rectified linear unit) kullanılmıştır. YSA derlemede optimize etme fonksiyonu olarak 'Adam' fonksiyonu, kayıp fonksiyonunda (loss function-sistem çalışırken kullanılan fonksiyon) ortalamaların karesi-hatası fonksiyonu (mean-squared error) ve metrik (metrics, tahmin edilecek veri) olarak da doğruluk, MAE, MSE, MAPE ve SMAPE seçilmiştir. Nöron sayısı seçimi için bir tecrübi oran olmasına rağmen, ideal olan deneme yanılma ile bu değer seçimi, sistem çalıştırılarak iteratif olarak bulmaktır. Buna göre: N gizli nöron sayısı, I giriş katmanındaki nöron sayısı ve T çıkış katmanındaki nöron sayısıdır. Bu durumda, ağı eğitmek için gereken optimum gizli nöron, giriş katmanı için 49, gizli katman için 98 adet ve çıkış katmanı için 1 adettir. Bu çalışmada, verilerin doğruluğu için aynı veriler ile tekrarlı deney yapılmış ve veri sayısı 128 adete çıkartılmıştır. 128 deneysel veri setinden 85'i eğitim verisi, 43 adedi test verisi olarak kullanılmıştır. Burada doğrulama verileri, ağı aşırı eğitilmesini önlemek için kullanılır. YSA hem lineer hem de non lineer durumlarda cevapları bulmak için en uygun optimizasyon metotlarından birisidir. Regresyon modellerinde ve YSA'de eğitim verileri ile test verileri çalıştırılarak sonuçlar elde edilmiştir. Sonuçta $49 \times 98 \times 1$ ileri beslemeli çok katmanlı bir algılayıcı (multi-layer-perceiving, MLP) mimarisinin en doğru sonuçları ürettiği ve en iyi sonuçları verdiği bulunmuştur.



Şekil 3.9. Yapay sinir ağı (ESA) algoritması (oluşturulan algoritmanın çıktısından alınmıştır)

İlk aşamada sınıflandırma işlemlerinin daha verimli yapılması için, verilere standartlaştırma işlemi (`anaconda\spyder\sklearn.preprocessing.StandardScaler`) uygulanmıştır. Standart yöntem olarak Denklem (3.1)'de verilen yöntem kullanılmıştır:

$$Z = \frac{x - \mu}{\sigma} \quad (3.1)$$

Bu eşitlikte; x veri değerini, μ x değerlerinin ortalamasını ve σ da standart sapmayı ifade etmektedir. Ortalamanın altındaki değerler eksi (-), üzerindeki değerler artı (+) olarak ifade edilmektedir. Standartlaştırma aşamasından sonra Deneysel Tasarım aşamasına geçilmiştir. Sonraki aşamada regresyon işlemleri gerçekleştirilmiştir. Bu aşamada 6 farklı regresyon algoritması ile deneyler gerçekleştirilmiştir. Bu algoritmalar; Lineer Regresyon, Polinomial Regresyon, Destek Vektör Makinası (Support Vektor Machine-SVM) Regresyon, Karar Ağacı Regresyon (Decision Tree-DT), Rasgele Orman (Random Forest-RF) Regresyon ve K-En Yakın Komşu (K-Nearest Neighbors-Knn) Regresyon ve yapay sinir ağları (ANN) algoritmalarıdır. Son aşamada ise önerilen modelin etkinliği test etmek için istatistiki değerlendirme ölçütlerinden yararlanılmıştır. Bu aşamada ortalama

mutlak hata (MAE), ortalama karesel hata (MSE), kök ortalama kare hatası (RMSE), ortalama mutlak yüzdesel hata (MAPE) ve simetrik ortalama mutlak yüzdesel hata (sMAPE) gibi değerlendirme yöntemleri kullanılmıştır.

3.3. Punta Kaynak Hatalarının, Evrişimli Yapay Sinir Ağları (ESA) ile Tespit Edilmesi

Genel olarak otomotiv sektöründe vardiya başında, Şekil 3.10' deki gibi puntalar için tahribatlı kontrol, ultrasonik kontrol ve yarı tahribatlı kontrol ile onay verilerek, vardiya üretimine başlanmamaktadır.



Şekil 3.10. Punta uygunluk doğrulama kontrolleri A) Yarı tahribatlı B) Tam tahribatlı C) Ultrasonik kontrol

Punta hatalı parçayı Tespit edememe ilgili sorunlar tüm tedarikçilerde ve ana sanayilerde frekansiyel olarak yaşıyor. Bunu engellemek adına her robot hücresinde ve/veya sabit puntada operatör her parçayı %100 görsel kontrol yaparak uygun olanları kasaya atması ve uygun olmayan parçayı red kasasına atması istenir. Burada saha ergonomi şartları(ışık şiddeti yetersizliği, sürekli aynı parça inceleme nedeniyle işletme körlüğü oluşması), parçanın aşırı büyük olması ve dar kesitte kalan zor algılanan bölgede hatalı punta olması, operatörün tecrübe eksikliği, punta hatasının çok spesifik olup algılanmasının zor olması, büyüteç ile algılanabilecek kadar küçük olması vb. nedenler ile punta hatası gözden kaçmaktadır.

Bu durum, punta hatalarının tespit edilmesini ve robot hücresinin veya sabit puntayı hattını durduracak uygulamaların, hatayı tahmin edilmesini mümkün kılan uygulamalara

olan ihtiyacı artırmaktadır. Bu tür uygulamalar olması, punta hatalarının tespit edilmesi işini operatör insiyatifinden çıkararak, çok yüksek bir oranda tespit etmeyi mümkün kılacaktır. Özellikle robot hücreleri, farklı hata modlarında PLC ekranlarında farklı hata mesajları(logları) vermektedir. Fakat mevcutta, tüm hata kodları için geçerli değildir. Bu hata modlarının tek tek analiz edilerek, hatanın kök nedeninin bulunarak ortadan kaldırılması beklenir. Fakat üretim adet miktarı yetiştirme kaygıları veya değişkenliklerin önemsenmesi nedeniyle genel olarak bu hata mesajları(logları) reset düğmesine basılarak geçiştirilmektedir. Bu durumda, operatörün %100 göz kontrolü ile hatayı yakalaması, vardiyada frekansiyel yapılan tahribatlı kontrol ve ultrason kontrol ile prosesin güvenliği garanti altına alınmaya çalışılmaktadır.

Literatürde, punta hataları yakalama konularında genel olarak ultrason üzerinde odaklanıldığı görülmektedir. Evrişimsel sinir ağları kullanarak punta analizi ile ilgili çalışmalar, laboratuvar koşullarında, benzer parçalar üzerine odaklanılarak yapılmış görünüyor.

Evrişimli sinir ağları(ESA) için en önemli konu ise, pek çok varyasyonu içeren çoklu öğrenme verilerin ve resimlerin toparlanmasıdır. Fakat prosesin kendi doğası gereği bu zaman, maliyet, pekçok hatanın tekilliği ve teknolojik kısıtlar nedeniyle çok kolay olmayacaktır. Bu yüzden literatürde, bu punta hatasının ESA ile yakalanması hakkında, çoklu ve farklı veri seti ile yapılmış çalışmalar sınırlıdır. Bu makalede, gerçek atölye çalışması yanında, yıllar boyunca yaşanmış tedarikçi hatalarından da training verisi olarak da yararlanarak, öğrenmesi yüzdesi arttırılmıştır.

Otomotiv sektöründe pek çok firmanın farklı punta kaynak şartnameleri olsa da, genel olarak birbirine yakın beklentileri mevcuttur. İdeal bir punta işleminde aşağıdaki çekirdek çapı değerleri elde edilirken, estetik olarak da kaynak uygunluk değerlerini sağlaması beklenir.

Punta kaynağı uygulamasında olası hatalı sonuçlar Şekil 3.11'de görülmektedir.



Şekil 3.11. Punta kaynak hataları A) Delik punta B) Küçük çekirdek C) Çökertmeli punta D) Kenar punta E) Kopuk punta F) Çift sac punta G) Deformeli punta H) Üst üste punta I) Punta çapak

3.4. Gazaltı Kaynak Hatalarının, Evrişimli Yapay Sinir Ağları (ESA) ile Tespit Edilmesi

Gazaltı kaynak hatalı parçayı tespit edememesi sorunları, tüm yan sanayilerde ve ana sanayilerde frekansiyel olarak yaşanmaktadır. Bunu engellemek adına her robot hücresinde ve/veya manuel gazaltı kaynakta, operatörün her parçayı %100 görsel kontrol yaparak uygun olanları kasaya atması ve uygun olmayan parçayı red kasasına atması istenir. Burada sahanın ergonomi şartları (ışık şiddeti yetersizliği, sürekli aynı parça inceleme nedeniyle işletme körlüğü oluşması), parçanın aşırı büyük olması ve dar kesitte kalan zor algılanan bölgede hatalı gazaltı kaynak olması, operatörün tecrübe eksikliği, gazaltı kaynak hatasının çok spesifik olup algılanmasının zor olması, büyüteç ile algılanabilecek kadar küçük olması vb. nedenler ile gazaltı kaynak hatası gözden kaçmaktadır.

Bu durum, gazaltı kaynak hatalarının tespit edilmesini ve robot hücrelerini veya manuel gazaltı kaynak makinası durduracak uygulamaların, hatanın tahmin edilmesini mümkün kılan uygulamalara olan ihtiyacı arttırmaktadır. Bu tür uygulamalar, gazaltı kaynak hatalarının yakalanması işini operatör insiyatifinden çıkararak, çok yüksek bir oranda yakalanmayı mümkün kılacaktır. Özellikle robot hücreleri, farklı hata modlarında PLC ekranlarında farklı hata mesajları (logları) vermektedir. Fakat mevcutta, tüm hata kodları için geçerli değildir. Bu hata modlarının tek tek analiz edilerek, hatanın kök nedeninin bulunarak ortadan kaldırılması beklenir. Fakat üretim hızı yetiştirme kaygıları veya değişkenliklerin önemsenmemesi nedeniyle genel olarak bu hata mesajları reset düğmesine basılarak geçiştirilmektedir. Bu durumda, operatörün %100 göz kontrolü ile hatayı yakalaması, vardiyada frekansiyel yapılan tahribatlı kontrol ve penetrasyon kontrol ile prosesin güvenliği garanti altına alınmaya çalışılmaktadır.

Gazaltı kaynak hataları özellikle kendilerine has hatalar olup, özellikle seri imalat parçalar için görülme frekansı değişkenlik gösterir. Hatalar tekil (gazaltı kaynak delik, çapak vb.) olabileceği gibi, çoğul hatada da görülebilir. Burada yukarıda belirtilen pek çok kök nedenden biri ve/veya birkaçı bir araya gelince hata oluşur. Hatanın görülme frekansı da bu kök nedenlerin tekilliği-çoğulluğu, anlık veya kalıcı görülmesi vb. nedenlerine göre farklılık arz eder.

Literatürde, gazaltı kaynak hataları yakalama konularında genel olarak plazma optik spektroskopi metodu ve termal kamera üzerinde odaklanıldığı görülmektedir. Evrimsel sinir ağları kullanarak, gazaltı kaynak analizi ile ilgili çalışmalar da ancak laboratuvar koşullarında ve genellikle benzer parçalar üzerine odaklanılarak yapılmıştır.

ESA için en önemli konu ise, pek çok varyasyonu içeren çoklu öğrenme verilerin ve resimlerin toparlanmasıdır. Fakat prosesin kendi doğası gereği bu zaman, maliyet, pek çok hatanın tekilliği ve teknolojik kısıtlar nedeniyle çok kolay olmayacaktır. Bu yüzden literatürde, gazaltı kaynak hatasının ESA ile yakalanması hakkında, çoklu ve farklı veri seti ile yapılmış çalışmalar sınırlı kalmıştır. Bu makalede, gerçek atölye çalışmasının

yanında, yıllar boyunca yaşanmış tedarikçi hatalarından da veri olarak yararlanılarak öğrenme yüzdesi arttırılmıştır.

Otomotiv sektöründe pek çok firmanın farklı gazaltı kaynak şartnameleri olsa da, genel olarak birbirine yakın beklentiler mevcuttur. Gazaltı kaynağında minimum penetrasyon isterleri elde edilirken, estetik olarak da kaynak uygunluk değerlerinin sağlanması beklenir. Gazaltı kaynağı uygulamasında olası hatalı sonuçlara örnekler Şekil 3.12’de görülmektedir.



Şekil 3.12. Gazaltı kaynak hataları A) Aşırı penetrasyon B) Çentik kaynak C) Gözenek D) Saclar arası boşluk E) Çapaklı F) Delik G) Eksik kaynak H) Penetrasyon eksik I) Kaynak dikişinde incelme İ) Kaynakta köpürme J) Çatlak K) Hatalı Rota L) Kopma M) Kesintili kaynak N) Yetersiz kaynak dolgusu

3.5. Sac Metal Çatlaklarının Evrişimli Yapay Sinir Ağları ile Tespit Edilmesi

Günümüzün otomobilinde pek çok sac parça kullanılmaktadır. Bu sac parçalar üretilirken, hat sonunda operatörler tarafından göz kontrolü yapılarak, bu hataların yakalanması hedeflenir. Göz kontrollerinde, operatör dikkatsizliği, çatlak çizgisinin görünmez olması, hat içi ışıklandırmanın yetersiz olması vb. nedenler ile çatlak hataları tanımlanamayabilmektedir. Son müşteride hatanın tespit yerine göre (malzeme giriş, hat

yanı, yarımamul ve mamul), azdan başlayarak katlanarak artan parça ayıklama/tarama ve ıskarta/ kalitesizlik maliyetleri oluşmaktadır. Bu durum firmaları hem maliyet hem de firma kalite hedefleri açısından ciddi olarak etkilemektedir.

