



T.C.
BURSA TEKNİK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

ÜRETİMDE GÖRÜNTÜ TABANLI ANOMALİ TESPİTİ: TEKSTİL VERİSİ
İLE YAPAY ZEKÂ DESTEKLİ GÖMÜLÜ SİSTEM UYGULAMASI

YÜKSEK LİSANS TEZİ

Veysel AKBAŞ

Mekatronik Mühendisliği Anabilim Dalı

Mekatronik Mühendisliği Tezli Yüksek Lisans Programı

TEMMUZ 2025

T.C.
BURSA TEKNİK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

ÜRETİMDE GÖRÜNTÜ TABANLI ANOMALİ TESPİTİ: TEKSTİL
VERİSİ İLE YAPAY ZEKÂ DESTEKLİ GÖMÜLÜ SİSTEM
UYGULAMASI

YÜKSEK LİSANS TEZİ

Veysel AKBAŞ

(22434972603)

ORCID: 0009-0008-0554-2569

Mekatronik Mühendisliği Anabilim Dalı
Mekatronik Mühendisliği Tezli Yüksek Lisans Programı

Danışman: Dr. Öğr. Üyesi Ahmet Remzi ÖZCAN

ORCID: 0000-0002-4093-1059

TEMMUZ 2025

BTÜ, Lisansüstü Eğitim Enstitüsü'nün 22434972603 numaralı Yüksek Lisans Öğrencisi Veysel AKBAŞ, ilgili yönetmeliklerin belirlediği gerekli tüm şartları yerine getirdikten sonra hazırladığı “ÜRETİMDE GÖRÜNTÜ TABANLI ANOMALİ TESPİTİ: TEKSTİL VERİSİ İLE YAPAY ZEKÂ DESTEKLİ GÖMÜLÜ SİSTEM UYGULAMASI” başlıklı tezini aşağıda imzaları olan jüri önünde başarı ile sunmuştur.

Tez Danışmanı: **Dr. Öğr. Üyesi Ahmet Remzi ÖZCAN**
Bursa Teknik Üniversitesi

Jüri Üyeleri: **Prof. Dr. Ahmet MERT**
Bursa Teknik Üniversitesi

Doç. Dr. Metin BİLGİN
Uludağ Üniversitesi

Savunma Tarihi : 21 Temmuz 2025

Teslim Tarihi : / / 2025



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

İNTİHAL BEYANI

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

Adı SOYADI: Veysel AKBAŞ

İmzası:

(Faint signature watermark)



Eşim, kızım ve aileme,

ÖNSÖZ

Çalışmalarım boyunca bana her türlü destek ve öneriyi veren Dr. Ahmet Remzi ÖZCAN 'a tüm içtenliğimle teşekkür ederim.

Üretimde veri analizi ve anomali tespiti çalışmalarına öz veriyle katkıda bulunan ve tecrübe edinmemi sağlayan Bosch San. Ve Tic. A.Ş. 'ye teşekkürü borç bilirim.

Beni tüm süreçte yalnız bırakmayan ve destekleyen eşim Çiğdem AKBAŞ' a ve kızım Derin AKBAŞ' a sevgi saygı ve teşekkürlerimi sunarım.

Temmuz 2025

Veysel AKBAŞ

İÇİNDEKİLER

	<u>Sayfa</u>
ÖNSÖZ.....	viii
İÇİNDEKİLER	ix
KISALTMALAR.....	xiv
ÇİZELGE LİSTESİ.....	xvi
ŞEKİL LİSTESİ.....	xvii
ÖZET.....	xix
SUMMARY	20
1. GİRİŞ	21
1.1 Çalışmanın Amacı ve Kapsamı	22
1.2 Problem Tanımı Üretim Hatlarında Yüzey Kusurlarının Tespiti.....	23
1.3 Araştırmanın Önemi ve Katkıları.....	24
1.4 Tezin Organizasyonu	25
2. LİTERATÜR İNCELEMESİ	28
2.1 Anomali Tespiti Hakkında Literatür Analizi	28
2.1.1 Anomali tespiti hakkında yıllara göre yayın dağılımı	29
2.1.2 Anomali tespitinin konulara göre dağılımı	30
2.1.3 Anomali tespiti hakkında anahtar kelime dağılımı	32
2.1.4 Anomali tespiti hakkında kurumsal katkı dağılımı.....	33
2.1.5 Anomali tespiti çalışmalarının ülkelere göre dağılımı.....	37
2.1.6 Anomali tespiti hakkında literatür incelemesi özeti	38
2.2 Görüntü Tabanlı Anomali Tespiti Hakkında Literatür Analizi.....	39
3. GÖRÜNTÜ TABANLI ANOMALİ TESPİTİ.....	41
3.1 Geleneksel Görüntü İşleme Tabanlı Yöntemler.....	44
3.1.1 İstatistiksel ve histogram tabanlı yaklaşımlar	44
3.1.2 Doku analizi ve filtreleme tabanlı yaklaşımlar	45
3.2 Makine Öğrenmesi Tabanlı Yöntemler.....	46
3.2.1 Denetimli öğrenme yaklaşımları.....	47
3.2.2 Yarı denetimli öğrenme yaklaşımları	50
3.2.3 Denetimsiz öğrenme yaklaşımları	53
3.3 Derin Öğrenme Tabanlı Anomali Tespiti Yöntemleri	55
3.3.1 Yeniden yapılandırma tabanlı yaklaşımlar	55
3.3.2 Özellik haritası ve temsil öğrenme tabanlı yaklaşımlar.....	55

