



**T.C.
BURSA TEKNİK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**

**ENDÜSTRİYEL ÜRETİM HATLARINDA YAPAY ZEKÂ DESTEKLİ
KALİTE KONTROL SİSTEMİNİN GELİŞTİRİLMESİ**

YÜKSEK LİSANS TEZİ

Elif Aydan BİKE

Akıllı Sistemler Mühendisliği Anabilim Dalı

Akıllı Sistemler Mühendisliği Tezli Yüksek Lisans Programı

KASIM 2024

**T.C.
BURSA TEKNİK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**

**ENDÜSTRİYEL ÜRETİM HATLARINDA YAPAY ZEKÂ DESTEKLİ
KALİTE KONTROL SİSTEMİNİN GELİŞTİRİLMESİ**

YÜKSEK LİSANS TEZİ

**Elif Aydan BİKE
22434998010
ORCID: 0000-0003-0249-9522**

**Akıllı Sistemler Mühendisliği Anabilim Dalı
Akıllı Sistemler Mühendisliği Tezli Yüksek Lisans Programı**

**Danışman: Doç. Dr. Gökay BAYRAK
ORCID: 0000-0002-5136-0829**

KASIM 2024

BTÜ, Lisansüstü Eğitim Enstitüsü'nün 22434998010 numaralı Yüksek Lisans / Elif Aydan BİKE, ilgili yönetmeliklerin belirlediği gerekli tüm şartları yerine getirdikten sonra hazırladığı “ENDÜSTRİYEL ÜRETİM HATLARINDA YAPAY ZEKÂ DESTEKLİ KALİTE KONTROL SİSTEMİNİN GELİŞTİRİLMESİ” başlıklı tezini aşağıda imzaları olan jüri önünde başarı ile sunmuştur.

Tez Danışmanı : **Doç. Dr. Gökay BAYRAK**
Bursa Teknik Üniversitesi

Jüri Üyeleri : **Doç. Dr. Ömer Faruk EFE**
Bursa Teknik Üniversitesi

Doç. Dr. Didem GÜLERYÜZ ÖZDEN
Bayburt Üniversitesi

Teslim Tarihi :
Savunma Tarihi : 26.11.2024



20.04.2016 tarihli Resmi Gazete’de yayımlanan Lisansüstü Eğitim ve Öğretim Yönetmeliğinin 9/2 ve 22/2 maddeleri gereğince; Bu Lisansüstü teze, Bursa Teknik Üniversitesi’nin abonesi olduğu intihal yazılım programı kullanılarak Lisansüstü Eğitim Enstitüsü’nün belirlemiş olduğu ölçütlere uygun rapor alınmıştır.

Bu tez, TÜBİTAK TEYDEB 1501 Sanayi Ar-Ge Projeleri Destekleme Programı kapsamında (Proje No: 3220867) desteklenmiştir. TÜBİTAK’a desteklerinden dolayı teşekkür ederiz.

İNTİHAL BEYANI

Bu tezde görsel, işitsel ve yazılı biçimde sunulan tüm bilgi ve sonuçların akademik ve etik kurallara uyularak tarafımdan elde edildiğini, tez içinde yer alan ancak bu çalışmaya özgü olmayan tüm sonuç ve bilgileri tezde kaynak göstererek belgelediğimi, aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul ettiğimi beyan ederim.

Öğrencinin Adı Soyadı: Elif Aydan BİKE

İmzası:



Eşime ve oğluma,

ÖNSÖZ

Bu çalışma, TÜBİTAK TEYDEB 1501 Sanayi Ar-Ge Projeleri Destekleme Programı kapsamında (Proje No: 3220867) “Otomotiv ve Savunma Sanayi Üretim Hatlarındaki Parçaların Dalgacık Dönüşümü Tabanlı Yapay Görme Sistemi ile Otomatik Kontrolü” isimli proje ile desteklenmiştir. TÜBİTAK’a desteklerinden dolayı teşekkür ederiz. Tez çalışmasına desteklerinden dolayı başta tez danışmanım Doç. Dr. Gökay BAYRAK’a ve ERBAB Otomat Yedek Parça San. ve Tic. Genel Müdürü Ufuk ERDOĞAN’a ve KARSAN’a teşekkür ederim.

Kasım 2024

Elif Aydan BİKE

İÇİNDEKİLER

Sayfa

1. GİRİŞ	1
1.1 Tezin Amacı	1
1.2 Literatür Araştırması	2
1.3 Hipotez	7
2. KALİTE KONTROL UYGULAMALARINDA YAPAY GÖRÜ SİSTEMLERİ	8
2.1 Yapay Görü İle İlgili Genel Bilgiler.....	8
2.1.1 Görüntü alma ve ön işleme	9
2.1.1.1 Kamera	10
2.1.1.2 Lens	10
2.1.1.3 Aydınlatma.....	11
2.2 Makine Öğrenmesi Yöntemleri.....	11
2.2.1 Öznitelik çıkarma	12
2.2.2 Sınıflandırma.....	13
3. ÖNERİLEN YAPAY GÖRÜ SİSTEMİ.....	14
3.1 Ölçümsel Hataların Tespiti İçin Yapay Görme Sistemi.....	14
3.1.1 LabVIEW NI Vision Builder	15
3.1.2 Vision Builder fonksiyon bloklarının işlevi.....	16
3.2 Görsel Hataların Tespiti İçin Yapay Görme Sistemi	21
3.2.1 Veri seti	22
3.2.2 Eğitim.....	24
4. ÖNERİLEN YAPAY ZEKÂ TEMELLİ KONTROL SİSTEMLERİ	26
4.1 Sistemin Genel Blok Şeması	26
4.2 Özellik Çıkarma Yöntemleri	27
4.2.1 Örnek indirgenmemiş dalgacık dönüşümü (UWT).....	27
4.2.2 Sürekli dalgacık dönüşümü (CWT)	29
4.2.3 Ayrık dalgacık dönüşümü (DWT)	31
4.3 Sınıflandırma Yöntemleri.....	32
4.3.1 Derin öğrenme (DL) kullanan yöntem.....	32
4.3.2 Makine öğrenmesi yöntemleri ile entegrasyon	34
4.3.2.1 Destek vektör makineleri (SVM)	34
4.3.2.2 K- en yakın komşu (KNN).....	37
4.3.2.3 Karar ağacı (DT)	39
4.3.2.4 Yapay sinir ağı (YSA).....	41
4.3.2.5 Gradyan arttırma (GB).....	43
5. DENEYSEL SONUÇLAR.....	46
5.1 Ölçümsel Sonuçlar	46
5.2 UWT'ye Göre Sonuçlar.....	54
5.3 CWT'ye Göre Sonuçlar.....	58

5.4 DWT'ye Göre Sonuçlar.....	61
6. SONUÇ VE TARTIŞMA.....	64
ÖZGEÇMİŞ.....	68



KISALTMALAR

AI	: Automated Inspection
ANN	: Artificial Neural Network
CSP	: Cross Stage Partial
CWT	: Continuous Wavelet Transform
DL	: Deep Learning
DNN	: Deep Neural Network
DT	: Decision Tree
DWT	: Discrete Wavelet Transform
GB	: Gradient Boosting
GPU	: Graphics Processing Unit
HSL	: Hue, Saturation, Lightness
KNN	: K-Nearest Neighbors
LDA	: Linear Discriminant Analysis
LSTM	: Long Short-Term Memory
ML	: Machine Learning
MSE	: Mean Squared Error
NOK	: Not Okay
OCR	: Optical Character Recognition
OK	: Okay
PCA	: Principal Component Analysis
R-CNN	: Region-Based Convolutional Neural Network
RGB	: Red, Green, Blue
RNN	: Recurrent Neural Network
SVM	: Support Vektor Machine
UWT	: Undecimated Wavelet Transform
YSA	: Yapay Sinir Ağları
YZ	: Yapay Zekâ

SEMBOLLER

A^1	: Gizli katmanın aktivasyon çıktıları
b^1	: Gizli katmanın bias vektörü
b^2	: Çıktı katmanın bias vektörü
W^1	: Girdi katmanı ile gizli katman arasındaki ağırlık matrisi
W^2	: Girdi katmanı ile çıktı katman arasındaki ağırlık matrisi
$\hat{y}$	: Yeni veri noktasının tahmini sınıfı veya regresyon çıktısı
Z^1	: Gizli katmanın ağırlıklı girişleri
Z^2	: Çıktı katmanının ağırlıklı girişleri
A	: Ölçek parametresi
B	: Zaman kaydırma parametresi
F	: Frekans
X	: Giriş verileri matrisi (n, m) (n örnek sayısı, m girdi özellik sayısı)
Λ	: Dalga boyu
Ξ	: Sınıflar arasındaki hata veya marjinal hata
Σ	: Girişlerin çıktılarına dönüştürülmesi için kullanılan aktivasyon fonksiyonu
Ψ	: Faz

ÇİZELGE LİSTESİ

	<u>Sayfa</u>
Çizelge 3.1: Vision builder ön işlem fonksiyonları	17
Çizelge 4.1 : YOLOv5 karşılaştırma tablosu.....	34
Çizelge 5.1 : Kontrol edilen parçalara ilişkin üst ölçüm sonuçları.....	49
Çizelge 5.2 : Kontrol edilen parçalara ilişkin yan ölçüm sonuçları.....	49
Çizelge 5.3 : Birinci test ölçüm sapmaları.....	49
Çizelge 5.4 : İkinci test ölçüm sapmaları.....	51
Çizelge 5.5 : Üçüncü test ölçüm sapmaları.	53
Çizelge 5.6 : UWT uygulanmış sonuçlar.....	55
Çizelge 5.7 : CWT uygulanmış sonuçlar.....	59
Çizelge 5.8 : DWT uygulanmış sonuçlar.....	62
Çizelge 6.1 : Karşılaştırma tablosu.....	66

ŞEKİL LİSTESİ

Sayfa

Şekil 2.1 : Geliştirilen yapay görme kontrol sistemi temel prensip şeması.	10
Şekil 2.2 : Makine öğrenmesi yöntemlerinin bir sınıflandırması.	12
Şekil 3.1 : Axis ve gerçek değer girdi ekranı.....	19
Şekil 3.2 : Beş fotoğrafın ortalama değerinin hesaplanması	19
Şekil 3.3 : (a) FCE fonksiyonu, (b) FCE fonksiyonu ile daire tespiti.	20
Şekil 3.4 : Parçanın uygun-uygun değil kontrolü ara yüzü.	20
Şekil 3.5 : (a)Üst kamera görüntüsü ölçümü, (b) yan kamera görüntüsü ölçümü.	21
Şekil 3.6 : LabVIEW VI arayüzü için oluşturulan algoritma	21
Şekil 3.7 : Tezde geliştirilen yapay zekâ algoritması temel yapısı.....	22
Şekil 3.8 : Etiketleme sayıları.....	24
Şekil 3.9 : Kabin içi ölçüm işlemi	24
Şekil 3.10 : (a) Etiketlenmiş çapak görseli, (b) etiketlenmiş deformasyon görseli. ...	25
Şekil 4.1 : Tez çalışmasında kullanılan makine öğrenmesi yönteminin aşamaları ..	28
Şekil 4.2 : Darknet53 ve CSP-Darknet53 karşılaştırması.....	35
Şekil 4.3 : SVM ayırım grafiği.	36
Şekil 4.4 : Karar ağacı genel yapısı.	41
Şekil 4.5 : YSA tek katmanlı yapı.	43
Şekil 5.1 : Birinci tip örnek parça hata tespiti.	47
Şekil 5.2 : İkinci tip örnek parça hata tespiti.	47
Şekil 5.3 : İkinci tip (alt görünüm) örnek parça hata tespiti.	48
Şekil 5.4 : Birinci test uygulanan parametreler sonra alınan görüntü.....	49
Şekil 5.5 : İkinci test uygulanan parametreler sonra alınan görüntü.	51
Şekil 5.6 : Üçüncü test uygulanan parametreler sonra alınan görüntü.	52
Şekil 5.7 : SVM hata matrisi.	56
Şekil 5.8 : UWT ve KNN hata matrisi.....	56
Şekil 5.9 : YSA model sonuçları.	57
Şekil 5.10 : YSA metodu ile saptanan çapaklı parça.....	57
Şekil 5.11 : YSA metodu ile saptanan deformasyonlu parça.	58
Şekil 5.12 : UWT ve DT hata matrisi.	58
Şekil 5.13 : UWT ve GB hata matrisi.....	59
Şekil 5.14 : SVM hata matrisi.	60
Şekil 5.15 : KNN hata matrisi.	59
Şekil 5.16 : DT hata matrisi.....	60
Şekil 5.17 : GB hata matrisi.....	60
Şekil 5.18 : SVM hata matrisi.	62
Şekil 5.19 : KNN hata matrisi.	64
Şekil 5.20 : DT hata matrisi.....	64

ENDÜSTRİYEL ÜRETİM HATLARINDA YAPAY ZEKÂ DESTEKLİ KALİTE KONTROL SİSTEMİNİN GELİŞTİRİLMESİ

ÖZET

Görüntü işleme teknolojisi, otomotiv başta olmak üzere bir çok sektörde kullanılmakta ve gün geçtikçe teknolojik altyapısı gelişmektedir. Özellikle imalat sektöründe, ürünlerin kalitesini sağlamak ve üretim süreçlerini optimize etmek için görüntü işleme sistemleri sıkça kullanılır. Üretilen parçaların yüzeylerinin incelenmesi, pürüzlülük, çatlaklar, delikler veya diğer kusurların tespit edilmesi için görüntü işleme teknolojisi kullanılmaktadır. Kamera sistemleri, ürün yüzeylerini yüksek çözünürlüklü görüntülerle tarar ve algoritmalar, belirlenen kriterlere uygun olmayan herhangi bir kusuru tespit eder. Üretilen parçaların boyutları ve geometrisi, görüntü işleme teknolojisi kullanılarak ölçülür. Kamera sistemleri, parçaların belirli ölçülere ve toleranslara uygun olup olmadığını kontrol eder ve herhangi bir sapma tespit ederse uyarı verir. Bunlara ek olarak montaj hattında, parçaların doğru monte edilip edilmediği, etiket doğruluğu ve benzeri bir çok üretim ve kontrol aşamasında görüntü işleme teknolojisi yaygın bir şekilde kullanılmaktadır. Bu tezde, makine öğrenmesi yöntemlerinden yararlanarak endüstriyel parçalar üzerindeki hataların saptanması ve sınıflandırılması için uygun yöntemlerin geliştirilmesi hedeflenmiştir. Öncelikle üretim hattındaki parçaların ölçümsel hatalarının bulunması amacı ile belirlenen toleranslara uygun bir kalite yapay görü kontrol sistemi geliştirilmiştir. Daha sonra parça üzerindeki çizik ve çapak problemleri için toplam 2650 adet görüntüden oluşan bir veri seti oluşturulmuştur. Bu veri setinde hatasız, çizik ve çapak olmak üzere 3 temel sınıf oluşturulmuştur. Veri setinin %80'i eğitim ve %20'si test olarak seçilerek sırasıyla DWT, CWT ve UWT dalgacık dönüşümü yöntemleri uygulanmıştır. Öznitelikleri elde edilen görüntüler farklı tip sınıflandırıcılara giriş olarak verilerek en uygun makine öğrenmesi yönteminin elde edilmesine çalışılmıştır. Öznitelik çıkarma işlemleri sonrasında, yapay sinir ağları, destek vektör makineleri, k-en yakın komşu ve karar ağacı gibi sınıflandırıcı metotları denenmiş ve test edilmiştir. Daha sonra, derin öğrenme yaklaşımı ile parça görüntülerinden elde edilen temel dokusal özellikler kullanarak daha ayırt edici özellikler elde edilmeye çalışılmıştır. Tez çalışması sonucunda, endüstriyel parçaların 0,003 ile 0,05 arası sapma ile boyutsal olarak kontrolleri gerçekleştirilmiştir. UWT ve DT kombinasyonu ile gerçekleştirilen makine öğrenmesi yöntemi ise %98,2 başarı ile endüstriyel parçalardaki görsel kusurları tespit edilerek sınıflandırma yapabilmektedir. Derin öğrenme sürecinde ise Gabor Filtresi ile elde edilen görüntüler YOLOv5 kullanılarak eğitilmiş, çizik ve çapak hatalarının yüksek doğruluk ile sınıflandırılması sağlanmıştır. Tez çalışmasında geliştirilen hem ölçüsel kontrol hem de yapay zekâ temelli kontrol yöntemleri, endüstriyel üretim hatları çıkışındaki parçaların kalite kontrolü için pratikte uygulanabilir bir çözüm sunmaktadır.

Anahtar kelimeler: Makine Öğrenmesi, Yapay Görü, Endüstri 4.0, Derin Öğrenme, Kalite Kontrol

DEVELOPMENT OF ARTIFICIAL INTELLIGENCE-SUPPORTED QUALITY CONTROL SYSTEM IN INDUSTRIAL PRODUCTION LINES

SUMMARY

Image processing technology is used in many industries, especially in the automotive sector, and its technological infrastructure continues to develop day by day. In the manufacturing sector, image processing systems are frequently utilized to ensure product quality and optimize production processes. Image processing technology is used to inspect the surfaces of manufactured parts and detect defects such as roughness, cracks, holes, or other imperfections. Camera systems scan product surfaces with high-resolution images, and algorithms detect any flaws that do not meet predetermined criteria. The dimensions and geometry of manufactured parts are measured using image processing technology. Camera systems check whether parts conform to specified dimensions and tolerances, issuing warnings in case of any deviation. In addition, image processing technology is widely used on assembly lines in various production and control stages, such as verifying whether parts are correctly assembled or ensuring label accuracy. This thesis aims to develop suitable methods for detecting and classifying defects on industrial parts by leveraging machine learning techniques. Initially, a vision-based quality control system was developed to identify dimensional defects in parts according to predefined tolerances. Subsequently, a dataset comprising 2,650 images was created to address issues such as scratches and burrs on parts. This dataset was divided into three main classes: defect-free, scratched, and burr-containing. 80% of the dataset was used for training, while 20% was reserved for testing. DWT, CWT and UWT methods were applied to the images. The features extracted from the images were fed into various types of classifiers to determine the most effective machine learning method. After the feature extraction process, classification methods such as artificial neural networks, support vector machines, k-nearest neighbors and decision trees were tested and evaluated. Subsequently, a deep learning approach was employed to obtain more distinctive features using the basic textural properties extracted from part images. As a result of the study, dimensional inspections of industrial parts were performed with deviations ranging between 0.003 and 0.05. The machine learning method implemented using a combination of UWT and DT achieved a 98.2% success rate in detecting and classifying visual defects in industrial parts. In the deep learning process, images obtained using Gabor filters were trained with the YOLOv5 model, enabling the high-accuracy classification of scratches and burrs. The methods developed in this thesis, including both dimensional control and AI-based defect detection, provide a practical and applicable solution for quality control of parts at the output stage of industrial production lines.

Keywords: Machine learning, Computer Vision, Industry 4.0, Deep Learning, Quality Control.

1. GİRİŞ

1.1 Tezin Amacı

Otomotiv ve savunma sanayi başta olmak üzere, endüstrinin birçok alanında beklentiler gün geçtikçe artmaktadır. Ancak insana bağlı tüm süreçler hata oluşumuna ve bu hataların gözden kaçmasına zemin hazırlamaktadır. İnsan doğasından kaynaklanan bu hataları önlemek için akıllı sistemlere olan ilgi de giderek artmaktadır. Geleneksel üretim ve kalite kontrol süreçleri, insana bağlı sistemlerdir. Bu nedenle, endüstriyel tesislerde geleneksel yöntemler yerine akıllı sistemlerin kullanımı daha yaygın hale gelmektedir. Bu amaca yönelik olarak, endüstriyel ürünlerin daha üretimi tamamlanmadan çıkabilecek hataların tespit edilmesi ve kalitesizlik maliyetlerinin minimize edilmesi gerekmektedir.

