



**T.C.
HALIÇ ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
ENDÜSTRİ MÜHENDİSLİĞİ ANABİLİM DALI
ENDÜSTRİ MÜHENDİSLİĞİ TEZLİ YÜKSEK LİSANS PROGRAMI**

**ENDÜSTRİYEL ÜRETİM HATLARINDA AZ SAYIDA VERİ İLE
ÖĞRENEBİLEN GÖRÜNTÜ İŞLEME TEKNOLOJİSİ İLE
KUSURLU ÜRÜN TESPİTİ**

YÜKSEK LİSANS TEZİ

Hazırlayan

Ali AKYOL

Tez Danışmanı

Dr. Öğr. Üyesi İlkay SARAÇOĞLU

İSTANBUL

Ocak 2024



**T.C.
HALIÇ ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
ENDÜSTRİ MÜHENDİSLİĞİ ANABİLİM DALI
ENDÜSTRİ MÜHENDİSLİĞİ TEZLİ YÜKSEK LİSANS PROGRAMI**

**ENDÜSTRİYEL ÜRETİM HATLARINDA AZ SAYIDA VERİ İLE
ÖĞRENEBİLEN GÖRÜNTÜ İŞLEME TEKNOLOJİSİ İLE
KUSURLU ÜRÜN TESPİTİ**

YÜKSEK LİSANS TEZİ

Hazırlayan

Ali AKYOL

Tez Danışmanı

Dr. Öğr. Üyesi İlkay SARAÇOĞLU

İSTANBUL

Ocak 2024



LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ MÜDÜRLÜĞÜ'NE

Endüstri Mühendisliği Anabilim/Anasanat Dalı Yüksek Lisans Programı Öğrencisi Ali Akyol tarafından hazırlanan "ENDÜSTRİYEL ÜRETİM HATLARINDA AZ SAYIDA VERİ İLE ÖĞRENEBİLEN GÖRÜNTÜ İŞLEME TEKNOLOJİSİ İLE KUSURLU ÜRÜN TESPİTİ" konulu çalışması jürimizce Yüksek Lisans Tezi olarak kabul edilmiştir.

Tez Savunma Tarihi: 23/01/2024

Jüri Üyesinin Ünvanı, Adı, Soyadı ve Kurumu:

İmzası

Jüri Üyesi : (Dr. Öğr. Üyesi İlkey Saraçoğlu)
(Haliç Üniversitesi)

Jüri Üyesi : (Dr. Öğr. Üyesi Figen Özen)
(Haliç Üniversitesi)

Jüri Üyesi : (Prof. Dr. Ramazan Yaman)
(İstanbul Atlas Üniversitesi)

Bu tez yukarıdaki jüri üyeleri tarafından uygun görülmüş ve Enstitü Yönetim Kurulu'nun kararıyla kabul edilmiştir.

(Enstitü Müdürünün Ünvanı, Adı, Soyadı)
Müdür

YÜKSEK LİSANS TEZ ÇALIŞMASI

ORJİNALLİK RAPORU

% **13**

BENZERLİK ENDEKSİ

% **12**

İNTERNET KAYNAKLARI

% **7**

YAYINLAR

% **9**

ÖĞRENCİ ÖDEVLERİ

BİRİNCİL KAYNAKLAR

- | | | |
|---|---|------|
| 1 | Submitted to The Scientific & Technological Research Council of Turkey (TUBITAK)
Öğrenci Ödevi | % 1 |
| 2 | 9lib.net
İnternet Kaynağı | % 1 |
| 3 | export.arxiv.org
İnternet Kaynağı | % 1 |
| 4 | informatica.vu.lt
İnternet Kaynağı | % 1 |
| 5 | svk.fav.zcu.cz
İnternet Kaynağı | <% 1 |
| 6 | acikbilim.yok.gov.tr
İnternet Kaynağı | <% 1 |
| 7 | dergipark.org.tr
İnternet Kaynağı | <% 1 |
| 8 | Submitted to National College of Ireland
Öğrenci Ödevi | <% 1 |
| 9 | Xiaofeng Lu, Wentao Fan. "Transformer-based Encoder-Decoder Model for Surface | <% 1 |

23.01.2024

TEZ ETİK BEYANI

Yüksek Lisans Tezi olarak sunduğum “Endüstriyel Üretim Hatlarında Az Sayıda Veri İle Öğrenebilen Görüntü İşleme Teknolojisi İle Kusurlu Ürün Tespiti” başlıklı bu çalışmayı başından sonuna kadar danışmanım Dr. Öğr. Üyesi İlkay Saraçoğlu'nun sorumluluğunda tamamladığımı, verileri kendim topladığımı, deneyleri/analizleri ilgili laboratuvarlarda yaptığımı/yaptırdığımı, başka kaynaklardan aldığım bilgileri metinde ve kaynakçada eksiksiz olarak gösterdiğimi, çalışma sürecinde bilimsel araştırma ve etik kurallara uygun olarak davrandığımı ve aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul ettiğimi beyan ederim.

Ali AKYOL

ÖNSÖZ

Bu tez, endüstriyel üretim hatlarındaki kalite kontrol süreçlerinde az sayıda veri ile öğrenme yeteneğine sahip görüntü işleme teknolojilerinin geliştirilmesi ve kusurlu ürün tespiti üzerine odaklanmaktadır. Çalışmanın temeli, az veriyle etkin bir şekilde çalışabilen RD4AD ve RegAD modelleri ile YOLOv8 segmentasyon ve RegAD hibrit modelinin kullanımı üzerine kuruludur. Endüstrinin karşılaştığı zorluklardan biri olan verinin kısıtlı olması durumunda, bu modellerin nasıl etkili sonuçlar üretebileceğini keşfetmek bu tezin ana amacıdır. Bu çalışmada, yapay zeka ve makine öğrenimi alanındaki yeniliklerin, endüstriyel süreçlerin iyileştirilmesine nasıl katkı sağlayabileceğini göstermek hedeflenmektedir. Bu tez, hem akademik hem de pratik açıdan, endüstri mühendisliği ve yapay zeka uygulamalarının kesişim noktasında önemli bir katkı sunmayı amaçlamaktadır.

Araştırmanın her aşamasında hiçbir konuda desteğini esirgemeyen kıymetli danışmanım Dr. Öğr. Üyesi İlkay SARAÇOĞLU'na, veri toplama ve analiz aşamasında destek veren Çözüm Makina Sanayi ve Ticaret Limited Şirketi Ar-Ge Ekibine, akademik anlamda hiçbir zaman desteğini esirgemeyen Şükrü Şahin GÖKDERE ve Cemile İpar POLAT'a tüm bu çalışmalarımı sürdürürken desteklerini hep hissettiğim kardeşim Metehan YAŞAR, Aytek UZUN ve çok sevgili aileme şükranlarımı sunarım.

Ocak 2024

Ali AKYOL

İÇİNDEKİLER

Sayfa No

TEZ ETİK BEYANI	i
ÖNSÖZ	ii
İÇİNDEKİLER	iii
KISALTMALAR	v
TABLO LİSTESİ	vii
ŞEKİL LİSTESİ	viii
ÖZET	ix
ABSTRACT	x
1. GİRİŞ	1
2. LİTERATÜR TARAMASI	3
3. GENEL BİLGİLER	10
3.1. Yapay Zeka.....	10
3.2. Makine Öğrenmesi	11
3.3. Derin Öğrenme	11
3.3.1. Bilgisayarlı Görü (Computer Vision)	12
3.3.2. Evrişimli Sinir Ağları (Convolutional Neural Network)	13
3.3.2.1. VGGNet (Vision Geometry Group Network).....	15
3.3.2.2. Artık bağlantı ağı (Residual Network - ResNet).....	16
3.3.2.3. Birleştirilmiş Ağ (Unified Neetwork – U-Net)	17
3.3.2.4. Bilgisayarlı görü için transformer: ViT (Vision Transformer)	18
3.4. Yapay Zeka için Öğrenme Paradigmaları	19
3.4.1. Denetimli Öğrenme (Supervised Learning).....	20
3.4.2. Denetimsiz Öğrenme (Unsupervised Learning)	21
3.4.3. Pekiştirmeli Öğrenme (Reinforcement Learning)	21
3.4.4. Birkaç Adımda Öğrenme (Few-Shot Learning)	23
3.4.5. Tek Adımda Öğrenme (One-Shot Learning)	23
3.4.6. Transfer Öğrenmesi (Transfer Learning).....	24
3.4.7. Değerlendirme Metriği Olarak ROC-AUC.....	25
3.5. Üretim Bantlarında Anomali Tespit Yöntemleri.....	26

4. AZ AYIDA VERİ İLE KUSURLU ÜRÜN TESPİTİ UYGULAMASI	27
4.1. Veri Seti.....	27
4.2. Yöntem	27
4.3. Geliştirme Ortamı	29
5. BULGULAR.....	31
6. SONUÇLAR VE ÖNERİLER	34
KAYNAKLAR	37
ÖZGEÇMİŞ.....	40



KISALTMALAR

AUC	: Area Under The Curve (Eđri Altındaki Alan)
COCO	: Common Objects in Context (Bađlamsal Yaygın Nesne)
CNN	: Convolutional Neural Network (Evrifimli Sinir Ađı)
DAGM	: Deutsche Arbeitsgemeinschaft für Mustererkennung (Alman Desen Tanıma Çalıřma Grubu)
DCGAN	: Deep Convolutional Generative Adversarial Network (Derin Evriřimli Üretimsel Çekiřmeli Ađ)
DDİ	: Doğal Dil İşleme
FPN	: Feature Pyramid Network (Özellik Piramit Ađı)
GAN	: Generative Adversarial Network (Üretimsel Çekiřmeli Ađ)
GELU	: Gaussian Error Linear Unit (Gauss Hatası Doğrusal Birimi)
GLCM	: Gray Level Co-occurrence Matrices (Gri Seviye Eř Oluřum Matrisi)
GPU	: Graphical Processor Unit (Grafik İşlemci Birimi)
ILSVRC	: ImageNet Large Scale Visual Recognition Challenge (ImageNet Büyük Ölçekli Görsel Tanıma Yarıřması)
LBP	: Local Binary Pattern (Yerel İkili Desen)
LSTM	: Long-Short Term Memory (Uzun Kısa Süreli Bellek)
PCA	: Principal Component Analysis (Temel Bileřen Analizi)
PAN	: Path Aggregation Network (Yol Birleřtirme Ađı)
ReLU	: Rectified Linear Unit (Dođrusal Doğrultma Birimi)
RegAD	: Registration based Few-Shot Anomaly Detection (Kayıt Temelli Birkaç Adımda Anomali Tespiti)
RD4AD	: Reverse Distillation for Anomaly Detection (Anomali Tespiti için Tersine Damıtma)
ROC	: Receiver Operating Characteristic (Alıcı İşletim Karakteristiđi)
RNN	: Recurrent Neural Network (Yinelemeli Sinir Ađı)
STN	: Spatial Transform Network (Uzamsal Dönüřüm Ađı)
SVM	: Support Vector Machine (Destek Vektör Makinesi)
t-SNE	: T-Distributed Stochastic Neighbor Embedding

(T-Dağılımlı Olasılıksal Komşuluk Gömmeleri)

- VGGNet** : Vision Geometry Group Network (Görü Geometri Grubu Ağı)
ViT : Vision Transformers (Görü Transformer)
ResNet : Residual Network (Artık Bağlantı Ağı)
YOLO : You Only Look Once (Sadece Bir Kere Bak)



TABLO LİSTESİ

Sayfa No

Tablo 5.1. MVTec Veri Seti için İlgili Modellerin Orijinal Başarım Ölçümleri.....	31
Tablo 5.2. Veri Seti için Yöntemlerin Değerlendirme Metrikleri (ROC-AUC)	33
Tablo 6.1. Her İki Veri Seti için Yöntemlerin Değerlendirme Metrikleri.....	35



ŞEKİL LİSTESİ

Sayfa No

Şekil 2.1. Akçay vd. Tarafından Önerilen Ağ.....	4
Şekil 2.2. Deshpande ve ark. Tarafından Önerilen Ağın Mimarisi.....	5
Şekil 2.3. Mevcut Modeller ve SIVT Karşılaştırma.....	7
Şekil 2.4. SIVT (Self Induction Vision Transformer) Modeli	7
Şekil 2.5. Netzer ve ark. Tarafından Önerilen Yöntem.....	8
Şekil 2.6. Smith ve ark. tarafından önerilen model.....	9
Şekil 2.7. Makine Öğrenmesi ve Derin Öğrenme İlişkisi	11
Şekil 2.8. Makine Öğrenmesi ve Derin Öğrenme Karşılaştırma	12
Şekil 2.9. CNN Mimarisi	14
Şekil 2.10. VGG16 Ağı Model Mimarisi.....	16
Şekil 2.11. (Sağda) Artık Bağlantı Gösterimi, (Solda) ResNet Ağ Mimarisi	16
Şekil 2.12. UNet Modeli Mimarisi.....	17
Şekil 2.13. ViT Mimarisi	18
Şekil 2.14. Makine Öğrenmesi Paradigmaları ve Derin Öğrenme İlişkisi.....	19
Şekil 2.15. Yapay Zeka Öğrenme Paradigmaları Şeması	20
Şekil 2.16. Pekiştirmeli Öğrenme	22
Şekil 2.17. One-Shot Learning (Siamese Ağ Modeli)	24
Şekil 2.18. Transfer Öğrenmesi.....	25
Şekil 2.19. ROC-AUC Eğrisi Gösterimi	26
Şekil 3.1. Verilerin Toplandığı Konveyör.....	27
Şekil 3.2. Tercih Edilen İlk Modelin Mimarisi	28
Şekil 3.3. Tercih Edilen İkinci Modelin Mimarisi	29
Şekil 3.4. Önerilen Birleştirilmiş Hibrit Model	29
Şekil 5.1. RD4AD Modeli ile Elde Edilen Çıktılar.....	31
Şekil 5.2. RegAD Model Çıktıları.....	32
Şekil 5.3. YOLOv8 Segmentasyon + RegAD ile Elde Edilen Çıktılar.....	32
Şekil 5.4. Değerlendirme Testleri ROC-AUC Eğrisi.....	33

ÖZET

ENDÜSTRİYEL ÜRETİM HATLARINDA AZ SAYIDA VERİ İLE ÖĞRENEBİLEN GÖRÜNTÜ İŞLEME TEKNOLOJİSİ İLE KUSURLU ÜRÜN TESPİTİ

Geçmişten günümüze, sanayi devriminin başlangıcıyla seri üretim hatları her sektör için farklı şekilde geliştirilmiştir. Seri üretime geçilmesiyle, mekanik ve teknik hatalar sebebiyle bu hatlarda üretilen tüm ürünlerin hatasız çıkması mümkün olmamaktadır. Bu sebeple kalite kontrol süreçleri içinde farklı çözümler üretilmeye çalışılmıştır. Geleneksel olarak, üretim hatlarındaki hata tespiti insan gözlemciler tarafından yapılmaktadır. Bu yöntem, yüksek dikkat gerektiren ve yorucu bir iş olup, hataya açık bir süreçtir. Ayrıca, bu yöntemle hataların tespiti zaman alıcı ve maliyetli olabilir. Yapay zeka (AI) teknolojilerinin yükselişiyle birlikte, hata tespiti için yeni çözümler geliştirilmeye başlanmıştır. Yapay zeka tabanlı sistemler, hızlı ve doğru hata tespitiyle ön plana çıkmaktadır. Ancak, mevcut AI sistemlerinin etkin bir şekilde çalışabilmesi için büyük miktarda veri gerekmektedir. Dahası, özellikle az veri bulunan veya sürekli değişen üretim ortamlarında, bu sistemlerin performansı düşmektedir. Bunun sonucu olarak az veri ile anomali tespiti ayrı bir çalışma alanı haline gelmiştir.

