

T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

OTOMOTİV SEKTÖRÜNDE PARÇA KONTROLÜ İÇİN YAPAY
ZEKÂ DESTEKLİ YAZILIM GELİŞTİRİLMESİ

DOKTORA TEZİ

Onur ARDIÇ

Elektrik-Elektronik Mühendisliği Anabilim Dalı

Elektronik Bilim Dalı

SUBAT 2025

T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

OTOMOTİV SEKTÖRÜNDE PARÇA KONTROLÜ İÇİN YAPAY
ZEKÂ DESTEKLİ YAZILIM GELİŞTİRİLMESİ

DOKTORA TEZİ

Onur ARDIÇ

Elektrik-Elektronik Mühendisliği Anabilim Dalı

Elektronik Bilim Dalı

Tez Danışmanı: Doç. Dr. Gökçen ÇETİNEL

ŞUBAT 2025

Onur ARDIÇ tarafından hazırlanan “**OTOMOTİV SEKTÖRÜNDE PARÇA KONTROLÜ İÇİN YAPAY ZEKÂ DESTEKLİ YAZILIM GELİŞTİRİLMESİ**” adlı tez çalışması 20.12.2024 tarihinde aşağıdaki jüri tarafından oy birliği ile Sakarya Üniversitesi Fen Bilimleri Enstitüsü Elektrik-Elektronik Mühendisliği Anabilim Dalı’nda Doktora tezi olarak kabul edilmiştir.

Tez Jürisi

Jüri Başkanı:	Prof. Dr. Devrim AKGÜN Sakarya Üniversitesi
Jüri Üyesi :	Doç. Dr. Gökçen ÇETİNEL (Danışman) Sakarya Üniversitesi
Jüri Üyesi :	Doç. Dr. M. Kürşad UÇAR Sakarya Üniversitesi
Jüri Üyesi :	Doç. Dr. A. Furkan KAMANLI Sakarya Uygulamalı Bilimler Üniversitesi
Jüri Üyesi :	Doç. Dr. Orhan AKBULUT Kocaeli Üniversitesi



ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ

Sakarya Üniversitesi Fen Bilimleri Enstitüsü Lisansüstü Eğitim-Öğretim Yönetmeliğine ve Yükseköğretim Kurumları Bilimsel Araştırma ve Yayın Etiği Yönergesine uygun olarak hazırlamış olduğum “Otomotiv Sektöründe Parça Kontrolü için Yapay Zekâ Destekli Yazılım Geliştirilmesi” başlıklı tezin bana ait, özgün bir çalışma olduğunu; çalışmamın tüm aşamalarında yukarıda belirtilen yönetmelik ve yönergeye uygun davrandığımı, tezin içerdiği yenilik ve sonuçları başka bir yerden almadığımı, tezde kullandığım eserleri usulüne göre kaynak olarak gösterdiğimi, bu tezi başka bir bilim kuruluna akademik amaç ve unvan almak amacıyla vermediğimi ve 20.04.2016 tarihli Resmi Gazete ’de yayımlanan Lisansüstü Eğitim ve Öğretim Yönetmeliğinin 9/2 ve 22/2 maddeleri gereğince Sakarya Üniversitesi’nin aboneliği olduğu intihal yazılım programı kullanılarak Enstitü tarafından belirlenmiş ölçütlere uygun rapor alındığımı, çalışmamla ilgili yaptığım bu beyana aykırı bir durumun ortaya çıkması halinde doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi beyan ederim.

(30/01/2025)

Onur ARDIÇ



TEŞEKKÜR

Doktora eğitimim sürecinde deneysel çalışmaların yönlendirilmesi, sonuçların değerlendirilmesi ve yazım aşamalarında yapmış olduğu büyük katkılarından dolayı tez danışmanım Sayın Doç. Dr. Gökçen ÇETİNEL'e en içten teşekkürlerimi sunarım. Tez izleme süreçlerinde farklı açılar ile çalışmanın yönlendirilmesine katkıda bulunan Sayın Prof. Dr. Devrim AKGÜN ve Doç. Dr. Muhammed Kürşad UÇAR hocalarıma da teşekkürü borç bilirim.

Araştırmalarım boyunca gerçek zamanlı çalışma ortamı sağlayarak gerekli izin ve desteklerini esirgemeyen ve bir parçası olmaktan gurur duyduğum, Toyota Otomotiv Sanayi A.Ş. ailesine de minnettarım. Bu çalışmanın gerçekleşmesinde önemli rol oynayan yöneticilerimden hattaki çalışma arkadaşlarıma kadar herkesin gösterdiği anlayış ve iş birliği, araştırmanın başarısında kilit bir rol oynamıştır.

Bu zorlu süreçte maddi ve manevi destekleriyle her zaman yanımda olan, bana inanan ve gerektiği anda motivasyon aşılayan başta eşim Fatma ARDIÇ'a ve sevgili aileme en derin şükranlarımı sunarım. Ayrıca, süreç içerisinde desteklerini esirgemeyen tüm arkadaşlarıma ve bugünlere gelmemde emekleri olan, bana ilham veren tüm hocalarıma teşekkür ederim. Her birinizin katkısı, bu çalışmanın tamamlanmasında önemli bir yere sahiptir.

Onur ARDIÇ



İÇİNDEKİLER

Sayfa

ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ	v
TEŞEKKÜR	vii
İÇİNDEKİLER	ix
KISALTMALAR	xi
SİMGELER	xiii
TABLO LİSTESİ	xv
ŞEKİL LİSTESİ	xvii
ÖZET	xix
ABSTRACT	xxiii
1. GİRİŞ	1
1.1. Otomotiv Sektöründe Parça Kontrolünün Önemi	2
1.2. Literatür Taraması	6
1.3. Derin Öğrenmede Denetimli ve Denetimsiz Yaklaşımlar.....	11
1.4. Derin Öğrenmenin Gelişimi ve Modern Uygulama Alanları.....	13
1.5. Tezde Kullanılan Derin Öğrenme Teknikleri.....	15
1.6. Yapay Zekâ ve Etik Kuralları.....	26
1.7. Önerilen Çalışmanın Özgün Yönleri.....	27
2. DERİN ÖĞRENMEDE VERİ ARTIRMA VE UYGULAMA YÖNTEMLERİ	31
2.1. Veri Artırma Yöntemleri	35
2.2. Rastgele Rotasyon Yönteminin Oluşturulması	36
3. YAPAY ZEKÂ TABANLI MOTOR PARÇA KONTROL SİSTEMİ KURULUMU	43
3.1. Derin Öğrenme Yöntemleri Kullanılarak Gerçek Zamanlı Parça Kontrol Sistemi Uygulama Süreci	51
4. İNSAN ROBOT İŞ BİRLİĞİ VE YAPAY ZEKÂ İLE DESTEKLENMİŞ ÜRETİM OPTİMİZASYONU	67
4.1. İş Birlikçi Robotların Gelişimi	72
4.2. Problem Tanımı ve Matematiksel Model.....	73
4.3. İnsan Robot İş Birliğinde Kullanılan Yöntemler	81
5. TARTIŞMA VE SONUÇ	91
KAYNAKLAR	95
ÖZGEÇMİŞ	107

KISALTMALAR

ANN	: Artificial Neural Network (Yapay Sinir Ağı)
AP	: Average Precision (Ortalama Hassasiyet)
Bbox	: Bounding Box (Nesne Sınırlama Kutusu)
Bbox reg	: Bounding Box Regression (Sınırlayıcı Kutu Regresyonu)
CNN	: Convolutional Neural Network (Evrışimsel Sinir Ağı)
DNN	: Deep Neural Network (Derin Sinir Ağı)
DOF	: Degrees of Freedom (Serbestlik Derecesi)
FC	: Fully Connected (Tam Bağlantılı Katman)
FPN	: Feature Pyramid Network
FPS	: Frames Per Second (Saniye Başına Kare)
GAN	: Generative Adversarial Network (Üretken Çekişmeli Ağ)
HRC	: Human-Robot Collaboration (İnsan-Robot İş Birliği)
IoT	: Internet of Things (Nesnelerin İnterneti)
IoU	: Intersection over Union (Birleşim Üzerinden Kesişim)
LSTM	: Long Short-Term Memory (Uzun Kısa Dönem Hafızası)
mAP	: Mean Average Precision (Ortalama Hassasiyet)
Max Dets	: Maximum Detections (Maksimum Tespit Edilen Nesne Sayısı)
ML	: Machine Learning (Makine Öğrenimi)
NMS	: Non-Maximum Suppression (Maksimum Olmayan Bastırma)
RBFN	: Radial Basis Function Network (Radyal Tabanlı Fonksiyon Ağı)
RGB	: Red Green Blue (Kırmızı Yeşil Mavi)
R-CNN	: Region-based Convolutional Neural Networks
RNN	: Recurrent Neural Network (Tekrarlayan Sinir Ağı)
ROI	: Region of Interest (İlgilenilen Alan)
RPN	: Region Proposal Network (Bölge Öneri Ağı)
SSD	: Single Shot Multibox Detektör
SSIM	: Structural Similarity Index Measure (Yapısal Benzerlik İndeksi)
SVM	: Support Vector Machine (Destek Vektör Makineleri)
SxS	: Grid Size (Izgara Boyutu)
VOC	: Visual Object Classes (Görsel Nesne Sınıfları)

YOLO : You Only Look Once (Tek Seferde Bak)

YZ : Yapay Zekâ



SİMGELER

x	: Model giriş görüntüsü [<i>Matris</i> - Birimsiz]
c	: Tahmin edilen sınıf olasılıkları [<i>Vektör</i> - Birimsiz]
l	: Normalize edilmiş koordinat (<i>Vektör</i> - [0,1] veya pixel (px))
g	: Normalize edilmiş koordinat (<i>Vektör</i> - [0,1] veya pixel (px))
a_1	: Kayıp fonksiyonlarının ağırlık faktörü [<i>Skaler</i> - Birimsiz]
α	: Katma değeri olmayan iş [<i>Skaler</i> - Saniye (sn)]
t_{ap}	: Görev süresi [<i>Skaler</i> - Saniye (sn)]
μ	: Ortalama parlaklık değeri [<i>Skaler</i> - Birimsiz]
σ	: Parlaklık varyansı [<i>Skaler</i> - Birimsiz]
FPS	: Saniye başına düşen kare sayısı [<i>Skaler</i> - Kare/Saniye (sn)]
C_a	: Görev başlangıç zamanı [<i>Skaler</i> - Saat: Dakika: Saniye]
N	: Pozitif eşleşen çapa kutuların sayısı [<i>Skaler</i> - Birimsiz]
B	: Tampon kapasitesi [<i>Skaler</i> - Adet]
T	: Zaman [<i>Skaler</i> - Saniye (sn)]
k	: İstasyon indeksi [<i>Skaler</i> - Birimsiz]
γ_{ao}	: Görev sıralama değişkeni [<i>Skaler</i> - İkili değişken (0 veya 1)]
ε	: Mümkün en düşük proses zamanı [<i>Skaler</i> - Saniye (sn)]



TABLO LİSTESİ

Sayfa

Tablo 2.1. VY ile RRY yönteminin farklı koşullar altında karşılaştırılması.....	40
Tablo 3.1. Faster R-CNN ve SSD için eğitim sonuçları.....	62
Tablo 3.2. Faster R-CNN ve SSD metotlarının yüzdelik eğitim sonuçları ve işlem süreleri.....	65
Tablo 3.3. Faster R-CNN ve SSD yöntemlerine ait eğitim ve test sonuçları [18]. ...	65
Tablo 4.1. Birlikte var olma kategorisi için örnek çalışma senaryosu.	70
Tablo 4.2. Senkronizasyon kategorisi için örnek çalışma senaryosu.	70
Tablo 4.3. İş birliği kategorisi için örnek çalışma senaryosu.	70
Tablo 4.4. Ortak çalışma kategorisi için örnek çalışma senaryosu.	71
Tablo 4.5. Hat matematiksel modeli için kullanılan terimler.....	77
Tablo 4.6. Alternatiflerin verildiği hat zaman tablosu.	80
Tablo 4.7. Özel veri kümesi üzerinde SSIM performansının değerlendirilmesi.....	85



ŞEKİL LİSTESİ

Sayfa

Şekil 1.1. Otonom araçlar için kontrol edilen bölgeler.....	3
Şekil 1.2. RCNN mimarisi ve nesne tanıma süreci.....	16
Şekil 1.3. Fast- RCNN mimarisi nesne tanıma sıralaması.....	17
Şekil 1.4. Faster- RCNN mimarisi ile alakalı nesne tanıma sıralaması.....	18
Şekil 1.5. YOLO mimarisi nesne tanıma süreçleri	20
Şekil 1.6. SSD ve YOLO mimarisi katmanları.....	23
Şekil 2.1. Ön işleme ile veri artırma yöntemine ait blok diyagram.	35
Şekil 2.2. Gerçek zamanlı veri artırma yöntemine ait blok diyagram.	36
Şekil 2.3. Uygulamada sıklıkla kullanılan bazı veri artırma yöntemleri.	36
Şekil 2.4. Seri üretim parçası üzerinde $\pm 6^\circ$ pozisyon değişikliği örneği.....	38
Şekil 2.5. DL eğitim sürecinde açı ve eksenel boyut değişim örnekleri.....	39
Şekil 3.1. (a) Motorun araca monte edilmeden önceki gösterimi, (b) Motorun araç üzerine monte edilmiş gösterimi	43
Şekil 3.2. (a) Gizlenmiş üç boyutlu bir motor modeli, (b) Kontrol istasyonu ile alakalı simülasyon.....	44
Şekil 3.3. Üç boyutlu motor modeli ve ihtiyaç duyulan parça kontrol alanı.	44
Şekil 3.4. Motor parçalarının kontrolü amaçlı iş birlikçi robot kullanım seçenekleri (a) Yan yana konumlandırılmış iki iş birlikçi robot ve (b) Ters çevrilmiş iş birlikçi robot kullanımı (Robo-Guide Programı).	45
Şekil 3.5. Farklı sınıflardaki araç parçalarının örnek gösterimi.....	47
Şekil 3.6. Fanuc CR-15ia taşıma yükü ile alakalı grafik	48
Şekil 3.7. YZ destekli motor kontrol sistemine ait genel diyagram.....	49
Şekil 3.8. DL eğitim aşamaları.	50
Şekil 3.9. Karar verme blok diyagramı.....	51
Şekil 3.10. Gerçek zamanlı parça kontrol sisteminin fabrika içerisindeki görünümü.	52
Şekil 3.11. İş birlikçi robot çalışması için oluşturulan taşıyıcı çerçeve.....	54
Şekil 3.12. Parça denetleme kalite kontrol sistemi genel diyagramı.	57
Şekil 3.13. (a) Faster R-CNN, (b) SSD için toplam kayıp eğrisi.....	61
Şekil 3.14. Faster R-CNN ve SSD metotları ile alakalı eğitim ve test sonuçları.....	64
Şekil 4.1. HRC süreçlerinin işin yapılış türüne göre sınıflandırılması.	69
Şekil 4.2. Test ve Simülasyon için oluşturulmuş direksiyon hazırlık prosesi a) Genel görünüm, b) Montaj parçaları.	74
Şekil 4.3. İş adımları için oluşturulmuş görev diyagramı.....	75
Şekil 4.4. Montaj ve operasyon adımlarına ait sıralı simülasyon gösterimi.....	75
Şekil 4.5. Farklı görev modları ile alakalı döngü süreleri.....	81
Şekil 4.6. YZ eğitim ve operasyon süreçleri hakkında örnek akış diyagramı.	82
Şekil 4.7. SSIM yöntemi bütünleştirilerek geliştirilmiş YZ eğitim ve operasyon süreçleri hakkında örnek akış diyagramı.....	85
Şekil 4.8. Bölgesel bazlı kontrol sisteminin direksiyon hazırlık masa örneği ile gösterimi.....	87



OTOMOTİV SEKTÖRÜNDE PARÇA KONTROLÜ İÇİN YAPAY ZEKÂ DESTEKLİ YAZILIM GELİŞTİRİLMESİ

ÖZET

Otomotiv sektörü teknolojik gelişmelerin en hızlı bütünleştiği ve küresel ekonomiye yön veren önemli endüstrilerden birisidir. Üretim süreçlerinde kalite kontrol mekanizmalarının iyileştirilmesi hem maliyetleri azaltmak hem de ürün güvenilirliğini artırmak açısından kritik bir öneme sahiptir. Geliştirilen yeni nesil teknolojiler, araçlarda kullanılan parçaların karmaşıklığını artırırken kullanılan parçaların da denetlenmesini de zorlaştırmaktadır. Bu sistemlerin güvenli ve doğru çalışması, sadece üretim süreçlerinde değil son kullanıcı güvenliği açısından da hayati önem taşımaktadır. Ulusal Karayolu Trafik Güvenliği İdaresi (NHTSA) tarafından yayınlanan bir araştırmaya göre kazaların yaklaşık %2'si araç bileşenlerinden kaynaklanmaktadır. Bu oran dünya genelindeki kazalar göz önüne alındığında, üretim hatalarının zamanında tespiti ve giderilmesinin önemini vurgulamaktadır.

Bu tez çalışmasında, Yapay Zekâ (YZ) ve Derin Öğrenme (Deep Learning, DL) yöntemlerinin otomotiv sektöründe kalite kontrol ve üretim sistemlerine entegrasyonu incelenmiş ve süreçlerin iyileştirilmesine yönelik yenilikçi yaklaşımlar sunulmuştur. Çalışmanın temel amacı, üretim süreçlerinde meydana gelebilecek hataları en aza indirerek kalite standartlarını artırmak, etkin maliyeti azaltmak, üretim süresini kısaltmak, üretim güvenliğini geliştirmek ve endüstriyel süreçlerde sürdürülebilirliği sağlamaktır. Bu amaçla tezde, literatürde var olan yöntemler kullanılarak YZ destekli bir yazılım geliştirilmiş ve yazılımın gerçek zamanlı üretim ortamlarındaki performansı detaylı bir şekilde analiz edilmiştir.

Tezin ilk aşamasında, evrimsel sinir ağları (Convolutional Neural Network, CNN) üzerinden gerçek zamanlı bir veri artırma uygulaması yapılmıştır. Gerçek zamanlı veri artırma, veri artırma yöntemlerinden biridir ancak temel farkı verinin ön-işleme sırasında değil modelin eğitimi sırasında işlenmesidir. Tez kapsamında yapılan çalışmada, Tensorflow geliştirme çatısına Rastgele Rotasyon Yöntemi (RRY) olarak adlandırılan gerçek zamanlı bir veri artırma tekniği eklenmiştir. Bu teknik sayesinde ön-işleme ile veri artırma tekniklerinden farklı olarak, ekstra depolama, nispeten daha az manuel işlem gerektiren, aşırı uyum riskini azaltan ve dinamik eğitim sağlayan bir veri artırma yöntemi sunulmuştur. Önerilen RRY tekniğinin performansı CNN tabanlı bir uygulamada Toyota Otomotiv Sanayi A.Ş. (TMMT) fabrikasından elde edilen veriler üzerinde test edilmiştir. Elde edilen sonuçlar RRY'nin hareketli parçaların daha yüksek doğrulukla tanınmasında mevcut yöntemlere göre performans artışı sağlayabildiğini ortaya koymuştur. Bu yenilikçi yaklaşım, özellikle üretim süreçlerinde hızlı ve güvenilir bir kalite kontrol mekanizması sağlamak için önemli bir adım olarak değerlendirilmiştir.

İkinci aşamada, gerçek zamanlı motor parça denetimine odaklanan DL tabanlı bir sistem geliştirilmiş ve sistem TMMT fabrikasında uygulanmıştır.

Fanuc CR-15ia modeli bir iş birlikçi robot kullanılarak gerçekleştirilen sistemde, motor parçalarının görsel denetimi için Tekli Atış Dedektörü (Single Shot Detector, SSD) ve Daha Hızlı Bölge Tabanlı CNN (Faster R-CNN) algoritmaları hibrit bir yapı oluşturularak kullanılmıştır.

Yapılan uygulamada 1060 adet motor parça görüntüsü üzerinde 2800 nesne etiketlenmiştir. Kullanılan algoritmaların eğitim ve test aşamaları detaylı bir şekilde incelenmiş ve tüm yapının var olan sistemler ile senkronize çalışması sağlanmıştır. TMMT fabrikasından dört aylık bir sürede elde edilen verilere dayanan analizler, algoritmaların 0.5 Birleşim Üzerinden Kesişim (Intersection over Union, IoU) ile Faster R-CNN için %99,4 ve SSD için %95,5 oranlarında doğruluk sağladığını göstermiştir. Hibrit yapıda oluşturulan gerçek zamanlı motor parça denetim sistemi nihai olarak %99,9 doğruluk oranına ulaşmıştır. Bu çalışma hem donanımsal entegrasyon hem de veri paylaşımı açısından önemli bir katkı sunmuş, üretim süreçlerinde güvenlik, ergonomi ve sürdürülebilirlik açısından kayda değer iyileşmeler elde etmiştir.

Üçüncü ve son aşamada, İnsan-Robot İş Birliği (Human Robot Collaboration, HRC) ile geliştiren YZ tabanlı görüş sistemleri yenilikçi yöntemlerle birleştirilerek çok yönlü bir yaklaşım sunulmuştur. Catia V5 yazılımı kullanılarak geliştirilen dijital bir ortamda, insan ve iş birlikçi robotlar farklı modlarda simüle edilmiş, CNN ve yapısal benzerlik indeksi (Structural Similarity Index Measure, SSIM) ile desteklenen bölge tabanlı parça takip sistemi oluşturulmuştur. Sistem, ek sensör ya da karmaşık kamera kurulumlarına gerek duymadan üretim süreçlerini daha hızlı ve güvenli hale getirmiştir. Simülasyonlar ve deneysel çalışmalar, önerilen sistemin görev tamamlama sürelerinde ve doğruluk oranlarında önemli iyileşmeler sağladığını göstermiştir. İş birlikçi robotlar ve YZ tabanlı sistemlerin bir arada kullanılması ile nesne tanıma performansında sonuçta %99,12 doğruluk oranına ulaşılmıştır. Ayrıca geleneksel yöntemlere kıyasla görev sürelerinde yaklaşık %49 oranında bir kısalma sağlanmıştır. Ergonomi ve iş güvenliği standartlarını iyileştiren bu sistem üretim süreçlerinin daha akıllı ve sürdürülebilir bir yapıya kavuşmasına önemli katkı sunmuştur.

Tez kapsamında yapılan çalışmalar genel açıdan değerlendirildiğinde YZ destekli sistemlerin, kontrol süreçlerinde insan hatalarının azaltılmasında, doğruluğun artırılmasında ve süreçlerin daha şeffaf hale getirilmesinde önemli bir katkı sağladığı görülmüştür. Ayrıca YZ destekli sistemlerin diğer endüstriyel alanlarda da oldukça geniş bir yelpazede kullanılabilir olduğu tespit edilmiştir. Lisan koşulları ve etik açısından gerekli düzenlemeler yapıldığında YZ destekli sistemlerin ekonomik ve operasyonel faydalar sağlayacağı ön görülmüştür.

Tez çalışmasında yapılan uygulamalarda NVIDIA RTX 3080ti ekran kartına sahip, 64 GB RAM ve Intel Core i9-12950HX işlemcili dizüstü bilgisayar kullanılmıştır. Geliştirilen algoritmaların etkin çalışmasını sağlamak amacıyla Python 3.8.13, Anaconda 4.12.0 ve TensorFlow 2.9.1 sürümlerinden yararlanılmıştır. Ayrıca, yazılım ortamı kapsamlı kütüphaneler ve optimize edilmiş paketler ile desteklenmiş, böylece veri işleme ve model eğitimi süreçlerinin daha verimli şekilde gerçekleştirilmesi sağlanmıştır. Bu güçlü donanım ve yazılım altyapısı, özellikle büyük veri setlerinin işlenmesi ve karmaşık derin öğrenme modellerinin eğitilmesinde kritik avantajlar sunmuştur.

Bu tez çalışması var olan yöntemler kullanılarak hem teknik yenilikler hem de çözüm odaklı yaklaşımlarla sektörel inovasyona katkı sunmayı amaçlamaktadır. YZ tekniklerinin sağladığı ileri veri işleme, karmaşık karar verme ve öngörü yetenekleri

retim srelerinin daha etkin, gvenilir ve verimli hale gelmesine olanak tanımaktadır. Tezde sunulan bulgular, YZ tabanlı sistemlerin endstriyel entegrasyonda sahip olduėu yksek potansiyeli ortaya koymakta ve bu sistemlerin sektrel dnşm zerindeki belirleyici etkisini gl bir Őekilde vurgulamaktadır. Spesifik problemler iin geliřtirilen zmler, kalite kontrol srelerinde doėruluk ve hızın nasıl artırılabilceėini gstererek bu tr sistemlerin sektrel dnşmdeki nemini bir kez daha ortaya koymaktadır.





DEVELOPMENT OF AI-SUPPORTED SOFTWARE FOR PART INSPECTION IN THE AUTOMOTIVE INDUSTRY

ABSTRACT

The automotive industry is one of the most important industries where technological developments are integrated at the fastest rate and which directs the global economy. Improving quality control mechanisms in production processes is critical both in reducing costs and increasing product reliability. The new generation of technologies not only increases the complexity of vehicle components but also makes their inspection significantly more challenging. The safe and accurate operation of these systems is essential both for production processes and for end-user safety. According to a study published by the National Highway Traffic Safety Administration (NHTSA), approximately 2% of accidents are caused by vehicle components. Considering this rate of accidents worldwide, it emphasizes the importance of timely detection and elimination of production defects.

In this thesis, the integration of Artificial Intelligence (AI) and Deep Learning (DL) methods into quality control and production systems in the automotive industry is analyzed and innovative approaches to improve the processes are presented. The main objective of the study is to increase quality standards, reduce effective cost, shorten production time, improve production safety and ensure sustainability in industrial processes by minimizing errors occurring in production processes. For this purpose, in this thesis, AI supported software has been developed by using the existing methods in literature and the performance of the software in real-time production environments has been analyzed in detail.

In the first phase of the thesis, a real-time data augmentation over Convolutional Neural Networks (CNN) was implemented. Live (or online) data augmentation is a method of data augmentation; the main difference is that it is performed not during data pre-processing, but during the training of the model. In this thesis, a live data augmentation method, referred to as the Random Rotation Method (RRY), was integrated into the TensorFlow framework. Unlike traditional pre-augmentation methods, this method offers a data augmentation strategy that requires no additional storage, minimizes human intervention, reduces the risk of overfitting, and enables dynamic training. The performance of the proposed RRY strategy is tested in a CNN based application on data obtained from Toyota Motor Manufacturing Turkiye (TMMT) factory. The results show that the RRY can provide performance improvement over existing methods in recognizing moving parts with higher accuracy. This innovative approach is considered as an important step to provide a fast and reliable quality control mechanism, especially in production processes.

In the second phase, a DL based system focusing on real-time engine part inspection was developed and implemented in TMMT factory. The system uses a hybrid structure integrating Single Shot Detector (SSD) and Faster Region-Based CNN (Faster R-CNN) algorithms for visual inspection of engine parts, implemented using a Fanuc CR-15ia collaborative robot.

In the application, 2800 objects were labelled on 1060 engine part images. The training and testing phases of the algorithms used were examined in detail and the whole structure was synchronized with the existing systems. Analyses based on the data obtained from the TMMT factory over a period of four months showed that the algorithms provided 99.4% accuracy for Faster R-CNN and 95.5% accuracy for SSD with Intersection over Union (IoU) threshold of 0.5. The real-time engine part inspection system created in the hybrid framework ultimately achieved an accuracy of 99.9%. This study has made a significant contribution in terms of both hardware integration and data sharing, and has achieved significant improvements in terms of safety, ergonomics and sustainability in production processes.

In the third and final stage, a versatile approach is presented by combining AI based vision systems developed by Human-Robot Collaboration (HRC) with innovative methods. In a digital environment developed using Catia V5 software, human and collaborative robots were simulated in different modes and a region-based part tracking system supported by CNN and Structural Similarity Index Measure (SSIM) was created. The system has made production processes faster and safer without the need for additional sensors or complex camera installations. Simulations and experimental studies have shown that the proposed system provides significant improvements in task completion times and accuracy rates. With the combination of collaborative robots and AI-based systems, an average accuracy rate of 99.12% was achieved in object recognition performance. In addition, a reduction of approximately 49% in task times was achieved compared to traditional methods. This system, which improves ergonomics and occupational safety standards, has made a significant contribution to making production processes smarter and more sustainable.

When the studies carried out within the scope of the thesis are evaluated in general terms, it is seen that AI-supported systems make a significant contribution to reducing human errors in control processes, increasing accuracy and making processes more transparent. It has been determined that AI-supported systems can be used in a wide range of other industrial areas. It is foreseen that AI-supported systems will deliver economic and operational benefits once the necessary adjustments are made in terms of regulatory compliance and ethical guidelines.

A laptop with NVIDIA RTX 3080ti graphics card, 64 GB RAM and Intel Core i9-12950HX processor was used in the applications in this thesis. Python 3.8.13, Anaconda 4.12.0 and TensorFlow 2.9.1 were used to ensure the efficient operation of the developed algorithms. In addition, the software environment was supported with comprehensive libraries and optimized packages, thus enabling data processing and model training processes to be performed more efficiently. This powerful hardware and software infrastructure provided a critical advantage, especially in processing large data sets and training complex deep learning models.

This thesis aims to contribute to sectoral innovation with both technical innovations and solution-oriented approaches by using existing methods. The advanced data processing, complex decision making and forecasting capabilities provided by AI techniques enable production processes to become more effective, reliable and efficient.

The findings presented in the thesis reveal the high potential of AI-based systems in industrial integration and strongly emphasize the decisive impact of these systems on sectoral transformation. The solutions developed for specific problems demonstrate how the accuracy and speed of quality control processes can be enhanced, highlighting the critical role of such systems in industrial transformation.





1. GİRİŞ

Bu bölümde, çalışmanın daha kolay anlaşılabilmesi için makine öğrenmesi ve Derin Öğrenme (Deep Learning, DL) yöntemleri hakkında temel bilgiler verilmiş ve tezin özgünlüğünü ortaya koyabilmek amacıyla konuya ilişkin kapsamlı bir literatür taraması yapılmıştır.

Otomotiv sektörü, teknolojik yeniliklerin ve endüstriyel gelişmelerin en yoğun şekilde yaşandığı alanlardan biri olarak öne çıkmaktadır. Bu sektörde kalite kontrol ve parça denetimi, üretim hattı verimliliğini ve son ürün kalitesini belirleyen kritik faktörler arasında yer almaktadır. Geleneksel denetim yöntemleri, genellikle zaman alıcı ve işgücü yoğun olmasının yanı sıra hata yapma olasılığını da artırmaktadır. Bu nedenle, çağın gerekliliklerine uygun olarak Yapay Zekâ (YZ) teknolojilerinin kalite kontrol süreçlerine entegrasyonu önem kazanmıştır.

YZ, makine öğrenmesi ve DL gibi alt disiplinler aracılığıyla, insan benzeri zekâ gerektiren problemleri çözme kapasitesine sahip bir teknoloji alanıdır. Makine öğrenmesi veri temelli algoritmaları kullanarak sistemlerin öğrenme ve performansını iyileştirme yeteneğini geliştirirken; DL, çok katmanlı sinir ağları üzerinden karmaşık problemleri çözme potansiyeli sunmaktadır. Bu teknolojiler özellikle büyük veri setleri ile desteklendiğinde geleneksel yöntemlerle ulaşılması zor olan hassasiyet ve hız seviyelerine erişmeyi sağlamaktadır.

Otomotiv sektöründe YZ uygulamaları, sadece üretim hattı verimliliğini arttırmakla kalmayıp aynı zamanda maliyetlerin azaltılması, işgücü tasarrufu ve insan hatalarının minimize edilmesi gibi çeşitli faydalar da sağlamaktadır. Bu tez otomotiv sektöründe parça kontrolü için geliştirilen YZ destekli yazılımların etkinliğini ortaya koymayı ve sektörel inovasyona katkı sağlamaya yönelik öneriler sunmayı amaçlamaktadır.

Bu doğrultuda, öncelikle YZ'nin temel prensipleri, makine öğrenmesi ve DL yöntemlerinin teorik temelleri ele alınmış daha sonra bu teknolojilerin otomotiv sektöründeki uygulamaları üzerine odaklanılmıştır. Sonuç olarak geliştirilen sistemlerin endüstriyel faydaları ve gelecekteki olası yönleri üzerine kapsamlı bir analiz sunulmuştur.

1.1. Otomotiv Sektöründe Parça Kontrolünün Önemi

Otomotiv sektörü, dünyanın en büyük endüstriyel alanlarından biri olup üretim kapasitesi ve ekonomik katkısı ile küresel kalkınmada önemli bir rol oynamaktadır. Ancak bu sektörü etkileyen rekabetçi baskılar ve artan kalite beklentileri, yenilikçi teknolojilerin entegrasyonunu zorunlu hale getirmektedir. Çağın çözüm odaklı yaklaşımlarından biri olan YZ, otomotiv üretim hatlarının birçok aşamasında etkili bir şekilde kullanılabilecek kapasiteye sahiptir.

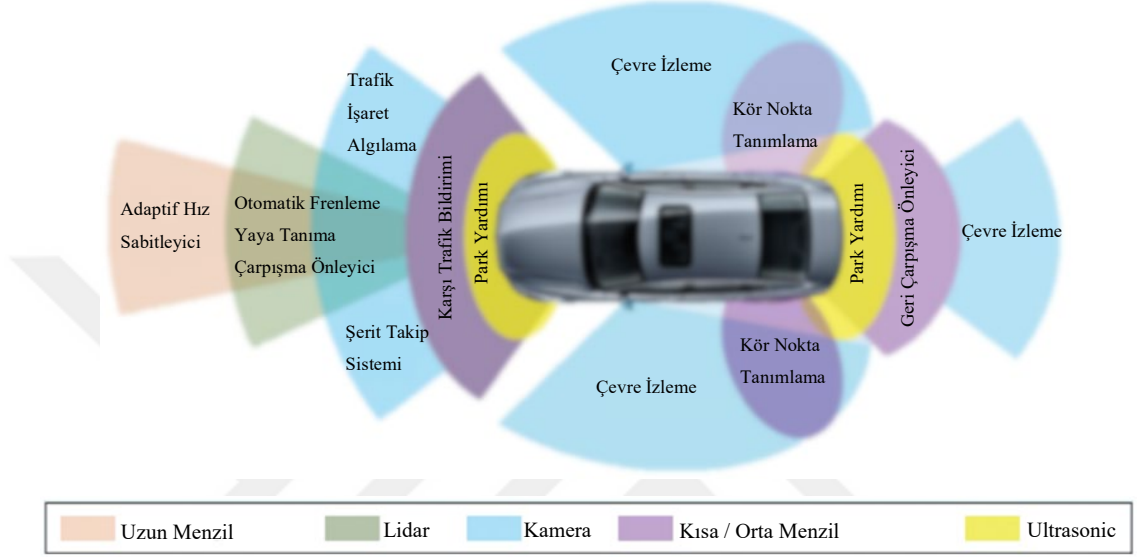
Kalite kontrol ve parça denetimi, otomotiv sektöründeki operasyonel başarının temel taşlarından biridir. Geleneksel kontrol mekanizmaları genellikle manuel işlem gerektirmesi nedeniyle zaman kaybı, maliyet artışı ve hata oranının yüksek olması gibi sorunlar meydana getirir. Bu bağlamda YZ destekli sistemler, veri analitiği ve otomasyon ile bu sorunların üstesinden gelerek sektöre çağ atlattırma potansiyeline sahiptir.

Ayrıca YZ'nin sunduğu esneklik, kök neden analizi, öngörüler ve gerçek zamanlı uyarlamalar gibi özellikler, otomotiv sektörünün daha çevik ve rekabetçi bir yapı kazanmasını sağlamaktadır. Bu tez YZ teknolojilerinin sektörel uygulamalarını ele alarak, yenilikçi yaklaşımların nasıl bir fark yaratabileceğini kapsamlı bir şekilde incelemektedir. Konunun bu derece önemli olması hem akademik araştırma dünyası hem de endüstriyel uygulamalar için bu tez çalışmasını kritik bir katkı haline getirmektedir.

YZ'nin hızla gelişmesi çeşitli alanlarda farklı görevlerin başarıyla yerine getirilmesini mümkün hale getirmiştir. Bu alandaki önemli DL yöntemleri arasında Evrimsel Sinir Ağları (Convolutional Neural Networks, CNN) [1], Uzun Kısa Dönem Hafıza Ağları (Long Short-Term Memory, LSTM) [2], Tekrarlayan Sinir Ağları (Recurrent Neural Network, RNN) [3], Üretken Çekişmeli Ağlar (Generative Adversarial Network, GAN) [4] ve Radyal Tabanlı Fonksiyon Ağları (Radial Basis Function Network, RBFN) [5] yer almaktadır. Bu yöntemler çeşitli veri analizi, öngörü ve karar destek sistemleri gibi sorunları çözmek amacıyla geliştirilmiştir. Özellikle CNN tabanlı görüntü işleme teknikleri, şekil ve nesne tanıma gibi karmaşık problemler karşısında etkili çözümler sunarak başarılı sonuçlar elde edilmesini sağlamıştır [6], [7], [8].