Bu çalışmada, otomotiv ve savunma sanayisi için talaşlı imalat yöntemi ile yedek parça üretimi yapan bir firmanın üretimindeki parçaların, endüstriyel üretim hattında ölçüsel ve görsel kontrollerinin yapılması hedeflenmiştir. Firma, üretiminde paslanmaz ağırlıklı hammaddeler kullanmaktadır ve paslanmaz malzeme ülkemize ithal yollarla gelen, kilogram fiyatı en yüksek olan çelik malzemedir. Üretimde farkedilemeyen veya müşteri montaj hattında farkedilen her hatanın geri dönüşü, firmada büyük maddi kayıplara sebep olmaktadır. Firmalar için maliyetler, yeniden işlem süreçleri ve benzeri zararların yanında, en önemli zararlardan bir tanesi de endüstriyel üretim hattındaki parçalardan kaynaklanan hatalardır. Bu nedenle firmada ciddi itibar ve güven problemleri de oluşmaktadır. Tüm bu etkenler ele alındığında firmanın akıllı sistemler kullanılarak üretim ve kalite süreçlerini insan insiyatifinden çıkarması zorunluluk haline gelmiştir. Tezde yapılan çalışma ile endüstriyel parçalar üretim hattının çıkışında, geliştirilen PLC tabanlı otomasyon sistemi ile uygun konuma ve temizliğe getirilerek, önerilen yapay görü sisteminin ölçüsel ve deformasyona bağlı kalite kontrol hatalarının tespiti için hazır hale getirilmektedir. Geliştirilen yapay görü sistemi, 2 adet kamera, aydınlatma sistemi, kapalı bir kabin, endüstriyel tip bir

bilgisayar ve LabVIEW NI Vision Builder ve Python'da geliştirilen yazılımlardan oluşacak şekilde tasarlanmıştır. Yapay görü sistemine gelen konumlandırılmış ve temizlenmiş endüstriyel parçalar, LabVIEW NI Vision Builder AI tabanlı geliştirilen yazılımla ölçüsel kontrollere tabi tutulmuştur. Ölçüsel olarak uygun olan parçalar, ikinci aşamada yapay zekâ temelli kontrol sistemi

yazılımı tarafından hatasız, çapaklı ve çizikli olacak şekilde 3 sınıfta değerlendirilmiştir.

Endüstriyel parça üzerindeki çizik ve çapak problemleri için toplam 2650 adet görüntüden oluşan bir veri seti oluşturulmuştur. Bu veri setinde hatasız, çizik ve çapak olmak üzere 3 temel sınıf oluşturulmuştur. Veri setinin %80'i eğitim ve %20'si test olarak seçilerek sırasıyla DWT, CWT ve UWT dalgacık dönüşümü yöntemleri uygulanmıştır. Öznitelikleri elde edilen görüntüler farklı tip sınıflandırıcılara giriş olarak verilerek en uygun makine öğrenmesi yönteminin elde edilmesine çalışılmıştır. Öznitelik çıkarma işlemleri sonrasında, yapay sinir ağları, destek vektör makineleri, k-en yakın komşu ve karar ağacı gibi sınıflandırıcı metotları denenmiş ve test edilmiştir. Daha sonra, derin öğrenme yaklaşımı ile parça görüntülerinden elde edilen temel dokusal özellikler kullanarak daha ayırt edici özellikler elde edilmeye çalışılmıştır.

Tez çalışması sonucunda, endüstriyel parçaların 0,003 ile 0,05 arası sapma ile boyutsal olarak kontrolleri gerçekleştirilmiştir. UWT ve DT kombinasyonu ile gerçekleştirilen makine öğrenmesi yöntemi ise %98,2 başarı ile endüstriyel parçalardaki görsel kusurları tespit edilerek sınıflandırma yapabilmektedir. Derin öğrenme sürecinde ise Gabor Filtresi ile elde edilen görüntüler YOLOv5 kullanılarak eğitilmiş, çizik ve çapak hatalarının yüksek doğruluk ile sınıflandırılması sağlanmıştır.

1.2 Literatür Araştırması

İmalat sektörü, veri bilimi ve yapay zekâ (YZ) teknolojilerinin ilerlemesiyle önemli bir dönüşüm yaşamaktadır. Derin öğrenmeyi de içeren YZ teknikleri, fabrikaların daha verimli, esnek ve akıllı üretim süreçleri hedeflerine ulaşmalarına yardımcı olmaktadır. Sektördeki hayati konulardan biri de endüstriyel üretim hatlarındaki parçalardaki hatalarını önlemek için YZ'yi otomatikleştirmek ve kullanmaktır. Metal parçalardaki yüzey kusurlarının tespit edilmesi, üretim süreçlerindeki kalite kontrolün önemli bir parçasıdır. Ancak geleneksel kalite kontrol yöntemleri pratikte çeşitli zorluklara yol

açmaktadır. YZ, bu zorlukların üstesinden gelme ve daha hassas ve verimli kusur tespiti sağlama potansiyeline sahiptir. Sektörün gelecekteki ana hedeflerinden birisi de üretimde otomasyon ve kalite sistemlerindeki kontrolün iyileştirilmesi için pratik ve etkili çözümlerin bulunmasıdır. Bu nedenle, Endüstri 4.0 hedefleri doğrultusunda yapılacak yenilikçi kalite kontrol çalışmalarına ihtiyaç duyulmaktadır. Otomotiv sektörü, endüstriyel ürünlerin kalite kontrolünde yenilikçi yapay görü yaklaşımlarını ve kalite kontrolü ile endüstriyel üretimde sıfır hata ile üretiminin yaygınlaşmasını hedeflemektedir.

Sensör montaj hattındaki hataların tespiti için yapılan bir çalışmada [1], YOLOv3 kullanılarak nesne tespiti yapılmıştır. Çalışmada, anomali tespiti için makine öğrenmesi algoritması olan otokodlayıcı (Autoencoder) ile sapma tespit edilmiştir. PoC'de kullanılan model anomali algılama modeli, 2 gizli evrişimli katmana sahip bir otokodlayıcıdır ve MSE (ortalama kare hatası) kayıp fonksiyonu ile eğitilmiştir. Parçaların yaklaşık %16'sı uygun (OK) veya uygun olmayan (NOK) olarak doğru bir şekilde sınıflandırılabilmiştir. Görüntü işleme teknolojisi, çeşitli sektörlerde yaygın olarak kullanılan ve sürekli gelişen bir teknolojidir. Başka bir çalışmada [2], Endüstri 4.0 uyumlu bir yapay görme sistemi geliştirilerek otomotiv üretim hatlarında 3D parçaların kalite kontrolü sağlanmıştır. Elde edilen sonuçlar, düşük hata oranlarıyla etkili bir kalite kontrol sistemi oluşturulduğunu göstermektedir. Çalışmada görüntü işleme için LabVIEW NI Vision Builder AI (Automated Inspection) kullanılmıştır. Görüntü işleme teknolojisiyle, parçalar için uygun yazılım altyapısı oluşturulmuş ve yapılan piksel tabanlı ölçümler ve morfolojik işlemler sonucunda hata oranı %0,04'ten daha düşük seviyelerde gerçekleştirilmiştir. Bu sonuçlar, kalite kontrol ve ölçüm işlemlerinin çok düşük hata oranlarıyla başarıyla gerçekleştirildiğini göstermektedir.

Yapay görü ile kalite kontrolü konusunda yapılan başka bir çalışmada [3], görsel kalite kontrol süreçlerini geliştirmeye yönelik otomatik hata tespit sistemi üzerine bir çalışma yapılmıştır. Çalışmada, işlenmiş bir metal parçanın görüntüsü alındıktan sonra, RGB'den HSL'ye dönüştürme işlemi yapılmış ve kalite kontrolü, logo tanımlama üzerine kurulu bir desen eşleştirme tekniği kullanılarak gerçekleştirilmiştir. Logo tanımlama işleminden sonra, çizik hatalarının tespiti ve miktarlarının belirlenmesi sağlanmıştır. Yüzeydeki hataların tespiti histogram eşleştirme normalizasyonu ile gerçekleştirilmiştir. QR kodu okuma işlemi gerçekleştirilerek deliklerin algılanması ve ölçümü yapılmıştır. Optik Karakter Tanıma (OCR) işlemi

için eğitim kümesi oluşturulmuş ve tanıma işlemi başarıyla gerçekleştirilmiştir. Son olarak, kenar tespiti için basit kenar tespit yöntemi ve Hough dönüşümü kullanılmıştır. Bu altı adımlı kalite kontrol süreci, işlenmiş metal parçasının üretim süreçlerinde başarıyla uygulanan kalite kontrol yöntemlerini göstermektedir.

Otomotiv sektöründeki kalite kontrol süreçlerindeki iyileştirme ihtiyacı, uygulamada birçok kalite kontrol çalışmasının gerçekleştirilmesini sağlamıştır. Araç tamponlarındaki yüzey kusurlarını otomatik olarak tespit edebilen bir çalışmada [4], görüntü işleme ve yapay zekâ teknikleri kullanılarak tamponlardaki kusurları tespit edebilen bir derin öğrenme algoritması geliştirilmiştir. Bu otomatik kontrol sistemi, insan kaynaklı hataları ortadan kaldırmayı, çevrim süresini azaltmayı ve üretimde verimliliği artırmayı hedeflemektedir. Çalışmada, nesne tespiti için Faster R-CNN modeli kullanılmıştır. Toplamda 600 eğitim, 70 doğrulama ve 70 test fotoğrafıyla yaklaşık %80-10-10 oranında bir train-test-validasyon ayrımı yapılmıştır. Modelin eğitimi için Tensorflow kütüphanesi kullanılarak GPU üzerinde gerçekleştirilmiştir. Eğitim verisi, LabelImg programı kullanılarak kusurların koordinatlarıyla etiketlenmiştir. Otomotiv endüstrisinde mekanik parçalar üreten bir firma için yapılan çalışmada [5], ise görsel hata kontrol sistemi Python dilinde uygulanmış ve OpenCV kütüphanesinden yararlanılarak yapay görü sistemi geliştirilmiştir. Sadece üretimden çıkan parçalar değil, montaj ve ek operasyonlardaki doğruluğun tespiti için de yapılan çalışmalar olmuştur. Bunlardan birisi [6], kaynak operasyonu sonrası yüzeyde kaynak kusurlarının derin öğrenme metodu kullanılarak ayrılması ve sınıflandırılması üzerine yapılan bir çalışmadır. Çalışmadaki görsellere ilk olarak KNN yöntemi uygulanarak ısı haritası analizi yapılmış ve renklere göre OK-NOK etiketlemesi gerçekleştirilmiştir. Oluşturulan veri seti, makine öğrenmesi sınıflandırıcılarından gradient boosting, decision tree ve support vector machine algoritmalarına tabi tutulmuştur. İki kaynak türünde yapılan çalışmada, XGBoost ile %99,3 ve SVM ile de %98,7 başarımlar sağlanmıştır.

Veri bilimi ve YZ, otomotiv sektörü başta olmak üzere birçok alanda yaygınlaşmış ve kullanılmaya başlanmıştır. Demiryolu sistemlerinde kullanılan YZ tabanlı bir bilgisayarlı yapay görü uygulamasında [7], denetimsiz öğrenme prensipleri kullanılarak ray yüzey kusurlarının tespit edilmesi amaçlanmıştır. ImageNet verileri ile önceden eğitilmiş Vgg16 ve MobileNetV3 ağırları kullanılarak, gerçekte sağlam olan etiketsiz ray görüntüleri ile alt katmanların eğitimi gerçekleştirilmiştir. Daha sonra,

sağlam ray görüntülerinin özelliklerini öğrenen ağlara, ilk kez verilen test görüntüleri kullanılarak kusur (anomali) tespiti yapılmıştır. yüzey kusurlarının tespitinde, önerilen yöntem ile %98 doğruluk oranı elde edilmiştir. Başka bir çalışmada [8], robot kolunun çevresindeki nesneleri tespit etmek ve onlara göre hareket etmesini sağlamak için görüntü işleme ve YZ teknikleri kullanılmıştır. Bu kapsamda, görüntülerin arka planları U2-Net YZ modeli kullanılarak eğitilmiş ve nesnelerin renklerine göre sınıflandırma yapılmıştır. Bu bilgiler kullanılarak robot kol, belirlenen renklere ait nesnelerin konumlarını tespit edip, nesneleri belirlenen hedef konumlara yerleştirmiştir.

Derin öğrenme, insan beyninin işleyişini taklit eden bir makine öğrenmesi alt dalıdır ve son on yılda birçok sektörde yaygın olarak kullanılmaya başlamıştır. Büyük veri kümelerinden karmaşık desenleri tespit edebilme yeteneği, özellikle kalite kontrolü ve üretim süreçlerinde kusur tespiti gibi çeşitli uygulamalarda önemli bir araç haline gelmiştir. Derin öğrenme yaklaşımı, endüstriyel parçaların görüntülerinden elde edilen temel dokusal özellikleri kullanarak daha ayırt edici özellikler elde etmeye çalışır. Özellikle, yapay sinir ağları (YSA) ve derin sinir ağları (DNN) sınıflandırmada başarılı sonuçlar vermiştir. Evrişimli sinir ağları (CNN) ise özellikle nesne algılama ve sınıflandırmada popülerdir. Son yıllarda derin öğrenme temelli sınıflandırma çalışmaları önemli ölçüde artmıştır.

Kazaya uğrayan veya kaybolan insanların tespit edilmesi için derin öğrenme yöntemleri olan YOLOv4 ve YOLOv4-tiny algoritmalarını kullanan bir çalışmada [9], elde edilen acil durum tespit başarı oranları mAP cinsinden %97,91 ve %99,04 olarak belirlenmiştir. Bir başka çalışmada [10], derin öğrenme tekniklerine odaklanarak, plastik endüstrisinde kalite kontrolü ve kusur tespiti yapılmıştır. İmalatta otomatik görsel kontrol süreçlerinde yaygın olarak kullanılan bir mimari ise CNN'ler, özelliklerin uzamsal hiyerarşilerini otomatik ve uyumlu bir şekilde öğrenebilme yetenekleriyle, görüntü tanıma ve sınıflandırma görevlerinde mükemmel performans göstermiştir. Mekanik ürün radyasyon görüntüsü otomatik tespiti ve sınıflandırması için çift görüntü pozlama tekniği önerilen bir çalışmada [11], deney için "kusurlular" ve "kusursuzlar" arasındaki kesintiler göstergeler olarak alınmış ve yarı denetimli öğrenme teknolojisi kullanılarak elde edilen sınıflandırıcı test verileri %88,6 doğruluk oranına ulaşmıştır.Yapılan farklı çalışmalarda [12,13], bir görüntü arka planından histogram eşleme yöntemi kullanılarak mekanik ürünlerin kusurları tespit edilmiştir.

Bir diğerk çalışmada [14], görüntü işleme sırasındaki aydınlatma yöntemi doğruluk oranını artırmak için dikkate alınmıştır.

CNN'ler zaman serileri gibi zamansal dizilerle başa çıkarken bazı zorluklar yaşamaktadır. İşte bu noktada, Tekrarlayan Sinir Ağları (RNN'ler) ve türevi olan Uzun Kısa Süreli Bellek (LSTM) ağları devreye girer. Geleneksel RNN'lerin uzun vadeli bağımlılık sorununu çözmek için LSTM ağları geliştirilmiştir [15]. LSTM ağları, zaman serisi verilerin işlenmesinde ve tahmin edilmesinde üstün performans göstermiştir [15]. Bu yöntemi kullanan bir çalışmada [16], uçak motorlarının sensör verilerine dayalı olarak kalan kullanım ömrünü tahmin etmek için LSTM ağları kullanılmıştır. Plastik enjeksiyon kalıplama sürecinde gerçek zamanlı kusur tespiti ve sınıflandırması için de RNN ve LSTM ağları kullanılmıştır [17]. Ancak, bu çalışmalar genellikle belirli kusur tiplerine veya üretim sürecinin tek bir aşamasına odaklanmıştır. Kusur tespiti kadar, kusurların oluşumuna katkıda bulunan faktörlerin belirlenmesi de sürecin optimize edilmesi açısından önemlidir. Birçok çalışma, ürün kalitesi ile imalat parametrelerini ilişkilendirmeye yönelik geleneksel istatistiksel yöntemler kullanmıştır. Ancak, bu yöntemler genellikle çoklu değişkenler arasındaki karmaşık ve doğrusal olmayan ilişkilerle başa çıkamaz. Son zamanlarda, araştırmacılar bu amaçla derin öğrenmenin kullanımını keşfetmeye başlamışlardır. Bu çalışmalardan birinde [18], sac metal şekillendirme sürecinde çeşitli işlem parametrelerinin ürün kalitesine etkisini analiz etmek için derin öğrenme modeli uygulanmıştır. Model, değişkenler arasındaki doğrusal olmayan ilişkileri tanımlayabilmiş ve böylece sürecin optimize edilmesi için derin öğrenmenin potansiyelini göstermiştir. Özetle, mevcut literatürde, derin öğrenmenin imalat süreçlerinde kusur tespiti için son yıllarda kullanıldığı görülmektedir. [19-21].

Bu tez çalışmasında, endüstriyel üretim hatlarındaki metal parçaların yüzey kusurlarının tespiti için yapay zekâ tabanlı öğrenme algoritmalarının geliştirilmesi hedeflenmiştir. Otomotivde kullanılan bağlantı parçaları ele alınarak öncelikle ölçme odaklı geliştirilen LabVIEW yazılımı kullanılarak, parçaların ölçüsel doğrulukları girilen tolerans kısıtları ile karşılaştırılarak ölçümleri yapılmıştır. Ölçüm sonrası alınan OK/NOK sinyalleri doğrultusunda, modelin gelişmiş nesne algılama yetenekleri ile yüksek doğruluk ile hata tespitinin yapılmasına çalışılmıştır. Endüstriyel parça üzerindeki çizik ve çapak problemleri için toplam 2650 adet görüntüden oluşan bir veri seti oluşturulmuştur. Bu veri setinde hatasız, çizik ve çapak olmak üzere 3 temel sınıf

oluşturulmuştur. Veri setinin %80'i eğitim ve %20'si test olarak seçilerek sırasıyla DWT, CWT ve UWT dalgacık dönüşümü yöntemleri uygulanmıştır. Öznitelikleri elde edilen görüntüler farklı tip sınıflandırıcılara giriş olarak verilerek en uygun makine öğrenmesi yönteminin elde edilmesine çalışılmıştır. Tezden elde edilen sonuçların, sektörün gelecekteki ana hedeflerinden biri olan üretimde otomasyon, Endüstri 4.0 ve kalite kontrolün iyileştirilmesi için pratik ve etkili bir çözüm sunması hedeflenmiştir. İzleyen bölümler, bu çalışmanın metodolojisini ve bulgularını detaylandırmaktadır.

1.3 Hipotez

Bu çalışmanın hipotezi, talaşlı imalat süreçlerinden elde edilen parçalarda meydana gelen ölçüsel hatalar, çapak ve deformasyonların tespit edilmesinde YZ tekniklerinin etkin bir şekilde kullanılabileceği yönündedir. YZ algoritmalarının, büyük veri setleri üzerinde eğitilerek, parçaların yüzeylerindeki çapak ve deformasyonları tespit etme yeteneğine sahip olduğu bilinmektedir. İncelemelerin ve çalışmanın yapıldığı firma incelendiğinde, yapılan %100 kontrollerin insan insiyatifine bağlı olması ve üretim tamamlandıktan sonra toplu halde yapılması nedeniyle kalitesizlik ve hata maliyetlerinin yüksek olduğu gözlemlenmiştir. Dolayısıyla çözüm bulma noktasında, bu tez çalışması, YZ tekniklerinin talaşlı imalat süreçlerindeki kalite kontrolünü geliştirmek için kullanılabilirliğini değerlendirmeyi amaçlamıştır. Bu hipotez, YZ destekli bir kalite kontrol sisteminin, üretim süreçlerindeki hataları saptama ve düzeltme süreçlerini optimize ederek, maliyetleri azaltabileceği ve ürün kalitesini artırabileceği varsayımına dayanmaktadır.