Bu çalışmada 400 hatasız ve 10 anomali içeren, metal içecek kutularıyla veri seti oluşturulmuştur. Yöntem olarak RD4AD ve RegAD modelleriyle birlikte YOLOv8 segmentasyon modeli ve RegAD'nin birleştirildiği hibrit model kullanılmıştır. Veri seti içindeki resimler üzerinde herhangi bir ön işlem gerçekleştirilmemiştir. Bu çalışmada önerilen hibrit model, YOLOv8 segmentasyon modeli anomali içeren resimler üzerinde 50 dönem eğitilmiş ve RegAD için 8 atışlık yöntem kullanılarak veri seti üzerinde sonuçlar ölçülmüştür.

Sonuç olarak bu çalışmada önerilen hibrit modelin özelleştirilmiş veri seti üzerinde diğer yöntemlere göre %10'dan fazla bir oranda daha semantik bir başarı gösterdiği görülmüştür.

Anahtar Kelimeler: Kalite Kontrol, Anomali Tespiti, Az Veri İle Öğrenme, Derin Öğrenme, Birkaç Adımda Öğrenme

ABSTRACT

DEFECTED PRODUCT DETECTION IN INDUSTRIAL ASSEMBLY LINES USING IMAGE PROCESSING TECHNOLOGY WITH LIMITED DATA

From past to present, with the beginning of the industrial revolution, mass production lines have been developed differently for each sector. With the introduction of mass production, it is not possible for all products produced on these lines to be defect-free due to mechanical and technical errors. For this reason, different solutions have been tried to be produced within the quality control processes. Traditionally, defect detection on production lines is done by human observers. This method is a tiring job that requires high attention and is a process prone to errors. Additionally, detecting errors using this method can be time-consuming and costly. With the rise of artificial intelligence (AI) technologies, new solutions have begun to be developed for error detection. Artificial intelligence-based systems stand out with fast and accurate error detection. However, current AI systems require large amounts of data to work effectively. Moreover, the performance of these systems decreases, especially in production environments where little data is available or constantly changing. As a result, anomaly detection with little data has become a separate field of study.

In this study, a data set was created with 400 error-free metal beverage cans and 10 anomalies. As a method, a hybrid model combining the YOLOv8 segmentation model and RegAD along with the RD4AD and RegAD models was used. No pre-processing was performed on the images in the data set. The hybrid model proposed in this study, the YOLOv8 segmentation model, was trained on images containing anomalies for 50 periods and the results were measured on the data set using the 8-shot method for RegAD.

As a result, it was observed that the hybrid model proposed in this study showed more than 10% more semantic success than other methods on our customized data set.

Keywords: *Quality Control, Anomaly Detection, Less Dataset, Deep Learning, Few-shot Learning*

1. GİRİŞ

Endüstriyel üretim süreçleri, günümüz ekonomisindeki temel taşlardan biri olup, ürün kalitesi ile doğrudan ilişkilidir. Ürün materyallerinin lojistiği sırasında veya ürünün üretimi esnasında üretim bandında meydana gelen hataların erken tespiti ve düzeltilmesi, ürün kalitesinin istikrarı, müşteri memnuniyeti ve verimlilik açısından kritik öneme sahiptir. Geleneksel olarak, insan gücüne dayalı yöntemlerle kusurlu ürünlerin tespit edilmesi, zaman alıcı, maliyetli ve zaman, yorgunluk ve algı kayması gibi insani sebeplerle bağlantılı olarak hataya daha eğilimlidir (Shutub ve Cohen, 2016).

Günümüzde artan arz trendinin yukarı yönde olmasından dolayı, aynı oranda talebin karşılanabilmesi için üretim hatlarının kapasitesinin genişletilmesi, bu ürünlerin kalite kontrol süreçlerinin de aynı oranda iyileştirilmesi anlamına gelmektedir. Bu aşama ise sadece insana bağlı kalite kontrol süreçlerinin haricinde ve alternatif olarak endüstriyel üretim hatlarında kullanılan görüntü işleme teknolojileri, kusurlu ürünlerin otomatik olarak tespit edilmesi konusunda önemli bir potansiyele sahiptir. Ancak, yapay zekaya dayalı bu teknolojilerin etkinliği ve güvenilirliği, genellikle yeterli miktarda ve nitelikte veri ile doğru orantılıdır. Endüstriyel üretimden elde edilen veri setleri sıklıkla sınırlı, heterojen ve gürültülü olabilir, bu da kusurlu ürün tespiti için güvenilir yapay zeka modellerin geliştirilmesini daha zor hale getirmektedir (Li ve ark., 2017).

Bu çalışma, endüstriyel üretim hatlarında az miktardaki veri ile kusurlu ürünlerin tespitini yapabilen yapay zeka tabanlı görüntü işleme teknolojisi kullanılan bir sistemin geliştirilmesini hedeflenmiştir. Bu amaç doğrultusunda literatür incelenecek, yapay zeka ve görüntü işleme tekniklerinin kullanımıyla ilgili mevcut bilgi ve yöntemler ele alınmıştır. Bu doğrultuda geleneksel çözümlerin yanı sıra yapay zeka destekli çalışmaların karşılaştırılmaları yapılacaktır.

Ayrıca üretim bantlarından bazı örnek veri kümeleri toplanmıştır. Bu veri kümeleri kullanılarak, bu çalışmada çözüm olarak önerilecek CNN (Convolutional Neural Network - Evrişimli Sinir Ağı) ve Transfer Öğrenmesi (Transfer Learning) gibi derin öğrenme temelli yöntemlerin yetkinliği incelenmiştir. Belirlenmiş başarımların metrikleri kullanılarak önerilen çalışmaların performansı değerlendirilmiş ve elde edilen sonuçlar analiz edilmiştir.

Bu çalışmanın bir diğer hedefi, veriye ulaşmanın kısıtlı olduğu endüstriyel üretim bantlarında son kullanıcı için kullanıma uygun bir uygulama geliştirerek örnek bir kusurlu ürün tespit sistemi geliştirmektir. Bu kapsamda, kusurlu ürün tespiti için gerekli olan görüntü işleme teknikleri tasarlanmış ve derin öğrenme tabanlı bir model oluşturulmuştur. Geliştirilen sistem, endüstriyel üretim süreçlerinin otomasyonunu sağlayarak insan bağımlılığını azaltacak ve üretim verimliliğini artıracaktır.

Bu çalışmada kronolojik olarak anomali tespiti için yapılmış farklı yöntemleri içeren çalışmalar incelenerek bu çalışmaların metodları açıklanmıştır. Son olarak bu çalışmada, endüstriyel üretim hatlarında kusurlu ürün tespiti konusunda bilimsel araştırma yöntemlerini kullanarak özgün bir katkı sağlanması ve veriye ulaşmanın kısıtlı olduğu endüstriyel uygulamalar için pratik bir çözüm sunulması amaçlanmıştır.


2. LİTERATÜR TARAMASI

Seri üretimin bir akış halinde olduğu, arz talep dengesinin karşılanabilmesi için farklılaşan ürünler için farklı üretim bandı işlemleri bulunmaktadır. İşlem sonunda elde edilecek ürünün hammaddeden ürün haline kadar her adımında hem müşteri memnuniyeti hem de ekonomik olarak ürünün kar ettirici bir unsur olması açısından kalite kontrol süreçleri, bu süreçlerdeki hataların, anomalilerin, erken tespiti büyük önem arz etmektedir. Bu tespitin en erken teşhis mekanizması da üretim bantlarıdır. Bu sebeple literatürde bu konuyla ilgili yapılmış oldukça fazla çalışma bulunmaktadır.

Kaynar ve ark. (2017) tarafından yapılan başka bir kusurlu ürün tespiti olan, kumaş hatalarını tespit etmek için farklı öznitelik çıkarma yöntemlerini ve yapay sinir ağlarını birleştiren bir yöntem sunulmuştur. Bu yöntemde öncelikle, LBP (Local Binary Pattern) ve GLCM (Gray Level Co-occurrence Matrices - Gri Düzey Eş oluşum Matrisi) gibi özellik çıkarma yöntemleri kullanılarak öznitelikler elde edilmiştir. Daha sonra bu öznitelikler MLP (Multilayer Perceptron - Çok Katmanlı Algılayıcı) yapay sinir ağları ile eğitilerek kumaş hatalarını sınıflandırmak için modeller oluşturulmuştur. Yapılan karşılaştırmalar, GLCM öznitelik çıkarma yönteminin, daha az sayıda öznitelik kullanarak daha iyi performans gösterdiğini ortaya koymuşlardır (Kaynar ve ark., 2017).

Akçay ve ark. (2019) denetimsiz öğrenme paradigması kullanarak anomali tespiti için atlamalı bağlantı (skip connection) ve DCGAN (Deep Convolutional Generative Adversarial Network) prensiplerini kullanarak bir yöntem önermişlerdir. Önerdikleri yöntemde eğitim veri setinde sadece normal veriler mevcutken test veri setinde hem normal hem de anormal veriler bulunmaktadır. Bu yöntemde eğitim aşamasında üretici ağı kodlayıcı bloğu ile belirtilen girdiden bir gizli temsil elde edilerek, normal verinin dağılımı hem düşük hem de yüksek seviyedeki özellikleri yakalanmaya çalışılmıştır (Şekil 2.15). Bunun sonucu olarak bir anormallik puanı hesaplanır. Modelin tahmin aşamasında ise atlamalı bağlantılar sayesinde üretici ağı kod çözücü bloğu, gizli vektör uzayını girdi olarak alarak ve üretici ağda karşılık gelen veriyle birleştirilerek görüntünün yeniden oluşturulmasını sağlamışlardır (Şekil 2.1). Bu

bağlantı, katmanlar arasında bilginin doğrudan iletilmesini sağlayan önemli bir özelliktir. Son olarak gerçek resmi ve yeniden elde edilen resim bir ayırıcı ağ yardımıyla normal veya anormal olarak karar verilir. Bu çalışmada Akçay ve ark. (2019) yenilikçi bir fikir sunmalarına karşı, eğitim için belli bir miktar verinin varlığına ihtiyaç duymaktadırlar.

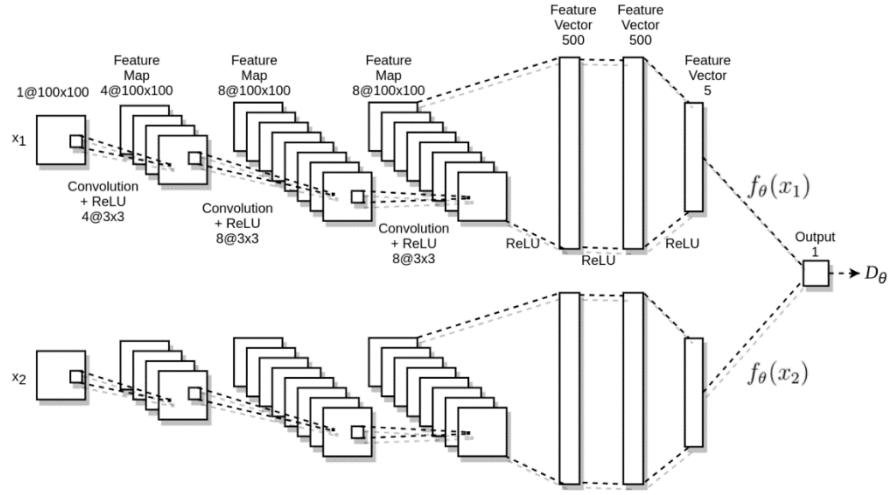


Şekil 2.1. Akçay vd. Tarafından Önerilen Ağ

Kaynak: Akçay ve ark., (2019)

Deshpande ve ark. (2020), literatürde tek seferde öğrenme görüntü tanıma konseptine dayalı bir yapay sinir ağı türü olan, belirli bir sınıfa ait tek bir örnek verildiğinde, ağın bu sınıfa ait diğer örnekleri tanıyabilmesine odaklanan Siamese Ağları kullanarak, çelik sektörü için kalite kontrol aşamasında kusur anomalisi tespit eden bir model önermişlerdir. Şekil 2.2’de gösterilen model mimarisindeki her iki modül de aynıdır ve ağırlıkları paylaşır. Her bir modülde üç evrişim katmanı bulunmaktadır. Bu evrişim katmanları üç tam bağlı katman takip etmektedir. Evrişim işlemleri için 3x3’lük filtreler (kernel) ve adım boyutu (stride) olarak 1 kullanılmıştır.

Deshpande ve ark. (2020), Şekil 2.2 ile gösterilen geliştirdikleri ağın eğitiminde kullandıkları kontrastif kayıp fonksiyonu, ağırlıklar ve eğitim örnekleri tarafından parametreleştirme yapılan bir işlemdir. Giriş örnekleri x_1 ve x_2 ifade edilen görüntü çiftleridir ve bunların her biri y etiketiyle belirtilir. eğer x_1 ve x_2 aynı sınıfa aitse, $y = 1$ olur; aksi takdirde, $y = 0$ olur. Bu kayıp fonksiyonu, giriş çiftlerinin kodlanmış vektörlerinin benzerliklerini ve farklılıklarını öğrenmek için kullanılır.



Şekil 2.2. Deshpande ve ark. Tarafından Önerilen Ağın Mimarisi

Kaynak: Deshpande ve ark., (2020)

Çelik levha üretim tesislerinde, üretim aşamasındaki anomali tespiti, bu çelikten üretilecek ürünün kalitesi ve çeliğin maliyeti açısından çok önemli bir parametredir. Bu doğrultuda Damacharla ve ark. (2021) Severstal veri setini kullanarak Transfer öğrenmesi temelli, kodlayıcı olarak iki farklı ResNet ve DenseNet kullanan bir U-Net modeli önermişlerdir. ImageNet veri seti ile ön eğitilmiş modeller ile karşılaştırıldığında mutlak olarak %5, göreceli olarak ise yaklaşık olarak %25 oranında başarı elde etmişlerdir.

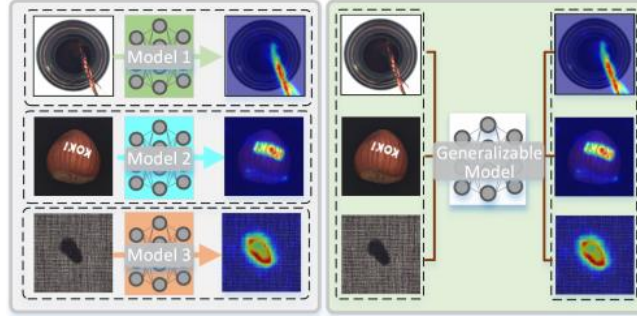
Duman ve Özsoy (2021), metal eklemeli imalat, karmaşık geometrilikli parça imalatında sıklıkla tercih edilen toz yatak füzyon birleştirme imalat makinalarını kullanarak kusur tespit çalışması yapmışlardır. Parça imalat süreçlerindeki gerçek zamanlı anomali tespiti üzerine yaptıkları çalışmada derin öğrenme yöntemlerini kullanmışlardır. Çalışmada EOS M290 veri setinin kullanılması tercih edilmiştir. Anomalilerin algılanması ve sınıflandırılmasında literatürde sıklıkla tercih edilen VGG-16, InceptionV3 ve DenseNet gibi ön eğitilmiş farklı CNN modelleri kullanarak çözüm sunmuşlardır. Yaptıkları testler sonucunda VGG-16 modelinin en iyi performansı elde ettiğini belirtmişlerdir.