Seri üretim olanaklarının artmasıyla birlikte dünya genelinde üretim hacimleri muazzam rakamlara ulaşmıştır. Bu artan üretim seviyeleri, rekabetçi piyasalarda

şirketlerin hata oranlarını en aza indirmesini güvenilir, kaliteli ve yenilikçi teknolojiler geliştirmesini zorunlu kılmaktadır. Şekil 1.1'de de sunulduğu üzere, modern otomobiller birçok sensör, radar, lidar ve kameranın bütünleşmiş şekilde çalıştığı kompleks yapılar haline gelmiştir. Bu yapılar sadece üretim süreçlerinde değil, aynı zamanda son kullanıcı deneyimlerinde de karmaşık sorunların etkili bir şekilde ele alınmasını gerektirmektedir.



Şekil 1.1. Otonom araçlar için kontrol edilen bölgeler [9].

Gelişen YZ tabanlı yöntemler üretim süreçlerini optimize ederek hem maliyetleri düşürmekte hem de kalite standartlarını yükseltmektedir. Bu bağlamda otomotiv sektöründe YZ ile desteklenen kalite kontrol sistemlerinin geliştirilmesi, endüstriyel rekabetçiliği artırmada önemli bir role sahiptir.

Araçlarda güvenlik sistemlerinin doğru ve gerektiği durumlarda çalışması büyük önem taşımaktadır. Statista Araştırma Departmanı'nın dünya genelinde yaptığı araştırmaya göre 2023 yılında yaklaşık 94 milyon motorlu araç üretilmiştir [10]. Dolayısıyla geçmiş yıllarda üretilen araçlar da göz önüne alındığında, trafikte oluşabilecek anlık bir arıza veya gecikme sonrası kaza olma olasılığı bir hayli yüksektir. Türkiye İstatistik Kurumu (TÜİK) verilerine göre Türkiye genelinde 2023 yılında meydana gelen toplam ölümlü veya yaralanmalı kaza sayısı 235 bin 71 olarak kayıtlara geçmiştir [11]. Bu nedenle araç fonksiyonlarının veya güvenlik sistemlerinin doğru çalışması kazaların önlenmesi açısından oldukça önemlidir. Ulusal Karayolu Trafik Güvenliği İdaresi (National Highway Traffic Safety Administration, NHTSA) tarafından yayınlanan bir araştırmaya göre ise kazaların yaklaşık %2'si araç bileşenlerinden

kaynaklanmaktadır [12]. Bu oran, dünya genelindeki kazalar göz önüne alındığında, imalat sürecinin daha iyi denetlenmesi ve hatalı araç parçalarından kaynaklanan ölüm veya yaralanma sayısının önlenmesi için son derece önemlidir.

Otomotiv üretim tesislerinde üretim süreçleri boyunca birçok kontrol yapılmaktadır. Ancak bu kontrollerin insan gözüyle veya klasik görüntü işleme metotları ile yapılması hataların doğru tespit edilmemesine ve hatalı ürünlerin kullanıcıya ulaşmasına neden olabilir. Örneğin klasik yöntemlerle yapılan bir kontrol operasyonu, ışık şiddetinin değişken olması, incelenecek parçanın üç boyutlu düzlemde farklı konum ve varyasyonlarda gelmesi gibi faktörlere bağlı olarak sistem performansı düşebilir ve sistem çıktılarının güvenilirliği azalabilir.

Son dönemde ivmelenerek gelişen YZ yöntemleri ile kalite kontrol süreçleri yeni nesil algoritmalar veya metotlar kullanılarak yapılabilmektedir. YZ'nin genel olarak otomotiv sektöründe kullanım amaçları aşağıda listelenmiştir:

- *Öngörücü bakım*: Üretim ortamında kullanılan robot veya ekipmanların aşınma ve yıpranma durumları sürekli takip edilerek potansiyel arızaların, arıza oluşmadan önce tahmin edilmesini amaçlanmaktadır. Böylelikle bakım maliyetlerinin azaltılması ve üretim verimliliğinin artması hedeflenmektedir.
- *Otonom sürüş*: Lidar, radar ve kamera gibi çeşitli cihazlardan gelen verilerin toplanması ve DL yöntemleri kullanılarak çevresel faktörlerin algılanması amaçlanmaktadır. Böylelikle sürüş kararları insan faktörüne bağlı kalmadan gerçekleştirilir. Günümüzde özellikle üretim hatlarında lojistik operasyonlar insanlı transfer yöntemlerinden, otomatik transfer yöntemlerine dönüşmektedir.
- *Gelişmiş sürücü destek sistemleri (ADAS)*: Genel olarak araç üzerinde bulunan çarpışma engelleyici sistem, şerit takip sistemi ve acil fren sistemi gibi teknolojiler ile ileri görüntü işleme teknikleri kullanılarak yol sürüş desteği sağlanmaktadır.
- *Kalite kontrol ve denetim*: Bu çalışma içerisinde de konu edinen üretim hatlarında makine öğrenmesi ve DL teknikleri kullanılarak kusurlu parçaların yerinde kalite anlayışı ile tespit edilmesinin amaçlanmaktadır. Böylelikle, hatanın bir sonraki istasyona veya müşteriye ulaşmadan belirlenmesini, üretim verimliliğinin artırılmasını ve maliyetlerin düşürülmesini amaçlanmaktadır.

Bu tez çalışmasında üretim süreçlerinde meydana gelen hataların tespit edilmesi ve kullanıcıya ulaşmadan önce giderilmesi için otonom bir kalite kontrol sistemi oluşturulması hedeflenmiştir. Ayrıca sistemin gerçek zamanlı olarak endüstriyel üretim ortamında kullanılması amaçlanmaktadır. Literatürde farklı amaçlar için önerilen çok sayıda çalışma bulunmaktadır. Bu çalışmalarda farklı YZ yöntemlerinin benzer problemler karşısındaki performansları birçok açıdan değerlendirilmiştir. Elde edilen çıktılar üzerinden avantaj ve dezavantaj değerlendirmeleri yapılmıştır. YZ kullanımının sağladığı avantajlar yüksek doğruluk, düşük hata oranları, hızlı karar verme yetenekleri ve insan kaynaklı hataların azaltılması şeklinde özetlenebilir. Diğer taraftan yüksek başlangıç maliyetleri, büyük miktarda eğitim verisi ihtiyacı, algoritmalarının karmaşıklığı ve donanım gereksinimleri en önemli dezavantajlardandır.

YZ tabanlı endüstriyel sistemler üretim hatlarında yerinde ve gerçek zamanlı kalite kontrolü sağlayarak endüstriyel verimliliği artırmakta, maliyetleri düşürmekte ve son ürün kalitesini yükseltmektedir. Müşteri memnuniyeti artarken otomotiv üreticilerinin rekabet avantajı da güçlenmektedir. YZ'nin otomotiv sektöründe kullanılması sadece üretim süreçlerini optimize etmekle kalmaz aynı zamanda ürün geri çağırma gibi maliyetli ve marka imajını zedeleyici durumların da önlenmesine destek olur.

YZ tabanlı kalite kontrol sistemlerinin üretim sürecindeki diğer otomasyon ve dijitalleşme çabaları ile entegre edilmesi, akıllı fabrika ve Endüstri 4.0 girişimlerinin bir parçası olarak büyük bir potansiyele sahiptir. Bu entegrasyon, veri analitiği ve büyük veri teknikleri ile desteklendiğinde üretim hatlarındaki eğilimlerin olası arızaların ve bakım gereksinimlerinin öngörülmesi de mümkün hale gelir. Öngörücü bakım sistemleri, makinelerin ömrünü uzatırken beklenmedik arızaların ve duruşların önüne geçer, bu da operasyonel sürekliliği sağlar.

Ayrıca YZ destekli sistemlerin kullanımı, sadece üretim süreçlerinde değil aynı zamanda tedarik zinciri yönetimi, stok optimizasyonu ve lojistik gibi diğer iş alanlarında da önemli iyileştirmeler sunabilir. Örneğin tedarik zincirinde YZ kullanımı, parça ve malzeme kalitesinin kontrol edilmesinde daha etkin bir yaklaşım sunarak hammadde tedarikinde bile hataların erken aşamada tespit edilmesine yardımcı olabilir.

1.2. Literatür Taraması

Bu kısımda YZ metotları kullanılarak oluşturulmuş çalışmalar incelenmiş ve tez çalışmasına ışık tutacak bilgiler elde edilmiştir. Genel olarak çalışmalar endüstriyel ortamlarda ürün kusurlarını tespit etmek nesne tanıma sistemlerini geliştirmek ve insan-robot iş birliğine dayalı uygulamaları optimize etmek amacıyla DL tekniklerini kullanmıştır. Çalışmaların çoğunda farklı algoritmaların performans değerlendirmesi yapılmış ve algoritmaların pratik uygulamalarda nasıl iyileştirilebileceği konusu üzerinde durulmuştur. Öne çıkan çalışmalar aşağıda özetlenmiştir.

2019 yılında Yang ve arkadaşları, SSD [13] ağı ve DL yöntemleri kullanarak bir fabrikadaki ürünlerin gerçek zamanlı küçük parça hata tespit sistemi ile kontrol edilmesine yönelik bir sistem önermişlerdir [14]. Önerilen sistemin performansı, tahmin olasılıkları, doğruluk oranı, konumlandırma süresi ve tespit oranı açısından değerlendirmiştir. Çalışmada öncelikle tüm sistemi etkileyen çevresel koşullar incelenmiştir. Daha sonra sistemin hareketli konveyör üzerinde gerekli parçaları tanıyabilmesi için çeşitli deneyler yapılmıştır. Deney sonuçlarına göre çalışma içerisinde konum ve nesne türüne dayalı olarak eşzamanlı regresyon yapması nedeniyle SSD yönteminin kullanılmasına karar verilmiştir.

Sistem performansı 0,8 cm yama iğneleri ile gerçek zamanlı olarak test edilmiştir. Deney amaçlı bir fabrika akış şeması oluşturulmuş ve bu sistem üzerinde simülasyonlar yapılmıştır. Simülasyonlar ve yapılan testlerde özelleştirilmiş Tek Atış Dedektörü (Single Shot Detector, SSD), Yalnızca Bir Kez Bak (You Only Look Once, YOLO) [15] V3, Faster R-CNN [16] ve Özellik Piramidi Ağı (Feature Pyramid Network, FPN) [17] yöntemleri 1261 standart, 1258 hata tipi 1, 1239 hata tipi 2, 1246 hata tipi 3 ve 1302 hata tipi 4 görüntülerini içeren özel bir veri tabanı üzerinde denenmiştir. Yazarlar önerilen değiştirilmiş SSD tabanlı yöntemin mevcut yöntemlerden daha iyi sonuçlar verdiğini bildirmişlerdir. Önerilen değiştirilmiş SSD yönteminin hata tipleri 1, 2, 3 ve 4 için eğitim doğruluk oranları sırasıyla %98, %99, %97,8 ve %79,4 olarak rapor edilmiştir. Hata tipleri 1, 2, 3 ve 4 için FPN yönteminin elde ettiği en yakın performans sırasıyla %95, %96,8, %93,4 ve %72,6 olmuştur. Çalışmada tahmin olasılıkları eğitim doğruluk oranlarından yaklaşık %4 daha düşük olarak belirlenmiştir. Değiştirilmiş SSD konumlandırma süresi bir görüntü için 0,56 saniye olarak ölçülmüştür. Sonuçlara göre Faster R-CNN, SSD yöntemine göre her görüntü karesi için 0,43 saniye daha yavaştır. Bu nedenle SSD'nin sınırlı çevrim süresi

koşullarında etkili bir şekilde kullanılabilmesi belirtilmiştir. Yazarlar gelecekteki çalışmalarda tespit edilemeyen nesnelere için farklı algoritmaların kullanılabilmesini de vurgulamışlardır.

İlgili çalışma hem SSD hem de Faster R-CNN modellerinin entegrasyonu yoluyla nesne tespitinde karşılaşılan zorlukları ele almıştır. Buradan hareketle sunulan tez çalışmasında değişken koşullar altında dahi nesne tespit adımlarını başarıyla yürütebilen algoritmalar oluşturma fikri ortaya çıkmıştır.

2021 yılında Rajan S. ve arkadaşları, fren parçaları üzerinde hasarlı üretilmiş kısımları tespit etmek ve konumlarını belirlemek için iki DL yönteminin aynı anda kullanılabilmesi fikrini öne sürmüşlerdir. Bu parçalar arasında piston, ana silindir ve piston parçası yer almaktadır [18]. Fren parçalarının araçlara monte edilmeden önce incelenmesi ve hatalı parçaların tespit edilmesi hayati önem taşımaktadır. Ayrıca, küçük hatalar için insan gözü ile inceleme yapmak oldukça zordur. Veri tabanı oluşturmak amacıyla 2800 motor parçası etiketlenmiştir. Bu çalışmada fren parçalarıyla ilgili veri eksikliği nedeniyle sistem eğitimi sırasında COCO2017 [19] veri tabanı kullanılmıştır. Bir transfer öğrenme yöntemi kullanılmış ve sistemler fren parçalarındaki hataları tespit etmek için devreye alınmıştır. Faster R-CNN ve SSD tabanlı algoritmaların eğitim doğruluk oranları sırasıyla %97,1 ve %95,4 olarak tespit edilmiştir. Ayrıca bu algoritmaların Ortalama Hassasiyet (Mean Average Precision, mAP) değerleri, fren parçasının silindirik gri tonlu olması durumunda %95,64 ve %73,2 olarak belirlenmiştir. Çalışma içerisinde Faster R-CNN yöntemine dayalı nesne tanılama metodlarının SSD tabanlı yöntemlerden biraz daha yavaş olduğunu belirtilmiştir.

Önerilen sistem kritik koşullar altında veya gerçek zamanlı bir sistem üzerinde test edilmemiştir. Veri tabanına dahil edilen görüntü sayısı sınırlıdır ve görüntüler el kamerasıyla çekilmiştir. Sonuç olarak oluşturulan sistemin gerçek zamanlı seri üretim ortamında denenmesi sistem performansı ile alakalı daha doğru çıktılar verecektir. Yine de aynı sistemde iki nesne tespit yönteminin kullanılması farklı avantajları ile öne çıkmaktadır.

Olesen A.S. ve arkadaşları, rastgele kutu alma için DL metodlarına ve çoklu tutucu değiştirme stratejisine dayanan iş birliğine dayalı bir robot hücresi üzerinde çalışmışlardır [20]. Çalışmada, bir cep telefonu üretim fabrikası simüle edilmiş ve

parçalar YOLOV3 metodu kullanılarak tespit edilmiştir. Sonrasında parça yönleri birincil Faster R-CNN Görsel Geometri Grubu (Visual Geometry Group, VGG) 16 yöntemiyle belirlenmiştir. İş birlikçi robotun parçayı doğru şekilde kavraması ve parçaları farklı açılarda gerekli istasyona iletmesi sağlanmıştır. Çalışmada ayrıca Darknet mimarisi de incelenmiştir.

Test ortamında en yüksek performans skoru %96 olarak belirlenmiştir. Ancak gerçek zamanlı ortamda maksimum %89,17 doğruluk elde edilmiştir. Sisteminin tüm parçaları dikkate alındığında bu skor, nihai testlerde %47'ye kadar düşmüştür.

Yazarlar bazı küçük ancak tespit edilemeyen parça kusurları nedeniyle birçok hat durmasının meydana geldiğini ve bu sorunun genel performansı etkilediğini belirtmişlerdir. Buna karşılık önerilen çalışmada hassas olarak aynı görüntü konumlarına erişebilmek amaçlı iş birlikçi robot kullanılmakta çeşitli ve sağlam bir eğitim veri kümesi ile değişen koşullar altında gerçek zamanlı veri toplanmaktadır.

Bu tez çalışmasında oluşturulacak yaklaşım ile gerçek zamanlı bir otomotiv üretim ortamında yüksek doğruluklarda parça kontrolü yapılması planlanmıştır. Hibrit DL tabanlı motor parçası inceleme sistemi ile hat duruşlarının minimize edilmesi en önemli çıktılardan biridir.

Hridoy, M. W. ve arkadaşları, CNN mimarileri kullanarak yüksek hassasiyet ile altıgen somun parçalarının denetlenmesi için bir DL yapısı önermişlerdir [21]. Çalışmada DL yöntemlerinin çeşitli endüstriyel ortamlarda geniş uygulama alanlarına sahip olduğu ve verimli bir endüstriyel denetim sistemi geliştirmedeki temel zorluğun modelleri eğitmek için büyük miktarlarda etiketli veriye ihtiyaç duyulması olduğu vurgulanmıştır. Ardından üretim süreçlerinde hata tespiti için artımlı DL yöntemleri incelemiştir [22]. Çalışmada DL'nin görsel tanımadaki rolü vurgulanmıştır. Böylelikle kusurların tespit edilmesinde doğruluğu artmış işlem süreleri azalmış ve verimli bir yapı elde edilmiştir.

Özellikle parça hatalarının veya beklenmedik durumların bir şekilde ortaya çıkabileceği dinamik ortamlarda yeni verilerle karşılaşıldığında DL modellerini gerçek zamanlı olarak güncellemenin zorluğu bilinmektedir. Çalışmada artımlı öğrenme yaklaşımlarının gerçek zamanlı üretim görevlerine nasıl etkili bir şekilde uygulandığı gösterilmiştir. Bunun için gerçek zamanlı saha çalışmaları sunulmuş ve parça hatası

tespit modellerinin sıfırdan, yeniden eğitim gerektirmeden doğru ve verimli kalması üzerinde durulmuştur.

Lee, J. S. ve arkadaşları, otomotiv endüstrisinde üretim sırasında fazla malzemeyi kesmek için kullanılan kritik araçlar olan kırpma kalıbı tasarımlarının denetimini otomatikleştirmek amacıyla tasarlanan yenilikçi bir sistem üzerinde durmuşlardır [23]. Yazarlar YZ modüllerinin bilgisayar destekli tasarım (Computer Aided Design, CAD) yazılımı ile entegrasyon yöntemini önererek denetim sürecinin otomatik olarak gerçekleştirilmesine olanak tanımakta ve çalışanlar tarafından halihazırda yapılan manuel kontrol ihtiyacını azaltmaktadır. YZ ve CAD arasındaki bütünsel etkileşim denetim verimliliğini artırmakta ve bu yaklaşımın diğer tasarım ve üretim görevlerine uyarlanma potansiyelini göstererek önemli ölçülenebilirlik ve esneklik sunmaktadır.

Ayrıca Zubayer ve arkadaşları, havacılık ve uzay endüstrisindeki kritik bileşenler olan jet motoru türbin ve kompresör kanatlarındaki yüzey kusurlarını tespit etmek amaçlı çalışmışlardır [24]. YOLOv8 DL yöntemi kullanılan çalışmada, üretim sırasında hatalı parça tespitinin doğruluğu ve hızının artırılması amaçlanmıştır. Yazarlar motor performansını ve güvenliğini ciddi şekilde etkileyebilecek çentik, yüzey pürüzlülüğü ve kenar kusurları gibi problemlerin meydana getirdiği zorlukları vurgulamışlardır. Nesne tespitindeki yüksek verimliliğiyle bilinen YOLOv8 modeli bu kusurları %99,5 doğruluk oranıyla tespit edecek şekilde uyarlanmış ve model görüntüleri 280 saniyede işleyebilmiştir.

Diğer taraftan literatürde bulunan birçok çalışmada İnsan-Robot İş birliği (Human-Robot Collaboration, HRC) konusu üzerinde durulmuştur. Günümüzde iş birlikçi robotların YZ teknikleri kullanılarak denetim sistemlerine entegre edilmesi giderek yaygınlaşmaktadır. Böylelikle HRC, üretim ve montaj süreçlerinde önemli bir odak noktası haline gelmiştir. DL, robotların çevrelerini daha iyi algılamalarını ve kavramalarını sağlayarak robot yeteneklerini geliştirmede etkili olmuştur.

Mendez, E. ve arkadaşları, nesne sınıflandırma ve ses tanıma yöntemlerini kullanarak parça transferi ve depolama da dahil olmak üzere montaj görevlerinde çalışanlara destek olabilecek iş birlikçi robotlar ve DL'nin entegrasyonu üzerinde çalışmışlardır [25]. CNN tabanlı sistemler montaj parçalarını sınıflandırmak ve insan-robot etkileşimlerini %90'ı aşan doğruluk oranlarıyla tespit etmek için başarıyla

uygulanmıştır [25]. Bu çalışma iş birlikçi görevler için bir robotla birlikte sinir ağlarının etkinliğini göstermektedir.

Liau, Y.Y. ve arkadaşları, yaptıkları çalışmada parçalardan üretim sırasını tespit etmek için CNN tabanlı nesne algılama yöntemi kullanılmıştır [26]. Yaklaşık 1000 görüntüden oluşan sınırlı veri nedeniyle önceden eğitilmiş YOLOv5s, YOLOv5m, YOLOv5l ve YOLOv5x modelleri kullanılmıştır. Çalışmada çeşitli araçları tespit etme becerisi doğrultusunda YOLOv5l modelinin kullanılmasına karar verilmiştir. Bu araçlar arasında çekiçler, altıgen anahtarlar, vidalar, kılavuz pimler, itme burçları ve konumlandırma halkaları da bulunmaktadır. Özellikle modeli uyarlamak için model içerisindeki katmanlar yok edilmeden basit değişiklikler yapılmıştır. Ancak sistem titizlikle tasarlanmış olmasına rağmen henüz gerçek zamanlı uygulamalarda yeteri kadar denenmemiştir. Başka bir çalışmada insan güvenliğini görsel izleme yoluyla sağlamak amacıyla DL tabanlı yöntemler önerilmiştir [27]. Önerilen sistem operatörlerin gelecekteki hareketlerini tahmin etmek için RNN kullanarak robot eylemlerinin çevrimiçi planlaması ve uygulanması üzerinde durmuştur. Bahsedilen sistemin montaj hatlarında gerçek zamanlı proseslere uygulanması endüstriyel ortamlarda hem verimliliği hem de güvenliğini artırıcı birçok fayda oluşturacaktır.

A. Pal ve arkadaşları, çalışmalarında YOLOv5 ile nesne tespiti ve derin sıralama (DeepSort) yöntemi ile kişi takibi yöntemlerini entegre ederek tarımsal ürün toplama işlemleri sırasında faaliyetlerin tahmin edilmesi konusunda çalışmışlardır [28]. Otonom robot eylemleri insan durumu göz önünde bulundurularak mesafe ve 3D koordinat tespiti dahil edilerek belirlenmektedir. Bu çalışmada gerçek zamanlı alan çalışmaları ile desteklenmiş ve RGB-D kameralar ile 2D lidar sensörleri kullanılmıştır.

Elde edilen sonuçlara göre dinamik tarım ortamlarında doğru tahmin ve yanıt vermede birleşik yaklaşımın etkinliğini vurgulayan 0,94 ile 0,992 değerlerin arasında değişen kategorik doğruluk oranları elde edilmiştir. CNN modelleri Eylemsel Ölçüm Birimi (Inertial Measurement Units, IMU) verileri ve iskelet takibi ile entegre edilerek insan eylemlerini tanıma amaçlı kullanılmıştır [29]. Sistem tornavidalar, alyan anahtarlar, el vidaları ve çekiçler dahil olmak üzere çeşitli aletleri tanıyabilmektedir. Eylem tahmini ilgili görev sırasının kavranması için kullanılmıştır ve ilgili iş birlikçi robot eylemlerini kontrol etmektedir. Bu yaklaşım küçük sandalye ve kutu montaj simülasyonları ile test ortamında tecrübe edilmiş olup sistemin dinamik ortamlarda insan eylemlerini doğru bir şekilde yorumlama ve yanıt vermesi için çalışılmıştır.

Literatürde bulunan son çalışmalara göre iş birlikçi robotların endüstriyel üretim süreçlerinde artan entegrasyonu, özellikle hassasiyet ve uyarlanabilirlik gerektiren dinamik ortamlarda önemli bir değişime işaret etmektedir.

İnsan operatörlerle birlikte çalışmak üzere tasarlanan iş birlikçi robotlar insan esnekliğini makine hassasiyetiyle benzersiz bir şekilde birleştirerek verimli ve güvenli bir çalışma ortamı oluşturmaktadır [30], [31]. Programlama kolaylıkları ve uyarlanabilir olmaları sayesinde iş birlikçi robotlar özellikle kalite kontrol görevlerinde etkili olmaktadır. Ayrıca kullanılan YZ yöntemleri ilgili parça kusurlarını tespit etme yetenekleri ile insan kontrolü tercih edilen prosesler karşısında çok daha etkilidir [31].

YZ ve DL teknolojilerindeki son gelişmeler özellikle gerçek zamanlı nesne algılama, sınıflandırma ve karar verme gerektiren görevlerde iş birlikçi robotların yeteneklerini daha da geliştirmiştir. Çalışmalarda iş birlikçi robotlar ile CNN gibi DL modellerini birleştirilen gerçek zamanlı izleme ve yüksek doğrulukta kusur tespit çalışmalarının arttığı gözlemlenmiştir. Bu tür sistemler hatalı parça sayısını en aza indirme üretim hattının duruş süresini azaltma ve yüksek kalite standartlarında üretim imkânı sağlama avantajları ile ilgi çekmektedir. Ayrıca iş birlikçi robotların esnekliği, montaj ve demontaj dahil olmak üzere çeşitli üretim süreçleri için robotları adaptif çalışmayı uygun hale getirmektedir [25], [30], [31].

1.3. Derin Öğrenmede Denetimli ve Denetimsiz Yaklaşımlar

Son yıllarda hızla gelişen YZ, sosyal ve ekonomik açıdan önemli fırsatlar sunmaktadır. YZ'nin temel amacı, insan benzeri öğrenme, düşünme ve karar verme süreçlerini taklit ederek veri odaklı problemleri çözmektir. Makine öğrenmesi, YZ'nin önemli bir alt alanıdır. Yapay sinir ağları (Artificial Neural Networks, ANN) ve DL ise makine öğrenmesinin alt dallarını oluşturmaktadır [32]. DL, karmaşık veri setlerinden anlam çıkarma, bağımsız kararlar verme ve daha önce görülmemiş verilerden genelleme yapabilme yetenekleriyle öne çıkmaktadır.

Veri, sistemlerin analiz edilmesi ve öğrenme süreçlerinin başarılı bir şekilde gerçekleşmesi için kritik bir bileşendir. DL modellerinin etkin bir şekilde eğitilebilmesi için iyi yapılandırılmış ve sınıflandırılmış veri setlerine gereksinim duyulmaktadır. DL modeli belirlenirken veri boyutu, karmaşıklığı, etiketleme süreci,

kabul edilebilir hata oranı, giriş verisi ve çeşitlilik oranı gibi faktörler dikkate alınmalıdır [33].

Veri işleme için iki farklı yaklaşım benimsenebilir: model odaklı ve veri odaklı yaklaşım. Model odaklı yaklaşımda, sistem performansının artırılması amaçlanarak model yapısı optimize edilir. Veri odaklı yaklaşımda ise, eğitim ve test verileri işlenerek sistemin doğruluk oranının iyileştirilmesi hedeflenir [34].

DL modelleri, giriş verileri üzerinde eğitim yaparak bağımsız tahminlerde bulunabilen algoritmalarıdır. Bu modeller genellikle verilerdeki örüntülerini algılamaya çalışır ve daha önce görülmemiş veriler üzerinde uygun tahminler yapmayı amaçlar. DL yaklaşımları, temel olarak denetimli öğrenme ve denetimsiz öğrenme olmak üzere iki ana kategoriye ayrılabilir.

Denetimli Öğrenme: Bu yöntemde belirli bir problem hakkındaki verilerin etiketlenmesi ve eğitim süreçlerinde kullanılması ile sistemin öğrenmesi sağlanır. Yani modele hem giriş verileri hem de bu verilere karşılık gelen doğru sonuçlar (etiketler) yüklenir. Bu süreçte model, giriş ile çıkış arasındaki ilişkileri öğrenir ve bu ilişkiler sayesinde daha önce görmediği yeni veriler üzerinde tahminlerde bulunur. Denetimli öğrenme yöntemleri iki ana alt başlıkta incelenir: sınıflandırma ve regresyon.

Sınıflandırma, verilerin belirli kategori sınıfları altında gruplandırılması mantığına dayanır. Örneğin bir modelin resimlerdeki kedi ve köpek figürlerini tanıması isteniyorsa sınıflandırma yöntemi kullanılır. Model, resim içerisindeki objeleri analiz eder ve bu objelerin kedi mi yoksa köpek mi olduğunu yani sınıfını belirler. Bu tür problemler genellikle "evet" ya da "hayır" gibi ikili sonuçlar üretir; ancak birden fazla sınıfın olduğu durumlar da söz konusu olabilir. Bu tezin de amaçlarından biri olan otomotiv parçalarının yapı, renk ve işaret gibi farklılıklarından yararlanılarak tanınması için parçalar farklı sınıflarda etiketlenerek DL sistemi eğitilmiştir.

Regresyon ise sürekli değişkenlerin tahmini üzerine odaklanır. Örneğin sağlık alanında ilaç tüketimi veya maliyet tahminleri yapmak için regresyon modelleri kullanılabilir. Bu tür modellerde bağımsız değişken olarak ilaç fiyatları, medikal ekipman giderleri ve çalışan maaşları gibi etkenler kullanılırken bağımlı değişken olarak ise toplam sağlık harcaması gibi değerler tahmin edilebilir. Bu tür modeller sonuç olarak sayısal değerler üretir ve sürekli değişkenlerin öngörülmesinde önemli bir rol oynar.

Sonuç olarak denetimli öğrenme, giriş-çıkış ilişkilerini modellemek için oldukça etkili bir yöntemdir. Giriş verilerine dayanarak uygun tahminler yapma kapasitesi ile birçok alan için kritik uygulamalara zemin oluşturur.

Denetimsiz Öğrenme: Denetimli öğrenmeden farklı olarak etiketlenmemiş veriler üzerinde çalışır. Bu yöntem veriler üzerinde herhangi bir önceden tanımlı doğru sonuç olmaksızın veriler arasındaki gizli yapıları veya örüntüleri keşfetmeye odaklanır. Denetimsiz öğrenmenin temel amacı modelin girdiler arasındaki bağıntıları öğrenmesini sağlamak ve bu verilerde anlamlı gruplamalar veya ilişkiler tespit etmektir. Bu bağlamda denetimsiz öğrenme iki ana başlık altında incelenebilir: kümeleme ve ilişkilendirme.

Kümeleme, verilerin benzerlik veya farklılıklarına göre gruplandırılması mantığına dayanır. Bu yöntemde sistem veri içerisindeki benzer örüntüleri bulur ve bu verileri benzer özelliklere sahip gruplara ayırır. Örneğin bir resim içerisinde hem kuşlar hem de kediler bulunuyorsa kümeleme algoritması görsel özelliklere dayalı olarak kuşları ve kedileri farklı gruplar altında sınıflandırabilir. Kümeleme, veri etiketlenmenin zor olduğu veya mümkün olmadığı durumlarda verileri otomatik olarak analiz etmek için kullanışlı bir yöntemdir.

İlişkilendirme, veriler arasındaki ilişkileri ortaya çıkarmak için kullanılır. Bu yöntem özellikle pazarlama ve öneri sistemlerinde yaygın olarak kullanılır. Örneğin bir kişinin balıkçılık ekipmanlarından birisini (olta) satın almış olması, onun balıkçılıkla ilgili diğer ürünlere (yem, misina gibi) ilgi göstereceğine dair bir ilişki kurabilir. İlişkilendirme kuralları müşterilerin satın alma alışkanlıklarını anlamak ve uygun ürün önerileri sunmak amacıyla kullanılmaktadır. Bu sayede müşterilere kişiselleştirilmiş deneyimler sunulur.

Sonuç olarak denetimsiz öğrenme, etiketlenmemiş verilerle çalışarak veriler içerisindeki örüntüleri ve ilişkileri keşfetmeye olanak tanır. Bu yöntem özellikle büyük ve etiketlenmemiş veri kümelerinde kullanılmakta olup veri analizinde önemli bir rol oynamaktadır.

1.4. Derin Öğrenmenin Gelişimi ve Modern Uygulama Alanları

DL ile alakalı ilk çalışmalar uzun zaman önce başlamasına rağmen yeteri kadar veri ve hesaplama gücü olmaması gibi nedenler ile DL yöntemleri uzunca bir süre istenen

verimi sağlamamıştır [35]. İlk eğitim modelleri oldukça sınırlı olmakla birlikte yapıları gereği basit problemlerin çözümlerinde kullanılmıştır. Nesne tespit etme ve tanıma gibi karmaşık problemlerin çözümü ilerleyen dönemlerde mümkün hale gelmiştir. Uzun yıllarca yapılan geliştirmeler sonucunda içerik haritaları görüntünün piksel değerlerinin işlenmesi veya içerik vektör formları oluşturulmaya başlanmış ve sonuçta nesne tanıma, tespit etme ve sınıflandırma işlemleri mümkün hale gelmiştir. Günümüzde filtrelenmemiş veya etiketlenmemiş veriden dahi nesne tespiti veya sınıflandırma yapma becerisine sahip olan DL mimarileri geliştirilmiştir [36].

DL ağları birçok katmandan oluşmakta ve işlenmemiş girdiden başlayarak soyut bir düzeye kadar basit ancak doğrusal olmayan modüller içermektedir. Ancak eğitim için yeterli, doğru veri olduğunda ve iyi bir süreç yönetiminde başarılı sonuçlar elde edilebilmektedir. DL temsil öğrenimi yöntemi kullanır. Böylelikle örnek olarak sınıflandırma görevleri için ilgili temsil katmanları girdi yönlerini güçlendirirken alakasız varyasyonlar da bastırılır.

Bir görüntünün işlenmesi ile alakalı genel ilerlemede ilk olarak piksel değerlerinin bir dizi şeklinde ele alınması sonrasında genel olarak görüntüdeki belirli yönelimlerin konumların veya kenarların varlığı-yokluğu temsil edilir. İkinci katman detaylardan bağımsız olarak kenar pozisyonlarındaki motifleri algılar. Üçüncü katman ise tanılanan motifleri daha büyük kombinasyonlar ile birleştirebilir ve sonraki katmanların ilgili nesneyi tanılamasına destek olur. Böylelikle ilgili nesne veya sınıf için istenen çıkış sağlanır [36].

DL sayesinde birçok alanda farklı konulardaki problemler çözülebilir. DL ile alakalı görüntü tanıma [37], [38], [39] ve [40], konuşma tanıma [41], [42] ve [43], potansiyel ilaç moleküllerinin tahmin edilmesi [44], parçacık hızlandırıcı verilerinin analiz edilmesi [45], [46] beyin ile alakalı incelemeler [47] ve DNA'daki mutasyonların gen ifadesi ve etkilerinin tahmin edilmesi [48], [49] gibi birçok alan örnek olarak verilebilir.

DL için büyük veri setleri ve karmaşık algoritmalar kullanılır. DL çıktılarının başarılı olabilmesinin arkasında kullanılan donanımların önemli rolü vardır. Eğitim ve çıktıların işlenmesi için Grafik İşlem Birimleri (Graphics Processing Unit, GPU), Tensor İşlem Birimleri (Tensor Processing Unit, TPU), Merkezi İşlem Birimleri (Central Processing Unit, CPU), Alan Programlanabilir Kapı Dizileri (Field-

Programmable Gate Array, FPGA) ve Uygulamaya Özel Entegre Devreler (Application-Specific Integrated Circuit, ASIC) donanımları çokça kullanılır [50].

GPU'lar paralel işlem yetenekleri sayesinde DL eğitimlerinde ve çalıştırılmasında sıkça kullanılır. Günümüzde GPU'lar büyük matris çarpımları ve karmaşık hesaplamaları diğer donanımlara göre bir hayli hızlı gerçekleştirebilir.

TPU Google tarafından özel olarak geliştirilmiştir. TPU özellikle TensorFlow gibi mimarilerde oldukça yüksek performans değerleri sunabilmektedir [50]. FPGA, kullanıcıların kendi ihtiyaçlarına göre donanım oluşturabildiği veya yeniden yapılandırdığı sistemlerdir. Günümüzde Xilinx Virtex UltraScale+ ve Intel Stratix 10 gibi modeller, yüksek performans ve esneklik sunmaktadır [51].

1.5. Tezde Kullanılan Derin Öğrenme Teknikleri

Sunulan tezde iki önemli uygulama üzerinde çalışmalar yapılmış ve bu uygulamalara ilişkin problemlerin çözümünde DL mimarilerinin kullanılması uygun görülmüştür. Bölüm 2'de verilen motor parçalarının kontrolü amacıyla yapılan çalışmada Faster R-CNN ve SSD algoritmalarından, Bölüm 3'te açıklanan HRC ile ilgili çalışmada ise Yapısal Benzerlik İndeksi (SSIM) yöntemi kullanılarak modüler bir ek yazılım oluşturulmuş ve DL yapısı ile çalışacak şekilde uyarlanmıştır. Yöntemlere ilişkin detaylar aşağıda açıklanmıştır.