3.3.3 Üretici veya karşıt öğrenme tabanlı yaklaşımlar	56
3.3.4 Öz denetimli ve öğretmen öğrenci stratejileri	57
3.3.5 Transformer tabanlı yaklaşımlar ve güncel mimari uygulamalar.....	58
3.4 Transfer Öğrenme ve İnce Ayarlama Teknikleri	59
3.4.1 Önceden eğitilmiş modeller ve uygulama alanları	60
3.4.2 İnce ayarlama tabanlı anomali tespiti	61
3.5 Anomali Skorlama ve Eşikleme Teknikleri	62
3.5.1 Sabit ve adaptif eşikleme yöntemleri.....	62
3.5.2 Hibrit ve çok aşamalı eşikleme yaklaşımları.....	63
3.6 Model Açıklanabilirliği ve Sonuçların Görselleştirilmesi	63
3.6.1 Anomali haritaları ve ısı haritası teknikleri	64
3.7 Hafifletilmiş Uygulamalar İçin Optimizasyon Teknikleri	64
3.8 Endüstride ve Tekstil Sektöründe Otomatik Kusur Tespiti Uygulamaları	65
4. ÜRETİMDE GÖRSEL ANOMALİ TESPİTİ ÖN ÇALIŞMALAR	67
4.1 Anomali Kütüphanesi ve Bileşenleri	68
4.2 Görsel Anomali Tespiti Modelleri	70
4.3 EfficientAD Modeli	70
4.3.1 Girdi görselinin temsili	71
4.3.2 Öğretmen ağı ile özellik çıkartımı	71
4.3.3 Öğrenci ağı ile taklit ve fark analizi	72
4.3.4 Sert özellik kaybı	72
4.3.5 Öğrencinin genellemesini sınırlama	73
4.3.6 Mantıksal anomaliler için otomatik kodlayıcı	73
4.3.7 Anomali haritası ve skoru.....	73
4.4 FastFlow Modeli	74
4.4.1 Girdi ve özellik haritası	75
4.4.2 Yamalara ayırma ve vektöre çevirme	75
4.4.3 Normalizing flow ile yoğunluk modelleme	75
4.4.4 Kayıp fonksiyonu.....	76
4.4.5 Anomali skoru hesaplama.....	76
4.5 PatchCore Modeli.....	77
4.5.1 Girdi ve özellik çıkartımı.....	78
4.5.2 Core-Set seçimi ile bellek optimizasyonu	78
4.5.3 Test aşaması ve benzerlik hesaplama	79
4.5.4 Görüntü seviyesi anomali skoru	79
4.6 GLASS Modeli.....	80
4.6.1 Dağılım varsayımları	80
4.6.2 Global anomali üretimi	81
4.6.3 Gradyan yükseliş	81
4.6.4 Kesikli projeksiyon.....	82
4.6.5 Hiperküre projeksiyonu:	83
4.6.6 LAS: Lokal anomali üretimi.....	83

4.6.7 Kayıp fonksiyonları	84
4.6.8 Çıkarsama ve anomali skorları	85
4.7 Derin Öğrenmede Omurga (Backbone)	86
4.7.1 Anomali tespiti modellerinde omurganın rolü.....	86
4.7.2 3. Transfer öğrenme.....	87
4.7.3 4. Hafifletilmiş hesaplama	87
4.7.4 Backbone ağların yapısı ve çalışma prensibi: ResNet örneği.....	88
4.8 Uygulama Aşamasında Seçilen Model ve Donanımlar	89
5. DEĞERLENDİRME METRİKLERİ	92
5.1 Image Level Metrikler.....	92
5.1.1 Image level AUROC performans hesaplaması.....	92
5.1.2 Image level F1-score performans hesaplaması.....	94
5.2 Piksel Level Metrikler.....	95
5.2.1 Piksel level AUROC hesaplaması	95
5.2.2 Piksel level F1-score hesaplanması	97
5.3 Mühendislik Kriterleri.....	98
5.3.1 Parametre sayısı	98
5.3.2 Model boyutu.....	99
5.3.3 Çıkarım süresi.....	100
5.3.4 Bellek kullanımı.....	101
5.4 Eşik Seçimi ve Model Davranışı.....	102
6. SEÇİLEN MODELLERİN ANALİZİ	104
6.1 Kullanılan Donanım ve Yazılım Altyapısı.....	104
6.1.1 Karşılaşılan teknik sorunlar ve çözüm yolları	105
6.2 İlk Model Analizi MVTecAD Veri Seti.....	106
6.2.1 PatchCore ResNet18 MVTecAD kumaş analizi.....	107
6.2.2 PatchCore ResNeXt101 MVTecAD kumaş analizi.....	107
6.2.3 PatchCore WideResNet101 MVTecAD kumaş analizi.....	109
6.2.4 PatchCore WideResNet50-2 MVTecAD kumaş analizi.....	110
6.2.5 EfficientAd MVTecAD kumaş analizi	111
6.2.6 FastFlow ResNet18 MVTecAD kumaş analizi	113
6.2.7 FastFlow WideResNet50-2 MVTecAD kumaş analizi	114
6.2.8 GLASS ResNet18 MVTecAD kumaş analizi.....	115
6.2.9 GLASS WideResNet50 MVTecAD kumaş analizi.....	116
6.2.10 MVTecAD Kumaş analizi özeti	118
6.3 En Başarılı Üç Modelin Seçilmesi ve WFDD Veri Seti ile Analizi	119
6.3.1 Seçilen modellerin belirlenme kriterleri	121
6.3.2 GLASS Resnet18 WFDD performans analizi	122
6.3.3 PatchCore Resnet18 WFDD performans analizi	124
6.3.4 FastFlow Resnet18 WFDD performans analizi.....	125
6.3.5 WFDD sonuçlarının genel değerlendirilmesi ve model seçimi.....	127
7. AIORCOM-TEXTILEAD ÖZEL VERİ SETİNİN OLUŞTURULMASI....	129