Üzen ve ark. (2022), otomatik olarak yüzey hasar tespitine dayalı anomali tespiti için InceptionV3 CNN modelini temel aldıkları ve zenginleştirilmiş öznetelik birleştirme ismini verdikleri birleştirme ağı kullanarak bir derin öğrenme modeli önermişlerdir. Bu modelde belirli katmanlardaki uyumlu öznetelik çıktılarının birleştirilmesi sonucu 5 öznetelik haritası elde etmişler ve bu daha düşük bilgileri

içeren öznitelikleri bir piramit ağ mimarisi ile yüksek seviyeli öznitelik haritalarına aktarmışlardır. Elde edilen öznitelik haritaları, öznitelik birleştirme ve anlamlandırma ismini verdikleri modül üzerinde birleştirilerek nihai bir öznitelik haritası elde edilmiştir. Bu öznitelik haritası birkaç normalizasyon bloğundan geçerek son katmanında CNN ve sigmoid katmanları kullanılarak kusur tespit edilmiştir. Çalışmada MT, MVTec-Doku ve DAGM (Deutsche Arbeitsgemeinschaft für Mustererkennung) veri setlerini kullanmayı tercih etmişlerdir. Yaptıkları deneysel ölçümler sonucunda ise literatürde yer alan teknolojilerden yüksek sonuçlar elde ettiklerini belirtmişlerdir.

Lu ve ark. (2022), seramik karoların üretim kalitesini artırmak için yaptıkları, manuel olarak gerçekleştirilen düşük verimli ve zaman alıcı bu süreci geliştirmeyi hedeflemişlerdir. Yüksek çözünürlüklü seramik karo görüntülerindeki küçük yüzey kusurlarını tespit etmek için, geliştirilmiş bir YOLOv5 (You Only Look Once) algoritması tabanlı akıllı bir tespit yöntemi önermişlerdir. İlk olarak, yüksek çözünürlüklü seramik karo görüntüleri dilimlere bölünür ve YOLOv5s ağındaki Darboğaz (Bottleneck) modülü, derinlik bazlı evrişim yöntemi ile optimize edilir ve ağıın tamamında değiştirilmiştir. Daha sonra, geliştirilmiş Shufflenetv2 ana omurga (Backbone) kullanılarak özellik çıkarma işlemi gerçekleştirilmiştir. Ana omurga ağına bir dikkat mekanizması eklenmiş ve özellik çıkarma yeteneğinin artırılması hedeflenmiştir. Ayrıca, PAN (Path Aggregation Network – Yol Birleştirme Ağı) ve FPN (Feature Pyramid Network - Özellik Piramit Ağları) boyun kısımları özellik çıkarma yeteneğini artırmak için kullanılmıştır. Deneysel sonuçlar, önerilen yöntemin orijinal YOLOv5s tespit algoritmasına göre model parametrelerinin ve işlemlerinin azaldığını ve kusur tespit hassasiyetinin arttığını ölçmüşlerdir.

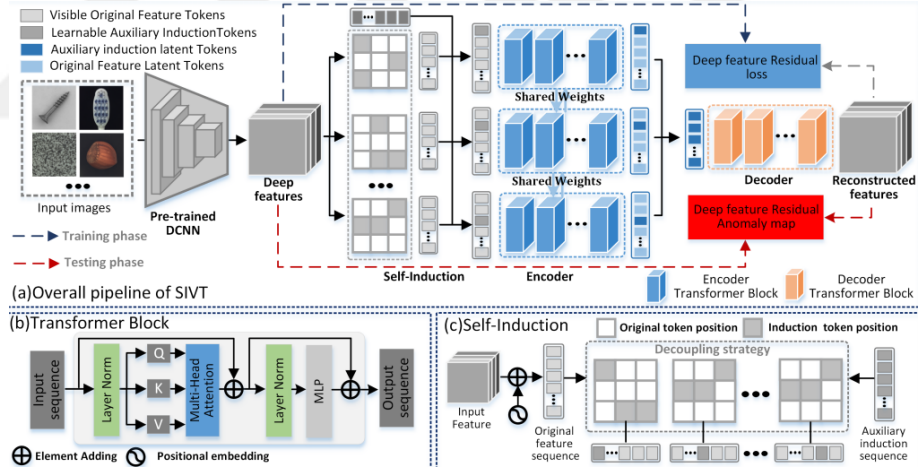
Yao ve Yu (2022) anomali tespiti için genellikle tek bir ürün kategorisine modellerin aksine görevden ve veriden bağımsız, denetimsiz genelleştirilebilir çoklu kategori için endüstriyel görsel anomali tespiti sağlayan SIVT (Self Induction Vision Transformer) modelini sunmaktadırlar (Şekil 2.3). CNN mimarisinin lokal bağlamı anlama gücü olmasına rağmen global bağlamı ifade edemediğini ve bu durumun model performansını etkilediğini belirtmektedirler.



Şekil 2.3. Mevcut Modeller ve SIVT Karşılaştırma

Kaynak: Yao ve Yu, (2022)

Yao ve Yu (2022) tarafından önerilen SIVT modeli ilk olarak önceden eğitilmiş CNN'den ayırt edici özellikler çıkarır. Ardından SIVT, çıkarılan özellikleri kendinden denetimli bir şekilde yeniden oluşturmak için kullanılır. Son olarak anomali özellikleri, anlamsal özellik farkıyla tespit edilebilir. Yaptıkların testlerin sonucunda ise mevcut veri setleri üzerindeki en yüksek başarımların üzerine çıkabildiklerini belirtmektedirler (Şekil 2.4).

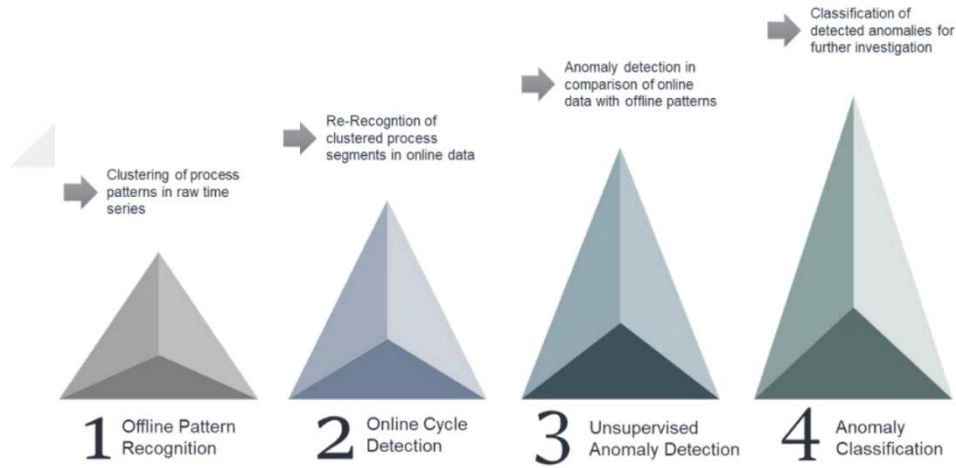


Şekil 2.4. SIVT (Self Induction Vision Transformer) Modeli

Kaynak: Yao ve Yu, 2022

Netzer ve ark. (2022), elektrik motoru üretimine yönelik montaj hattında deneysel doğrulama yaptıkları fakat farklı üretim bandı süreçleri içinde genelleştirilebilen bir yöntem önermektedirler. Önerilen yöntem Şekil 2.5'te gösterildiği gibi temel olarak 4 adımda açıklanmaktadır:

- Çevrimdışı Desen Tanıma: Bu süreçte, üretim bandından gelen ham data, alt dizilere bölünür. Bu veriler için en doğru kümeleme ve sapma parametreleri tespit edilmeye çalışılır.
- Çevrimiçi Süreç Tespiti: Üretim hattındaki gerçek zamanlı sinyallerin, daha önceden belirlenen desenlere göre incelenmesi ve puanlanması sağlanmıştır. Bu süreç, sinyallerin kümelenmiş desenlerle karşılaştırılması ve sapmaların tespit edilmesini sağlar.
- Denetimsiz Anomali Tespiti: Bu adımda doğru süreç kümelerinin tespit edilmesinden sonra, önceden kümelenmiş olan sinyaller üzerinden karşılaştırma yapılarak anomali tespiti yapılmıştır.
- Anomali Sınıflandırma: Son olarak, denetimsiz tespit edilen anomaliler DVM (Destek Vektör Makineleri) ve otomatik kodlayıcılar gibi bir hibrit yaklaşım kullanılarak sınıflandırılır. Aynı zamanda, denetimsiz olarak bulunan anomalilerin sınıflandırılması ve etiketlenmesi mümkün hale gelmiştir.

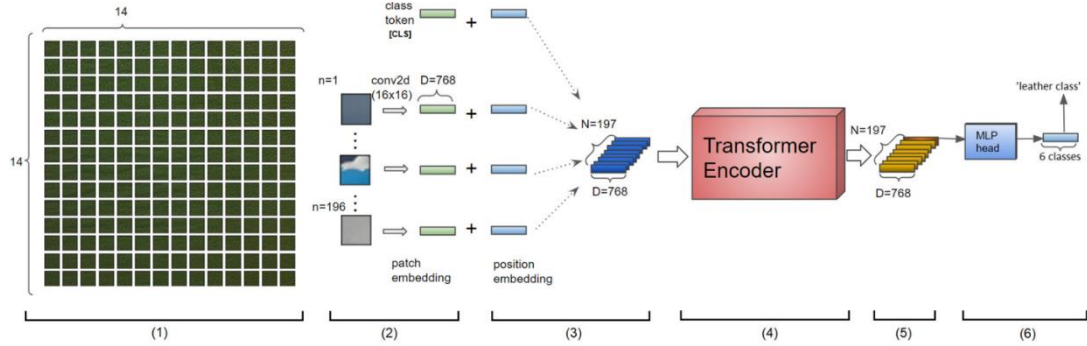


Şekil 2.5. Netzer ve ark. Tarafından Önerilen Yöntem

Kaynak: Netzer ve ark., (2022)

Smith ve ark. (2023), deri sektöründe kullanılan hayvan derilerinin, hayvanların doğal ortamlarından dolayı maruz kalabildikleri durumlar göz önüne alındığında yüzey kusurlarının kaçınılmaz olduğunu belirtmişlerdir. Deri üretim bantlarındaki farklı hayvan derilerinin, farklı kusurlarının olabileceği de göz önüne alındığında sadece insan kontrolünün eksik kaldığını ifade etmişlerdir. Bu sebeple az veri kullanarak geliştirdikleri ve en son teknoloji olarak kabul edilen ViT mimarisıyla çözüm sunmuşlardır (Şekil 2.6). Değerlendirme sonucu diğer birçok yönteme göre

performans açısından başarılı olduğunu belirtmektedirler. Fakat modelin hangi kısımlara odaklandığı tespit edilebilse de nasıl odaklandığı ve karar sürecine dair aksiyonları anlamak mümkün değildir.



Şekil 2.6. Smith ve ark. tarafından önerilen model

Kaynak: Smith ve ark., (2023)

Bu çalışma için toplanan özelleştirilmiş veri seti ile literatürde anomali tespit modellerinin başarımlarının karşılaştırılmasında sıklıkla kullanılan MVTec anomali veri seti üzerinde son yıllarda oldukça başarılı sonuçlar ürettikleri belirtilen RD4AD ve RegAD modelleri denenmiştir. MVTec üzerinde başarılı olduklarını belirtmelerinin aksine özelleştirilmiş bir veri seti üzerinde, bu çalışmada önerilen YOLOv8 Segmentasyon + RegAD hibrit modeli kadar bir başarı gösterememektedirler. Buradan hareketle bu çalışmada önerilen yöntemin özelleştirmiş veri setleri üzerinde daha başarılı oldukları söylenebilir ve sonuçlarda bunu doğrular niteliktedir.

3. GENEL BİLGİLER

Anomali tespiti ile alakalı çalışmalar geleneksel yöntemler ile eski zamanlardan beri üzerine çalışılan bir alan olmuştur. Üretim bantlarındaki kalite kontrol aşaması için, insan temelli kontrol faktörünü bu denklemden çıkartarak bu süreçlerin otomatikleştirilmesi amaçlanmıştır. Endüstri 4.0 ile bu problem daha da önemli hale gelmeye başlamıştır. Bu bağlamda çalışma yapılırken literatürde farklı kaynaklardan faydalanılmıştır.

3.1. Yapay Zeka

Yapay zeka, deterministik bir işleyişe sahip olan bilgisayar sistemlerine daha karmaşık düşünme becerilerine sahip olan insan benzeri zeka yetenekleri kazandırmayı amaçlayan, makinelerinde düşünebileceğini konseptini ortaya koymaya çalışan bir disiplindir (Turing, 1950). Mitchell'den aktaran Geron (2017) "Belirli bir görev T ve performans ölçütü P açısından bir bilgisayar programı, deneyim E ile ilgili olarak öğrenme deneyimine sahiptir, eğer T üzerindeki performansı, P tarafından ölçüldüğünde deneyim E ile gelişme gösteriyorsa yapay zekadır" şeklinde de tanımlamıştır. Bu sistemler, verilerin analiz edilmesi, öğrenme, problem çözme ve karar verme gibi insan zekasına benzer işlevleri yerine getirebilmek amacıyla tasarlanmaktadır. Yapay zeka tek başına çok geniş bir kavramı ifade etmektedir ve tek başına genelleşmiş bir yapay zekadan bahsetmek günümüz için mümkün değildir. Bu bağlamda genel yapay zeka çalışma alanının altında makine öğrenmesi ve derin öğrenme başlıkları içinde incelenmektedir (Şekil 2.7). Bu sebeple farklı problemler için farklı çözüm yöntemleri özelleşmiştir. Doğal dil üzerinde yapılan çalışmalar için, bu alana özgü RNN (Recurrent Neural Network), LSTM (Long-Short Term Memory), GRU (Gated Recurrent Unit) ve son zamanlarda son teknoloji (state-of-the-art) kabul edilen, GPT (Generative Pretrained Transformer) gibi çığır açan yeniliklerin temelini oluşturan Transformatör gibi mimarileri barındıran Doğal Dil İşleme (DDİ) yöntemleri kullanılırken, nesne tespiti ve takibi, anomali tespiti gibi görüntü analitiğine dayanan alanlarda da CNN (Convolutional Neural Network - Evrişimli Sinir Ağları) modelleri gibi bilgisayarlı görü (Computer Vision) yöntemleri kullanılmaktadır.



Şekil 2.7. Makine Öğrenmesi ve Derin Öğrenme İlişkisi

Kaynak: Chollet, F., (2017)

3.2. Makine Öğrenmesi

Makine öğrenmesi, bilgisayar sistemlerine veri üzerinden öğrenme ve kendini geliştirme yetisi kazandıran bir yapay zeka dalıdır. Bu sistemler, veri setlerini analiz eder, desenleri tanımlar ve bu desenleri gelecekteki veriler üzerinde kullanarak öngörülerde bulunabilir. Makine öğrenimi, genellikle denetimli, denetimsiz veya takviyeli öğrenme olarak kategorize edilir. Denetimli öğrenmede, sisteme etiketlenmiş veri sağlanırken, gözetimsiz öğrenme veri etiketi olmadan desenleri keşfetmeye çalışır. Takviyeli öğrenme ise deneme-yanılma yoluyla öğrenmeyi temsil eder, sistem ödül veya cezalar alarak kendini geliştirir (Chollet, 2017).