Tez çalışması boyunca farklı öznitelik ve sınıflandırıcılar birbiri ile eşleştirilerek ve karşılaştırılarak kullanılmış ve en uygun makine öğrenmesi yöntemlerinin elde edilmesi hedeflenmiştir. Ayrıca derin öğrenme yöntemleri ile de hataların tespitine çalışılmıştır. Elde edilen sonuçların literatüre yenilikçi bir yaklaşım kazandıracağı, üretim hatlarında gelişimin artacağı düşünülmektedir.

2. KALİTE KONTROL UYGULAMALARINDA YAPAY GÖRÜ SİSTEMLERİ

2.1 Yapay Görü İle İlgili Genel Bilgiler

Yapay görü sistemleri kalite kontrol uygulamalarında yaygın olarak kullanılan önemli bir teknolojidir. Bu sistemler genellikle görüntü işleme ve makine öğrenmesi tekniklerini kullanarak üretim süreçlerinde kusurları tespit etmek için tasarlanmıştır. Yapay görü sistemleri ile oluşturulan teknolojiler kalite kontrol uygulamalarında yaygın bir şekilde kullanılmaktadır.

Otomatik görüntü işleme ve kontrol sisteminin geliştirilmesinde, endüstriyel tip kamera, lens, ağ kartı, aydınlatma sistemi, kontrolcü (PLC) ve endüstriyel PC gibi bileşenler kullanılmıştır. Tezde yapılan çalışma ile endüstriyel parçalar üretim hattının çıkışında, geliştirilen PLC tabanlı otomasyon sistemi ile uygun konuma ve temizliğe getirilerek, önerilen yapay görü sisteminin ölçüsel ve deformasyona bağlı kalite kontrol hatalarının tespiti için hazır hale getirilmektedir. Geliştirilen yapay görü sistemi, 2 adet kamera, aydınlatma sistemi, kapalı bir kabin, endüstriyel tip bir bilgisayar ve LabVIEW NI Vision Builder ve Python'da geliştirilen yazılımlardan oluşacak şekilde tasarlanmıştır. Yapay görü sistemine gelen konumlandırılmış ve temizlenmiş endüstriyel parçalar, LabVIEW NI Vision Builder AI tabanlı geliştirilen yazılımla ölçüsel kontrollere tabi tutulmuştur. Ölçüsel olarak uygun olan parçalar, ikinci aşamada YZ temelli kontrol sistemi yazılımı tarafından hatasız, çapaklı ve çizikli olacak şekilde 3 sınıfta değerlendirilmiştir. Şekil 2.1 geliştirilen yapay görme kontrol sistemi temel prensip şemasını göstermektedir.



Şekil 2.1 : Geliştirilen yapay görme kontrol sistemi temel prensip şeması.

2.1.1 Görüntü alma ve ön işleme

Yapay görü sistemindeki ilk adım, ürünün veya iş parçasının görüntüsünün bir kamera veya sensör aracılığıyla alınmasıdır. Bu adımda, görüntü işleme sistemleri kullanılarak dijital bir görüntü elde edilir. İlk olarak, parçanın veya nesnenin görüntüsünün kamera veya sensör kullanılarak alınması gereklidir. Matematiksel olarak, bu adım Denklem (2.1)'deki gibi ifade edilebilir:

$$I(x,y) = f(O(x,y)) + n(x,y) \quad (2.1)$$

Bu denklemde $I(x,y)$ dijital görüntü, $O(x,y)$ parça veya nesnenin optik özellikleri, f görüntü işleme fonksiyonu ve son olarak $n(x,y)$ görseldeki gürültüdür.

Alınan görüntüler ön işleme adımında düzeltme, görüntüyü azaltmak ve kontrast ayarı gibi morfolojik yöntemlerin uygulanması ve ayarlanması gibi aşamalara tabi tutulur. Ön işleme adımı çeşitli filtreler ve işlemler kullanılarak gerçekleştirilir.

$$I_{\text{filtreli}}(x,y) = m \{ I(x+i,y+j) | i=-r, \dots, r; j=-r, \dots, r \} \quad (2.2)$$

Denklem (2.2)'de, $I_{\text{filtreli}}(x,y)$ filtre uygulanmış görüntü, m uygulanmak istenen filtrenin adı, r filtre boyutu ve $I(x+i,y+j)$ görüntünün belirlenen piksel değerini ifade etmektedir.

Görüntü işleme ve ön işlem aşamalarında başarılı sonuç alınabilmesi için kamera, lens, aydınlatma gibi unsurlar önemli bir rol oynamaktadır. Bu bölümde geliştirilen yapay görü sisteminde kullanılan bileşenler açıklanmıştır.

2.1.1.1 Kamera

Görüntü işleme teknolojisinde kullanılan kameraların önemli özellikleri arasında çözünürlük, görüş alanı, odak uzunluğu, görüntü sensörü boyutu, hız ve bağlantı arayüzü bulunmaktadır. Çözünürlük, görüntüdeki ayrıntı seviyesini belirlerken, görüş alanı kameraların aynı anda görebileceği alanı ifade eder. Odak uzunluğu ise kameranın odaklanma mesafesini belirler. Görüntü sensörü boyutu, kameranın ışık toplama yeteneğini ve görüntü kalitesini belirlerken, hız kameraların kaç kare/saniye hızında görüntü yakalayabileceğini ifade eder. Bağlantı arayüzleri ise kameranın veri aktarım hızını ve entegrasyon kolaylığını belirler. Mevcut durumda yazılım geliştirme çalışmaları ELP 4K USB3.0 marka-model kamera ile gerçekleştirilmiştir. 3840x2160 pixel çözünürlük sağlaması sayesinde parçanın detaylı görüntüleri net bir şekilde elde edilebilmiştir. Ayrıca bu çözünürlükte 30fps yüksek kare hızı sağlamaktadır. Farklı resim formatlarını (MJPEG/YUY2(YUYV)) desteklemektedir.

2.1.1.2 Lens

Kamera seçimi sonrasında uygun bir lens seçimi gerekmektedir. Lensin çalışma direnci, görüş alanı ve sensor boyutuna göre belirlenir. Lensin odak uzaklığını belirlemek için; görüntü ve nesne boyutları ile görüntü ve nesne mesafeleri arasındaki ilişkinin ifade edilmesi gerekmektedir. Lensin odak uzaklığı;

$$\frac{1}{f} = \frac{1}{B} + \frac{1}{G} \quad (2.3)$$

Denklem (2.3)'te, f lensin odak uzaklığı, B görüntü boyutu, G nesne boyutunu ifade etmektedir.

Kullanılan lens odak uzaklığı 3.5-18mm olan 3Mp çözünürlükte manuel bir iris lenstir. Lens seçiminde parçaya olan uzaklık en önemli kriterdir. Burada mümkün olan en optimum netlik ve görüntünün elde edilmesi sağlanmalıdır. Bu nedenle kullanılan lens daha hassas ayarlama yapabilmek için odak uzaklığı manuel değiştirilebilen özellikte seçilmiştir. Aynı zamanda parçanın tamamını görüntü içerisine alabilecek, 104°'lik bir yatay görüş açısına sahiptir.

2.1.1.3 Aydınlatma

Kamera ve lens seçiminin doğru yapılması tek başına yeterli olmamaktadır. Bu nedenle görüntü işleme çalışmalarında aydınlatma çok önemli bir unsurdur. Aydınlatma üç tipten oluşmaktadır. Bunlar: yapay aydınlatma, doğal aydınlatma ve kombine aydınlatmadır. Görüntü işleme ile kontrol süreçlerinde en uygun çeşit yapay aydınlatmadır. Yapay aydınlatma, yapay ışık kaynaklarının kullanılması ile sağlanır. Floresan, LED, halojen lamba ve çeşitleri yapay aydınlatmaya örnek olarak gösterilebilir. Kullanılan yapay aydınlatma sistemleri ön, arka, fiber-optik ve yapısal aydınlatma olarak dörde ayrılır.


Aydınlatma genişliği, bir ışık kaynağının bir yüzeye ne kadar homojen bir şekilde ışık yaydığını belirtir. Aydınlatma genişliği genellikle lux (lx) birimiyle ölçülür ve yüzeyin birim alanı üzerindeki ışık yoğunluğunu ifade eder. Matematiksel olarak, aydınlatma genişliği Denklem (2.4)'te şu şekilde ifade edilir:

$$E = \frac{F}{A} \quad (2.4)$$

Burada, E aydınlatma genişliği (lux, lx), F yüzeye düşen ışık akısı (lümen, lm), A, yüzey alanı (metrekare, m²) olarak ifade edilir. Bu denklem, bir yüzeyin belirli bir alandaki ışık yoğunluğunu hesaplamak için kullanılır. Daha yüksek bir aydınlatma genişliği, daha fazla ışığın yüzeye düştüğünü ve dolayısıyla daha parlak bir ortamın sağlandığını gösterir. Çalışmada şerit LED uygulaması ile yapay aydınlatma tekniği kullanılarak, metal parçaların parlamasından kaynaklanan sorunların önüne geçilmesi amaçlanmıştır.

2.2 Makine Öğrenmesi Yöntemleri

Makine öğrenmesi, bilgisayar sistemlerinin veri analizi yaparak desenleri tanınması ve bu desenlere dayalı olarak gelecekteki kararlar alabilmesi için algoritmalar geliştirmesini sağlayan bir YZ alt dalıdır. Bu algoritmalara veri verilir ve bu verilerden örüntüler çıkarılır. Makine öğrenmesi, genellikle gözetimli öğrenme, gözetimsiz öğrenme ve takviyeli öğrenme olmak üzere üç ana kategoride incelenir. Şekil 2.2 makine öğrenmesi yöntemlerinin bir sınıflandırmasını göstermektedir.



Şekil 2.2 : Makine öğrenmesi yöntemlerinin bir sınıflandırması.

2.2.1 Öznitelik çıkarma

İşlenmiş görüntülerden bu adımda belirli özelliklerin (kenar, köşe, yoğunluk değişiklikleri vb.) çıkarılması gerekmektedir. Makine öğrenmesinde, öznitelik çıkarma çeşitli yöntemlerle gerçekleştirilir. Temel öznitelikler, veri kümesinden doğrudan elde edilen basit özelliklerdir. Boyut azaltma yöntemleri, veri setinin boyutunu azaltarak öznitelik çıkarma işlemini gerçekleştirir ve bunlar arasında PCA ve LDA gibi yöntemler bulunur. Derin öğrenme tabanlı öznitelik çıkarımı, evrişimli sinir ağları (CNN) veya yinelemeli sinir ağları (RNN) gibi karmaşık sinir ağı mimarilerini kullanarak öznitelikleri otomatik olarak çıkarır. Özellikle görsel ve doğal dil işleme gibi alanlarda başarılıdır. Frekans alanı yöntemleri, verinin frekans alanında analiz edilmesine dayanır ve Fourier dönüşümü gibi yöntemlerle ses veya sinyal verilerinden özniteliklerin çıkarılmasını sağlar. Sınıflandırıcı tabanlı yöntemlerde, belirli bir sınıflandırıcı modelin öğrenme süreci içinde öznitelikler çıkarılır. Örneğin CNN modelindeki katmanlarından öznitelikler elde edildikten sonra sınıflandırıcıya sokulur.

Tez çalışmasında ise dalgacık dönüşümü yöntemleri kullanılarak görüntülerin öz nitelikleri çıkarılmıştır. Sürekli dalgacık dönüşümü (CWT), ayrık dalgacık dönüşümü (DWT) ve örnek indirgenmiş dalgacık dönüşümü (UWT) kullanılarak, farklı

sınıflandırıcılar ile performansları incelenmiştir. Böylece elde edilen veri setinin eğitilmesinde en yüksek doğruluğa sahip makine öğrenmesinin elde edilmesi amaçlanmıştır.

2.2.2 Sınıflandırma

Öznitelikleri çıkarılan verilerin, makine öğrenmesi metodu ile sınıflandırıcıya giriş olarak verilmesi işlemidir. Bu model, uygun ve uygun olmayan girdileri ayırt etmek için kullanılır. Matematiksel olarak, sınıflandırıcılar genellikle karar sınırlayıcı kullanımı ile gerçekleştirilir.

$$y = \begin{cases} 1, & \text{eğer } w^T x + b > 0 \\ 0, & \text{diğer} \end{cases} \quad (2.5)$$

Denklem (2.5)'te, y çıktı sınıfı, w ve b modelin parametreleri, x girdi öznitelik vektörünü temsil etmektedir.

Makine öğrenmesi ile sınıflandırma işlemi verinin bir sınıfa veya kategoriye ayrılmasıdır. Bu kategoriler veya sınıflar etiketler kullanılarak bilinir ve önceden tanımlandırılarak sisteme yüklenir. Sınıflandırma işleminde, girdi verisi ile ilişkilendirilen çıktı etiketi ve sınıfı tahmin etmeyi amaçlar. Makine öğrenmesi ile sınıflandırma için yaygın olarak kullanılan algoritmalarından bazıları, destek vektör makineleri (SVM), karar ağaçları ve random forest, k-en yakın komşu (KNN), yapay sinir ağları (ANN), naive bayes ve lojistik regresyon olarak sayılabilir. Her yöntem, veri setinin yapısına ve sınıflandırma problemine göre farklı avantajlar ve dezavantajlar sağlar. Bu nedenle uygun sınıflandırma yönteminin seçilmesi için veri seti ve problemin gerekliliklerinin doğru analiz edilmesi gerekmektedir. Yapılan çalışmada başlıca SVM, DT, KNN ve YSA yöntemleri kullanılarak sonuçlar karşılaştırılmıştır.

Sistem, otomotiv ve savunma sanayi üretim hatlarından çıkan parçaların, yapay görme ve yapay zekâ tabanlı görüntü işleme sistemleri ile otomatik olarak hata tespitinin yapılması ve hatalı olarak tespit edilen parçaların otomatik olarak hattan ayrılmasını hedeflemektedir.

3. ÖNERİLEN YAPAY GÖRÜ SİSTEMİ

Tezde yapılan çalışma ile endüstriyel parçalar üretim hattının çıkışında, geliştirilen PLC tabanlı otomasyon sistemi ile uygun konuma ve temizliğe getirilerek, önerilen yapay görü sisteminin ölçüsel ve deformasyona bağlı kalite kontrol hatalarının tespiti için hazır hale getirilmektedir. Geliştirilen yapay görü sistemi, 2 adet kamera, aydınlatma sistemi, kapalı bir kabin, endüstriyel tip bir bilgisayar ve LabVIEW NI Vision Builder ve Python'da geliştirilen yazılımlardan oluşacak şekilde tasarlanmıştır. Yapay görü sistemine gelen konumlandırılmış ve temizlenmiş endüstriyel parçalar, LabVIEW NI Vision Builder AI tabanlı geliştirilen yazılımla ölçüsel kontrollere tabi tutulmuştur. Ölçüsel olarak uygun olan parçalar, ikinci aşamada yapay zekâ temelli kontrol sistemi yazılımı tarafından hatasız, çapaklı ve çizikli olacak şekilde 3 sınıfta değerlendirilmiştir.

Tezde kalite kontrolü iki ana başlık altında ele alınmıştır:

- 1) Ölçümsel hataların (çap, en, boy, kontür vb.) tespiti için yapay görme sistemi,
- 2) Görsel hataların (çizik ve çapak) tespiti için yapay görme sistemi'dir.

3.1 Ölçümsel Hataların Tespiti İçin Yapay Görme Sistemi

Önerilen ilk prototipte, standart kamera sistemleri ile hem maliyeti düşürebilmek hem de verimliliği artırabilmek adına %0,5-%1 seviyelerindeki hata oranında çalışabilecek akıllı bir yapay görme sisteminin geliştirilmesi planlanmıştır. Planlanan ikinci prototip için ise geliştirilen makine öğrenmesi ve derin öğrenme metotları ile hatalı parçaların tespiti ve sınıflandırılması hedeflenmiştir. İlk prototipten elde edilen veriler ile üretimde kontrol edilecek parçaların veri seti oluşturulmuş, daha sonra önerilen makine öğrenmesi yöntemlerinden performansı en yüksek olanlar araştırılmıştır. Elde edilen veri setleri ile makine öğrenmesi algoritması eğitilerek sistemin karar mekanizması oluşturulmuştur. Farklı hatlardan çıkan farklı parçaların kontrolünün, makine öğrenmesi tabanlı algoritmalar ile otomatik şekilde gerçekleştirilmesi de amaçlanmıştır.

Üretim hattından çıkan parçaların fotoğraflarının alınarak veri setinin oluşturulması ve test süreci için, özel olarak geliştirilmiş, tamamen dış ortamdan izole edilmiş ve her seferinde parçanın kameranın önünde ölçüm için aynı konuma gelebileceği kapalı bir kabin tasarlanmıştır.

Yapısal yaklaşımlar: Bu yaklaşımlar, hataları, dokusal bileşenlerin bir kombinasyonu olarak görür. Dokunun analizi, özelliklerin belirlenmesi ve kuralların çıkarılmasıyla gerçekleştirilir. Hatalı bölge, temel dokusal yapıların birleşimiyle tanımlanabilir. Bu yöntem, belirgin hataları tespit etmede etkilidir ancak genelde güvenilirliği düşüktür.

İstatistiksel yaklaşımlar: Bu yaklaşım, dokusal özelliklerin çıkarılması için istatistiksel yöntemler kullanır. Eşleşme matrisleri, histogram özellikleri ve matematiksel morfoloji gibi yöntemlerle hata sınıflandırması yapılır. Literatürde, çapraz korelasyon, istatistiksel momentler ve kenar tespiti gibi farklı istatistiksel yaklaşımlar da bulunmaktadır.

Yapay zekâ tabanlı yaklaşımlar: Bu yaklaşımlar, hata tespiti için parça görüntülerinden elde edilen temel dokusal özellikleri kullanır. Destek Vektör Makineleri (SVM) gibi sınıflandırıcılar ve yapay sinir ağları (YSA'lar) bu yöntemler arasındadır. Derin sinir ağları (DNN'ler), özellikle sınıflandırmada üstün performans gösterir ve dalgacık dönüşümü gibi tekniklerle elde edilen özelliklerin DNN'lerle sınıflandırılması popülerdir. Özellikle evrişimli sinir ağları (CNN'ler), nesne algılama ve sınıflandırmada büyük ilgi görmüştür ve derin öğrenme tabanlı sınıflandırma çalışmaları literatürde artmaktadır.

3.1.1 LabVIEW NI Vision Builder

LabVIEW NI Vision Builder görüntü işleme ve görüntü analizi uygulamaları geliştirmek için kullanılan bir yazılım paketidir. LabVIEW, National Instruments tarafından geliştirilmiş bir programlama ortamıdır ve genellikle veri akışı tabanlı programlama kullanır. Vision Builder, LabVIEW'in bir modülü olarak görüntü işleme ve analizi için geliştirilmiş bir yazılım aracıdır. Vision Builder, görsel programlama ve sürükle-bırak araçlarıyla kullanıcılara görüntü işleme uygulamaları oluşturma ve çalıştırma imkanı sağlar. Vision Builder'da kullanılan bir çok yöntem yöntem vardır. Görüntü alma ve ön işlem yönteminde, görüntü yakalama, renk analizi, kenar algılama, filtre ve morfolojik işlemler bulunur. Nesne tanıma özelliğinde, nesnelerin algılanması, sınıflandırma, konumlandırma ve takip etme işlemleri yer almaktadır.