Çatlak oluşmuş parçayı yakalayamama ile ilgili sorunlar tüm yan sanayilerde ve ana sanayilerde frekansiyel olarak yaşanmaktadır. Bunu engellemek adına her pres hattı sonunda ve/veya C tipi preslerde operatör her parçayı %100 görsel kontrol yaparak uygun olanları kasaya atması ve uygun olmayan parçayı red kasasına koyması istenir. Burada; sahadaki ergonomik şartlar (ışık şiddeti yetersizliği, sürekli aynı parça inceleme nedeniyle işletme körlüğü oluşması), parçanın aşırı büyük olması ve dar kesitte kalan zor algılanan çatlak olması, operatörün tecrübe eksikliği, yırtığın batma şekilde olup algılanmasının zor olması, katlanma olan yüzeylerde ise katlanmanın form ile karıştırılması, yakından büyüteç ile ancak görülebilecek kadar küçük çentik şeklindeki çatlakların olması gibi nedenlerle, çatlak hataları gözden kaçmaktadır. Bu durum, çatlak türlerinin tespit edilmesini ve çatlak Tespitinden sonra pres hattını durduracak uygulamaların mümkün kılan uygulamalara olan ihtiyacı artırmaktadır. Pres hatlarında, çatlak hatalarının yakalanmasını operatör insiyatifinden çıkararak, çok yüksek bir oranda yakalanmayı mümkün kılacaktır.


Çatlak hataları özellikle kendilerine has hatalar olup, seri imalat parçalar için çoğunlukla tekil olarak ortaya çıkmaktadır. Hatanın ortaya çıkmasını tetikleyen pek çok faktör olabilir: Sacın tipi, kimyasal ve mekanik özellikleri, inklüzyon olması, pres şartları, kalıp şartları, ortam şartları vb. Bu nedenlerden biri veya birkaçının bir araya gelmesi ile hata meydana gelebilir. Fakat burada kritik olan konu, bir milyondan fazla parçada sadece bir kez çatlak ile karşılaşılmasıdır. Seri imalatta on yıl boyunca sadece bir kez yırtığın görüldüğü ve sonrasında hiçbir çatlak oluşmayan, pek çok parça ile sahada karşılaşılabilir. Hata analizi yapıldığında, proses şartları ekzejere edilerek (kalıp dayama kaydırma, pot basıncı arttırma vb.) hata simüle edilmeye çalışıldığında, hatanın tekrar oluşmadığı pek çok kez tecrübe edilmiştir. Bu durum, hatanın tekilliği açısından önemli olup hata için farklı sac tiplerinde ve çeşitlilikte veri toplanmanın da ne kadar zor

olduğunun/olacağıının göstergesidir. Bu nedenle, çatlak ile ilgili yapılan bilimsel çalışmaların Autoform gibi analiz programları üzerinden, sanal sınır şartlarının değiştirilmesiyle yapıldığı veya sadece laboratuvar şartlarında tek parça üzerinde yapılan çalışmalarla kısıtlı kaldığı görülmektedir. Evrişimli sınır ağları (ESA) için en önemli konu, pek çok varyasyonu içeren çoklu öğrenme veri ve resimlerin toplanarak veri setinin oluşturulmasıdır. Fakat prosesin kendi doğası gereği bu zaman, maliyet, pek çok hatanın tekilliği ve teknolojik kısıtlar nedeniyle kolay bir süreç değildir. Bu yüzden literatürde, bu tip çatlak hatasının ESA ile yakalanması hakkında, çoklu veri seti içeren çalışmalar sınırlıdır. Bu çalışmada, gerçek atölye çalışması yanında, yıllar boyunca yaşanmış tedarikçi hatalarından da veri olarak yararlanarak, öğrenme yüzdesi arttırılmıştır.

Bu bölümde, öncelikle sac metal şekil değiştirmenin mekaniği incelenerek, çatlak teorisi üzerinde durulacaktır.

3.5.1. Formlanabilme

Formlanabilme, bir malzemenin kırılmadan veya aşırı incelmeden önce dayanabileceği deformasyon miktarının ölçüsüdür. Bu nedenle, bir malzemenin ne ölçüde deforme olabileceğinin belirlenmesi, yeniden üretilebilir bir şekillendirme operasyonu tasarlamak için gereklidir. Şekil 3.13’de, X=çatlak dP=0 noktasındaki boyun vermenin başlangıç bölgesi D noktası, taralı alan uzama-sertleşme katsayısının hesaplamak için kullanılır.



Şekil 3.13. Gerilme-uzama grafiği (Gedney R. 2002'den değiştirilerek alınmıştır)

Şekil 3.13'de görülen A noktası malzemenin orantı limitini gösterir. Bu noktadan sonra yükleme devam ederse malzemede kalıcı ve plastik deformasyon görülür. Oransal limiti hesaplamak zor olduğu için iki pratik ölçüm, ofset akma gerilmesi ve yük altında uzama (YAU) geliştirilmiştir.

Nihai çekme gerilmesi veya tepe gerilmesi ise D noktası olarak grafikte gösterilmiştir. Boyun verme, gerilme-uzama eğrisinde, $dP = 0$ olduğu tepe noktası D başlar. Akma ve çekme dayanımı direk olarak formlanabilme ile ilgili değildir. Ancak, iki gerilmenin büyüklüğü ne kadar yakınsa, metalin o kadar çalışma sertliği artar ki bu durum da uzama kabiliyetini azaltır. Yani süneklik daha da azalır ki bu durum uzamayı azaltacaktır.

3.5.2. Süneklik Ölçümü

Süneklik, plastik deformasyon için bir kapasite ölçüsüdür. İki ölçütü vardır: Toplam uzama ve kopma büzülmesi. Toplam uzama; kırılmadaki tek eksenli gerilme miktarıdır ve Şekil 3.13 'deki Z noktasındaki uzama olarak tasvir edilmiştir. Denklem (3.2)'de, hem elastik hem de plastik deformasyonu içerir ve genellikle kopmadaki yüzde uzama:

$$\text{Kopma uzaması}(\%) = e_z = 100 * \frac{L_z - L_0}{L_0} \quad (3.2)$$

Kopma uzaması gibi kopma büzülmesi, sünekliğin başka bir ölçüsüdür ve yüzde olarak ifade edilir. Denklem (3.3)'de kırılma noktasındaki kesit alanı ölçülerek alan küçülmesi aşağıdaki şekilde hesaplanır:

$$\text{Kopma büzülmesi}(\%) = 100 * \frac{A_0 - A_z}{A_z} \quad (3.3)$$

Genel olarak, kesit büzülmesi arttıkça, bir sac malzeme için izin verilen minimum eğilme yarıçapı azalır. Toplam uzama ve kopma büzülmesi, numunenin kesit alanı arttıkça artar. Yüzde kopma uzaması, numunedeki lokal boyun verme nedeniyle artan ölçü uzunluğu ile azalır. B-D'deki uzama sertleştirme bölgesinde, gerilme-uzama eğrisi, aşağıdaki denklemlerle yaklaşık olarak belirlenir:

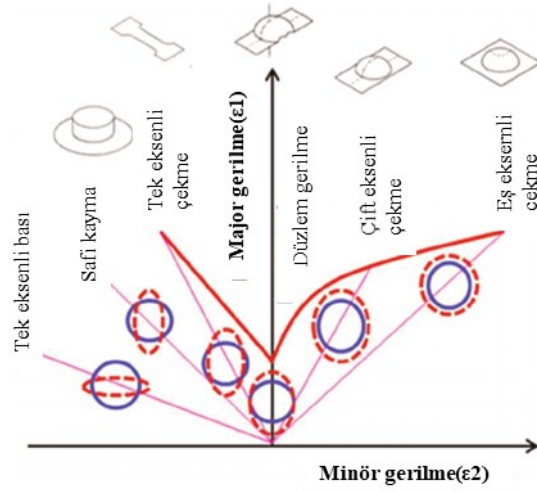
$$\sigma = K \varepsilon^n \quad (3.4)$$

$$\ln \sigma = \ln K + n \ln \varepsilon \quad (3.5)$$

Denklem (3.4) ve (3.5)'deki, σ : Gerçek gerilme, K: Mukavemet katsayısı, ε : Gerçek uzama ve n: Uzama sertleşme katsayısıdır (pekleşme üsteli). n değeri, pekleşme (deformasyon sertleşmesi) kabiliyetini gösterir. n arttıkça boyun verme zorlaşır, homojen şekil değiştirme kabiliyeti artar.

3.5.3 Şekillendirme Limit Diyagramı (ŞLD)


Şekillendirme limiti eğrisi olarak da bilinen bir şekillendirme limit diyagramı (ŞLD), sac metal şekillendirmede sac metalin davranışını tahmin etmek için kullanılır. Şekil 3.14' de sac parçalarda verilen forma göre, sac parça üzerindeki uzama/kısalma yönleri ve gerilme tipleri farklılık arzeder.



Şekil 3.14. Büyük ve küçük şekil değiştirmeler grafiği (Paul ve ark. 2013'den değiştirilerek alınmıştır)

3.6. Araç Görsel Hataların Evrişimli Yapay Sinir Ağları İle Tespit Edilmesi

Araç üretim süreçleri açısından, aracın görsel uygunluk değerlendirmesi son derece önemlidir. Üretim süreçlerinin farklı aşamalarında frekansiyel olarak araçlar, bu konuda özel eğitim almış üçüncül kişiler tarafından tanımlanmış kriterlere göre, özel ışıklandırılmış alanlarda puanlamaya tabi tutulur ve raporlanır (Şekil 3.15). Bu sürece müşteri gözüyle kalite değerlendirme, müşteri algılanan kalite vb. isimler ile farklı isimler ile isimlendirilebilir. Her puanlanan araç, şirket içerisinde üst yönetiminde katıldığı ayaküstü toplantılarda, ilgili departman sorumlularına tek tek açıklanır. Burada hatanın kök nedeni hangi departmana ait ise açıklama yapar veya bir sonraki toplantıda bu konuda yaptığı çalışmayı anlatır. Bu süreç, fabrika için en önemli göstergelerden olup, tüm üst yönetimin hedef kartında yer alır. Hatanın kritikliğine göre, araç tamir, sevkiyat duruş veya üretim duruşuna kadar farklı seviyede kararlar alınır, ilgili birimlerden acil olarak düzeltici faaliyet yapmanı ve uygun lot/ uygun şase gibi yeni seviyeye geçiş bilgisi talep edilir.



Şekil 3.15. Görsel hataları değerlendirme alanı

Araç görsel değerlendirme yapılırken, yetkin bir personel tarafından, tanımlı kriterlere göre puanlama yapılır (Şekil 3.16).

Değerlendirme Parametresi	Puan	sorun	
Görsel kusur bulundu Değerlendirme - aşağıdaki parametrelerin her biri için değerlendirin ve bireysel değerlerin toplamını sağlayın.			
Görünürlük (* 1)	1	Görsel olarak tespit etmek için - Aydınlatma unsurları kusuru görmek için gereklidir - Sadece bir eğimden veya birkaç konumdan görünür.	
	2	90° tarama sırasında sıkça görülebilir - ışık koşullarına bağlıdır - tarama sırasında aralıklı olarak görünür	
	3	Görüş açısı ve aydınlatmadan bağımsız olarak görünür	
Boyutlar (* 2)	0	<2mm	
	1	2 ila 5 mm arasında	
	2	5 ila 25 mm arasında	
	3	> 25 mm	
Kontrast (* 3)	Kusurunu çevreye göre karşılaştırın ve farklılıkları gözlemleyin. Kromatik veya dokunsal kontrasta göre maksimum ağırlık uygulayın		
	Dokunsal / yüzeysel kontrast		Kromatik kontrast
	0	Algılanan / ortalama müşteri tutarlı bir farklılık tespit etmez.	Renk Eşleştirme / parlaklık farkı fark edilmez
	1	Yüzey farkı, dokunma ile kolayca algılanabilir ancak zor görsel olarak tespit edilecek (aşın şeffaf) Veya sadece görsel olarak algılanabilir - dokunmaya değmez.	Aynı renk, ancak farklı gölge - kötü renk eşleşmesi veya pırıltı
	2	Görsel olarak algılanabilen ve dokunma yoluyla doğrulanabilen 3 mm yüzey farklılıkları. Başansızlıktutarlılığı geçişi.	Renksiz Alan> 3mm / Koyu Mavi karşı Koyu Yeşil / Kahverengi karşı Sarı karşı Kahverengi / Açık Gri karşı Koyu Gri / Güçlü Fark parlattıcı (Kumlanma)
3	Yüksek görsel etki ile yüzey Yüzey yapısındaki kuvvetli rahatsızlık> 3 mm'ye neden olur. Yüksek görsel etki. Ya da yüzeydeki ani değişimi> 5 mm.	Diğer görsel etkilerle renk farkı: Güçlü Kontrast Renk Alanı> 3 mm / siyah karşı beyaz / beyaz karşı koyu gri / kırmızı karşı siyah	

Şekil 3.16. Görünürlük, boyut ve kontrast kriterleri detayı (FCA Tofaş eski uygulamalarından alınmıştır)

Şekil 3.17'de, araç değerlendirme yapılırken, araç üzerinde bölgelere ayrılır.



Şekil 3.17. Algılanan kalite değerlendirme bölgeleri **A**) A bölgesi (Zone A), görsel öncelikli alan **B**) B bölgesi (Zone B), ikinci görsel alan **C**) C bölgesi (Zone C), düşük görsel alan (FCA Tofaş uygulamalarından alınmıştır)

Çizelge 3.1’de görüldüğü gibi, A,B ve C bölgelerine göre, hatanın değerlendirme puanlaması farklılık göstermektedir.

Çizelge 3.1. Görsel hataları puanlama kriterleri (FCA Tofaş uygulamalarından alınmıştır)

	A100	A50	A10
Bölge A	Da 9-8	7-6	5-4-3
Bölge B	9	8	7-6-5
Bölge C		9	8

Buna göre puan kriter, hatanın görüldüğü bölgeye göre kriter listesinde yerine konur. Buna göre 10, 50 ve 100 puanlık değerler tespit edilir. 100 puan çok kritik, 50 puan müşterinin daha az hissedeceği kritik ve 10 puan ise müşterinin algılayabileceği fakat şikayet etmeyeceği bir seviye olarak set edilir.