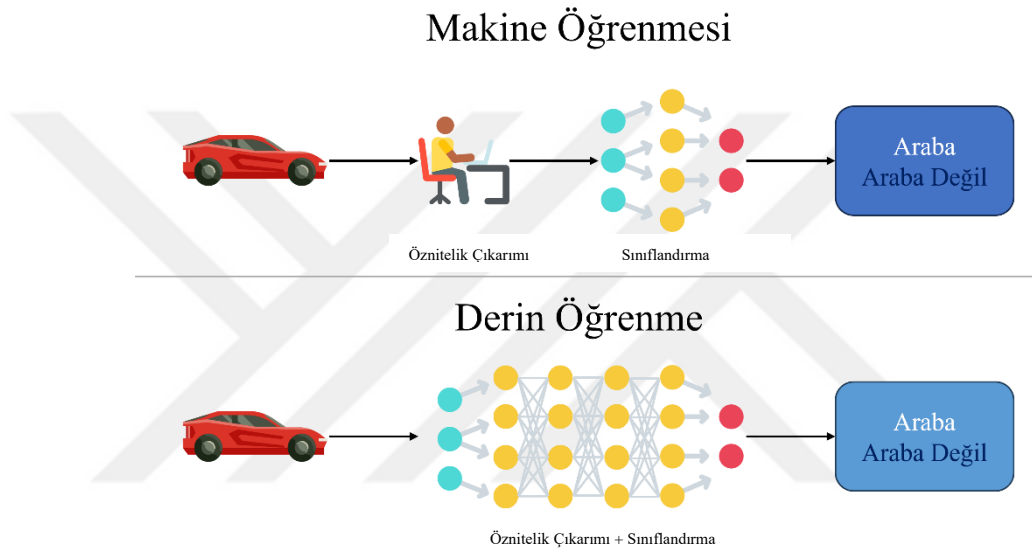
Makine öğrenimi, sağlık, finans, otomotiv, endüstriyel üretim gibi birçok alanda kullanılırken, veri analizi, tahmin, sınıflandırma gibi birçok farklı görevde de kullanılabilir.

3.3. Derin Öğrenme

Derin öğrenme, yapay sinir ağları gibi karmaşık ve çok katmanlı yapıları kullanarak veri üzerinde derinlemesine öğrenme süreçlerini gerçekleştiren bir makine öğrenimi dalıdır. Bu yöntem, büyük veri setleri üzerinde karmaşık desenleri tanımlama ve öğrenme yeteneği ile öne çıkar. Derin öğrenme algoritmaları, katmanlar arasında bilgiyi iletebilen ve veri üzerinde otomatik olarak özellik çıkarabilen yapay sinir

ağlarına dayanır. Özellikle resim tanıma, doğal dil işleme, ses tanıma gibi alanlarda derin öğrenme teknikleri büyük başarı elde etmiştir (Goodfellow ve ark., 2016).

Derin öğrenme, genellikle veri setlerinin öğrenilmesi ve karmaşık modellerin oluşturulması için yüksek hesaplama gücü gerektirir. Bu teknoloji, tıp, otomotiv, finans, endüstriyel üretim gibi birçok alanda kullanılarak veri analizi, tahmin, görüntü tanıma ve anlama gibi birçok farklı alanda çeşitli problemlere çözüm sunabilir. Makine öğrenmesi ve derin öğrenme arasındaki fark Şekil 2.8’de gösterildiği üzere çözüme dair özelliklerin belirlenmesinde yatmaktadır (Chollet, 2017).



Şekil 2.8. Makine Öğrenmesi ve Derin Öğrenme Karşılaştırma

Örnek olarak aynı sınıflandırma problemi üzerinde düşünülerek karşılaştırma yapılırsa makine öğrenmesine, bir arabayı tanıması için bir tekerleğe sahip olması gerektiğini ve arabanın spesifik şeklini belirtmek gerekirken, derin öğrenme bu özelliklerin çıkarımını kendisi yaparak bir görselin içinde araba olup olmadığını anlayarak sınıflandırabilir. Derin öğrenmenin çalışma alanlarını prensip olarak doğal dil işleme ve bu çalışmanın da içinde bulunduğu ve görüntü analitiği alanında kullanılan bilgisayarlı görü şeklinde belirtebiliriz.

3.3.1. Bilgisayarlı Görü (Computer Vision)

Bilgisayarlı görü, bilgisayarların görsel verileri işlemesi, anlamlandırması ve yorumlamasıyla ilgilenen bir alandır. Bu alan, görüntü veya video verileri üzerinde

çalışarak nesnelere algılama, tanıma, takip etme, sahne anlama ve analiz etme gibi işlevleri gerçekleştirmek için çeşitli algoritmalar ve teknikler kullanılır (Chollet, 2017).

Gelişmiş bilgisayarlı görü sistemleri, derin öğrenme gibi yapay zeka tekniklerinin kullanımıyla birlikte büyük veri setleri üzerinde karmaşık desenlerin tanımlanması ve öğrenilmesi konusunda önemli ilerlemeler kaydetmiştir. Görüntü işleme, kenar tespiti, renk analizi, nesne tanıma gibi temel işlemlerle başlayarak, bilgisayarlı görü sistemleri artık daha karmaşık görevleri yerine getirebilir bir duruma gelmiştir. Bu görevler arasında yüz tanıma, nesne tespiti, otonom araçlar ve bu çalışmanın konusu olan anomali tespiti gibi birçok çalışma sahasında yer bulmaktadır (Chollet, 2017).

Bilgisayarlı görü, tıp, otomotiv, güvenlik, endüstriyel üretim, tarım gibi çeşitli alanlarda kullanılmaktadır (Pang ve ark., 2021). Örnek olarak tıp alanında, tıbbi görüntüleme teknolojileri sayesinde hastalıkların erken teşhisi ve tedavisi için önemli bir rol oynamaktadır. Otomotivde, sürücüsüz araç teknolojileri, bilgisayarlı görü sistemlerine dayanarak çevre algılama ve otomasyon yeteneklerini geliştirmekte, güvenlik ve sürüş konforunu artırmaktadır. Bu şekilde, bilgisayarlı görü, çeşitli sektörlerdeki uygulamalarda önemli bir rol oynamakta ve ilerleyen teknolojiyle birlikte daha da geniş bir etki alanına sahip olmaktadır.


Bilgisayarlı görünün bu kadar ilerlemesinin ön büyük öncülerinden biri CNN temelli mimarileridir ve CNN mimarisi ile birlikte yaklaşık olarak 25 yıl gibi bir süreçte hesaplama hızı ve gücü anlamında büyük gelişmeler gösteren GPU (Graphical Processing Unit) teknolojisi olmuştur (Goodfellow ve ark., 2016). GPU gibi donanımların kapasite ve gelişmişlik düzeylerinin artması beraberinde yüksek kapasiteli işlem yoğun görevleri paralel olarak hesaplayabilme kabiliyetine sahip olması CNN mimarileri üzerine yapılan çalışmaların artmasına ve gelişmesine yardımcı olmuştur (Chollet, 2017).

3.3.2. Evrişimli Sinir Ağları (Convolutional Neural Network)

CNN, derin öğrenme sinir ağlarının en bilinen türlerinden biridir. CNN'ler, özellikle iki boyutlu sistemlerde görsel veri analizi, tanıma ve sınıflandırmada, nesne tespiti ve takibi gibi alanlarda sıklıkla tercih edilir. CNN'ler, genellikle görüntü işleme problemlerini çözmek için tasarlanmışlardır, tam bağlı katmanların birbirleriyle

oluşturduğu karmaşık ve hesaplama maliyeti yüksek çözüme alternatif olarak, görüntüler üzerine evrişim filtreleri uygulayarak görüntülerdeki desenleri ve özellikleri tanıma konusunda oldukça etkilidirler (Prince, 2023).

Görseller içindeki bağlamın semantik bilgisini keşfetme konusunda yeteneklidir. Bu filtreler alt katmanlarda yatay, dikey kenarlar gibi özellikleri keşfedebilirken, daha ileri katmanlarda cisimleri tanıyabilecek kadar karmaşık özellikleri keşfetme yeteneğini elde eder. Şekil 2.9'da gösterildiği gibi görüntü üzerinde gezen filtreler, görüntülerin bölgesel özelliklerinin keşfedilmesini sağlayarak daha derin katmanlarda bağlamsal bilgiyi de elde ederek, mimarilere göre bir temsil elde edilmesini sağlamaktadır (Chollet, 2017).



Şekil 2.9. CNN Mimarisi

Kaynak: Ramsundar ve Zadeh., (2018)

CNN kullanılarak oluşturulan mimarilerin temel yapı taşları şunlardır;

- **Evrişim Katmanları (Convolutional Layers):** Görüntüler üzerinde özellikleri tanımak için kullanılan bu katmanlar, belirli boyutlarda bir filtre veya kernel ile evrişim işlemi uygular. Bu işlem, görüntü üzerindeki çeşitli özellikleri (kenarlar, köşeler, doku desenleri vb.) algılamak için tasarlanmıştır (Chollet, 2017).
- **Aktivasyon Fonksiyonları (Activation Functions):** Evrişim sonrası katmanlardan gelen çıktıların üzerine uygulanan bu fonksiyonlar, ağırlıklı girdiyi işleyerek ve belirli bir eşiği geçen değerler için bir çıkış üreterek modele non-lineerlik kazandırır. ReLU (Rectified Linear Activation) yaygın olarak kullanılan aktivasyon fonksiyonlarından biridir (Goodfellow ve ark., 2016).
- **Havuzlama Katmanları (Pooling Layers):** Evrişim sonrası elde edilen çıktıları küçültmek ve önemli özellikleri vurgulamak için kullanılır. Genellikle

maksimum veya ortalama deęerlerin alındığı küçük bölgeler üzerinde işlem yaparlar (Chollet, 2017).


- Tam Baęlantılı Katmanlar (Fully Connected Layers): CNN'in sonunda bulunan bu katmanlar, önceki katmanlardan gelen özelliklerin sınıflandırma veya regresyon gibi sonuçları elde etmek için kullanılır. Bu katmanlar, genellikle bir veya daha fazla yoğun (dense) katman içerir (Chollet, 2017).

CNN'lerin en büyük avantajlarından biri, özellikle büyük ve karmaşık görsel veri setlerinde yüksek performans gösterme kabiliyetidir. Bu modeller, öğrenme verileri üzerinden ağırlıkları otomatik olarak ayarlayabilen bir geri yayılım (backpropagation) süreciyle eğitilirler. Bu sayede, doğru çıktıya ulaşmak için modelin parametreleri, filtre ağırlıkları ve önyargı (bias) parametresi gibi deęerlerin optimize edilmesi sağlanır (Goodfellow ve ark., 2016).

CNN'ler, sadece görüntü işleme problemleriyle sınırlı değildir; ses tanıma, doğal dil işleme, zaman serileri ve çeşitli alanlardaki veri analizi ve analitięi gibi birçok alanda da başarıyla kullanılmaktadır. Her ne kadar görsel verilerle özdeşleşmiş olsalarda, genel olarak özellik çıkarma ve desen tanıma problemlerinde geniş bir uygulama sahası bulunmaktadır (Jurafsky ve Martin, 2023).

3.3.2.1. VGGNet (Vision Geometry Group Network)

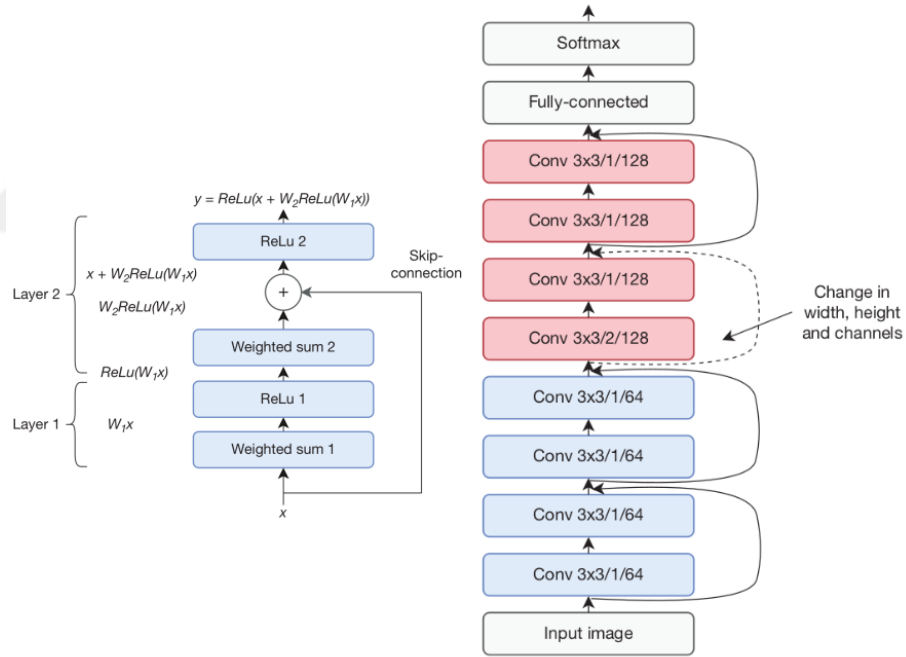
VGGNet, Oxford Üniversitesi'nin Visual Geometry Group (VGG) tarafından geliştirilmiş, ağ derinliğinin doğruluk üzerindeki etkisini inceleyen bir CNN mimarisidir (Simonyan & Zisserman, 2015). Bu amaçla, ağın derinliğini çekirdek boyutu ve adım gibi dięer parametreleri ayarlamaya gerek kalmadan derinleştirebilecekleri bir mimari geliştirdiler. Tüm evrişim katmanlarında 3×3 sabit bir çekirdek boyutu ve adım (stride) olarak 1 kullanıldı. Adım (stride) 1 kullanıldığında, bir sonraki katmanın genişliği ve yüksekliği, uygun dolgulama (padding) kullanıldığında, önceki katmanın genişliği ve yüksekliğiyle aynı olur (Simonyan ve Zisserman, 2015). Bu, VGGNet'in genişliği ve yüksekliği çok küçük hale gelme sorunu olmadan istenildięi kadar derin olmasını sağlamaktadır (Ramsundar ve Zadeh, 2018). Şekil 2.10'da gösterilen 16 evrişim ve havuzlama katmanları ile tam baęlı (dense) katman içeren VGG-16, 2014 yılında ImageNet resim sınıflandırma yarışmasında, önceki modellerle karşılaştırıldığında daha yüksek başarımler elde ederek gücünü kanıtlamıştır (Ekman, 2021).



Şekil 2.10. VGG16 Ağ Model Mimarisi

3.3.2.2. Artık bağlantı ağı (Residual Network - ResNet)

ResNet Ağ Mimarisi “Residual Network” (Artık Bağlantı Ağı) için bir kısaltmadır. Bu mimaride evrişim ağ blokları arasında atlamalı bağlantı (Skip Connection) adını verdikleri bir yöntemle ağırlık paylaşımını sağlar (Ekman, 2021). Bu yöntemde önceki evrişim bloklarının çıktıları sonraki evrişim bloklarına beslenirken, önceki evrişim bloğunun giriş parametreleri de kendinden sonraki evrişim bloğunun girişine beslenir (Şekil 2.11).