7.1 Özel Veri Setinin Gerekçesi ve Genel Özellikleri	129
7.1.1 Logitech Brio 4K kamera	130
7.1.2 K&F Concept SA254T2 alüminyum kompakt tripod	130
7.1.3 Görüntülerin fotoğraflanması ve saklama prosedürleri	130
7.1.4 Photoshop ile segmentasyon maskeleri ve etiketleme.....	132
7.2 Veri Setinin Eğitim, Doğrulama ve Test Bölümlemesi ile Veri Artırımı	132
7.2.1 Veri bölümlenme stratejileri.....	133
7.2.2 Veri artırımı yöntemleri.....	133
8. AIORCOM-TEXTILEAD VERİSETİ GLASS EĞİTİMİ	135
8.1 GLASS Modeli Eğitim Ortamları	135
8.2 GLASS Modeli Çalıştırılması	135
8.3 GLASS Modeli Çalışma Prensipleri	136
8.4 GLASS Modeli Eğitim Süresi.....	136
8.5 GLASS Eğitimi Model Saklanması ve En İyi Model	137
9. AIORCOM-TEXTILEAD GLASS CANLI ORTAM TESTİ	138
9.1 GLASS Modeli Inference Kodu Oluşturulması.....	138
9.2 GLASS Modeli Canlı Ortam Sonuçları	140
10. GÖMÜLÜ SİSTEM UYGULAMALARI VE RASPBERRY PI 5 TESTİ . 141	
10.1 Raspberry Pi 5 Donanım Yapısı ve Kamera Kullanımı	142
10.1.1 Raspberry Pi 5 teknik özellikleri ve donanım seçimi	143
10.1.2 Raspberry Pi 5 ortamında Logitech Brio 4K yapılandırması	144
10.2 Raspberry Pi 5 GLASS Modelinin Çalıştırılması	144
10.2.1 Raspberry Pi 5 ortamında çıkarım süreleri	147
10.2.2 Raspberry Pi 5 ve dizüstü bilgisayar performans karşılaştırılması.....	148
10.3 Raspberry Pi 5 Üzerinde Sonuçlar ve İyileştirme Önerileri.....	148
10.4 Model Kuantizasyon Sonuçları	149
10.4.1 Gömülü sistemde elde edilen sonuçların genel değerlendirmesi.....	150
11. DENEY SONUÇLARI VE ANALİZLER	152
11.1 Model Performanslarının Genel Değerlendirmesi	152
11.2 Backbone Mimarilerinin Etkisi ve Kıyaslanması	153
11.3 Gömülü Sistemlerde Uygulanabilirlik Analizi.....	154
12. TARTIŞMA	155
12.1 Deney Sonuçlarının Yorumlanması	155
13. SONUÇLAR	157
13.1 Çalışmanın Genel Değerlendirmesi ve Katkıları	157
13.2 GLASS Modelinin Üstünlüğü ve Gömülü Sistem Uygulamaları	158
14. GELECEK ÇALIŞMALAR.....	159

KAYNAKLAR.....	160
ÖZGEÇMİŞ.....	165



KISALTMALAR

ABD	: Amerika Birleşik Devletleri
AD	: Anomaly Detection
AIORCOM-TextileAD	: Aior.com Textile Anomaly Detection Dataset
Anomalib	: Anomali Library
Ar-Ge	: Araştırma Geliştirme
AUROC	: Area Under the ROC Curve
C-Flow	: Conditional Normalizing Flow
CART	: Classification and Regression Trees
CFA	: Coupled Hypersphere Based Feature
CNN	: Convolutional Neural Network
CNRS	: Centre National de la Recherche Scientifique
CPU	: Central Process Unit
CS-Flow	: Cond. Normalizing Flow with Cross Scale Features
DBSCAN	: Density Based Spatial Cluster. App. With Noise
DFKDE	: Deep Feature Kernel Density Estimation
DFM	: Deep Feature Modeling
DRAEM	: Discrim. Trained Reconstr. Embed. for Surface AD
DTD	: Describable Textures Dataset
EfficienAD	: Efficient Anomaly Detection
FPR	: False Positive Rate
GAN	: Generative Adversarial Network
GANomaly	: Generative Adversarial Networks based AD
GLASS	: Global and Local Anomaly Co Synthesis Strategy
GMM	: Gaussian Mixture Models
Grad-CAM	: Gradient Weighted Class Activation Mapping
GPU	: Graphics Processing Unit
GUI	: Graphical User Interface
IA	: Image AUROC
ID3	: Iterative Dichotomiser 3
IS	: Inference Süresi

IF	: Image F1 Score
IoT	: Internet of Things
k-NN	: k-Nearest Neighbors
LIME	: Local Interpretable Model Agnostic Explanations
LOF	: Local Outlier Factor
LPB	: Local Binary Patterns
MB	: Model Boyutu
MVTecAD	: The MVTecAD Anomaly Detection Dataset
NASA	: National Aeronautics and Space Administration
OC-SVM	: One Class Support Vector Machines
OM	: Omurga
PA	: Piksel AUROC
PatchCore	: Patch Level Coreset
PaDim	: Patch Distribution Modeling
PF	: Piksel F1 Skoru
PS	: Parametre Sayısı
ResNet-18	: Residual Network 18
ResNeXt101	: Residual Networks Next 101
ROC	: Receiver Operating Characteristic
STFPM	: Student Teacher Feature Pyramid Matching
SVM	: Support Vector Machines
TPR	: True Positive Rate
TÜBİTAK	: Türkiye Bilimsel ve Teknolojik Araştırma Kurumu
QAT	: Quantization Aware Training
VAE	: Variational Autoencoder
VGG	: Oxford University Visual Geometry Group
ViT	: Vision Transformer
WFDD	: Woven Fabric Defect Detection tekstil veri seti
WideResNet50-2	: Wide Residual Network 50 - 2
YAML	: User Friendly Programming Language