Makine öğrenmesinin bir alt dalı olan DL, görüntü tanıma, sınıflandırma ve segmentasyon konularındaki üstün başarıları sayesinde birçok alanda geniş uygulama alanlarına sahip olmuştur [52]. CNN tabanlı nesne tespit metotları genel olarak iki aşamalı (R-CNN ve çeşitleri [53], [54]) ve tek aşamalı tespit metotları (SSD ve YOLO [55]) olarak iki ana başlıkta toplanabilir [56].

İki aşamalı metotlar genel olarak öncelikle nesne içerebilecek olası bölgeleri belirler, sonrasında nesnelere sınıflandırır. Doğruluk oranlarının yüksek olmasına karşın hız açısından yavaş yöntemlerdir.

Tek aşamalı tespit metotları ise bölgenin belirlenmesi ve sınıflandırılmasını tek bir adım içerisinde değerlendirir ve görüntü piksellerini doğrudan sınırlayıcı kutuların koordinat bilgilerine göre eşlemeyi amaçlar. Tek aşamalı tespit metotları iki aşamalı tespit metotlarına göre daha hızlı ancak daha düşük doğruluk oranları sağlamaktadır.

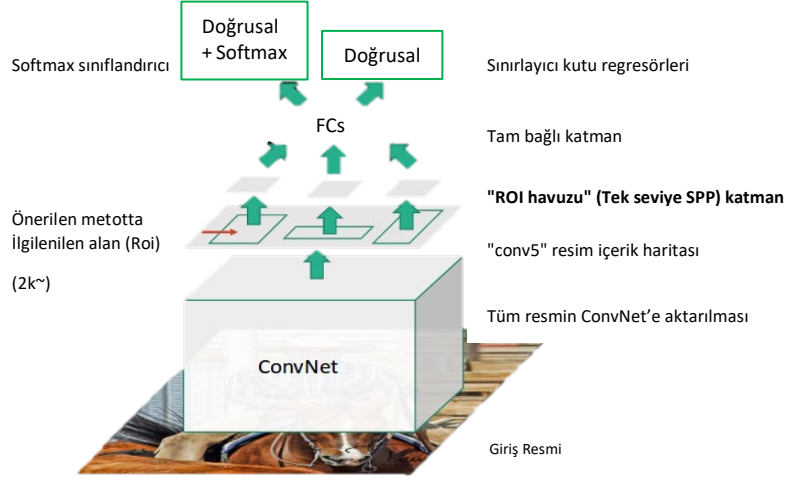
İlk olarak Faster R-CNN yönteminin açıklanmasında R-CNN ve Fast R-CNN mimarilerinin evrimsel gelişimleri ele alınacaktır.

Şekil 1.2’de gösterildiği üzere R-CNN çalışma yapısı temel olarak iki aşamadan oluşmaktadır. İlk aşamada giriş resmi üzerinde yapılan bölgesel öneriler yer almaktadır. Giriş resmi üzerinde yaklaşık 2000 hedef bölge kutusu oluşturulur ve her bir kutu üzerinde bir CNN uygulanır [57]. CNN içerisinde konvolüsyon, maksimum havuzlama (max pooling) işlemleri ve tam bağlı katmanları barındıran bir yapıdır [58]. Böylece her bölge ConvNet üzerinden işlenmiş olur. İkinci aşamada ise sonuçların sınıflandırılması için Support Vector Machine (SVM) yöntemi kullanılır ve gerekli Nesne Sınırlandırma Kutusu (Bounding Box Regression, Bbox reg) çizilir.



Şekil 1.2. RCNN mimarisi ve nesne tanıma süreci [59].

R-CNN mimarisi yapılan geliştirmeler ile Fast R-CNN yapısını oluşturmuş ve yeni yapı R-CNN mimarisinde bulunan problemlerin kısmen giderilmiş versiyonu olarak kullanıma sunulmuştur. Fast R-CNN mimarisinde R-CNN'de kullanılan 2000 kutu ve her resim üzerinde gerçekleştirilen 2000 CNN işlem adımları optimize edilmiştir. Sonuç olarak işlem fazlalığından kaynaklanan süre kaybının kısmen önüne geçilmiştir [54], [59].




Şekil 1.3. Fast- RCNN mimarisi nesne tanıma sıralaması [59].

Fast R-CNN ile elde edilen çözüm, eğitim verisindeki her resim üzerinde yalnızca bir kez CNN işlemi yapılması ve içerisinde nesne bulunduran tüm ROI (Region of Interest) bölgelerinin tanımlanmasıdır. Şekil 1.3'te gösterildiği üzere ConvNet'ten geçen veriler önceden oluşturulan ROI havuzunu aktive eder ve veriyi şekillendirir. Sonrasında ise şekillendirilen veri Tam Bağlı (Fully Connected, FC) Katmana gönderilir. Bu aşamada tahmin edilen sınıflar için doğrusal regresyon ve paralelinde sınırlayıcı kutu koordinatları kullanılır [54]. Yapılan modifikasyonlar sayesinde Fast R-CNN ile her bir resim yaklaşık iki saniyede işlenmektedir. Uzmanlar bu süreci daha da kısaltmanın bir yolunu bulmuş ve bu yönteme Faster R-CNN adını vermişlerdir.

Faster R-CNN mimarisi [16], temelde Fast R-CNN yapısına benzemektedir. Aralarındaki en büyük fark Fast R-CNN'in ROI belirlemek için seçilmiş aramalar yaparken Faster R-CNN'in Bölgesel Öneri Ağını (Region Proposal Network, RPN) kullanmasıdır [59]. Şekil 1.4'te gösterildiği üzere giriş olarak alınan resim üzerinde ConvNet işlemi başlar. Bu aşama içerik haritalarının oluşturulduğu kısımdır. Sonrasında Fast R-CNN yapısından farklı olarak, içerik haritaları üzerinde RPN işlemi uygulanır. RPN aşamasında, içerik haritaları üzerinde algoritma sayesinde kaydırılan bir pencere oluşturulur. Her bir pencere kendi merkezi üzerinde K çapa (K anchor) noktası adı verilen önceden tanımlı farklı boyutlarda kutular oluşturur. RPN

aşamasında öncelikli olasılık oluşturulan çapa noktasının sınıflamadan bağımsız olarak bir nesne olmasıdır.



Şekil 1.4. Faster- RCNN mimarisi ile alakalı nesne tanıma sıralaması [59].

Sonraki adım çapa noktalarının nesneye uyarlanması ve sınırlayıcı kutunun konulmasıdır. Bölge önerileri ve kayıp fonksiyonu için her çapa noktasında ikili sınıf etiketi (nesne veya değil) atanır. Bu kısımda aşağıda verildiği üzere iki tür çapa noktası pozitif etiket ile atanır.

- (i) Yerleşik kutuyla en yüksek Birleşim Üzerinden Kesişim (Intersection over Union, IoU) örtüşmesine sahip çapa noktaları.
- (ii) Herhangi bir yerleşik kutuyla 0,7'den yüksek IoU örtüşmesine sahip çapa noktaları.

Bir yerleşik kutu birden fazla çapa noktasından oluşuyorsa pozitif etiket atanabilir. Tüm yerleşik kutular için IoU oranı 0,3'ten düşükse pozitif olmayan bir çapa noktası dolayısı ile negatif etiket atanır. Ne pozitif ne de negatif olmayan çapa noktaları eğitim amacına katkıda bulunmaz. Sonuç olarak bir görüntü için kayıp fonksiyonu Denklem 1.1'de verildiği üzere aşağıda tanımlanır.

$$L(\{p_i\}, \{t_i\}) = \frac{1}{N_{cls}} \sum_i L_{cls}(p_i, p_i^*) + \lambda \frac{1}{N_{reg}} \sum_i p_i^* L_{reg}(t_i, t_i^*) \quad (1.1)$$

Burada i , küçük-yığındaki (mini-batch) bir çapa noktasının göstergesidir ve p_i , çapa noktasının nesne olma olasılığını temsil etmektedir. Yerleşik etiket p_i^* pozitif bir çapa

noktası için 1 ve negatif bir çapa noktası için 0'dır. t_i , tahmin edilen sınırlayıcı kutunun dört adet parametresinden oluşan koordinatlarını temsil eden bir vektördür ve t_i^* , pozitif çapa noktası ile ilişkili yerleşik kutunun koordinatlarını temsil eder.

Sınıflandırma kaybı L_{cls} , iki sınıf (nesne veya nesne değil) üzerinden logaritma tabanlı kayıptır. Regresyon kaybı için, $L_{reg}(t_i, t_i^*) = R(t_i, -t_i^*)$ kullanılır. Burada R , [54]'te tanımlanan kayıp fonksiyonu (smooth L1)'dur. Terim $p_i^* L_{reg}$, regresyon kaybının yalnızca pozitif çapa noktaları için etkinleştiği (yani $p_i^* = 1$) ve aksi takdirde devre dışı bırakıldığı anlamına gelir ($p_i^* = 0$). cls ve reg katmanlarının çıktuları sırasıyla $\{p_i\}$ ve $\{t_i\}$ 'den oluşur. İki terim N_{cls} ve N_{reg} ile normalize edilir ve bir dengeleme ağırlığı λ uygulanır. Regresyon için Referans [53] içerisinde verilen dört koordinatın parametreleri kullanılır:

$$t_x = \frac{x - x_a}{w_a}, t_y = \frac{y - y_a}{h_a}, \quad t_w = \log\left(\frac{w}{w_a}\right), t_h = \log\left(\frac{h}{h_a}\right), \quad (1.2)$$

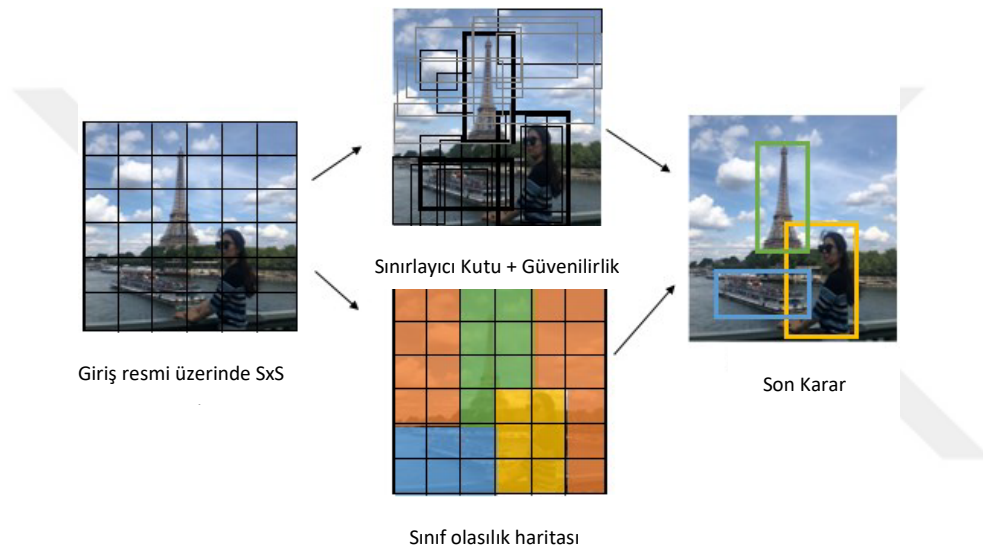
$$t_x^* = \frac{x^* - x_a}{w_a}, t_y^* = \frac{y^* - y_a}{h_a}, \quad t_w^* = \log\left(\frac{w^*}{w_a}\right), t_h^* = \log\left(\frac{h^*}{h_a}\right) \quad (1.3)$$

Denklem 1.2 ve 1.3'te x , y , w ve h sırasıyla kutu merkezinin iki koordinatını genişlik ve yüksek değişkenlerini temsil etmektedir. Değişkenler x , x_a ve x^* sırasıyla tahmin edilen kutu, çapa nokta kutusu ve yerleşik kutu içindir (y , w , h için de aynısı geçerlidir). Bu işlem bir çapa noktası kutusundan yakındaki bir yerleşik kutuya sınırlayıcı kutu regresyon olarak düşünülebilir. Bununla birlikte Faster R-CNN yönteminin oluşumunda önceki özellik haritası tabanlı yöntemlerden [53], [60] farklı bir mantık yürütülmüş sınırlayıcı kutu regresyonu sağlanmıştır.

Yapılan çalışmalarda sınırlayıcı kutu regresyonu rasgele boyutlandırılmış bölgelerden oluşturulmuş bir havuz ile özellikler üzerinde gerçekleştirilir ve regresyon ağırlıkları tüm bölge boyutları tarafından paylaşılır [53], [60]. Regresyon için kullanılan özellikler özellik haritaları üzerinde aynı uzaysal boyutta ($n \times n$) sabittir. Farklı boyutları hesaba katmak için k sınırlayıcı kutu regresörleri öğretilmelidir. Her regresör bir ölçek ve bir en-boy oranından sorumludur ve k regresör ağırlıkları paylaşmaz. Bu nedenle özellikler sabit bir boyut/ölçekte olmasına rağmen çeşitli boyutlarda kutular tahmin etmek hala mümkündür.

Böylelikle skorlanmış ve derecelenmiş nesnelere elde edilir. Son aşamada öneriler softmax ve lineer regresyonların olduğu tam bağlı katmana gönderilir. Bu aşamada nesnelere sınıflandırılır ve çevreleyen kutular çizilerek süreç tamamlanır [16].

YOLOv3 tek aşamalı bir nesne tanıma sınıflandırıcısıdır [15], [57]. Bu mimaride sınıflandırma ve konumlandırma için tek bir ağ kullanılmaktadır. Ayrıca YOLO algoritması diğer birçok yöntemle karşılaştırıldığında oldukça hızlıdır; Örneği V3 versiyonunda Pascal Titan X kullanılarak COCO test verisi üzerinde 30 FPS (Frame Per Second- Saniyede Kare) ve %57,9 mAP değerlerinde performans sunabilmektedir [55], [61].



Şekil 1.5. YOLO mimarisi nesne tanıma süreçleri [59].

Şekil 1.5'te gösterildiği üzere YOLO mimarisinde giriş resmi basitçe S*S ızgara alanlarına ayrılır. Her bir ızgara alanı için tanılama ve sınırlayıcı kutular oluşturulur. Sonrasında güvenilirlik skoru ve sınıflandırma işlemleri aynı anda gerçekleştirilir ve sınıf olasılıkları ile oluşturulmuş sınırlayıcı kutular birleştirilir. Son katman ise hem sınıf olasılıklarını hem de sınırlayıcı kutu koordinatlarını tahmin edildiği kısımdır.

Sınırlayıcı kutunun genişlik ve yüksekliği, görüntü genişliği ve yüksekliği ile eşleştirilir. Böylece değerlerin 0 ve 1 arasında kalması sağlanır. Sınırlayıcı kutunun x ve y koordinat bilgileri, belirli bir ızgara hücresi konumunun ofsetleri olarak göz önüne alınır. Son katman için doğrusal bir aktivasyon fonksiyonu diğer tüm katmanlar için ise Denklem 1.4'te verildiği üzere Sızıntılı Doğrultulmuş Birim (Leaky ReLU) kullanılır.

$$\varphi(x) = \begin{cases} x, & \text{eğer } x > 0 \text{ ise,} \\ 0.1, & \text{diğer} \end{cases} \quad (1.4)$$

Böylece nesnelere softmax veya maksimum baskılama işlemi olmadan tanımlanmış olur. YOLO hız açısından büyük bir atılım yapmış olmasına rağmen sistem doğruluğu açısından tam olarak sorunsuz değildir. Bu durumu düzeltmek için çıkış modeli için kare toplam hatası optimize edilir. Kare toplam hatasının kullanılmasının en büyük nedenlerinden biri optimizasyonunun kolay olmasıdır. Ancak bu kullanım Ortalama Kesinliği (Average Precision, AP) maksimize etme hedefi ile tam olarak örtüşmez. Lokasyon hatasını sınıflandırma hatası ile eşit şekilde ağırlıklandırır ki bu durum bazen ideal sonuçlar oluşturmayabilir.

Ayrıca her görüntüde birçok ızgara hücresi herhangi bir nesne içermeyebilir. Karesele toplam hata metodu ile bu hücrelerin “güven” puanlarını sıfıra yaklaştırılarak nesne içeren hücrelerden gelen gradyanı genellikle bastırır. Böylelikle bu durum modelin kararsızlığına neden olabilir eğitim sürecinin erken aşamada doğruluk sapmalarına yol açabilir [15]. Muhtemel kararsızlık ve sapmaları düzeltmek için sınırlayıcı kutu koordinat tahminleri için kaybı artırmak ve nesne içermeyen kutular için güven puanlarının kaybını azaltmak gereklidir.

Sistem mimarisinde kare toplam hatası, büyük kutular ve küçük kutular arasındaki hataları eşit şekilde ağırlıklandırmaktadır. Amaç olarak hata metrikleri, büyük kutulardaki küçük sapmaları küçük kutulardaki sapmalardan daha az önemli olduğunu gösterebilmelidir. Bu durumu çözmek amaçlı sınırlayıcı kutunun genişlik ve yüksekliğini doğrudan tahmin etmek yerine karekökü tahmin edilir.

YOLO her ızgara hücresinde birden fazla sınırlayıcı kutu tahmin eder. Böylelikle teoride eğitim sürecinde her nesne için tahminlenen yalnızca bir sınırlayıcı kutu sorumlu olur. Bir nesneyi belirlemek için ise sorumlu olan sınırlayıcı kutular içerisinde yer gerçekliği ile en yüksek IoU'ya sahip olan tahmin belirlenir. Bu, sınırlayıcı kutu tahminleri arasında uzmanlaşmaya yol açar. Her bir tahminci belirli boyutları, en-boy oranlarını veya nesne türlerini tahmin etme konusunda daha iyi hale gelir ve genel hatırlama oranını artırır.

$$\lambda_{coord} \sum_{i=0}^{S^2} \sum_{j=0}^B 1_{ij}^{obj} [(x_i - x'_i)^2 + (y_i - y'_i)^2] \quad (1.5)$$

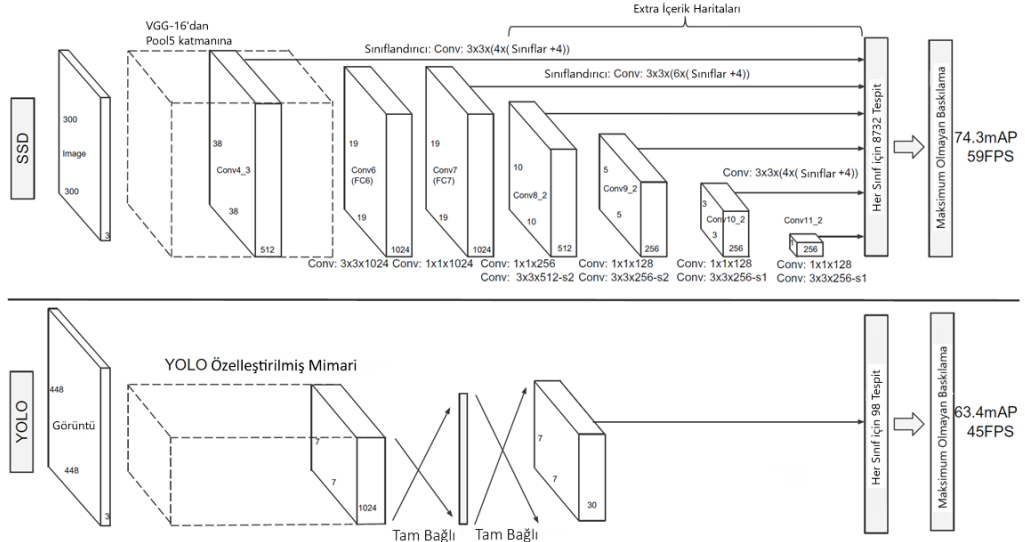
$$\begin{aligned}
& + \lambda_{coord} \sum_{i=0}^{S^2} \sum_{j=0}^B 1_{ij}^{obj} \left[\left(\sqrt{w_i} - \sqrt{w'_i} \right)^2 + \left(\sqrt{h_i} - \sqrt{h'_i} \right)^2 \right] \\
& + \sum_{i=0}^{S^2} \sum_{j=0}^B 1_{ij}^{obj} [(C_i - C'_i)^2] \\
& + \lambda_{noobj} \sum_{i=0}^{S^2} \sum_{j=0}^B 1_{ij}^{noobj} [(C_i - C'_i)^2] \\
& + \sum_{i=0}^{S^2} 1_i^{obj} \sum_{c \in classes} (p_i(c) - p'_i(c))^2
\end{aligned}$$

Fonksiyon 1.5'te 1_i^{obj} , i hücresinde nesne bulunup bulunmadığını gösterir ve 1_{ij}^{obj} , i hücresindeki j . sınırlayıcı kutu tahmincisinin bu tahmin için sorumlu olduğunu belirtmektedir. Kayıp fonksiyonu sadece sınıflandırma hatalarını cezalandırır. Ayrıca yalnızca o tahmincinin Yer Gerçekliği Kutusuna (Ground Truth Box) (yani o ızgara hücresindeki herhangi bir tahmincinin en yüksek IoU'suna) ilgili sınıflandırma hatası ile alakalı sorumlu olması durumunda ceza verir. YOLO mimarisinde doğruluk sorunlarına ek olarak çok küçük nesnelere tanınması konusunda da zorluklar yaşanmaktadır.

SSD yöntemi [13] her içerik haritası için farklı oran ve boyutlarda varsayılan kutular oluşturur. Nihai sınırlayıcı kutuların oluşumu için model aracılığıyla hesaplanan koordinatlar ve sınıf değerleri kullanılır [57].

Bu yöntemde nesne tespiti amacıyla tek bir Derin Sinir Ağı (Deep Neural Networks, DNN) kullanılır ve tahmin aşamasında her nesne kategorisi için skorlar üretebilir. Metod içerisinde sınırlayıcı kutuların şekillerinin daha iyi eşleşmesi için ayarlamalar yapılır. SSD hem eğitim hem de çıkarım aşamalarında birleşik bir çerçeve sunar ve YOLOv3 mimarisine göre daha yüksek hız ve doğruluk sağlar. Bu yöntem tekrar piksel veya özellikleri örneklemeyen ancak bunu yapan diğer derin ağ tabanlı yöntemler kadar doğru sonuçlar verebilen bir yöntemdir [62].

SSD yaklaşımı sabit boyutlu bir sınırlayıcı kutu koleksiyonu ve bu kutularda nesne sınıfı örneklerinin varlığına ilişkin puanlar üreten bir ileri beslemeli evrimsel bir ağa dayanır. Nihai tespitleri üretmek için Maksimum Olmayan Baskılama (Non-Maximum Suppression, NMS) adımı uygulanır.



Şekil 1.6. SSD ve YOLO mimarisi katmanları [55].

Şekil 1.6’da sunulduğu üzere SSD mimarisine YOLOv3 mimarisine ek olarak birçok içerik katmanı eklenmiştir. Örneğin YOLO mimarisinde tek bir evrimsel ağ katmanı ile oluşturulan özellik haritaları kullanılır. Böylelikle sabit bir grid yapısı ve sınırlı sayıda öneri kutusu ile nesne tahmini yapılır. Ancak SSD mimarisinde birden fazla içerik katmanı bulunmaktadır. Bu katmanlar farklı ölçeklerde olabilir (örneğin 8x8, 4x4, 2x2). Bu gibi farklılıklar sayesinde SSD ile küçük orta ve büyük nesnelere aynı anda tahmin edilebilir. Ayrıca YOLO mimarisinde kullanılan sabit grid yapısı bazı nesne şekillerine uyum sağlamada sınırlı kalabilir.

SSD eğitimi Çoklu Kutu (MultiBox) hedefinden yola çıkılarak türetilmiş ve çoklu nesne kategorilerini işleyebilecek şekilde genişletilmiştir [63], [64]. Örnek olarak p kategorisinde $x_{ij}^p = \{1,0\}$, i . Varsayılan kutunun j . yer gerçekliği kutusuna denk gelsin. Bu stratejiden hareketle $\sum_i x_{ij}^p \geq 1$ olabilmektedir. Genel kayıp fonksiyonu ise yerleştirme kaybının ve güven kaybının ağırlıklı toplamları olarak tanımlanabilir.

$$L(x, c, l, g) = \frac{1}{N} \left(L_{conf}(x, c) + \alpha_1 L_{loc}(x, l, g) \right) \quad (1.6)$$

Denklem 1.6’da yer alan (N) değeri, modelin eğitiminde kullanılan ve uygun şekilde eşleştirilmiş varsayılan kutuların sayısını temsil etmektedir. Bu eşleştirme modelin algıladığı kutular ile gerçek nesne konumları arasındaki uyumu ifade eder. Yerleştirme kaybı modelin tahmin ettiği kutu koordinatları (l) ile gerçek nesne kutusu koordinatları (g) arasındaki farkı ölçmek için kullanılan bir yöntemdir ve bu

amaçla Smooth L1 kaybı kullanılır. Smooth L1 kaybı hata hesaplamasında hem L1 hem de L2 kaybı özelliklerini bir araya getirerek daha az hassas olan büyük hatalar üzerinde daha az dikkat çekmeye ve daha küçük hatalar üzerinde daha fazla hassasiyet sağlamaya olanak tanımaktadır.

Faster R-CNN modelinde olduğu gibi bir yaklaşım izlenerek model her bir nesne için sınırlayıcı kutunun merkezini genişlik ve yükseklik değerlerini ayarlamak için kaymaları tahmin etmektedir. Bu kaymalar tahmin edilen kutunun gerçek kutuya olan konumunu ve boyutunu daha doğru bir şekilde belirlemek için kullanılır. Modelin tahmin ettiği sınıf içeriklerine ait güven sonucunu hesaplamak için softmax fonksiyonu kullanılır. Softmax fonksiyonu, modelin her bir nesne sınıfı için olasılık değerleri oluşturmasını sağlar ve bu varsayımlar hangi sınıfa ait olduğuna dair bir güven aralığı sunar. Sonuç olarak güven kaybı, modelin tahmin ettiği sınıf güvenleri (c) üzerinden hesaplanır. Ayrıca denklemin içinde yer alan (α_1) ağırlık terimi, yerleştirme kaybı ile güven kaybı arasında bir denge oluşturmaktadır. Bu değer çapraz doğrulama yöntemi ile saptanmış olup gerçekleşen denemeler sonucu 1 olarak belirlenmiştir. Böylece her iki kaybın modelin genel eğitimine katkısı eşit şekilde olmuştur [13].

SSD içerisinde farklı katmanlardan gelen özellik haritaları kullanılarak varsayımlar yapılabilir. Böylelikle görüntüyü diğer metotlarda olduğu gibi farklı boyutlarda tekrar oluşturup kullanmak gerekmez. Ayrıca önceki katmanların kullanımı giriş nesnelere ait daha fazla detayları yakaladığı için segmentasyon kalitesinin artmasını da sağlayabilir. Böylelikle obje tespiti için hem alt hem de üst özellik haritaları kullanılabilir. Varsayılan kutuların dizilimi ise belirli özellik haritalarında olan belirli nesne boyutlarına karşı duyarlı olacak şekilde tasarlanır. Kutuların dizilimi için m özellik haritası kullanmak istediğimizi varsayalım. Her özellik haritası için varsayılan kutuların ölçeği Denklem 1.7'de verildiği üzere hesaplanır.

$$s_k = s_{\{min\}} + \frac{s_{\{max\}} - s_{\{min\}}}{m - 1} (k - 1), \quad k \in [1, m] \quad (1.7)$$

$s_{\{min\}}$, $s_{\{max\}}$ sırasıyla 0.2 ve 0.9 değerlerini alır. En düşük katman 0.2 ölçeğine sahip, en yüksek katman ise 0.9 ölçeğine sahip olacaktır. Ayrıca tüm katmanlar arası düzenli bir şekilde dağıtılmış olacaktır. Varsayılan kutular için farklı görünüm oranları uygulanır ve bunları $a_r \in \left\{1, 2, 3, \frac{1}{2}, \frac{1}{3}\right\}$ gibi değerler alabilir. Her varsayılan kutu için

genişlik $w_k^a = s_k \sqrt{a_r}$ ve yükseklik $h_k^a = s_k \sqrt{a_r}$ hesaplanabilir. Görünüm oranı bir olduğu durum için ayrıca bir varsayılan kutu eklenir. Bu duruma özel ölçek ise $s'_k = \sqrt{sk \cdot sk + 1}$ şeklinde tanımlanır. Her özellik haritası konumu başına altı adet varsayılan kutu elde edilmiş olur. Her varsayılan kutunun merkezi $\frac{i+0.5}{|f_k|}, \frac{j+0.5}{|f_k|}$ olarak ayarlanır. Burada $|f_k|$ k. kare özellik haritasının boyutunu, i ve j ise 0 ile $|f_k|$ aralığında değerlerdir. Pratikte belirli bir veri kümesine en uygun varsayılan kutu dağıtımını da o veri kümesine özel olarak tasarlamak mümkündür.

Farklı ölçekler ve görünüm oranları ile tüm varsayılan kutuların tahminlerini birleştirerek çeşitli giriş nesne boyutları ve şekillerini kapsayan bir tahmin veri kümesi elde edilir. Ancak bazı durumlarda özellik haritası ve varsayılan kutu eşleşmeyebilir. Bu durum eğitim sırasında olumsuz sonuçların var olmasında önemli rol oynar. Visual Object Challenge (VOC) 2007 test verisi kullanılarak yapılan testlerde SSD için 300x300, YOLO için 448x448 piksel boyutundaki resimler ile giriş sağlanmış ve SSD metodunun daha iyi sonuçlar verdiği görülmüştür.

Sonuç olarak bu bölümde literatürde çokça kullanılan YZ tekniklerinin avantajları ve dezavantajları kapsamlı bir şekilde incelenmiştir. Özellikle DL metodolojilerinin otomotiv endüstrisinde kalite kontrol veya ortak çalışma süreçlerindeki uygulamaları üzerinde durulmuştur. Geliştirilmesi planlanan gerçek zamanlı CNN tabanlı kalite kontrol sistemi için farklı DL metotları değerlendirilmiş ve bu yöntemler arasından en uygun mimariler seçilmiştir.

YZ tabanlı sistemlerin endüstriyel uygulamalarda kullanılması, yüksek doğruluk oranları, hız ve otomasyon avantajları sağlamaktadır. Ancak bu teknolojilerin seçiminde sadece performans faktörleri değil aynı zamanda ticari kullanım açısından lisans koşulları da büyük önem arz etmektedir. Lisans koşulları bir teknolojinin kullanımını sınırlayabileceği gibi belirli kullanım alanlarını tamamen engelleyebilir. Bu yüzden kullanılacak DL mimarisinin seçimi sırasında ilgili lisanslar detaylı bir şekilde analiz edilmiştir.

Genel olarak açık kaynaklı yazılımlar MIT Lisansı, Apache Lisansı 2.0, GPL (Genel Kamu Lisansı) ve BSD Lisansları altında sunulmaktadır. MIT Lisansı ve Apache Lisansı 2.0, kullanıcıların yazılımı serbestçe kullanmasına değiştirmesine ve dağıtmasına olanak tanırken GPL lisansı daha katı düzenlemelere sahiptir ve dağıtılan yazılımın da aynı lisans altında olmasını zorunlu kılar. BSD lisansı ise kullanım

kolaylığı ve esneklik sunar ancak yazılımın orijinal lisansını ve yazarın adını koruma şartı içerir.

Bazı durumlarda belirli DL mimarileri performans açısından üstün olmalarına rağmen, lisans koşulları veya kısıtlı kullanım hakları nedeniyle ticari çalışmalar içerisinde tercih edilmeyebilir. Örneğin bir sistem GPL lisansı altında sunulduğu için ticari projelerde kullanımı sınırlı olabilir bu da özellikle endüstriyel uygulamalarda dikkate alınması gereken önemli bir husustur. Lisans konusu derinlemesine incelenmesi bir konu olmakla birlikte konu hakkında daha detaylı bir örnek verilecek olursa: YOLO V7 modeli GPL 3.0 lisansına sahiptir. Serbest bir şekilde kişisel ya da firma içerisinde kalacak şekilde kullanılabilir ve modifiye edilebilir. Ancak GPL 3.0 lisanslı bir yazılım başka bir lisans altında ya da kapalı kaynak kodlu bir yazılım olarak satılamaz başka bir deyişle kamuya yayılamaz. Bu durum da yarışın üst seviye olduğu yazılım çevrelerince tercih edilmemesinin ya da dikkat edilmez ise maddi sonuçlar ile karşılaşılmanın nedeni olabilir [65].

Bu çalışma kapsamında kullanılan YZ yöntemlerinin ticari projelerde rahatlıkla uygulanabilir olması için daha uygun lisans koşullarına sahip mimarilere öncelik verilmiştir.

Lisanslar ile alakalı limitler ve kullanım kuralları başka bir çalışmanın derinlemesine konusu olabilir; ancak burada yapılan incelemeler seçilen mimarinin sadece teknik açıdan değil aynı zamanda lisans ve yasal uygunluk açısından da en uygun seçenek olduğuna işaret etmektedir. Bu yaklaşım sistemin uzun vadeli sürdürülebilirliğini ve endüstriyel kabul edilebilirlik oranını artıracaktır.

1.6. Yapay Zekâ ve Etik Kuralları

YZ yöntemlerinin hızlı gelişimi bu alandaki etik kavramların da gündeme gelmesini gerektirmiştir. YZ sistemlerinin gündelik hayatın birçok alanında giderek daha yaygın bir şekilde kullanılması etik kaygıların daha derinlemesine incelenmesi gerektiği gerçeğini ortaya koymaktadır. Bu sistemler sağlıktan eğitime, hukuktan iş dünyasına kadar birçok alanda büyük bir potansiyele sahipken aynı zamanda önemli riskleri de barındırırlar. Örneğin sağlık hizmetlerinde YZ kullanımı yanlış teşhise neden olabilmekte iken adalet sisteminde kullanılan YZ hatalı kararlar verebilmektedir. Bu nedenle YZ'nin adil, şeffaf, hesap verebilir ve insan hakları açısından uygun bir şekilde geliştirilmesi tüm paydaşlar için önem teşkil etmektedir [66].

Sistemlerin şeffaflığı, takip edilebilirliği, anlaşılabilirliği ve hesap verebilirliği YZ'nin etik kullanımında önemli bir rol oynamaktadır. Özellikle karar alma süreçlerinin takip edilebilir olması hem kullanıcılar hem de düzenleyiciler için güven artırıcı bir faktördür. Bununla birlikte YZ'nin insanlarda bulunan duygusal durumları anlamak için empatik yetenekler edinmesi gerektiği de vurgulanmaktadır. Bu tür yetenekler insan-makine etkileşimlerinde daha etik ve sorumlu bir yaklaşım sağlayabilir [67].

YZ'nin topluma ve bireylere zarar vermemesi için geliştirilen sistemlerin tüm dünya tarafından tanınan insani değerlerle de uyumlu olması gerekmektedir. Özellikle kişiler arası mahremiyetin korunması, kişilik haklarının ihlal edilmemesi ve toplumun sosyal refahının artırılması gibi etik ilkeler YZ'nin geliştirilmesi ve uygulanmasında dikkate alınmalıdır [67]. Ek olarak hükümetler ve özel sektör kuruluşları, YZ'nin etik ve güvenilir kullanımı için ortak bir yapı oluşturabilir ve bu teknolojilerin topluma fayda sağlaması için birlikte çalışılabilir [66].

1.7. Önerilen Çalışmanın Özgün Yönleri

Tez çalışmasında sunulan otomotiv sektöründe YZ destekli parça kontrol sistemi aşağıda verilen yönleri ile bilime katkı sağlamaktadır.

* Veri toplama ve test süreçleri dünya genelinde en büyük otomotiv üretim tesislerinden birinde yürütülmüştür. Ayrıca gerçek zamanlı uygulamalar seri üretim ortamında test edilmiştir.

* Test sürecinde ortaya çıkan kritik problemlere özgü pratik deneyimler detaylı olarak analiz edilmiştir. Önerilen hibrit yapılar ve etkileşimler sayesinde yenilikçi ve etkili çözümler üretilerek üretilen çözümler yerinde denenmiştir.

* Çalışmanın veri tabanı, iki farklı DL yöntemini aynı sistemde kullanacak şekilde sekiz farklı motor parça varyasyonu ile oluşturulmuştur.

* TensorFlow geliştirme çatısı içerisinde gerçek zamanlı çalışabilen yeni bir veri artırma yöntemi geliştirilmiş ve kurulan sistem eğitim süreçlerinde kullanılmıştır.

* Yukarıdan aşağı bakar pozisyonda monte edilmiş iş birlikçi robot içeren sistem tasarlanmış, iş birlikçi robota monte edilen kameranın ilgili noktalara ulaşabilmesi sağlanmıştır. Sistemin Programlanabilir Lojik Kontrolcü (Programmable Logic Controller, PLC) gibi çevresel sistemler ile sorunsuz bir şekilde entegre olup seri üretim için diğer üretim bileşenleri ile de sağlıklı çalışması sağlanmıştır.