Şekil 2.11. (Sağda) Artık Bağlantı Gösterimi, (Solda) ResNet Ağ Mimarisi

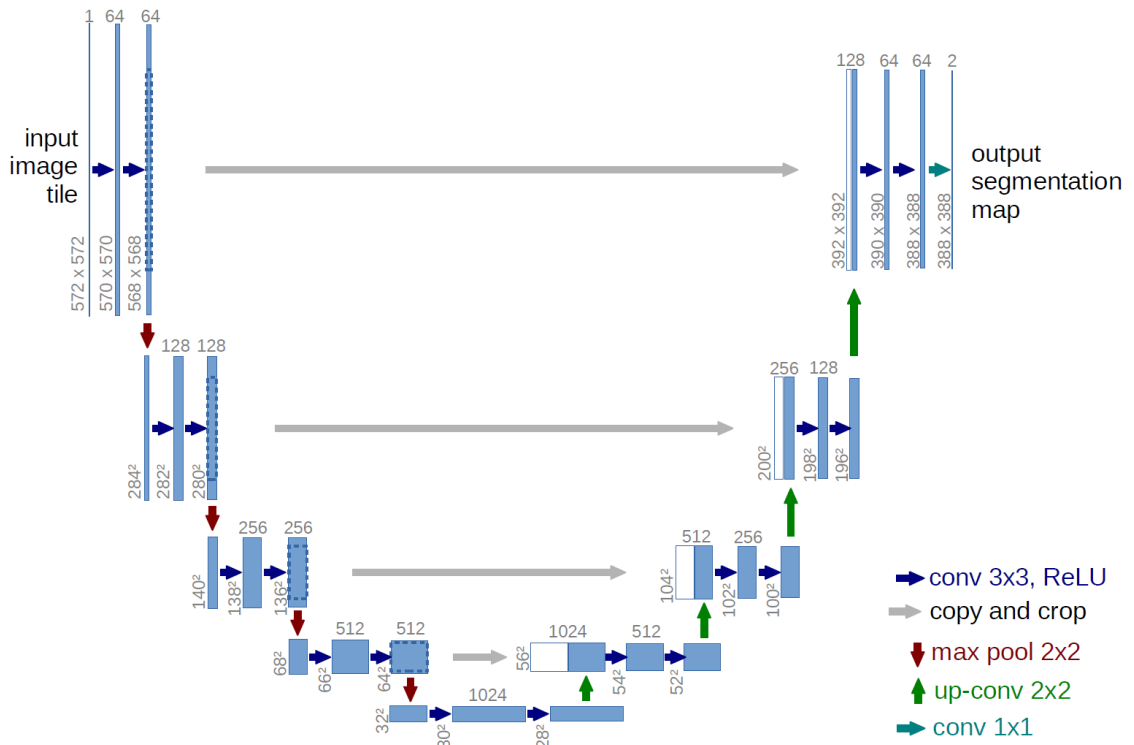
Kaynak: Ekman, M., (2021)

Derin öğrenmede ağırlıkların uygun bir şekilde başlatılması (initialization), grup normalizasyonunun (batch normalization) uygulanması ve ağ içindeki non-lineerliği sağlamak amacıyla katmanlara uygulanan ReLU gibi aktivasyon fonksiyonlarının kullanılması gibi kaybolan gradyan sorununu çözmeye yönelik adımlar atıldıktan sonra bile derin ağların hala öğrenme sorunları olduğu ortaya çıktı.

ResNet'ler, derin ağlardaki katman sayısı arttıkça eğitimi zorlaştıran kaybolan gradyan problemini çözmek için geliştirilmiştir (Ekman, 2021).

3.3.2.3. Birleştirilmiş Ağ (Unified Neetwork – U-Net)

U-Net, ilk olarak Ronneberg ve ark. (2015) tarafından geliştirilen ve medikal görüntü segmentasyonunda kullanılan bir derin öğrenme modelidir. Şekil 2.12’de gösterildiği üzere kodlayıcı bir evrişim ağı ve bu ağı çözen, transpoz evrişim yapan bir dekonvolüsyon ağının oluşturduğu “U” şeklindeki görüntüden dolayı ve iki ayrı ağı birleştirmesi sebebiyle “Unified” sözcüğünün baş harfi kullanılarak U-Net ismini almıştır (Ronneberg ve ark., 2015).



Şekil 2.12. UNet Modeli Mimarisi

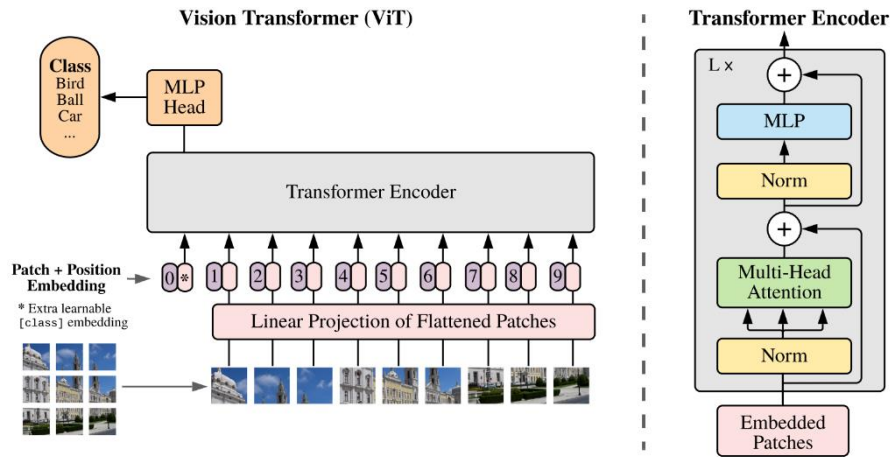
Kaynak: Ronneberg ve ark., (2015)

"UNet" terimi, "birleştirme (downsampling)" ve "genişletme (upsampling)" adımlarının birleştirilmesiyle oluşturulan bu ağ yapısını tanımlar. Ağ yapısı, birçok evrişimli katman içerir ve kodlayıcı ağ (encoder) ve kod çözücü ağ (decoder) aşamalarından oluşur. Kodlayıcı aşaması, görüntüyü gittikçe daha düşük boyutlu özellik haritalarına indirirken, kod çözücü aşaması bu özellik haritalarını orijinal boyutlarına getirir. Genellikle sınırlı veri bulunan biyomedikal ve tıbbi görüntüleme

problemlerinin analizi ve analitiği için yapılan çalışmalarda kullanışlı bir mimari sunan bir derin öğrenme modelidir (Ronneberg ve ark., 2015).

3.3.2.4. Bilgisayarlı görü için transformer: ViT (Vision Transformer)

2017 yılında Google araştırma ekibi tarafından asıl olarak DDİ problemlerine çözüm olarak sundukları, mevcut yöntemlere ek birçok yenilik sağladıkları ve günümüze kadar semantik anlamda da somut başarılar elde eden dönüştürücü mimarisini tanıtmışlardır (Vaswani ve ark., 2017). Bu mimariden ilham alan Dosovitskiy ve ark. (2020) Vision Transformer (ViT) modelini önermişlerdir. ViT, geleneksel olarak DDİ için tasarlanmış Transformer modeline benzeyen bir yapı kullanır. 2 boyutlu resimleri işlemek için resimleri sabit boyutlu kareler halinde düzleştirilmiş yamalar şeklinde kullanır. Transformer, sabit boyutlu gizli uzay vektörü kullanır ve bu vektörlerin boyutunu, eğitilebilir bir lineer projeksiyonla düzleştirilmiş yamalara eşler. Pozisyon bilgisinin korunması amacıyla yama vektörlerine pozisyon vektörleri eklenir. Bu aşamanın çıktıları Transformer mimarisinin öz dikkat katmanı ve diğer katmanların bulunduğu kodlayıcı bloğuna beslenir. Son olarak ise GELU (Gaussian Error Linear Unit) aktivasyon fonksiyonuna sahip iki katmanlı bir ağdan geçirilerek sınıflandırma yapılır (Şekil 2.13).



Şekil 2.13. ViT Mimarisi

Kaynak: Dosovitskiy, A. ve ark., (2020)

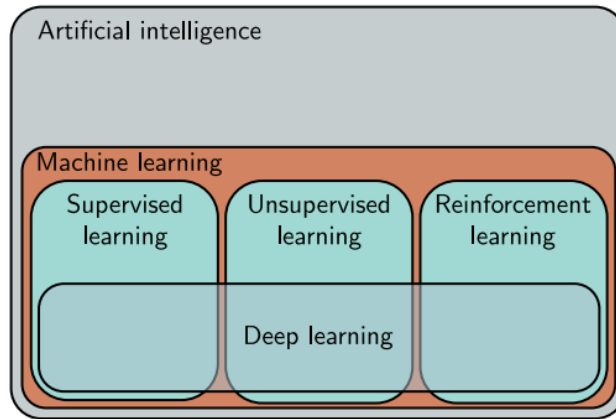
Bu kısımlar problemlere özgü farklı modifikasyonlar ile de kullanılabilirler. ViT'nin bir alternatifi olarak, girdi dizisi bir CNN'in özellik haritasından

oluşturulabilir. Bu hibrit modelde, yama gömme projeksiyonu, bir CNN özellik haritasından çıkarılarak yamalara uygulanabilir.

3.4. Yapay Zeka için Öğrenme Paradigmaları

Bilgisayar biliminin kurucularından olan, Turing testine adını veren İngiliz Matematikçi ve bilgisayar bilimci Alan Turing tarafından ortaya atılan “Makineler Düşünebilir mi?” fikrinin üzerinden geçen yarım asırdan fazla bir zamanda birçok bilim insanı bu konu üzerine çalışmış ve çeşitli problemlerin çözümünde birçok farklı yöntem üretmişler ve paradigmlar geliştirmişlerdir (Turing, 1950).

Temel olarak yapay zeka özelinde makine öğrenimini değerlendirildiğinde, mevcut verilerin matematiksel fonksiyonlara, modellere, uydurulmaya çalışıldığı bir yöntem elde edilmesi amaçlanmaktadır. Genel olarak, denetimli öğrenme, denetimsiz öğrenme ve pekiştirmeli öğrenme olmak üzere üçe ayrılabilir (Şekil 2.14). Derin öğrenme ise bu alanların her birine katkı sağlamaktadır (Prince, 2023).



Şekil 2.14. Makine Öğrenmesi Paradigmaları ve Derin Öğrenme İlişkisi

Kaynak: Prince, S.J., (2023)

Günümüzde yapay zeka ile ilgili elde edilen en son çalışmalar her ne kadar çığır açıcı olsa da, çözümler genelde bir veya birkaç problemin çözümüne odaklanabilmekte ve çözebilmektedir. Her şeyden önce günümüz yapay zeka teknolojileri verinin varlığı ile mümkün olabilmektedir. Şekil 2.14’de belirtilen paradigmalara ek olarak az veri ile çözüm sunulmak istendiğinde bazı farklı paradigmlar üzerinden de geliştirmeler yapılabilmektedir (Şekil 2.15). Burada

bahsedilen paradigmlar, verilerin işleme yöntemleri ve verilerden elde edilmek istenen durumlara göre farklılık göstermektedirler.



Şekil 2.15. Yapay Zeka Öğrenme Paradigmaları Şeması

3.4.1. Denetimli Öğrenme (Supervised Learning)

Denetimli öğrenme, makine öğrenimi alanında önemli bir paradigmadır. Bu yöntem, etiketlenmiş verilerle çalışır ve girdi verilerinin belirli çıktılarla ilişkilendirildiği durumlarda kullanılır. Bu ilişkiyi öğrenerek, yeni girdiler için doğru çıktılar tahmin etmeye çalışır (Goodfellow ve ark., 2016). Bu veri seti, girdi-çıkı çiftlerinden oluşur. Algoritma, bu veri setindeki girdi-çıkı ilişkilerini öğrenerek, yeni girdi verileriyle karşılaştığında doğru çıktılar tahmin etmeye çalışır. Örneğin, bir el yazısı rakam tanıma sistemi için, eğitim verisi, el yazısı rakamların görüntülerinden oluşur ve her bir görüntü hangi rakama karşılık geldiği bilgisiyle etiketlenmiştir. Bu verileri kullanan bir algoritma, yeni bir el yazısı rakamı görüntüsü aldığı anda, o rakamın hangi sayıya karşılık geldiğini tahmin etmeye çalışır. Denetimli öğrenme, genellikle sınıflandırma ve regresyon olmak üzere iki temel kategorideki problemleri çözer:

- Sınıflandırma (Classification): Bu türde, bir girdi verisi, belirli bir sınıfa ait olup olmadığını belirlemek için kullanılır. Örneğin, bir e-posta mesajının spam olup olmadığını belirleme veya bir resmin içeriğini tanımlama gibi görevler sınıflandırma problemlerine örnek olarak verilebilir (Prince, 2023).
- Regresyon (Regression): Girdi verileri arasındaki ilişkiyi anlayarak, sonraki girdiler için modelin sürekli bir çıktı tahmin etmesini sağlar. Bir evin fiyatını veya hava durumu tahminlerini içeren problemler regresyon örnekleridir (Prince, 2023).

Denetimli öğrenme, gerçek dünya uygulamalarında oldukça yaygın olarak kullanılır ve çeşitli alanlarda, veri analitiğinden yapay zeka uygulamalarına kadar geniş bir yelpazede kullanım potansiyeline sahiptir.

3.4.2. Denetimsiz Öğrenme (Unsupervised Learning)

Denetimsiz öğrenme, girdi verilerine karşılık gelen çıktı etiketlerinin olmaması durumunda kullanılan bir makine öğrenimi yöntemidir. Bu durumda veri etiketli olmadığı için denetim de yapılamamaktadır (Prince, 2023). Bu yöntem, veri setindeki desenleri ve yapılardaki doğal ilişkileri keşfetmeye odaklanır. Denetimsiz öğrenme, genellikle veri setindeki örüntüleri algılamak, veri noktalarını kümelere ayırmak veya veri setindeki yapılardan anlamlı bilgiler çıkarmak için kullanılır (Goodfellow ve ark., 2016). Temel olarak iki ana kategoriye ayrılır:

- Kümeleme (Clustering): Veri noktalarını benzerliklerine göre gruplara ayırmak için kullanılır. Veri setindeki yapısal ilişkileri veya benzer özelliklere sahip veri noktalarını belirlemek için kullanışlıdır. Örneğin, pazarlama analizi için müşteri segmentasyonu yapmak veya genetik veri analizinde gen gruplarını belirlemek için kümeleme algoritmaları kullanılabilir (Goodfellow ve ark., 2016).
- Boyut Azaltma (Dimensionality Reduction): Yüksek boyutlu veri setlerindeki karmaşıklığı azaltmak ve önemli özellikleri vurgulamak için kullanılır. Veri setlerinin özellik sayısını azaltarak veri setinin anlaşılabilirliğini artırır ve model oluşturma sürecini hızlandırabilir. Örneğin, PCA (Principal Component Analysis) veya t-SNE (t-Distributed Stochastic Neighbor Embedding) gibi teknikler boyut azaltma için kullanılabilir (Goodfellow ve ark., 2016).

Denetimsiz öğrenme, etiketlenmemiş verilerle çalıştığı için denetimli öğrenmeye kıyasla daha genel ve esnek bir yaklaşım sunar. Bu yöntem, veri setindeki yapıları keşfetmek ve bu yapılar üzerinden anlamlı bilgiler çıkarmak için kullanılır. Veri setlerindeki gizli ilişkileri ve yapıları anlamak için oldukça faydalıdır.


3.4.3. Pekiştirmeli Öğrenme (Reinforcement Learning)

Takviyeli öğrenme, bir yapay zeka öğrenme yöntemidir ve bir ajanın belirli bir ortamda belli bir hedefe ulaşmak için en uygun eylemleri seçmeyi öğrendiği bir paradigmadır. Takviyeli öğrenme, genellikle bir ajanın çevresiyle etkileşim halinde olduğu durumlarda kullanılır. Bu çevre, ajanın eylemlerinin sonuçlarını belirler ve ajanın hedefine ulaşmak için hangi eylemleri seçmesi gerektiğini öğrenmesini sağlar. Bu öğrenme yönteminde, ajan bir dizi durum ve durumlara bağlı olarak alabileceği bir dizi eylem arasında hareket eder. Her durumda ajan, bu duruma bağlı olarak bir eylem

seçer ve bu eylem çevre üzerinde bir etki yapar. Çevre bu eyleme tepki verir ve ajan yeni bir duruma geçer. Bu süreç, ajanın hedefine ulaşmak için deneyim kazandıkça, ödüllendirme veya cezalandırma yoluyla en iyi eylemleri seçmesini öğrenmesini sağlar (Chollet, 2017).