ÇİZELGE LİSTESİ

Sayfa

Çizelge 2.1: Anomali tespitinin konulara göre dağılımı.....	31
Çizelge 2.2: Anomali tespitinin anahtar kelime dağılımı.	33
Çizelge 2.3: Anomali tespitinin kurumsal katkı dağılımı.	35
Çizelge 2.4: Anomali tespitine finansman sağlayan kuruluşlar.....	36
Çizelge 4.1: Backbone omurga türleri tablosu.	89
Çizelge 4.2: MVTecAD performans tablosu.	90
Çizelge 6.1: PatchCore ResNet18 MVTecAD kumaş analizi.	107
Çizelge 6.2: PatchCore ResNeXt101 MVTecAD kumaş sonuçları.	109
Çizelge 6.3: PatchCore WideResNet101 MVTecAD kumaş analizi.....	110
Çizelge 6.4: PatchCore WideResNet50-2 MVTecAD kumaş analizi.	111
Çizelge 6.5: EfficientAd MVTecAD kumaş analizi.	112
Çizelge 6.6: FastFlow ResNet18 MVTecAD kumaş analizi.	114
Çizelge 6.7: FastFlow WideResNet50-2 MVTecAD kumaş analizi.	115
Çizelge 6.8: GLASS ResNet18 MVTecAD kumaş analizi.	116
Çizelge 6.9: GLASS WideResNet50 MVTecAD kumaş analizi.....	117
Çizelge 6.10: MVTecAD kumaş analizi özeti.	119
Çizelge 6.11: GLASS Resnet18 WFDD performans analizi.	123
Çizelge 6.12: PatchCore Resnet18 WFDD performans analizi.	125
Çizelge 6.13: FastFlow Resnet18 WFDD performans analizi.....	126

ŞEKİL LİSTESİ

Sayfa

Şekil 2.1: Anomali tespiti yıllara göre yayın dağılımı.....	30
Şekil 2.2: Anomali tespiti makalelerinin ülkelere göre dağılımı.....	38
Şekil 2.3: Görüntü tabanlı anomali tespiti hakkında literatür analizi.....	39
Şekil 3.1: Bir anomalinin ısı haritası ile belirlenmesi örneği.....	41
Şekil 3.2: Bir anomalinin işaretlenmesi örneği.....	42
Şekil 3.3: İstatistiksel ve histogram tabanlı yaklaşım örneği.....	44
Şekil 3.4: LBP doku analizi ve filtreleme tabanlı yaklaşım örneği.....	46
Şekil 3.5: Gabor Filtresi uygulama örneği.....	46
Şekil 3.6 : Denetimli öğrenme yaklaşımları SVM örneği.....	49
Şekil 3.7: Yarı denetimli öğrenme yaklaşımları isolation forest örneği.....	52
Şekil 3.8: K-means denetimsiz öğrenme algoritması ile anomali tespiti örneği.....	54
Şekil 4.1: Efficient AD Modeli.....	74
Şekil 4.2: FastFlow Modeli.....	76
Şekil 4.3: PatcCore Modeli.....	79
Şekil 4.4: Glass Modeli.....	86
Şekil 5.1: AIORCOM-TextileAD kusurlu görsel örneği.....	93
Şekil 5.2: AIORCOM-TextileAD normal görsel örneği.....	93
Şekil 5.3: Kusurlu bir görsel örneği.....	96
Şekil 5.4: Kusurlu bir görsel Ground_truth örneği.....	96
Şekil 6.1: PatchCore ResNeXt101 MVTecAD kumaş sonuçları.....	108
Şekil 6.2: PatchCore ResNet18 MVTecAD kumaş analizi.....	108
Şekil 6.3: PatchCore WideResNet101 MVTecAD kumaş analizi.....	110
Şekil 6.4: PatchCore WideResNet50-2 MVTecAD kumaş analizi.....	111
Şekil 6.5: Anomalib EfficientAd MVTecAD kumaş analizi.....	112
Şekil 6.6: FastFlow ResNet18 MVTecAD kumaş analizi.....	113
Şekil 6.7: FastFlow WideResNet50-2 MVTecAD kumaş analizi.....	115
Şekil 6.8: GLASS ResNet18 MVTecAD kumaş analizi.....	116
Şekil 6.9: GLASS WideResNet50 MVTecAD kumaş analizi.....	117
Şekil 6.10: GLASS Resnet18 WFDD performans analizi.....	124
Şekil 6.11: PatchCore Resnet18 WFDD performans analizi.....	124
Şekil 6.12: FastFlow Resnet18 WFDD performans analizi.....	126
Şekil 7.1: Görüntülerin fotoğraflanması ve saklanması arayüzü.....	131
Şekil 8.1: GLASS model eğitimi sonuçlar görseli örneği.....	137
Şekil 9.1: GLASS modeli canlı ortam anomali tespiti.....	140
Şekil 10.1: Raspberry 5 gömülü sistem modülü.....	142
Şekil 10.2: Raspberry Camera Module 3 geniş açı kamera.....	143
Şekil 10.3: Tripod Logitech kamera ve Raspberry 5 ile canlı sistem.....	146
Şekil 10.4: GLASS modelinin Raspberry 5 ile çalıştırılması.....	146
Şekil 10.5: Raspberry 5 canlı deneme görüntüsü.....	147
Şekil 10.6: GLASS modeli kuantize model sonuçları.....	150



ÜRETİMDE GÖRÜNTÜ TABANLI ANOMALİ TESPİTİ: TEKSTİL VERİSİ İLE YAPAY ZEKÂ DESTEKLİ GÖMÜLÜ SİSTEM UYGULAMASI

ÖZET

Bu tez çalışması, tekstil üretim hatlarında karşılaşılan yüzey kusurlarının otomatik olarak tespitine yönelik görüntü tabanlı anomali tespiti problemine, derin öğrenme temelli yöntemlerle çözüm geliştirmeyi amaçlamaktadır. Bu kapsamda, literatürde yaygın olarak kullanılan MVTecAD ve WFDD veri setleri üzerinde 9 farklı model ve omurga mimarisi sistematik biçimde değerlendirilmiş; doğruluk, çıkarım süresi, bellek tüketimi ve parametre sayısı gibi çok boyutlu performans ölçütleri kullanılarak kapsamlı karşılaştırmalar gerçekleştirilmiştir. Elde edilen bulgular doğrultusunda en başarılı üç model belirlenmiş ve nihai seçim olarak GLASS mimarisi tercih edilmiştir.