Optik karakter tanıma (OCR), görüntülerdeki metnin tanınması ve çözme için kullanılır. Örneğin belge tanıma, etiket okuma vb. ölçüm yöntemi ile nesnenin boyutları, uzaklıkları ve açıları ölçülebilir. Yaptığımız çalışmada LabVIEW programının görüntü işleme ve ölçüm yöntemleri kullanılmıştır.

3.1.2 Vision Builder fonksiyon bloklarının işlevi

Vision Builder fonksiyon blokları, kullanıcıların belirli bir görüntü işleme uygulaması için gerekli olan işlevleri kolayca entegre etmelerini sağlar. Vision Builder'in sağladığı işlev blokları, kullanıcıların hızlı prototipleme ve uygulama geliştirme süreçlerini hızlandırır ve kolaylaştırır.

Bu fonksiyonlardan ayrıntılı bir şekilde bahsetmek gerekirse, kamera veya diğer görüntüleme cihazlarından görüntüleri yakalamak için “acquire image” fonksiyonu kullanılır. Bu fonksiyon kullanılan görüntü parametrelerini ayarlama ve işleme gibi seçenekler sunar. Alınan görüntüler işleme, analiz, filtreleme ve özellik çıkarma gibi işlemleri kolaylaştırmak için “vision assistant” fonksiyonu kullanılır ve görüntü tabanlı uygulamaların hızlı bir şekilde geliştirilmesini sağlar. İşleme, filtreleme vb süreçler tamamlandıktan sonra “calibrate image” kalibrasyon fonksiyonu kullanılarak renk, parlaklık, ölçüler noktalar arası uzaklık vb. özelliklerin kalibrasyon süreçleri için kullanılır. Çizelge 3.1, Vision Builder ön işlem fonksiyonlarını ve işlevlerini göstermektedir.


Çizelge 3.1 : Vision Builder ön işlem fonksiyonları.

Sembol	Sembol Adı	İşlevi
	Acquire Image	Kamera veya diğer görüntüleme cihazlarından görüntüleri yakalamak, görüntü parametrelerini ayarlamak ve işlemek
	Vision Assistant	Alınan görüntüleri işleme, analiz, filtreleme

Çizelge 3.1(devam) : Vision Builder ön işlem fonksiyonları.


Sembol	Sembol Adı	İşlevi
	Calibrate Image	Kalibrasyon fonksiyonu kullanılarak renk, parlaklık, ölçüler noktalar arası uzaklık vb. özelliklerin kalibrasyon süreçleri için kullanılır
	Calculator	Hesap Makinesi Foksiyonu
	Set Inspection Status	Parça için tüm değerlerin doğruluğunun kontrolü ve parçanın uygun yada uygun olmadığı durumu görmek için kullanılır
	Custom Overlay	Parçanın OK veya NOK olma durumunda ilgili ölçüler için değer sonuçlarının gözlemlenmesi için kullanılır

Vision Builder kullanılarak ölçüm yapılması için öncelikle ölçüm yapılacak mesafenin x ve y ekseninde işaretlenmesi ve piksel değeri ile gösterilen mesafe ölçüsünün istenilen ölçüm cinsi üzerinden karşılığı belirtilmelidir. Yapılan çalışmada ölçümlerin mm olarak karşılığı, axislerin belirlenmesi ve ölçüm karşılığının sisteme girilmesi için yapılan kalibrasyon işlemi Şekil 3.1’de gösterilmektedir.




Şekil 3.1 : Axis ve gerçek değer girdi ekranı.

Çizelge 3.1’de gösterilen “calculator” hesap makinesi fonksiyonu kullanılarak, parçanın anlık beş adet ölçümünün ortalama değerleri alınarak, parlama, titreşim ve aydınlatma nedeni ile oluşabilecek hataların önüne geçilmesi amaçlanmıştır. Beş fotoğrafın ortalamasının hesaplanması için oluşturulan kod Şekil 3.2’de gösterilmiştir. Bu hesaplama sonrasında sistem çıkan değeri, girilen tolerans limitleri ile karşılaştırıp, parçanın ilgili ölçüsü için OK veya NOK sinyali vermektedir.



Şekil 3.2 : Beş fotoğrafın ortalama değerinin hesaplanması

Ölçüm noktaları belirlenen parçada eğer çap ölçümü yapılacak ise dairesel kenarların bulunması için daire kenarlarını bulma fonksiyonu (FCE) kullanılır. Bu fonksiyon dairenin kenarlarını algılar ve belirler. Şekil 3.3 FCE fonksiyonu ile daire tespiti işlemini göstermektedir.



Şekil 3.3 : (a) FCE fonksiyonu, (b) FCE fonksiyonu ile daire tespiti.

Görüntünün kamera ile alınması, morfolojik ve kalibrasyon işlemlerinden sonra, yazılım üzerinden parça ölçümleri otomatik olarak gerçekleştirilmiştir. Ancak anlık alınan görüntülerde titreşimden kaynaklanan yanlış ölçümlerin olabildiği tespit edilmiştir. Bu nedenle ölçümün doğruluğunu arttırmak için aynı parçadaki tüm ölçümleri ardışık olarak beş kere fotoğraflayıp, alınan ölçümlerin ortalaması nihai sonuç olarak kabul edilmiştir.


Ölçümler yapıldıktan sonra, ilgili ölçüler için OK ve NOK sinyalleri alındıktan sonra, parçanın tüm verilen kısıtlar için doğruluğu da kontrol edilmelidir. Parça için tüm değerlerin doğruluğunun kontrolü ve parçanın uygun ya da uygun olmadığı durumu görmek için Çizelge 3.1’de gösterilen “set inspection status” işlevi kullanılmıştır. Parçanın OK veya NOK olma durumunda ilgili ölçüler için değer sonuçları da kullanıcılar için önem arz etmektedir. Bu durumda kullanıcılar için kolaylık sağlayan Çizelge 3.1’de simge resmi gösterilmiş olan “custom overlay” fonksiyonu kullanılır ve bu fonksiyon sayesinde Şekil 3.4’teki gibi ölçüm sonuçları rahatlıkla gözlemlenebilir.

Ölçüm	Referans
Çap 1: 19,291 mm	19,30 ± 0,05mm
Çap 2: 12,990 mm	12,98 ± 0,03mm
Çap 3: 9,633 mm	9,63 ± 0,03mm
PARÇA DURUMU	OK

Şekil 3.4 : Parçanın uygun-uygun değil kontrolü ara yüzü.


Yapılan çalışmada, Şekil 3.5’te görüldüğü gibi parçanın yandan ve üstten görüntüsü ele alınarak iki farklı ölçüm işlemi gerçekleştirilmiştir. Bu ölçümler sonucunda

parçanın uygun olup olmadığı durumlar için OK (uygun) ve NOK (uygun değil) sinyali oluşturulmuştur.



Şekil 3.5 : (a) Üst kamera görüntüsü ölçümü, (b) yan kamera görüntüsü ölçümü.

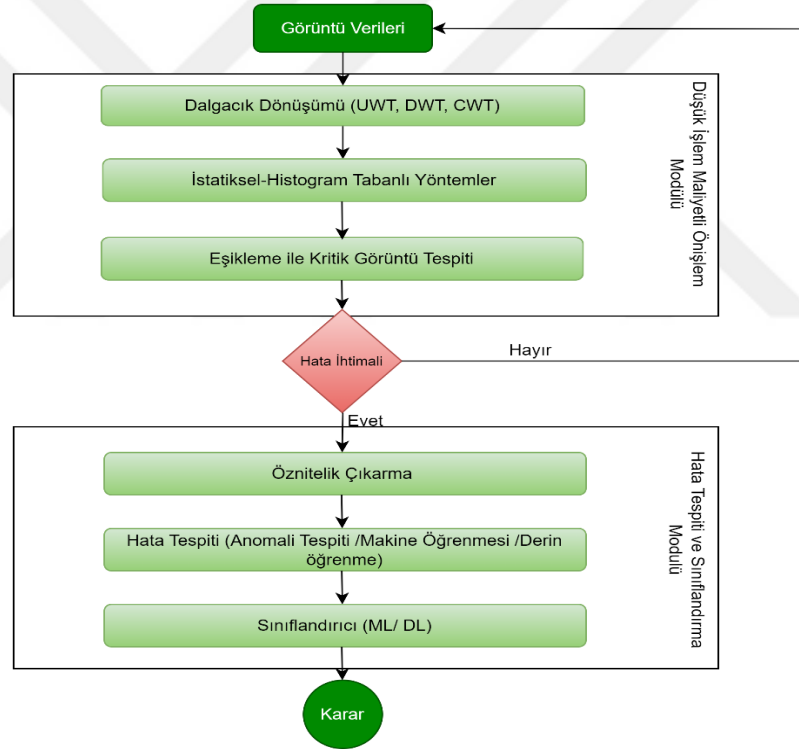
Vision Builder tarafından oluşturulan ölçüm ve görüntü işleme sonuçları LabVIEW'de .VI uzantılı dosya haline getirildikten sonra, çıktı sinyalleri olan OK veya NOK sinyallerine göre sistem Python tarafına aktarılarak sınıflandırma işlemleri yapılmıştır. LabVIEW'de VI oluşturmak için geliştirilen yazılımın algoritması Şekil 3.6'da gösterilmiştir.



Şekil 3.6 : LabVIEW VI arayüzü için oluşturulan algoritma.

3.2 Görsel Hataların Tespiti İçin Yapay Görme Sistemi

Ölçüsel olarak uygun olan parçalar, ikinci aşamada yapay zekâ temelli kontrol sistemi yazılımı tarafından hatasız, çapaklı ve çizikli olacak şekilde 3 sınıfta değerlendirilmiştir. Endüstriyel parça üzerindeki çizik ve çapak problemleri için toplam 2650 adet görüntüden oluşan bir veri seti oluşturulmuştur. Bu veri setinde hatasız, çizik ve çapak olmak üzere 3 temel sınıf oluşturulmuştur. Veri setinin %80'i eğitim ve %20'si test olarak seçilerek sırasıyla DWT, CWT ve UWT dalgacık dönüşümü yöntemleri uygulanmıştır. Öznitelikleri elde edilen görüntüler farklı tip sınıflandırıcılara giriş olarak verilerek en uygun makine öğrenmesi yönteminin elde edilmesine çalışılmıştır. Tezde geliştirilen yapay zekâ algoritmasının temel yapısı Şekil 3.7'de gösterilmiştir.



Şekil 3.7 : Tezde geliştirilen yapay zekâ algoritması temel yapısı.

Öznitelik çıkarma işlemleri sonrasında, yapay sinir ağları, destek vektör makineleri, k-en yakın komşu ve karar ağacı gibi sınıflandırıcı metotları denenmiş ve test edilmiştir. Daha sonra, derin öğrenme yaklaşımı ile parça görüntülerinden elde edilen temel dokusal özellikler kullanarak daha ayırt edici özellikler elde edilmeye çalışılmıştır.

Derin öğrenme sürecinde ise Gabor Filtresi ile elde edilen görüntüler YOLOv5 kullanılarak eğitilmiş, çizik ve çapak hatalarının yüksek doğruluk ile sınıflandırılması sağlanmıştır.

Hata tipi kullanılarak kök nedenle ilgili çıkarımlar yapılarak, sistemin operasyonu ile ilgili karar verilmiştir. Ayrıca hatalı olduğu belirlenen görüntüler bulut ortamında ya da firmanın yerel sunucularında kaydedilerek arşivlenmiştir. Bu görüntülerin ilerideki çalışmalar için saklanması yerinde olacağı düşünülmüştür.


3.2.1 Veri seti

Veri seti oluşturmak, çalışmanın temel adımlarından biridir ve başarılı bir yapay zekâ veya veri bilimi projesi için oldukça önemlidir. Çalışmanın veri setinin oluşturulması için öncelikle, hedefler ve gereksinimler netleştirilmelidir. Hangi tür verilere ihtiyaç olduğu, hangi tür özelliklerin öğrenilmek istendiği ve modelin ne tür bir performans sergilemesinin beklediği belirtilerek çalışma başlatılmalıdır.

Veri toplama sürecinde periyodik örnek alma yöntemi uygulanmış ve her vardiya bitiminde, tezgahtan alınan parçalar uygun, çapaklı ve deformasyonlu olarak ayrı kutulara koyulmuştur. Vardiya bitiminde ayrılan parçaların resimleri kabin içinde çekilmiş ve kalite birimine teslim edilmiştir. Verileri toplarken, tezin amacına uygun, çeşitli bir veri seti elde etmeye özen gösterilmiştir.

Toplanan verileri temizleme ve ön işleme adımları uygulanmıştır. Eksik veya bozuk veriler eleme, aykırı değerleri düzeltme veya kaldırma, verileri normalleştirme veya ölçekleme gibi işlemlere tabi tutulmuştur. Verileri düzenlemek ve standart hale getirmek, modelin doğru bir şekilde öğrenmesine yardımcı olacaktır.

Veri seti üzerinde etiketleme işlemleri yapılmıştır. Etiketleme sayıları Şekil 3.8’de sunulmuştur. Bu yaklaşım, her bir veri örneğinin doğru şekilde etiketlendiğinden ve kategorize edildiğinden emin olmak için önemlidir. Özellikle denetimli öğrenme projelerinde, her veri örneğiyle birlikte doğru etiketlerin bulunması gerekmektedir.



Şekil 3.8: Etiketleme sayıları.


Endüstriyel parça üzerindeki çizik (deformasyonlu) ve çapak problemleri için toplam 2650 adet görüntüden oluşan bir veri seti oluşturulmuştur. Bu veri setinde hatasız, çizik ve çapak olmak üzere 3 temel sınıf oluşturulmuştur. Otomotiv ve savunma sanayiye talaşlı imalat yapan bir firmanın üretim hattından alınan 1800 adet uygunsuz, 850 adet te uygun parçanın, veri seti ve test süreci için test kabini içerisinde görüntüleri alınmıştır. Firmada üretilen parçalar metal olması nedeniyle ışık ayarlamaları yansımayı önleyecek şekilde ayarlanmış ve kabin karanlık ortam şartlarını sağlayacak şekilde tasarlanmıştır. Şekil 3.9 kabin içi ölçüm işlemini göstermektedir.



Şekil 3.9 : Kabin içi ölçüm işlemi.

Parçalarda deformasyon ve çapak olmak üzere iki farklı hata türü bulunmaktadır. Parça üzerindeki bu hataların görüntüdeki konumlarını ve hangi tür hatayla ilgili olduklarını belirlemek için Roboflow sitesi kullanılmıştır. Roboflow, deformasyon ve çapak gibi

retim hatalarına ynelik alıřmalarda hızlı veri etiketleme ve ynetim sreleri sunmaktadır. Ancak, bu kusurların kk boyutlu veya zel yapıda olduėu durumlarda manuel inceleme yapılarak sre ilerletilmiřtir. řekil 3.10’da, etiketlenmiř apak ve deformasyon hatalarıyla ilgili para grntleri bulunmaktadır.



řekil 3.10 : (a) Etiketlenmiř apak grseli, (b) etiketlenmiř deformasyon grseli.

Veri seti oluřturma sreci, alıřmanın bařarısı iin temel bir adımdır ve titizlikle ele alınmıřtır. Verilerin kalitesi, modelimizin performansını doėrudan etkilediėinden, veri setinin doėruluėundan emin olmak olduka nemlidir.

Tez alıřmasında kullanılan veri seti; eėitim ve test setleri olarak blnerek, test seti, modelin genelleme yeteneėini deėerlendirmek iin ayrılmıřtır. Veri setinin %80’i eėitim ve %20’si test olarak seilerek veri seti zerinden ėrenme gerekleřtirilmiřtir.

3.2.2 Eėitim

Model eėitimi, Google’ın saėladıėı Google Colab platformunda tamamlanmıřtır. Eėitim sreci, Colab Pro versiyonu kullanılarak gerekleřtirilmiř ve 16 GB A100 GPU ile desteklenen, 51 GB sistem RAM’ine sahip bir bilgisayar zerinde gerekleřtirilmiřtir. Eėitim verisi 416x416 piksel boyutuna leklendirilmiřtir. Toplam 300 epoch kullanılmıřtır ve her bir eėitim adımımda batch size 16 olarak belirlenmiřtir. Colab ortamının tercih edilmesi, yksek grafik iřlem birimi (GPU) kapasitesinden kaynaklanmaktadır. Seilen eėitim parametreleri, yzey hata tespiti projesinin gereksinimlerine ve kullanılan yapay zekâ modeline gre zenle ayarlanmıř ve en iyi sonucu elde etmek iin optimize edilmiřtir.

Eğitim ve test verileri arasındaki oran, genellikle projenin karmaşıklığına, veri setinin büyüklüğüne ve kullanılacak modelin özelliklerine bağlı olarak değişebilir. Ancak, yaygın olarak kullanılan bir yaklaşım, veri setinin yaklaşık %70-80'ini eğitim için kullanarak, geri kalan %20-30'unu test için ayırmaktır.

Bu oranlar, eğitim verisinin yeterince büyük olmasını ve modelin doğru bir şekilde öğrenmesini sağlarken, aynı zamanda test verisinin modelin genelleme yeteneğini doğrulamak için yeterince büyük ve çeşitli olmasını sağlar. Eğitim ve test verilerinin önceden karıştırılmış olması önemlidir. Böylece modelin genelleme performansı doğru bir şekilde değerlendirilebilir.

Bu önerilen oranlar, genel bir kural olarak kabul edilir ve uygulamada projenin gereksinimlerine ve veri setinin doğasına bağlı olarak değişebilir. Tez çalışmasında, veri setinin %80'i eğitim ve %20'si test olarak ayrılmış ve kullanılmıştır.

Google Colab, Google tarafından sunulan bir bulut tabanlı Jupyter defteri hizmetidir. Araştırma, eğitim ve proje geliştirme gibi veri bilimi ve yapay zekâ projelerini kolayca yürütmek için kullanılır. Temel kullanımı ücretsizdir ve Google hesabı olan herkes tarafından erişilebilir. Colab'i kullanarak Python kodları ve Jupyter defterleri ücretsiz olarak çalıştırılabilmektedir.

Google Colab, kullanıcılara google'ın yüksek performanslı sunucularında ücretsiz olarak hesaplama gücü sunmaktadır. Bu, GPU veya TPU gibi yüksek performanslı donanımları kullanarak büyük veri setleri üzerinde hızlı hesaplamalar yapmayı mümkün kılar.

Colab, Jupyter defterlerini desteklemekte ve kod, metin ve görselleri bir arada tutabilmeyi sağlamaktadır. Bu, kodu adım adım çalıştırma, sonuçları görselleştirme ve açıklamaları metin formatında ekleyerek çalışmayı belgeleme imkanı sağlamaktadır. Google Drive gibi çeşitli google hizmetleriyle entegre çalıştığı için veri setlerini kolayca yüklememize ve tez çalışmasındaki veri setinin depolanmasına olanak tanımaktadır.

Ek olarak Colab, popüler Python kütüphanelerini ve araçlarını (numpy, pandas, matplotlib, TensorFlow, PyTorch vb.) içeren önceden yüklenmiş bir çalışma ortamı da içermektedir.

4. ÖNERİLEN YAPAY ZEKÂ TEMELLİ KONTROL SİSTEMLERİ

4.1 Sistemin Genel Blok Şeması


ML sisteminin genel blok şeması, bir makine öğrenmesi projesinin farklı aşamalarını ve bu aşamalar arasındaki ilişkileri görselleştirir. Genel olarak bir makine öğrenmesi sisteminin blok şemasını oluştururken ilk olarak, problemle ilgili veri toplanır. Yapılan projede 902 adet çapaklı, 850 adet kusursuz ve 898 adet deformasyonlu parça kalite kontrol biriminden temin edilmiştir. Toplanan uygunsuz parçalar test kabinde fotoğraflandırılarak veri seti oluşturulmuştur.