Takviyeli öğrenme temelde şu unsurları içerir:

- Ajan (Agent): Kararlar alan ve çevreyle etkileşime geçen yapay zeka ajanıdır.
- Çevre (Environment): Ajanın etkileşimde bulunduğu, eylemlerinin sonuçlarını gösteren sistem veya ortamdır.
- Durum (State): Ajanın bulunduğu anlık durum veya konumu ifade eder. Ajanın eylemleri, bu durumların değişmesine yol açar.
- Eylem (Action): Ajanın belirli durumlarda alabileceği hareketler veya seçeneklerdir.
- Ödül (Reward): Ajanın belirli bir durumda belirli bir eylem için aldığı geri bildirimdir. Bu ödül, ajanın performansını değerlendirmesine ve gelecekteki eylemlerini belirlemesine yardımcı olur.
- Hedef (Goal): Ajanın ulaşmayı amaçladığı belirli bir hedeftir veya istenen durumdur.



Şekil 2.16. Pekiştirmeli Öğrenme

Takviyeli öğrenme algoritmaları, ajanın hedefe ulaşmak için en iyi stratejiyi öğrenmesini sağlayacak şekilde tasarlanır. Bu öğrenme süreci genellikle deneme yanılma yoluyla gerçekleşir ve ajan, çeşitli eylemleri deneyerek ödülleri maksimize etmeye çalışır. Öğrenme süreci ajanın deneyimlerinden ve aldığı geri bildirimlerden ilerler ve zamanla daha iyi bir strateji geliştirir.

3.4.4. Birkaç Adımda Öğrenme (Few-Shot Learning)

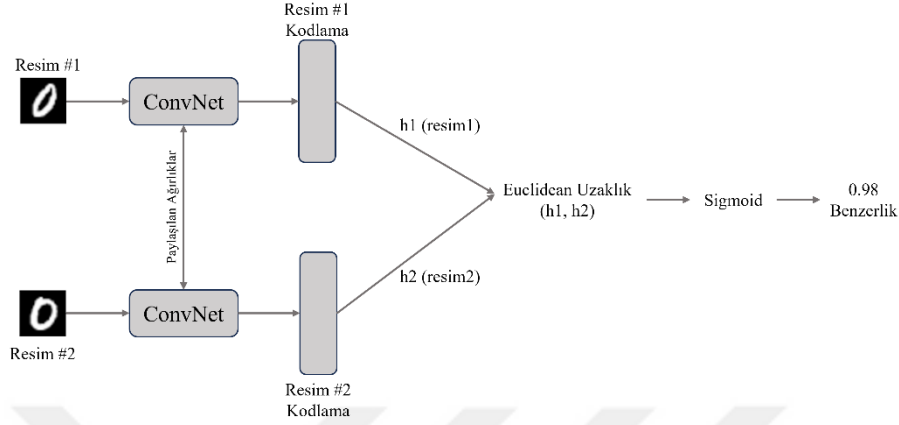
Bu yöntem örnek ya da hatta hiç örnek olmadan yeni kavramları öğrenebilmeyi sağlayan, "few-shot learning" olarak adlandırılan bir kavramı ortaya çıkarmıştır. İnsanlar, makinelerin aksine, birkaç örnekten hızla bir nesnenin temel özelliklerini kavrayabilir. İnsan bir elma gördüğü zaman, hızla şekil, renk ve doku gibi temel özellikleri algılayabilir. Farklı renk, şekil veya dokuya sahip bir elma gördüğünde bunu sınıflandırabilir. Ayrıca insanlar, benzer nesnelere tanımlamak için ortak fiziksel özellikleri genelleştirme yeteneğine sahiptirler. Ancak günümüz makine öğrenme modelleri, özellikle derin öğrenme modelleri, sınırlı örneklerle öğrenmekte zorlanır ve eğitim sürecinde geniş bir etiketli veri setine ihtiyaç duyarlar. Karakteristiği olarak çok fazla örnek ve etiket içermeyen, öngörülemeyen bazı görevler için insanların az veriyle öğrenme yeteneğini taklit etmeyi amaçlayan "few-shot learning" modelleri geliştirilmiştir. Bu modeller, yeni kavramlara az sayıda düzeltme örneği ile adapte olmayı sağlayarak önceki deneyimleri kullanma yeteneğini taklit eder. Few-shot learning, zero-shot learning, one-shot learning, Bayesian program learning, yetersiz kaynaklı öğrenme ve alan genelleştirme gibi çeşitli yöntemleri içerir. Tüm bunlar, hedef alanlarda çok az etiketli ya da hatta etiketlenmemiş verilerin bulunduğu durumları ele almak için transfer öğrenmenin birer varyasyonu olarak kabul edilir. Bu yaklaşım, veri kısıtlı ya da hedef alandaki veri neredeyse hiç bulunmayan senaryolar için geleneksel makine öğrenme paradigmasının aksine yeni bir yaklaşım sunar (Ramsundar & Zadeh, 2018).

3.4.5. Tek Adımda Öğrenme (One-Shot Learning)

Geleneksel olarak, derin öğrenme modelleri eğitilmesi ve başarılı sonuçlar elde edilmesi için yüksek miktarda çeşitli veriye ihtiyaç duymaktadır. AlexNet mimarisi nesne tespiti yapmak üzere ILSVRC veri setini kullanarak büyük miktarda veri eğitilmiştir. Ancak, bilişsel bilimlerde yapılan araştırmalar, insanların bazen sadece birkaç örnekten karmaşık kavramları öğrenebileceğini göstermektedir. Bir bebek için ilk kez bir zürafayı görmek bu örneklerden biridir. Bebek, hayvanat bahçesinde sadece bir zürafayı gördüğünde sonrasında gördüğü tüm zürafaları tanıma eğilimindedir (Ramsundar ve Zadeh, 2018).

Siyam Ağı (Siamese Network) yaklaşımı, belirli bir sınıfa ait tek bir görüntü örneği verildiğinde, ağın bu sınıfa ait aday örnekleri tanıyabilmesi üzerine yoğunlaşır.

Eđitim ařamasında, ađ, girdi grnt iftlerinin zelliklerindeki farkları ğrenir ve ardından eđitilmiř bir model, belirli bir sınıfa ait tek bir rnek grntsyle aday verilerin bu sınıfa ait olup olmadıđını tanıyabilir (řekil 2.17).

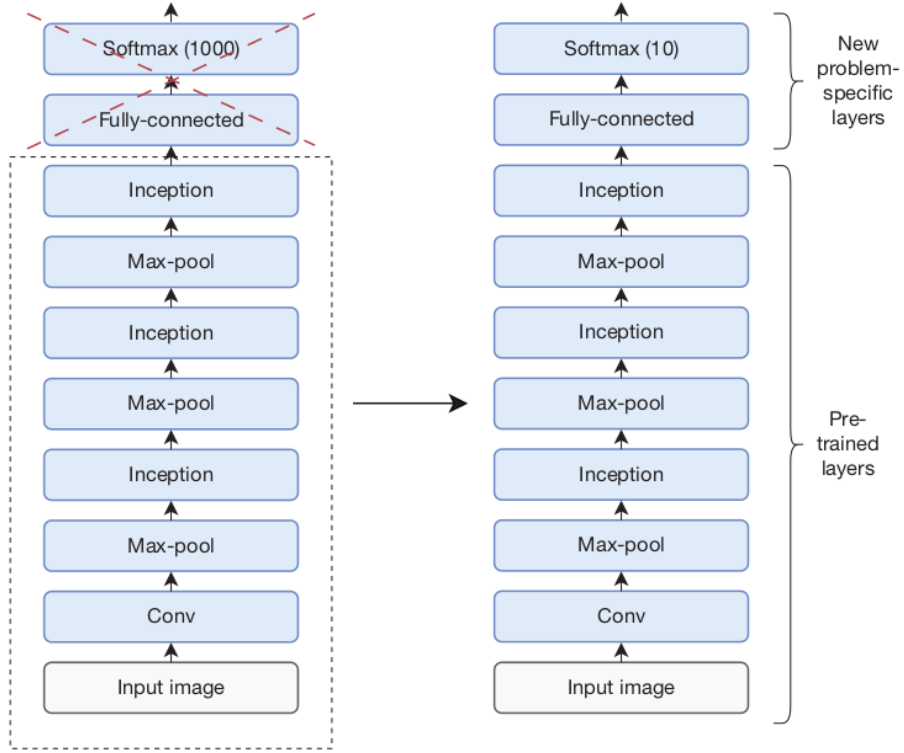


řekil 2.17. One-Shot Learning (Siamese Ađ Modeli)

3.4.6. Transfer ğrenmesi (Transfer Learning)

Transfer ğrenme, bir sistem tarafından ğrenilen bilginin bařka bir sistem iin hızlı bir řekilde yeni durumlara, grevlere ve ortamlara adapte olabilmesi amacıyla aktarılmasını sađlamaktadır. Sınırlı miktarda verinin bulunduđu durumlarda hedef problemleri zebilme yeteneđi kazandırmaktadır (Yang ve ark., 2020). rnek olarak, ImageNet veya COCO (Common Objects in Context) gibi ok byk bir veri seti zerinde eđitilmiř bir modeli alıp, bu modelin ğrendiđi yetenekleri bařka bir benzer, ancak farklı bir grevde kullanmak transfer ğrenmenin temel prensibidir (Ekman, 2021). Bu yaklařım, zellikle kısıtlı veri setleri veya zel grevler iin etkilidir. Belirli bir konuda sahip olunan kısıtlı veriyi, nceden eđitilmiř bir model kullanarak oluřturulan veri seti zerinde kısa srede eđitip, hedef grev iin zm sunulabilir.

Transfer ğrenme, genellikle ađın son katmanlarını, zelleřtirilecek yeni greve uyacak řekilde deđiřtirerek yapılır (řekil 2.18). rnek olarak YOLOv5 modeli COCO gibi byk bir veri seti zerinde eđitilmiřtir. YOLO modelinin ıktı katmanlarından nceki katmanlar sabit tutulup, son katmanlar spesifik olarak greve zg olacak řekilde eđitilebilir (řekil 2.18). Bu sayede, ađın nceki ğrenmiř olduđu genel zellikler, yeni grev iin benzer zelliklerin tanımlanmasını yardımcı olması beklenir. Bu yntem, zellikle sınırlı veri setleriyle alıřırken ve nceden eđitilmiř modellerin sađladıđı genel zelliklerin yeni grevlerde de kullanılmasını gerektiđi durumlarda bařarım ve zaman gibi kazanımlar sađlamaktadır (Yang ve ark., 2020).



Şekil 2.18. Transfer Öğrenmesi

Kaynak: Ekman, M., 2021

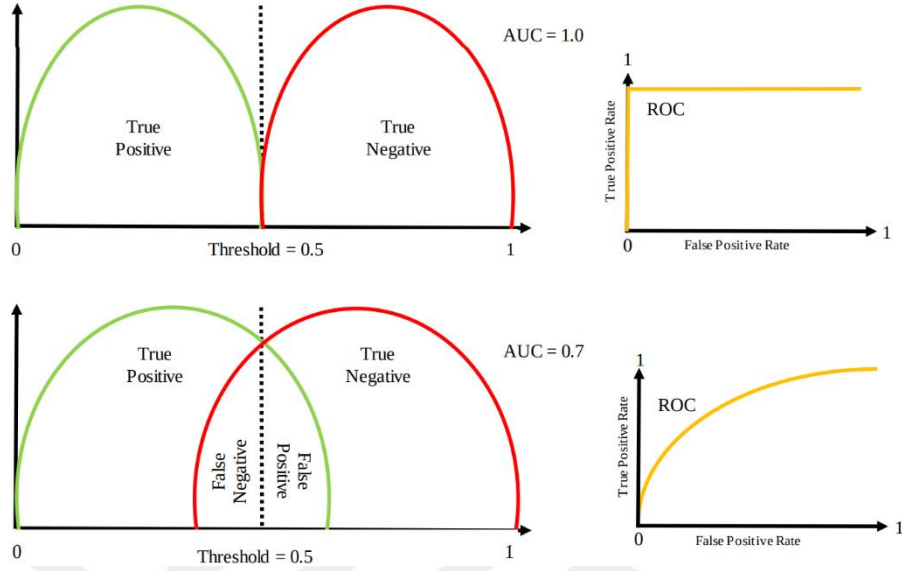
3.4.7 Değerlendirme Metriği Olarak ROC-AUC

Makine öğrenimi ve veri bilimi, farklı problemlerin çözümünde çeşitli ölçütlerin kullanıldığı geniş bir alanı kapsar. Dengeli sınıflandırma problemlerinde, her sınıfın eşit olarak temsil edildiği durumlarda, doğruluk (accuracy) genellikle yaygın bir metrik olarak kullanılır. Bununla birlikte, sınıf dengesizliği, çoklu etiketli sınıflandırma veya sıralama problemleri gibi senaryolarda, doğruluk yanıltıcı olabilir (Géron, 2019).

Bu durumlarda, hassasiyet (precision) ve geri çağırma (recall) gibi metrikler daha önemli hale gelebilir. Hassasiyet, doğru pozitif olarak tahminlenen örneklerin gerçekten pozitif olma oranını gösterirken, geri çağırma, gerçek pozitiflerin ne kadarının doğru şekilde tahminlendiğini ifade eder. Bu metrikler, özellikle sınıf dengesizliği olan durumlarda daha bilgilendirici olabilir (Géron, 2019).

ROC Eğrisi (Receiver Operating Characteristics - Alıcı İşlem Özelliği) ve altındaki alan AUC (Area Under The Curve), sınıflandırma modellerinin performansını değerlendirmede kullanılan önemli bir ölçüttür. AUC, ROC eğrisinin

altındaki alanı ifade ederek, bu eğri altındaki genel performansı ölçer (Chollet, 2017). Farklı sınıflandırma eşiklerinde doğruluk ve yanlış alarm oranlarını karşılaştırarak model performansını görselleştirir (Şekil 2.19).



Şekil 2.19. ROC-AUC Eğrisi Gösterimi

3.5. Üretim Bantlarında Anomali Tespit Yöntemleri


Üretim bantlarındaki kalite kontrol süreçleri marka değeri ve müşteri memnuniyeti kriterleri için önemli bir konu başlığıdır. Bu seri üretim bantlarındaki anormallik tespitleri endüstri 1.0'da sadece insan gücünü kapsarken, Endüstri 4.0'a doğru arzın artması ile makine destekli ve günümüzde yapay zeka destekli sistemler halini almıştır. İlk olarak insan gücü ve geleneksel yöntemlerin kullanılması ile başlayan bu süreç her aşamada daha da gelişerek, makine destekli ve günümüzde bir trend olan yapay zeka temelli yöntemler kullanılarak daha etkin çözümler sunulmaya çalışılmıştır. Yaygın olarak mevcut veri seti için istatistiksel analiz, eşik değerlendirme ve regresyon analizi gibi tekniklerin kullanılmasını içermektedir. Karar ağaç yapıları özellikle anomali gibi aykırı değerlerin veya nadir olayların tespitinde kullanılabilir. Geleneksel yöntemlerden sayılabilir. Yapay zeka tabanlı yöntemler için ise özellikle, yapay zekanın bir alt çalışma alanı olan derin öğrenme altında bilgisayarlı görü alanındaki çalışmalar temel alınmaktadır.