Çalışmanın özgün katkılarından biri, endüstriyel üretim koşullarını yansıtan AIORCOM-TextileAD adlı özel bir veri setinin oluşturulmasıdır. Bu veri seti ile yeniden eğitilen model, öncelikle yüksek performanslı sistemlerde test edilmiş, ardından gömülü sistem ortamına (Raspberry Pi 5) aktarılmıştır. Gömülü sistem üzerinde yapılan testlerde modelin gerçek zamanlı çalışabilirliği ve sınırlı kaynaklarda gösterdiği performans analiz edilmiştir. Elde edilen sonuçlar, seçilen modelin düşük maliyetli donanımlarda dahi anlamlı bir doğruluk ve işlem süresi ile çalışabildiğini ortaya koyarak, yapay zekâ tabanlı otomatik kalite kontrol sistemlerinin tekstil endüstrisine entegrasyonuna yönelik önemli bir uygulama potansiyeli sunmaktadır.

Anahtar kelimeler: Üretimde anomali tespiti, Derin öğrenme, Gömülü sistem, GLASS, Raspberry Pi 5

IMAGE-BASED ANOMALY DETECTION IN MANUFACTURING: AN EMBEDDED SYSTEM APPLICATION SUPPORTED BY ARTIFICIAL INTELLIGENCE USING TEXTILE DATA

SUMMARY

This thesis aims to develop a solution to the problem of Image-based anomaly detection for the automatic detection of surface defects encountered in textile production lines using deep learning-based methods. In this context, 9 different models and backbone architectures were systematically evaluated on the MVTecAD and WFDD data sets widely used in the literature; comprehensive comparisons were made using multi-dimensional performance criteria such as accuracy, inference time, memory consumption and number of parameters. In line with the findings obtained, the three most successful models were determined, and the GLASS architecture was preferred as the final choice.

One of the original contributions of the study is the creation of a special data set called AIORCOM-TextileAD, which reflects industrial production conditions. The model, which was retrained with this data set, was first tested on high-performance systems and then transferred to the embedded system environment (Raspberry Pi 5). In the tests conducted on the embedded system, the real-time operability of the model and its performance on limited resources were analyzed. The results obtained demonstrate that the selected model can operate with significant accuracy and processing time even on low-cost hardware, offering significant application potential for the integration of artificial intelligence-based automatic quality control systems into the textile industry.

Keywords: Industrial anomaly detection, Deep learning, Embedded systems, GLASS, Raspberry Pi 5

1. GİRİŞ

Günümüzde, üretim süreçlerinde kalite kontrol ve hata tespiti, rekabetçi piyasa göz önünde bulundurulduğunda kritik bir öneme sahiptir. Ürün kalitesinin yüksek standartlarda tutulması ve hatalı ürün oranının minimize edilmesi hem müşteri memnuniyetini artırmakta hem de işletmelerin kârlılığını iyileştirmektedir. Üretim hatlarında ortaya çıkabilen yüzey kusurlarının erken ve doğru şekilde tespiti, özellikle tekstil sektöründe, kumaş kalitesinin korunmasında önemlidir. Geleneksel kalite kontrol yöntemlerinde deneyimli personel, kumaşı elle veya gözle inceleme yapmaktadır. Ancak bu yaklaşım, yüksek iş gücü maliyeti, insan kaynaklı hata riski ve süreçteki gecikmeler gibi dezavantajlara sahiptir. Endüstri 4.0 süreciyle birlikte artan otomasyon ve dijitalleşme ihtiyacı, yapay zekâ ve özellikle derin öğrenme tabanlı çözümlerin kullanımını giderek daha avantajlı hale getirmektedir.

Derin öğrenme tabanlı anomali tespiti; öğrenme süreçlerinde kusurlu örneklerin sınırlı veya hiç olmadığı durumlarda dahi, normal örneklerden elde edilen bilginin anormal örnekleri ayırt etmede kullanılmasını olanaklı kılan bir yaklaşım sunar. Bu sayede, tekstil gibi büyük veri gerektiren alanlarda verimlilik ve doğruluk açısından avantajlar elde edilmektedir.

Son yıllarda Intel firması[1] öncülüğünde geliştirilen Anomalib kütüphanesi[2] ve içeriğinde yer alan PatchCore[3,4], FastFlow[5,6], EfficientAD[7,8] ve ayrıca GLASS[9,10] gibi çeşitli modeller, görüntü tabanlı anomali tespitini hem akademik hem de endüstriyel uygulamalarda yaygın biçimde kullanılır hale getirmiştir. Söz konusu modellerin performanslarını, farklı omurga mimarileriyle örneğin ResNet18[11], WideResNet50-2[12,13], ResNet101[14], WideResNet101[13] ve çeşitli veri setlerinde kıyaslamak, endüstri ölçeğinde uygulanabilir bir çözüm önermeye yönelik gerekli bir adımdır.