4. BULGULAR (BULGULAR VE TARTIŞMA)

4.1. Punta Kaynağında, Çekirdek Çapının Python Regresyon Modelleri ve Yapay Sinir Ağları ile Tahmini

Minitab’da sistemin $y= f(x)$ şeklindeki matematik modeli, Denklem (4.1)’de aşağıdaki şekilde oluşturulmuştur:

$$\begin{aligned} \text{Çekirdek Çapı} = & [-70,3 + 0,01390 \text{ Akım} - 0,1678 \text{ Kuvvet} - 1,799 \text{ Zaman} + 10,25 \text{ Soğuma} + 0,891 \text{ Yaklaşma} + 4,156 \\ & \text{Baskı} - 19,72 \text{ SacKal} + 0,000009 \text{ Akım} * \text{Kuvvet} + 0,000034 \text{ Akım} * \text{Zaman} - 0,001484 \text{ Akım} * \text{Soğuma} - 0,000197 \\ & \text{Akım} * \text{Yaklaşma} - 0,000507 \text{ Akım} * \text{Baskı} + 0,000029 \text{ Akım} * \text{SacKal} + 0,005809 \text{ Kuvvet} * \text{Zaman} + 0,01413 \\ & \text{Kuvvet} * \text{Soğuma} + 0,000435 \text{ Kuvvet} * \text{Yaklaşma} - 0,002555 \text{ Kuvvet} * \text{Baskı} + 0,02007 \text{ Kuvvet} * \text{SacKal} + 0,0717 \\ & \text{Zaman} * \text{Soğuma} + 0,04775 \text{ Zaman} * \text{Yaklaşma} - 0,04365 \text{ Zaman} * \text{Baskı} + 0,3685 \text{ Zaman} * \text{SacKal} - 0,0865 \\ & \text{Soğuma} * \text{Yaklaşma} - 0,3496 \text{ Soğuma} * \text{Baskı} - 0,123 \text{ Soğuma} * \text{SacKal} - 0,01809 \text{ Yaklaşma} * \text{Baskı} + 0,5262 \\ & \text{Yaklaşma} * \text{SacKal} + 0,5950 \text{ Baskı} * \text{SacKal} - 0,000000 \text{ Akım} * \text{Kuvvet} * \text{Zaman} - 0,000001 \text{ Akım} * \text{Kuvvet} * \text{Soğuma} + \\ & 0,000000 \text{ Akım} * \text{Kuvvet} * \text{Baskı} + 0,000002 \text{ Akım} * \text{Kuvvet} * \text{SacKal} - 0,000004 \text{ Akım} * \text{Zaman} * \text{Yaklaşma} + 0,000006 \\ & \text{Akım} * \text{Zaman} * \text{Baskı} - 0,000023 \text{ Akım} * \text{Zaman} * \text{SacKal} + 0,000014 \text{ Akım} * \text{Soğuma} * \text{Yaklaşma} + 0,000040 \\ & \text{Akım} * \text{Soğuma} * \text{Baskı} + 0,000104 \text{ Akım} * \text{Soğuma} * \text{SacKal} + 0,000002 \text{ Akım} * \text{Yaklaşma} * \text{Baskı} - 0,000034 \\ & \text{Akım} * \text{Baskı} * \text{SacKal} - 0,000211 \text{ Kuvvet} * \text{Zaman} * \text{Soğuma} - 0,000017 \text{ Kuvvet} * \text{Zaman} * \text{Yaklaşma} - 0,000033 \\ & \text{Kuvvet} * \text{Zaman} * \text{Baskı} - 0,000106 \text{ Kuvvet} * \text{Zaman} * \text{SacKal} - 0,001166 \text{ Kuvvet} * \text{Soğuma} * \text{SacKal} + 0,000060 \\ & \text{Kuvvet} * \text{Yaklaşma} * \text{Baskı} - 0,000709 \text{ Kuvvet} * \text{Yaklaşma} * \text{SacKal} - 0,000311 \text{ Kuvvet} * \text{Baskı} * \text{SacKal} + 0,000890 \\ & \text{Zaman} * \text{Soğuma} * \text{Baskı} - 0,01024 \text{ Zaman} * \text{Soğuma} * \text{SacKal} - 0,000275 \text{ Zaman} * \text{Yaklaşma} * \text{Baskı} - 0,001501 \\ & \text{Zaman} * \text{Baskı} * \text{SacKal} - 0,01721 \text{ Soğuma} * \text{Yaklaşma} * \text{SacKal} - 0,007095 \text{ Yaklaşma} * \text{Baskı} * \text{SacKal} - 3,736 \text{ Ct Pt}] \quad (4.1) \end{aligned}$$

Oluşturulan Python algoritmasında, sisteme hangi değerlerin etki ettiğini görmek amacıyla OLS (Sıradan en küçük kareler yöntemi, Ordinary least squares) metodu uygulanmıştır. Burada, $y=f(x)$ modelinde, bağımsız değişkenlerin bağımlı değişken üzerindeki etki değeri görüldü. P value değerlerinin idealde 0,05 değerinden küçük olması istenmektedir.

a) Tüm parametreler alındığında 2 adet P değerinin 0,05 değerinden büyük olduğu, Çizelge 4.1 ’de görülmektedir.

Çizelge 4.1. 7 adet parametre ile OLS regresyon tablosu

OLS Regresyon Sonuçları (7 PARAMETRE İLE)						
Dep, Değişken:	y			R2 (merkezsiz):	0,771	
Model	OLS			Düz.- R2 (merkezsiz):	0,758	
Metot	En küçük kareler			F-istatistik:	59,23	
	kats	std hata	t	P> t	[0,025	0,975]
x2	-0,0090	0,002	-4,885	0,000	-0,013	-0,005
x3	0,1587	0,016	9,859	0,000	0,127	0,191
x4	-0,0693	0,104	-0,667	0,506	-0,275	0,136
x5	-0,0416	0,029	-1,436	0,153	-0,099	0,016
x6	-0,0683	0,022	-3,096	0,002	-0,112	-0,025
x7	0,1058	0,188	0,563	0,575	-0,266	0,478

R-squared R^2 ve adj R-squared (düzeltilmiş R^2) değeri ile regresyon doğrusuna her bir veri noktasının ne kadar yakın olduğunu gösteren bir ölçüdür. Lineer korelasyon kararlılık katsayısı (R^2) olarak isimlendirilir. Önerilen yöntemin uygulanması ile elde edilen çekirdek çapı tahminleri Çizelge 4.2’de sunulmuştur. MSE’ye göre, karar ağacı algoritmasına (7 parametrelili) ile en iyi sonuçla elde edilmiştir. MSE’ye göre, en kötü sonuçlar yine YSA regresyon algoritması ile elde edilmiştir.

Çizelge 4.2. Regresyon modelleri karşılaştırma -7 adet parametre ile

	Linear Regresyon	Polinomial Regresyon	Destek Vektör Makine Regresyon	Karar Ağacı Regresyon	Rasgele Orman Regresyon	K-en Yakın Komşu Regresyon	Yapay Sinir Ağları Regresyon
MAE	0,66	0,41	0,37	0,11	0,61	0,69	0,25
MSE	0,6	0,28	0,32	0,03	0,72	0,67	2,74
RSME	0,36	0,08	0,1	0	0,52	0,44	7,52
MAPE	88,12	46,04	37,25	19,13	77,57	81,98	28,08
sMAPE	63,97	33,25	52,11	19,53	87,03	114,51	34,59

b) P-value değeri 0,05’ten çok büyük iki değer $y=f(x)$ modelinden çıkarıldığındaki durum Çizelge 4.3’de görülmektedir. R-squared R^2 ve adj R-squared değerinden kısmi

iyileşme olmuştur. Fakat regresyon sonuçlarında büyük farklılıklar Çizelge 4.4’de görülmektedir.

Çizelge 4.3. Regresyon modellerinin karşılaştırılması (5 adet parametre ile)

OLS Regresyon Sonuçları (5 Parametreleri ile)						
Dep. Variable:	y	R2 (merkezsiz):				0,770
Model	OLS	Düz.- R2 (merkezsiz):				0,761
Metot	En küçük kareler	F-istatistik:				83,64
	kats	std hata	t	P> t	[0,025	0,975]
x1	0,0006	0,000	6,178	0,000	0,000	0,001
x2	-0,0091	0,002	-5,012	0,000	-0,013	-0,005
x3	0,1581	0,016	9,910	0,000	0,127	0,190
x4	-0,0435	0,028	-1,533	0,128	-0,100	0,013
x5	-0,0695	0,022	-3,197	0,002	-0,113	-0,026


Çizelge 4.4. Regresyon modelleri karşılaştırma -5 adet parametre ile

	Lineer regresyon	Polinomial regresyon	Destek vektör makina regresyon	Karar ağacı regresyon	Rasgele orman regresyon	K-En yakın komşu regresyon	Yapay sinir ağları regresyon
MAE	0,65	2,31E+12	0,62	0,54	0,59	0,71	0,57
MSE	0,57	8,33E+24	0,67	0,60	0,58	0,68	0,64
RSME	0,32	6,94E+49	0,44	0,35	0,33	0,47	0,41
MAPE	87,16	2,87E+14	99,32	90,61	81,14	95,28	93,77
sMAPE	62,36	200,00	85,75	76,36	84,12	107,56	84,22

5 adet parametre, regresyon sonuçlarını tamamen değiştirip ve sistemin doğruluk oranlarını bozmuştur. Minitab programında sistemin $y=f(x)$ modelini oluştururken, otomatik geri doğru süpürme yapılmıştır. Minitab programında $y=f(x)$ modelini oluştururken tüm parametrelerin 2’li ve 3’lü kombinasyonlarını modele dahil ederek modeli çıkartılmıştır. MSE’ye göre, lineer regresyon en iyi sonuçlar vermiştir. En kötü sonuçlar, Polinomial regresyon elde edilmiştir.

MAE, MSE, MAPE ve sMAPE istatistiksel büyükler görülmektedir. Burada döngü değeri, YSA'nin eğitim sırasında tüm eğitim verilerinin yapay sinir ağında çevrim sayısıdır. Eğitimin doğruluğu arttığında bile, validasyon doğruluğu azalmaya başlayana kadar döngü sayısı artırılmıştır. Doğruluğun en yüksek olduğu yerde döngü sayısı 1000 olarak alınmıştır.


c) Döngü sayısı, eğitim sırasında tüm eğitim verilerinin ağa gösterilme sayısıdır. Eğitimin doğruluğu arttığında bile, validasyon doğruluğu azalmaya başlayana kadar döngü sayısı artırılmalıdır. Doğruluğun en yüksek olduğu yerde döngü sayısını ideal sayı olarak alınır. Şekil 4.1'deki MSA, MSE, MAPE nin döngü sayısına göre gidişatı görülmektedir.



Şekil 4.1. Python programında regresyon sonuçlarının, döngü(epoch) değerine göre değişim grafiği **A)** MAE' e göre **B)** MSE' e göre **C)** MAPE'e göre (oluşturulmuş algoritmanın sonuçlarından alınmıştır)


d) Yapay sinir ağları (YSA), model hatasını hesaplamak için bir kayıp fonksiyonu gerektiren bir optimizasyon işlemi kullanılarak eğitilir. Herhangi bir derin öğrenme projesinde, kayıp fonksiyonunun yapılandırılması, modelin amaçlanan şekilde çalışmasını sağlamak için en önemli adımlardan biridir.

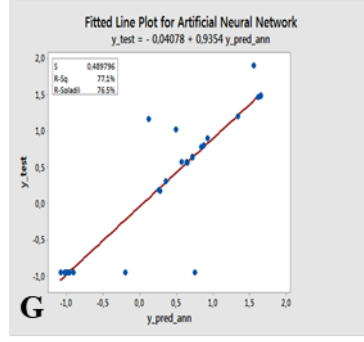
Kayıp fonksiyonu, sinir ağlarınıza çok fazla pratik esneklik verebilir ve ağ çıkışının ağın geri kalanıyla tam olarak nasıl bağlandığını tanımlar. Bu fonksiyon, bir modelin eğitim esnasındaki süreci en aza indirmesi gereken miktarı hesaplamaktadır (Şekil 4.2).



Şekil 4.2. Kayıp fonksiyonu-döngü grafiği (oluşturulmuş algoritmanın sonuçlarından alınmıştır)

e) Python’da yazılan algoritmaya göre, y test değerlerine göre, tüm regresyon ve YSA’da y tahmin (predict) hesaplanmıştır. Bu değerler, Minitab programına aktarılarak minitab\Stat\Regression\FittedLinePlot yapılmıştır. Regresyon grafikleri, matematik modelleri, R-Sq ve R-Sq(adj) değerleri elde edilmiştir. Burada karar ağacı (decision tree) R-Sq 97,8% ve R-Sq(adj) 97,6%’dır. Şekil 4.3’de *ytest* ve *y tahmin* değerlerine göre regresyon grafikleri görülmektedir.





Şekil 4.3. y_{test} ve y_{tahmin} değerlerine göre regresyon grafikleri **A)** Lineer regresyon **B)** Polinomial regresyon **C)** Destek vektör makinası (SVR) regresyonu **D)** Karar ağacı regresyonu (DT) **E)** Sıradan orman regresyonu (RF) **F)** En yakın komşu regresyonu (Knn) **G)** Yapay sinir ağları ile elde edilen sonuçların regresyonu (Oluşturulmuş deney tasarımı Minitab sonuçlarından alınmıştır)

4.2. Punta Kaynak Hatalarının, Evrişimli Yapay Sinir Ağları (ESA) ile Tespit Edilmesi

Bu araştırmada, pek çok farklı parça numunesinde, proses şartları değiştirilerek denemeler yapılmıştır. Bu denemeler sonucunda 848 adetlik bir punta kaynak kütüphanesi oluşturulmuştur. Burada 699 adet uygun olmayan parça veri seti vardır. Ayrıca uygun puntalı parçalardan oluşan ayrı bir veri seti vardır.

Veri bölme fonksiyonu, resimleri tarayacak sistemi eğitecektir. Buna göre eğitim ve test ayrıldı (Çizelge 4.5).