* Catia V5 kullanılarak insanın karmaşık işler için uyum becerisi ile iş birlikçi robot hassasiyetini birleştiren kapsamlı bir HRC modeli geliştirilmiştir. Sonuç olarak görev performansı, hat güvenliği ve sürdürülebilirliği ile alakalı simülasyonlar yapılmıştır.

* SSIM yöntemi ve bölge tabanlı parça izleme yaklaşımları modüler bir yazılım paketi oluşturularak DL tabanlı görüntü işleme ile birleştirilerek uygulanmıştır. Sonuç olarak çıktı kalitesi artırılarak ek sensör ve karmaşık kamera konfigürasyonları ortadan kaldırmıştır. Daha basit ve modüler sistemler oluşturularak farklı senaryolar üzerine simülasyonlar yapılmıştır.

* İş birliği modu ile tanımlanan görev sürelerinde kısaltmalar ve hedef görüntülerin algılanmasında yüksek doğruluk sağlanmıştır. Sonuçlar simülasyonlar ve gerçek zaman uygulamalar üzerinden gösterilmiştir.

* İnsan robot iş birliği ile ilgili literatürde bulunan matematiksel modelde iyileştirme sağlanmıştır. Modele iki yeni parametrenin etkisi de dahil edilerek gerçek zaman uygulamalarda daha gerçekçi sonuçlar üretilmesi mümkün hale getirilmiştir.

Bu çalışmada otomotiv üretim süreçlerinde meydana gelebilecek hataların, DL yöntemleri kullanılarak tespit edilmesi üzerinde durulmuştur. Çalışma içerisinde özellikle CNN tabanlı nesne algılama yöntemlerinin üretim aşamalarında meydana gelen hataları yüksek performansla tespit edebilmesi üzerinde durulmuştur. Önerilen hibrit yapılar ile motor bileşenleri gibi karmaşık parçaların kalite kontrolünün otonom olarak yapılması hataların son kullanıcıya ulaşmadan önce belirlenmesi ve önlenmesi amaçlanmıştır. Elde edilen sonuçlar önerilen yöntemlerin mevcut klasik görüntü işleme yöntemlerine kıyasla daha yüksek doğruluk ve hassasiyet sağladığını göstermiştir.

Tez çalışması şu şekilde organize edilmiştir. İkinci bölümde, çalışmada geliştirilen Rastgele Rotasyon Yöntemi (RRY) açıklanmış bu yöntemin üretim hattında karşılaşılan pozisyon değişimlerine karşı model performansını nasıl iyileştirdiği değerlendirilmiştir. Üçüncü bölümde, otomotiv parçalarının görüntü işleme teknikleri ile nasıl kontrol edildiği incelenmiş ve önerilen CNN tabanlı nesne tanıma yöntemleri açıklanmıştır. Oluşturulmak istenen sistem üzerinde teorik çalışmalar yapılarak ilgili proses simülasyonları gerçekleştirilmiştir. Dördüncü bölümde, geliştirilen sistemin test süreçleri, performans ölçüm kriterleri ve analiz sonuçları sunulmuştur. Beşinci bölümde ise çalışmanın sağladığı katkılar, sınırlılıkları ve otomotiv endüstrisinde YZ

tabanlı kalite kontrol sistemlerinin gelecekteki potansiyel kullanım alanları tartışılmıştır.





2. DERİN ÖĞRENMEDE VERİ ARTIRMA VE UYGULAMA YÖNTEMLERİ

DL modellerinin başarısı büyük ölçüde eğitim verisinin miktarına ve çeşitliliğine bağlı hale gelmiştir. Geleneksel veri artırma yöntemleri, mevcut veri seti üzerinde döndürme, ölçekleme, kırpma, parlaklık ayarlama gibi dönüşümler uygulayarak modelin genelleme yeteneğini artırmayı amaçlamaktadır. Ancak bu yöntemler, veri seti oluşturma sürecinde önceden tanımlanmış dönüşümlerle sınırlı kalmaktadır ve gerçek zamanlı adaptasyon yeteneğinden yoksundur.

Gerçek zamanlı veri artırma modelin eğitim süreci sırasında dinamik olarak veri dönüşümleri gerçekleştirmesine olanak tanır. Bu sayede model, her eğitim adımında farklı varyasyonlarla karşılaşarak daha sağlam ve esnek bir öğrenme süreci geçirir. Özellikle gerçek zamanlı uygulamalar ve sürekli değişen veri ortamlarında geleneksel veri artırma tekniklerine kıyasla daha etkili bir yaklaşım sunmaktadır.

Bu bölümde önce temel teknikler hakkında genel bilgiler verilmiş ardından geleneksel veri artırma yöntemlerinin gerçek zamanlı çalışma süreçlerinde yetersiz kalması nedeniyle önerilen gerçek zamanlı veri artırma yöntemi açıklanmıştır.

Tez çalışması kapsamında motor parçalarının kontrolü amacıyla alınan görüntülerden oluşan yeni bir veri seti oluşturulmuştur. Bu bağlamda görüntü işleme ve derin öğrenme tekniklerinden yararlanılmıştır. DL mimarilerinin görüntü işleme alanında atılım yapması 2012 yılında AlexNet modelinin ImageNet Büyük Ölçekli Görüntü Tanıma Yarışmasında (ILSVRC) [68] birinci olması ile başlamıştır. AlexNet geniş veri kümeleri üzerinde eğitilen CNN mimarisi sunarak modelin eğitim hızını GPU kullanımı ile belirgin oranda artırmıştır. Alexnet, Alex Krizhevsky, Ilya Sutskever ve Geoffrey Hinton tarafından oluşturulmuştur.

Sekiz katmandan oluşan bu ağ yapısı ile binlerce sınıftan oluşan görüntü tanıma işlemleri %84,6 doğruluk oranı ile başarıyla gerçekleştirilmiştir. Böylelikle DL modellerinin daha geniş veri kümelerinde etkili olabileceği de kanıtlanmıştır. AlexNet'in başarısı sağlık, güvenlik, otonom sürüş gibi birçok alanda DL'nin etkinliğini göstermiş ve bilgisayar görmesi çalışmalarında CNN kullanımını yaygınlaştırmıştır [69].

Sonrasında Oxford Üniversitesi'nden Karen Smolyan ve Andrew Zisserman tarafından yapılan çalışmalar ile DL'de katman sayısının artırmasının model doğruluğunu da artırabileceği gösterilmiştir. Bu amaçla derin öğrenme alanında bir kilometre taşı olan VGGNet modeli önerilmiştir. VGGNet özellikle 16 ve 19 katmanlı VGG16 ve VGG19 versiyonları ile görüntülerde ayrıntılı özelliklerin algılanmasını sağlamıştır [70]. Ancak bu yaklaşım daha çok işlem gücü ve bellek ihtiyacı gerektirmiş bunun bir sonucu olarak DL mimarilerinde hesaplama optimizasyonu ihtiyaçları doğmuştur. VGGNet, sonraki geliştirmeler için bir referans olurken günümüzde dahi performans karşılaştırma amaçlı olarak araştırmacılar tarafından çokça kullanılmaktadır.

2014 yılında GoogleNet olarak da bilinen ve geniş veri kümelerinde daha etkili parametre verimliliği sağlayan Inception mimarisi oluşturulmuştur. Bu mimari aynı katmandaki nesnelere için farklı boyutlarda çekirdekler (kernels) kullanarak modelin parametre sayısını düşürürken önceki metotlara oranla daha geniş bilgi oluşturulmasını sağlamıştır. Inception mimarisi CNN uygulamalarının daha karmaşık görüntü işleme problemlerinde daha verimli ve doğru aksiyon almasına katkıda bulunmuştur. Sonuç olarak GoogleNet özellikle büyük veri setlerinde VGGNet gibi derin ancak daha fazla işlem gerektiren bir modele karşı popüler bir model konumuna gelmiştir [71].

Daha karmaşık DL ağları oluşturuldukça farklı sorunlar meydana gelmiş ve kaybolan gradyan (vanishing gradient) sorunu olarak adlandırılan bir problem ile karşılaşmıştır. Kaybolan gradyan, modelin derinleştikçe geri yayılım (backpropagation) yöntemi ile bilgi aktarım sırasında her katmandaki hata (loss) değerinin türevleri yani gradyanlarının bir önceki katmana göre küçülmesi ve sifıra çok yaklaşması ile oluşur. Bu durum ise ağın ilk katmanlarında oluşan ağırlıkların yeterince güncellenmesini engeller. Problem ile alakalı Microsoft Research'ten Kaiming He ve ekibi, atlama bağlantıları (skip connections) fikrini oluşturarak özel bağlantılarla katmanlar arasındaki akışı sürdürmeyi sağlayabilen ResNet (Residual Networks) modelini geliştirmişlerdir. Bu özel bağlantılar gradyan akışını daha doğru bir şekilde sürdürerek modelin daha derin katmanlarda dahi eğitimine olanak sağlamıştır. Ek olarak 152 katmanlı bir ResNet modeli, yapılan ImageNet yarışmasında birinci olmuştur. Bu durum ise ResNet, DL ağlarının daha karmaşık ağlarda daha fazla katman ile eğitilebileceğini göstermiştir [72].

2017 yılına gelindiğinde ise R-CNN ailesinden gelen Mask R-CNN mimarisi oluşturulmuştur. Bu mimari nesne sınırlarını tanımakta ve görüntü içerisindeki nesnelere ayırarak maskeleyiş işlemleri yapabilmektedir. Kaiming He ve arkadaşları tarafından geliştirilen Mask R-CNN, özellikle güvenlik kameralarında nesne tanıma veya otonom sürüş becerilerinin geliştirilmesi amaçlı kullanılan oldukça güçlü bir araç olarak değerlendirilmektedir [73].

2020 yılında Dosovitskiy ve ekibinin çalışmaları ile ilk olarak doğal dil işleme alanlarında popülerlik kazanan dönüştürücü (transformer) tabanlı modelleri Görüntü Dönüştürücüleri (Vision Transformer, ViT) ismi ile görüntü işleme görevlerine uyarlanmışlardır. Bu yöntemde çok katmanlı dikkat mekanizmaları kullanılmış ve nesne tanıma görevlerinde yüksek doğruluk değerleri elde edilmiştir. Bu gelişme CNN tabanlı mimarilere alternatif olarak dönüştürücü tabanlı modellerin de görüntü işleme alanında başarılı olabileceği düşüncesini güçlendirmiştir. [74].

Sonraki yıllarda çok modlu model yaklaşımı geliştirilmiştir. Özellikle 2021'de geliştirilen Florence modeli hem metin hem de görüntü verilerini paralel olarak işleyebilmektedir. Örnek olarak Karşıtlık Tabanlı Dil-Görüntü Ön Eğitimi (Contrastive Language-Image Pre-training, CLIP), Büyük Ölçekli Görüntü ve Gürültülü Metin (A large-scale Image and Noisy-Text, ALIGN) ve Wu Dao 2.0 modelleri verilebilir. Bu tür modeller çoklu bilgi temsilleri ve anlam çıkarma becerileri sayesinde farklı alanlarda daha yüksek doğruluk elde etmek için kullanılır [75].

DL ve görüntü işleme alanlarında yaşanan gelişmeler büyük veri setlerinde verimli ve yüksek doğruluklu nesne tanılamasını mümkün hale getirmiştir. Ancak verilerin yeterli olmadığı veya sınıflar arası veri dengesizliğinin yaşandığı durumlarda veri artırma yöntemleri kritik bir rol oynamaktadır.

Daha önce de vurgulandığı gibi DL mimarileri son dönemde birçok farklı alanda geniş bir uygulama alanı bulmuştur [1]-[5]. Özellikle endüstriyel ortamlarda karşılaşılan karmaşık problemlerin üstesinden gelmek ya da bu süreçlerde çeşitli kolaylıklar sağlamak amacıyla DL sistemleri yaygın bir şekilde kullanılmaktadır.

Kullanılan DL mimarisinin yapısı uygulanan metotlar ve kullanılan veri setlerinin içeriklerine göre farklı DL mimarilerinin performansları değişmektedir. Ancak bu mimarilerin en önemli avantajlarından biri eğitim süreci sonrasında elde edilen

modelin yeni ve daha önce görülmemiş veriler karşısında genelleme yeteneğine sahip olmasıdır [76].

DL modellerinin eğitimi genellikle zaman alıcı olabilir ve sürecin iyi yönetilememesi durumunda performans düşebilmektedir. Eğitim, test ve doğrulama adımları için geniş hacimli veri tabanlarına ihtiyaç duyulmaktadır. Eğitim verilerinin yetersiz olduğu durumlarda, modelin performansını iyileştirmek ve çıktı kalitesini artırmak amacıyla veri artırma yöntemleri sıklıkla kullanılır [76], [77], [78]. Bu yöntemler özellikle veri miktarının sınırlı olduğu senaryolarda modelin genelleme yeteneğini artırmak ve aşırı öğrenme sorunlarını önlemek için hayati öneme sahiptirler.

Günümüzde CNN tabanlı mimariler endüstriyel ortamlarda özellikle kalite kontrol süreçlerinde yaygın olarak kullanılmaktadır. Ancak kontrol edilmek istenen parçaların kontrol alanına her zaman eğitim verisi ile aynı pozisyonda veya durumda girmesi beklenemez. Bu farklılıklar tespit veya sınıflandırma hatalarına yol açarak kontrol prosesinin işlevselliğini azaltabilir. Dolayısıyla sistemlerin eğitim süreci boyunca bu tür durumlara karşı hazırlıklı hale getirilmesi gerekmektedir. Bu bağlamda veri artırma yöntemleri sistem performansını artırmak ve modelin daha önce görülmemiş veriler karşısında daha sağlıklı sonuçlar vermesini sağlamak için kullanılır.


Gerçek zaman uygulamalar için en yaygın kullanılan DL kütüphanelerinden biri de TensorFlow geliştirme çatısıdır [79]. TensorFlow geliştirme çatısı içerisinde yaklaşık 40 adet gerçek zamanlı veri artırma yöntemi bulunmaktadır [80]. Google tarafından geliştirilen bu kütüphane ile ilgili olarak günümüzde GitHub üzerinde yaklaşık 146 bin örnek çalışma mevcuttur ve bu sayının gün geçtikçe arttığı gözlemlenmektedir.

Tez süresince yapılan gerçek zamanlı testler sırasında parçaların belirli bir ekseninde veya açıda rastgele farklı konumlarda geldiği gözlemlenmiş ve bu durumun sistem performansını olumsuz yönde etkilediği tespit edilmiştir. Bu nedenle bu kısımda yeni bir gerçek zamanlı veri artırma özelliği geliştirilmiş ve bu yöntem TensorFlow geliştirme çatısı altında 41. yöntem olarak çalıştırılmıştır. Geliştirilen veri artırma yöntemi, endüstriyel üretim tesislerinden alınan gerçek veriler üzerinde test edilmiş ve motor parçalarının kontrolü ile ilgili gerekli test ve analizler yapılmıştır. Testlerde performans değerlendirme amacıyla SSD mimarisi kullanılmış veri artırma yönteminin varlığı ve yokluğu durumunda elde edilen tespit başarımları karşılaştırmalı olarak analiz edilmiştir.

2.1. Veri Artırma Yöntemleri

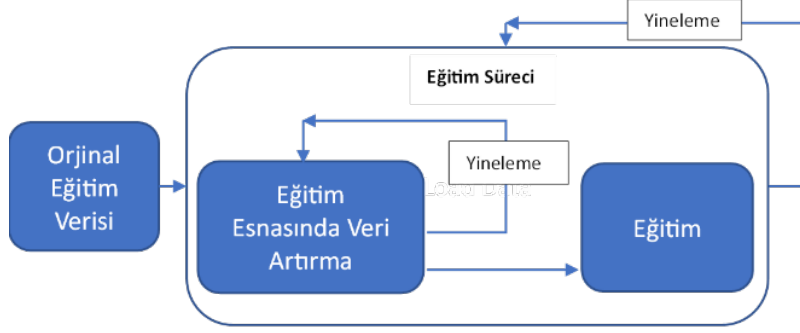
CNN tabanlı sistemlerde ön işleme ile veri artırma (pre-augmentation) ve gerçek zamanlı veri artırma (live or online augmentation) olmak üzere iki yaygın veri artırma stratejisi bulunmaktadır [81].

Ön işleme ile veri artırma yönteminde veri artırma işlemleri eğitim sürecinden önce gerçekleştirilir. Bu süreçte orijinal veriler üzerinde orijinaline sadık kalınarak çeşitli manipülasyonlar yapılır ve yeni veriler oluşturularak depolanır. Dolayısıyla veri miktarının yetersiz olduğu durumlarda, depolama kapasitesinin yeterli olduğu veya hazırlık süresi ile ilgili kısıtlamanın bulunmadığı senaryolarda bu yöntem sıklıkla tercih edilir. Ayrıca ön işleme ile veri artırma yöntemi sistemin karmaşık olmadığı ve veri miktarlarının çok yüksek olmadığı durumlarda uygun bir seçenek olabilir. Şekil 2.1'de ön işleme ile veri artırma yöntemine ait blok diyagram verilmiştir.




Şekil 2.1. Ön işleme ile veri artırma yöntemine ait blok diyagram.

Gerçek zamanlı veri artırma yöntemi veri artırma işleminin eğitim sırasında orijinal veriler kullanılarak otomatik olarak gerçekleştiği yaklaşımdır. Bu yöntemde eğitim süreci sırasında veri artırma işlemleri gerçek zamanlı olarak uygulanır ve bu sayede daha az manuel iş yükü ve depolama gereksinimi ortaya çıkar. Ayrıca manuel işlemlerin azaltılmasına ve etiketleme süreçlerinde insan kaynaklı hataların da önüne geçilmesine destek olur. Bu yöntem, eğitim sırasında veri artırımını yapmak için bilgisayar işlem birimlerinde ek hesaplama kaynakları gerektirir. Şekil 2.2'de gerçek zamanlı veri artırma yöntemine ait blok diyagram verilmiştir.



Şekil 2.2. Gerçek zamanlı veri artırma yöntemine ait blok diyagram.

TensorFlow geliştirme çatısı içerisinde bulunan başlıca gerçek zamanlı veri artırma yöntemleri arasında rastgele yatay çevirme, rastgele görüntü ölçeklendirme, rastgele kırpma, dolgu görüntüsü oluşturma, rastgele 90° döndürme ve rastgele JPEG kalitesi değişimi gibi yöntemler bulunmaktadır. Bu veri artırma yöntemlerine ait örnek görüntüler, binek otomobil helezon yayı üzerinde uygulamalı olarak Şekil 2.3'te verilmiştir.



Şekil 2.3. Uygulamada sıklıkla kullanılan bazı veri artırma yöntemleri.

Böylelikle orijinal parçadan yola çıkarak yeni perspektifler oluşturulmuş ve veri artırımını sağlanmıştır. Sonuç olarak sistemin ileride karşılaşılabileceği farklı durumlara karşı ve aşırı öğrenme problemlerini gidermek amacı ile rastgele veri artırım yöntemleri kullanılmaktadır.

2.2. Rastgele Rotasyon Yönteminin Oluşturulması

Bu aşamada gerçek zamanlı uygulamalarda karşılaşılan problemlerin çözümüne odaklanılmış ve TensorFlow geliştirme çatısı içerisine rastgele rotasyon yöntemi olarak adlandırılan bir veri artırma yönteminin eklenmiştir.

RRY yönteminin katkısını incelemek amacıyla yürütülen çalışmanın amacı DL teknikleri kullanılarak motor parçalarını işaretlerine, damgalarına veya etiketlerine göre kategorize etmek ve böylece üretim sürecinin kontrolünü sağlamaktır.

Deneysel çalışma, gerekli yasal izinlerin alınmasının ardından, Toyota Otomotiv Sanayi Türkiye A.Ş. (TMMT) tesisinde gerçekleştirilmiştir. Bu tesiste üretilen motor tiplerine göre beş standart sınıf belirlenmiştir. Test amaçlı bu beş sınıf için toplamda 2800 nesne içeren 1060 görüntünün bulunduğu bir veri kümesi meydana getirilmiştir. Tespit amacıyla kullanılan örnek DL mimarisi ise SSD olarak tercih edilmiştir.

Gerçek zamanlı çalışma sırasında üretim parçalarının her döngüde aynı konumda kontrol sürecine girmediği gözlemlenmiş ve parçaların kontrol sürecine yaklaşık $\pm 6^\circ$ farklı varyasyonlarla girdiği belirlenmiştir. Bu tür varyasyonlar sistemin kontrol sürecinde doğruluk oranının düşmesine veya bazı durumlarda çıktı üretilemediğinden sistemin durmasına neden olmaktadır. TensorFlow geliştirme çatısındaki veri artırma yöntemleri incelendiğinde bu probleme en yakın var olan çözümün yalnızca 90° döndürme seçeneği olduğu görülmüştür. Ancak gerçek zamanlı çalışmalarda, $\pm 6^\circ$ 'lik farklılıklar için 90° döndürme seçeneği yeterli olmamıştır.

Bu sorunun üstesinden gelmek için TensorFlow geliştirme çatısı altında çalışabilecek yeni bir veri artırma yöntemi üzerinde durulmuştur. TensorFlow görüntü verilerini bir veri akışında işler ve görüntüyü modele beslemeden önce bazı adımlardan geçirir. Bu adımlardan bir tanesi de ön işleme adıımıdır.

Öncelikle esnek ve gelişmiş algoritma yapısından dolayı OpenCV kütüphanesi ile TensorFlow birleşimi üzerine çalışılmıştır. Burada amaç, TensorFlow eğitimi sırasında görüntüleri istenen boyut ve açı aralığında döndürebilecek bir yazılım oluşturmak ve TensorFlow geliştirme çatısı ile bağlantılı işlemler yaparak eğitim sürecinde canlı veri artırma işlemleri yapabilmektir. Ancak TensorFlow'da varsayılan olarak kullanılan eager execution modu her bir işlem adımının hemen çalıştırılabildiği bir sistem mantığını barındırmaktadır [82]. OpenCV yapı gereği Numpy dizileri ile çalışmakta olup paralel yığın işlemleri için oluşturulmamıştır. Ayrıca TensorFlow objeleri ile doğrudan çalışamamış dönüşüm gerektirmiştir. Verinin sıralı işlenmesi durumunda dahi (eager execution modu: kapalı) OpenCV fonksiyonlarının çalışabilmesi için dönüşüm yapılması yanı sıra kullanılan TensorFlow 2.9.1 versiyonu için tf.compat.v1 değişimlerini de beraberinde getirmiştir. Bu durumun birçok hata,

ekstra bellek kullanımı ve zaman kaybına neden olacağı görülmüştür. Son olarak OpenCV 'nin GPU ile çalıştırıldığında dahi bazı fonksiyonlarının CPU üzerinde kalması gibi dezavantajlardan dolayı daha başka yöntemler üzerinde durulmuştur [83], [84], [85], [86].

Yapılan çalışmalar sonucunda, TensorFlow geliştirme çatısı altında çalışabilecek özel bir döndürme yöntemi tasarlanmıştır. Bu yöntemde rastgele açılar için Rodrigues dönüşüm matrisi hesaplanmıştır. Bu formül bir vektörü istenen ekseninde döndürmek için kullanılabilir [87]. Bu aşamadan sonra rastgele oluşturulmuş açı değerleri görüntü üzerinde uygulanmıştır. Uygulama için TensorFlow Addons kullanılmış ve `tfa.image.rotate()` fonksiyonu ile döndürme işlemi yapılmıştır. Son olarak ilgili döndürme matrisi CUDA ile GPU üzerinde paralel hesaplama kabiliyeti ile çalıştırılarak istenen sonuca ulaşılmıştır.

Bu yönteme RRY adı verilmiştir. Bu yeni döndürme yöntemi, eğitim esnasında istenilen eksene boyut ve derece aralığında gerçek zamanlı rastgele döndürme yapabilecek şekilde tasarlanmıştır. Böylelikle parçaların kontrol sürecinde farklı açılarda olmasına rağmen modelin doğru sonuçlar üretebilmesini ve genel performansının iyileştirilmesini sağlamaktadır.



Şekil 2.4. Seri üretim parçası üzerinde $\pm 6^\circ$ pozisyon değişikliği örneği [88].

Şekil 2.4'te gösterildiği üzere helikon yay üzerindeki yeşil renkli işaretleme, parça varyasyonunu temsil eder ve bu işaretleme üretici tarafından parçaların ayırt edilmesi için oluşturulmuştur. YZ sisteminin bu ve benzeri işaretlemeleri seri üretim ortamında yüksek hassasiyetle doğru bir şekilde tanıyabilmesi ve parça varyasyonlarını ayırt etmesi beklenir.

Geliştirilen yeni veri artırma metodu, TensorFlow geliştirme çatısı içerisine eklenmiş ve DL eğitimi sırasında nesnelerin istenilen eksenel boyut ve açı aralıklarında rastgele döndürülmesini sağlamak için tasarlanmıştır. Böylelikle parçaların farklı açılarda ve pozisyonlarda sisteme tanıtılmasını ve sistemin Şekil 2.4'te verildiği üzere rastgele farklı pozisyon varyasyonlarına karşı dayanıklı olmasını hedeflenmiştir.

Şekil 2.5'te, RRY'nin kullanıldığı DL eğitim sürecinde gerçekleştirilen gerçek zamanlı açı ve eksenel boyut değişimlerine ait örnekler sunulmuştur.



Şekil 2.5. DL eğitim sürecinde açı ve eksenel boyut değişim örnekleri.

Eğitim performansını değerlendirmek ve geliştirilen veri artırma yönteminin etkisini incelemek üzere Python programlama dili kullanılarak çeşitli analizler yapılmıştır. Test için üretim hattından farklı zaman dilimlerinde alınan 115 ek görüntü rastgele bir şekilde toplanmış ve bu veriler üzerinden sistem performansı farklı senaryolar üzerinden test edilmiştir.

Tablo 2.1'de varsayılan yöntem (VY), [89] kaynağından elde edilen model-master verisinin değiştirilmeden gerçekleştirilen halihazırda literatürde bulunan veri artırma ve SSD yöntemi uygulamasını içermektedir. RRY olarak adlandırılan yöntem ise, [89] kaynağından elde edilen model-master verisine uygulanan değişikliklerle birlikte araç parça verilerinin eksenel boyutunu ve $\pm 6^\circ$ aralığında rastgele döndürme fonksiyonunu içeren veri artırma işleminin SSD yöntemi ile uygulamasını içermektedir.

Tablodan görüldüğü gibi hem VY hem de RRY yöntemleri için yaklaşık 32.000 iterasyon sonrasında eğitim tamamlanmış ve test aşamasına geçilmiştir. Test aşamasında karşılaştırma amacıyla tabloda gerçek pozitif (GP), gerçek negatif (GN), yanlış pozitif (YP) ve yanlış negatif (YN) değerleri ile doğruluk oranları verilmiştir.

Deneylerde yığın değeri kullanılan bilgisayarın işlem kapasitesine bağlı olarak sekiz olarak seçilmiştir.

Tablo 2.1. VY ile RRY yönteminin farklı koşullar altında karşılaştırılması.

Giriş resimlerinde döndürme olmadığı durum:						
IoU:0.5, Eşik Değeri:0.6						
	GP	GN	YP	YN	Toplam	Doğruluk
VY	107	0	6	2	115	0,930435
RRY	110	0	3	2	115	0,956522
±6° içerisinde rastgele döndürme testi						
IoU:0.5, Eşik Değeri:0.6						
	GP	GN	YP	YN	Toplam	Doğruluk
VY	109	0	5	1	115	0,947826
RRY	109	0	4	2	115	0,947826
±6° içerisinde rastgele döndürme testi						
IoU:0.6, Eşik Değeri:0.6						
	GP	GN	YP	YN	Toplam	Doğruluk
VY	108	0	4	3	115	0,93913
RRY	109	0	3	3	115	0,947826
±6° içerisinde rastgele döndürme testi						
IoU:0.6, Eşik Değeri:0.5						
	GP	GN	YP	YN	Toplam	Doğruluk
VY	107	0	5	4	115	0,930435
RRY	109	0	4	2	115	0,947826
±6° içerisinde rastgele döndürme testi						
IoU:0.6, Eşik Değeri:0.75						
	GP	GN	YP	YN	Toplam	Doğruluk
VY	104	0	7	4	115	0,904348
RRY	106	0	5	4	115	0,921739

Testler, beş farklı IoU ve eşik değerleri üzerinden gerçekleştirilmiştir. IoU değeri nesnenin gerçekten bulunduğu bölge ile model tarafından tespit edilen bölgenin ne kadar örtüştüğünü ifade eder ve maksimum değeri bir olur [90]. IoU değeri ne kadar yüksek olursa sistemin nesneyi doğru bir şekilde tanıma olasılığı o kadar artar.

İlk durumda yani giriş (test) görüntülerinde döndürme işlemi olmadığında IoU 0,5 ve eşik değer 0,6 olarak belirlenmiştir. Bu durumda RRY ile yaklaşık %2,6'lık bir doğruluk artışı sağlanmıştır. Bu artış RRY yönteminin sabit açılardaki nesnelerin tanınmasında geleneksel yöntemlere göre daha üstün olduğunu göstermiştir.

Test verileri ±6° sınırları içerisinde rastgele döndürülerek analizler tekrarlanmıştır. İlk durumda olduğu gibi IoU 0,5 ve eşik değeri 0,6 olarak belirlenmiştir. Bu durumda hem VY hem de RRY yöntemi benzer sonuçlar üretmiştir.

Eşik değeri 0,75'e çıkarıldığında RRY yönteminin geleneksel yöntemle göre %2 oranında bir iyileşme sağladığı gözlemlenmiştir. Bu durum ise daha zorlayıcı durumlarda RRY yönteminin etkili olduğunu ortaya koymaktadır.

Gerçek dünya koşullarında hareket eden parçalar sistemin nesne tanıma performansını olumsuz etkileyebilir. Bu tür problemlerin üstesinden gelmek ve sistemi çalışır durumda tutmak oldukça zordur. IoU ve eşik değerleri gibi metriklerin düşürülmesi, sistemin doğruluk oranını olumsuz etkiler ve sonuç olarak sistemin genel kalitesini zayıflatabilir. Ancak Tablo 2.1'de görüldüğü üzere RRY yöntemi kullanıldığında daha yüksek IoU ve eşik değerlerinde dahi rastgele dönen giriş görüntüleri karşısında VY yöntemine kıyasla daha iyi sonuçlar elde edilmiştir.

Bu bulgular RRY yönteminin özellikle değişken koşullar altında çalışan sistemlerde nesne tanıma performansını artırmada önemli bir avantaj sağladığını göstermektedir. Dolayısıyla bu yöntem endüstriyel uygulamalarda daha güvenilir ve doğru bir kontrol süreci sağlamak için ideal bir çözüm olarak değerlendirilebilir.

Sonuç olarak parça kontrol süreçlerini yürütmek ve DL sistemlerinin performansını artırmak için geniş veri setlerine ihtiyaç duyulur. Ancak eksik veya yetersiz referans verileri modelin doğruluğunu olumsuz etkileyebilir. Bu tür durumların üstesinden gelmek için yaygın olarak kullanılan veri artırma yöntemleri arasında ölçeklendirme, renk değişiklikleri, rastgele çevirme ve döndürme gibi teknikler bulunur. Bu yöntemler modelin aşırı öğrenme problemleriyle başa çıkmasına da yardımcı olur.

Geliştirilen bu yöntem eğitim sürecinde giriş görüntülerini kullanıcının belirlediği açı ve eksenel boyutlar içerisinde rastgele döndürme imkânı sunar. Bu özellik uzun vadede sabit disk kullanımını optimize ederken insan kaynaklı etiketleme hatalarının da minimize edilmesini sağlar.

Sistem ile alakalı çalışmalar TensorFlow geliştirme çatısının SSD modeli temel alınarak test edilmiştir. Yapılan testler sonucunda RRY olarak adlandırılan bu yeni yöntemin VY'ye kıyasla yaklaşık %2,6 oranında doğruluk artışı sağladığını göstermiştir.

Ancak döndürme işleminin belirli bir açının üzerinde (örneğin 25°) gerçekleştirilmesi durumunda sonuçların iyileşmediği ve görüntülerde nesne boyut ve konumlarına bağlı olarak veri kaybının olduğu da gözlemlenmiştir. Bu bulgu döndürme açı ve ekseninin

görüntü içerisindeki nesne durumuna göre eğitim öncesinde dikkatle ayarlanması gerekliliğini göstermektedir.

Çalışmada kullanılan donanım ve yazılım altyapısı da önemli bir rol oynamaktadır. Eğitim ve test süreçleri için RTX 3080ti ekran kartına sahip bir dizüstü bilgisayar kullanılmıştır. Python 3.8.13, Anaconda ve TensorFlow 2.9.1 sürümleri kullanılarak gerçekleştirilen bu çalışmada, SSD modeli parça varyasyonlarını tespit etmek amacıyla 640x640 boyutlu giriş verisiyle eğitilmiştir. Veri tabanında bulunan 2800 nesne içeren 1060 görüntünün %80'i eğitim için kullanılmış, geri kalan veriler ise test amacıyla ayrılmıştır.

Bu kapsamda geliştirilen yeni veri artırma yöntemi parça kontrol süreçlerinde doğruluk oranını artırmak ve sistem performansını optimize etmek için güçlü bir araç olarak değerlendirilmiştir. Sistemin sağladığı bu avantajlar endüstriyel uygulamalarda daha etkili ve güvenilir bir kalite kontrol süreci sunma potansiyeline sahiptir. Yapılan çalışma referans [91]'te verildiği üzere 32. IEEE Sinyal İşleme ve İletişim Uygulamaları Kurultayı tarafından kabul edilmiş ve IEEE üzerinden yayınlanmıştır.

3. YAPAY ZEKÂ TABANLI MOTOR PARÇA KONTROL SİSTEMİ KURULUMU

Bu bölümde YZ yöntemleri kullanılarak oluşturulan parça kontrol sisteminin gerçek zamanlı üretim hatlarında kullanımı öncesinde örnek bir simülasyon çalışması yapılmıştır. Öncelikle oluşturulan veri tabanı hakkında bilgi verilmiş ve problem açıklanmıştır. Daha sonra farklı çalışma modları ile bir üretim prosesi üç boyutlu ortamda simüle edilmiştir. Son olarak elde edilen sonuçlar verilmiştir.

Yapılan çalışmada amaç motor parçalarını buldukları konumlarda tespit ederek parçaları işaretleri, damgaları veya etiketleri bakımından sınıflandırmaktır. Bu amaçla DL ve görüntü işleme tekniklerinden yararlanılmaktadır. Şekil 3.1’de üretim sürecinde bir motorun araca monte edilmeden önceki ve monte edildikten sonraki gösterimleri verilmiştir. Şekilden de görüldüğü gibi parça kontrolü yapılacak motor oldukça karmaşık bir yapıdadır. Dolayısıyla insan gözü ile yapılan kontrollerde özellikle yorgunluk gibi bireysel faktörler devreye girdiğinde hata oranı yükselmekte ve bu durum üretim sürecinin zamanında tamamlanmasına engel olmaktadır.




(a)



(b)

Şekil 3.1. (a) Motorun araca monte edilmeden önceki gösterimi [92], (b) Motorun araç üzerine monte edilmiş gösterimi [93].


Bu çalışmada otomotiv sektöründe üretim hatalarını tespit etmek amaçlı yüksek hassasiyete sahip YZ tabanlı otonom ve tümleşik bir sistem geliştirilmesi hedeflenmiştir. Oluşturulacak sistem ile alakalı tüm bileşenler dijital ortamda Catia V5 programı kullanılarak üç boyutlu olarak tasarlanmış ve sistem bileşenlerinin büyük oranda gerçek ortam ile aynı sonuçları vermesi amaçlanmıştır.



Şekil 3.2. (a) Gizlenmiş üç boyutlu bir motor modeli, (b) Kontrol istasyonu ile alakalı simülasyon.

Şekil 3.2 gizlenmiş üç boyutlu motor modelini ve geleneksel bir seri üretim kontrol prosesini göstermektedir. Klasik kontrol metodunda motor parçaları ilgili ekipmanlar sayesinde operatörler tarafından monte edilmektedir. Sonraki süreçlerde ise monte edilen parçalar başka operatörler tarafından kontrol edilerek süreç onaylanmaktadır.

Bu aşamada kontrol görevi için yüksek hassasiyet ve doğrulukta insan faktörüne bağlı kalınmadan parçaları kontrol edebilecek bir sistem tasarlanmıştır. Motor yapısı birçok parçadan oluşmaktadır. Şekil 3.3'te ilgili kontrol alanları gösterilmekte olup kontrol sisteminin görüş açısı üç boyutlu yarı çember geometrisi ve yeşil bölge gibi alanları tarayabilmelidir. Tanımlanan kontrol alanı motor etrafında kontrol amaçlı 360° görüş açısı gerektirmektedir. Ancak bu sayede doğrulanması gereken tüm parçaların kontrolü sağlanmaktadır.