Bu tez kapsamında öncelikle sektörde standart haline gelmiş olan MVTecAD veri setinin tekstil kategorisi olan Kumaş (Carpet) kategorisi kullanılmıştır[15,16]. Sonrasında seçilen en başarılı 3 model ile WFDD veri setinde Gri Kumaş kategorisi (Gray Cloth)[17] ile derin öğrenme modellerinin daha kapsamlı bir karşılaştırması

gerçekleştirilmiştir. Deneysel analizlerde doğruluk ölçütleri görsel etiketi ve piksel etiketi skorlarının yanında mühendislik bakış açısıyla parametre sayısı, model boyutu, çıkarım hızı ve bellek kullanımı gibi faktörler dikkate alınmıştır. Elde edilen bulgular doğrultusunda, en iyi performansı sergileyen üç model belirlenmiş ve son aşamada GLASS modelinin, gerçek zamanlı bir gömülü sistem uygulamasına entegre edilmesi hedeflenmiştir. Bu doğrultuda, Logitech Brio 4K kamera[18] kullanılarak toplanan gerçek üretim hattı verileriyle model eğitimi ve doğrulama adımları yürütülmüştür. Ardından model, Raspberry Pi 5[19] gibi sınırlı donanım kaynaklarına sahip sistemlerde test edilerek hem performans hem de kullanım kolaylığı açısından elde edilen sonuçlar incelenmiştir.

Yapılan bu çalışma, farklı anomali tespiti modellerinin farklı tekstil verileri üzerinde değerlendirmesini sunarak, işletmelerin üretim hatlarında otomatik bir kalite kontrol çözümü geliştirmelerine rehberlik etmeyi amaçlamaktadır. Böylece, teorik kazanımların yanı sıra pratik uygulama deneyimiyle desteklenen bir model seçimi süreci sunulmakta, sonraki çalışmalar için de bir rehber oluşturulması planlanmaktadır.

1.1 Çalışmanın Amacı ve Kapsamı

Bu tez çalışmasının temel amacı, tekstil üretim hatlarında karşılaşılan yüzey kusurlarının otomatik olarak tespit edilmesine yönelik, derin öğrenme tabanlı anomali tespiti modellerinin kapsamlı biçimde analiz edilmesi ve bu modellerin sınırlı donanıma sahip gömülü sistemlerdeki uygulanabilirliğinin değerlendirilmesidir.

Bu kapsamda, güncel ve yüksek başarıma sahip anomali tespiti modelleri farklı veri setleri ve omurga mimarileri ile karşılaştırılmış; doğruluk, parametre verimliliği, çıkarım hızı ve bellek kullanımı gibi çok boyutlu kriterler temelinde performans analizi gerçekleştirilmiştir. Gerçek üretim ortamını temsil eden görüntüler, Logitech Brio 4K kamera kullanılarak toplanmış ve oluşturulan veri seti ile model yeniden eğitilmiştir. Son olarak, modelin Raspberry Pi 5 platformu üzerinde çalıştırılmasıyla hem işlem hızı hem de sistem uyumluluğu analiz edilmiş; pratik uygulamalara yönelik potansiyel darboğazlar ve iyileştirme alanları ortaya konmuştur.

Bu çalışma, akademik model karşılaştırmaları yanında uygulamaya yönelik veri toplama, model optimizasyonu, donanım seçimi ve hızlandırma stratejilerini de kapsayan bir yaklaşım sunmaktadır. Böylece, çalışma ile üretim hatlarında yapay zekâ destekli otomatik kalite kontrol sistemlerinin geliştirilmesine yönelik teorik ve uygulamalı bir çerçeve ortaya konmaya çalışılmıştır.

1.2 Problem Tanımı Üretim Hatlarında Yüzey Kusurlarının Tespiti

Endüstriyel üretim süreçlerinde yüzey kalitesinin sürekliliği, ürün güvenilirliği ve müşteri memnuniyeti açısından kritik bir öneme sahiptir. Özellikle tekstil sektöründe, kumaş yüzeylerinde meydana gelebilecek çizik, leke, iplik bozulması veya dokusal düzensizlik gibi kusurların zamanında tespit edilememesi; büyük ölçekli maddi kayıplara, üretim verimliliğinde düşüşe ve marka itibarında zedelenmeye yol açabilmektedir.

Geleneksel kalite kontrol yöntemleri çoğunlukla insan gözüyle yapılan görsel denetimlere dayanmaktadır. Ancak kumaş yapısının karmaşıklığı, desen ve renk çeşitliliği, yüksek üretim hızı ve sürekli çalışma gereksinimi gibi etkenler, bu yöntemlerin yetersiz kalmasına neden olmaktadır. Yüzey kusurlarının otomatik olarak tespit edilebilmesini sağlayan anomali tespiti (AD) temelli sistemlerin geliştirilmesi hem doğruluk hem de verimlilik açısından önemli bir gereklilik hâline gelmiştir.

Anomalinin doğru şekilde tespit edilmesi görselliğin yanında ürünün işlevsel ve mekanik özellikleri açısından da önem taşır. Örneğin, tekstil kumaşındaki ince bir lif kopması veya dokuma hatası, son kullanıcının memnuniyetini azaltabileceği gibi, kumaşın dayanıklılığında da azalmaya yol açabilir. Geleneksel yaklaşımlar, uzman personel veya yarı otomatik sistemler üzerinden yürütülse de operatör yorgunluğu, insandan kaynaklı subjektif değerlendirme farklılıkları ve yüksek üretim adetleri bu yöntemlerin yetersizliğini ortaya koymaktadır.

Endüstri 4.0'ın getirdiği otomasyon ve yapay zekâ eğilimleri, üretim hatlarında sensör veya kamera tabanlı takip ve veri analitiğine dayalı karar mekanizmalarının yaygınlaşmasını desteklemektedir. Bu alanda geleneksel görüntü işleme ve makine öğrenmesi yöntemleri uzun zamandır kullanılmakta olsa da yüzey kusurlarının karmaşık yapısı ve her türlü kusur senaryosunun veriye dönüştürülmesindeki

zorluklar, bu ilk yöntemlerin sınırlarını net bir şekilde göstermektedir. Üretim ortamlarındaki ışık koşulları, malzeme farklılıkları gibi değişkenlikler tutarlı ve güvenilir bir kalite kontrol sistemi kurmayı güçleştirmektedir.