Çizelge 4.5. Veri dağılımı

Deneme No	Test Verisi (%)	Eğitim Verisi (%)	Resim Boyutu	Resim Boyutu
1	10	90	98 x 142	
2	20	80	min	
3	30	70	2160 x 3840	<2929Kb
4	40	60	max	
5	50	50		

Buradaki eğitim ve test veri seti hatalı ve uygun olacak şekilde bölünmüştür (Şekil 4.4 ve Şekil 4.5).



Şekil 4.4. Eğitim ve test verisi için bölünen hatalı punta parça örnekleri



Şekil 4.5. Eğitim ve test verisi için bölünen uygun punta parça örnekleri

Veri setine göre veri adet dağılımını Çizelge 4.6'deki gibi oluşmuştur.

Çizelge 4.6. Toplam veri seti dağılımı

Test Sırası	Test Veri (%)	Eğitim Veri (%)	Toplam Test Verisi Resim Adedi	Toplam Eğitim Verisi Resim Adedi
1	10	90	85	763
2	20	80	170	678
3	30	70	255	593
4	40	60	340	508
5	50	50	424	424

Eğitim/test veri oranı- yüzde doğruluk karşılaştırması, Çizelge 4.7'deki gibi oluşmuştur.

Çizelge 4.7. Eğitim/test veri oranı- yüzde doğruluk karşılaştırması

Öğrenme oranı 0,0002, Çevrim=1000	
Eğitim/test Oranı	Doğruluk(Accuracy) (%)
90% öğrenme verisi, 10% test verisi	96,21
80% öğrenme verisi, 20% test verisi	94,42
70% öğrenme verisi, 30% test verisi	96,72
60% öğrenme verisi, 40% test verisi	97,47
50% öğrenme verisi, 50% test verisi	93,88

ESA, punta resmini tanımak için en iyi sistemin çevrim ve öğrenme oranını test etmelidir. Çevrim, veri kümesini tüm sinir ağı düğümleri üzerinden bir kez ileri ve geri süreç boyunca 1 kez derliyor. Çevrim oranı ile yüzde doğruluk değerleri karşılaştırılmıştır (Çizelge 4.8).

Çizelge 4.8. Çevrim- yüzde doğruluk karşılaştırması

Öğrenme Oranı=0,0002	
Çevrim	Doğruluk %
100	86,65
300	89,82
600	90,97
1000	94,42
2000	96,39

Öğrenme oranı en yüksek doğruluğu elde etmeye hizmet eder. Bunun nedeni, öğrenme oranının değeri ne kadar düşük ise, hata/kayıp değerini azaltacak ve tespit doğruluğunu arttıracaktır (Çizelge 4.9).

Çizelge 4.9. Öğrenme oranı- yüzde doğruluk oranı karşılaştırması

Çevrim=1000, Eğitim/test Veri Oranı = %80/20	
Öğrenme Oranı	% Doğruluk
0,1	81,44
0,01	82,43
0,001	92,94
0,0001	93,27
0,0002	94,42

ESA yapısı, EK 3’de görüldüğü gibi gerçekleşmektedir

4.3. Gazaltı Kaynak Hatalarının, Evrişimli Yapay Sinir Ağları (ESA) ile Tespit Edilmesi

Bu araştırmada, pek çok farklı parça numunesinde, proses şartları değiştirilerek denemeler yapılmıştır. Bu denemeler sonucunda 555 adetlik bir gazaltı kaynak kütüphanesi oluşturulmuştur. Burada 407 adet uygun olmayan parça veri seti vardır. Ayrıca uygun gazaltı kaynaklı parçalardan oluşan ayrı 148 adetlik bir veri seti vardır.


Veri bölme fonksiyonu, resimleri tarayacak sistemi eğitecektir. Buna göre eğitim ve test olarak ayrıldı (Çizelge 4.10). Buradaki eğitim ve test veri seti hatalı ve uygun şeklinde bölünmüştür (Şekil 4.6 ve 4.7). Toplam veri seti eğitim ve test olarak Çizelge 4.10’de görüldüğü gibi bölünmüştür.

Çizelge 4.10. Veri dağılımı

Den. No	Test Veri (%)	Eğitim Veri (%)	Resim Boyutu	Resim Boyutu
1	10	90		
2	20	80	102 x 184	
3	30	70	min, 4000	<3458Kb
4	40	60	x 2250	
5	50	50	maks.	



Şekil 4.6. Eğitim ve test verisi için bölünen hatalı gazaltı parça örnekleri



Şekil 4.7. Eğitim ve test verisi için bölünen uygun gazaltı kaynaklı parça örnekleri

Çizelge 4.11. Toplam veri seti dağılımı

Test Sırası	Test Verisi (%)	Eğitim Verisi (%)	Toplam Test Verisi Resim Adet	Toplam Eğitim Verisi Resim Adet
1	10	90	55	500
2	20	80	110	445
3	30	70	165	390
4	40	60	220	335
5	50	50	275	280

Eğitim/test veri oranı- yüzde doğruluk karşılaştırması, Çizelge 4.12’de gösterilmiştir.

Çizelge 4.12. Eğitim/test veri oranı- yüzde doğruluk karşılaştırması

Öğrenme oranı 0,0002, Çevrim=1000	
Eğitim/test Oranı	Doğruluk (Accuracy) (%)
90% öğrenme verisi, 10% test verisi	95,99
80% öğrenme verisi, 20% test verisi	97,77
70% öğrenme verisi, 30% test verisi	97,28
60% öğrenme verisi, 40% test verisi	98,08
50% öğrenme verisi, 50% test verisi	96,5

ESA, gazaltı kaynak resmini tanımak için en iyi sistemin çevrim ve öğrenme oranını test etmelidir. Çevrim ile veri kümesi, tüm sinir ağı düğümleri üzerinden bir kez ileri ve geri süreç boyunca derlenir. Çevrim oranı ile yüzde doğruluk değerleri karşılaştırılmıştır (Çizelge 4.13).

Çizelge 4.13. Çevrim- % doğruluk karşılaştırması

Öğrenme Oranı= 0,0002	
Çevrim	% Doğruluk
100	83,13
300	86,67
600	93,81
1000	97,77
2000	97,16

Öğrenme oranı en yüksek doğruluğu elde etmeye hizmet eder. Bunun nedeni, öğrenme oranının değeri ne kadar düşük ise hata/kayıp değeri azalacak ve tespit doğruluğunu arttıracaktır (Çizelge 4.14).

Çizelge 4.14. Öğrenme oranı- % doğruluk oranı karşılaştırması

Çevrim=1000, Eğitim/test Veri Oranı = % 80/20	
Öğrenme Oranı	% Doğruluk
0,1	73,05
0,01	73,29
0,001	91,73
0,0001	93,14
0,0002	97,77

ESA sonuçlarına göre öğrenme oranı düştükçe, yüzde doğruluk oranının da arttığı görülmektedir

ESA yapısı, EK 4’de görüldüğü gibi gerçekleşmektedir.

4.4. Sac Metal Çatlaklarının Evrişimli Yapay Sinir Ağları ile Tespit Edilmesi

Bu araştırmada, pek çok farklı parçada form verme proseslerinde, proses şartları değiştirilerek denemeler yapılmıştır. Bu denemeler sonucunda 611 adetlik bir çatlak kütüphanesi oluşturulmuştur. Burada 490 adet çatlak parça veri seti vardır (Şekil 4.8). Ayrıca çatlak olmayan parçalardan oluşan ayrı bir veri seti (121 çatlak olmayan) oluşturulmuştur (Şekil 4.9).



Şekil 4.8. Çatlak parça örnekleri



Şekil 4.9. Çatlak olmayan parçalar

Bu testte, veri kümesi birkaç veri bölüntüsüne ayrılmıştır (Çizelge 4.15). Öğrenme oranı ve çevrim sayısına göre değerlendirme yapılmıştır (Çizelge 4.16).

Çizelge 4.15. Veri dağılımı

Den. No	Test Veri (%)	Eğitim Veri (%)	Resim Boyutu	Resim Boyutu
1	10	90		
2	20	80		
3	30	70	196x417min	<4128Kb
4	40	60	2322*4128maks	
5	50	50		

Çizelge 4.16. Toplam veri seti dağılımı

Test Sırası	Test Verisi (%)	Eğitim Verisi (%)	Toplam Test Verisi Resim Adedi	Toplam Eğitim Verisi Resim Adedi
1	10	90	61	550
2	20	80	122	489
3	30	70	183	428
4	40	60	244	367
5	50	50	305	306

Eğitim/test veri oranı- yüzde doğruluk karşılaştırması, Çizelge 4.17’de gösterilmiştir.

Çizelge 4.17. Eğitim/test veri oranı- yüzde doğruluk karşılaştırması

Öğrenme Oranı=0,0002, Çevrim=1000	
Eğitim/test Oranı	Doğruluk (%)
%90 öğrenme verisi, %10 test verisi	97,73
%80 öğrenme verisi, %20 test verisi	97,86
%70 öğrenme verisi, %30 test verisi	95,61
%60 öğrenme verisi, %40 test verisi	96,32
%50 öğrenme verisi, %50 test verisi	97,55

ESA, çatlak resmini tanımak için en iyi sistemin çevrim ve öğrenme oranını test etmelidir. Çevrim, veri kümesini tüm sinir ağı düğümleri üzerinden bir kez ileri ve geri süreç boyunca 1 kez derlenir. Çevrim oranı ile yüzde doğruluk değerleri karşılaştırılmıştır (Çizelge 4.18).

Çizelge 4.18. Çevrim- yüzde doğruluk karşılaştırması

Öğrenme Oranı=0,0002	
Çevrim	Doğruluk (%)
100	86,75
300	91,88
500	96,15
1000	97,86
2000	98,5

Öğrenme oranı, sistemin ince ayar parametrelerinden biridir. Öğrenme oranı, zamanın lineer bir fonksiyonudur ve zaman t ile ters orantılı bir fonksiyondur. En yüksek doğruluğu elde etmeye hizmet eder. Bunun nedeni, öğrenme oranının değeri ne kadar düşük ise, hata/kayıp değeri azalır ve tespit doğruluğu artar (Çizelge 4.19).

Çizelge 4.19. Öğrenme oranı- yüzde doğruluk oranı karşılaştırması

Çevrim=1000, Eğitim/test Veri Oranı = % 80/20	
Öğrenme Oranı	% Doğruluk
0,1	80,77
0,01	79,49
0,001	92,31
0,0001	95,73
0,0002	97,86

ESA yapısı, EK 5’de görüldüğü gibi gerçekleşmektedir.

4.5. Araç Görsel Hataların Evrişimli Yapay Sinir Ağları ile Tespit Edilmesi

Bu araştırmada, pek çok araçlarda müşteri gözüyle değerlendirme yapılmış araçlarda hatalardan resim kütüphanesi oluşturulmuştur. Bu araçlarda, farklı hata modunda birden çok hata çıkmaktadır. Bu denemeler sonucunda toplam 1447 adetlik bir hata kütüphanesi oluşturulmuştur. Burada 1372 adet uygun olmayan, 75 adetlik uygun bir veri seti oluşturulmuştur.

Veri bölme fonksiyonu, resimleri tarayacak sistemi eğitecektir. Buna göre eğitim ve test ayrıldı (Çizelge 4.20). Toplam veri seti eğitim ve test olarak Çizelge 4.21’de görüldüğü gibi bölünmüştür.

Çizelge 4.20. Görsel hata veri dağılımı

Den .No	Test Veri (%)	Eğitim Veri (%)	Resim Boyutu	Resim Boyutu
1	10	90		
2	20	80		
3	30	70	640 x 480	<181Kb
4	40	60		
5	50	50		

Çizelge 4.21. Görsel hata veri dağılımı

Test Sırası	Test Verisi (%)	Eğitim Verisi (%)	Toplam Test Verisi Resim Adedi	Toplam Eğitim Verisi Resim Adedi
1	10	90	147	1325
2	20	80	294	1178
3	30	70	442	1030
4	40	60	589	883
5	50	50	739	736

Eğitim/test veri oranı- yüzde doğruluk karşılaştırması, Çizelge 4.22’de gösterilmiştir.

Çizelge 4.22. Eğitim/test veri oranı- yüzde doğruluk karşılaştırması

Öğrenme Oranı=0,0002, Çevrim=1000	
Eğitim/test Oranı	Doğruluk (%)
%90 öğrenme verisi, %10 test verisi	98,75
%80 öğrenme verisi, %20 test verisi	98,86
%70 öğrenme verisi, %30 test verisi	98,89
%60 öğrenme verisi, %40 test verisi	97,75

ESA sonuçlarına göre, çevrim sayısı arttıkça, yüzde doğruluk oranının da arttığı görülmektedir (Çizelge 4.23).

Çizelge 4.23. Çevrim- yüzde doğruluk karşılaştırması

Öğrenme Oranı=0,0002	
Çevrim	Doğruluk %
100	95,22
300	96,97
600	98,44
1000	98,6

ESA sonuçlarına göre öğrenme oranı düştükçe, yüzde doğruluk oranının da arttığı görülmektedir (Çizelge 4.24).

Çizelge 4.24. Öğrenme oranı-% doğruluk değeri karşılaştırması

Çevrim Sayısı =1000	
Öğrenme Oranı	Doğruluk %
0,1	89,07
0,01	95,41
0,001	96,79
0,0001	98,65

ESA yapısı, EK 6'de verildiği gibi gerçekleşmektedir.

5. SONUÇ (TARTIŞMA ve SONUÇ)

5.1.a. Araştırma Hipotezi 1: Otomotivde Punta Kaynağında, Çekirdek Çapının Python Regresyon Modelleri ve Yapay Sinir Ağları ile Tahmininde Kullanılabilir.

Bu çalışmada; punta kaynak çekirdek çapının tahmini için, regresyon modelleri ve yapay sinir ağları (YSA) için, python programında makine öğrenmesi algoritmaları oluşturularak bir modelleme çalışması gerçekleştirilmiştir. Önerilen yöntemde makine öğrenmesinin önemli aşamalarından olan veri ön işleme, veri dağılımı belirleme, regresyon ve performans değerlendirme adımları bulunmaktadır.