Şekil 3.3. Üç boyutlu motor modeli ve ihtiyaç duyulan parça kontrol alanı.

Parçaların görüntülenmesi için birden fazla sabit kamera kullanma fikrinin, parça görüşlerinin ortaklaştırılması ve gelecekteki değişiklikler açısından pek de esnek bir

yapı olmadığı açıkça görülmektedir. Ayrıca geleneksel robot kullanımı da halihazırda yetersiz alana sahip olan hat içerisinde ekstra güvenlik ekipmanları gerektirmektedir. Bu nedenle insan ile çalışabilen ve hızlı bir şekilde yeni parça konumlarına uyum sağlayabilen bir proses oluşturmak için iş birlikçi robot kullanımına karar verilmiştir. Tasarlanan sistem yeni değişikliklere açık ve esnek bir yapıda olacaktır. İş birlikçi robot kullanımı ile yoğun olan proses ve alan gereksinimi insanlarla paylaşılan ortak süreçler sayesinde etkili bir şekilde en aza indirgenir. Sistemde seri üretim esnasında motor kontrolü için kullanılması amaçlanan iş birlikçi robota kamera monte edilerek parça kontrolü yapılmıştır.

Motor üzerinde tanımlanan bölgeler iş birlikçi robot ile seri üretim hattında iki farklı teknik kullanılarak incelenebilir. Şekil 3.4 kontrol yöntemi ile alakalı konsept simülasyonları göstermektedir. Şekil 3.4 (a) ve (b)'de yan yana iki iş birlikçi robot yerleştirme konsepti ve ters çevrilmiş konumda tek bir iş birlikçi robot seçeneği gösterilmektedir.



Şekil 3.4. Motor parçalarının kontrolü amaçlı iş birlikçi robot kullanım seçenekleri (a) Yan yana konumlandırılmış iki iş birlikçi robot ve (b) Ters çevrilmiş iş birlikçi robot kullanımı (Robo-Guide Programı).

İş birlikçi robot yük kapasitesi, yatay erişim mesafesi, tekrarlanabilirlik ve serbestlik derecesi (DOF) açısından gerekli koşulları sağlamalıdır. Yapılan testler sonucunda robotun kamerayı kontrol esnasında ilgili parçalardan 250-300 mm arası mesafede tutması ve tüm tanımlanmış parça konumlarına ulaşabilmesi gerekmektedir.

Kontrol işlemlerini yerine getirmek amaçlı piyasada bulunan ürünlerin araştırması ve tedarikçilerle ürün incelemesi yapılmıştır. Sonuçta tüm belirlenmiş parça konumlarına

ulařabilecek yeterli uzunluęa sahip en uygun iř birlikçi robot modeli belirlenmiřtir. Bu řekilde esnek ve insan dostu bir proses geliřtirilmesi amaçlanmıřtır.

Parça kontrolü için 15kg yük tařıma kapasitesi, 1441 mm maksimum yatay eriřim mesafesi, 0,02 mm tekrarlanabilirlik ve 6 DOF'ye sahip Fanuc CR-15ia iř birlikçi robot modeli seçilmiřtir. İlgili program ve simülasyonlar için Fanuc Robo-Guide programı kullanılmıř ve dijital ortamda gerekli simülasyonlar yapılmıřtır. Tanımlı parça konumları için takılı kamerayı başarıyla hareket ettirebilmek için robotun eksen sayıları ve serbestlik dereceleri ayrıca incelenmiřtir [94], [95].


Tasarlanan sistemde seri üretim sırasında motor parçalarını incelemek için DL tabanlı nesne tespit yöntemleri kullanılmaktadır. Bu ařamada iřlem sırasında ortaya çıkabilecek ıřık ve konum deęiřiklikleri gibi kořullara dayanıklı bir motor denetleme sistemi tasarlamak son derece önemlidir. DL yöntemleri kullanılarak motor parçaları iřaretleri, damgaları veya etiketleri doęrultusunda kategorize edilmektedir. Bu amaçla önerilen parça kontrol sisteminin gerçek zamanlı olarak kurulduęu otomotiv üretim tesisinde mevcut üretim motor tiplerinden tüm varyasyonları kapsayan beř adet standart sınıf seçilmiřtir. Bu sınıflar normal bir yüzey üzerindeki renk, parlak bir yüzey üzerindeki renk, etiket üzerindeki harf, bir parça yüzeyi üzerindeki harf, parlak bir yüzey üzerindeki harf olarak tanımlanmıř ve řekil 3.5'te verilmiřtir.



a) Normal yüzey
üzerindeki renk



b) Parlak yüzey
üzerindeki renk



c) Etiket
üzerindeki yazı



d) Parça
üzerindeki yazı




e) Parlak yüzey
üzerindeki yazı

Şekil 3.5. Farklı sınıflardaki araç parçalarının örnek gösterimi.

Tez çalışmasının bu aşamasında 17 farklı motor tipi için toplamda 125 adet farklı parça kontrolü yapılarak doğru parçaların doğru motor üzerine takılıp takılmadığının tespit edilmesi hedeflenmektedir. Böylelikle motorun araç üzerine yüklenmesi aşamasından önce gerekli kontroller YZ’li bir sistem tarafından yüksek doğruluk ve hassasiyet ile yapılmış olur.

Kontrol amaçlı tasarlanan proste motor kendinden tahrikli bir taşıyıcı üzerinde ve planlanan çalışma zamanı içerisinde durdurularak kontrol edilmektedir. Kontrol öncesi motor ile alakalı özellik bilgileri fabrikanın üretim sisteminden alınarak bölge bazlı hangi özellikli parçaların olması gerektiği YZ’li program tarafından teyit edilir. Aynı zamanda hat ile kontrol PLC [96] bağlantısı yapılarak ilgili motorun konum bilgisi alınır. Kontrol esnasında iş birlikçi robot ve altıncı eksenine bağlı olan kamera ile gerekli nesne tanıma ve onaylama işlemleri yürütülür. Farklı lensler ile gerçek zamanlı yapılan analizler sonucunda 8mm lens ile 5mp Flir marka, blackfly serisi kamera kullanımına karar verilmiştir.

Kamera, koruma parçası ve kabloların başlangıçta tasarlanan robotlu kontrol sistemine monte edileceği düşünüldüğünde robot dinamiklerinin değişeceği açıktır. Hesaplama hataları, sonraki aşamalarda birçok problemin meydana gelmesine ve hat duruşlarına neden olabilir. Kamera koruma kapağı, ortam aydınlatıcı gibi parçaların altıncı eksene monte edilmesi için tasarlanmıştır. Uzunluğu 370 mm olan ve yeni tasarlanmış ek parça robotun ağırlık merkezini ve taşıma kapasitesini değiştirmiştir. Kullanılan iş birlikçi robota ait eksen-altı yük bilgilerini içeren grafik Şekil 3.6'da verilmiştir.

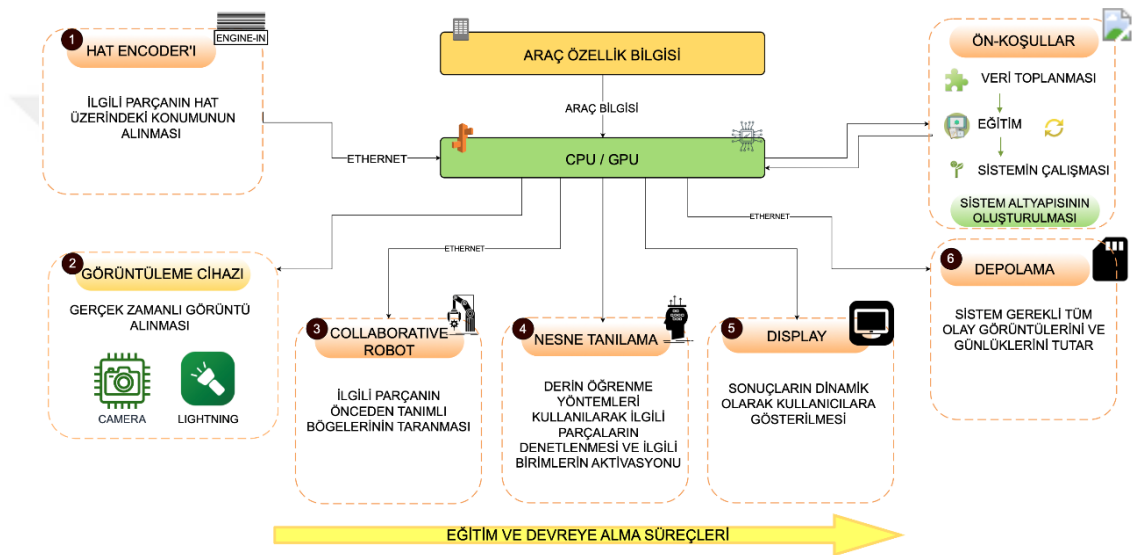


Şekil 3.6. Fanuc CR-15ia taşıma yükü ile alakalı grafik [97].

Kataloglarda iş birlikçi robotun taşıma kapasitesi 15 kg olarak gösterilmiş olsa da ek parçalar ile robotun merkezi denge noktası değişmektedir. Üretici firmanın teknik bilgi dokümanından elde edilen ve Şekil 3.6'da sunulan bilgilere göre ek kamera tasarımı, boyutları ve ağırlığı ile iş birlikçi robot eksen-altıda en fazla 4 kg taşıyabilmektedir [98], [99]. Ayrıca uluslararası ve Avrupa regülasyonları nedeniyle iş birlikçi robot hızı maksimum 800 mm/saniye hız ile sınırlandırılmalıdır [100].

Sonuç olarak ilgili çalışmada alan tarayıcılar gibi ek güvenlik önlemleri olmadan güvenli bir şekilde iş birlikçi robotların kullanılabileceği teyit edilmiştir. Önerilen motor parça kontrol sistemi içerisinde YZ modeli ve fiziksel bileşen seçimi başlıca kritik konulardır. Şekil 3.4 (b)'de gösterildiği gibi, ilgili parça pozisyonlarına erişmek için baş aşağı monte edilmiş iş birlikçi robot seçeneği kullanımına karar verilmiştir.

Bu durumda hali hazırda çalışan çevresel sistemler dikkate alınmalıdır. Sistem gerçek zamanlı bir ortamda mevcut üretim sistemleri ile iletişim kurmalı ve motor parça pozisyonları gibi gerekli bilgileri de almalıdır. Son olarak sistem motor spesifikasyonları ile alakalı parça bilgi ve varyasyon gibi içerikleri dinamik olarak edinmelidir. Bu iletişimi sağlamak için üretim hattı ve kontrol edilen sistem arasındaki gerekli veriler TCP-IP ve RS232 iletişimleri kurularak alınmaktadır. Robot iletişimi ana bilgisayar (nesne tespit algoritması dahil) tarafına yazılan yazılım ile Modbus protokolü üzerinden sağlanmaktadır. Üretim tesisinin gizlilik kurallarına uymak açısından daha detaylı bilgi verilememektedir.




Şekil 3.7. YZ destekli motor kontrol sistemine ait genel diyagram.

Tezde önerilen YZ destekli motor parça kontrol sistemine ait genel diyagram Şekil 3.7'de verilmiştir. Motor parça kontrol istasyonunun öncelikli olarak seçilmesi prosesin karmaşık olması ve geçmişte yaşanan arıza deneyimleri ile alakalıdır. Motor montajında hortum ve kablo gibi birçok parça bir araya gelerek otomobilin en önemli kısımlarından birini oluşturur. Ayrıca montaj işlemlerinden hemen sonra motorun gövde içerisine yerleştirilmesi bazı hataların sonradan bulunmasını zorlaştırır.

Sistemde öncelikli olarak ilgili parça görüntüleri toplanmakta ve gerekli etiketleme işlemlerinden sonra ilgili YZ yöntemi ile eğitim yapılmaktadır. Eğitim öncesinde veya esnasında veri artırma teknikleri kullanılarak aşırı öğrenme, veri yetersizliği veya veri dengesizliği (Bazı nesnelerin daha az verisinin olması) gibi problemlere karşı önlem alınmaktadır. Eğitim; konumlama, sınıflandırma veya total kayıp gibi değerler kontrol edilerek mümkün en ideal noktada sonlandırılmaktadır. Sonrasında ilgili eğitim çıktıları ile gerçek ortamda denemeler yapılmaktadır. Denemeler sırasında yukarıdan

aşağı asılmış iş birlikçi robot hareket ettirilerek ve eğitim sonucu ile alakalı sistem performansı teyit edilmektedir.

DL adımları Şekil 3.8’de verildiği üzere üç ana aşamaya ayrılmış ve detaylandırılmıştır [101], [102]. Bu çalışma kapsamında daha çok görüntü işleme üzerinde durulmuş ve görüntü işleme adımları incelenmiştir.



Şekil 3.8. DL eğitim aşamaları.

Aşamalar özetle şu şekilde açıklanabilir:

Görüntü Toplama ve Filtreleme: Gün içerisinde değişken ışığın olduğu bir ortamda hedef nesnenin görüntülerini toplamak için farklı zamanlarda ve mümkünse gerçek zamanlı görüntüler alınmalıdır. Alınan görüntüler detaylı analizlerden geçirilerek ilgisiz veriler ayklanır. Bu süreçte nesne içeren görüntüler dikkatlice incelenir ve benzer görüntüler filtelenir. Gerekli durumlarda manuel kırpma işlemleri yapılarak gereksiz bölümler çıkarılır.

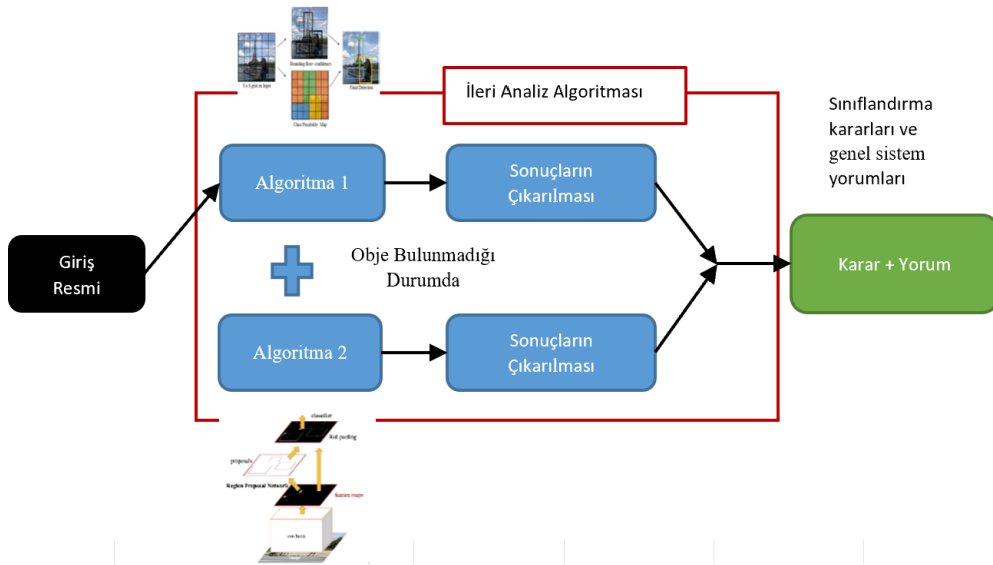
Görüntülerin İşlenmesi ve Etiketlenmesi: Görüntüler kullanılacak modelin gereksinimlerine göre yeniden boyutlandırılır. Büyük veri setlerinden kaynaklanabilecek zaman kaybı ve diğer problemleri önlemek amacı ile özel bir

yazılım kullanılarak görüntülerin boyutları küçültülür. Daha sonra tüm görüntüler rastgele yeniden adlandırılarak parça görüntüleri homojen bir şekilde dağıtılır. Veri tabanı için seçilen görüntüler farklı sınıflara ayrılır ve her sınıftan yeteri kadar veri oluşturulur. Bazı görüntüler birden fazla nesne içerebilir bu durumda bu nesnelere etiketleme sırasında dikkate alınarak işaretlenir. Etiketleme işlemi tamamlandıktan sonra tüm etiketler kontrol edilerek eğitim için hazır hale getirilir.

Eğitim ve Test Veri Setlerinin Oluşturulması: Veri tabanı eğitim ve test veri kümesi olarak ikiye ayrılır. Görüntülerin yaklaşık %80'i rastgele seçilerek eğitim veri kümesi oluşturulur geri kalan %20 ise test veri kümesi olarak kullanılır. Bu şekilde modelin eğitimi sırasındaki performansı ve doğruluğu hakkında bilgi sağlanabilir.

3.1. Derin Öğrenme Yöntemleri Kullanılarak Gerçek Zamanlı Parça Kontrol Sistemi Uygulama Süreci

Verilen bilgiler doğrultusunda parça denetim sisteminin fiziksel bileşenleri oluşturulmuş ve yazılım ile ilgili parça kontrol çalışmaları yapılmıştır. Gerçekleştirilen ön çalışma sonuçlarına göre sistemin kendi içerisinde iki algoritma ile çalışabilen hibrit yapıda olması tercih edilmiştir. Oluşturulan yapıda öncelikle algoritma bir çalışmakta ve algoritma birin yetersiz kaldığı durumlar için algoritma iki devreye girmektedir. Algoritmalarla ilgili basitleştirilmiş karar verme blok diyagramı Şekil 3.9'da verilmiştir.



Şekil 3.9. Karar verme blok diyagramı.

Motor parça denetimi için oluşturulan gerçek zamanlı sistem görüntüsü Şekil 3.10'da verilmiştir. Program yapıları çevresel sistem iletişimi ve gerekli simülasyonlarla ilgili testler yapılmıştır. Minimum seviyede alan kullanımı ile esnek bir yapı kurulmuş ve parça denetimleri gerçekleştirilmiştir.



Şekil 3.10. Gerçek zamanlı parça kontrol sisteminin fabrika içerisindeki görünümü.

Gerçek zamanlı uygulama esnasında iş birlikçi robotun bağlandığı çerçeve dayanıklılığı yük altındaki mukavemet sınırları ve yapısal zayıflıkları değerlendirmek amacıyla kapsamlı bir gerilme analizi de gerçekleştirilmiştir. Robot çerçevesine ilişkin gerilme testleri Şekil 3.11'de verilmiş olup Catia v5 programı kullanılarak Von Mises gerilmesi yöntemi ile hesaplanmıştır.

İşbirlikçi robotlar endüstriyel uygulamalarda operatörle aynı alanda çalışacak şekilde tasarlandığından çerçeve tasarımı ve yapısal dayanıklılığı büyük önem taşır. Çerçevenin herhangi bir deformasyona veya arızaya yol açmaması iş güvenliği ve üretim verimliliği açısından oldukça kritik rol oynamaktadır. Analiz sürecinde öncelikle robotun çerçevesi üç boyutlu ortamda tasarlanmış ve belirlenen destek noktalarından sabitlenmiştir. Çerçeve üzerinde robotun bağlanacağı kısımlardan olacak şekilde program ile sanal yükler oluşturulmuş ve çerçevenin bu yükler karşısındaki davranışı analiz edilmiştir. Ayrıca çerçevenin yer ile temas eden kısımları gerçek zamanlı çalışmada olduğu üzere sabitlenmiştir.


Yük dağılımının doğruluğunu sağlamak için yükün etki ettiği noktaların doğru bir şekilde modellenmesi gerilme analizinin doğruluğunu artırmaktadır. Gerçekleştirilen bu adımlar çerçevenin çalışma sırasında karşılaşacağı dinamik yükler altında yapısal bütünlüğünü korumasına olanak tanımaktadır.

Çerçeveye uygulanan yük robotun toplam ağırlığının 1,5 katı olacak şekilde hesaplanmış böylece robotun dinamik hareketler sırasında oluşturabileceği maksimum yük dikkate alınmıştır. Bu yük simülasyonları çerçevenin olası en zorlu koşullarda bile deformasyona uğramadan performans göstermesi açısından önemlidir.

Bu aşamada çerçevede potansiyel zayıflık noktaları analiz edilerek yapısal dayanıklılığı artırmaya yönelik iyileştirmeler yapılmıştır. Çerçevenin zayıf noktalarına yönelik güçlendirmeler yapılarak sistemin uzun süreli kullanımı boyunca istenen görevleri başarılı bir şekilde yerine getirebilmesi hedeflenmiştir.

Yapılan gerilme testleri ile yapı destek ayakları ve bağlantılar ekstra güçlendirilmiştir. Von Mises gerilmesi malzemenin akma dayanımına ulaşip ulaşmadığını belirlemek için kullanılan yaygın bir kriterdir. Bu analizde çerçevenin yük altındaki dayanım sınırları ve potansiyel zayıf noktaları belirlenmiştir. Çıkan sonuçlar robot taşıyıcı çerçevesinde en yüksek gerilme değerlerinin bağlantı noktalarında ve taşıyıcı çerçevenin eğilme alanlarında yoğunlaştığını göstermiştir. Analizler esnasında özellikle çerçevenin üst kısmına yakın bölge ve alt destek noktaları, maksimum gerilme değerlerine maruz kalmıştır. Bu bulgular doğrultusunda çerçevenin destek ayakları ve bağlantı elemanları daha sağlam hale getirilmiş ilgili bölgeler için yapısal dayanıklılık artırılmıştır.

Bu kapsamda özellikle yüksek gerilme altında kalan bağlantı noktaları için daha güçlü malzemeler kullanılmış ve ilave destek parçaları eklenmiştir. Güçlendirme çalışmalarının ardından yapılan ikinci gerilme testi sonuçları iyileştirilen yapının gerilme ve deformasyon seviyelerinin azaldığını göstermiştir. Bu durum robotun uzun süreli kullanımı boyunca stabil ve güvenli bir şekilde çalışmasını sağlayacaktır. İlgili analizler sonrası oluşturulan çerçevenin son hali Şekil 3.11 'de verilmiştir.



Şekil 3.11. İş birlikçi robot çalışması için oluşturulan taşıyıcı çerçeve.

Robot çerçevelerinin dayanıklılığı ile ilgili literatür incelendiğinde farklı yapı malzemeleri ve bağlantı elemanları kullanılarak yapılan benzer gerilme testleri dikkat çekmektedir. Örneğin Smith ve arkadaşlarının [103] iş birlikçi robot çerçevelerinde karbon fiber malzeme kullanımının gerilme dayanımını artırdığı yönündeki çalışması, benzer analizlerle karşılaştırıldığında büyük önem arz etmektedir.

Ayrıca Wang ve Liu'nun [104] iş birlikçi robotlar için optimize edilmiş çerçeve tasarımlarının dayanıklılığını artırmaya yönelik sundukları analizler de hesaplamalarda dikkate alınmıştır. Bu doğrultuda mevcut iş birlikçi robot taşıyıcı çerçevesinin test sonuçları literatürdeki çalışmalarla kıyaslanarak analiz edilmiş ve bu çerçevede güçlendirme çalışmaları bilimsel temellere dayandırılmıştır.

Üretim sırasında sistem ile ilgili yazılım ve parametreler ayrıntılı bir şekilde incelenmiştir. Nesne tespiti için birçok DL yöntemi vardır. Geçmiş tecrübeler ve literatür incelemeleri sonucunda parça tespiti için SSD ve Faster R-CNN mimarileri tercih edilmiştir.

SSD bölge öneri ağı gereksinimini ortadan kaldırarak işlem süresini hızlandıran bir nesne algılama algoritmasıdır. Hız avantajı özellikle üretim hattı gibi zamanın oldukça kritik olduğu uygulamalarda SSD yöntemini ideal hale getirir. SSD tek bir mimaride

nesne tespiti ve sınıflandırma sağlar ve üç ana bileşenden oluşur: CNN mimarisi çoklu kutu dedektör ağı ve maksimum bastırma olmayan yapı.

CNN mimarisi özellik çıkarma aşamasında kullanılarak giriş görüntüsünden özellik haritaları oluşturur. SSD, VGG16 modelini kullanarak giriş görüntüsünden detaylı özellik vektörleri çıkarır ve bu vektörler çoklu kutu dedektörüne uygulanarak sınırlayıcı kutular elde edilir. Maksimum bastırma olmayan yöntem tespit edilen kutulardan en yüksek güven değerine sahip olanı seçerek son çıktıyı verir.

Faster R-CNN ise daha derin bir ağ yapısı sunar ve nesne tespitinde daha yüksek doğruluk oranlarına ulaşmayı hedefler. Bir giriş görüntüsünü alır ve özellik haritası elde etmek için evrimsel bir ağdan geçirir. Bu ağ Inception, ResNet veya VGG16 gibi derin modellerden herhangi biri olabilir ve özellik çıkarma aşaması oldukça iyi bir şekilde gerçekleştirilir. Faster R-CNN, SSD yönteminin aksine bölge önerileri oluşturarak nesne tespiti sürecine katkı sağlar. Bu bölge önerileri her bir nesne adayının çevresinde sınırlayıcı kutular oluşturur ve bu kutular üzerinden sınıflandırma işlemi yapılır. Bu yöntem doğruluk parametresinin hız parametresinden daha öncelikli olduğu durumlarda tercih edilmektedir.

SSD ve Faster R-CNN yöntemlerinin hibrit kullanımı her iki yöntemin de güçlü yanlarını birleştirerek üretim sürecindeki nesne algılama performansını optimize eder. SSD'nin hızlı yapısı ile Faster R-CNN'nin yüksek doğruluk sağlayan yapısının birleşimi, üretim hattında hem hız hem de doğruluk açısından ideal bir çözüm sunmaktadır. Bu hibrit yapı üretim sürecinde sürekli veri akışını sağlamakta ve çeşitli açılardan alınan görüntülerdeki nesnelerin doğru şekilde tespit edilmesine olanak sağlamaktadır. Özellik haritaları elde edildikten sonra her bir nokta farklı boyut ve şekillerde birden fazla kutu oluşturmak için çapa olarak ele alınır. İşlenen çapa noktası kutuları nesne algılama hedefine ulaşmak için kullanılır.


Bir ağ kullanılarak çapa noktaları bölge önerilerine dönüştürülür. Son adımda maksimum bastırma olmayan teknik, tekrarlanan sınırlayıcı kutuları ortadan kaldırır ve dedektör nesnelere içeren kutuları tanır. Bölge önerileri sınıflandırma görevlerini gerçekleştirmek için sınırlayıcı kutudaki nesnelere sınıflandıran bir ağa gönderilir. SSD ve Faster R-CNN mimarilerinin detayları referans [13] ve [16]'da verilmiştir.

Şekil 3.12'de sistemin tüm süreçlerini ve algoritmanın nasıl çalıştığını daha iyi anlamak için bir sistem akış diyagramı oluşturulmuştur. Akış diyagramından

görülebceđi üzere süreçlerin başlaması SSD ve Faster R-CNN yöntemleriyle ilgili gerekli kütüphanelerin yüklenmesini içerir.

SSD belirli koşullarda bir öğeyi tespit edemezse (çevresel sistemlerden alınan veriler doğrultusunda o anda hangi parçanın incelendiđi ve işlem sırası bilinmektedir), kontrol sürecinin proses süresi içinde tamamlanmasını sağlamak için sistem bir sonraki öğeye geçer. Bu sırada Faster R-CNN önceden kaydedilmiş belirli bir dizi görüntü (isteđe bađlı olarak ayarlanabilir) üzerinde çalışarak kusurlu öğeleri tespit eder.

Çalışma akışı kullanıcı arayüzünde basitleştirilmiş görsellerle verilmiş ve kullanıcı dostu bir arayüz oluşturulmuştur. Seri üretim ortamlarında zaman çok değerli ve sınırlıdır. Bu nedenle sistem akış diyagramı sınırlı zamanı en etkili şekilde kullanacak mantıkta oluşturulmuştur.



Şekil 3.12. Parça denetleme kalite kontrol sistemi genel diyagramı.

Ön Bilgi Toplama: Sistem işlem sürecine başlamadan önce sunucudan ayrıntılı veri olarak kontrol sırasında kullanılacak referans bilgileri toplar. Bu aşama işlemin doğru bir temel üzerine kurulmasını sağlamak amacıyla yapılır.

Motor Pozisyonunun Doğrulanması: Sunucudan alınan veriler doğrultusunda motor pozisyonunun doğruluğu sistem tarafından kontrol edilir ve onaylanır. Bu adım işlemin başlangıcında hatalı bir durum oluşmasını önlemeyi amaçlar.

Kullanıcı Arayüzüne Bilgi Aktarımı: Motor pozisyonu doğrulandıktan sonra mevcut durum kullanıcı arayüzünde gösterilir. Bu sayede kullanıcı, sistemin mevcut konum ve durumu hakkında bilgilendirilir.

Başlangıç Pozisyonuna Hareket: Sistem robotu varsayılan pozisyonundan işlemin başlangıç konumuna hareket ettirir. Bu hareket belirli bir zaman sınırı içinde gerçekleştirilir ve işlem başlangıcı için uygun konum sağlanır.

Motor Verilerinin Sunucu ile Uyumu: Motorun durumu anlık olarak sunucu verileriyle karşılaştırılır. Eğer veriler arasında uyumsuzluk varsa bu uyumsuzluk kullanıcı arayüzünde gösterilir ve ilgili aksiyonların alınması beklenir.

Güncel Motor Verisi Kontrolü: Motorun anlık durumu sunucudaki veri havuzundaki bilgilerle karşılaştırılarak uyum kontrol edilir.

İlgili Nesnelerin Tespiti: SSD algoritması aktif edilerek istasyon ile ilişkili nesnelere önceden belirlenen sıralama doğrultusunda tespit edilir.

Görüntü Kaydetme: İlgili nesnelere tespit edildiği sırada istasyondaki kontrol süresince beş adet görüntü kaydedilir. Bu görüntüler ileri aşamalarda analiz ve karar verme süreçleri için kullanılır.

Karar Verme Bölgesi: Tespit edilen nesnelere belirlenmiş sınırlara (örneğin; IoU, eşik değeri) göre değerlendirilir. Belirlenen değerleri karşılamayan ve karşılayan kontrol sonuçları için karar verme süreci farklı şekillerde işletilir.

Karar Verme Süreci: Tanımlanmış kriterler karşılanamaz ise kaydedilen görüntüler üzerinden Faster R-CNN algoritması çalıştırılarak nesnenin durumu detaylı olarak analiz edilir. Eğer tanımlı sınırlar karşılanırsa robot bir sonraki istasyona hareket eder.

Belirlenen Kriterlerin Karşılanmaması Durumunda Parça Seçiminin Onaylanması: Kullanıcı, kontrol işlemi sonucunda seçilen parçanın uygun olup olmadığını değerlendirir. Parça uygun bulunursa sistem bir sonraki adımına geçer. Seçilen parça hemen tamir edilebilir durumdaysa, sistem tamir prosedürlerini başlatır.

Kullanıcı Onayı İşlemleri: Kullanıcı, “Tamir Et” butonuna basarsa, sistem tamir sürecini işletir.

Eğer kullanıcı “Geç” butonuna basarsa ilgili nesneye müdahale edilmeden sonraki adıma geçilir. İlgili nesne tamir işlemleri ilgili bölüme bilgi olarak aktarılır. Parça tamiri olmadan aracın fabrika dışına çıkmaması için otonom tutma işlemi yapılır.

Döngü Süreci: Tüm bu adımlar biten her kontrol süreci sonrasında yeni motor bilgisi ile yeniden başlatılır. Bu sürecin tamamı robotun her bir istasyondaki görevleri etkin ve güvenli bir şekilde gerçekleştirmesi için tasarlanmıştır. Karar verme ve kullanıcı onayı aşamaları ise sistemin esnekliğini ve adaptasyon kabiliyetini artırmaktadır.

Önerilen DL tabanlı denetim sisteminin performans değerlendirmesinde kayıp fonksiyonları dikkate alınmıştır. Kayıp fonksiyonları modelin performansını ölçer ve optimizasyon sürecine süreçte verilen eğitim verilerine ne kadar iyi uyduğuna dair geri bildirim sağlayarak rehberlik eder.

Literatürde seçilecek birçok kayıp fonksiyonu vardır. Bir model eğitilirken hangi kayıp fonksiyonu seçileceği ya da kayıp fonksiyonunun veya rolünün ne olduğu konusunda bilgi sahibi olmak zor olabilir. Sistem hakkında tüm yetenek ve metriklerin ölçülmesi sistem kalitesini sağlamak için önemlidir. Bu çalışmada nesne kaybı fonksiyonu dikkate alınmıştır. Nesne kaybı fonksiyonu Denklem 3.1'de verildiği gibi güven ve konum kaybının toplamıdır.

$$L(z, c, l, g) = \frac{1}{n} (L_{conf}(z, c) + L_{loc}(z, l, g)) \quad (3.1)$$

Burada n , gerçek nesneyle eşleşen varsayılan çerçevelerin sayısını ifade eder $L_{conf}(z, c)$ güven kaybını ve $L_{loc}(z, l, g)$ konum kaybını temsil eder [14]. Farklı kategorilerin standart kutuların ve gerçek nesnelerin eşleşme sonuçları z ile gösterilirken c tahminin güven değerini ve g ise konum bilgisini ifade eder. Nesne kaybı fonksiyonu ve konum kaybı aynı zamanda önemli kayıpları da içerir.

Eğitim sürecinde CNN mimarisi kayıp fonksiyonunu mümkün olan en küçük değerine düşürmek için çalışır. Sonuç olarak sistemin güvenilirliği ve öngörü kapasitesi artırılabilir. Çeşitli optimizasyon yöntemleri sistemin tanı performansını sürekli olarak geliştirmeye yardımcı olur.

Nesne algılama ve tanıma sistemlerinin performansını değerlendirmek için çeşitli kriterler kullanılabilir. Bu çalışmada sistem değerlendirmesi için IoU, mAP ve Ortalama Geri Çağırma (AR) metrikleri ağırlıklı olarak kullanılmıştır.

IoU tespit edilecek nesneyi içeren gerçek sınırlayıcı kutuyu DL yöntemi tarafından tahmin edilen sınırlayıcı kutu ile karşılaştırır. IoU, 0 ile 1 arasında değer alır ve belirli bir veri kümesinde nesne algılama doğruluğunu ölçer. Daha yüksek IoU gerçek

sınırlayıcı kutu ve tahmin edilen kutular arasında daha yüksek örtüşme anlamına gelir. IoU aşağıdaki ifade ile hesaplanabilir [105].

$$IoU = \frac{area(B_p \cap B_{gt})}{area(B_p \cup B_{gt})} \quad (3.2)$$

Denklem 3.2'de B_p sınırlayıcı kutunun tahminini, B_{gt} ise sınırlayıcı kutunun gerçeğini (ground truth) ifade eder. Tespit edilecek nesne için belirtilen sınırlayıcı kutuyu kabul etmek amacıyla belirlenen IoU eşik değeri 0.5'tir. IoU 0.5'i aşarsa tespit edilen nesne doğru pozitif olarak sınıflandırılır.

mAP, Faster R-CNN, YOLO ve SSD gibi nesne tespit yöntemlerinin performansını analiz etmek için de yaygın olarak kullanılan bir kriterdir. Ortalama Hassasiyet (AP) geri çağırma değeri 0'dan 1'e kadar olan doğruluk verilerinin ortalamasını hesaplar. mAP, karışıklık matrisi, IoU ve geri çağırma metriklerine dayanarak hesaplanır. İlk olarak tüm sınıfların hassasiyet değerlerini bulmak için hesaplanır. Daha sonra ortalama hassasiyet değeri, geri çağırma eğrisi üzerinde enterpolasyon yöntemi ile elde edilir ve bu işlem Denklem 3.3 ve Denklem 3.4 ile ifade edilir.

$$AP = \sum_{r=0}^1 (r_{n+1} - r_n) \rho_{interp}(r_{n+1}) \quad (3.3)$$


$$\rho_{interp}(r_{n+1}) = \max_{\tilde{r}: \tilde{r} \geq r_{n+1}} \rho(\tilde{r}) \quad (3.4)$$

Burada $\rho(\tilde{r})$ geri çağırmada \tilde{r} ölçülen doğruluğu ifade eder [20]. Son olarak önemli metriklerden biri de duyarlılık olarak bilinen ortalama geri çağırma değeridir [106]. Geri çağırma doğru pozitiflerin sayısının toplam gerçek değer sayısına bölünmesiyle hesaplanabilir. Denklem 3.5'te *relevant data*: gerçekten doğru ve ilgili olan veriler için kullanılırken *retrieved data* ise sistem tarafından geri çağırılarak getirilen verilerdir. Ortalama geri çağırma ilgili verinin başarıyla elde edildiği bir veri geri getirme sürecidir ve modelin görüntülerden sınıfları geri çağırma konusunda ne kadar iyi olduğunu gösterir ve Denklem 3.5'te verilmiştir.

$$AR = \frac{|\{relevantdata\} \cap \{retrieveddata\}|}{|\{retrieveddata\}|} \quad (3.5)$$

Bu çalışmada eğitilmiş ağırları değerlendirmek için referans [108] ve GitHub incelenerek Python programı kullanılmış ve modifiye edilmiş bir yapı oluşturulmuştur. DL mimarilerinin eğitim yeteneğini izlemek amacıyla, yinelemeler sırasında eğitim aşamaları gözlemlenmiştir.