Modern derin öğrenme yaklaşımları ise bu sorunlara yenilikçi ve dinamik çözümler getirmektedir. Özellikle anomali tespiti alanında geliştirilen son yöntemler, normal verilerin istatistiksel özelliklerini öğrenerek anormal veya kusurlu bölgeleri yüksek doğrulukla ayırt edebilmektedir. Bu yaklaşımlar, insan gücüne dayalı kalite kontrol süreçlerini otomatikleştirip standardize ederek, maliyetleri düşürürken verimliliği arttırabilmektedir. İşte bu tez çalışmasında, söz konusu derin öğrenme temelli anomali tespiti modellerinin verimliliği ve performans kıyaslaması ele alınarak, üretim hatlarındaki kalite kontrol sürecine entegrasyon olanakları ve karşılaşılan güçlükler incelenmiştir.

1.3 Araştırmanın Önemi ve Katkıları

Bu tez çalışmasının özgün katkılarından biri, literatürde yaygın olarak kullanılan MVTecAD veri setinin Kumaş kategorisinin ve WFDD veri setinin Gri Kumaş kategorisinin ötesine geçilerek, gerçek üretim koşullarını yansıtan AIORCOM-TextileAD adlı yeni bir özel veri setinin oluşturulmasıdır. Bu veri seti, Logitech Brio 4K kamera ile toplanan 301 kusursuz eğitim görseli ve bu görsellere ait 301 segmentasyon maskeleri, ayrıca 60 kusursuz ve 60 kusurlu test görseli ile 60 kusurlu test maskelerini içeren toplam 782 görselden oluşmaktadır. Veri seti, tekstil dokularına özgü karmaşık varyasyonları içermesi açısından literatürdeki benzerlerinden farklı bir dokuda seçilmeye çalışılmıştır. Veri seti oluştururken fark edilmesi çok kolay olan hataların yanında fark edilmesi zor olan veya vakit alan hataların seçilmesine çalışılmıştır.

Tezde yalnızca standart model doğruluk metriklerinin değerlendirilmesiyle yetinilmemiş; aynı zamanda mühendislik perspektifinden model parametre sayısı, bellek tüketimi, model boyutu ve çıkarım süresi gibi endüstriyel ölçütler de dikkate alınmıştır. Bu yönüyle bu tez çalışmasında hem akademik hem de pratik uygulanabilirlikleri açısından çeşitli analiz ve deneme çalışmaları yapılmıştır.

Deneyler, NVIDIA RTX 5080 GPU[20] ve Intel Core Ultra 9 CPU[21] mimarisi gibi yeni donanımlar üzerinde gerçekleştirilmiştir. AD modellerinin farklı

sistemlerdeki davranışları ile Raspberry Pi 5'in 8 GB ve 16 GB varyantları[22] gibi sınırlı kaynaklı platformlardaki gerçek zamanlı performansları karşılaştırmalı olarak incelenmiştir. Bu sayede, oluşturulan AD sistemlerinin hem araştırma düzeyinde hem de sahada uygulamaya hazır hale gelebilecek bir çözüm sunup sunmadığı değerlendirilmiştir.

1.4 Tezin Organizasyonu

Bu tez çalışması, görüntü tabanlı anomali tespiti alanında gerçekleştirilen araştırmaların kuramsal temellerini, yöntemsel uygulamalarını, deneysel sonuçlarını ve mühendislik düzeyindeki değerlendirmelerini ele alacak şekilde on dört ana bölümden oluşmaktadır.

Birinci bölümde, çalışmanın amacı, kapsamı, problemi ve araştırmaya yönelik özgün katkılar ortaya konulmakta; üretim hatlarında yüzey kusurlarının tespiti sürecinde karşılaşılan zorluklara çözüm getirmek üzere geliştirilen yaklaşım genel hatlarıyla sunulmaktadır.

İkinci bölümde, anomali tespiti ve görüntü temelli anomali tespiti literatürü ayrıntılı biçimde incelenmektedir. Bu kapsamda, akademik yayınların yıllara, konulara, anahtar kelimelere, ülkeler ve kurumsal desteklere göre dağılımı analiz edilmekte ve alandaki gelişim eğilimleri betimlenmektedir.

Üçüncü bölüm, anomali tespitine yönelik yöntemleri kuramsal düzlemde ele almaktadır. Öncelikle geleneksel görüntü işleme teknikleri (istatistiksel analiz, histogram yaklaşımı, LBP ve Gabor filtreleri) açıklanmakta; ardından denetimli, yarı denetimli ve denetimsiz makine öğrenmesi teknikleri ile derin öğrenme temelli yöntemler (yeniden yapılandırma, özellik haritası temelli, üretici-karşıt, öğretmen-öğrenci ve transformer tabanlı stratejiler) sınıflandırılmaktadır. Ayrıca, transfer öğrenme, eşikleme teknikleri, model açıklanabilirliği, model optimizasyonları ve tekstil sektöründeki uygulama örnekleri kapsamlı şekilde değerlendirilmektedir.

Dördüncü bölüm, üretim ortamına yönelik hazırlık çalışmaları çerçevesinde Anomalib kütüphanesi ile kullanılan modellerin (FastFlow, PatchCore, EfficientAD ve GLASS) mimari yapıları ve uygulama senaryoları üzerine odaklanmaktadır.

Beşinci bölümde, deneysel değerlendirmelerde kullanılan metrikler tanımlanmakta; Image-level ve Pıksel-level AUROC ile F1-score hesaplamaları yanında parametre sayısı, model boyutu, bellek kullanımı ve çıkarım süresi gibi mühendislik ölçütleri detaylandırılmaktadır.

Altıncı bölüm, seçilen modellerin MVTecAD ve WFDD veri setleri üzerindeki başarımlarını ortaya koymaktadır. Bu kapsamda, her bir modelin analiz çıktıları ve karşılaşılan teknik zorluklar sistematik olarak sunulmakta; sonuçların karşılaştırmalı analizine yer verilmektedir.