ML ikinci aşaması veri temizleme ve hazırlık aşamasıdır. Veri, eksik değerler, gürültülü veriler veya tutarsızlıklar gibi sorunlar içerebilir. Bu nedenle, veri temizleme ve ön işleme adımlarıyla veri hazırlanır. Bu aşamada çekilen fotoğraflarda morfolojik işlemler uygulanarak gürültü azaltılmış ve hataların yakalanabilmesi için uygun görseller oluşturulmuştur. Üçüncü aşamada özellik seçimi yapılır. Bu aşama problemle en iyi şekilde uyum sağlayacak özelliklerin seçilmesi için denemeler ve testlerin uygulandığı aşamadır. Özelliklerin aynı ölçekte olmasını sağlayarak algoritmaların daha iyi performans göstermesi sağlanmaya çalışılmıştır. Özellik çıkarma süreçlerinde dalgacık dönüşümü yöntemlerinden UWT, CWT ve DWT yöntemleri ile özellik çıkarımı yapılmış ve sonrasında sınıflandırma aşamasına geçilmiştir.

Sınıflandırma sürecinde problem türüne ve veri yapısına göre uygun bir model seçilir. Yaptığımız çalışmada farklı sınıflandırma metotları kullanılarak değerler gözlenmiş ve en iyi sonuç veren yöntem belirlenmiştir. Çalışmada kullanılan sınıflandırma yöntemleri: SVM, GB, DT, YSA, K-NN'dir.

Sınıflandırma yöntemi belirlendikten sonra seçilen model, hazırlanan veri seti üzerinde eğitilmiştir. Bu, modelin verilerden öğrenmesini sağlar. Modelin genellemesini değerlendirmek için ayrılmış bir test veri seti kullanılmıştır. Çalışmada %80 eğitim %20 test olacak şekilde veri seti bölünmüştür.

Tez çalışmasında kullanılan makine öğrenmesi aşamalarının blok şeması Şekil 4.1'de gösterilmiştir.



Şekil 4.1 : Tez çalışmasında kullanılan makine öğrenmesi yönteminin aşamaları.

4.2 Özellik Çıkarma Yöntemleri

4.2.1 Örnek indirgenmemiş dalgacık dönüşümü (UWT)

UWT, dalgacık dönüşümü tekniklerini birleştirerek geliştirilmiş bir sinyal işleme yöntemidir. Bu yöntem, farklı dalgaboyu dönüşümlerini tek bir çatı altında birleştirerek sinyal analizini yapmayı sağlar. UWT'nin kullanıldığı alanların başında sinyal işlemenin yaygın olarak kullanıldığı ses ve görüntü sinyalleri gelmektedir. UWT, çeşitli dalga boyu dönüşümlerinin birleştirilmesi ve çeşitli ölçeklerdeki detayları eş zamanda ele almaya imkan sağlar. Kullanım alanlarından bir tanesi de görüntü işlemedir. UWT, özellik çıkarma, sıkıştırma, desen tanıma ve benzeri birçok uygulamada kullanılmaktadır. Değişik ölçeklerdeki özellikleri belirleyerek görüntüleri daha etkili bir şekilde analiz edebilmektedir.

UWT aynı zamanda biyoistatistik ve tıbbi görüntüleme alanında da yaygın olarak kullanılmaktadır. Bu alanda sinyalin analiz edilmesi ve özellik çıkarımı önemli bir noktadır. Bu nedenle UWT yaygın olarak tercih edilmektedir. UWT, veri sıkıştırma algoritmalarında da kullanılır. Farklı ölçeklerdeki detayları temsil edebilme yeteneği, veri sıkıştırma işlemlerinde daha etkili bir performans sağlayabilir.

UWT'nin matematiksel gösterimi, kullanılan dalgaboyu dönüşümlerine ve birleştirme işlemine bağlı olarak değişebilir. Ancak genel olarak, UWT'nin matematiksel gösterimi şu şekilde ifade edilebilir:

Varsayalım ki $x(t)$ sürekli bir sinyal olsun. UWT, bu sinyali farklı ölçeklerde ve konumlarda analiz etmek için birden fazla dalgaboyu işlevini kullanır. Örneğin, $\psi_{j,k}(t)$ belirli bir ölçekte j ve belirli bir konumda k olan bir dalgaboyu işlevini temsil eder. Bu dalgaboyu işlevleri, sinyali belirli ölçeklerde ve konumlarda temsil etmek için kullanılır.

UWT'nin genel formülü Denklem (4.1)'deki gibi ifade edilebilir:

$$W_X(j,k) = \langle x, \psi_{j,k} \rangle \quad (4.1)$$

Bu denklemde $W_X(j,k)$, UWT'deki $x(t)$ sinyalin temsilcisidir. iç çarpım işlemi $\langle ., . \rangle$ ifade edilmektedir. Belirli bir konumda ve ölçekte ki dalga boyu da $\psi_{j,k}(t)$ ile gösterilmektedir. UWT'nin matematiksel gösterimi, kullanılan dalga boyu uygulama alanı ve işlevine bağlı olarak değişiklik gösterebilir.

UWT'nin en önemli avantajlarından birisi, çeşitli ölçeklerde detayları tek bir çatı altında ele alması ve böylelikle görüntü ya da sinyallerin detaylı bir şekilde incelenmesinin sağlanmasıdır. Buna ek olarak çeşitli dalga boyu dönüşümlerini birleştirerek, özellik çıkarımı için zengin bir çeşitlilik sunar ve desen tanıma, sınıflandırma gibi aşamalarda daha etkili sonuçlar elde edilmesini sağlar. Veri sıkıştırmayı etkin bir şekilde kullanarak, yüksek verimlilik ve koruma sağlar. UWT'nin bu avantajları, geniş bir alanda kullanılmasını ve sinyal işleme ve görüntü işleme alanlarındaki çeşitli zorluklara etkili çözümler sunmasını sağlar.

UWT yönteminin avantajlarının yanı sıra, bazı dezavantajları da bulunmaktadır. UWT çoğunlukla hesaplama gücü gerektiren karmaşık işlemler kullanır. Özellikle büyük veri seti veya yüksek çözünürlükteki görüntüler gibi karmaşık veri tipleri için işlem gücü ihtiyacı artabilir. UWT'nin avantajlarından olan farklı dalga boyu dönüşümlerinin birleştirilmesinde sunduğu seçeneklerin uygun seçilmesi ve /veya ayarlanması karmaşık olabilir. Bu da kullanıcılar için karar verme aşamasında zorluklar çıkarabilir. Diğer avantajlarından biri olan veri sıkıştırma işlemlerinde çözünürlüğün düşmesi veya veri yitimi gibi riskler dezavantajları arasında sayılabilir.

UWT'nin farklı dalgaboyu dönüşümlerini birleştirmesi, genelleme zorluğu yaratabilir. Yani, belirli bir uygulamada iyi sonuçlar veren birleşik dönüşüm, diğer uygulamalarda aynı derecede iyi sonuçlar vermeyebilir. UWT'nin kullanımında belirli hiperparametrelerin ayarlanması gerekebilir. Bu hiperparametrelerin optimal değerlerini belirlemek, bazen deneme yanılma yoluyla yapılabilir ve zaman alabilir. Bu dezavantajlar, UWT'nin belirli uygulamalarda zorluklarla karşılaşabileceği durumları yansıtır. Ancak, bu yöntemin sağladığı genişletilmiş analiz kapasitesi ve veri işleme yetenekleri, birçok durumda bu dezavantajları tolere edilebilir hale getirmektedir.

4.2.2 Sürekli dalgacık dönüşümü (CWT)

CWT, bir sinyalin zaman ve frekans alanındaki özelliklerini aynı anda analiz etmek için kullanılan bir dalgacık dönüşümü yöntemidir. Dalgacık dönüşümleri, geleneksel Fourier dönüşümünden farklı olarak, sinyalin zaman-frekans alanında yerleştirilmiş özelliklerini analiz edebilirler. Yani, bir sinyalin hem zaman hem de frekans bileşenlerini aynı anda gözlemlemek için kullanılırlar. Bu durum, özellikle zaman-dönüşümü ve frekans-dönüşümü gibi tek boyutlu dönüşümlerle zor veya olanaksız olan bazı analizleri gerçekleştirmek için yararlıdır. CWT, bir dalgacık fonksiyonunun orijinal sinyal ile farklı ölçekler ve zaman kaymaları ile karşılaştırılmasını içerir. Bu, sinyalin farklı zamanlarda ve farklı frekanslarda nasıl değiştiğini incelememize olanak tanır.

CWT'nin matematiksel formülasyonu oldukça karmaşıktır ve uygulanması biraz teknik bilgi gerektirebilir. Ancak, dönüşüm genellikle çeşitli işaret işleme ve veri analizi uygulamalarında kullanılır. Özellikle zaman-serisi analizi, spektrogram oluşturma, görüntü işleme ve desen tanıma gibi alanlarda yaygın olarak kullanılır.

Veri seti $f(t)$, dalgacık fonksiyonu $\psi(t)$ olarak adlandırılmıştır. CWT, bu dalgacık fonksiyonunu ve ölçek parametresini (a) kullanarak veri setini analiz eder. CWT'nin matematiksel formülasyonu Denklem (4.2)'de verilmiştir:

$$\text{CWT}(a,b) = \int_{-\infty}^{\infty} f(t) \psi^*\left(\frac{t-b}{a}\right) dt \quad (4.2)$$

Bu denklemde “ a ” ölçek parametresi, dalgacık fonksiyonunun ölçeklenmesi veya genişlemesi için kullanılır. “ b ” zaman kaydırma parametresi, dalgacık fonksiyonunun

kaydırılması için kullanılmaktadır. $\Psi^*(t)$ ise dalgacık fonksiyonunun kompleks eşleniğini temsil eder.

Bu formülasyon, veri setinin dalgacık fonksiyonu ile çapraz korelasyonunu hesaplar. Çeşitli “a” ve “b” değerleri için bu işlem gerçekleştirilir. Böylece veri setinin farklı ölçeklerde ve zamanlarda nasıl davrandığı gözlemlenir.

CWT'nin sağladığı faydaların yanı sıra bazı zorlukları ve dezavantajları da mevcuttur. Bunlardan ilki hesaplama gücü ve zaman maliyetidir. CWT genellikle hesaplama gücü ve zaman maliyeti yüksek bir yöntemdir. Özellikle, sinyalin farklı ölçeklerde ve zamanlarda analiz edilmesi için çok sayıda işlem gerektirebilir. Bu, büyük veri setleri üzerinde CWT'nin kullanılmasını zorlaştırabilir ve hesaplama maliyetini artırabilir.

CWT'nin başarılı bir şekilde uygulanması için doğru dalgacık fonksiyonunun ve ölçek parametresinin seçilmesi gereklidir. Ancak, doğru parametrelerin seçimi bazen zor olabilir ve deneme-yanılma yöntemi gerektirebilir. Bu, kullanıcı tarafından deneyim ve uzmanlık gerektirebilir. Büyük veri setleri üzerinde kullanıldığında performans açısından kısıtlı olabilir. Büyük veri setleri üzerinde CWT uygulamak, hesaplama gücü ve bellek gereksinimlerini artırabilir ve zaman alabilir.

Spektrogram oluşturmada da CWT yaygın olarak kullanılmaktadır. Bir sinyalin frekans bileşenlerini zamanla nasıl değiştiğini görselleştirmek için kullanılabilir. Bu, belirli bir sinyalin hangi frekanslarda ve hangi zaman aralıklarında yoğun olduğunu anlamak için kullanılır. Özellikle ses işleme ve iletişim sistemlerinde yaygın olarak kullanılır. Bir diğer kullanım alanı da görüntü işlemedir. CWT, görüntülerdeki desenleri, kenarları, köşeleri ve diğer yapıları belirlemek için kullanılabilir. Görüntülerdeki farklı ölçeklerdeki ve farklı konumlardaki özelliklerin tanımlanmasına yardımcı olabilir. Bu, medikal görüntüleme, uzaktan algılama, video işleme ve diğer görüntü işleme uygulamalarında yaygın olarak kullanılmasına yol açmıştır. Görüntü işlemeye ek olarak çeşitli sinyal işleme uygulamalarında da CWT kullanılmaktadır. Elektrokardiyogram (EKG), elektroensefalografi (EEG) ve manyetik rezonans görüntüleme (MRI) gibi biyomedikal sinyallerin analizinde titreşim analizi, akustik sinyal işleme ve diğer endüstriyel uygulamalarda da yaygın olarak kullanılmaktadır. Özellikle, belirli bir sinyalin belirli bir deseni veya davranışı içerip içermediğini belirlemek için de CWT tercih edilmektedir.

4.2.3 Ayırık dalgacık dönüşümü (DWT)

DWT, sürekli dalgacık dönüşümü yöntemini ayırık bir formda uygulayan bir dönüşüm tekniğidir. CWT'nin aksine, DWT, sinyali belirli ölçek faktörlerine ve zamanlara göre kesirli parçalara böler ve bu parçaları analiz eder. DWT'nin ana prensibi, sinyali birbirine dik olan ve farklı frekans aralıklarında temel dalgacık fonksiyonları ile çözümlenektir. Bu dalgacık fonksiyonları, sinyalin farklı ölçeklerinde ve zamanlarında kullanılarak, sinyalin farklı frekans bileşenlerini ve zaman ölçeği temsilini elde etmemizi sağlar.

DWT, sinyalin frekans ve zaman çözünürlüğünü aynı anda sağlayan çoklu ölçek analizini gerçekleştirir. Ayrıca, DWT'nin hızlı ve hesaplama açısından verimli algoritmaları bulunmaktadır. Bu da büyük veri setleri üzerinde etkin bir şekilde kullanılabilmesini sağlamaktadır.

DWT'nin birçok uygulama alanı bulunmaktadır, bunlar arasında sinyal işleme, görüntü işleme, veri sıkıştırma, zaman-serisi analizi ve desen tanıma yer almaktadır. Özellikle, veri sıkıştırma uygulamalarında, DWT sinyaldeki gereksiz veya tekrar eden bilgileri ortadan kaldırarak veri boyutunu azaltabilir ve veri iletimi veya depolama verimliliğini artırabilir.

DWT matematiksel olarak aşağıdaki gibi ifade edilebilir:

Veri seti $f(t)$, dalgacık fonksiyonu $\psi(t)$ olarak adlandırılmıştır. CWT, bu dalgacık fonksiyonunu ve ölçek parametresini (a) kullanarak veri setini analiz eder. CWT'nin matematiksel formülasyonu Denklem 4.3'te verilmiştir:

$$DWT(a,b) = \int_{-\infty}^{\infty} f(t) \cdot \psi_{a,b}(t) dt \quad (4.3)$$

Denklem (4.3)'te, “a” ölçek parametresini temsil eder ve dalgacık fonksiyonunun genişlemesini veya sıkışmasını kontrol eder. “b” zaman kaydırma parametresini temsil eder ve dalgacık fonksiyonunun zaman içinde nasıl kaydırıldığını kontrol eder. $\psi_{a,b}(t)$ dalgacık fonksiyonunun “a” ve “b” parametrelerine göre ölçeklendirilmiş ve kaydırılmış versiyonunu ifade eder. Bu ifade, veri setinin dalgacık fonksiyonu ile çarpımının integralini hesaplar. Bu, veri setinin farklı ölçeklerde ve zamanlarda nasıl tepki verdiğini incelememize olanak tanır. DWT'nin uygulanması genellikle bir alt örnekleme ve düzey kaydırma işlemi içerir ve sonunda bir DWT katsayıları dizisi

üretilir. Bu katsayılar, sinyalin farklı frekans bileşenlerini ve zaman ölçeği temsilini içerir.

Discrete wavelet transform (DWT) yönteminin avantajlarını sıralamak gerekirse çoklu ölçek analizi, hesaplama verimliliği, yüksek sıkıştırma oranı, geniş uygulama alanı ve geri dönüşümlü operasyonlar olarak sayılabilir.

DWT, gerçek zamanlı uygulamalar için uygundur. Sinyaldeki gereksiz veya tekrar eden bilgileri tespit etmek için kullanılabilir. Özellikle, veri iletimi veya depolama verimliliğini artırmak için yaygın olarak kullanılır.

DWT bazlı sıkıştırma yöntemleri, sıkıştırma sırasında bazı bilgi kayıplarına neden olabilir. Özellikle yüksek oranda sıkıştırma yapıldığında, sinyalin bazı detayları kaybolabilir ve sıkıştırılmış sinyalin kalitesi düşebilir. Sinyali belirli ölçek faktörlerine ve zamanlara göre kesirli parçalara böler. Bu işlem sinyalin kenar bölgelerinde istenmeyen etkilere neden olabilir. Kenar efektleri, sinyalin kenarlarında doğru bir şekilde analiz yapmayı zorlaştırabilir ve sonuçları etkileyebilir. DWT, sinyali farklı ölçeklerde parçalara ayırır ve bu parçaları analiz eder. Ancak, hangi seviyelerin ve dalgacık fonksiyonlarının seçileceği konusunda belirsizlik vardır. Seviye seçimi, sonuçların kalitesini etkileyebilir ve bazen deneme-yanılma yöntemleri ile seçim yapmayı gerektirebilir. Bu gibi sorunlar, DWT'nin sinyaldeki belirli özellikleri tam olarak yakalamasını engelleyebilir.

4.3 Sınıflandırma Yöntemleri

Sınıflandırma yöntemleri, bir veri setindeki örnekleri belirli sınıflara ayırmayı amaçlayan denetimli makine öğrenimi algoritmalarıdır. Bu yöntemler, özellikle sınıflandırma problemleri için tasarlanmıştır ve geniş bir yelpazede kullanılmaktadır.

4.3.1 Derin öğrenme (DL) kullanan yöntem

Nesne algılama, görüntülerdeki nesneleri tanıma, konumlandırma ve sınıflandırma gibi işlemleri gerçekleştirir. YOLO (You only look once), genellikle nesne algılama görevlerinde kullanılan bir algoritmadır. Diğer yöntemlere kıyasla avantajı, bir görüntüyü tek bir girişte analiz ederek tüm nesneleri tespit etmeye çalışmasıdır. YOLOv5, YOLO ailesine ait bir algoritmadır. YOLOv5, farklı kullanım senaryolarına yönelik olarak dört farklı versiyona sahiptir. Bu versiyonlar, gömülü sistemlerden


mobil ve bulut tabanlı sistemlere kadar deęişen sistem özelliklerine uygun şekilde YOLOv5s, YOLOv5m, YOLOv5l ve YOLOv5x olarak adlandırılır.

Bu versiyonlar arasında en hızlı olan versiyon YOLOv5s (small)'dir. Daha küçük boyutlu nesneleri tanımak ve hızlı işlem yapmak için kullanılır. Daha az bellek ve işlem gücü gerektirir. Her üst versiyonda, karmaşıklık, bellek kullanımı ve doğruluk artmaktadır. En büyük ve en karmaşık versiyonu YOLOv5x (extra large)'tir. YOLOv5x yüksek bellek ve işlemci gücü gerektirir. Yüksek çözünürlüklü nesne algılama uygulamalarında kullanıma uygundur ve diğer versiyonlara göre daha yüksek doğruluk ve ayrıntı sağlar. Ancak YOLOv5x diğer sürümlere göre daha yavaş çalışır. YOLO versiyonlarının bir karşılaştırılması Çizelge 4.1'de gösterilmiştir. Bu versiyonlar, kullanılacak nesne, bellek gereksinimi, işlem gücü gibi faktörlere bağlı olarak tercih edilir.