Farklı parametre değerleri ile Minitab programında deney tasarımı oluşturularak, parametreler belirlenmiş ve bu parametrelere göre deneysel çalışmalar yapılmıştır. Bu çalışmalara göre, $y=f(x)$ modelleri oluşturulmuştur. Ardından Anaconda\Spyder de python yazılım programı kullanılarak, regresyon ve yapay sinir ağları yazılımı hazırlanıp sistem çalıştırılmıştır. Buradan *ytest* değerlerine göre *y tahmin (ypredict)* değerleri bulunmuştur. Bu değerlerin istatistiki karşılaştırmaları yapılmıştır. En iyi değer (7 parametre ile), Karar Ağacı Regresyon yöntemi ile elde edildiği görülmüştür.

Bundan sonraki süreçte, punta kaynak çekirdek çapı tahmini hesabı için, deney tasarımı veri sayısı artırılarak, regresyon yöntemleri ve YSA ile hesaplama durumu daha da iyileştirilebilir.

Endüstride mevcut problemleri çözümünde, matematik tabanlı istatistik programları özellikle otomotiv sektöründe hızlı çözümler sunabilmektedir. Punta kaynak belirleme işleminde sistem girdileri fazla olması ve optimum parametreyi elde etmede Minitab programının istatistik çözümlerinden kolaylıkla yararlanılabilir.

Burada kaynak parametrelerinin belirlenmesinde, yüksek maliyetler oluşturacak pek çok deneme yaparak uygun parametre belirlemek yerine, istatistik tabanlı Minitab programı

kullanılmıştır. Yukarıda özetlenen deneysel çalışmaların ardından aşağıdaki çıkarımları yapmak mümkündür.

5.1.a.1 S1.1 Regresyon ve YSA Metotları Punta Çekirdek Çapı Tahmininde Kullanılabilir mi?

- Kaynak parametreleri bazıları punta çapı pozitif korelasyonu varken, bazıları negatif korelasyona sahiptir.
- 7 adet kaynak parametresinin bazıları tekil olarak direk orantılı olabilirken, bazı parametrelerin 2'li ve/veya 3'lü kombinasyonları $y=f(x)$ üzerinde pozitif korelasyona sahiptir.
- En son çalışmada, rasgele seçilen parametreler ile yüksek bir R-Sq ve R-Sq(adj) değerleri elde edilmiştir ki, bu da elde edilen $y=f(x)$ matematik modeli doğruluğu hakkında bilgi vermektedir.
- Sonuç olarak; bu yayında özetlenen deneysel çalışmaların sonuçlarına göre, tekil olarak öncelikle punta parametrelerinden akım ve baskı pozitif diğerlerinin etkileri negatiftir. Punta parametre optimizasyonu yapılırken, tekil parametre değişimi yerine, komple parametrelerin optimizasyonu yapmak gerekir. Burada kısa zamanda ve ekonomik çözüm için, Minitab gibi istatistik yöntem kullanılması optimum çözüm olacaktır.

5.1.a.2. S1.2 Regresyon ve YSA Teknikleri Sınırları Yeterli midir?


Çizelge 4.2. ve Çizelge 4.4'deki değerlere göre, farklı istatistik göstergelerine göre, regresyon ve YSA metotları sınırları yeterlidir. YSA uygulanmış değerlerin regresyon grafikleri, matematik modelleri, R-Sq ve R-Sq(adj) değerleri elde edilmiştir. Burada karar ağacı (decision tree) R-Sq 97,8% ve R-Sq(adj) 97,6% 'dır.

5.1.b. Araştırma Hipotezi 2: Otomotivde Punta Kaynak Hatalarını, Görüntü İşleme ile Kalite Kontrol Süreçlerinde AI ve ML Teknikleri Kullanılabilir.

5.1.b.1. S2.1 AI ve ML Teknikleri Punta Kaynak Hatalarının Tespitinde Kullanılabilir mi?

Punta kaynak hatalarının tespitinde, AI ve ML teknikleri kullanılabilir. Burada, yapılan doğrulamalarda yüksek doğruluk değerleri elde edilmiş olup, doğruluk değerleri aşağıda sıralanmıştır:

1. Bu veri setinde, daha yüksek çevrim oranlarında (2000), öğrenme oranı=0,0002 eğitim ve test yüzde doğruluk, kayıp fonksiyon değerleri görülmektedir (Şekil 5.1). Burada eğitim verileri doğruluk oranı başlangıçtan sonra giderek artarak %96,39'a ulaşmıştır. Test doğruluk oranı ise %85'de kalmıştır ki bu değer oldukça iyi bir değerdir. Eğitim kayıp fonksiyonu 0,1149 ve test kayıp fonksiyonunun 1,9964.



Şekil 5.1. Punta çevrim oranı=2000, öğrenme oranı =0,0002 olan bir ESA modeli eğrileri **A)** Eğitim ve validasyon (test) doğruluğu **B)** Eğitim ve validasyon (test) kaybı ve **C)** Eğitim ve validasyon (test) doğruluğu, eğitim ve doğrulama (test) kaybı

2. Ayrıca 100 çevrim oranında, farklı transfer fonksiyonlarından bazıları karşılaştırıldı (Çizelge 5.1). Buna göre, doğruluk ve validasyon doğruluk oranına göre VGG16 en yüksek doğruluk elde edilmiştir.

Çizelge 5.1. Transfer fonksiyonların çıktı değerleri karşılaştırması (punta kaynak için)

Transfer Fonksiyon	Doğruluk (%)	Val_doğruluk (%)	Kayıp	Val_kayıp
Inception ResNet V2	94,98	81,25	0,1322	0,6418
Resnet50	91,78	72,5	0,2598	0,6014
Xception	90,29	81,93	0,2335	0,4437
VGG19	92,47	75	0,2361	0,2361
VGG16	96,13	82,5	0,1334	4,8168

3. Ayrıca 100 çevrim oranında, farklı transfer fonksiyonlarından özgüllük, kesinlik, duyarlılık, F1 skor ve AUC değerleri karşılaştırıldı (Çizelge 5.2).

Çizelge 5.2. Transfer fonksiyonların özgüllük, kesinlik, duyarlılık, F1 skor ve AUC değerleri karşılaştırması (punta kaynak için)

Transfer Fonksiyon	Özgüllük	Kesinlik	Duyarlılık	F1 Skore	AUC Değeri
VGG16	1,00	0,87	1,00	0,93	0,70
VGG19	0,20	1,00	0,02	0,05	0,51
Inception					
ResnetV2	1,00	0,87	1,00	0,93	0,70
inceptionV3	0,00	0,80	1,00	0,89	0,50
ResNet152V2	1,00	0,87	1,00	0,93	0,70

5.1.b.2. S2.2 AI ve ML Tekniklerinin Sınırları Punta Hatalarının Tespiti İçin Yeterli midir?

Çizelge 5.1 ve 5.2’de yapılan çalışmalarda elde edilen doğrulama değerleri görülmektedir. Bu değerlere göre, yüksek doğruluk değeri elde edilmiş olup, bu değerler punta hataları tespit edebilmek için yeterli değerlerdir.


Bu çalışmada, sac punta hataları parçalarının tahmini için evrişimli yapay sinir ağları (ESA), Anaconda\Spyder 4.1.5 yazılımdan Python 3.8 program versiyonları kullanılmıştır. Burada:

- Bu çalışma performans değeri, firmalardaki görsel kontrol uygulamaları baz alındığında, oldukça yüksek bir başarı oranı olduğu görülmektedir. Punta kaynak ESA uygulaması tespiti ile, sahada uygulanması durumunda yüksek bir adam-saat, ekipman yatırım ve kalitesizlik maliyetleri kazançları sağlanabilecektir.
- Eğitim-test seti oranları ve yüzdelik doğruluk oranı karşılaştırmasına göre, bu veri setinde ikisi arasında direk korelasyon olarak görülmemiştir (Çizelge 4.7).
- Öğrenme oranlarına göre doğruluk değerlerinin değişkenlik gösterdiği görülmüştür. Öğrenme oranı azaldıkça, doğruluk değeri artmaktadır (Çizelge 4.8).
- Çevrim sayısı arttıkça, yüzde doğruluk değerinin de arttığı gözlenmiştir (Çizelge 4.9).

5.1.c. Araştırma Hipotezi 2: Otomotivde Gazaltı Kaynak Hatalarını, Görüntü İşleme ile Kalite Kontrol Süreçlerinde AI ve ML Teknikleri Kullanılabilir.

5.1.c.1. S2.1 AI ve ML Teknikleri Gazaltı Kaynak Hatalarının Tespitinde Kullanılabilir mi?

1. Bu veri setinde, daha yüksek çevrim oranlarında (2000), öğrenme oranı=0,0002 eğitim ve validasyon yüzde doğruluk, kayıp fonksiyon değerleri görülmektedir (Şekil 5.2). Burada eğitim verileri doğruluk oranı başlangıçtan sonra giderek artarak %97,16'ya ulaşmıştır. Validasyon doğruluk oranı ise %86'da kalmıştır ki bu değer oldukça iyi bir değerdir. Eğitim kayıp fonksiyonu 0,099 ve validasyon kayıp fonksiyonunun 5,7746'dır.



Şekil 5.2. Gazaltı çevrim oranı=2000, öğrenme oranı =0,0002 olan bir ESA modeli eğrileri **A)** Eğitim ve validasyon doğruluğu **B)** Eğitim ve validasyon kaybı ve **C)** Eğitim ve validasyon doğruluğu, eğitim ve validasyon kaybı

2. Karşılaştırmalar farklı transfer fonksiyonları kullanılarak yapılmıştır (Çevrim sayısı 100). Doğruluk ve validasyon doğruluk değerine göre, Inception ResnetV2 fonksiyonu ile en yüksek değerler ile elde edilmiştir (Çizelge 5.3).

Çizelge 5.3. Transfer fonksiyonların çıktı değerleri karşılaştırması (gazaltı için)

Transfer Fonksiyon	Doğruluk (%)	Val_ doğruluk (%)	Kayıp	Val_ kayıp
VGG16	89,44	80	0,32	0,61
VGG19	82,61	97,5	1,41	0,21
Xception	91,25	75,34	0,19	0,67
Inception ResnetV2	98,09	83,33	0,02	1,14
Resnet50	77,6	83,6	4,22	1,35
Inception V3	87,85	90,62	0,29	0,19
Resnet152	91,69	72,5	0,21	5,09

3. Farklı transfer fonksiyonları kullanılarak özgüllük, kesinlik, duyarlılık, F1 skor ve AUC değer, bazıları karşılaştırıldı yapılmıştır (Çevrim sayısı 100, Çizelge 5.4).

Çizelge 5.4. Transfer fonksiyonların özgüllük, kesinlik, duyarlılık, F1 skor ve AUC değerleri karşılaştırması (gazaltı için)

Transfer Fonksiyon	Özgüllük	Kesinlik	Duyarlılık	F1 Skor	AUC Değeri
VGG16	0,71	1,00	0,95	0,97	0,97
VGG19	0,43	0,95	0,90	0,92	0,75
Inception ResnetV2	0,71	1,00	0,95	0,97	0,97
InceptionV3	0,67	0,93	0,97	0,95	0,69
ResNet152V2	0,67	0,93	0,97	0,95	0,69

5.1.c.2. S2.2 AI ve ML Tekniklerinin Sınırları Gazaltı Hataları Tesbiti İçin Yeterli midir?

Bu çalışmada, sac gazaltı kaynak uygulama hatalarının tahmini için ESA Anaconda\Spyder 4.1.5 yazılımdan Python 3.8 program versiyonları kullanılmıştır.


Burada:

- Eğitim-test seti oranları ve yüzdeler doğruluk oranı karşılaştırmasına göre, bu veri setinde ikisi arasında direkt korelasyon olarak görülmemiştir (Çizelge 4.12).
- Çevrim sayısı arttıkça, yüzde doğruluk değerinin de arttığı gözlemlenmiştir (Çizelge 4.13).
- Öğrenme oranlarına göre doğruluk değerlerinin gösterdiği görülmüştür. Öğrenme oranı azaldıkça, doğruluk değeri artmaktadır (Çizelge 4.14).

5.1.d. Araştırma Hipotezi 2: Otomotivde Sac Çatlak Hatalarını Tespit Etmede, Görüntü İşleme ile Kalite Kontrol Süreçlerinde AI ve ML teknikleri kullanılabilir.

5.1.d.1. S2.1 AI ve ML Teknikleri Sac Çatlak Hatalarının Tespitinde Kullanılabilir mi?

1. Burada daha yüksek çevrim oranlarında (2000), öğrenme oranı =0,0002 eğitim ve % doğruluk, kayıp fonksiyon değerleri görülmektedir, Şekil 5.3. Burada eğitim verileri doğruluk oranı başlangıçtan sonra giderek artarak %98,5'a ulaşmıştır. Validasyon doğruluk oranı ise %90'da kalmıştır ki bu değer oldukça iyi bir değerdir. Eğitim kayıp fonksiyonu 0,0572 ve validasyon kayıp fonksiyonun 0,9237.



Şekil 5.3. Sac çatlak çevrim oranı=2000, öğrenme oranı =0,0002 olan bir ESA modeli eğrileri **A)** eğitim ve validasyon doğruluğu **B)** eğitim ve validasyon kaybı ve **C)** eğitim ve validasyon doğruluğu, eğitim ve validasyon kaybı

2. Transfer fonksiyonları ile doğruluk değerleri, çevrim oranı 100’de doğruluk ve test doğruluk değerleri incelenmiştir. Buna göre, Çizelge 5.5’de doğruluk değerine göre Resnet50, validasyon doğruluk değerine göre VGG16/ Inception ResnetV2’ de en yüksek doğruluk değerine ulaşılmıştır. Test doğruluk oranlarına göre VGG16 en yüksek doğruluk oranları elde edilmiştir.