Eğitim ile alakalı durma noktası sınıflandırma öğrenme oranı ve konumlandırma kayıpları gibi bazı göstergeler doğrultusunda belirlenmiştir. Şekil 3.13 eğitim süresince sistemden toplanan veriler doğrultusunda Faster R-CNN ve SSD yöntemlerine ait toplam kayıp eğrilerini göstermektedir.



Şekil 3.13. (a) Faster R-CNN, (b) SSD için toplam kayıp eğrisi.

Ayrıca sistemin değerlendirme kriterine göre performansı da ölçülmüştür. Tablo 3.1 Faster R-CNN ve SSD yöntemleri için parametreleri ve ilgili eğitim sonuçlarını vermektedir. Tablo 3.1'de verilen algoritmik sonuçlar, bu çalışma için eğitim ve test verilerini çalıştırmak üzere oluşturulan bir program sayesinde toplanmıştır. Bu program yardımcı sistemleri içermekte olup, ilk aşamada sunucudan veri alımı yapmaktadır. Hedef nesne ile ilgili bilgiler algılamaya doğrulaması için programda tutulmaktadır.

Tablo 3.1. Faster R-CNN ve SSD için eğitim sonuçları.

No.	Başlık	Faster R-CNN	SSD
1	Yığın değeri	3	6
2	İterasyon	40k	61,7k
3	Etiketleme tipi	bbox	bbox
4	Sonuç üretme zamanı	0,24s	0,22s
5	AP (IoU=[0.50:0.95], Alan= Tümü, Max Dets=100)	0,705	0,652
6	AP (IoU=0.50, Alan= Tümü, Max Dets=100)	0,994	0,955
7	AP (IoU=0.75, Alan= Tümü, Max Dets=100)	0,904	0,793
8	AR (IoU=0.50:0.95, Alan= Orta, Max Dets=100)	0,752	0,716
9	AR (IoU=0.50:0.95, Alan= Uzun, Max Dets=100)	0.792	0.766
10	Tanılama kutu hassasiyeti/mAP	0.705	0.652
11	Tanılama kutu hassasiyeti/mAP (0.50 IoU için)	0.993	0.955
12	Tanılama kutu geri çağırma/AR (large)	0.792	0.766
13	Kayıp/RPN kaybı/ konumlandırma kaybı	0.005708	Yok
14	Kayıp/RPN kaybı/obje kaybı	0.000996	Yok
15	Kayıp/konumlandırma kaybı	0.028726	0.097177
16	Kayıp/sınıflandırma kaybı	0.037269	0.204348
17	Kayıp/Total Loss	0.072699	0.355400

Tablo 3.1'de yığın boyutu bir sistemin bir iterasyon süresince işlediği girdi verisini ifade etmektedir. Eğitim sürecinde GPU olarak RTX3080ti, 16Gb GPU bulunan dizüstü bilgisayar kullanılmasına rağmen Faster R-CNN ve SSD yöntemlerinin yığın boyutları farklıdır. Çünkü Faster R-CNN için yığın boyutu altı iken birkaç adım sonrasında sistemin devam edemediği ve OOM (out of memory) hatası verdiği görülmüştür. Bu durum kullanılan YZ modeli, giriş görüntü boyutları gibi birçok etken ile de alakalıdır. Dolayısı ile Faster R-CNN yığın boyut değeri düşürülmüştür.

Düşük yığın boyutunun eksileri olabileceği gibi avantajları da vardır. Örneğin düşük yığın boyutu ile daha az bellek kullanımı daha iyi genelleme becerisi elde edilebilir. Ayrıca aşırı öğrenme problemlerine karşı destekte olabilir. Ancak düşük yığın boyutu kullanımı ile eğitim sürecinin uzaması ve gradyan güncellemelerin daha gürültülü olmasından kaynaklı model optimizasyonunun daha zor olması beklenmektedir [107].

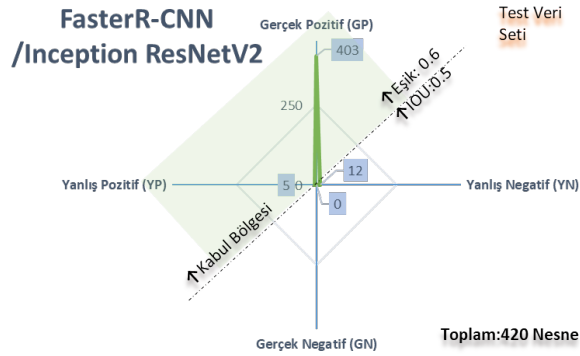
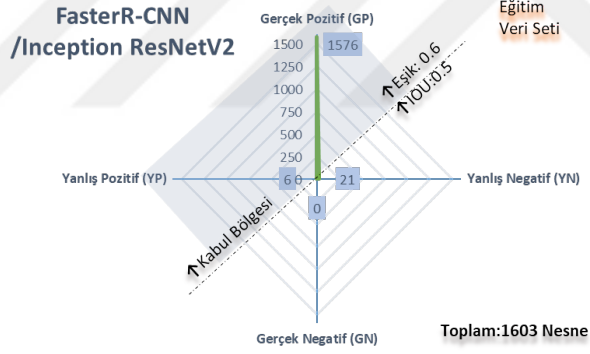
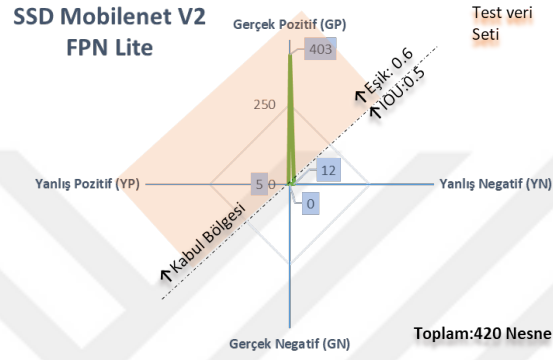
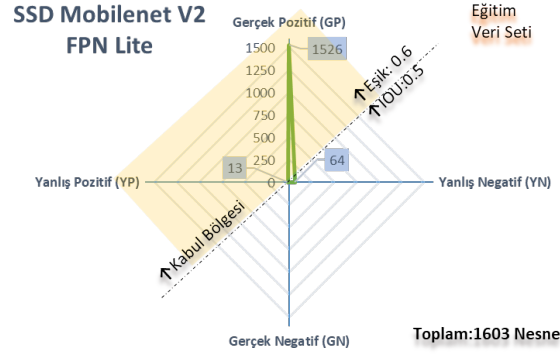
Etiketleme yöntemi olarak sınırlayıcı kutu yöntemi kullanılmıştır. Farklı IoU değerleri ve farklı alan boyutları uygulanarak mAP ve ortalama geri çağırma değerleri hesaplanmıştır [109]. AP, 0,5 ve 0,95 arasındaki IoU değerlerinde 0,5 artışlarla sınıflar üzerinde ortalama olarak hesaplanmıştır. Algoritma bir seferde en fazla 100 nesnenin

tanımlandığı maksimum tespit sayısı (MaxDets) ile tüm çerçeve için (Alan=hepsi) alanı seçmektedir.

Ayrıca, küçük (alan < 3232 piksel), orta (3232 < alan < 9696 piksel) ve büyük (alan > 9696 piksel) olmak üzere farklı piksel büyüklükleri mAP ile ilişkilidir. Son olarak ilgili yöntemlerin simülasyon sonuçları yerelleştirme, sınıflandırma, düzenleme ve toplam kayıp gibi çıktıları farklı yönleri ile birlikte sunulmaktadır.

Farklı yığın boyutları nedeniyle SSD ve Faster R-CNN için ortalama eğitim süreleri adım başına 2,84 ve 1,45 saniyedir. Şekil 3.14 kullanılan yöntemlerin eğitim ve test aşamalarındaki performanslarını göstermekte olup metrik olarak GP, GN, YP ve YN değerleri verilmiştir.

Şekil 3.14'te verildiği üzere, kullanılan yöntemlerin hem eğitim hem de test performansları görülmektedir. Tablo 3.2'de ayrıca ilgili veri kümesi üzerinde meydana gelen eğitim/test doğruluk ve hata yüzdeleri hesaplanmıştır. Ek olarak algoritmanın bir görüntü için çıktı üretmesi ve süreçte hesaplanan işlem süresi de Tablo 3.2'de verilmiştir.



Şekil 3.14. Faster R-CNN ve SSD metotları ile alakalı eğitim ve test sonuçları.

Tablo 3.2. Faster R-CNN ve SSD metotlarının yüzdelik eğitim sonuçları ve işlem süreleri.

	Eğitim Doğruluğu	Eğitim Hatası	Test Doğruluğu	Test Hatası	İşlem Zamanı
SSD Mobile Net V2 FPN Lite 640*640	95.24%	4.76%	96.04%	3.96%	0.04s
FasterR-CNN Inception ResNetV2 640*640	99.06%	0.94%	98.57%	1.43%	0.25s

Tablo 3.2’de sunulan çıktılar, [18]’de verilen ve literatürde var olan mevcut bir çalışma ile karşılaştırılmıştır. Ancak bu karşılaştırmanın tam olarak doğru bir karşılaştırma olmadığı unutulmamalıdır. Çünkü kullanılan veriler ve eğitim yöntemleri aynı koşullar altında oluşturulmamıştır. Ayrıca ilgili çalışmada hangi SSD veya Faster R-CNN mimarisinin tercih edildiği konusunda da bilgi verilmemiştir.

Referans [18]’de, hatalı üretilen piston, ana silindir ve kapak gibi fren parçalarındaki hasarların yerlerini belirlemek için SSD ve Faster R-CNN yöntemleri kullanılmıştır. İlgili çalışmada önerilen mimari kritik koşullar altında gerçek zamanlı bir sistemde test edilmemiştir. Veri tabanına dahil edilen görüntü sayısı sınırlıdır ve görüntüler el kamerası ile çekilmiştir. Bu durum ise sistemin seri üretim ortamında daha düşük çıktı üretmesine neden olabilir.

Bu çalışmada ise görüntüler gerekli izinler alınarak gerçek zamanlı seri üretim ortamından toplanmış ve sisteme özel bir kütüphane oluşturulmuş. İlgili çıktılar Tablo 3.2’de verilmiştir.

Tablo 3.3. Faster R-CNN ve SSD yöntemlerine ait eğitim ve test sonuçları [18].

	Eğitim Doğruluğu	Eğitim Hatası	Test Doğruluğu	Test Hatası	İşlem Zamanı
SSD	%95,4	%6,17	%94,16	%7,1	0.36s
Faster R-CNN	%97,1	%4,23	%95,64	%5,6	0.42s

Tablo 3.2 ve Tablo 3.3 incelendiğinde eğitim doğruluğu SSD yöntemi için %0,16 farkla verilen referansta daha yüksek olup Faster R-CNN’de ise %1,96’lık bir fark ile bu çalışmada oluşan çıktının daha iyi olduğu gözlenmiştir. Test doğruluğunda ise SSD ve Faster R-CNN için sırası ile %1,88 ve %2,93’lük farklar ile bu çalışmada elde edilen

veriler daha yüksektir. İşlem zamanı olarak SSD için 0,32 sn, Faster R-CNN için ise 0,17 sn farklar ile bu çalışmada oluşturulan çıktıların süreleri daha hızlı olmuştur. Ancak çalışmada kullanılan eğitim verileri YZ yönteminin detayları ve donanımlar bildirilmemiştir. Böylelikle ilgili çalışmada sunulan bilgiler doğrultusunda karşılaştırma yapılmıştır.

Bu kısımda oluşturulan sistem üretim süreçlerinin YZ destekli parça kontrol yöntemleri ile iyileştirilmesini amaçlanmıştır. Bu bağlamda gerçek zamanlı nesne algılama ve kontrol işlemleri yapabilen DL tabanlı bir çalışma yapılmıştır. Oluşturulan sistemin kurulumu ve performansı detaylı olarak incelenmiştir. Çalışma ile alakalı yayın IEEE Access sistemi üzerinde yayınlanmış ve referans [110]'de verilmiştir.

Geliştirilen sistem endüstriyel üretim ortamlarında parça pozisyonlarını ve varyasyonlarını dinamik olarak takip etme kabiliyetine sahiptir ve mevcut üretim hatları ile uyumlu çalışacak şekilde geliştirilmiştir. Gerçek zamanlı veri alışverişi ve yüksek hassasiyet gerektiren otomotiv sektörü gibi alanlarda bu tür kontrol sistemi ürün kalitesinin ve operasyonel verimliliğin artmasında önemli roller üstlenebilir.

4. İNSAN ROBOT İŞ BİRLİĞİ VE YAPAY ZEKÂ İLE DESTEKLENMİŞ ÜRETİM OPTİMİZASYONU

Bu bölümde insan-robot iş birliği, YZ destekli üretim sürecinden ve süreç optimizasyonundan bahsedilmiştir. Ayrıca, iş birlikçi robotların günümüzde hangi amaçlarla kullanıldığı üzerinde durulmuştur. Son olarak üretim sürecinde örnek bir görev üzerinde insan-robot iş birliği uygulaması yapılmış ve uygulama için matematiksel bir model geliştirilmiştir. Elde edilen sonuçlar yorumlanmıştır.

Teknolojinin gelişmesi üretim endüstrisinde yeni bir dönemin başlamasını sağlamıştır. Üretim süreçleri artık HRC süreçlerini aynı alanda mümkün kılan YZ destekli sistemler ile kolaylaştırmaktadır. Bu değişim üretim yapısını önemli ölçüde etkileyerek çıktılarının artmasını sağlamıştır. Ayrıca kalite standartlarının korunmasını veya daha da iyileştirilmesini sağlayarak etkin maliyetlerin de düşürülmesini başarmıştır [111], [112]. Ancak tüm bu gelişmelere rağmen iş birlikçi robotların karmaşık montaj görevlerinde kullanımı günümüz koşulları için hala iyileştirilmesi gereken bir konudur [111].

Geleneksel olarak iş birlikçi robotlar, insanlarla birlikte çalışabilme yeteneğine sahiptir. Ancak kullanım esnasında, dokunma/itme, buton basma, yön kontrolü veya klavye/fare gibi çevresel yöntemlerin uygulanması gereklidir [112], [113].

Bu tür zorluklar HRC süreçlerinde yeni gelişmelere yol açmıştır. Günümüzde iş birlikçi robotlar, YZ sistemleri ile hibrit yapıda çalışabilmektedir. İş birlikçi robotların güç, yüksek hassasiyet ve kesintisiz çalışma gibi avantajları, YZ sistemleri ve gelişmiş yeteneklere sahip insan desteği ile birleştiğinde aynı ürün daha kısa sürede ve daha düşük maliyetle üretilebilmektedir [112]. Böylece çalışma geleneksel yöntemlerin ötesinde daha verimli sürdürülebilir.

Dünya genelinde müşteri tercihlerinin sürekli olarak farklılıklar göstermesi üretim sistemlerinde esnek bir yapı gerekliliğini meydana getirmiştir. İş birlikçi robotlar hafif, kurulumlarının kolay olması, programlarının basit ve farklı görevlere kolayca uyum sağlaması gibi özellikleri nedeniyle endüstriyel alanlarda oldukça yaygın olarak kullanılır [114]. HRC süreçlerinin nihai amacı otomasyonun potansiyelini YZ ve insan

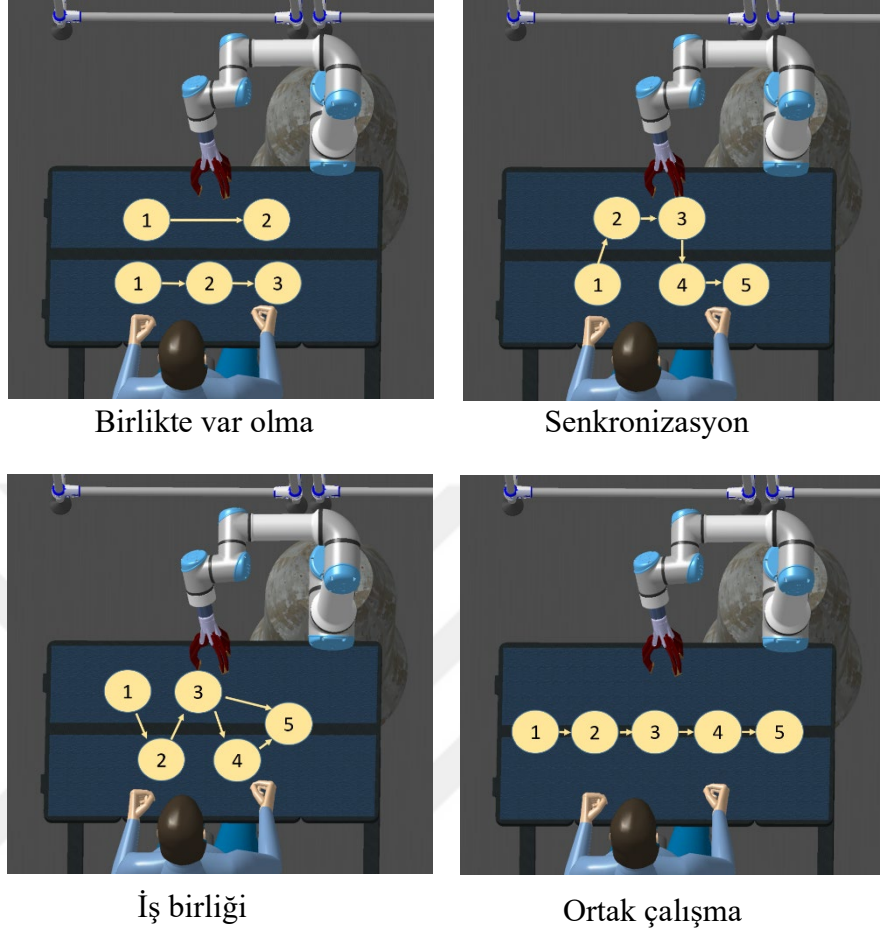
becerileri ile birleřtirerek operatörün çalışma kořullarını (ergonomi), üretim performansını ve çevresel faktörlerini iyileřtirmektedir [115].

HRC ile oluřturulan sistemlerin kullanımıyla montaj operasyonları daha sürdürülebilir ve insan odaklı bir yapıya döndürülebilir. Ayrıca iř birlikçi robotlar tehlikeli ve ergonomik olmayan görevlerde insanlara yardımcı olarak süreç ile alakalı iř durumunu iyileřtirebilir ve katma deęeri olmayan faaliyetlerin etkisini azaltabilir [115], [116]. Otomasyon üreticileri de HRC süreçlerini üretim hatlarına hızla entegre etmişlerdir [117], [118], [119], [120]. Bu sayede zaman, maliyet ve doğruluk açısından üretim gereksinimleri daha verimli hale getirilmiştir. HRC ayrıca hem insan hem de iř birlikçi robotların avantajlarını birleřtirir; süreçte iř birlikçi robotların hassasiyeti ve yorgunluęa karřı direnci ile insan operatörlerin esneklik ve uyum sağlama yeteneklerinden yarar sağlanır [121].

Ancak HRC sürecinin iyi tasarlanmış ve gerekli teknolojilerle desteklenmiş olması gerekir. Sadece iř birlikçi robot hücrelerinin yerleřtirilmesi tüm sorunları tamamen çözmeyecektir. İnsan hareketlerinin karmařıklığı göz önünde bulundurulursa süreçlerin güvenli, istikrarlı ve doğru çalışmasını sağlamak için YZ tabanlı görüntüleme teknolojileri gibi bazı tekniklerin kullanılması gereklidir [122]. İř birlikçi robotlardaki herhangi bir arıza durumunda HRC süreçlerinde güvenli olmayan operasyonlar nedeniyle hat durması veya insan yaralanmasıyla sonuçlanabilecek kazalar meydana gelebilir. Bu nedenle genel sistemin güvenliğini ve sürekliliğini sağlamak için sistemin doğru zamanda başlatılması veya gerekli durumlarda durdurulması gerekmektedir [122].

Başarılı bir sistem kurulumunda süreç gereksinimlerinin iyi anlaşılması ve çalışma ortamının iyice tanınması gereklidir. Literatür analizine göre HRC süreç yapıları için dört ortak terim belirlenmiş olup bunlar süreçlerdeki iř türleri ile ilişkilidir.

Bu kategoriler Şekil 4.1’de verildiği üzere birlikte var olma, senkronizasyon, iş birliği ve ortak çalışma olarak adlandırılmıştır [114], [123], [124], [125].



Şekil 4.1. HRC süreçlerinin iş yapılış türüne göre sınıflandırılması.

Birlikte var olma: Bu yapı operatörlerin ve iş birlikçi robotların aynı operasyonel ortamda bulunduğu ancak genellikle doğrudan fiziksel temas olmadan çalıştıkları senaryolar için geçerlidir. Birlikte var olma iş modeli için örnek senaryo Tablo 4.1’de verilmiştir.

Tablo 4.1. Birlikte var olma kategorisi için örnek çalışma senaryosu.

İşlem Adımı	İşlemi Kim Yapıyor?	İş Detayı
1	Robot	Metal parçaların kesimi
2	Robot	Parçaların Taşınması
1	İnsan	Ürün paketlemesi
2	İnsan	Manuel inceleme yapılması
3	İnsan	Son kontrol ve sevkiyat

Senkronizasyon: Bu yapıda operatörler ve iş birlikçi robotlar aynı çalışma alanını paylaşır. Ancak görevlerini eş zamanlı olarak gerçekleştirirler. Bu süreçte operasyonel uyum sağlanırken doğrudan etkileşim kısmen azaltılmış olur. Senkronizasyon iş modeli için örnek senaryo Tablo 4.2’de verilmiştir.

Tablo 4.2. Senkronizasyon kategorisi için örnek çalışma senaryosu.

İşlem Adımı	İşlemi Kim Yapıyor?	İş Detayı
1	Robot	Parçaların birleştirilmesi
2	Robot	Vida sıkma işleminin yapılması
3	Robot	Yapıştırıcı uygulanması
4	İnsan	Montajın tamamlanması
5	İnsan	Son kalite kontrollerinin yapılması

İş birliği: Bu yapı operatörlerin ve iş birlikçi robotların aynı çalışma alanında eş zamanlı olarak farklı görevler gerçekleştirdiği ancak ortak bir operasyonel amaca katkıda bulunduğu iş birliği dinamiğini barındırır. İş birliği modeli için örnek senaryo Tablo 4.3’te verilmiştir.

Tablo 4.3. İş birliği kategorisi için örnek çalışma senaryosu.

İşlem Adımı	İşlemi Kim Yapıyor?	İş Detayı
1	Robot	Büyük parçaların taşınması
2	İnsan	Küçük parçaların birleştirilmesi
3	Robot	Montajlanan parçaların bir sonraki istasyona taşınması
4	İnsan	Elektrik bağlantılarının yapılması
5	İnsan & Robot	Robot vidalama yaparken, insanın kablo bağlantılarını tamamlaması

Ortak çalışma: İnsan- iş birlikçi robot etkileşiminin zirvesi olan bu yapı, operatörler ve iş birlikçi robotların karşılıklı görevlerde aktif olarak görev aldığı sinerjik bir iş birliğini gerektirir. Bu yapıda özel sensörler ve görüntüleme sistemleri aracılığıyla hassas koordinasyon sağlanır. Yapılan bir eylem diğer eylemleri büyük ölçüde etkiler ve bu da etkili bir çalışma ortamı oluşturur. Ortak çalışma iş modeli için örnek senaryo Tablo 4.4'te verilmiştir.

Tablo 4.4. Ortak çalışma kategorisi için örnek çalışma senaryosu.

İşlem Adımı	İşlemi Kim Yapıyor?	İş Detayı
1	İnsan & Robot	Robot parçayı tutarken, insanın vidaları sıkması
2	İnsan & Robot	Robot ağır parçayı yerleştirirken, insanın montajı tamamlaması
3	İnsan & Robot	Robot parçayı döndürerek hizalarken, insanın kontrol etmesi
4	İnsan & Robot	Robot kaynak yaparken, insanın parçaları sabitlemesi
5	İnsan & Robot	Son kontroller, insan hata tespiti yaparken robotun veri topaması

Literatürde yapılan çalışmalar incelendiğinde genellikle insan hareketlerine dayalı olarak bir sonraki eylemi tahmin etme denemeleri görülmüştür. Bu amaçla sensörlerle (bazı sensörler insan üzerine monte edilmiştir) ve kinetik kameralarla canlı izleme yapılmaktadır [126]. Diğer çalışma türlerinde ise parça kontrol amaçlı herhangi bir alan belirlemeden sınırlı görüş mesafesi ile nesnelere algılanması ve işlem adımlarının tahmin edilmesi işlemlerine dayalıdır (temel olarak parça kamera görüşünün tamamını kaplamaktadır) [127].

Bu kısımda HRC süreçlerinde parça takibi için ileri düzey YZ teknikleri kullanarak her bir parça için belirgin sanal bölgeler tanımlayan kapsamlı bir yaklaşım üzerinde durulacaktır. İş adımlarının takibi ilgili parçaların belirlenen bölgelerdeki aksiyonlarına dayalı olarak belirlenmektedir. Ayrıca YZ'nin tanımlama da eksik kaldığı durumlar için sistem sürekliliğini sağlamak amacıyla SSIM yöntemi YZ mimarisi içerisine entegre edilmiştir.

Sunulan çalışmada kullanılan matematiksel model, referans [128]'deki bulguları genişleten Catia V5 kullanılarak oluşturulan örnek bir simülasyona dayanmaktadır. İş birlikçi robot operasyonları sırasında kontrol alanındaki insan hareketleri özellikle el ve baş hareketleri maksimum güvenliği sağlamak amacıyla YZ sistemi tarafından izlenmektedir. Sistem ilgili çalışma alanını sürekli olarak izler ve dinamik olarak insan

ve parça hareketlerine tepki vererek iş birlikçi robot hareketlerini yönetir. Ayrıca lojistik alanından gelen parçalar verimli bir şekilde üretim ortamındaki uygun alana yerleştirilir ve üretim sürekliliği sağlanır.

4.1. İş Birlikçi Robotların Gelişimi

İş birlikçi robotlar 2000'lerin başlarından itibaren gelişen teknoloji sayesinde endüstriyel otomasyonda önemli değişimler meydana getirmiştir. Geleneksel robotların aksine iş birlikçi robotlar ayrı bir hücreye konulmalarına gerek kalmadan güvenli bir şekilde insanlarla doğrudan etkileşim kurabilme potansiyeline sahiptirler [129].

Bu dönüşüm özellikle Universal Robots firmasının 2008 yılında UR5 modelini piyasaya sürmesiyle hız kazanmıştır [130]. UR5 güvenlik sensörleri sayesinde temas olduğu durumda otomatik olarak durabilmektedir. Ayrıca kolay program arayüzüne sahip olduğundan küçük ve orta ölçekli işletmeler için oldukça uygun maliyetli bir çözüm olarak görülmüştür. İş birlikçi robotların güvenli ve uyumlu yapısı endüstriyel alanda daha geniş kullanım imkânı bulmalarını sağlamıştır. Böylelikle ilk aşamalarda iş birlikçi robotlar özellikle tekrarlayan işlerde insan çalışanların yükünü azaltmak amaçlı kullanılmıştır [130].

2010'lu yıllara gelindiğinde iş birlikçi robot teknolojisindeki yenilikler hızla artmaya devam etmiştir. Özellikle Rethink Robotics'in geliştirdiği Baxter robotu, üretim hatlarında esneklik sağlayan düşük maliyetli bir çözüm sunmuştur. Baxter iki kolu, algılama yetenekleri ve güvenli çalışma özellikleri ile endüstriyel alanda iş gücü açığını kapatmak isteyen işletmelere yönelik alternatif bir çözüm olarak sunulmuştur [131]. 2014'ten sonra International Federation of Robotics (IFR) raporları, iş birlikçi robotların kullanımında belirgin bir artış olduğunu bildirmiştir [132]. Endüstriyel otomasyonda güvenlik protokollerinin uygulanması ve iş birlikçi robot kullanımının artması üretim süreçlerinde daha fazla esneklik ve verimlilik sağlamıştır [132].

2020 yılına gelindiğinde ise iş birlikçi robot teknolojisi YZ ve makine öğrenimiyle birleştirilmiş ve daha karmaşık görevleri yerine getirir hale gelmiştir. Örneğin Amazon Robotics ve Fanuc gibi şirketler, iş birlikçi robotları depolarda ürünlerin yerleştirilmesi, sınıflandırılması gibi işlerde kullanarak süreçleri hızlandırmış ve iş gücünü daha verimli hale getirmişlerdir. Amazon depolarında iş birlikçi robotlar insan

çalışanlarla koordineli olarak raflara parça yerleştirme ve paketleme işlerinde görev almışlardır [133].

COVID-19 pandemisi ile iş birlikçi robotların kullanımı daha da yaygınlaşmış ve sağlık sektöründe dahi yeni kullanım alanları oluşmuştur. Denso gibi şirketler hastanelerde lojistik destek ve dezenfeksiyon gibi işlemler için iş birlikçi robot çözümleri geliştirmiş ve böylece sağlık hizmetlerinin sunumunda robotlarında rol almasını sağlamıştır [133].

Bu süreçte akademik çalışmalar da iş birlikçi robot teknolojisi ile alakalı gelişim süreçlerinde önemli katkılar sağlamıştır. Örneğin Colgate ve Peshkin [129] iş birlikçi robotların temel tasarım prensipleri üzerinde çalışmış alınabilecek güvenlik önlemleri ve insan-robot etkileşimi üzerinde durmuşlardır. Krüger ve arkadaşları [134] insan ve robot iş birliğinin üretim fabrikalarındaki uygulamaları ile alakalı kapsamlı bir çalışma yapmışlardır. Çalışmada güvenlik protokolleri ve iş verimliliğini artırıcı etkenler de detaylı bir şekilde verilmiştir. Almeida ve arkadaşları [135] ise iş birlikçi robotların Endüstri 4.0 kapsamında kullanımı konusunu incelemişlerdir. Ek olarak YZ ve makine öğrenimi gibi yöntemlerin iş birlikçi robot entegrasyonu ile gelecekteki muhtemel kullanım olasılıklarını da değerlendirmişlerdir.

4.2. Problem Tanımı ve Matematiksel Model

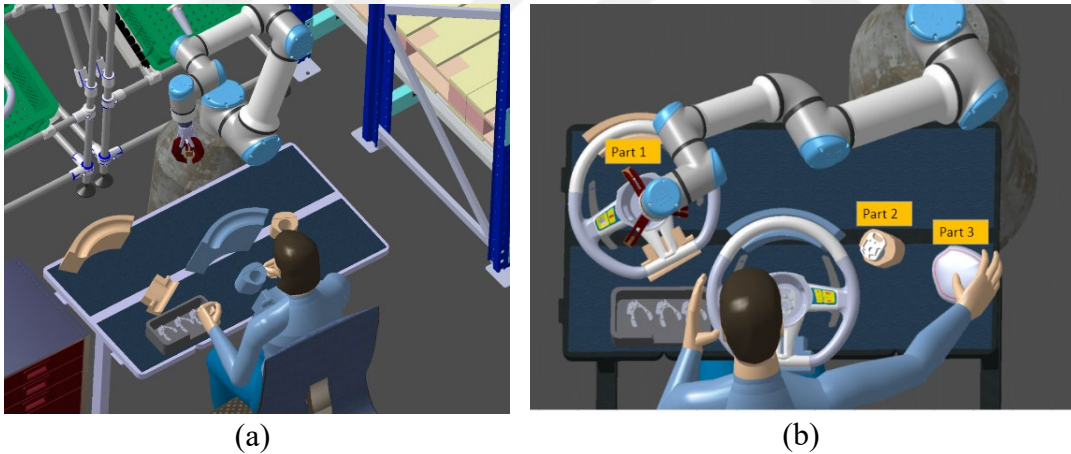
Bu kısımda iş birlikçi robot ve operatörün aynı çalışma alanında iş birliği içinde çalıştığı bir montaj süreci tasarlanmıştır. Tasarımda robot, direksiyon ve lojistik rafı [136] kaynağından alınarak modifiye edilmiştir. Matematiksel model gerçek zamanlı montaj süreçlerinden elde edilen deneyimler sonucu [128] baz alınarak elde edilmiştir. Bir montaj hattı üzerinde istasyonları (istasyon indeksi $k \in K$ ile) ve n görevden ($i \in I$) oluşan bir ürün göz önüne alınarak ardışık bir montaj ve aktarım süreci oluşturulmak istenmektedir.

Hat, insan, robotik ve iş birliği çalışmalarının (P) değişen modlarına sahip olduğu düşünüldüğünde; $p \in P = \{P_H, P_R, P_C\}$. P_H , P_R , ve P_C , sırasıyla bir görevin "insan", "iş birlikçi robot" ve "insan ve iş birlikçi robot" tarafından gerçekleştirildiğini varsayalım. Ardışık süreçlerle ($a \in I$) atanan görevler olduğu ürün içerisindeki parçaların önceden bilinen iş standart ve adımlarına göre üretildiği düşünülmektedir. Her istasyona atanacak iş birlikçi robot sayısında bir sınırlama olmalıdır. Bu nedenle istasyonlara entegre edilebilecek iş birlikçi robot sayısı q ($q < ns$) olarak

belirlenmiştir. Her görev için işlem süresi t_{ap} ve işlem alternatifleri $p \in P$ şeklinde tanımlanmıştır. İş birlikçi robotların görevleri bağımsız olarak, çalışanlarla birlikte, paralel veya aynı iş üzerinde çalışmak gibi alternatiflerle yerine getirebildiği düşünülmektedir.

Senaryoya göre bazı görevlerin hat yapısı ve ürün gereksinimleri hakkında öncelikli olması gerektiği için bu üretim süreci ardışık olarak kabul edilmektedir (E). Sonuç olarak tüm kaynaklar döngü süresini azaltmak ve çalışanlar için ergonomik bir ortam meydana getirmek gibi nihai hedeflere ulaşmak için kullanılmalıdır.


Şekil 4.2 (a) ve (b), bir iş birlikçi robot ve çalışanın yer aldığı örnek bir montaj sürecini göstermektedir. Bu örnek simülasyonda iş birlikçi robot, toplamda üç parçadan oluşan direksiyon parçalarını parça lojistik alanından alır ve masadaki ilgili kalıplara yerleştirir. YZ yöntemleri kullanılarak belirlenmiş alanda parça tespit edilmediğinde her bir parça lojistik alanından alınarak ilgili montaj bölgesine yerleştirilir. *Parça bir* direksiyon gövdesini, *parça iki* direksiyon destek parçasını ve *parça üç* hava yastığı kapağını gösterir şekilde tanımlanmıştır. Montaj işlem sırası parça iki-bir-üç şeklinde tanımlanmış ve işlem Şekil 4.2(b)'de gösterilmiştir.



Şekil 4.2. Test ve Simülasyon için oluşturulmuş direksiyon hazırlık prosesi a) Genel görünüm, b) Montaj parçaları.

Bu kısımda tek bir istasyonun ($K = 1$) ve toplam on görevin ($I = 10$) bulunduğu bir senaryo ele alınmıştır. İş birlikçi robot ve insan arasındaki iş birliği güvenli bir çalışma ortamı sağlamak için farklı veya örtüşen bölgelerde ancak aynı anda olmamak kaydıyla iş birliği yapmayı içerir. İnsan uzuvlarının, iş birlikçi robot çalışma alanına girmesi ile iş birlikçi robot geçici olarak operasyonlarını durdurur ve çalışanın onayı ile kaldığı yerden devam eder. Üretim belirli bir ardışık sırayı takip eder ve bu sıraya

protokoller rehberlik eder (örneğin üretim sırası parçalar için iki-bir-üç şeklindedir). Ayrıca bazı işler iş birliği robotların yapması için bir hayli karmaşıktır. Dolayısı ile bu işler matematiksel model içerisinde $t_{apc} = \infty$ olarak tanımlanır. Şekil 4.3 süreçle ilgili iş sırasını gösteren görev diyagramını vermektedir.



Şekil 4.3. İş adımları için oluşturulmuş görev diyagramı.

Şekil 4.4'te ise planlanan senaryo 3D olarak dijital ortamda oluşturulmuş ve tüm çalışma adımları sırası ile verilmiştir.



Şekil 4.4. Montaj ve operasyon adımlarına ait sıralı simülasyon gösterimi.

Şekil 4.4'teki adımlar şu şekilde açıklanabilir:

Adım bir: Bu adımda sistem otomatik olarak başlar. Ürün için gerekli olan üç parça sırası ile lojistik raflarından alınır ve iş birliği robot tarafından masadaki uygun montaj alanlarına yerleştirilir.

Adım iki: Operatör, parça ikiyi ilk konumundan alır ve montaj alanına yerleştirir.

Adım üç-dört: Bu adımlar eş zamanlı olarak gerçekleşir.

Adım üç: Operatör, parça biri belirlenmiş kalıbından alır.

Adım dört: İş birlikçi robot, yeni bir parça ikiyi masadaki uygun alana yerleştirir.

Adım beş: YZ, parça birin yerinde olmadığını tespit ederse, iş birlikçi robot tarafından otomatik olarak uygun alana yeni bir parça bir ürünü beslenir.