Çizelge 4.1: YOLOv5 karşılaştırma tablosu

Model	Map (0.5)	Zaman(ms)
Yolov5s	38	27
Yolov5m	43	32
Yolov5l	46	41
Yolov5x	48.5	49

YOLOv5, Python kütüphanelerinden pytorch tabanlı bir modeldir. Pytorch kullanım açısından esnek ve kolay olması nedeniyle endüstriyel uygulamalarda çok sık kullanılmaktadır. YOLOv5, darknet53'ün csp eklenmiş ve geliştirilmiş versiyonu olan sinir ağı csp-darknet53 kullanmaktadır. Csp yani çoklu özellik çıkarıcı, ağıın bölünmesini ve birleştirilmesini kullanarak öğrenmeyi geliştirir. Bu, YOLOv5'in daha fazla parametreye izin vermesini sağlar ve farklı boyuttaki nesneleri tek bir görüntüde daha başarılı bir şekilde tespit etmesini sağlar [22]. Darknet53 ve CSP-Darknet53 karşılaştırması Şekil 4.2'de gösterilmiştir.



Şekil 4.2 : Darknet53 ve CSP-Darknet53 karşılaştırması

4.3.2 Makine öğrenmesi yöntemleri ile entegrasyon

Sınıflandırıcıların makine öğrenmesi yöntemleri ile entegrasyonu, modern veri analitiği süreçlerinin temel taşlarından biridir. Makine öğrenmesi, sınıflandırma problemlerini çözmek için geniş bir yöntem yelpazesi sunar. Bu yöntemler, verilerin özelliklerini öğrenerek tahmin yapma veya kategorilere ayırma görevlerini yerine getirir.

4.3.2.1 Destek vektör makineleri (SVM)


SVM, özellikle sınıflandırma ve regresyon problemleri için kullanılan bir makine öğrenmesi algoritmasıdır. SVM, veri noktalarını birbirinden ayıran optimal bir hiperdüzlemi bulmaya çalışır. Bu, sınıflar arasındaki en büyük boşluğu sağlar ve modelin genelleme performansını artırır.

SVM'nin maksimum marjin hiperdüzlemi etrafındaki veri noktalarına destek vektörleri denir. Bu noktalar, hiperdüzleme olan en yakın noktalardır ve sınıflar arasındaki karar sınırını belirler.

SVM, doğrusal olarak ayrılabilen verilerin yanı sıra doğrusal olarak ayrılamayan verileri de sınıflandırabilir. SVM destek vektörleri ve margin Şekil 4.3'te gösterilmiştir.

Sınıflandırma problemlerindeki ana hedefimiz, gelecekteki verilerin hangi kategoriye ait olduğunu belirlemektir. Bu amaçla, iki farklı sınıf arasında bir ayırma yapmak için bir doğru (veya düzlem) çizilir. Bu doğrunun iki tarafındaki bölgeye "margin" denir ve bu bölge, sınıflar arasındaki ayrımın ne kadar net olduğunu gösterir. Margin ne kadar geniş olursa, sınıflar arasındaki ayrım o kadar iyi olur.

SVM'nin matematiksel ifadesi, veri noktalarını ayırmak için bir hiperdüzlemi bulmaya dayanır. $\{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\}$ şeklinde ifade edilen bir eğitim seti düşünelim, burada x_i veri noktalarını, y_i ise bu veri noktalarının sınıf etiketlerini temsil eder. x_i vektörlerinin boyutu m ve sınıf etiketleri y_i 1 veya -1 değerlerini alır.



Şekil 4.3 : SVM ayırım grafiği.

Temelde, SVM'nin amacı, bu veri noktalarını ayırmak için bir hiperdüzlem oluşturmaktır. Hiperdüzlem matematiksel olarak Denklem (4.4)'te ifade edilmiştir.

$$w \cdot x + b = 0 \quad (4.4)$$

Burada w normal vektörüdür (hiperdüzlemin yönünü belirler) ve b sabittir (hassasiyeti ayarlar). Eğitim sürecinde, SVM, veri noktalarını doğru bir şekilde sınıflandırabilmek için bu hiperdüzlemi bulmaya çalışır.

SVM'nin optimizasyon problemini çözmek için birçok farklı formülasyon vardır. Ancak genellikle aşağıdaki sınırlı destek vektörleri (LSV) denklemleri kullanılır:

$$\min(w,b) \frac{1}{2} ||w||^2 + C \sum_{i=1}^n \xi_i \quad (4.5)$$

$$y_i(w \cdot x_i + b) \geq 1 - \xi_i, \quad i=1,2,\dots,n \quad (4.6)$$

$$\xi_i \geq 0, \quad i=1,2,\dots,n \quad (4.7)$$

Denklem (4.5) 'de, C bir hiperparametredir ve marjini kontrol eder. ξ_i ise sınıflar arasındaki hata veya marjinal hata olarak adlandırılır.

Burada amaç, $||w||^2$ minimize ederek hiperdüzlemi maksimize etmek ve aynı zamanda marjinal hataları minimize etmektir. Bu, doğru bir şekilde sınıflandırılmış veri noktalarının marjinlerini maksimize eden ve hatalı sınıflandırılmış veri noktalarının etkisini sınırlayan bir dengeyi sağlar. Bu optimizasyon problemi, genellikle özel optimizasyon algoritmaları veya konvansiyonel optimizasyon teknikleri kullanılarak çözülür.

SVM, metin sınıflandırması, görüntü sınıflandırması, tıbbi teşhisler ve biyoinformatik gibi birçok alanda başarıyla kullanılmaktadır. Ayrıca, regresyon problemleri için de kullanılabilir. Özellikle az sayıda örnek ve gürültülü veri içeren regresyon problemlerinde etkilidir. Diğer kullanım alanı da doğruluk ve genellemedir. Yüksek boyutlu veri setlerinde ve küçük örneklem sayısında bile iyi performans gösterir. Maksimum marjin ilkesine dayanarak, SVM genelleme yeteneği yüksektir. Çok boyutlu veri uzaylarında da SVM kullanılmaktadır. Düşük boyutlu veri uzaylarını yüksek boyutlu uzaylara taşıyarak karmaşık sınıflandırma problemlerini çözebilir. Bu, özellikle görüntü işleme gibi alanlarda faydalıdır.

SVM kullanmanın bazı dezavantajları da vardır. Bu dezavantajların bazılarını baktığımızda ilk olarak hassas parametre ayarını söylebiliriz. SVM'nin etkin kullanımı, Kernel ve C parametrelerinin doğru şekilde ayarlanmasına bağlıdır. Bu parametrelerin optimal değerlerini bulmak bazen zor olabilir. Büyük veri setleri üzerinde çalışırken,

yüksek boyutlu veri uzaylarında ve karmaşık Kernel fonksiyonlarında hesaplama gücü gerektirebilir.

Sonuç olarak, SVM, sınıflandırma ve regresyon problemleri için güçlü bir makine öğrenmesi algoritmasıdır. Doğruluk, genelleme yeteneği ve çok boyutlu veri uzaylarında etkinliği nedeniyle birçok alanda başarıyla kullanılmaktadır. Ancak, parametre ayarı ve hesaplama gücü gibi bazı dezavantajları da vardır. Bu nedenle, SVM'nin kullanılacağı belirli bir uygulama bağlamında dikkatle değerlendirilmelidir.

Avantajları ve dezavantajları dikkate alınarak SVM'nin kullanım alanları çeşitlilik göstermektedir. SVM, metin belgelerini otomatik olarak sınıflandırmak için sıkça kullanılır. Örneğin, spam e-postalarını tespit etme, haber makalelerini kategorize etme veya duygu analizi gibi görevlerde SVM kullanılmaktadır. Nesne tanıma, yüz tanıma, el yazısı tanıma gibi görüntü sınıflandırma problemlerinde de etkili bir şekilde kullanılır. Özellikle öznitelik çıkarımı ve görüntü sınıflandırması için önceden eğitilmiş sinir ağlarıyla birlikte kullanılmaktadır.

SVM'nin bu çeşitli kullanım alanları, geniş bir uygulama yelpazesine sahip olduğunu göstermektedir. Özellikle sınıflandırma ve regresyon problemleri için güçlü bir araç olması, SVM'nin birçok endüstride ve disiplinde tercih edilmesine olanak sağlar.

4.3.2.2 K- en yakın komşu (KNN)

KNN, bir makine öğrenmesi algoritmasıdır ve sınıflandırma veya regresyon problemlerini çözmek için kullanılır. KNN, basit yapısı ve anlaşılabilir mantığı ile popüler olmuştur.

Temelde, KNN bir sınıflandırma problemi için verilen bir veri noktasının sınıfını belirlemek veya bir regresyon problemi için verilen bir veri noktasının çıktı değerini tahmin etmek için kullanılır. KNN'de her veri noktası, özellik vektörü olarak temsil edilir. Özellik vektörleri, veri noktasının özelliklerini tanımlayan sayısal değerlerdir.

Sınıflandırma durumunda, her veri noktası bir sınıf etiketi ile etiketlenir. Regresyon durumunda, her veri noktası bir çıktı değeri ile etiketlenir. KNN, yeni bir veri noktasının sınıfını belirlemek veya çıktı değerini tahmin etmek için, bu veri noktasının en yakın komşularının etiketlerini kullanır. KNN'de, "k" adet en yakın komşu seçilir. "k" değeri, kullanıcı tarafından belirlenir ve tipik olarak bir tek sayıdır. Sınıflandırma durumunda, en yakın komşuların çoğunluğu sınıfına ait olan veri noktası, yeni veri

noktasının sınıfı olarak tahmin edilir. Regresyon durumunda ise en yakın komşuların çıktı değerlerinin ortalaması, yeni veri noktasının çıktı değeri olarak tahmin edilir.

KNN'nin önemli bir parametresi "k" değeridir. Bu değer, kullanıcının belirlemesi gereken bir hiperparametredir ve KNN'nin performansını etkiler. Küçük "k" değerleri, modelin karmaşıklığını artırırken, büyük "k" değerleri daha düzgün ancak daha az hassas tahminler yapabilir.

Matematiksel olarak, KNN algoritması Denklem (4.8)'deki gibi ifade edilebilir:

$$\hat{y}_q = \text{argmax}(\sum_{i=1}^k \delta(y_i, c)) \quad (4.8)$$

Burada $\hat{y}_q$, yeni veri noktasının tahmini sınıfı veya regresyon çıktısıdır. $\delta(y_i, c)$, i numaralı veri noktasının sınıf etiketi c ile eşleşiyorsa 1, aksi takdirde 0 değerini alan bir fonksiyondur. Bu ifade, sınıflandırma problemleri için KNN algoritmasının temelini oluşturur. Regresyon problemleri için benzer bir ifade, en yakın k komşunun değerlerinin ortalaması veya ağırlıklı ortalaması kullanılarak oluşturulur.

KNN, anlaması ve uygulaması kolay olan basit bir algoritmadır. Temel olarak, bir veri noktasını etiketlemek için yalnızca en yakın komşularının sınıf etiketleri veya değerleri kullanılır. Eğitim aşaması olmayan KNN için modeli eğitmek için veri seti üzerinde özel bir işlem yapılmasına gerek yoktur. Bunun yerine, tahmin yaparken sadece veri noktalarının konumları kullanılır. KNN, hem sınıflandırma hem de regresyon problemleri için kullanılabilir. Ayrıca, çoklu sınıf etiketleri ve çoklu çıktı değerleriyle çalışabilir.

KNN, basitliği ve esnekliği nedeniyle birçok uygulama alanında kullanılır. Ancak, büyük veri setleri veya yüksek boyutlu özellik uzaylarıyla çalışırken bellek ve hesaplama gücü sorunları ortaya çıkabilir.

Özetlemek gerekirse, KNN sınıflandırma, regresyon ve örüntü tanıma için kullanılır. Bir veri noktasını çevresindeki en yakın komşularının sınıf etiketlerine göre sınıflandırmak için kullanılabilir. Örneğin, bir e-postanın spam olup olmadığını belirlemek veya bir hastanın bir hastalığa yakalanıp yakalanmadığını tahmin etmek için kullanılabilir. En yakın komşularının değerlerini kullanarak sürekli bir çıktı tahmin etmek için de kullanılabilir. Örneğin, bir evin değerini tahmin etmek veya bir ilacın etkin dozunu belirlemek için kullanılabilir. Ek olarak KNN, bir resmin veya

görüntünün çevresindeki benzer resimlerin etiketlerini kullanarak görüntü sınıflandırma veya tanıma için de kullanılabilir.

4.3.2.3 Karar ağacı (DT)

DT, bir makine öğrenmesi algoritmasıdır ve sınıflandırma ve regresyon problemlerini çözmek için kullanılır. Karar ağaçları, bir dizi karar düğümü ve bu düğümler arasında bağlantılar içeren bir ağaç yapısı kullanır. Her iç düğüm, bir özellik veya özneliği temsil ederken, her yaprak düğümü bir sınıf etiketi veya regresyon çıktısıdır.


Karar ağaçları, veri kümesindeki özelliklerin değerlerine göre veri noktalarını bölerek bir sınıflandırma veya regresyon modeli oluşturur. Temel prensip, veri setini en iyi şekilde bölerek homojen alt gruplar elde etmektir. Bu bölünmeler, veri setindeki enformasyonu maksimize edecek şekilde yapılır.

Karar ağaçları, ağacın yapısını oluşturmak için farklı bölme kriterleri kullanır. Örneğin, sınıflandırma problemlerinde genellikle Gini impurity veya entropy gibi ölçütler kullanılırken, regresyon problemlerinde ortalama kare hatası (MSE) gibi ölçütler kullanılabilir. Her bir bölme kriteri, ağacın en iyi bölme noktasını belirlemek için kullanılır.

Karar ağaçları, yüksek performans, veri ön işleme gereksiniminin azlığı ve doğal bir şekilde kategorik ve sayısal veri türlerini bir araya getirebilme yeteneklerine sahiptir. Ancak, aşırı uyum (overfitting) gibi dezavantajları da vardır. Bu nedenle modelin karmaşıklığının kontrol edilmesi önemlidir.

Karar ağaçları, ağaç yapısında olup problemin çözüm adımlarına göre dalların kesilerek ilerlemesi şeklinde kabaca anlatılabilir. Karar ağacı genel yapısı Şekil 4.4'te gösterilmiştir.

Öncelikle tüm öğrenme kümesi ağaca dahil edilir. Daha sonrasında öğrenme kümesinde hataya sebep olabilecek gürültü ve benzeri dallar silinir ve dalların entropileri hesaplanır. Entropy rasgele olabilecek durumların olasılığını gösterir.



Şekil 4.4 : Karar ağacı genel yapısı.

Hesaplama yapmak için öncelikle karar ağacının hangi kararı alacağı ile ilgili konu netleştirilir.

$$\text{Entropy}(S) \equiv -p_{\oplus} \log_2 p_{\oplus} - p_{\ominus} \log_2 p_{\ominus} \quad (4.9)$$

Bütün örnekler aynı sınıfta ise $E(S)=0$, bütün örnekler sınıflara eşit dağılmış ise $E(S)=1$ 'dir.

Sonrasında sistemin entropysi de alttaki şekilde hesaplanır;

$$E(s_1, s_2, \dots, s_m) = -\sum_{i=1}^m \frac{s_i}{S} \log_2 \frac{s_i}{S} \quad (4.10)$$

Son adımda da ağacın en üstünde kökte konumlanacak özellik belirlenir. Information gain yani bilgi kazancı en yüksek olan nitelik ağacın en üstüne konumlandırılır. Information gain alttaki gibi hesaplanır;

$$\text{Gain}(S, A) \equiv \text{Entropy}(S) - \sum P(v) \text{Entropy}(S(v)) \quad (4.11)$$

Burada V , A 'nın değeri olmak üzere:

$$P(v) \equiv |S(v)|/|S| \quad (4.12)$$


Karar ağacı oluşturmak ve yorumlamak kolaydır. Anlaşılabilir kurallar oluşturulabilir. Ancak sürekli nitelik değerlerini tahmin etmekte çok başarılı sonuçlar alamayabilir. Sınıf sayısı fazla, öğrenme kümesi az olduğunda model oluşturma konusunda pek başarılı değildir.

4.3.2.4 Yapay sinir ağı (YSA)

YSA, biyolojik sinir sisteminden esinlenerek tasarlanmış matematiksel model ve algoritmalar içeren bir yapay zekâ teknolojisidir. YSA, karmaşık veri setlerini analiz etmek, desenleri tanımak, sınıflandırmak, regresyon yapmak ve tahminlerde bulunmak için kullanılır. YSA, deneyimlerden öğrenme yeteneğine sahiptir. Belirli bir görevi yaparken verilen girdi-veri çiftleri üzerinden kendini ayarlayabilir ve iyileştirebilir. Aynı zamanda geniş bir problem yelpazesine uyarlanabilir.

YSA, birçok işlemci ve işlem biriminde paralel olarak çalışabilir. Bu sayede paralel hesaplama gücünden yararlanarak büyük miktarda veriyi işleyebilirler. Değişen çevresel koşullara uyum sağlayabilir ve yeni verilere adapte olabilir. Negatif durumlardaki geri bildirimlere bakıldığında YSA, belirli bir miktarda hasara veya gürültüye karşı dirençlidir ve girdilerden otomatik olarak anlamlı özellikler çıkarabilir ve öğrenebilir. Hata geriye yayılma (backpropagation) gibi tekniklerle hataları tanımlayabilir ve azaltabilir.

Yapay sinir ağları, özellikle makine öğrenmesi ve derin öğrenme alanlarında geniş bir uygulama alanına sahiptir. Ses ve görüntü tanıma, doğal dil işleme, tıbbi teşhis, finansal tahminler gibi birçok alanda kullanılmaktadır. Bir girdi katmanı, bir gizli katman ve bir çıktı katmanı olan basit bir yapay sinir ağı örneğini ele alalım. Bu ağ, girişlerden çıktıları üretmek için ağırlık matrisleri ve aktivasyon fonksiyonları kullanır. Tek katmanlı YSA yapısı Şekil 4.5'te gösterilmiştir. Formüle edilen YSA temel bir yapay sinir ağı modelinin matematiksel gösterimi için basit bir örnektir. Daha karmaşık ağlar ve görevler için, daha karmaşık matematiksel ifadeler ve işlemler gerekebilir.



Şekil 4.5 : YSA tek katmanlı yapı.

İlk olarak terimleri tanımlamamız gerekirse;

W^1 = Girdi katmanı ile gizli katman arasındaki ağırlık matrisi

W^2 = Gizli katman ile çıktı katmanı arasındaki ağırlık matrisi

b^1 = Gizli katmanın bias vektörü

b^2 = Çıktı katmanın bias vektörü

σ : Girişlerin çıktılarına dönüştürülmesi için kullanılan aktivasyon fonksiyonu

İlk olarak girdi katmanından gizli katmanına;

$$Z^1 = XW^1 + b^1 \quad (4.13)$$

$$A^1 = \sigma(Z^1) \quad (4.14)$$

Sonrasında gizli katmandan çıktı katmanına;

$$Z^2 = A^1W^2 + b^2 \quad (4.15)$$

$$\hat{Y} = \sigma(Z^2) \quad (4.16)$$

Burada;

- X : Giriş verilerini içeren matris (n, m) (n örnek sayısı, m girdi özellik sayısı)
- Z^1 : Gizli katmanın ağırlıklı girişleri
- A^1 : Gizli katmanın aktivasyon çıktıları
- Z^2 : Çıktı katmanının ağırlıklı girişleri
- $\hat{Y}$: Sinir ağının çıktı tahminleri

Geri yayılım (backpropagation) işlemi, ağırlıkların ve bias terimlerinin güncellenmesini içerir ve genellikle bir kayıp fonksiyonunun türevlerinin hesaplanması ve gradyan iniş algoritması gibi optimizasyon teknikleri kullanılarak gerçekleştirilir.