4. AZ SAYIDA VERİ İLE KUSURLU ÜRÜN TESPİTİ UYGULAMASI

Bu bölümde üretim hattında belirli bir görev için veri toplama, anomali uygulamasının gerçekleştirilmesi ve değerlendirilmesi ele alınacaktır. İlk olarak kısıt veri prensibi üzere metal içecek kutuları kullanılarak hatasız ve az sayıda anomaliden oluşan bir veri seti oluşturuldu. Bu veri seti literatürde mevcut olan RD4AD, RegAD modelleri ve bu çalışmada önerilen YOLOv8 segmentasyon + RegAD hibrit modelin sonuçları test edilerek karşılaştırıldı.

4.1. Veri Seti

Uygulama için kullanılacak veri seti, bir konveyör üzerinde deney ortamı kurularak metal kutu içecek kutularının kapak kısımları üzerinden elde edilmiştir. Toplanan veri setinde bulunan 400 kusursuz ve 10 kusurlu fotoğraf üzerinde çalışma yapılmıştır. Fotoğrafların çekiminde Basler Ace 2 model kamera kullanılarak yüksek kalite fotoğrafların elde edilmesi sağlanmıştır.

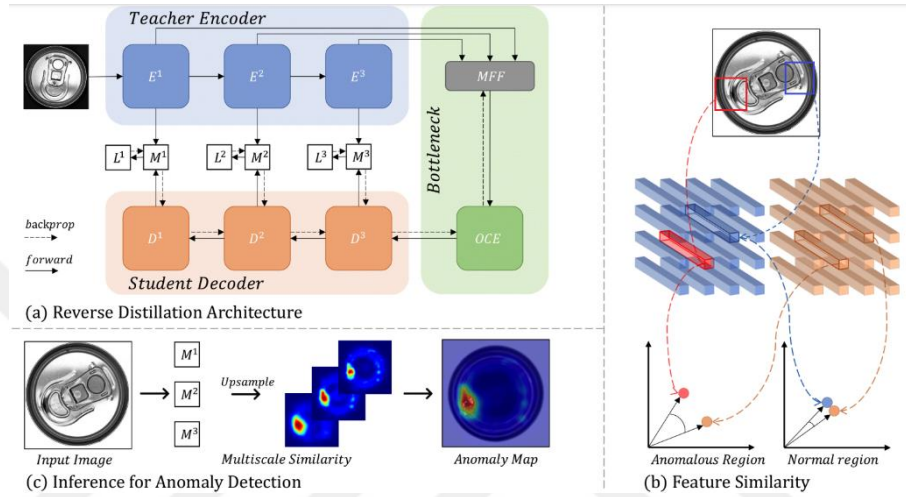


Şekil 3.1. Verilerin Toplandığı Konveyör

4.2. Yöntem

Uygulama olarak iki yöntem tercih edilmiştir. Bunlardan ilki MVTEC veri seti ile denetimsiz öğrenme paradigması üzerinden bilgi damıtma (Knowledge

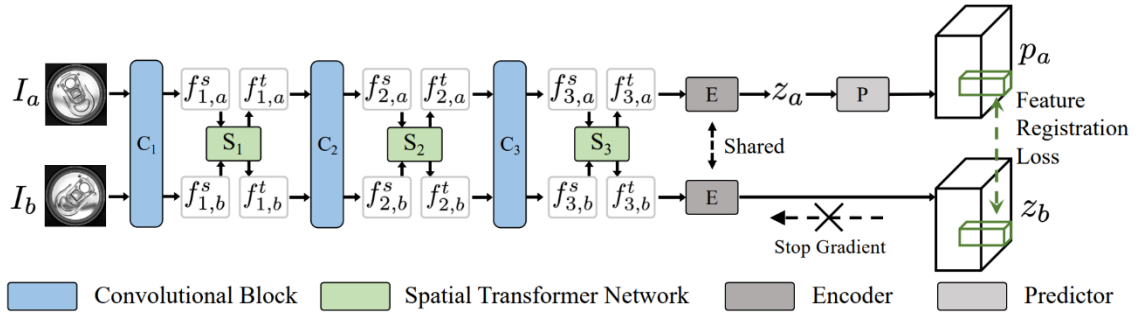
Distillation) yöntemi ile normalde iki ayrı eğitimden oluşan öğretmen ve öğrenci modelleri yerine, öğretmen ağından çıkan gömmelerin (Embedding) öğrenci model tarafından damıtılarak öğrenilmesi sağlanmıştır (Deng ve Li, 2022). Bu yöntem ile metal içecek kutularından oluşan 400 kusursuz resim içeren veri seti 75 dönem (epoch) boyunca omurga olarak (backbone) ResNet-50 mimarisini kullanarak kodlayıcı (encoder) ve bir darboğaz (bottleneck) ağından geçerek kod çözücüye (decoder) beslenen bir mimari ile eğitim yapılmıştır (Şekil 3.1).



Şekil 3.2. Tercih Edilen İlk Modelin Mimarisi

Kaynak: Deng ve Li, (2022)


İkinci denenen yöntem ise Huang ve ark. (2022) tarafından önerilen her kategori için ayrı bir eğitim yerine, insanın tespit mekanizmasını temel alan, bir anomalinin ne olduğunu bildiği durumda, farklı bir kategori için anomaliyi tespit etmede az sayıda kusursuz destek seti ile karşılaştırarak tespit edebilen bir yöntem baz alınmıştır. Bu yöntemde modelin eğitildiği kategorilere özgü kusurları öğrenmek yerine kategoriden bağımsız özellikleri öğrenilmesini amaçlamaktadır. Test aşamasında, normal görüntüler destek seti olarak verildiğinde, hedef kategorinin özelliklerinin normal dağılımı, istatistiksel bir dağılım tahminçisi ile hesaplanır. Öğrenilmiş istatistiksel normal dağılımın dışında kalan test örnekleri anormallik olarak kabul edilir. Şekil 3.3’de gösterildiği gibi hedef kategori için farklı resimler ResNet tipi, son katmanların yerine her blok için bir STN (Spatial Transform Network - Uzamsal Dönüşüm Ağı) eklenmiş bir mimari ile özelliklerin paylaşılmasını sağlar. Siamese ağı ise bir özellik çıkarıcı olarak davranır (Huang ve ark., 2022).



Şekil 3.3. Tercih Edilen İkinci Modelin Mimarisi

Kaynak: Huang ve ark., (2022)

Son olarak anomali tespitinde YOLOv8 segmentasyon ve RegAD modellerini hibrit bir şekilde önerilen model kullanmıştır. Şekil 3.4'te gösterilen bu yaklaşımda 25 anomali resmi üzerinde 50 dönem boyunca eğitilen YOLOv8 modelinin çıktıları, 8 atışta eğitilen RegAD modeli ile birleştirilerek her iki modelin güçlü yanlarının birleştirilmesi ve göreve özgü başarılı bir modelin elde edilmesi sağlandı. Bu yöntemde her iki modelde eşit ağırlıklı olarak kullanıldı. İlk olarak her iki modelden elde edilen anomali çıktılarının aritmetik ortalaması alınarak belli bir eşik değeri kullanılarak anomalilerin tahmin edilmesi sağlandı. Sonuç olarak ise oluşturulan üzerinde diğer ayrı ayrı kullanılan RD4AD ve RegAD modellerine göre başarılı sonuçlar elde edilmiştir.



Şekil 3.4. Önerilen Birleştirilmiş Hibrit Model

4.3. Geliştirme Ortamı

Uygulama çıktıları, yapay zeka çalışmalarında sıkça kullanılan Python programlama dili ile elde edilmiştir. Yapay zeka için uygulama çatısı (Framework) olarak hem baz alınan çalışmalar hem de çıktıların oluşturulmasında Meta Inc.

tarafından geliştirilen PyTorch kullanılmıştır. Fiziksel ortam ve donanım olarak Intel i7 işlemci, 64 GB RAM (Random Access Memory) ve Nvidia GeForce 2080Ti ekran kartı bulunan bir makine üzerinde eğitim ve test aşamaları gerçekleştirilmiştir.




5. BULGULAR

Literatürde mevcut olan RD4AD ve RegAD mimarilerinin, orijinal çalışmalarının içinde mevcut olan ve MVTec anomali veri seti ile yaptıkları testlerinin sonuçları Tablo 5.1’de belirtilmiştir (Bergmann ve ark., 2019). Diğer anomali tespiti çalışmalarında da sıklıkla tercih edilen ROC-AUC metriği kullanılarak başarımlar ifade edilmiştir. Bu çalışma için önerilen modeli değerlendirme amacıyla tercih edilen, literatürde RD4AD olarak tanımlanan model ile yapılan çalışmalar sonucunda bazı anomali çıktı örnekleri Şekil 5.1’de gösterildiği gibi elde edilmiştir.

Tablo 5.1. MVTec Veri Seti için İlgili Modellerin Orijinal Başarım Ölçümleri

Yöntemler	MVTec Veri Seti (Ortalama)
RD4AD	%98.5
RegAD (Shot = 2)	%85.7
RegAD (Shot = 4)	%88.2
RegAD (Shot = 8)	%91.2

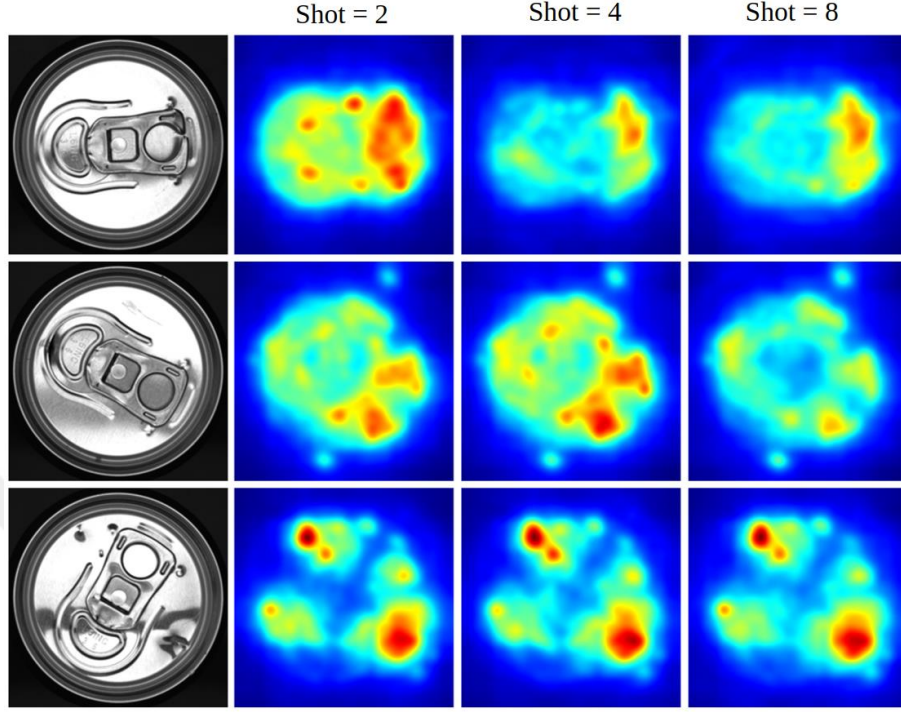
Kaynak: Deng, H. ve Li,X. (2022); Huang ve ark., (2022)



Şekil 5.1. RD4AD Modeli ile Elde Edilen Çıktılar


İkinci olarak denenen model olan RegAD’nin Şekil 5.2’de gösterilen, sırasıyla 2, 4 ve 8 atışta eğitim yapılan modelin ise çıktıları Tablo 5.1 ve Tablo 5.2’de gösterildiği gibi daha az başarımla elde edilmiştir. Bunun en önemli sebebi ise modelin

metal iecek kutu kapađının yanındaki ukurlar gibi anomali olmayan resimlerde de anomali ıktısı vermesidir. Őekil 5.2’de gsterildiđi gibi atıř sayısı artıka anomalileri daha iyi tespit etmeye bařladıđı grlmektedir.



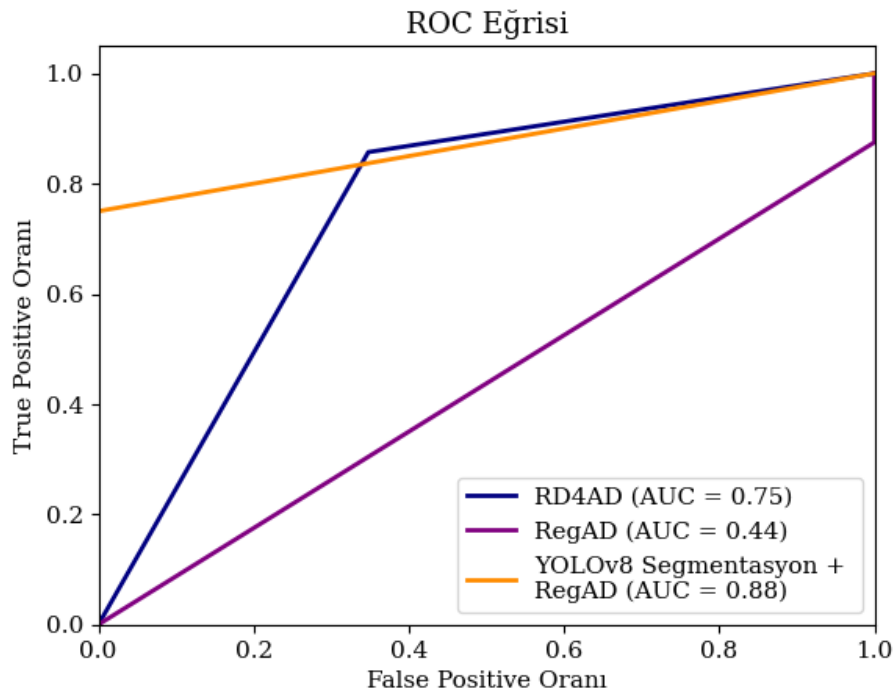
Őekil 5.2. RegAD Model ıktıları

Hibrit olarak nerilen modelde Őekil 5.3’te gsterildiđi gibi her resim iin sol stteki ıktı RegAD modelinden alınan ıktı, sađ stteki resim YOLOv8 segmentasyon modelinin ıktılarını belirtmektedir. Őekil 5.3’teki sol alttaki ıktı ise ađırlıklı olarak hibrit olarak kullanılan modelin son anomali ıktısını belli bir eřik deđeri kullanarak grselleřtirmektedir. Őekil 5.3’te sađ alttaki resimler ise segmentasyon olmadan tahmin edilen ıktıları gstermektedir.



Őekil 5.3. YOLOv8 Segmentasyon + RegAD ile Elde Edilen ıktılar

RD4AD, RegAD modellerinin ve bu çalışmada önerilen YOLOv8 + RegAD hibrit modelin, metal içecek kutularından oluşan veri seti üzerinde yapılan çıktı ve ölçümlerin sonuçları Tablo 5.2’de sayısal ve Şekil 5.4’te görsel olarak belirtilmiştir. Tablo 5.2’de RegAD ile yapılan testlerin düşük çıkmasının sebebi diğer modellere göre daha fazla yanlış pozitif sinyal üretmesinden kaynaklanmaktadır. Tablo 5.2’deki değerlendirme ölçütü lojistik regresyon problemlerinin ölçümünde tercih edilen ROC-AUC metriği kullanılarak elde edilmiştir. ROC-AUC metriklerinin ölçümünde sklearn kütüphanesinin ilgili metodları kullanılmıştır (Pedregosa ve ark., 2011).