Adım altı: Montaj işlemi operatör tarafından parça iki ve parça bir kullanılarak gerçekleştirilir.

Adım yedi: Operatör, parça üçü masadaki ilgili kalıbından çıkarır.

Adım sekiz: İş birlikçi robot, yeni bir parça üçü masadaki ilgili kalıbına yerleştirir.

Adım dokuz: Operatör, parça üç için montaj işlemini gerçekleştirir.

Adım on: Üretim tamamlandıktan sonra, operatör bitmiş ürünü montaj alanından ilgili lojistik alanına veya bir depolama kutusuna yerleştirir.

Bu standart iş sırası iş birlikçi robot ve operatörlerin koordineli eylemlerini ayrıntılarıyla açıklayarak verimli bir montaj sürecini garanti altına almak üzere tasarlanmıştır.

Montaj hattının çalışma mantığı, tanımlar ve süreç simülasyonu dikkate alındıktan sonra matematiksel model üzerinde durulmuş ve kullanılan notasyonlar Referans [111] ve [128] çalışmaları baz alınarak Tablo 2'de yeni eklemeler ile verilmiştir.

Sunulan çalışmada mevcut referans çalışmalarından farklı olarak iki yeni parametre tanıtılmaktadır: Tampon (Buffer, B) ve Katma Değer Oluşturmayan İşler (Non value added time, α). B, üretim hattındaki olası kesintilere karşı hazırlıklı olmayı sağlayan önceden üretilmiş parçalardır.

Böylelikle kısmi hat duruşlarının tüm üretim sistemini etkilememesi için bir güvence görevi görür. α , ürüne doğrudan değer katmayan ancak yerine getirilmesi gereken faaliyetleri temsil eder. Bu yenilikçi eklemeler gerçek zamanlı üretim sistemi simülasyonlarının doğruluğunu önemli ölçüde artırmakta ve mevcut literatüre büyük katkı sağlamaktadır. Bu iki parametrenin dahil edilmesiyle bu çalışma üretim süreci verimliliği üzerine daha derin bir analiz sunmakta ve üretim sistemlerinde mükemmelliği hedefleyen akademik ve endüstriyel uygulamalara destek olmaktadır.

Tablo 4.5. Hat matematiksel modeli için kullanılan terimler.

İndeksler:	
a, b	Görev indeksi, $a, b \in \{1, \dots, n\}$
k	İstasyon indeksi, $k \in \{1, \dots, m\}$
r	Robot tipi indeksi, $r \in \{1, \dots, rt\}$
p	Hat alternatif indeksi, $p \in \{1, 2, \dots, rt + 1, rt + 2, \dots, 2 \cdot rt + 1\}$
I	Görev tanımlamaları $I = \{a, b = 1, \dots, n\}$
K	İstasyon tanımlamaları $K = \{k = 1, \dots, m\}$
R	İş birlikçi robot tip tanımlamaları $R = \{r = 1, \dots, rt\}$
Parametreler:	
P	Hat alternatif tanımlamaları $P = \{p = 1, 2, \dots, rt + 1, rt + 2, \dots, 2 \cdot rt + 1\}$. $p = 1$ için P_H ; $p = r + 1$ için P_R $r \in R$; $p = r + rt + 1$ için P_C , $r \in R$.
E	Doğrudan öncelik ilişkileri kümesi (a, b)
t_{ap}	Görev $a \in I$ 'nin hat alternatifi $p \in P$ ile gerçekleştirme süresi
\bar{c}	Döngü süresi üst sınırı $\bar{c} = \max\{t_{sum_max}, t_{max}\{ap_max}\}$ ve $t_{sum} = \sum_{a \in I} \max\{t_{ap} p \in P\}$ içerisinde.
q	Kullanılabilecek maksimum iş birlikçi robot miktarı
B	$B = \{1, 2, \dots, B_{max}\}$, tampon negatif bir sayı olamaz, $B \geq 0$
Kabuller ve ek parametreler:	
x_{akp}	İkili bir numara değer olarak 1, eğer görev $a \in I$ hat alternatifi $p \in P$ ile $k \in K$ istasyonuna atanmış ise
z_a	Görev $a \in I$ 'nin atandığı istasyon numarasını kodlayan sürekli değişken
s_a	Görevin $a \in I$ 'nin başladığı zamana ait sürekli değişken
α	Görev gerçekleştirilirken icra edilen katma değer oluşturmeyen işler için oluşturulmuş sürekli değişken $\alpha \geq 0$
o_r	Bir iş birlikçi robot türü $r \in R$ 'nin $k \in K$ istasyonuna atanıp atanmadığını gösteren ikili değişken
c	Döngü süresini kodlayan negatif olmayan değişken
y_{ab}	Görevin başlangıç sıralamasını gösteren ikili değişken, eğer görev $a \in I$, $b \in I$ ($s_a \leq s_b$)'den önce başlamışsa.

$$C_{min} \leq \varepsilon \text{ (mümkün en küçük proses zamanı)} \quad (4.1)$$

$$B \cdot c - [s_a + \sum_{k \in K} \sum_{p \in P} t_{ap} \cdot x_{akp}] - \alpha \leq c \quad \forall a \in I \quad (4.2)$$

$$\sum_{k \in K} \sum_{p \in P} x_{akp} = 1 \quad \forall a \in I \quad (4.3)$$

$$\sum_{r \in R} o_{kr} \leq 1 \quad \forall k \in K \quad (4.4)$$

$$\sum_{k \in K} \sum_{r \in R} o_{kr} \leq q \quad (4.5)$$

$$\sum_{k \in K} \sum_{p \in P} k \cdot x_{akp} = z_a \quad \forall a \in I \quad (4.6)$$

$$s_a + \sum_{k \in K} \sum_{p \in P} t_{ap} \cdot x_{akp} \leq s_b + \bar{c} \cdot (z_b - z_a) \quad \forall (a, b) \in E, \text{ for } B = 0, \alpha = 0 \quad (4.7)$$

$$x_{ak,r+1} + x_{ak,r+rt+1} \leq o_{kr} \quad \forall a \in I, k \in K, r \in R \quad (4.8)$$

$$\begin{aligned} & [s_a + \sum_{p \in P_H, P_C} t_{ap} \cdot x_{akp}] \leq s_b + \bar{c} \cdot (K - \sum_{p \in P_H, P_C} x_{akp} - \sum_{p \in P_H} x_{bkp} - y_{ab}) \quad \forall a, b \in I, k \in K, \text{ for } B = 0, \alpha = 0 \end{aligned} \quad (4.9)$$

$$\begin{aligned} & s_a + \sum_{p \in P_R, P_C} t_{ap} \cdot x_{akp} \leq s_b + \bar{c} \cdot (K - \sum_{p \in P} x_{akp} - \sum_{p \in P_C} x_{akp} - y_{ab}) \quad \forall a, b \in I, k \in K, \text{ for } B = 0, \alpha = 0 \end{aligned} \quad (4.10)$$

$$\begin{aligned}
s_a + \sum_{p \in P} t_{ap} \cdot x_{akp} &\leq s_b + \bar{c} \cdot (K - \sum_{p \in P} x_{akp}) & (4.11) \\
- \sum_{p \in P_C} x_{akp} - y_{ab}) &\quad \forall a, b \in I, k \in K, \text{ for } B \\
&= 0, \alpha = 0
\end{aligned}$$

$$y_{ab} + y_{ba} = 1 \quad \forall a, b \in I, a < b \quad (4.12)$$

$$x_{akp} = \{0,1\} \quad \forall a \in I, k \in K, p \in P \quad (4.13)$$

$$o_{kr} = \{0,1\} \quad \forall k \in K, r \in R \quad (4.14)$$

$$y_{ab} = \{0,1\} \quad \forall a, b \in I, a < b \quad (4.15)$$

$$s_a, z_b \geq 0 \quad \forall a \in I \quad (4.16)$$

Bu kısımda öncelikli hedef, hattın döngü süresini mümkün en düşük proses zamanı değerine düşürmektir. Bu hedef *Denklem 4.1*'de verilmiştir.

Denklem 4.2, atanan tüm görevlerin s_a zamanında başlaması ve tanımlanan döngü zamanında bitirilmesi gerektiğini belirtir. Birden fazla işletim istasyonunun veya transferlerin bulunduğu ortamlarda bitmiş ürünlerin bulunduğu B bölgeleri (parça transfer yolları) mevcut olabilir. Bu B bölgeleri hatlar arasındaki dengeyi sağlar. Seri üretim sistemlerinde bir istasyon durduğunda, B bölgesindeki ürünler ilgili sistemin B değeri sıfır olana kadar çalışmaya devam etmesini sağlar. Böylelikle kısmi duruş sağlanan hatta, duruş nedeninin giderilmesine olanak oluşurken genel üretim sayıları da etkilememiş olur.

Denklem 4.3 her görevin uygun işleme atanmasını garanti eden eşitliktir.

Denklem 4.4 iş birlikçi robot varlığı ile alakalı olup iş birlikçi robotun mevcut olduğunu bir ile, mevcut olmadığını ise sıfır ile sembolize eder.

Denklem 4.5 toplam iş birlikçi robot sayısının maksimum izin verilen sayıyı aşmadığını garanti etmek amaçlı oluşturulmuştur.

Denklem 4.6 görevlerin ilgili istasyonlara atanıp atanmadığını doğrular.

Denklem 4.7 standart iş adımlarının sıralı olduğunu kontrol eder. Böylece bir önceki süreç tamamlanmadan sonraki süreç başlayamaz.

Denklem 4.8 her istasyonda yalnızca bir iş birlikçi robot atanabileceğini tanımlar.

Denklem 4.9'dan Denklem 4.11'e kadar olan eşitlikler, belirli süreç alternatifleri için gerekli kaynakların var olup olmadığını garanti eder. Bir görev sonraki görev için seçilen süreç alternatiflerinden kaynak gerektiriyorsa sonraki görev önceki görev tamamlanmadan devam edemez. Bu kısıtlamalar manuel, robotik ve iş birlikçi operasyonların kullanımını sırasıyla sınırlar.

Denklem 4.12 aynı istasyondaki görevlerin sırasını ifade eder.

Denklem 4.13-4.16 çeşitli sistem bileşenlerinin varlığı veya yokluğunu ele alır.


Bir karşılaştırma tablosu operatör iş akışları ile iş birlikçi robot entegreli iş akışları arasındaki farkları vurgulamıştır. Aynı görev bir insan tarafından veya bir insan ve iş birlikçi robot ile veya tamamen iş birlikçi robot tarafından yerine getirilmiş olup bu işlemlerin süreleri Tablo 4.6'da karşılaştırmalı olarak verilmiştir. Bazı görevlerin karmaşıklığı nedeniyle belirli işlemler sadece iş birlikçi robot tarafından gerçekleşmemiş, alternatif operasyon türlerine ihtiyaç duyulmuştur. İş birlikçi robot işlemlerinde iş birlikçi robotun tüm parçaları prosese beslemesi gerekliliği ile alakalı ek bir adım oluşturulmuştur (yaklaşık 15 saniye). Bu adım bir defalık olmasından kaynaklı operasyon döngü zamanının hesaplamasına dahil edilmemiştir.

Tablo 4.6. Alternatiflerin verildiği hat zaman tablosu.

Görev a	Proses Zamanı(s)		
	t_{aH}	t_{aR}	t_{aC}
0_{Prep}	0	15	-
1	24	0	-
2	4	4	-
3	5	3	-
4	5	5	-
5	5	3	-
6	26	∞	13
7	5	3	-
8	5	3	-
9	8	∞	6
10	7	7	6

Tabloda t_{aH} , t_{aR} ve t_{aC} a görevinin insan, robot, insan-robot iş birliği ile yapıldığında geçen süreleri temsil etmektedir. Eğer YZ sistemi iş alanında parçaların eksik olduğunu tespit ederse iş birlikçi robot aktive olur ve parçalar ilgili alana beslenerek yerleştirilir. Bu durum iş birlikçi robotların dahil olduğu döngü süreçlerinde parça beslemelerinin beklenme gerekliliğini ortadan kaldırır.

Buna karşın sadece insan ile yürütülen prosesler için operatör, parçaların her döngünün sonunda yeniden lojistik alanından alınması ve montaj alanına yerleştirilmesinden sorumlu olacak ve bu işlem yaklaşık 24 saniye sürecektir. Farklı modda çalışmalar için ölçülen süreler Şekil 4.5’te verilmiştir.



Şekil 4.5. Farklı görev modları ile alakalı döngü süreleri.

Böylelikle araç direksiyonu üretmek üzere örnek olarak tasarlanmış bir montaj süreci, sadece insan, insan ve iş birlikçi robot birlikte ve iş birliği içinde çalışma olmak üzere üç farklı iş yapısı/modu kullanılarak Şekil 4.5’te simüle edilmiştir.

Matematiksel fonksiyonlar [111] ve [128]’de özetlenen metodolojilerin genişletilmesiyle türetilmiş ve bu çalışma bağlamında geliştirilerek yeniden incelenmiştir. Sonuçlar sadece insan ve iş birliği yapılan süreçler arasında 48 saniyelik anlamlı bir fark olduğunu ortaya koymuştur. İş birliği sürecinin kullanıldığı yapılardaki montaj yöntemlerinin sağladığı önemli etkinlik ve verimlilik kazançları da vurgulanmıştır.

4.3. İnsan Robot İş Birliğinde Kullanılan Yöntemler

Bu kısım insan ve iş birlikçi robot arasında güvenli ve verimli iş birliği kurmak için geliştirilen görüntü işleme teknikleri ile alakalı incelemeleri içermektedir. Oluşturulan yaklaşımın temeli önceden tanımlanmış sanal bölgelerdeki nesnelere izlemek ve takip etmek için CNN tabanlı YZ yöntemlerinin kullanımına dayanmaktadır. İşlem sırası bu sanal sınırlar içindeki nesnelere tespiti veya yokluğuna göre dinamik olarak takip edilir. Ayrıca YZ performansının düşük olmasından kaynaklı sorunları veya yeni parçaların eklenmesi süreçlerinde yaşanan problemleri ele almak için YZ algoritmasından bilgi alabilen ek bir yazılım geliştirilmiştir.

Otomobil direksiyon montajının bileşenlerini tanılamak için CNN tabanlı nesne algılama teknikleri kullanılmıştır. Çeşitli nesne tespit yöntemlerini araştıran birçok

çalışma mevcuttur. Örneğin bir çalışmada, pasif terahertz (THz) görüntülerinde güvenliği artırmak için ResNet-50 tabanlı modifiye edilmiş bir SSD algoritması kullanılmış ve doğruluk %95,04'ten %99,92'ye yükseltilmiştir. Faster-RCNN, YOLO ve diğer metodolojilerle yapılan karşılaştırmalar da çalışma içerisinde verilmiştir [137].


Günümüzde çeşitli uygulamalar için birçok DL tabanlı tespit modeli mevcuttur. Ayrıca Eğitim amaçlı veri oluşturmak için model gereksinimlerine göre özel programlar kullanılmaktadır (Labelmg [138], Labelme [139] vb.). Bu modellerin bazıları ile detaylı inceleme Bölüm bir içerisinde verilmiştir.

DL ağı mimarisinin eğitimi için genellikle TensorFlow Versiyon 2 için TensorFlow model Zoo [140] veya YOLO v7 [141] gibi önceden eğitilmiş modeller kullanılmaktadır. Model belirtilen gereksinimleri karşılayana kadar eğitim yapılmalıdır. Eğitim tamamlandıktan sonra eğitim sonuçlarını içeren bir dosya oluşturulmakta ve programı içerisinde kullanılmak üzere hazırlanmaktadır.

ADIM I: Derin öğrenme modelinin eğitilmesi



ADIM II: Derin öğrenme modelinin çalıştırılması



Şekil 4.6. YZ eğitim ve operasyon süreçleri hakkında örnek akış diyagramı.

Bu aşamada geleneksel YZ yöntemlerinin yanı sıra yeni bir algoritma operasyonel programa entegre edilmiş ve bu yazılım genel sistem içerisinde ek bir kontrol istasyonu olarak kurgulanmıştır. DL süreci Şekil 4.6'da gösterildiği üzere birden fazla aşama ve katmanlardan oluşmaktadır. Ayrıca eğitim süreci kullanılan donanım ve verilere bağlı olarak değişiklik gösterir.

Oluşturulan merkezi sistem bir parçayı istenen düzeyde tespit edemediğinde veya sistemde eğitilmeyen yeni bir parça test döngüsüne dahil edildiğinde sistem sürekliliğini sağlamak bir hayli zor olabilir. Bu sorunları gidermek amacıyla Şekil

4.7'de sunulduğu üzere SSIM yöntemi merkezi sisteme entegre edilmiştir. SSIM iki görüntü arasındaki benzerliği ölçmek için kullanılan bir yöntemdir. Daha eski yöntemler olan Tepe Sinyal-Gürültü Oranı (PSNR) ve Ortalama Kareysel Hata (MSE) [142] yöntemlerine göre avantajları bulunmaktadır. Bahsedilen eski yöntemler hesaplama, doğrudan hata miktarlarını gösterme ve optimizasyon açılarından basittirler. Ancak, insan gözünün algıladığı gerçek görüntü kalitesini tam olarak yansıtamazlar. SSIM yönteminde ise her bir görüntünün parlaklık, kontrast ve yapı gibi üç yönlü parametrelerini dikkate almaktadır [143].

Gelinen aşamada Şekil 4.6'da gösterilen merkezi sistem Şekil 4.7'de gösterildiği gibi modifiye edilerek değiştirilmiştir. Birinci tespit algoritması (Merkezi model) her döngüde giriş görüntüsünü işler ve önceden tanımlanmış kriterlere göre çıktılar sağlar. Kriterler programcı tarafından belirlenir ve puan veya sınıf kimliği gibi metriklere dayalı olabilir. Merkezi modelin istenen kriterleri karşılamadığı durumlarda o anki giriş görüntüsü, SSIM programı olarak bilinen (İkinci tespit algoritması) paralel bir algoritmaya aktarılır.

Bu algoritma merkezi sistemden bağımsız olarak çalışmaktadır. Buna bağlı olarak birinci tespit algoritması genellikle giriş görüntüsü aktarıldıktan sonra bir sonraki görüntüyü işlemektedir. Eşzamanlı olarak SSIM programı merkezi sistem tarafından hedef olarak gönderilen giriş görüntüsünü (I_t) incelemekte ve programcı tarafından tanımlanan referans görüntülerle (I_r) eşleştirerek karşılaştırma yapmaktadır.

Hedef görüntüye en çok benzeyen görüntü ve buna karşılık gelen değerler isteğe bağlı olarak kayıt altına alınmakta veya kullanıcıya gösterilmektedir. Dolayısıyla merkezi tespit algoritması ilgili nesneyi istenen kriterler ile tespit edemez ise SSIM programı aktive olarak nesneyi eşleştirmeye çalışır. Böylelikle SSIM programı tarafından kullanılan referans görüntüler istenildiği zaman kullanıcı tarafından dinamik ve hızlı bir şekilde güncellenebilir. Bilindiği üzere YZ modellerini yeniden eğitmek ve sonuçlar elde etmek zaman alıcı olabilmekte ve önemli ölçüde donanım ve hesaplama kaynakları gerektirebilmektedir.

SSIM yönteminin program adımları aşağıda özetlenmiştir:

1- Görüntü işlemleri,

Yükleme,

Boyutlandırma,

Gri tonlama dönüşümü

2- En benzer görüntüyü bulma,

$$SSIM(I_t, I_r) = \frac{(2\mu_{I_t}\mu_{I_r} + c_1)(2\sigma_{I_t I_r} + c_2)}{(\mu_{I_t}^2 + \mu_{I_r}^2 + c_1)(\sigma_{I_t}^2 + \sigma_{I_r}^2 + c_2)} \quad (4.17)$$

Denklem 4.17'de verilen terimler aşağıdaki gibidir:

I_t ve I_r hedef ve referans görüntüleri gösterir,

μ_{I_t} ve μ_{I_r} , I_t ve I_r 'nin ortalama parlaklık değerleridir,

$\sigma_{I_t}^2$ ve $\sigma_{I_r}^2$, I_t ve I_r 'nin varyanslarıdır,

$\sigma_{I_t I_r}$ I_t ve I_r 'nin kovaryansıdır,

c_1 ve c_2 sıfıra bölme hatalarını önlemek için kullanılan sabitlerdir.


3- İlgili XML dosyasından tanımlanan sınırlayıcı kutu koordinatlarının çıkarılması.

4- Hedef ve referans görüntüler arasındaki SSIM değerlerinin hesaplanması.

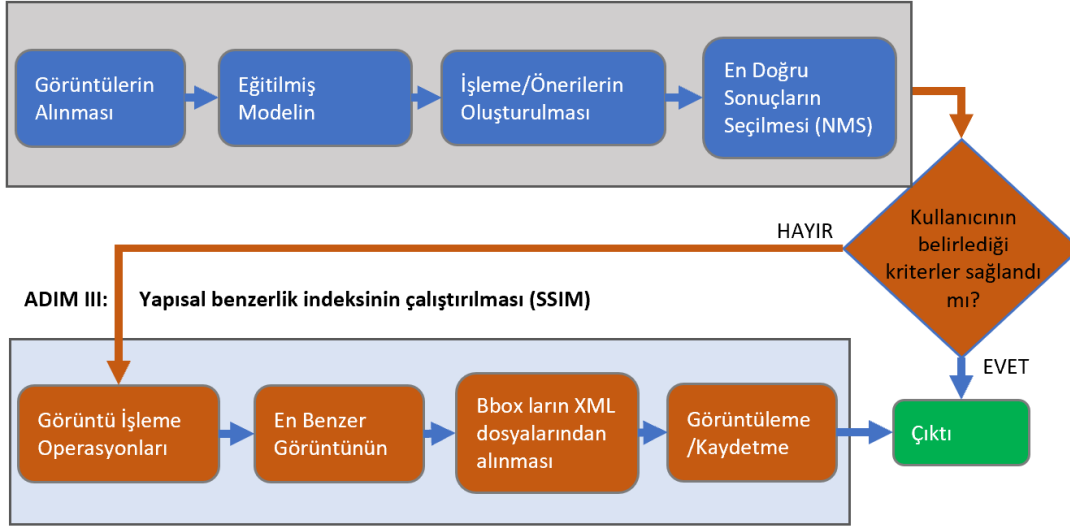
5- SSIM benzerlik çıktı değerinin mevcut maksimum değeri aşması durumunda, halihazırdaki en benzer görünümün güncellenmesi.

Önerilen tespit algoritmasının nihai durumu SSIM yönteminin merkezi tespit algoritmasına dahil edildiği yeni hali ile Şekil 4.7'de verilmiştir.


ADIM I: Derin öğrenme modelinin eğitilmesi



ADIM II: Derin öğrenme modelinin çalıştırılması



ADIM III: Yapısal benzerlik indeksinin çalıştırılması (SSIM)



Şekil 4.7. SSIM yöntemi bütünleştirilerek geliştirilmiş YZ eğitim ve operasyon süreçleri hakkında örnek akış diyagramı.

Tablo 4.7. Özel veri kümesi üzerinde SSIM performansının değerlendirilmesi.

Hedef Görüntüler	Referans Görüntüler	Doğruluk (%)	Görüntü Boyutu	İşlem Süresi
114	323	99.123	600x600x3	0.048s


Tablo 4.7’de özel bir otomotiv üretim fabrikasından alınan gerçek zamanlı veriler kullanılmış ve SSIM yöntemi ile alakalı performans değerlendirmesi yapılmıştır. SSIM yöntemi ile oluşturulan programın bir görüntü üzerindeki işlem süresi 48 ms (mili saniye) olarak ölçülmüştür.

SSIM yöntemi ayrıca referans [144] ve [145] ile verilen halka açık veri kümeleri üzerinde de test edilmiş ancak sonuçlar bir hayli düşük olarak ölçülmüştür. Bu düşük sonuçların başlıca nedenleri ilgili referansta veri tabanını oluşturan araçların renklerinin aynı olması ve bazı görüntülerin arka planlarının beyaz veya benzer renkte olmasıdır [144].

Referans [145] içerisinde ise bazı görüntülerin arka planlarının kaldırıldığı görüntü renginin koyulaştırıldığı veya ana nesnenin görüntü içerisinde büyük bir kısmını kapsamadığı tespit edilmiştir. Buna karşılık özel veri setlerinde birkaç faktörün olumlu etkisi ile iyi sonuçlar elde edilmiştir. Bu faktörler arasında parçalar arasındaki belirgin farklar olması hedeflenen test ve eğitim görüntülerinin benzerliği ve geliştirilen bölge tabanlı yazılım ile parçaların yakından incelenebilmesi yer almaktadır.

Dinamik kütüphanesi ve yüksek hızı nedeniyle SSIM programı sorunlu çıktılarının olduğu sistemleri desteklemek için değerli bir araç olabilir. Ancak yukarıda bahsedildiği üzere SSIM yönteminin çalışma mantığına özgü bazı sınırlamalar vardır. Görüntülerin büyük oranda benzer olması ayrıştırmayı zorlaştırır ve yukarıda sunulan örneklerde de görüldüğü üzere tatmin edici sonuçlar vermeyebilir.

Bir tespit sistemi kurmak operasyonların gerçek zamanlı izlenmesini ve verimli bir şekilde yönetilmesini kolaylaştırır. Ancak tüm süreci denetlemek için tasarlanmış tek bir kamera aynı anda lojistik bileşenler kalıplardaki veya gelecekteki üretim parçaları ve şu anda işlenen parçalar da dahil olmak üzere karmaşık bir operasyonu tespit ettiğinden tüm görevleri etkili bir şekilde yönetemez. Bu sınırlama sistemin işlevselliğini engelleyebilir. Bu sorunu çözmek için tezde kameranın görüş alanı içinde sanal bölgeler tanımlayan yenilikçi bir çözüm uygulanmıştır. Örnek sanal bölgeler çalışma üzerinde oluşturulmuş ve Şekil 4.8'de verilmiştir.



Şekil 4.8. Bölgesel bazlı kontrol sisteminin direksiyon hazırlık masa örneği ile gösterimi.

Bölge bir direksiyon simidi gövdesine, bölge iki direksiyon simidi destek parçasına ve bölge üç ise hava yastığı kapağına özel olacak şekilde oluşturulmuştur. Oluşturulan yazılım, yeni gereksinimlere uyum sağlamak için bu bölgelerin kolayca değiştirilmesine olanak tanımaktadır.

Gelinen aşamaya kadar nesne tanılama üzerinde durulmuş ve parça kamera görüş alanı içerisinde olduğunda sistemin parçayı tanıması ve uygun şekilde operasyonu yönetmesi için çalışılmıştır. Sadece tanılama yönteminde parçanın kamera görüş alanı içerisinde olması yeterlidir. Ancak tüm prosesin bir kamera ile yönetilmeye çalışıldığı sistemler için parçanın kamera görüş alanı içerisinde olması o parçanın uygun bölge veya dışında olduğu bilgisini içermez. Bu problemin çözümü için bölge bazlı parça tanılama yöntemi geliştirilmiş ve parçanın sistem tarafından mevcut sayılabilmesi için parçanın tanımlanan bölge içerisinde olma şartı koyulmuştur.

Böylelikle sadece belirlenen bölge veya bölgelerde ilgili parça algılanmadığı durumlar için, iş birlikçi robot parça besleme amaçlı etkinleştirilir. Ayrıca işlem sırasında belirlenen bölge içerisinde herhangi bir insan uzvu veya istenmeyen nesne algılandığında iş birlikçi robot isteğe bağlı olarak geçici bir süre duraklatılabilir. Gelişmiş güvenlik için sürekli durdurma ve buton onaylı hareket seçeneği de

düşünülebilir. Bunun yanı sıra iş birlikçi robot operasyonları sırasında hiçbir operatörün bulunmadığını teyit etmek amacıyla iş birlikçi robot alanı olarak adlandırılan ek bir bölge de oluşturulabilir. Bu sayede yüksek-yavaş hızlı modlar oluşturulup iş birliğine dayalı ortamın güvenliği ve verimliliği artırılabilir.

Bu bölümde operatör ve iş birlikçi robotların aynı alanda birlikte çalışmasını sağlayan YZ destekli bir parça destek süreci incelenmiştir. YZ sisteminin eğitim ve operasyon aşamaları gözden geçirilmiştir. Ardından sorunlu çıktıları ele alarak sistem sürekliliğini sağlamak için SSIM yöntemi geleneksel YZ yöntemlerine entegre edilmiştir. Bu modüler ek, herhangi bir sisteme uyum sağlayabilir yapıda geliştirilmiştir. Süreç adımları matematiksel fonksiyonlarla tanımlanmış ve geleneksel proje yönetimi değiştirilerek sorunlu süreçlerde sürekli üretim desteklenmiştir. Ayrıca tek bir kameranın tüm süreci izlemesine ve tüm görevleri etkili bir şekilde yönetmesine olanak tanıyan bölge tabanlı kontrol mantığı geliştirilmiş ve başarılı bir şekilde simüle edilmiştir.

Umut verici sonuçlara rağmen bu çalışmanın daha fazla araştırma gerektiren birkaç sınırlaması vardır. İlk olarak simülasyonlar ve vaka çalışmaları kontrol edilen ortamlarda gerçekleştirilmiştir. Bu durum da gerçek dünya üretim ortamlarının karmaşığını ve değişkenliğini tam olarak yansıtmayabilir. Gelecekteki araştırmalar önerilen HRC modelinin sağlamlığını ve uyarlanabilirliğini doğrulamak için çeşitli ve dinamik endüstriyel ortamlarda uygulanmasına odaklanmalıdır.

İkinci olarak bölge tabanlı izleme sistemi yüksek doğruluk göstermiş olsa da performansı aydınlatma koşullarındaki değişiklikler ve çalışma alanındaki engellemelerden etkilenebilir. Bu tür çevresel faktörlere karşı sistemin dayanıklılığını artırmak için daha fazla araştırma ve pratik yapılması gerekmektedir.

Son olarak mevcut çalışma ağırlıklı olarak HRC modelinin teknik ve operasyonel yönlerini ele almaktadır. Gelecek çalışmalar iş gücü eğitimi üzerindeki etkisi, çalışanların kabulü ve üretimde iş birliğine dayalı robotların yaygın benimsenmesinin daha geniş ekonomik etkileri gibi sosyo-teknik sonuçları da göz önünde bulundurulabilir.

Sonuç olarak bu çalışma üretim verimliliği ve insan-robot iş birliğine önemli katkılar sağlamaktadır. Kapsamlı ve yenilikçi bir yaklaşım sunarak daha verimli, güvenli ve sürdürülebilir üretim ortamları oluşturmak için gelecekteki araştırmalar ve pratik

uygulamalar için bir temel oluşturmaktadır. Bu çalışmadan elde edilen bulgular, hızla gelişen üretim teknolojisi ve tedarik zinciri alanında daha fazla ilerleme ve uygulamaya ilham verebilir.





5. TARTIŞMA VE SONUÇ

Günümüzde YZ yöntemleri, birçok alanda uygulanmış ve başarılı sonuçlar elde edilmiştir. Tez çalışmasının ilk aşmasında gerçek zamanlı bir veri artırma modeli önerilmiştir. Seri üretim ortamında modelin dayanıklılığını sağlamak, özellikle değişken nesne açılarında tutarlı sistem performansını korumak için hayati öneme sahiptir. TensorFlow gibi standart kütüphaneler gerçek zamanlı veri çoğaltma araçları sağlamış olsa da nesnelere değişken açılarda işleyebilme yetenekleri sınırlıdır. Bu çalışmada ilgili sorunu çözmek için TensorFlow geliştirme çatısına entegre edilmiş yeni bir veri artırma yöntemi geliştirilmiştir. Bu özel algoritma, eğitim sürecinde kullanıcı tanımlı açı ve boyutlarda dinamik döndürme işlemlerine olanak tanımakta ve sistemin değişken koşullar altında hareketli parçaları doğru şekilde tespit ederek işleme kapasitesini artırmaktadır. Önerilen algoritma esnekliği artırmakla birlikte uzun vadeli disk alanı kullanımını minimize ederek insan kaynaklı etiketleme hatalarını da azaltmaktadır. Yeni gerçek zamanlı veri artırma yöntemi literatürde kullanılan varsayılan yöntemle göre %2,6'lık doğruluk artışı sağlamıştır.

Tezin ikinci aşaması otomotiv sektöründe üretim süreçleri boyunca gerçekleşen parça kontrol operasyonlarının YZ tabanlı çözümler ile iyileştirilmesine yönelik kapsamlı bir yaklaşım sunulmaktadır. DL yöntemleri kullanılarak geliştirilen bu sistem örnek olarak seçilen binek araç motor parçalarının yüksek hassasiyet ve doğrulukla gerçek zamanlı olarak endüstri ortamında kontrol edilmesini amaçlamaktadır.

Çalışmada, insan veya klasik görüntü işleme yöntemleri ile yapılan kalite kontrollerinin üretim süreçlerindeki zorluklarından bahsedilmiştir. Bu tür klasik kontrol yöntemleri parça varyasyonları, değişken ışık yoğunluğu ve uzun çalışma saatleri gibi durumlar karşısında performans kayıpları yaşamaktadır. Bu çalışmada bahsedilen problemlerin üstesinden gelmek ve otomotiv sektöründe hatasız üretim hedefine katkı sağlamak için YZ tabanlı bir sistem önerilmiştir.

Çalışmada motor parçaları nesne tanıma yöntemleri kullanılarak yukarıdan aşağı şekilde monte edilen bir iş birlikçi robot ile kontrol edilmiştir. İşbirlikçi robotun ters şekilde asılması bu çalışma özelinde hat gerekliliğinden kaynaklı olmakla birlikte

birçok sorunu beraberinde getirmiştir. Sistemin gerçek ortamda çalışabilmesi için detaylı 3D analizlerinin tekrarlı ve hassas bir biçimde yapılması gerekmiştir. Bu nedenle planlama aşaması beklenenden daha uzun sürmüştür. Süreç analizleri ve gerilim testleri Catia v5 ortamında gerçekleştirilmiştir. Ayrıca sistem gerekli parça üretimi ve tedarik süreçleri ile üretim hattına başarıyla entegre edilmiştir. Süreçte oluşan çıktılar periyodik olarak takip edilerek yaşanan problemler için gerekli iyileştirme ve düzenlemeler yapılmaktadır.

Önerilen kontrol sistemi kapsamında var olan motor parçaları beş ana sınıf içerisinde kategorize edilmiştir. Bu kategoriler normal yüzey üzerindeki renk, parlak yüzey üzerindeki renk, etiket üzerindeki harf, parça yüzeyi üzerindeki harf ve parlak yüzey üzerindeki harf şeklindedir. Sistemin nesne tespiti amacı ile kullandığı SSD ve Faster R-CNN yöntemleri, belirli kurallar çerçevesinde devreye girmektedir. İlk olarak SSD devrede olup gerekli kontrolleri yapmaktadır. Diğer yandan, gerçek zamanlı dinamik veriler yerel ve sunucu konumlarına, iş birliği robotun ve motor pozisyonunun önceden belirlenen adımlarına göre kaydedilmektedir. Kayıt işlemi, ilgili adıma göre varsayılan olarak beş adet görüntü içermekte olup her motor için ortalama istasyon sayısı ise on üç olarak belirlenmiştir. SSD algoritmasının parçayı istenen hassasiyet veya kriterlerde algılamaması durumunda, döngü süresini sağlamak için sistem bir sonraki adıma doğru ilerlemektedir. Bu durumda problemler için Faster R-CNN arka planda aktive olmakta ve kaydedilen görüntüler üzerinden nesneyi tespit etmeye çalışmaktadır. Çalışmada iki farklı DL yönteminin hibrit olarak aynı sistemde kullanılması ile döngü süresi ve yüksek doğruluk arasında bir denge oluşturulması amaçlanmıştır. SSD için görüntü başına 0,04 saniye ve Faster R-CNN için 0,25 saniyelik işlem süresi, oluşturulan yapının seri üretim hattında gerekli döngü süresi içinde çalışmasını sağlamaktadır. Bu hız ve doğruluk dengesi üretim gecikmelerini önlerken yüksek kalite standartlarını da korumak için kritik rol üstlenir. Ayrıca parçanın hangi yöntem tarafından tespit edildiği geçmiş kayıtlarına işlenmekte olup istatistik amaçlı genel ekranda yansıtılmaktadır.

Sistem eğitim süreçlerinde öğrenme oranları, sınıflandırma kayıpları ve yerelleştirme kaybı gibi metrikleri dinamik olarak takip edilmiş ve eğitimin başarı ile tamamlanması sağlanmıştır. %50 IoU altında algılama kutularının mAP sonuçları 0,993 ve 0,955 olup eğitim aşamasının toplam kayıp fonksiyon değerleri ise Faster R-CNN ve SSD yöntemleri için sırasıyla 0,0726 ve 0,355'tir.