Çizelge 5.5. Transfer fonksiyonların çıktı değerleri karşılaştırması (sac çatlak, %100 veri seti ile)

Transfer Fonksiyon	Doğruluk (%)	Val_ doğruluk (%)	Kayıp	Val_ kayıp	Test doğruluk (%)
VGG16	90,32	90	0,29	0,9	87,5
VGG19	89,90	80	0,31	0,70	80
Xception	96,56	75	0,13	0,65	74
Inception					
ResnetV2	89,68	90	0,24	0,9	87,03
Resnet50	96,79	84,23	0,18	1,68	84,81
Inception V3	92,99	75	0,18	0,65	79,62
Resnet152	95,05	80	0,13	0.50	77,77

3. Farklı transfer fonksiyonları kullanılarak özgüllük, kesinlik, duyarlılık, F1 skor ve AUC değer, bazıları karşılaştırıldı yapılmıştır (Çevrim sayısı 100, Çizelge 5.6).

Çizelge 5.6. Transfer fonksiyonların özgüllük, kesinlik, duyarlılık, F1 skor ve AUC değerleri karşılaştırması (sac çatlak için)

Transfer Fonksiyon	Özgüllük	Kesinlik	Duyarlılık	F1 Skor	AUC Değeri
VGG16	0,40	0,93	0,97	0,95	0,61
VGG19	0,25	0,92	0,97	0,94	0,55
Inception					
ResnetV2	0,33	0,92	0,98	0,95	0,55
inceptionV3	0,50	0,93	0,98	0,96	0,61
ResNet152V2	1,00	0,94	1,00	0,97	0,63

5.1.d.2. S2.2 AI ve ML Tekniklerinin Sınırları Sac Çatlak Hataları Tespiti İçin Yeterli midir?

Bu çalışmada, sac gazaltı kaynak uygulama hatalarının tahmini için ESA Anaconda\Spyder 4.1.5 yazılımdan Pyhon 3.8 program versiyonları kullanılmıştır.

Burada:

- Çizelge 4.17'deki eğitim-test seti oranları ve yüzde doğruluk oranı ile doğrudan bir ilişki görülmemiştir.
- Çizelge 4.18'deki verilere göre çevrim sayısı arttıkça, yüzde doğruluk değeri de artmaktadır.
- Çizelge 4.19'de gösterildiği gibi, öğrenme oranlarına göre doğruluk değerleri değişmekte ve öğrenme oranı azaldıkça, doğruluk değeri artmaktadır.

5.1.e. Araştırma Hipotezi 2: Otomotivde Araç Görsel Hatalarını Tespit Etmede, Görüntü İşleme ile Kalite Kontrol Süreçlerinde Yapay Zeka ve Makine Öğrenmesi Teknikleri Kullanılabilir.

5.1.e.1. S2.1 AI ve ML teknikleri Araç Görsel Hatalarının Tespitinde Kullanılabilir mi?

1. Transfer fonksiyonları ile doğruluk değerleri, çevrim oranı 100'de doğruluk ve test doğruluk değerleri incelenmiştir. Buna göre, Çizelge 5.7'de doğruluk değerine göre,

Inception ResnetV2, val_doğruluk değerine göre Inception V3 en yüksek doğruluk değerleri elde edilmiştir.

Çizelge 5.7. Transfer fonksiyonların çıktı değerleri karşılaştırması (görsel hatalar için)

Transfer Fonksiyon	Doğruluk (%)	Val_doğruluk (%)	Kayıp	Val_kayıp	Test doğruluk
VGG16	94,86	92,86	0,21	0,29	93,57
VGG19	95,01	93,57	0,20	0,93	93,57
Inception ResnetV2	99,08	92	0,02	0,39	92,55
Inception V3	96,11	95,3	0,12	0,06	97
Resnet152	96,45	94,29	0,09	0,44	92,85

2. Görsel hatalar, farklı transfer fonksiyonları kullanılarak özgüllük, kesinlik, duyarlılık, F1 skor ve AUC değeri karşılaştırıldı (Çevrim sayısı 100, Çizelge 5.8).

Çizelge 5.8. Transfer fonksiyonların özgüllük, kesinlik, duyarlılık, F1 skor ve AUC değerleri karşılaştırması (görsel hatalar için)

Transfer Fonksiyon	Özgüllük	Kesinlik	Duyarlılık	F1 Skor	AUC Değeri
VGG16	0,40	0,99	0,95	0,97	0,85
VGG19	0,35	0,99	0,94	0,96	0,85
Inception ResnetV2	0,57	0,99	0,96	0,97	0,85
inceptionV3	0,40	0,99	0,95	0,97	0,85
ResNet152V2	0,36	0,98	0,96	0,97	0,73

5.1.e.2. S2.2 AI ve ML Tekniklerinin Sınırları Araç Görsel Hataları Tespit Etmek İçin Yeterli midir?

- Çizelge 4.22'deki eğitim-test seti oranları ve yüzde doğruluk oranı ile doğrudan bir ilişki görülmemiştir.
- Çizelge 4.23'deki verilere göre çevrim sayısı arttıkça, yüzde doğruluk değeri de artmaktadır.

- Çizelge 4.24’de gösterildiği gibi, öğrenme oranlarına göre doğruluk değerleri değişmekte ve öğrenme oranı azaldıkça, doğruluk değeri artmaktadır.

5.2. Araştırma Hipotezi 3: Görüntü İşlemede AI ve ML Tekniklerinin Kullanımı Yeterli Doğruluk Değerine Bizi Ulaştırabilir

5.2.1. S3.1 Ulaşılabilecek En Yüksek Doğruluk Değerini Belirleyen Faktörler Nelerdir?

Ulaşılabilecek en yüksek doğruluk değerini belirleyen faktörler ayrıca irdelediğimizde, farklı hata modları için farklı algoritmaların üstünlükleri gözlemlenmiştir. Burada özellikle algoritma içerisinde yapılacak ince ayarlar (fine tuning) ile, doğruluk oranları daha da artabilmektedir. Burada çevrim (epoch) sayısı, yığın (batch) sayısı, seçilen düğüm sayısı (dense), kullanılan katman sayısı, yığın normalizasyon (batchnormalization), ayrışma (dropout) kullanıp kullanılmadığı ve değeri, kullanılan aktivasyon fonksiyon tipi, kayıp (loss) aktivasyon fonksiyon tipi, öğrenme oranı kullanılıp kullanması ve oranı değeri vb. ince ayar için kullanılan parametrelerdir. Bu seçilen ince ayarlar için yüksek kombinasyonlar mevcuttur. Bunlardan özellikle biri ve birkaçı sabit tutularak ve/veya değiştirilmek suretiyle, doğruluk oranlarına verilen tepkisine göre değerlendirdi ve belli bir doğruluk oranına ulaşınca iterasyon bırakılmıştır. Bu çalışmada da doğruluk değerini arttırmak için, alternatif olarak farklı transfer fonksiyonu ve parametreler ile deneme yapılmıştır.

5.2.2. S3.2 Alternatif Yöntemler Bulunabilir mi?

Yapay zeka metotlarında doğruluğu arttırmak için farklı metotlar kullanılabilir. Farklı transfer fonksiyonları, farklı ince ayarlama optimizasyonları ile pek çok sayıda varyasyon üretilebilir. Burada özellikle %90’nın üzerindeki doğruluk değerleri, sistemin güvenilirliği açısından yeterli olacaktır.

5.3. Araştırma Hipotezi 4: Yapay Zekanın Görüntü İşlemede Kullanılması İçin Doğruluk Faktörünü Belirleyen En Önemli Kriter Kütüphane Büyüklüğüdür.

5.3.1. S4.1 Kütüphane Büyüklüğü ile Doğruluk Değeri Arasında Nasıl Bir Korelasyon Bulunur?

Yapay zekanın görüntü işlemede kullanılması için doğruluk faktörü ile kütüphane büyüklüğünün ilişkisi araştırıldığında, özellikle daha az sayıda eğitim verisi ile algoritma çalıştırıldığında, düşük doğruluk değerleri elde edildiği görülmüştür (Çizelge 5.9).

Transfer fonksiyonları kullanılarak, veri sayısı %50 azaltılarak tekrar analiz yapılmıştır. Buna göre Çizelge 5.9'da çevrim oranı 100'de, doğruluk ve test doğruluk değerleri incelenmiştir. Buna göre doğruluk değerlerinde %0,93- %11,13 arasında değişen oranlarda kötüleşme gözlenmiştir.

Çizelge 5.9. Transfer fonksiyonların çıktı değerleri karşılaştırması (%50 veri seti ile)

Transfer Fonksiyon	Doğruluk (%)	Val_doğruluk (%)	Kayıp	Val_kayıp	Test doğruluk
VGG16	80,27	80	0,52	0,50	85
VGG19	81,61	85	0,35	0,35	80
Xception	92,83	85	0,25	0,79	89,89
Inception					
ResnetV2	82,78	82,5	0,40	0,47	80,49
Resnet50	92,83	65	0,19	1,94	70,37
Resnet152	94,17	80	0,16	2,32	74,07

5.3.2. S4.2 Kütüphane Elemanlarını Belirlerken Nelere Dikkat Edilmelidir?

Veri kütüphane elemanlarını seçilirken, farklı varyasyonları içermesi gerekir. Eğitim verileri oluşturulurken proste parametre değişikliği yaparak, en kötü şartlara ait parça resimleri elde edilmeye zorlanmalıdır. Bunun deney tasarımı ile sınırlı veri ile tüm prosesi simüle edilebilecek veriler elde edilebilir. Verilerin doğru etiketlenmesi son derece önemlidir. Uygun etiketlenmemesi durumunda, doğruluk değerlerine direk olarak bozulma görülmektedir.

Bundan sonraki süreçte bu öğrenme verileri training datası olarak kullanılarak, çoklu kameralar ile tekrarlayan evrişimli yapay sinir ağıları (recurrent 3D convolutional neural network-R3DCNN, Fast R-CNN, Faster R-CNN) vb. metodlar ile atölye koşullarında hat içerisinde hata yakalama arařtırmaları da yapılabilir.

5.4. Genel Sonuç ve Gelecek Çalışmalar

- Bu çalışmada araç üretiminde sahada karşılaşılan örnek problemleri tespit etmek adına yapılan çalışmalarda, yapay zeka metotları ile yüksek doğruluk oranları elde edilmiştir.
- Bu çalışmalar, mevcutta yaşanan farklı hata modları içinde yaygınlaştırılarak, yüksek doğruluk oranları elde edilebilir
- Bundan sonraki süreçte bu öğrenme verileri training datası olarak kullanılarak, çoklu kameralar ile tekrarlayan evrişimli yapay sinir ağıları (recurrent 3D convolutional neural network-R3DCNN, Fast R-CNN, Faster R-CNN) vb. metodlar ile atölye koşullarında hat içerisinde hata yakalama arařtırmaları da yapılabilir.
- Ayrıca özellikle resim işleme haricinde, makine/ aparat üzerinden sensörler ile alınabilecek farklı proses parametreleri, yapay zeka metotları kullanılarak, hata oluşma anında hata tespiti de yapılabilir

KAYNAKLAR

- Affronti, E., Jaremenko, C., Merklein, M., Maier, A. 2018.** Analysis of forming limits in sheet metal forming with pattern recognition methods. Part 1: characterization of onset of necking and expert evaluation. *Materials*, 11(9), 1495.
- Alpaydın, E. 2016.** Machine Learning : The New AI . The MIT Press, Massachusetts, Amerika Birleşik Devletleri, 225 pp.
- Anonim, 2016.** Yapay zekanın kronolojik ilerlemesi. [https://blogs.nvidia.com/blog/2016/07/29/whats-difference-artificial-intelligence-machine-learning-deep-learning-ai/-](https://blogs.nvidia.com/blog/2016/07/29/whats-difference-artificial-intelligence-machine-learning-deep-learning-ai/) (Erişim tarihi: 03.01.2022).
- Anonim, 2017.** Denetimli Öğrenme (Supervised Learning). [https://veribilimcisi.com/2017/07/12/denetimli-ogrenme/-](https://veribilimcisi.com/2017/07/12/denetimli-ogrenme/) (Erişim tarihi: 03.01.2022)
- Anonim, 2017.** MSE, RMSE, MAE, MAPE ve Diğer Metrikler. [https://veribilimcisi.com/2017/07/14/mse-rmse-mae-mape-metrikleri-nedir/-](https://veribilimcisi.com/2017/07/14/mse-rmse-mae-mape-metrikleri-nedir/)(Erişim tarihi: 03.01.2022)
- Anonim, 2017.** Multi-Layer Neural Networks with Sigmoid Function Deep Learning for Rookies. <https://towardsdatascience.com/multi-layer-neural-networks-with-sigmoid-function-deep-learning-for-rookies-2-bf464f09eb7f-> (Erişim tarihi: 03.01.2022)
- Anonim, 2018.** Denetimli Öğrenme Yöntemleri Bölüm1. [https://devhunteryz.wordpress.com/2018/03/18/denetimli-ogrenme-yontemleri-bolum-1/-](https://devhunteryz.wordpress.com/2018/03/18/denetimli-ogrenme-yontemleri-bolum-1/) (Erişim tarihi: 03.01.2022)
- Anonim, 2018.** Denetimli öğrenme (Supervised learning). [https://yavuz.github.io/denetimli-ogrenme/-](https://yavuz.github.io/denetimli-ogrenme/) (Erişim tarihi: 03.01.2022)
- Anonim, 2019.** Denetimsiz Öğrenme Nedir ve Nasıl Çalışır? <https://ichi.pro/tr/denetimsiz-ogrenme-nedir-ve-nasil-calisir-71091020868708-> (Erişim tarihi: 03.01.2022)
- Anonim, 2020.** AUC eğrisi. <https://medium.com/@gulcanogundur/do%C4%9Fruluk-accuracy-kesinlik-precision-duyarl%C4%B1l%C4%B1k-recall-ya-da-f1-score-300c925feb38->(Erişim tarihi: 03.01.2022)
- Anonim, 2020.** Derin öğrenme nedir? <https://t24.com.tr/yazarlar/hayri-cem-haftalik/derin-ogrenme-nedir,29220-> (Erişim tarihi: 03.01.2022)
- Anonim, 2020.** Ortalama doğruluk(kesinlik) değerinin yıllara göre ilerlemesinin grafiği. <https://towardsdatascience.com/how-does-ai-detect-objects-technical-d8d63fc12881-> (Erişim tarihi: 03.01.2022)
- Anonim, 2020.** Yapay zeka, büyük veri ve veri bilimi kavramlarının şematik görünüşü.
- Aslanlar, S., Ozsarac, U., Ilhan, E., Ogur, A. 2008.** Welding time effect on mechanical properties of automotive sheets in electrical resistance spot welding. *Materials and Design*, 29(7):1427-1431.
- Boersch, I., Füssel, U., Gresch, C., Großmann, C., Hoffmann, B. 2018.** A non-destructive method to predict the welding spot diameter by monitoring processparameters. *The International Journal of Advanced Manufacturing Technology*, 99:1085–1099.
- Brown, J.D., Rodd, M.G.,Williams, N.T. 1998.** Application of artificial intelligence to