YSA, eğitim için genellikle büyük miktarda veri ve hesaplama gücü gerektirir. Bu, eğitim sürecini ve altyapı maliyetlerini artırabilir. Eğitim verisine aşırı uyum sağlayabilir ve yeni verilere genelleme yapma yeteneğini kaybedebilir. Bu, modelin doğruluğunu olumsuz etkileyebilir. Karmaşık yapılarından dolayı bazen içsel işleyişlerinin tam olarak anlaşılmasını zorlaştırabilir. Hataların kaynağını belirlemek ve düzeltmek için bazen karmaşık olabilir. Özellikle büyük ve karmaşık ağlar için bu zorluk daha da artar.

YSA'lar, nesne tanıma, yüz tanıma, optik karakter tanıma (OCR), tıbbi görüntüleme gibi birçok görüntü işleme ve tanıma görevlerinde kullanılır. Dil modelleri oluşturmak, metin sınıflandırma, metin üretimi, duygu analizi gibi doğal dil işleme problemlerinde yaygın olarak kullanılır.

YSA'lar, otonom araçlar ve insansız hava araçları gibi otomatik sürüş ve uçuş sistemlerinde de kullanılmaktadır. Üretim süreçlerini optimize etmek, hata tespiti, kalite kontrolü gibi endüstriyel otomasyon görevlerinde kullanılır. Pazarlama alanında ise müşteri segmentasyonu, ürün önerileri, reklam hedefleme gibi pazarlama ve müşteri hizmetleri alanlarında kullanılır. Yaygın kullanım alanlarından biri de enerji ve kaynak yönetimidir. Bu alan gerekliliği gereği enerji tüketimi tahmini, akıllı şebeke yönetimi, doğal kaynakların optimize edilmesi gibi enerji ve kaynak yönetimi problemlerinde kullanılır.

4.3.2.5 Gradyan arttırma (GB)

GB, "gradient boosting" (gradyan artırma) anlamına gelir. GB algoritmaları, özellikle sınıflandırma ve regresyon problemleri için kullanılan güçlü bir makine öğrenmesi

teknikidir. Bu algoritmalar, zayıf öğrenicileri (genellikle karar ağaçları) bir araya getirerek güçlü bir tahmin modeli oluştururlar.

GB, hata fonksiyonunu minimize etmek için gradyan iniş kullanır. Her iterasyonda, bir sonraki zayıf öğrenici, önceki öğrenicilerin yaptığı hatalara göre eğitilir. Bu, her bir sonraki öğrenicinin modelin genel hatasını düzeltmek için daha spesifik bir şekilde eğitilmesini sağlar.

GB algoritmaları, her bir yeni öğreniciyi eklerken önceki öğrencilere daha az önem vermek için bir küçültme faktörü kullanır. Bu, aşırı uyum riskini azaltır ve daha genel geçer bir model elde edilmesine yardımcı olur.

GB için bir veri setine ihtiyaç duyulur. Veri setinde, girdi özellikleri ($\mathbf{x}$) ve hedef değişkeni ($\mathbf{y}$) olarak gösterilir:

$$\mathbf{X} = \{x_1, x_2, \dots, x_n\} \quad (4.17)$$

$$\mathbf{Y} = \{y_1, y_2, \dots, y_n\} \quad (4.18)$$

GB modelin hatasını minimize etmek için bir kayıp fonksiyonu kullanır. En yaygın kayıp fonksiyonları regresyon ve sınıflandırma için kullanılmaktadır.

Regresyon için ,ortalama kare hata (MSE) Denklem (4.19)'da , sınıflandırma için de Denklem (4.20)'de verilmiştir.

$$L(y, \hat{y}) = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (4.19)$$

$$L(y, \hat{y}) = -\frac{1}{n} \sum_{i=1}^n [(y_i \log(\hat{y}_i) + (1 - y_i) \log(1 - \hat{y}_i))] \quad (4.20)$$

GB ilk adımda basit bir başlangıç tahminiyle başlar. Bu tahmin genellikle hedef değişkenin global bir özetidir. Regresyon için ortalama hedef değeri Denklem (4.21)'de gösterilmiştir.

$$F_0(x) = \frac{1}{n} \sum_{i=1}^n y_i \quad (4.21)$$

Her bir m iterasyonu için mevcut modelin tahminlerine göre bir hata fonksiyonu türetilir:

$$r_{im} = - \left[\frac{\partial L(y_i, F(x_i))}{\partial F(x_i)} \right]_{F(x) = F_{m-1}(x)}, \quad i = 1, 2, \dots, N \quad (4.22)$$

Bu hatalar üzerinde yeni bir tahmin modeli $h_m(x)$ öğrenilir:

$$h_m(x) = \arg \min_h \sum_{i=1}^N L(y_i, F_{m-1}(x_i) + h(x_i)) \quad (4.23)$$

Optimal tahmin modeli bulunduktan sonra, bir öğrenme oranı α ile bu model genelleştirilir:

$$F_m(x) = F_{m-1}(x) + \alpha h_m(x) \quad (4.24)$$

Bu süreç, belirlenen sayıda iterasyon tamamlanana kadar devam eder. Burada, $F_{m-1}(x)$ bir önceki modelin tahminlerinden kaynaklanan hata vektörüdür ve $h_m(x)$ bu hatayı en aza indirecek yeni bir tahmin modelidir. Son olarak, α bir öğrenme oranıdır ve her yeni tahmin modelinin ne kadar katkı sağlayacağını kontrol eder.


GB'nin temelini bu iteratif hatayı düzeltme süreci oluşturur. Her bir model, bir öncekinin hatalarını düzelterek genel hata fonksiyonunu azaltmaya çalışır. Bu nedenle, ardışık olarak eklenen modellerin kombinasyonu, güçlü bir tahmin modeli oluşturur.

GB sıralama problemlerinde arama motoru sonuçlarının sıralanması ve ürün tavsiyesi gibi alanlarda kullanılabilir. Bu tür problemlerde, örnekler bir sıra içinde sıralanmalıdır ve GB algoritmaları, doğru sıralamayı öğrenmek için ve anormal durumları tespit etmek için kullanılabilir. Bir ağ üzerindeki anormal ağ trafiğini tespit etmek veya bir makine parçasının anormal davranışını belirlemek gibi problemlerde GB tercih edilebilir.

5. DENEYSEL SONUÇLAR

5.1 Ölçümsel Sonuçlar


Çalışmada üretim hattında T01 nolu tezgâhta üretilen hidrolik bağlantı parçalarının geliştirilen yapay görme sistemi ile otomatik kontrolü gerçekleştirilmiştir. Geliştirilen yazılım ara yüzünde parçanın durumu OK/NOK şeklinde gösterilmekte ve çap, en, boy ve uzunluk gibi ölçümsel parametreler incelenmiştir. Elde edilen ölçüm görselleri sırasıyla Şekil 5.1, Şekil 5.2 ve Şekil 5.3'te detaylı olarak gösterilmiştir. Hatasız ve hatalı parçalar için ölçüm sonuçları ve referans değerler geliştirilen ara yüzde görülebilmektedir. Kontrol birimleri, indikatörler aracılığıyla yeşil veya kırmızı renkte OK/NOK çıktı vermektedir. Hatalı parçaların tespiti sonrasında ana kontrol birimi, otomasyon kontrolcüsüne çıktı göndererek hatalı parçaların hattan ayrılmasını sağlamaktadır.



Şekil 5.1 : Birinci tip örnek parça hata tespiti.



Şekil 5.2 : İkinci tip örnek parça hata tespiti.



Şekil 5.3 : İkinci tip (alt görünüm) örnek parça hata tespiti.

Şekil 5.1 ve Şekil 5.2’de parçanın yandan görünümü için kontrol gösterilmiştir. Şekil 5.3 ise parçanın üstten ölçüm sonucunu göstermektedir. Geliştirilen yazılım arayüzünde kontrol birimleri ekranın sağ üst kısmında çerçeve içerisinde yazdırılmaktadır. Çerçeve içerisinde ölçüm ve referans değerler için iki kısım bulunmaktadır. Yapılan kontrol sonrasında ölçüm sonucu ekrana yazdırılmaktadır ve referans değer bilgisi de ekranda gösterilmektedir. Şekil 5.1’de görüleceği üzere, parçanın referans ölçüsü 10,10 mm iken bu uzunluk değeri hatalı olduğundan indikatör kırmızıya dönmüştür.

Tüm kontrol birimleri için bir indikatör oluşturularak yeşil renk ile gösterilmiştir. Kontrol birimi istenilen aralıkta değilse indikatör kırmızıya dönerek çıktı vermektedir. Buna ek olarak parçanın genel durumunu gösteren bir indikatör de ara yüz ekranına eklenmiştir. Bu indikatör alt indikatörlerden en az birinin hata tespit etmesi durumunda kırmızıya dönerek çıktı vermektedir. Çizelge 5.1’de kontrol edilen parçalara ilişkin referans parametreler ile ölçülen değerler gösterilmiştir. Referans parametreler, müşteri teknik resminde belirtilen kabul edilebilir alt ve üst değerler baz alınarak verilmiştir. Kontrol edilen parçalar ilk olarak kumpas ve mikrometre kullanılarak ölçülmüştür. Ölçülen parçalar numaralandırılarak sıralı bir şekilde kabinde ölçüme sokulmuştur. Sistem üzerinde ölçülen parçayla, ölçüm aleti ile ölçülen değerler karşılaştırılmış ve çizelge haline getirilmiş. Çizelge 5.1, Çizelge 5.2 ve Çizelge 5.3’te paylaşılmıştır. Ölçüm sonuçları arasında ki ortalama sapma çizelge altında paylaşılmıştır. Çizelge 5.1 ve Çizelge 5.2 ’de de görüleceği üzere, geliştirilen sistemin kontrol hassasiyetinin $< \%1$ olduğu görülmektedir.


Çizelge 5.1 : Kontrol edilen parçalara ilişkin üst ölçüm sonuçları.

Kontrol Edilen Parça	Uzunluk-1		Uzunluk-2	
	Referans Değer (mm)	Ölçülen Değer (mm)	Referans Değer (mm)	Ölçülen Değer (mm)
Parça-1	14,27	14,26	10,1	10,09
Hata (%)	%0.7		0,10%	
Parça-2	14	14,009	7	6,991
Hata (%)	0,06%		0,13%	
Parça-3	19,3	19,291	12,98	12,99
Hata (%)	0,05%		%0.077	

Çizelge 5.2 : Kontrol edilen parçalara ilişkin yan ölçüm sonuçları.

Kontrol Edilen Parça	Uzunluk-3		Uzunluk-4		Uzunluk-5	
	Referans Değer (mm)	Ölçülen Değer (mm)	Referans Değer (mm)	Ölçülen Değer (mm)	Referans Değer (mm)	Ölçülen Değer (mm)
Parça-1	36,5	36,507	18,5	18,502	18	18,01
Hata (%)	0,02%		%0.01		0,06%	
Parça-2	2	2,005	-	-	-	-
Hata (%)	0,25%		-		-	
Parça-3	9,63	9,633				
Hata (%)	%0.0311					

Parçalar kabin oluşturulduktan sonra farklı ışık, arka plan, pim, kabin, kamera filtrlri kullanılarak Labview NI ile oluşturulan ölçü kontrolü yazılımında denenmiş ve alınan sonuçlar incelenmiş ve görselleri ile beraber sunulmuştur. İlk testte orta ayarda ışık, beyaz arka plan, beyaz pim kullanılarak kamera fitresi kullanılmadan sac kabinde testler yapılmıştır. Belirlenen ilk parametreler oluşturulduktan sonra kalibrasyonu yapılmış ve yakalanan görüntü Şekil 5.4'te sunulmuştur.



Şekil 5.4 : Birinci test uygulanan parametreler sonra alınan görüntü.

Belirlenen ölçüler ve tolerans değerlerine göre parçaların ölçümleri yapılmıştır, ölçüm sonuçlarına ait grafikler Çizelge 5.3'te sunulmuştur.

Çizelge 5.3 : Birinci test ölçüm sapmaları.

Ortalama
sapma

Grafik

-0.051

"Height" Values Comparison

Inspection No.	Inspected (mm)	Measured (mm)	Error (mm)
0	23.316	23.350	-0.034
1	23.281	23.249	-0.032
2	23.253	23.230	-0.023
3	23.319	23.270	-0.049
4	23.276	23.200	-0.076
5	23.307	23.245	-0.062
6	23.292	23.260	-0.032
7	23.297	23.356	-0.059
8	23.283	23.240	-0.043
9	23.297	23.240	-0.057

Average Error: -0.051

-0.064

"Middle Waist" Values Comparison

Inspection No.	Inspected (mm)	Measured (mm)	Error (mm)
0	14.300	14.230	-0.070
1	14.312	14.240	-0.072
2	14.302	14.240	-0.062
3	14.283	14.220	-0.063
4	14.309	14.240	-0.069
5	14.285	14.230	-0.055
6	14.283	14.230	-0.053
7	14.301	14.220	-0.081
8	14.293	14.230	-0.063
9	14.284	14.240	-0.044

Average Error: -0.064


0.056

"Inner Waist" Values Comparison

Inspection No.	Inspected (mm)	Measured (mm)	Error (mm)
0	10.129	10.020	-0.109
1	10.087	10.020	-0.067
2	10.090	10.020	-0.070
3	10.125	10.030	-0.095
4	10.233	10.233	0.000
5	10.051	10.030	-0.021
6	10.122	10.060	-0.062
7	10.117	10.060	-0.057
8	10.077	10.040	-0.037
9	10.085	10.040	-0.045

Average Error: -0.056


Çizelge 5.3 (devam) : Birinci test ölçüm sapmaları.



Işık ayarı, ön kamera otomatik ayarlama yaptığından dolayı etkisiz kalmaktadır. Çok düşük/yüksek seviye aydınlatma değişiklik oluşturabilir (dengesizliğe sebep olabilir).

İkinci testte ışık ayarı düşürülmüş, arka planda pembe ve siyah keçe kullanılmış, pim pembe ile kağıt ile kapatılarak sac kabinde kamera filtresi desteğiyle ölçümler yapılmıştır. Belirlenen ilk parametreler oluşturulduktan sonra kalibrasyonu yapılmış ve yakalanan görüntü Şekil 5.5'te sunulmuştur. Görsellere bakıldığında siyah keçenin

kenar tespitini kolaylaştırdığı ve ortam aydınlatmasının hassasiyetinin arttırdığı Çizelge 5.4’de paylaşılmıştır.




Şekil 5.5 : İkinci test uygulanan parametreler sonra alınan görüntü.

Çizelge 5.4 : İkinci test ölçüm sapmaları.


Ortalama sapma

Grafik


-0.089



0.008




-0.034




Çizelge 5.4 (devam) : İkinci test ölçüm sapmaları.

Aydınlatma
optimizasyonu
deneme kabiniinde
sağlanamadığından
ölçüm kaymıştır.
Ortalama sapma :
0.193



Üçüncü testte karşılaşılan hatalar düzeltilmeye çalışılmıştır. Işık ayarı orta ayarda tutulmuş, arka plan pembe fon ve siyah keçe kullanılmış, ön işlem değiştirilerek kamera filtresi ile sac kabinde denemeler yapılmıştır. Yapılan değişiklikler sonrası kabinde çekilen parça görseli Şekil 5.6’da verilmiştir. Üçüncü test öncesi kalibrasyon gerçek ölçülere göre güncellenmiştir ve siyah keçenin kenar tespitini kolaylaştırdığı gözlemlenmiştir. Ölçüm sonuçları ile gerçek değerler arasındaki sapmalar Çizelge 5.5’te verilmiştir.



Şekil 5.6 : Üçüncü test uygulanan parametreler sonra alınan görüntü.

Çizelge 5.5 : Üçüncü test ölçüm sapmaları.

Ortalama Sapma

Grafik


0.008




0.052




0.015



-0.003



0.073




5.2 UWT'ye Göre Sonuçlar


UWT, dalgacık dönüşümü tekniklerini kullanılarak oluşturulan görüntü veri seti işlenmiştir.

Bu yöntem veri setinde özellik çıkarma aşamasında kullanılmıştır. Değişik ölçeklerdeki özellikleri belirleyerek görüntüleri daha etkili bir şekilde analiz edebilmesi nedeniyle tercih edilmiştir. UWT uygulanmış görsel çıktısı hata yok, çapak ve deformasyon Çizelge 5.6'da gösterilmiştir. UWT (undecimated wavelet transform), metal parçalar üzerindeki hataları tespit etme çalışmasında, malzeme yüzeyindeki ince kusurları ve anormallikleri yüksek çözünürlüklü bir şekilde saptayabilmek için kullanılır. Bu yöntem, metal yüzeyinin detaylı bir analizini sağlayarak, hatalı bölgelerin frekans ve ölçek bilgilerini elde etmekte ve böylece erken aşamada kusur tespitine olanak tanımaktadır.

Çizelge 5.6 : UWT uygulanmış sonuçlar.


Hata yok	Çapak	Deformasyon
		

Öznitelik çıkarma işleminde UWT kullanıldıktan sonra SVM ile sınıflandırma işlemine tabi tutulmuştur. SVM sonrası çıkan sonuç, Şekil 5.7'de %97 olarak gösterilmiştir.




Şekil 5.7 : SVM hata matrisi.

Sınıflandırma çeşitleri bölümünde k-en yakın komşu metodu ve özellikleri detaylı bir şekilde anlatılmıştır. UWT işlemi uygulanan veri KNN sınıflandırıcısı metodu ile denenmiştir. Çıkan sonuçlar Şekil 5.8’de gösterilmiştir. Başarı oranı %95 çıkmıştır.




Şekil 5.8 : UWT ve KNN hata matrisi.

UWT sonrası YSA uygulanan görüntülerde %92,85 oranında doğruluk yakalanmıştır. Modele ait eğitim ve doğrulama değerleri Şekil 5.9’da paylaşılmıştır.



Şekil 5.9 : YSA model sonuçları.

YSA modeli ile sınıflandırma işleminde saptanan çapaklı parçaya ait görsel Şekil 5.10’da, deformasyonlu parça ise Şekil 5.11’de paylaşılmıştır. Sağ tarafta bulunan görseller parçanın işlem öncesi görselleridir.




Şekil 5.10 : YSA metodu ile saptanan çapaklı parça.