Şekil 5.4. Değerlendirme Testleri ROC-AUC Eğrisi

Tablo 5.2. Veri Seti için Yöntemlerin Değerlendirme Metrikleri (ROC-AUC)

Yöntemler	Veri Seti (Metal İçecek Kutusu)
RD4AD	%75
RegAD (Shot = 8)	%44
YOLOv8 Segmentasyon + RegAD	%88

6. SONUÇLAR VE ÖNERİLER

Üretim hatlarında, etiketlenmiş verinin az olduğu alanlarda, anomali tespiti üzerinde çalışırken, etiketli anomali sayısı genellikle yeterli sayıda bulunmamaktadır. Bu çalışma yapılırken kullanılan yöntemlerden biri, genellikle denetimli öğrenme ile eğitilen ve çok sayıda etiketli veri kullanan modellerden farklı olarak, yaklaşık 400 kusursuz örnekle eğitilen bir RD4AD modeli kullanıldı. Tablo 5.1'de sayısal olarak ve Şekil 5.1'de görsel olarak, sınırlı veriyle elde edilen bu modelin oldukça başarılı sonuçlar verdiği gösterilebilir.

RD4AD modeli, sayısal ve görsel çıktılar açısından kısmen RegAD modelinden daha iyi performans gösteriyor gibi görünmektedir. RD4AD modeli, sınırlı veriyle eğitildiğinde iyi sonuçlar vermesinin yanı sıra, RegAD modelinin sadece 2, 4 ve 8 resimden oluşan setlerden çıkarım yapabildiği de göz önünde bulundurulmalıdır. Bu durumda, neredeyse hiç anomali örneği bulunmayan senaryolarda, RegAD modelinin daha iyi performans gösterebileceği öngörülebilir. Ancak, RegAD modeli, ışık yansımaları gibi anomali olmayan durumlarda yanlış pozitif sinyaller ürettiği görülmektedir. Şekil 5.2'de gösterilen RegAD çıktılarında bu tür durumlar gözlemlenebilir.

Şekil 5.4'te görüleceği üzere RD4AD AUC değeri 0.75 olan bu model, ortalama bir performansa sahip görünmektedir. Burada pozitif sınıfı negatif sınıftan ayırt etme yeteneği makul düzeyde olduğu ancak, mükemmel olmaktan uzak konumdadır.

RegAD (Mor Çizgi) AUC değeri 0.44 olan bu model, rastgele tahmin yapan bir modelden ($AUC = 0.5$) daha kötü performans göstermektedir. Bu modelin, pozitif ve negatif sınıfları ayırt etme yeteneği oldukça düşük ve güvenilir olmaktan uzak olduğunu göstermektedir.

YOLOv8 Segmentasyon + RegAD (Turuncu Çizgi) AUC değeri 0.88 ile bu kombinasyon, incelenen üç model içinde en iyi performansı göstermektedir. Bu, modelin pozitif ve negatif sınıfları ayırt etme yeteneğinin oldukça yüksek olduğunu ve güvenilir sonuçlar ürettiğini yansıtmaktadır.

Bu çalışmada asıl olarak önerilen, göreve özgü olan veri seti üzerinde kullanılan YOLOv8 segmentasyon + RegAD hibrit modeli, lojistik regresyon görevlerinde kullanılan ROC-AUC başarımlarına dayanarak değerlendirildi. Tablo 5.2'de sayısal olarak belirtildiği, Şekil 5.3 ve Şekil 5.4'te görsel olarak görüldüğü üzere, göreve özel veri seti üzerinde yaklaşık olarak %10 oranında daha başarılı sonuçlar elde edilmiştir.

Yapılan çalışmalar ve testler sonucunda literatürde kendini kanıtlamış olan RD4AD ve RegAD modellerinin MVTEC anomali veri seti üzerinde başarılı sonuçlar elde etmelerine karşın özelleştirilmiş veri setinde beklenen çıktıları veremedikleri gözlenmektedir.

Günümüz teknolojileri kullanılarak henüz tek bir model veya mimari ile genel ve başarılı bir anomali tespit yöntemi tam olarak elde edilememiştir. RD4AD mimarisi RegAD'ye göre metrik olarak başarılı olarak ölçülmesinin en önemli faktörü RD4AD mimarisinde veri seti üzerinde eğitim yapılarak ağırlıkların öğrenilmesidir. RD4AD, 400 anomali bulunmayan resimlerden oluşan veri seti üzerinde 75 dönem boyunca eğitilmiştir. RegAD'de de ise sadece 2, 4 veya 8 resimlik setler üzerinde anomali tespiti yapılmaktadır. RegAD için atış sayısı arttıkça anomali tespit başarısının da arttığı gözlemlenmektedir. Oluşturulan veri seti içinde yeterli sayıda anomali içeren resim olmamasından dolayı resim seti sayısı orijinal makaleye bağlı kalınarak yapılmıştır.

Tablo 6.1. Her İki Veri Seti için Yöntemlerin Değerlendirme Metrikleri

Yöntemler	MVTEC Veri Seti (Ortalama)	Veri Seti (Metal İçecek Kutusu)
RD4AD	%98.5	%75
RegAD (Shot = 2)	%85.7	%42
RegAD (Shot = 4)	%88.2	%42
RegAD (Shot = 8)	%91.2	%44
YOLOv8 Segmentasyon + RegAD (Shot = 8)	%77	%88

MVTEC veri seti üzerinde başarılı olan modeller, MVTEC veri seti dışında özelleştirilmiş veri seti üzerinde aynı başarıyı gösteremedikleri görülebilmektedir

(Tablo 6.1). Sonuç olarak Tablo 6.1’den hareketle RD4AD ve RegAD için her veri seti için geliştirilebilir modeller olmadıkları ve MVTEC veri seti üzerinde başarılı olacak şekilde tasarlandıkları söylenebilir. Fakat bu çalışmada önerilen YOLOv8 Segmentasyon + RegAD hibrit modeli genel bir yöntem sunmasa da göreve özgü ve daha adaptif bir yöntem olduğu değerlendirilebilir. Bu yöntemin, MVTEC veri seti ile birlikte bu çalışma için toplanan veri seti üzerinde yapılan testlerin sonuçlarını gösteren Tablo 6.1’e bakıldığında, %10 daha başarılı olduğu ölçülmüştür. Testlerde, oluşturulan veri seti üzerinde anomali tespiti için doğru pozitif sinyallerin üretilmesi gereken durumlarda eksiklikler ve anomali olmayan kısımların yanlışlıkla anomali olarak tespit edilmesi gibi durumlar gözlemlenmiş ve bu yanlış pozitif durumları ROC-AUC metriği ile sayısallaştırarak hesaplanmıştır. Yani, bu ölçümde doğru ve yanlış pozitif sinyaller arasındaki ilişki üzerinde hesaplamalar yapılmıştır. Çalışmada az sayıda veri kullanılması nedeniyle, metriklerin hesaplanmasında görseller semantik olarak değerlendirilerek ve python programı içerisinde yer alan sklearn kütüphanesinin ilgili metodları kullanılarak ölçümler gerçekleştirilmiştir (Pedregosa ve ark., 2011).

YOLOv8 Segmentasyon modelinin eğitimi sırasında farklı optimizasyon algoritmaları ile daha başarılı model elde edilmesi sağlanabilir. Bu çalışmanın sonuçları, benzer akademik araştırmalar için de bir temel oluşturarak, bu alanda daha geniş ve çeşitli veri setleri üzerinde yapılabilecek testler için yol gösterici olabilir. Bu sayede, endüstriyel tesislerde yapılan kalite kontrol uygulamalarında yapay zeka ve makine öğrenimi tekniklerinin gelişimi ve uygulanabilirliği daha da ileriye taşınabilir.

KAYNAKLAR

- Akçay, S., Atapour-Abarghouei, A., & Breckon, T. P.**, (2019). Skip-GANomaly: Skip Connected and Adversarially Trained Encoder-Decoder Anomaly Detection, *2019 International Joint Conference on Neural Networks (IJCNN)*, Budapest, Hungary, 1-8, doi: 10.1109/IJCNN.2019.8851808.
- Bergmann, P., Fauser, M., Sattlegger, D., & Steger, C.** (2019). MVTec AD - A Comprehensive Real-World Dataset for Unsupervised Anomaly Detection. *2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 9584-9592. DOI: 10.1109/CVPR.2019.00982.
- Chollet, F.** (2017). *Deep learning with python*. New York. Manning Publications.
- Damacharla, P., Rao, A., Ringenberg, J., & Javaid, A. Y.** (2021, May). TLU-net: a deep learning approach for automatic steel surface defect detection. In *2021 International Conference on Applied Artificial Intelligence (ICAPAI)*, 1-6.
- Deng, H., & Li, X.** (2022). Anomaly Detection via Reverse Distillation from One-Class Embedding, in *2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, New Orleans, LA, USA, 9727-9736. doi: 10.1109/CVPR52688.2022.00951.
- Deshpande, A. M., Minai, A. A., & Kumar, M.** (2020). One-Shot Recognition of Manufacturing Defects in Steel Surfaces. *Procedia Manufacturing*, 48, 1064–1071. doi: 10.1016/j.promfg.2020.05.146
- Dosovitskiy, A., Beyer, L., Kolesnikov, A., Weissenborn, D., Zhai, X., Unterthiner, T. & Housby, N.** (2020). An image is worth 16x16 words: Transformers for image recognition at scale. *arXiv preprint arXiv:2010.11929*.
- Dube, D.C., Çom, M., & Akar, M.** (2023). Tekstil Proseslerinde Zamansal Model Tabanlı Toplu Anomali Tespiti. *Otomatik Kontrol Ulusal Toplantısı TOK*. İstanbul Teknik Üniversitesi Ayazağa Yerleşkesi'nde yer alan Süleyman Demirel Kültür Merkezi. 2023, 14-16 Eylül.
- Duman, B., & Özsoy, K.** (2021). Toz yatak füzyon birleştirme eklemeli imalatta kusur tespiti için öğrenme aktarımı kullanan derin öğrenme tabanlı bir yaklaşım. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 37(1), 361-376. <https://doi.org/10.17341/gazimmfd.870436>
- Ekman, M.** (2021). *Learning Deep Learning Theory and Practice of Neural Networks, Computer Vision, Natural Language Processing, and Transformers*. New York. Addison-Wesley Professional.
- Goodfellow, I., Bengio, Y., & Courville, A.** (2016). *Deep Learning*. MIT Press.

- Géron, A.** (2019). *Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems*. O'Reilly Media.
- Guansong Pang, Chunhua Shen, Longbing Cao., & Anton van den Hengel.** (2021). Deep Learning for Anomaly Detection: A Review. *ACM Comput. Surv.* 54(2), 1-38. doi:10.1145/3439950.
- Huang, C., Guan, H., Jiang, A., Zhang, Y., Spratlin, M., & Wang, Y.** (2022). Registration based Few-Shot Anomaly Detection. In *European Conference on Computer Vision (ECCV)*.
- Jurafsky, D., & Martin, J. H.** (2023). *Speech and Language Processing*. <https://web.stanford.edu/~jurafsky/slp3/> adresinden erişildi.
- Kaynar, O., Işık, Y. E., Görmez, Y. & Demirkoparan, F.,** (2017). Fabric defect detection with LBP-GLMC, *2017 International Artificial Intelligence and Data Processing Symposium (IDAP)*, Malatya, Turkey, 2017, 1-5. doi: 10.1109/IDAP.2017.8090188.
- Li, Bh., Hou, Bc., Yu, Wt., Lu, Xb, & Yang, Cw.** (2017). Applications of artificial intelligence in intelligent manufacturing: a review. *Frontiers Inf Technol Electronic Eng*, 18, 86–96. <https://doi.org/10.1631/FITEE.1601885>.
- Lu, Q., Lin, J., Luo, L., Zhang, Y., & Zhu, W.** (2022). A supervised approach for automated surface defect detection in ceramic tile quality control. *Advanced Engineering Informatics*, 53, 101692. doi: 10.1016/j.aei.2022.101692.
- Netzer, M., Bach, J., Puchta, A., Gönheimer, P. & Fleischer, J.,** (2022). Process Segmented based Intelligent Anomaly Detection in Highly Flexible Production Machines under Low Machine Data Availability. *Procedia CIRP*, 107, 647-652.
- Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Dubourg, V., Vanderplas, J., Passos, A., Cournapeau, D., Brucher, M., Perrot, M., & Duchesnay, E.** (2011). Scikit-learn: Machine Learning in Python. *Journal of Machine Learning Research*, 12, 2825–2830.
- Prince, S. J.** (2023). *Understanding Deep Learning*. MIT Press.
- Ramsundar, B., & Zadeh, R.B.** (2018). *Convolutional Neural Network by TensorFlow for Deep Learning*, ss. 119-146. O'Reilly Media, CA, USA.
- Ronneberger, O., Fischer, P., Brox, T.** (2015). U-Net: Convolutional Networks for Biomedical Image Segmentation. In: Navab, N., Hornegger, J., Wells, W., Frangi, A. (eds) *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015*. MICCAI 2015. *Lecture Notes in Computer Science()*, vol 9351. Springer, Cham. doi:10.1007/978-3-319-24574-4_28
- Shutub, A. & Cohen, Y.** (2016), *Introduction to Industrial Engineering (2nd Ed.)*. CRC Press. NY, USA.

- Simonyan, K., & Zisserman, A.** (2015). Very deep convolutional networks for large-scale image recognition. *3rd International Conference on Learning Representations (ICLR 2015)*, 1–14.
- Smith, A.D., Du, S., & Kurien, A.** (2023) Vision Transformers for Anomaly Detection and Localisation in Leather Surface Defect Classification Based on Low-Resolution Images and a Small Dataset. *Appl. Sci.* 13, 8716. <https://doi.org/10.3390/app13158716>
- Turing, A.M.** (1950). Computing Machinery and Intelligence. *Mind*, 59, 433-460. <http://dx.doi.org/10.1093/mind/LIX.236.433>
- Üzen, H., Türkoğlu, M., Arı, A., & Hanbay, D.** (2022). Piksel seviyesinde yüzey hata tespiti için InceptionV3 tabanlı zenginleştirilmiş öznetelik entegrasyon ağ mimarisi. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 38(2), 721-732. <https://doi.org/10.17341/gazimmfd.1024425>
- Yao, H., & Yu, W.** (2022). Generalizable industrial visual anomaly detection with self-induction vision transformer. *arXiv preprint arXiv:2211.12311*.
- Yang, Q., Zhang, Y., Dai, W., & Pan, S.** (2020). *Few-Shot Learning*. In *Transfer Learning* (ss. 177-195). Cambridge: Cambridge University Press. [doi:10.1017/9781139061773.015](https://doi.org/10.1017/9781139061773.015)

ÖZGEÇMİŞ

Ad-Soyad : Ali Akyol
Mevcut Çalıştığı Kurum : Çözüm Makina Sanayi Ticaret Limited Şirketi
Ünvanı : Ar-Ge Merkezi Direktörü
Lisans : Marmara Üniversitesi / Ekonometri
Y.Lisans : Haliç Üniversitesi Endüstri Mühendisliği

İş Deneyimi (Son 3 Yıl)

Çözüm Makina Sanayi ve Ticaret Limited Şirketi Ar-Ge Merkezi Takım Lideri /Ar-Ge Merkezi Direktörü 2021-

Aybey Elektronik / Ar-Ge Uzmanı 2021

Bulut Makina / Ar-Ge Uzmanı 2021

Yayınlar:

1. Imani, H., Hosen, M. I., Feryad, V., & Akyol, A. (2023, March). Efficient Object Detection Model for Edge Devices. In International Conference on Advanced Engineering, Technology and Applications (pp. 83-94). Cham: Springer Nature Switzerland.