- Cao J., Yang G., Yang X., 2021.** A Pixel-Level Segmentation Convolutional Neural Network Based on Deep Feature Fusion for Surface Defect Detection. *IEEE Transactions on Instrumentation and Measurement*, 70:99.
- Dixon, S., Burrows, S.E., Dutton, B., Fan, Y. 2011.** Detection of cracks in metal sheets using pulsed laser generated ultrasonda and EMAT detection. *Ultrasonics*, 51, 7–16.
- Dizajia S.A., Darendeliler H., Kaftanoğlu B. 2018.** Prediction of forming limit curve at fracture for sheet metal using new ductile fracture criterion. *European Journal of Mechanics*, 69:255–265.
- Duric, A., Klobčar, D., Milčić, D., Marković, B. 2019.** Parameter optimisation and failure load prediction of resistance spot welding of aluminium alloy 57547. IOP Conf. Series: Materials Science and Engineering 659, 9th International Scientific Conference - Research and Development of Mechanical Elements and Systems, 5–7 September, 2019, Kragujevac, Serbia.
- Eşme, U., Güven, O., Serin, H. 2007.** Direnç nokta kaynağında kaynak mukavemetinin modellenmesi ve tahmin edilmesinde yapay sinir ağlarının kullanılması. *Ç.Ü.MÜH.MM. AK.Dergisi*, 22(1).
- Fernandez, A., Souto, A., Gonza'lez, C., Me'ndez-Rial, R. 2020.** Embedded vision system for monitoring arc welding with thermal imaging and deep learning. International Conference on Omni-layer Intelligent Systems (COINS), 31 Aug.-2 Sept, 2020, Barcelona, Spain.
- Garcia-Allende, P.B., Mirapeix, J., M. Conde, M.O., Cobo, A., Lopez-Higuera J.M. 2009.** Defect Detection in Arc-Welding Processes by Means of the Line-to-Continuum Method and Feature Selection. *Sensors*, 9, 7753-7770.
- Gedney, R. 2002.** Sheet metal formability. *Advanced Materials & Processes*, 160(8).
- Guo, Z, Ye, S., Wang, Y., Lin, C. 2017.** Resistance Welding Spot Defect Detection with Convolutional Neural Networks. 11th International Conference ICVS, July 10–13, 2017, Shenzhen, China.
- Hayat F. 2011.** The effects of the welding current on heat input, nugget geometry, and the mechanical and fractural properties of resistance spot welding on Mg/Al dissimilar materials. *Materials and Design*, 32(4):2476-2484.
- Hebb, D.O. 1949.** The organization of behavior: a neuropsychological theory. *Brain Theory*, 231-233.
- Hiba, K.H., Israa, R.S., Iman, A.Z. 2019.** Prediction of spot welding parameters using fuzzy logic controlling. *Eastern-European Journal of Enterprise Technologies*, 5(2 (101)), 57-64.
[https://ai.plainenglish.io/data-science-vs-artificial-intelligence-vs-machine-learning-vs-deep-learning-50d3718d51e5-\(Eriřim-tarihi:03.01.2022\)](https://ai.plainenglish.io/data-science-vs-artificial-intelligence-vs-machine-learning-vs-deep-learning-50d3718d51e5-(Eriřim-tarihi:03.01.2022))
- Jawale, K., Duarte, J.F., Reisa, A., Silva M.B.,2018.** Characterizing fracture forming limit and shear fracture forming limit for sheet metals. *Journal of Materials Processing Tech.*, 255:886–897.
- Jin, L., Yang, Q., Liu, S., Zhang, C., Li, P. 2010.** Electromagnetic stimulation of the acoustic emission for fatigue crack detection of the sheet metal. *IEEE Transactions on Applied Superconductivity*, 20(3), 1848 –1851.
- Kim, K.Y., Ahmed, F. 2018.** Semantic weldability prediction with RSW quality dataset and knowledge construction. *Advanced Engineering Informatics*, 38:41-53.

- Kim, T., Park, H., Rhee, S. 2005.** Optimization of welding parameters for resistance spot welding of TRIP steel with response surface methodology. *International Journal of Production Research*, 43(21):4643-4657.
- Korzeniowski, M., Bialobrezeska, B. 2016.** Analysis of Using Acoustic Microscopy to Evaluate Defects in Spot Welding. *Archives of Metallurgy and Materials*, 61(2B), 1009–1019.
- Liu, J., Xu, G., Ren, L., Qian, Z., Ren, L. 2016.** Defect Intelligent Identification in Resistance Spot Welding Ultrasonic Detection based on wavelet packet and neural network. *Int J Adv Manuf Technol*, 90:2581–2588.
- Mani, V., Omkar, S., N. 2002.** International Journal of Production Research. *Understanding weld modelling processes using a combination of trained neural networks*, 40(3), 547-559.
- Martinez S.S., Ortega, J.G., Garcia A.S., Garcia J.G. 2011.** An adaptable vision system for the automatic inspection of surface defects in automotive headlamp lenses. IEEE International Conference on Automation Science and Engineering, August 24-27, 2011, Trieste, Italy.
- McCulloch, W.S., Pitts, W. 1943.** A logical calculus of the ideas immanent in nervous activity forms. *Bulletin of Mathematical Biophysics*, 9:127–147.
- Michie, D., Spiegelhalter, D.J., Taylor, C.C. 1994.** Machine Learning, Neural and Statistical Classification, Overseas Press, 289 pp.
- Mirapeix, J., Garcí'a-Allende, P.B., Cobo, A., Conde, O.M., Lo'pez-Higuera, J.M., 2007.** Real-time arc-welding defect detection and classification with principal component analysis and artificial neural networks. *NDT & E International*, 40(4), 315-323.
- Mirmahdi E. 2020.** Numerical and Experimental Modeling of Spot Welding Defects by Ultrasonic Testing on Similar Sheets and Dissimilar Sheets. *ISSN 1061-8309, Russian Journal of Non destructive Testing*, 56(8):620–634.
- Murphy K.P., 2012.** Machine Learning A Probabilistic Perspective. The MIT Press, Massachusetts, Amerika Birleşik Devletleri, 1007 pp.
- Nguyen, A.V., Tashiro, S., Ngo, M.H., Bui, H.V., Tanaka, M. 2020.** Influence of shielding gas composition on molten metal flow behavior during plasma keyhole arc welding process. *Journal of Manufacturing Processes*, 59, 649–657.
- Pashazadeh, H., Gheisari, Y., Hamed, M. 2016.** Statistical modeling and optimization of resistance spot welding process parameters using neural networks and multi-objective genetic algorithm. *J Intell Manuf*, 27:549–559.
- Pastor-L'opez I., Santos I., de-la-Peña-Sordo J., Salazar M., Santamar'ia-Ibirika A., Bringas P.G. 2013.** Collective Classification for the Detection of Surface Defects in Automotive Castings. IEEE 8th Conference on Industrial Electronics and Applications (ICIEA), 19-21 June, 2013, Melbourne, VIC, Australia.
- Paul, K.S., Manikandan, G., Verma, K. R. 2013.** Prediction of entire forming limit diagram from simple tensile material properties. *The Journal of Strain Analysis for Engineering Design*, 48-386.
- Pereda, M., Santos, J.I., Galán, J.M., Martín, Ó. 2015.** Direct quality prediction in resistance spot welding process: Sensitivity, specificity and predictive accuracy comparative analysis. *Science and Technology of Welding and Joining*, 20(8):679-685.

- Pernambuco, B.S.G., Pereira, J.R., Steffens, C.R., Werhli, A.V., Azzolin Rodrigo, Estrada Emanuel S.D. 2019.** Online Sound Based Arc-Welding Defect Detection using Artificial Neural Networks. Latin American Robotics Symposium (LARS), 23-25 Oct, 2019, Rio Grande, Brazil.
- resistance spot welding. *Iron making and Steelmaking*, 25(3):199-204.
- Rosenblatt, F. 1958.** The Perceptron: A Probabilistic Model for Information Storage and Organization in the Brain. *Psychological Review*, 65(6):386.
- Rosenblatt, F. 1962.** Principles of Neurodynamics: Perceptions and the Theory of Brain Mechanisms. Spartan Books, Washington DC, 616 pp.
- Ru-xiong, L., Xiao-chun, L., Ping, Z. 2009.** Analysis of welding defects in spot welding process U-I curves. Third International Conference on Genetic and Evolutionary Computing, 14-17 October, 2009, Guilin, China.
- Sambath, S., Nagaraj, P., Selvakumar, N. 2011.** Automatic Defect Classification in Ultrasonic NDT Using Artificial Intelligence. *Journal of Nondestructive Evaluation*, 30(1):20-28.
- Satonaka, S., Kaieda, K., Okamoto, S. 2004.** Prediction of Tensile-Shear Strength of Spot Welds Based on Fracture Modes. *Welding in the World: The International Journal of Materials Joining*, 48(5-6):39-45.
- Senthil S.V., Poluru V.R. 2020.** Application of Digital Image Processing Techniques in Determining the Quality of ARC and MIG Welding of Steel Joints. 8th International Conference on Reliability, Infocom Technologies and Optimization (Trends and Future Directions) (ICRITO) Amity University, June 4-5, 2020, Noida, India,
- Sheikhi, M., Valaee, T.M., Fattah-Alhosseini, A., Usefifar, G.R. 2017.** Thermal modeling of resistance spot welding and prediction of weld microstructure. *Metallurgical and Materials Transactions A: Physical Metallurgy and Materials Science*, 48(11):5415-5423.
- Sun, H., Yang, J., Wang, L. 2017.** Resistance spot welding quality identification with particle swarm optimization and a kernel extreme learning machine model. *Int J Adv Manuf Technol*, 91(5-8):1879-1887.
- Tandiya, A., Akhtar, S., Moussa M., Tarry C. 2018.** Automotive semi-specular surface defect detection system. 15th Conference on Computer and Robot Vision, 8-10 May, 2018, Toronto, Canada.
- Thongchai, A., Kawin, S., Phisut, A., Kreangsak, T. 2014.** Resistance Spot Welding Optimization Based on Artificial Neural Network. *Hindawi Publishing Corporation International Journal of Manufacturing Engineering*, 154784, 6.
- Ünal T. 2019.** Bir ve iki katmanlı yapay sinir ağlarının matematiği. *Yüksek Lisans Tezi*, Namık Kemal Üniversitesi, Fen Bilimleri Enstitüsü, Tekirdağ.
- Villanueva, M.B., Salenga, L.M. 2018.** Bitter Melon Crop Yield Prediction using Machine Learning Algorithm. *International Journal of Advanced Computer Science and Applications*, 20(9), 6.
- Wan X., Huang Y., Wang Y., Zhao, D. 2017.** A comparison of two types of neural network for weld quality prediction in small scale resistance spot welding. *Mechanical Systems and Signal Processing*, 93:634-644.

- Wangi X., Zhang Y., Ju J., Zhang J., Yang J. 2016.** Characteristics of Welding Crack Defects and Failure Mode in Resistance Spot Welding of DP780 Steel. *Journal of Iron At Steel Research International* , 23(10):1101- 1110.
- Xing, W., Mingming, W., Jinxia, Z., Jianguo, W. 2020.** Research on Classification Method of Vehicle Body Surface Defects Based on BP Neural Network. *IOP Conf. Series: Materials Science and Engineering*, 740(1):012036.
- Xue, F., Li, F., Li, J., He, M., Yuan, Z. 2013.** Ruiting Wanga, Numerical modeling crack propagation of sheet metal forming based on stress state parameters using XFEM method. *Computational Materials Science*, 69:311–326.
- Ye, S., Guo, Z., Zheng, P., Wang L., Lin, C. 2017.** A Vision Inspection System for the Defects of Resistance Spot Welding Based. 11th International Conference ICVS, July 10–13, Shenzhen, China.
- Yongyan, L., Weimin, Z., Haitao, X., Jian, D. 2012.** Defect Recognition of Resistance Spot Welding Based on Artificial Neural Network. *Software Engineering and Knowledge Engineering: Theory and Practice*, 115(2), 423-430.
- Zhang, Z., Wena, G., Chenb, S. 2019.** Weld image deep learning-based on-line defects detection using convolutional neural networks for Al alloy in robotic arc welding. *Journal of Manufacturing Processes*, 45:208–216.
- Zhao, X., Zhang, Y.S., Che, G.L. 2006.** Ultrasonic fast identification of automotive body spot weld defect based on echo characteristics qualitative analysis. *Science and Technology of Welding and Joining*, 11(6):731-736.
- Zhou X., Nie Y., Wang Y., Cao P., Ye M., Tang Y., Wang Z. 2020.** A Real-time and High-efficiency Surface Defect Detection Method for Metal Sheets Based on Compact CNN. 13th International Symposium on Computational Intelligence and Design (ISCID), 12-13 December, 2020, Hangzhou, China.