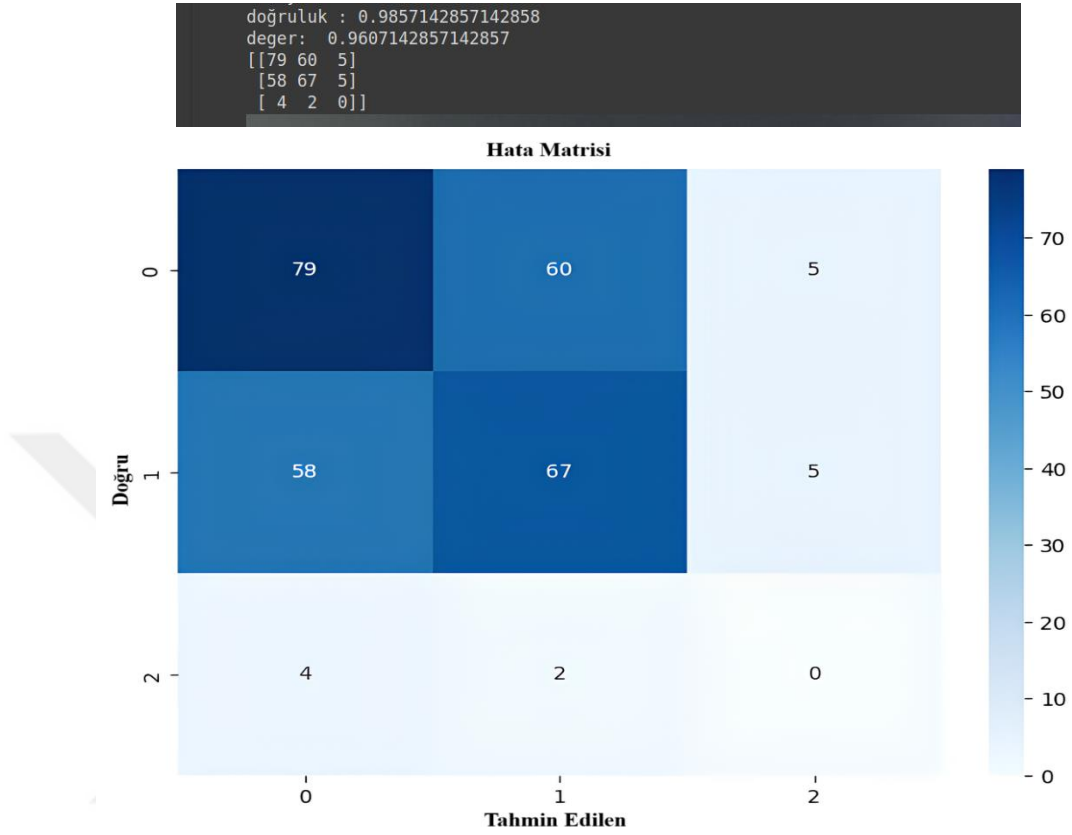
Şekil 5.11 : YSA metodu ile saptanan deformasyonlu parça.

Görüntü işleme uygulamalarında, genellikle çok sayıda özellik (veya piksel) bulunur. DT, veri özelliklerinin önemini değerlendirerek otomatik olarak en bilgilendirici özellikleri seçme yeteneğine sahiptir. Bu özelliğinin test edilmesi için UWT sonrası veri DT metodu ile sınıflandırılmaya çalışılmıştır. Şekil 5.12 ‘de görüldüğü üzere %98,2 doğruluk oranı yakalanmıştır.



Şekil 5.12 : UWT ve DT hata matrisi.

UWT ile özellik çıkarım yöntemi sonrası GB sınıflandırıcısının kullanılması, sinyal veya veri analizi alanında yaygın bir yaklaşımdır. UWT sonrası uygulanan GB metodu ile sınıflandırma çalışılmıştır ve %98,6 doğruluk oranı Şekil 5.13'te paylaşılmıştır.




Şekil 5.13 : UWT ve GB hata matrisi.

5.3 CWT'ye Göre Sonuçlar


CWT, özellikle görüntü işleme alanında kullanılan bir öznitelik çıkarma yöntemidir. CWT, farklı ölçeklerdeki (ya da frekanslardaki) yapıları tespit etme yeteneğine sahiptir. Bu, bir görüntüdeki farklı özellikleri, örneğin kenarlar, köşeler veya doku desenleri gibi, farklı ölçeklerde algılayabilme anlamına gelir. Parçanın kenarlarının tespiti, deformasyon ve çapaklı parçaların yakalanabilmesi için veri setine CWT metodu öznitelik çıkarmak için uygulanmıştır.

CWT uygulanmış görsel çıktısı Çizelge 5.7'de hata yok, çapak ve deformasyon gösterilmiştir.

Çizelge 5.7 : CWT uygulanmış sonuçlar.

Hata yok	Çapak	Deformasyon
		


CWT öznitelik çıkarma işlemi uygulanmış görsellere SVM metodu uygulanmıştır. %96,4 oranında doğruluk yakalanmıştır. CWT ve SVM işlem sonuçlarına göre ait hata matrisi Şekil 5.14'te paylaşılmıştır.



Şekil 5.14 : SVM hata matrisi.


CWT öznitelik çıkarma işlemi uygulanmış görseller KNN metodu uygulanmıştır. %95,71 oranında doğruluk yakalanmıştır. CWT ve KNN işlem sonuçlarına ait hata matrisi Şekil 5.15'te paylaşılmıştır.

```
Doğruluk: 0.9571428571428572  
Precision: 0.9593624726676385  
Recall: 0.9571428571428572  
F1 Score: 0.9562651821862346
```




Şekil 5.15 : KNN hata matrisi.

CWT öznitelik çıkarma işlemi uygulanmış görsellere DT metodu uygulanmıştır. %95 oranında doğruluk yakalanmıştır. CWT ve DT işlem sonuçlarına ait hata matrisi Şekil 5.16’da paylaşılmıştır.



Şekil 5.16 : DT hata matrisi.

CWT öznitelik çıkarma işlemi uygulanmış görsellere GB metodu uygulanmıştır. %95,71 oranında doğruluk yakalanmıştır.





5.4 DWT'ye Göre Sonuçlar

DWT (discrete wavelet transform), bir yapı veya desenin rotasyon veya ölçek değişimine karşı hassastır. Bu görüntülerdeki nesnelerin farklı açılarda veya boyutlarda bulunabileceği durumlarda bile etkili bir şekilde çalışmasını sağlar. Bu nedenle kabin içerisinde kamera kalibrasyonu veya konumlanmasından kaynaklı değişikliklerde diğer metotlara kıyasla nasıl bir sonuç vereceğinin gözlemlenmesi için test edilmiştir.

CWT uygulanmış görsel çıktısı Çizelge 5.8'de hata yok, çapak ve deformasyon gösterilmiştir.

Çizelge 5.8 : DWT uygulanmış sonuçlar.

Hata yok	Çapak	Deformasyon
		


DWT öznitelik çıkarma işlemi uygulanmış görsellere SVM metodu uygulanmıştır. %93 oranında doğruluk yakalanmıştır. DWT ve SVM işlem sonuçlarına ait hata matrisi Şekil 5.18’de paylaşılmıştır.



Şekil 5.18 : SVM hata matrisi.

DWT öznitelik çıkarma işlemi uygulanmış görsellere KNN metodu uygulanmıştır. %95 oranında doğruluk yakalanmıştır. DWT ve KNN işlem sonuçlarına ait hata matrisi Şekil 5.19’da paylaşılmıştır.

```
Doğruluk: 0.9535714285714286  
Precision: 0.9535714285714286  
Recall: 0.9535714285714286  
F1 Score: 0.9535714285714286
```



Şekil 5.19 : KNN hata matrisi.

DWT öznitelik çıkarma işlemi uygulanmış görseller DT metodu uygulanmıştır. %93,9 oranında doğruluk yakalanmıştır. DWT ve DT işlem sonuçlarına ait hata matrisi Şekil 5.20’de paylaşılmıştır.

```
Doğruluk: 0.9392857142857143  
Precision: 0.9464178925832751  
Recall: 0.9392857142857143  
F1 Score: 0.9414583333333334
```



Şekil 5.20 : DT hata matrisi.

6. SONUÇ VE TARTIŞMA

Talaşlı imalat metodu ile CNC tezgahlarda otomotiv ve savunma ana sanayiye metal bağlantı parçaları üreten bir firmada, tezgahtan çıkan parçaların ölçüsel kontrolleri yapılmış, uygun sinyali alındıktan sonra görsel kontrolleri yapılarak sınıflandırılmıştır. Vardiya bitiminde üretim bandından alınan parçalar, yıkama sonrası ölçüsel ve görsel kontrollere tabi tutulmuştur. Kontrol sonuçları karşılaştırma yapmak için kayıt altına alınmıştır. Bir vardiyalık üretimden çıkan hatalar anlık tespit edilemediği için hurdaya ayrılmakta veya yeniden işlem operasyonuna sokulmaktadır. Geliştirilen sistem ile çıkan ilk hatalı parça anlık olarak tespit edilmekte ve uygun parça üretimi yapılabilmesi için üretim bilgilendirilmektedir. Geliştirilen sistem iki ay boyunca kullanılarak veriler toplanmıştır. Geliştirilen sistem öncesinde ki veriler ile karşılaştırıldığında hurda adetlerinde %15 oranında azalma gözlemlenmiştir. Üretimde bulunan diğer tezgah ve parçalara da yaygınlaştırıldığında bu yüzdenin artacağı öngörülmektedir. Kontroller LabVIEW NI Vision Builder yazılımı kullanılarak gerçekleştirilmiştir. Ölçüsel kontroller sonucunda çıkan değerlere bakıldığında, %0,5-%1 aralığında hedeflenen saptanabilirliğin, doğru ışık ayarlamalarıyla %0,1 seviyelerinde yakalanabildiği gözlemlenmiştir. Ölçüsel uygun olan parçalar makine öğrenmesi yöntemleri kullanılarak görsel uygun, çapaklı ve deformasyonlu olarak sınıflandırılmıştır. Model eğitimi, Colab Pro versiyonu kullanılarak, 16 GB A100 GPU ve 51 GB Sistem Ram özellikli bilgisayarda gerçekleştirilmiştir. Eğitim verisi 416x416 piksel boyutuna getirilmiştir. Toplam 300 adım (epoch) kullanılmıştır. Ayrıca, her bir eğitim adımında ağı güncellemek için kullanılan toplu veri (batch size) 16 olarak seçilmiştir. Colab, yüksek grafik işlem birimi (GPU) özelliğinden dolayı seçilmiştir. Eğitim parametreleri, yüzeydeki hata tespit ihtiyaçlarına göre seçilmiştir ve en iyi sonucu verecek şekilde optimize edilmiştir. Öznitelik çıkarma işlemi tamamlanan data, import edilerek sınıflandırma işlemine sokulmuştur. Burada farklı sınıflandırıcılar ile denemeler yapılarak sonuçlar toplanmıştır. Çalışmada öznitelik çıkarma süreçlerinde UWT, DWT ve CWT kullanılmıştır. Görüntü işleme çalışmalarında UWT, CWT ve DWT kullanmak, özellikle frekans analizi, sıkıştırma,

denoising (gürültü giderme) ve özellik çıkarımı gibi alanlarda büyük avantajlar sunmaktadır. Öznitelik çıkarma işleminde kalite karakteristiği olarak ölçülemeyen ve görsel bütünlüğünü bozan çapak, deformasyon gibi unsurlar baz alınmıştır. Öznitelik çıkarma işlemi tamamlandıktan sonra sınıflandırma için SVM, KNN, YSA, DT, GB kullanılarak sonuçlar değerlendirilmiştir. Çıkan sonuçlar Çizelge 6.1’de ayrıntılı bir şekilde verilmiştir.

Çizelge 6.1 : Karşılaştırma tablosu.

	SVM	GB	KNN	YSA	DT
UWT	97,03%	98,5%	95,35%	92,85%	98,20%
CWT	96,42%	95,71%	95,71%	-	95,00%
DWT	93,21%	-	95,35%	-	93,92%

Görsel kontrol sonuçları incelendiğinde görüntü işleme uygulamalarında en iyi sonucun UWT ve GB ile alındığı gözlemlenmiştir. Çalışmalar sırasında verilerin bir kısmı prototip kabinde, bir kısmı da geliştiren sisteme ait kabinde toplanmıştır. Bu nedenle görsellerin konumlarında değişkenlikler vardır. İleriki çalışmalarda daha yüksek doğruluk değerleri için tüm verilerin aynı ışık, kamera konumu ve çevre faktörleri ile alınması önerilmektedir. Ölçüsel ve görsel kontrolün aynı sistem üzerinde birleştirilmesinde birçok sıkıntı ile karşılaşmıştır. Ölçüsel kontrolde karartılmış keskin köşeler sonucu olumlu yönde etkilerken, görsel kontrollerde ışıklı bir alan, parçanın yüzeyinin net görülebilmesi için önemli bir kriterdir. Işık optimizasyonu için polarize filtre, led çubuklar ve arka fon çeşitleri denenmiş, ölçüsel ve görsel kontroller için en uygun alan oluşturulmaya çalışılmıştır. Bir diğer yaşanan sıkıntı da kameralar kaynaklıdır. Sanayide bu tarz kontroller için kullanılan kameraların maliyetlerinin yüksek olması nedeni ile standart kameralar kullanılmış ve yazılım ile güçlendirilmiştir. Sistemin devreye alınması ve testler için bu kameralar iyi sonuçlar verse de, uzun soluklu kullanımlarda, ısınma, görüntü kaybı gibi sıkıntılarla karşılaşmaktadır. Üretim hattında tüm gün çalışması planlanan bir sistem için kamera modelinin değiştirilmesi, ölçüsel ve görsel kontrollerde ihtiyaç duyulan farklı tip ışık ayarları için otomasyona ışık aç, kapa gibi komutların tanımlanması daha iyi sonuçlar alınmasına olanak sağlayacaktır.

KAYNAKLAR

- [1] M. Schwab et al. (2022) "Multi-Model Machine Learning based Industrial Vision Framework for Assembly Part Quality Control," *2022 IEEE 27th International Conference on Emerging Technologies and Factory Automation (ETFA)*, Stuttgart, Germany, 2022, pp. 1-4, doi: 10.1109/ETFA52439.2022.9921587
- [2] G. Bayrak, A. Çakiroğlu, İ. Öztürk Yılmaz, A. Y. Bılcı and Y. A. Candemir (2022) "Otomotiv Üretim Hatlarındaki 3D Parçaların Kalite Kontrolü İçin Endüstri 4.0 İle Uyumlu Yapay Görme Sisteminin Geliştirilmesi," *2022 International Symposium on Multidisciplinary Studies and Innovative Technologies (ISMSIT)*, Ankara, Turkey, 2022, pp. 624-628, doi: 10.1109/ISMSIT56059.2022.9932814.
- [3] Güzelce, Burak (2021) *Endüstriyel uygulamalarda görüntü işleme tabanlı otomatik hata tespit yöntemlerinin geliştirilmesi*. 2021. Master's Thesis. BTÜ, Fen Bilimleri Enstitüsü
- [4] Kavas, Ataberk, et al. (n.d.). *Araç Tamponu Yüzey Kusurlarının Otomatik Tespiti için Görüntü İşleme ve Yapay Zeka Tabanlı Bir Sistem Geliştirilmesi* Development of an Image Processing and Artificial Intelligence-Based System for Automatic Detection of Vehicle Bumper Surface Defects.
- [5] T. Rekić, I. Beissmann, A. Čebo and F. Novoselnik. (2022). "Visual Quality Inspection of Rotors and Stators," *2022 International Conference on Smart Systems and Technologies (SST)*, Osijek, Croatia, 2022, pp. 319-324, doi: 10.1109/SST55530.2022.9954883.
- [6] Sharma, Sonia, and Megha Garg. (2022). "DL-based Visual Interpretability over Medical Images using StyleGAN." *2022 International Conference on Futuristic Technologies (INCOFT)*. IEEE, 2022.
- [7] Kırat, S. S.; Aydın, İ. (2023) *Açıklanabilir Yapay Zekâ Tabanlı Denetimsiz Öğrenme ile Ray Kusur Tespiti*. Demiryolu Mühendisliği, 2023, 18: 1-13.
- [8] Kaya, Z., Aksoy, B., & Özsoy, K. (n.d.). Eklemeli İmalat Yöntemiyle Üretilen Altı Eksenli Robot Kol ile Görüntü İşleme ve Yapay Zeka Tabanlı Ürünlerin Tasniflemesi. *Journal of Materials and Mechatronics: A*, 4.1: 193-210.
- [9] Göksu, Mustafa; Göksu, Şafak; Alkan, Ahmet (2022) *Derin Öğrenme Tabanlı Görüntü İşleme İle Acil Durum Tespiti*. Computer Science, 2022, 101-111.
- [10] E. Tur (2023) "Applying Deep Learning for Automated Quality Control and Defect Detection in Multi-Stage Plastic Extrusion Process," *2023 5th*

- [11] **N. Boaretto and T. M. Centeno.** (2017) ``Automated detection of welding defects in pipelines from radiographic images DWDI," NDT E Int., vol. 86, pp. 7-13, Mar. 2017.
- [12] **S. Hajizadeh, A. Núñez, and D. M. J. Tax.** (2016). ``Semi-supervised rail defect detection from imbalanced image data," IFAC-PapersOnLine, vol. 49, no. 3, pp. 78-83, 2016.
- [13] **Z. Wakaf and H. A. Jalab.** (2018). ``Defect detection based on extreme edge of defective region histogram," J. King Saud Univ.-Comput. Inf. Sci., vol. 30, no. 1, pp. 33-40, Jan. 2018.
- [14] **S. S. Martínez, C. O. Vázquez, J. G. García, and J. G. Ortega.** (2017). "Quality inspection of machined metal parts using an image fusion technique," Measurement, vol. 111, pp. 374-383, Dec. 2017.
- [15] **S. Hochreiter and J. Schmidhuber.** (1997). "Long short-term memory," Neural computation, vol. 9, no. 8, pp. 1735-1780, 1997.
- [16] **P. Malhotra, A. Ramakrishnan, G. Anand, L. Vig, P. Agarwal, and G. Shroff.** (2016). "LSTM-based encoder-decoder for multi-sensor anomaly detection," arXiv preprint arXiv:1607.00148, 2016.
- [17] **S. Kim, S. Kim, and K. R. Ryu.** (2018). "Deep learning experiments with skewed data for defect prediction in plastic injection molding," in *2018 IEEE/ACS 15th International Conference on Computer Systems and Applications (AICCSA)*, IEEE, 2018.
- [18] **Wang, Z., Xiao, Z., Tse, Y., Huang, C., & Zhang, W.** (2019). *Optimization of processing parameters and establishment of a relationship between microstructure and mechanical properties of SLM titanium alloy.* Optics & Laser Technology, 112, 159-167
- [19] **P. M. Bhatt et al.** (2021). "Image-based surface defect detection using deep learning: A review," Journal of Computing and Information Science in Engineering, vol. 21, no. 4, 2021.
- [20] **W. Zhao et al.** (2021). "A new steel defect detection algorithm based on deep learning," Computational Intelligence and Neuroscience, vol. 2021, pp. 1-13, 2021.
- [21] **A.-A. Tulbure, A.-A. Tulbure, and E.-H. Dulf** (2022) "A review on modern defect detection models using DCNNs–Deep convolutional neural networks," Journal of Advanced Research, vol. 35, pp. 33-48, 2022.
- [22] **Wang, C. Y., Bochkovskiy, A., & Liao, H. Y. M.** (2020). Scaled-YOLOv4: Scaling cross stage partial network.

ÖZGEÇMİŞ

Ad-Soyad : Elif Aydan Bike

Doğum Tarihi ve Yeri : -

E-posta : -

ÖĞRENİM DURUMU:

- **Lisans** : 2015, İstanbul Arel Üniversitesi, Mühendislik Fakültesi, Endüstri Mühendisliği
- **Yüksek Lisans** : 2024, Bursa Teknik Üniversitesi, Mühendislik ve Doğa Bilimleri Enstitüsü – Akıllı Sistemler Mühendisliği

MESLEKİ DENEYİM VE ÖDÜLLER:

- Karsan, ATA/ATAK Yeni Ürün Proje Lideri
- Erbab Otomat, Mühendislik ve Metot Yöneticisi

TEZDEN TÜRETİLEN ESERLER, SUNUMLAR VE PATENTLER:

- TÜBİTAK TEYDEB 1501 Sanayi Ar-Ge Projeleri Destekleme Programı kapsamında (Proje No: 3220867) “Otomotiv ve Savunma Sanayi Üretim Hatlarındaki Parçaların Dalgacık Dönüşümü Tabanlı Yapay Görme Sistemi ile Otomatik Kontrolü”. Proje Yürütücüsü: Elif Aydan BİKE.
- Elif Aydan BİKE, Gökay BAYRAK. “Development of LabVIEW-Based Quality Control System”. In Proceedings of IV. International Science and Innovation Congress, 27-30 July 2023, TURKEY. Pages: 83-90, ISBN: 978-605-71214-8-6.