Elde edilen sonuçlar DL tekniklerinin üretim süreçlerindeki uygulanabilirliğini ve bu alandaki potansiyel faydalarını somut bir şekilde ortaya koymaktadır. Özellikle SSD ve Faster R-CNN algoritmalarının aynı sistem içerisinde hibrit olarak çalıştırılması ile geliştirilen kontrol mekanizmasının, parçaların doğru tespit edilmesi ve kusurların belirlenmesi amaçlı %99,9 oranında doğruluk oranlarına ulaştığı gözlemlenmiştir. Sürdürülebilir çıktılar üretim hattında insan müdahalesi ihtiyacını minimuma indirerek sürecin daha verimli ve güvenilir olmasını sağlamaktadır.

Tezin son aşamasında üretim hattında iş birlikçi robot kullanımı ile entegre edilen ve klasik robot kullanılan proseslere kıyasla daha esnek bir yapı sunan bir uygulama yapılmıştır. İş birlikçi robotun ilgili parçaları farklı açılardan besleyebilmesi ve insan ile iş birliği içinde çalışabilmesi üretim hattındaki diğer sistemlerle beraber kısıtlı alanda çalışmasına olanak tanımaktadır. Çalışma içerisinde iş birlikçi robot kullanımına dair bir simülasyon yapılmış ve özgün bir matematiksel model elde edilmiştir. Literatürde bulunan çalışmalar incelenmiş ve gerçek ortamdan elde edilen deneyimler sonucunda B ve α ile alakalı parametreler literatüre ve matematiksel modele yenilik olarak eklenmiştir.

Çalışmada ayrıca YZ çıktılarının yetersiz olduğu durumlar için SSIM üzerinden sistemin devamlılığını sağlayabilecek bir yazılım YZ mimarisine eklenmiştir. Böylelikle tekrarlı ve basit hataların olması durumunda ilgili problem kalıcı olarak giderilinceye kadar SSIM yazılımı ile sistemin devamlılığı sağlanmaktadır. Sistem kalite kontrol süreçlerinde insan müdahalesini azaltarak otomotiv üretim tesislerinde iş gücü, genel verimlilik ve maliyet tasarrufu sağlamaktadır. Bu bağlamda otomotiv üreticileri açısından etkin maliyetlerin düşürülmesi verimlilik hedeflerinin yakalanması ve üretimin standart hale getirilmesi noktasında önemli bir katkı sunmaktadır.

Çalışmada lisans koşulları nedeniyle bazı DL yöntemleri kullanılmamıştır. Gelecek çalışmalar için ilgili lisans anlaşmaları yapılarak kullanım sağlanabilir. Böylelikle sistem performansı geliştirilerek zaman, hassasiyet ve çalışma yapısı konularında ilerleme sağlanabilir. Ayrıca sistem için oluşturulan arayüz birden çok kullanıcının aynı anda uzaktan erişebileceği şekilde yapılandırılabilir. Böylelikle aynı anda bağlanan kullanıcılar farklı işlemleri yapabilme imkanına sahip olabilir. Sistemin uygulama alanının yeteri kadar geniş olması durumunda, çalışma içerisinde de bahsedilen ve ilk aşamada bu çalışma içinde bir seçenek olarak düşünülen iki iş birlikçi

robot ile parça kontrolü seçeneğinin gerçekleştirilmesi düşünülebilir. Bu durum çalışmayı donanım adedi olarak artıracak olmasına rağmen genel sistemin kurulum ve test süreçlerinde kolaylıklar sağlayacaktır. Kontrol süresi ile alakalı problemlerin yazılım tarafından ayrı olacak şekilde büyük oranda giderilmesini de mümkün hale getirmektedir.

Sonuç olarak, bu çalışma, otomotiv sektöründe kalite kontrol süreçleri için DL tabanlı çözümlerin etkin bir şekilde uygulanabileceğini ve DL teknolojilerinin bu süreçlerde yüksek doğruluk ve güvenilirlik sağladığını ortaya koymaktadır. Çalışmada geliştirilen yöntemler, dinamik üretim hatlarında klasik yöntemlerin sınırlılıklarını aşarak YZ modelinin ilgili motor parçalarını tespit etmesini sağlamıştır. İş birlikçi robot ile entegre edilen sistem, yalnızca otomotiv sektöründe değil, farklı sanayi alanlarında da kalite kontrol süreçlerine yönelik örnek bir model oluşturmaktadır.

KAYNAKLAR

- [1] K.O'Shea, R.Nash. An Introduction to Convolutional Neural Networks, Neural and Evolutionary Computing (cs.NE); Computer Vision and Pattern Recognition (cs.CV); Machine Learning (cs.LG), <https://doi.org/10.48550/arXiv.1511.08458>.
- [2] Sepp Hochreiter, Jürgen Schmidhuber, Longshort-term memory, *Neural Comput.*9(8) (1997)1735–1780.
- [3] AlexSherstinsky, Fundamental soft recurrent neural network (RNN) & long short term memory (LSTM) network ,2018 arxiv:1808.03314,39 pages,10figures,66references.
- [4] I. Goodfellow, J. Pouget-Abadie, M. Mirza, B. Xu, D. Warde-Farley, S. Ozair, A. Courville, and Y. Bengio, "Generative adversarial nets," in *Proc. Advances Neural Information Processing Systems Conf.*, 2014, pp. 2672–2680.
- [5] Bianchini, M., Frasconi, P., and Gori, M. (1995), "Learning without local minima in radial basis function networks," *IEEE Transactions on Neural Networks*, vol. 6, no. 3, pp. 749-756.
- [6] Zhao Z.Q., Object Detection with Deep Learning: A Review, *IEEE Transactions on Neural Networks and Learning Systems*, VOL. 30, No. 11, November 2019 201, DOI: 10.1109/TNNLS.2018.2876865.
- [7] M.J. Er, J. Chen, Y. Zhang, W. Gao, Research Challenges, Recent Advances, and Popular Datasets in Deep Learning-Based Underwater Marine Object Detection: A Review, *Sensors* 2023, 23(4), 1990; <https://doi.org/10.3390/s23041990>.
- [8] S.Y. Alaba, Deep Learning-Based Image 3-D Object Detection for Autonomous Driving: Review, *IEEE Sensors Journal*, Vol. 23, No. 4, 15 February 2023, DOI: 10.1109/JSEN.2023.3235830.
- [9] K.Rana, G.Gupta, P.Vaidya, M.Khari, The Perception systems used in fully automated vehicles: a comparative analysis, April 2023, *Multimedia Tools and Applications*, DOI:10.1007/s11042-023-15090-w.
- [10] İnternet-<https://www.statista.com/statistics/262747/worldwide-automobile-production-since-2000/> - Accessed date: 08/07/2024.
- [11] İnternet-<https://www.aa.com.tr/tr/gundem/tuik-2023-yili-kara-yolu-trafik-kaza-istatistiklerini-acikladi/3221194#:~:text=Bu%20say%C4%B1n%C4%B1n%201%20milyon%2079,350%20bin%20855%20ki%C5%9Fi%20yaraland%C4%B1> Accessed date:08.07.2024.

- [12] Internet-<https://www.inlandempirelawyers.com/blog/what-to-do-when-brakes-fail-cause-an-accident#:~:text=Brake%20Failure%20Statistics%20%2D%20The%20National,fail%2C%20it%20is%20absolutely%20possible> Accessed date: 08.07.2024.
- [13] Liu, W., Anguelov, D., Erhan, D., Szegedy, C., Reed, S., Fu, C. Y., & Berg, A. C. (2016, October). SSD: Single shot multibox detector. In European conference on computer vision (pp. 21-37). Springer, Cha.
- [14] J.Yang, S.Li, Z.Wang, G.Yang, Real-Time Tiny Part Defect Detection System in Manufacturing Using Deep Learning. IEEE, 2019 DOI: 10.1109/ACCESS.2019.2925561.
- [15] J. Redmon and A. Farhadi, “YOLOv3: An incremental improvement,” arXiv, arXiv:1804.02767, Apr. 2018. [Online]. Available: <https://arxiv.org/abs/1804.02767>.
- [16] S. Ren, K. He, R. Girshick, and J. Sun, “Faster R-CNN: Towards real-time object detection with region proposal networks,” in Proc. Adv. Neural Inf. Process. Syst., 2015, pp. 91–99.
- [17] Y. Gong, X. Yu, Y. Ding, X. Peng, J. Zhao, Zhenjun. H. Effective fusion factor in FPN for tiny object detection, Computer vision foundation (CVF), WACV 2021.
- [18] Rajan S., Rameswari R., Gunasekaran S., Automotive Brake Part Inspection and fault Localization using Deep Learning, ICMML, 1059 (2021) 012062 doi: 10.1088/1757-899X/1059/1/012062.
- [19] Internet- <https://www.kaggle.com/datasets/awsaf49/coco-2017-dataset>, Accessed date: 16/07/2024.
- [20] A. S. Olesen, B. B. Georgaly, E. A. Ryberg, M. R. Thomsen, and D. Chrysostomou, “A collaborative robot cell for random bin-picking based on deep learning policies and a multi-gripper switching strategy,” *Procedia Manufacturing*, vol. 51, pp. 3–10, 2020. [Online]. Available: <https://doi.org/10.1016/j.promfg.2020.10.002>.
- [21] Hridoy, M. W., Rahman, M. M., & Sakib, S. (2024). A framework for industrial inspection system using deep learning. *Annals of Data Science*, 11(2), 445-478.
- [22] Mohandas, R., Southern, M., O’Connell, E., & Hayes, M. (2024). A Survey of incremental deep learning for defect detection in manufacturing. *Big Data and Cognitive Computing*, 8(1), 7.
- [23] Lee, J. S., Kim, T. H., Jeon, S. H., Park, S. H., Kim, S. H., Lee, E. H., & Lee, J. H. (2024). Automation of trimming die design inspection by zigzag process between AI and CAD domains. *Engineering Applications of Artificial Intelligence*, 127, 107283.
- [24] Zubayer, M. H., Zhang, C., Liu, W., Wang, Y., & Imdadul, H. M. (2024). Automatic Defect Detection of Jet Engine Turbine and Compressor Blade Surface Coatings Using a Deep Learning-Based Algorithm. *Coatings*, 14(4), 501.

- [25] Mendez, E., Ochoa, O., Olivera-Guzman, D., Soto-Herrera, V. H., Luna-Sánchez, J. A., Lucas-Dophe, C., & González, A. (2024). Integration of Deep Learning and Collaborative Robot for Assembly Tasks. *Applied Sciences*, 14(2), 839.
- [26] Liao, Y.Y.; Ryu, K. Status Recognition Using Pre-Trained YOLOv5 for Sustainable Human-Robot Collaboration (HRC) System in Mold Assembly. *Sustainability* 2021, 13, 12044.
- [27] Zhang, J.; Liu, H.; Chang, Q.; Wang, L.; Gao, R.X. Recurrent Neural Network for Motion Trajectory Prediction in Human-Robot Collaborative Assembly. *CIRP Ann.* 2020, 69, 9–12.
- [28] A.Pal, A.C.Leite, P.J.From, A novel end-to-end vision-based architecture for agricultural human–robot collaboration in fruit picking operations, *Elsevier, Robotics and Autonomous Systems* 172 (2024) 104567.
- [29] J.Male, U.M.Hernandez, 2023, Deep learning based robot cognitive architecture for collaborative assembly tasks, *Elsevier, Robotics and computer-integrated manufacturing, Robotics and Computer-Integrated Manufacturing* 83 (2023) 102572.
- [30] Polonara, M., Romagnoli, A., Biancini, G., & Carbonari, L. (2024). Introduction of Collaborative Robotics in the Production of Automotive Parts: A Case Study. *Machines*, 12(3), 196.
- [31] Keshvarparast, A., Battini, D., Battaia, O., & Pirayesh, A. (2024). Collaborative robots in manufacturing and assembly systems: literature review and future research agenda. *Journal of Intelligent Manufacturing*, 35(5), 2065-2118.
- [32] J.Kufel, K.B.Laczek, S.Kocot, M.Kozlik, W.Barnikowska, M.Janik, L.Czogalik, P.Dudek, M.Magiera, A.Lis, I.Paszkievicz, Z.Nawrat, M.Cebula, K.Gruszczynska, What is machine learning, *Artificial Neural Networks and Deep learning? – Examples of practical applications in medicine, MDPI, Diagnostics* 2023.
- [33] Dorfman, E. How Much Data Is Required for Machine Learning? *Postindustria*. Available online: <https://postindustria.com/how-much-data-is-required-for-machine-learning/> (accessed on 7 May 2023).
- [34] Patel, H. Data-Centric Approach vs. Model-Centric Approach in Machine Learning. *MLOps Blog* 2023. Available online: <https://neptune.ai/blog/data-centric-vs-model-centric-machine-learning> (accessed on 1 May 2023).
- [35] O.Inik, E.Ulker, Derin Öğrenme ve Görüntü Analizinde Kullanılan Derin Öğrenme Modelleri, *Gaziosmanpaşa Bilimsel Araştırma Dergisi (GBAD)*, ISSN: 2146-8168. Volume: 6, Year 2017.
- [36] Y. LeCun, Y.Bengio, G.Hinton, Deep Learning, *Nature/Review*, Doi:10.1038/nature14539, 436, Vol:521, 2015.
- [37] Krizhevsky, A., Sutskever, I. & Hinton, G. ImageNet classification with deep convolutional neural networks. In *Proc. Advances in Neural Information Processing Systems* 25 1090–1098 (2012).

- [38] Farabet, C., Couprie, C., Najman, L. & LeCun, Y. Learning hierarchical features for sceneing. *IEEE Trans. Pattern Anal. Mach. Intell.* 35, 1915–1929 (2013).
- [39] Tompson, J., Jain, A., LeCun, Y. & Bregler, C. Joint training of a convolutional network and a graphical model for human pose estimation. In *Proc. Advances in Neural Information Processing Systems* 27 1799–1807 (2014).
- [40] Szegedy, C. et al. Going deeper with convolutions. Preprint at <http://arxiv.org/abs/1409.4842> (2014).
- [41] Mikolov, T., Deoras, A., Povey, D., Burget, L. & Cernocky, J. Strategies for training large scale neural network language models. In *Proc. Automatic Speech Recognition and Understanding* 196–201 (2011).
- [42] Hinton, G. et al. Deep neural networks for acoustic modeling in speech recognition. *IEEE Signal Processing Magazine* 29, 82–97 (2012).
- [43] Sainath, T., Mohamed, A.-R., Kingsbury, B. & Ramabhadran, B. Deep convolutional neural networks for Processing 8614–8618 (2013).
- [44] Ma, J., Sheridan, R. P., Liaw, A., Dahl, G. E. & Svetnik, V. Deep neural nets as a method for quantitative structure-activity relationships. *J. Chem. Inf. Model.* 55, 263–274 (2015).
- [45] Ciodaro, T., Deva, D., de Seixas, J. & Damazio, D. Online particle detection with neural networks based on topological calorimetry information. *J. Phys. Conf. Series* 368, 012030 (2012).
- [46] Kaggle. Higgs boson machine learning challenge. Kaggle <https://www.kaggle.com/c/higgs-boson> (2014).
- [47] Helmstaedter, M. et al. Connectomic reconstruction of the inner plexiform layer in the mouse retina. *Nature* 500, 168–174 (2013).
- [48] Leung, M. K., Xiong, H. Y., Lee, L. J. & Frey, B. J. Deep learning of the tissue-regulated splicing code. *Bioinformatics* 30, i121–i129 (2014).
- [49] Xiong, H. Y. et al. The human splicing code reveals new insights into the genetic determinants of disease. *Science* 347, 6218 (2015).
- [50] Internet- <https://cloud.google.com/tpu>, Accessed date: 07/08/2024.
- [51] Internet-<https://www.amd.com/en/products/adaptive-socs-and-fpgas/fpga/virtex-ultrascale-plus-vu19p.html>, Accessed date: 07/08/2024.
- [52] LeCun Y., B.Yoshua, G.Hinton, Deep Learning Review/Nature, doi:10.1038/nature14539.
- [53] Girshick, R., Donahue, J., Darrell, T., & Malik, J. (2014). Rich feature hierarchies for accurate object detection and semantic segmentation. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 580-587).
- [54] Girshick, R. (2015). Fast r-cnn. In *Proceedings of the IEEE international conference on computer vision* (pp. 1440-1448).
- [55] Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016). You only look once: Unified, real-time object detection. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 779-788).

- [56] Li M., Pi D. Quin S., An efficient single shot detector with weight-based feature fusion for small object detection, *Scientific reports, Nature*, <https://doi.org/10.1038/s41598-023-36972-x> (2023), 13:9883.
- [57] Kim, J., Sung, J.-Y., & Park, S. (2020). Comparison of Faster-RCNN, YOLO, and SSD for Real-Time Vehicle Type Recognition. 2020 IEEE International Conference on Consumer Electronics - Asia (ICCE-Asia). doi:10.1109/icce-asia49877.2020.9277040.
- [58] A. Hossain, M. Ali, Recognition of Handwritten Digit using Convolutional Neural Network (CNN) DOI: 10.34257/GJCSTDVOL19IS2PG27, <https://www.researchgate.net/publication/333191386>.
- [59] A Step-by-Step Introduction to the Basic Object Detection Algorithms (Part 1), Accessed: 20/11/2021. [Online]. Available: <https://www.analyticsvidhya.com/blog/2018/10/a-step-by-step-introduction-to-the-basic-object-detection-algorithms-part-1/>.
- [60] K. He, X. Zhang, S. Ren, and J. Sun. Spatial pyramid pooling in deep convolutional networks for visual recognition. In ECCV. 2014.
- [61] Deepa R., Tamilselvan E., Abrar E.S., Shrinivas, S. Comparison of Yolo, SSD, Faster RCNN for Real Time Tennis Ball Tracking for Action, Deepar@bitsathy.ac.in, 978-1-7281-3250-1/19/ ©2019 IEEE.
- [62] Sermanet, P., Eigen, D., Zhang, X., Mathieu, M., Fergus, R., LeCun, Y.: Overfeat: integrated recognition, localization and detection using convolutional networks. In: ICLR (2014).
- [63] Erhan, D., Szegedy, C., Toshev, A., Anguelov, D.: Scalable object detection using deep neural networks. In: CVPR (2014).
- [64] Szegedy, C., Reed, S., Erhan, D., Anguelov, D.: Scalable, high-quality object detection. arXiv preprint v3 (2015). arXiv:1412.1441.
- [65] [Internet-https://www.gnu.org/licenses/gpl-faq.tr.html?form=MG0AV3#v3MakingAvailable](https://www.gnu.org/licenses/gpl-faq.tr.html?form=MG0AV3#v3MakingAvailable), Accessed Date: 09/02/2025.
- [66] Trotta, A., Ziosi, M., & Lomonaco, V. (2023). The future of ethics in AI: Challenges and opportunities. *AI & Society*, 38, 439-441. <https://doi.org/10.1007/s00146-023-01644-x>.
- [67] Gomes Rêgo de Almeida, P., dos Santos, C. D., & Silva Farias, J. (2021). Artificial Intelligence regulation: A framework for governance. *Ethics and Information Technology*, 23, 505-525. <https://doi.org/10.1007/s10676-021-09593-z>.
- [68] [Internet- https://www.image-net.org/challenges/LSVRC/](https://www.image-net.org/challenges/LSVRC/) , Accessed date: 27/10/2024.
- [69] Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). ImageNet classification with deep convolutional neural networks. *Advances in neural information processing systems*, 25.
- [70] Simonyan, K., & Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition. arXiv preprint arXiv:1409.1556.

- [71] Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., & Rabinovich, A. (2015). Going deeper with convolutions. Proceedings of the IEEE conference on computer vision and pattern recognition, 1-9.
- [72] He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. Proceedings of the IEEE conference on computer vision and pattern recognition, 770-778.
- [73] He, K., Gkioxari, G., Dollár, P., & Girshick, R. (2017). Mask R-CNN. Proceedings of the IEEE international conference on computer vision, 2961-2969.
- [74] Dosovitskiy, A., Beyer, L., Kolesnikov, A., Weissenborn, D., Zhai, X., Unterthiner, T., & Houlsby, N. (2020). An image is worth 16x16 words: Transformers for image recognition at scale. arXiv preprint arXiv:2010.11929.
- [75] Yuan, L., Chen, Y., Chen, X., Codella, N., Dai, X., Gao, J., Gong, B., Guo, M., Guo, Y., He, J., Li, J., Liu, L., Liu, M., Lu, M., Qiao, R., Wang, J., Wang, S., Zhang, L., Zhang, Y., Zhang, Z., Zhang, Z., Zhai, X., Chen, D., Houlsby, N., & Dai, A. (2021). Florence: A New Foundation Model for Computer Vision. arXiv preprint arXiv:2111.11432.
- [76] M.Yuwei, L.Wenyi, Improve Generalization Ability of CNN by Data Augmentation and SE Block in Landmark Classification. 2022 IEEE 14th International Conference on Computer Research and Development.
- [77] A.M. Taki, A.Awad, F.A.Azzo, M.Milanova, The Impact of Multi-optimizers and Data Augmentation on TensorFlow Convolutional Neural Network Performance. 2018 IEEE Conference on Multimedia Information Processing and Retrieval.
- [78] Gao Youwen, Zhou Benjun, Hu Xiaoxiao. Research on convolutional neural network image recognition based on data enhancement [J]. Computer Technology and Development, 2018, (8):62-65. DOI: 10.3969/j.issn.1673-629X.2018.08.
- [79] Abadi et al., "TensorFlow: Large-scale machine learning on heterogeneous systems," arXiv preprint arXiv:1603.04467, 2015. [Online]. Available: <https://doi.org/10.48550/arXiv.1603.04467>.
- [80] Internet-
https://github.com/tensorflow/models/tree/master/research/object_detection,
Accessed date: 10.11.2023.
- [81] C.A.Barajas, M.K.Gobbert, J.Wang, Performance Benchmarking of Data Augmentation and Deep Learning for Tornado Prediction. 2019 IEEE International Conference on Big Data (Big Data).
- [82] P. Delestrac, L. Torres and D. Novo, "Demystifying the TensorFlow Eager Execution of Deep Learning Inference on a CPU-GPU Tandem," 2022 25th Euromicro Conference on Digital System Design (DSD), Maspalomas, Spain, 2022, pp. 446-455, doi: 10.1109/DSD57027.2022.00066.
- [83] Hangün, B., & Eyecioğlu, Ö. (2017). Performance comparison between OpenCV built-in CPU and GPU functions on image processing operations. *International Journal of Engineering Science and Application*, 1(2), 1-6.

- [84] Internet- <https://medium.com/towards-data-science/opencv-gpu-usage-disappoints-bc331329932d>, Accessed date: 09.02.2025.
- [85] Internet- <https://www.tensorflow.org/guide/basics>, Accessed date: 09.02.2025.
- [86] M. Qasaimeh, K. Denolf, J. Lo, K. Vissers, J. Zambreno and P. H. Jones, "Comparing Energy Efficiency of CPU, GPU and FPGA Implementations for Vision Kernels," *2019 IEEE International Conference on Embedded Software and Systems (ICCESS)*, Las Vegas, NV, USA, 2019, pp. 1-8, doi: 10.1109/ICCESS.2019.8782524.
- [87] K. K. Liang, Efficient conversion from rotating matrix to rotation axis and angle by extending Rodrigues, 2018, <https://arxiv.org/abs/1810.02999>.
- [88] Internet-<https://www.youtube.com/watch?v=0yhUo3mmIUY->, Accessed date: 17.11.2023.
- [89] Internet-
https://github.com/tensorflow/models/tree/master/research/object_detection,
Accessed date: 10.11.2023.
- [90] H.Rezatofghi, N.Tsoi, J.Y.Gwak, A.Sadeghian, Generalized Intersection Over Union And A Loss For Bounding Box Regression, CVPR, IEEE Xplore,2019, Page:658-666.
- [91] O.Ardic, G.Cetinel, Exploring the Newly Introduced Data Augmentation Technique in TensorFlow Library, IEEE Signal Processing and Communications Applications (SIU), 2024, IEEE, DOI: 10.1109/SIU61531.2024.10601037.
- [92] Internet- <https://www.youtube.com/watch?v=Y8ABLV7NZOM>, Time: 6:20 / 9:20 Accessed date: 02/09/2024.
- [93] Internet- <https://cdn.motor1.com/images/mgl/8ApW6o/s3/2023-toyota-corolla-hybrid-engine.webp>, Accessed date: 02/09/2024.
- [94] Internet- <https://www.cobottrends.com/cobot-comparison-tool/> Accessed date: 19/07/2024.
- [95] E-Manual-internet-
<https://www.fanuc.eu/~media/files/pdf/products/robots/robots-datasheets-en/collaborative%20robots/ds-cr15ia-en.pdf?la=en>, Accessed date: 19/07/2024.
- [96] E-Manual-internet-
http://dl.mitsubishielectric.com/dl/fa/document/manual/school_text/sh081124eng/sh081124enga.pdf, Accessed date 20/07/2024.
- [97] Manual- Fanuc Robot CR15ia mechanical unit operator's manual. Volume B-84054EN/01, Page 23.
- [98] ISO 10218-1:2011. Robots and robotic devices -- Safety requirements for industrial robots -- Part 1: Robots.
- [99] ISO 10218-2:2011. Robots and robotic devices -- Safety requirements for industrial robots -- Part 2: Robot systems and integration.
- [100] ISO/TS 15066:2016. Robots and robotic devices – Collaborative robots.

- [101] J.Valente, J. Antonio, C.Mora, S.Jardim, Developments in Imge Processing Using Deep Learning and Reinforcement Learning, Journal of Imaging, MDPI, <https://doi.org/10.3390/jimaging9100207>.
- [102] C.Silvano, D.Ielmini, F.Ferrandi, L.Fiorin, S.Curzel, L.Benini, F.Conti A.Garofalo, C.Zambelli, E.Calore, S.F.Schifano, M.Palesi, Giuseppe Ascia, D.Patti, N.Petra, D.De Caro, L.Lavagno, T.Urso, V.Cardellini, G.C.Cardarilli, R.Birke, S.Perri, A Survey on Deep Learning Hardware Accelerators for Heterogeneous HPC Platforms, arXiv:2306.15552v2 [cs.AR] 12 Jul 2024.
- [103] Smith, J., et al. "Design and Analysis of Collaborative Robot Frames Using Carbon Fiber Composites." IEEE Transactions on Robotics, vol. 36, no. 8, 2023, pp. 1234-1246.
- [104] Wang, Z., Liu, H. "Optimized Structural Design for Collaborative Robots Using Finite Element Analysis." Springer Journal of Manufacturing Science and Engineering, vol. 45, no. 4, 2022, pp. 1109-1118.
- [105] M. Everingham, L. Van Gool, C. K. Williams, J. Winn, A. Zisserman, The pascal visual object classes (VOC) challenge, Int. Journal of computer vision 88 (2) (2010) 303–338 (2010).
- [106] İnternet-https://en.wikipedia.org/wiki/Precision_and_recall#Recall, Accessed date: 06/10/2022.
- [107] Oyebade K. Oyedotun and Konstantinos Papadopoulos and Djamila Aouada, A New Perspective for Understanding Generalization Gap of Deep Neural Networks Trained with Large Batch Sizes, <https://arxiv.org/abs/2210.12184>
- [108] İnternet-https://www.tensorflow.org/guide/keras/training_with_built_in_methods, Accessed date: 10/10/2022.
- [109] A. NAEEM, M. S. FAROOQ, A. KHELIFI, and A. ABID, Malignant Melanoma Classification Using Deep Learning: Datasets, Performance Measurements, Challenges and Opportunities, date of publication June 10, 2020, Digital Object Identifier 10.1109/ACCESS.2020.3001507.
- [110] O. Ardic, G. Cetinel, "Deep Learning Based Real-Time Engine Part Inspection with Collaborative Robot Application (August 2024)," *IEEE Access*, DOI: 10.1109/ACCESS.2024.3489714.
- [111] Sikora, C.G.S., Weckenborg, C., 2023. Balancing of assembly lines with collaborative robots: Comparing approaches of the benders' decomposition algorithm. Int. J. Prod. Res. 61 (15), 5117–5133. <http://dx.doi.org/10.1080/00207543.2022.2093684>.
- [112] Z.Gao, R.Yang, K.Zhao, W.Yu, Z.Liu and L.Liu, Hybrid Convolutional Neural Network Approaches for Recognizing Collaborative Actions in Human–Robot Assembly Tasks, MDPI, Sustainability 2024, 16, 139.<https://doi.org/10.3390/su16010139>.
- [113] ISO, I., (2011). 10218–2: 2011: Robots and Robotic Devices–Safety Requirements for Industrial Robots–Part 2: Robot Systems and Integration, vol. 3, International Organization for Standardization, Geneva, Switzerland.

- [114] Matheson, E.; Minto, R.; Zampieri, EGG; Faccio, M.; Rosati, G. Human-Robot Collaboration in Manufacturing Applications: A Review. *Robotics* 2019, 8, 100.
- [115] Gualtieri, L.; Rauch, E.; Vidoni, R. Human-Robot Activity Allocation Algorithm for the Redesign of Manual Assembly Systems into Human-Robot Collaborative Assembly. *Int. J. Comput. Integr. Manuf.* 2023, 36, 308–333.
- [116] Liu, L., Guo, F., Zou, Z., Duffy, V.G., 2022. Application, development and future opportunities of collaborative robots (cobots) in manufacturing: a literature review. *Int. J. Hum.–Comput. Interact.* 1–18. <http://dx.doi.org/10.1080/10447318.2022.2041907>.
- [117] Internet- Brigl, S., 2017. BMW group harnesses potential of innovative automation and flexible assistance systems in production. <https://www.press.bmwgroup.com/middle-east/article/detail/T0269645EN>. Accessed date: 24/03/2024).
- [118] Internet- Volvo, 2018. How can robot and human collaborate in the best way?<https://www.volvogroup.com/en/news-and-media/news/2018/oct/robot-human-collaborate.html>. Accessed date: 24/03/2024.
- [119] Internet- Volkswagen, 2019. High-tech in production. <https://events.universal-robots.com/online-events/hq-vw-tech-days-2021-cobots-virtual-event-202106/>. Accessed date: 24/03/2024.
- [120] Internet- BlueWeave, 2022. Collaborative Robots Market- Global Industry Size, Share, Trend Analysis and Forecast Report. Technical Report, BlueWeave, <https://www.blueweaveconsulting.com/report/collaborative-robots-market>. Accessed date: 26/03/2024.
- [121] Ferreira, C., Figueira, G., Amorim, P., 2021. Scheduling human-robot teams in collaborative working cells. *Int. J. Prod. Econ.* 235, 108094. <http://dx.doi.org/10.1016/j.ijpe.2021.108094>.
- [122] Villani, V.; Pini, F.; Leali, F.; Secchi, C. Survey on Human–Robot Collaboration in Industrial Settings: Safety, Intuitive Interfaces and Applications. *Mechatronics* 2018, 55, 248–266.
- [123] Wang, L.; Gao, R.; Váncza, J.; Krüger, J.; Wang, X.V.; Makris, S.; Chrysolouris, G. Symbiotic human-robot collaborative assembly. *CIRP Ann.* 2019, 68, 701–726.
- [124] Müller, R.; Vette, M.; Mailahn, O. Process-oriented task assignment for assembly processes with human-robot interaction. *Procedia CIRP* 2016, 44, 210–215.
- [125] Krüger, J.; Lien, T.K.; Verl, A. Cooperation of human and machines in assembly lines. *CIRP Ann.* 2009, 58, 628–646.
- [126] J.Male, U.M.Hernandez, 2023, Deep learning based robot cognitive architecture for collaborative assembly tasks, Elsevier, *Robotics and computer-integrated manufacturing, Robotics and Computer-Integrated Manufacturing* 83 (2023) 102572.

- [127] Liao, Y.Y.; Ryu, K. Status Recognition Using Pre-Trained YOLOv5 for Sustainable Human-Robot Collaboration (HRC) System in Mold Assembly. *Sustainability* 2021, 13, 12044.
- [128] Z.Mao, Y.Sun, K.Fang, D.Huang, J.Zhang, Model and metaheuristic for human-robot collaboration assembly line worker assignment and balancing problem, *ELSEVIER, Computer and Operations Research* 165 (2024) 106605, <https://doi.org/10.1016/j.cor.2024.106605>.
- [129] Colgate, J. Edward, ve Michael Peshkin. "The Design and Control of a Cobot." *IEEE Transactions on Robotics and Automation*, vol. 17, no. 4, pp. 347-359, 2001. IEEE Xplore.
- [130] Internet- Universal Robots. "UR5 Model Collaborative Robot." *Robots Done Right*, 2008. [Online]. Accessed date: 25/10/2024, Available: <https://robotsdoneright.com/Universal/Universal-UR5.html>.
- [131] Internet- Rethink Robotics, "Baxter: A Collaborative Robot for Manufacturing," 2012. [Online]. Accessed: 25/10/2024. Available: <https://robotsguide.com/robots/baxter>.
- [132] Internet- International Federation of Robotics (IFR), "World Robotics Report," 2016. [Online]. Accessed: 25/10/2024. Available: <https://ifr.org/>.
- [133] Internet- Amazon Robotics, "Robotic Solutions for Fulfillment Centers," 2019. [Online]. Accessed: 25/10/2024. Available: <https://amazon.jobs/en/teams/amazon-robotics>.
- [134] Krüger, J., Lien, T., & Verl, A. "Cooperation of Human and Machines in Assembly Lines." *CIRP Annals - Manufacturing Technology*, vol. 58, no. 2, pp. 628-646, 2009.
- [135] Almeida, F., et al. (2018). Human-robot collaboration in Industry 4.0: Applications and future trends. *Procedia Computer Science*, 138, 342-349.
- [136] Internet- https://grabcad.com/library/software/catia?page=1&per_page=100&time=all_time&sort=recent Accessed date: 26/05/2024.
- [137] L.Cheng, Y.Ji, C.Li, X. Liu, G.Fang, Improved SSD network for fast concealed object detection and recognition in passive terahertz security images, *Scientificreports*, (2022) 12:12082, <https://doi.org/10.1038/s41598-022-16208-0>.
- [138] Internet-<https://pypi.org/project/labelImg/>, Accessed date: 10/04/2024.
- [139] Internet-<https://pypi.org/project/labelme/>, Accessed date: 10/04/2024.
- [140] Internet- https://github.com/tensorflow/models/blob/master/research/object_detection/g3doc/tf2_detection_zoo.md, Accessed date: 10/04/2024.
- [141] Internet- <https://github.com/WongKinYiu/yolov7>, Accessed date: 10/04/2024.
- [142] Z. Wang, A. C. Bovik, H. R. Sheikh, and E. P. Simoncelli, "Image Quality Assessment: From Error Visibility to Structural Similarity," *IEEE Transactions on Image Processing*, vol. 13, no. 4, pp. 600-612, Apr. 2004. [Online]. Available: <https://doi.org/10.1109/TIP.2004.819861>.

- [143] A.A.S.Gunawan, E.J.Andreal, W.Budiharto, H.Nagariato, M.Attamimi, H.Tolle, ScienceDirect, Procedia Computer Science 227 (2023) 147–158.
- [144] Internet-<https://www.kaggle.com/datasets/jessicali9530/stanford-cars-dataset>, Accessed date: 12/04/2024.
- [145] Internet-<https://www.kaggle.com/datasets/likhon148/animal-data>, Accessed date: 12/04/2024.





ÖZGEÇMİŞ

Ad-Soyad : Onur ARDIÇ

ÖĞRENİM DURUMU

Doktora : 2025, Sakarya Üniversitesi/ Fen Bilimleri Enstitüsü/
Elektrik-Elektronik Mühendisliği
Yüksek Lisans : 2016, Afyon Kocatepe Üniversitesi/ Fen Bilimleri Enstitüsü/
Elektrik-Elektronik Mühendisliği
Lisans 2 : 2015, Sakarya Üniversitesi/ Mühendislik Fakültesi/ Elektrik-
Elektronik Mühendisliği
Lisans 1 : 2013, Gazi Üniversitesi/ Teknik Eğitim Fakültesi/ Elektrik
Öğretmenliği
Ön Lisans : 2009, Sakarya Üniversitesi/ Elektrik Bölümü
Lise : 2007, Arifiye Çok Programlı Lisesi/ Elektrik Bölümü

İŞ DENEYİMİ

Kıdemli Mühendis : 2024- , Toyota Motor Europe/ Zaventem/ Belçika
Kıdemli Mühendis : 2022-2024, Toyota Motor Corporation/ Aichi/ Japonya
Mühendis : 2016-2022, Toyota Otomotiv Sanayi/ Sakarya/ Türkiye
Mühendis : 2015-2016, Trenkwalder/ Sakarya/ Türkiye

TEZDEN TÜRETİLEN ESERLER:

- O. Ardic, G.Cetinel, "Exploring the Newly Introduced Data Augmentation Technique in TensorFlow Library", IEEE Signal Processing and Communications Applications (SIU), 2024, IEEE, DOI: 10.1109/SIU61531.2024.10601037.
- O. Ardic, G. Cetinel, "Deep Learning Based Real-Time Engine Part Inspection with Collaborative Robot Application (August 2024)," *IEEE Access*, DOI: 10.1109/ACCESS.2024.3489714.

YABANCI DİL

İngilizce, Japonca