EKLER

- EK 1** Tam-faktöriyel Deneysel Veriler (Seçilmiş)
- EK 2** Giriş Parametreleri ve İstatiksel Etki Analizleri
- EK 3** ESA Temel Mimari Yapısı (Punta Hatalarının Evrişimli Sinir Ağları ile Tespit Edilmesi)
- EK 4** ESA Temel Mimari Yapısı (Gazaltı Hatalarının Evrişimli Sinir Ağları ile Tespit Edilmesi)
- EK 5** ESA Temel Mimari Yapısı (Çatlak Hatalarının Evrişimli Sinir Ağlarının Tespit Edilmesi)
- EK 6** ESA Temel Mimari Yapısı (Araç Görsel Hatalarının Evrişimli Sinir Ağları ile Tespit Edilmesi)

EK 1 Tam-faktöriyel Deneysel Veriler (Seçilmiş)

StdOr	RunOr	Cente	Block	Akı	Kuvv	Zama	Soğu	Yaklaş	Bas	SacKal	Punta
4	1	1	1	104	420	8	6	15	15	3	0
64	2	1	1	104	420	36	10	30	35	3	9,44
1	3	1	1	780	180	8	6	15	15	3	0
65	4	0	1	910	300	22	8	22,5	25	1,8	8,2
17	5	1	1	780	180	8	6	30	15	0,6	4,81
48	6	1	1	104	420	36	10	15	35	0,6	5,61
46	7	1	1	104	180	36	10	15	35	3	8,36
25	8	1	1	780	180	8	10	30	15	3	0
32	9	1	1	104	420	36	10	30	15	0,6	7,64
29	10	1	1	780	180	36	10	30	15	0,6	2,93
52	11	1	1	104	420	8	6	30	35	3	0
34	12	1	1	104	180	8	6	15	35	3	0
62	13	1	1	104	180	36	10	30	35	0,6	6,09
16	14	1	1	104	420	36	10	15	15	3	11,08
30	15	1	1	104	180	36	10	30	15	3	8,96
9	16	1	1	780	180	8	10	15	15	0,6	4,41
57	17	1	1	780	180	8	10	30	35	0,6	0

EK 2 Giriş Parametreleri ve İstatiksel Etki Analizleri

Kaynak	D	Adj	Adj	F-	P-	Kaynak	D	Adj	Adj	F-	P-
	F	SS	MS	Value	Value		F	SS	MS	Value	Value
Model	5	911,	16,5	35,02	0	Model	55	911,3	16,5	35,02	0
	5	341	698				4	698			
Lineer	7	151,	21,6	45,69	0	Lineer	7	151,3	21,6	45,69	0
		332	189					18			
Akım	1	43,8	43,8	92,68	0	3-Yollu	26	444,2	17,0	36,11	0
		58	57			Etkileşim	7	87			
Kuvvet	1	4,73	4,73	10,01	0,011	Akım*Kuv	1	17,92	17,9	37,88	0
		6	61			vet*Zaman	5	2			
Zaman	1	36,5	36,5	77,16	0	Akım*Kuv	1	6,598	6,59	13,94	0,005
		12	118			vet*Soğum		8			
						a					
Soğuma	1	10,2	10,2	21,74	0,001	Akım*Kuv	1	7,203	7,20	15,22	0,004
		88	88			vet*Tutma		2			
Yaklaşma	1	27,2	27,2	57,67	0	Akım*Kuv	1	5,17	5,16	10,93	0,009
		88	87			vet*SacKa		9			
						l					

EK 2 Giriş Parametreleri ve İstatiksel Etki Analizleri (Devam)

Tutma	1	0,37	0,37	0,79	0,39	Akım*Za man*Yakl aşma	1	15,51	15,5	32,78	0
		5	52						1		
SacKalınlı ğı	1	28,2	28,2	59,75	0	Akım*Za man*Tutm a	1	88,97	88,9	188,0	0
		7	7						7	2	
2-Yol Etkileşim	2	301,	14,3	30,3	0	Akım*Za man*SacK al	1	16,16	16,1	34,1	0
	1	9	80						6		
Akım*Kuv vet	1	24,7	24,7	52,23	0	Akım*Soğ uma*Yakl aşma	1	4,824	4,82	10,19	0,011
		13	13						35		
Akım*Za man	1	0,00	0,00	0,01	0,91	Akım*Soğ uma*Tutm a	1	67,69	67,6	143,0	0
		6	64					2	918	5	
Akım*Soğ uma	1	38,6	38,6	81,76	0	Akım*Soğ uma*SacK al	1	6,786	6,78	14,34	0,004
		88	88						6		
Akım*Yak laşma	1	76,8	76,8	162,4	0	Akım*Yak laşma*Tut ma	1	2,612	2,61	5,52	0,043
		91	91	9					23		
Akım*Tut ma	1	0,04	0,04	0,1	0,75	Akım*Tut ma*SacKa l	1	18,14	18,1	38,3	0
		7	7						4		
Akım*Sac Kal	1	0,24	0,24	0,52	0,48	Kuvvet*Za man*Soğu ma	1	32,22	32,2	68,0	0
		8	7						1		
Kuvvet*Za man	1	49,9	49,9	105,5	0	Kuvvet*Za man*Yakl aşma	1	2,873	2,87	6,07	0,03
		3	3						3		
Kuvvet*So ğuma	1	14,3	14,3	30,42	0	Kuvvet*Za man*Tutm a	1	19,39	19,3	40,98	0
		9	9					3	9		

EK 2 Giriş Parametreleri ve İstatiksel Etki Analizleri (Devam)

Kuvvet*Tu tma	1	26,4 58	26,4 582	55,91	0	Kuvvet*So ğuma*Sac Kal	1	7,216	7,21	15,25	0,004
Kuvvet*Sa cKal	1	3,04 1	3,04 0	6,43	0,032	Kuvvet*Ba skı*Tutma	1	18,46 9	18,4	39,03	0
Zaman*So ğuma	1	7,43 9	7,43 9	15,72	0,003	Kuvvet*Y aklaşma*S acKal	1	37,54 6	37,5	79,35	0
Zaman*Ya klaşm	1	6,43 3	6,43 26	13,59	0,005	Kuvvet*Tu tma*SacK al	1	12,84 3	12,8	27,14	0,001
Zaman*Tu tma	1	17,2 6	17,2 6	36,48	0	Zaman*So ğuma*Tut ma	1	3,97	3,97	8,39	0,018
Zaman*Sa cKal	1	1,10 8	1,10 7	2,34	0,16	Zaman*So ğuma*Sac Kal	1	7,576	7,57	16,01	0,003
Soguma*Y aklas	1	1,61 6	1,61 6	3,42	0,098	Zaman*Ya klaşma*Tu tma	1	5,319	5,31	11,24	0,008
Soguma*T utma	1	22,8 4	22,8 4	48,29	0	Zaman*Tu tma*SacK al	1	4,07	4,07	8,6	0,017
Soğuma*S acKal	1	6,74 7	6,74 7	14,26	0,004	Soguma*B askı*SacK al	1	6,144	6,14	12,98	0,006
Baskı*Tu tma	1	0,00 7	0,00 6	0,01	0,90	Yaklaşm* Tutma*Sac Kal	1	26,09 9	26,0	55,16	0
Baskı*Sac Kal	1	0,01 4	0,01 3	0,03	0,87	Eğrilik	1	13,74	13,7	29,04	0
Tutma*Sac Kal	1	0,02 4	0,02 4	0,05	0,82	Hata	9	4,259	0,47	3	
						Toplam	64	915,6			

EK 3 ESA Temel Mimari Yapısı (Punta Hatalarının ESA ile Tespit Edilmesi)

	Katman (tip)	Çıktı (Şekil)	Param #
1	konv2d_106	(None, 62, 62, 32)	896
	aktivasyon_80	(None, 62, 62, 32)	0
	maks_havuzlama2d_64	(None, 31, 31, 32)	0
2	konv2d_107	(None, 29, 29, 32)	9248
	aktivasyon_81	(None, 29, 29, 32)	0
	max_havuzlama2d_65	(None, 14, 14, 32)	0
3	konv2d_108	(None, 12, 12, 64)	18496
	aktivasyon_82	(None, 12, 12, 64)	0
	maks_havuzlama2d_66	(None, 6, 6, 64)	0
4	düzleştirme_24	(None, 2304)	0
5	gizli katman_82	(None, 128)	295040
	aktivasyon_83	(None, 128)	0
6	ayırışma_16	(None, 128)	0
7	gizli katman_83	(None, 1)	129
8	aktivasyon_84	(None, 1)	0
	Total parametre: 323.809		
	Eğitilebilir parametre: 323.809		
	Eğitilemez parametre: 0		

EK 4 ESA Temel Mimari Yapısı (Gazaltı Hatalarının ESA ile Tespit Edilmesi)

	Katman(tip)	Çıktı Şekil	Param #
1	konv2d	(None, 62, 62, 32)	896
	Aktivasyon	(None, 62, 62, 32)	0
	maks_havuzlama2d	(None, 31, 31, 32)	0
2	konv2d_1	(None, 29, 29, 32)	9248
	aktivasyon_1	(None, 29, 29, 32)	0
	max_pooling2d_1	(None, 14, 14, 32)	0
3	konv2d_2	(None, 12, 12, 64)	18496
	aktivasyon_2	(None, 12, 12, 64)	0
	maks_havuzlama2d_2	(None, 6, 6, 64)	0
4	Düzleştirme	(None, 2304)	0
	Gizli katman	(None, 128)	295040

	aktivasyon_3	(None, 128)	0
	ayırışma	(None, 128)	0
	Gizli katman 1	(None, 1)	129
5	aktivasyon_4	(None, 1)	0
	Total parametre:	323,809	

EK 5 ESA Temel Mimari Yapısı (Çatlak Hatalarının ESA ile Tespit Edilmesi)

Katman	Katman(tip)	Çıktı Şekil	Param #	
1	Konv	konv2d_15 (Konv2D)	(None, 62, 62, 32)	896
	aktivasyon_Relu	aktivasyon_25 (Aktivasyon)	(None, 62, 62, 32)	0
	Maks_havuzlama	maks_havuzlama2d_15	(MaxPooling (None, 31, 31, 32)	0
2	Konv	konv2d_16 (Konv2D)	(None, 29, 29, 32)	9248
	aktivasyon_Relu	aktivasyon_26 (Aktivasyon)	(None, 29, 29, 32)	0
	Maks_havuzlama	maks_havuzlama2d_16	(MaxPooling (None, 14, 14, 32)	0
3	Konv	konv2d_17 (Konv2D)	(None, 12, 12, 64)	18496
	aktivasyon_Relu	aktivasyon_27 (Aktivasyon)	(None, 12, 12, 64)	0
	Maks_havuzlama	maks_havuzlama2d_17	(MaksHavuzlama (None, 6, 6, 64)	0
4	Düzleştirme_Relu	düzleştirme_5 (Düzleştirme)	None, 2304)	0
5	Gizli katman	Gizli katman_10 (Gizli katman)	(None, 128)	295040
6	aktivasyon_Relu	aktivasyon_28 (Aktivasyon)	(None, 128)	0
7	ayırışma	ayırışma_5 (Ayırışma)	(None, 128)	129
8	aktivasyon_Sigmoid	aktivasyon_29 (Aktivasyon)	(None, 1)	0
	Total parametre:	323,809		

EK 6 ESA Temel Mimari Yapısı (Araç Görsel Hatalarının ESA ile Tespit Edilmesi)

No	Katman (tip)	Çıktı Şekil	Param #
1	konv2d_24	(None, 62, 62, 32)	896
	aktivasyon_32	(None, 62, 62, 32)	0
	toplu_normalleştirme_28	(None, 62, 62, 32)	248
	maks_havuzlama2d_12	(None, 31, 31, 32)	0

	ayırışma_16	(None, 31, 31, 32)	0
2	konv2d_25	None, 29, 29, 64)	18496
	aktivasyon_33	(None, 29, 29, 64)	0
	toplu_normalleştirme_29	(None, 29, 29, 64)	116
3	konv2d_26	(None, 27, 27, 64)	36928
	aktivasyon_34	(None, 27, 27, 64)	0
	toplu_normalleştirme_30	(None, 27, 27, 64)	108
	maks_havuzlama2d_13	(None, 14, 14, 64)	0
	ayırışma_17	(None, 14, 14, 64)	0
4	konv2d_27	(None, 12, 12, 128)	73856
	aktivasyon_35	(None, 12, 12, 128)	0
	toplu_normalleştirme_31	(None, 12, 12, 128)	48
5	konv2d_28	(None, 10, 10, 128)	147584
	aktivasyon_36	(None, 10, 10, 128)	0
	toplu_normalleştirme_32	(None, 10, 10, 128)	40
6	konv2d_29	(None, 8, 8, 128)	147584
	aktivasyon_37	(None, 8, 8, 128)	0
	toplu_normalleştirme_33	(None, 8, 8, 128)	32
	maks_havuzlama2d_14	(None, 4, 4, 128)	0
	ayırışma_18	(None, 4, 4, 128)	0
7	düzleştirme_4	(None, 2048)	0
8	gizli katman_8	(None, 256)	524544
9	aktivasyon_38	(None, 256)	0
	toplu_normalleştirme_34	(None, 256)	1024
10	ayırışma_19	(None, 256)	0
11	gizli katman_9	(None, 2)	514
12	aktivasyon_39	(None, 2)	0
	Toplam parametre: 952.018		
	Eğitim parametresi: 951.210		
	Eğitilemez parametre: 808		

ÖZGEÇMİŞ

Adı Soyadı : İlhan ÇEKİÇ
Doğum Yeri ve Tarihi : 03.01.1975 Bursa
Yabancı Dil : İngilizce

Eğitim Durumu
Lise : Bursa Erkek Lisesi
Lisans : U.Ü.Makina Müh.Bölümü
Yüksek Lisans : U.Ü.Fen Bilimleri Ens. İmalat Kons.Ana Bilim Dalı

Çalıştığı Kurum/Kurumlar : Tofaş A.Ş.

İletişim (e-posta) : i_cekic@hotmail.com

Yayımları :

Çekiç, İ., Çavdar, K. 2020. Building Up Mathematical Modeling Using Spot Welding Parametres and Prediction Weld Nugget by Minitab. *European Mechanical Science*.
<https://dergipark.org.tr/tr/journal/1866/article/837829/author/production>

Çekiç, İ. Çavdar, K. 2022. Sac metal yırtıklarının evrişimli yapay sinir ağları ile tespit edilmesi. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*.
<https://dergipark.org.tr/tr/journal/339/article/873479/author/production>