Yedinci bölümde, bu çalışmaya özgü olarak geliştirilen AIORCOM-TextileAD veri seti tanıtılmakta ve veri setinin oluşturulma gerekçesi, kullanılan donanım (kamera ve tripod), segmentasyon süreci, veri artırımı ve bölümlendirme stratejileri detaylandırılmaktadır.

Sekizinci bölüm, AIORCOM-TextileAD veri seti üzerinde GLASS modelinin eğitimi sürecine odaklanmaktadır. Eğitim ortamı, kullanılan ayarlar, eğitim süresi ve en iyi modelin seçimi ile ilgili bilgiler sunulmaktadır.

Dokuzuncu bölümde, geliştirilen GLASS modelinin canlı ortamda kullanılmasına yönelik geliştirilen özel bir inference arayüzünün yapısı ve çalışması ele alınmakta; canlı test sonuçları performans metrikleriyle birlikte sunulmaktadır.

Onuncu bölüm, GLASS modelinin gömülü sistemler üzerindeki uygulanabilirliğini değerlendirmektedir. Raspberry Pi 5 cihazı üzerinde gerçekleştirilen model çalışma, çıkarım süresi ölçümleri, donanım uyumu, performans değerlendirmeleri, kuantizasyon denemeleri ve dizüstü sistemle karşılaştırmalar detaylı olarak incelenmektedir.

On birinci bölümde, elde edilen deneysel sonuçlar doğrultusunda model performanslarının genel bir değerlendirmesi yapılmakta; farklı backbone mimarilerinin ve donanım yapılandırmalarının başarıma etkileri açıklanmakta, gömülü sistemlerdeki uygulanabilirlik analizine yer verilmektedir.

On ikinci bölümde, tartışma başlığı altında deneysel bulgular irdelenmekte; modellerin güçlü ve zayıf yönleri karşılaştırmalı olarak ele alınmakta ve gerçek zamanlı endüstriyel uygulamalar için çıkarımlar yapılmaktadır.

On üçüncü bölümde, tez çalışmasının genel sonuçları özetlenmekte; özellikle GLASS modelinin başarımı, endüstriyel ortamlardaki uygulanabilirliği ve çalışmanın literatüre katkıları açıklanmaktadır.

Son olarak on dördüncü bölümde, bu çalışmayı takip edecek potansiyel araştırma alanları önerilmektedir. Farklı veri setleri, çoklu kusur sınıflandırması, donanım hızlandırıcılarla model optimizasyonu ve üretim hatlarına gerçek zamanlı entegrasyon gibi gelecek çalışmaların yönelmesi gereken başlıca konular ortaya konulmaktadır.



2. LİTERATÜR İNCELEMESİ

Bu bölümde, anomali tespiti alanında yapılan bilimsel çalışmalar önce Anomali Tespiti anahtar kelimesi ile incelenmiş; literatürdeki eğilimler, yayın sayıları, konu başlıkları, anahtar kelime dağılımları, kurumsal katkılar, fon sağlayıcı kuruluşlar ve ülkelere ve yıllara göre dağılımı analiz edilmiştir. Sonrasında özellikle görüntü tabanlı anomali tespiti konusuna odaklanılarak, ilgili yayınların artış eğilimi, teknik yaklaşım çeşitliliği ve uygulama alanlarındaki genişleme veriye dayalı olarak değerlendirilmiştir. Yapılan bu analizler sonucunda, anomali tespitinin yalnızca akademik bir araştırma konusu olmaktan çıkıp, endüstriyel kalite kontrol, siber güvenlik ve sağlık gibi alanlarda yaygınlaşan stratejik bir teknoloji alanına dönüştüğü ortaya konmuştur.

2.1 Anomali Tespiti Hakkında Literatür Analizi

Bu tez kapsamında gerçekleştirilen literatür taraması, Scopus veri tabanında[23] Anomali Tespiti anahtar terimi referans alınarak yürütülmüş ve güncel bilimsel eğilimler Bursa Teknik Üniversitesi öğrenci hesabı ile giriş yapılarak csv[24] formatında indirilerek Excel[25] ortamında analiz edilmiştir. Scopus, bilimsel literatürün önde gelen bibliyografik veri tabanlarından biri olup, dünya genelinde yayımlanan hakemli dergi makaleleri, kitaplar ve konferans bildirimlerini endeksleyerek araştırmacılara kapsamlı bir kaynak sunar. Fen, mühendislik, tıp, sosyal bilimler ve beşerî bilimler gibi çok çeşitli disiplinleri kapsayan bu platform, akademik yayınlara ilişkin özet, atıf ve istatistiksel verilere erişim sağlayarak bilimsel üretkenliğin ve araştırma eğilimlerinin analiz edilmesine olanak tanır[26]. Scopus ile elde edilen yayınlar, yıllara göre dağılım, konu alanları, anahtar kelime kullanımları, kurumsal katkı düzeyleri, fon sağlayıcı kuruluşlar, ülkeler ve yayıncı dilleri ekseninde sistematik biçimde sınıflandırılmıştır. Her biri analiz başlığı ve adet olmak üzere iki sütundan oluşan bu veriler, anomali tespiti konusunun evrimini, hangi alanlarda yoğunlaştığını, hangi kurumlar ve ülkeler tarafından üretildiğini ve hangi ortamlarda desteklendiğini anlamaya imkân tanımaktadır.


Aşağıdaki analizlerde, bu sütun çiftleri temel alınarak oluşturulan değerlendirmeler sunulmaktadır.

2.1.1 Anomali tespiti hakkında yıllara göre yayın dağılımı

Scopus veri tabanı temel alınarak gerçekleştirilen analiz sonucunda, anomali tespiti konusundaki bilimsel yayınların yıllara göre dağılımı incelendiğinde, özellikle son yirmi yıllık dönemde dikkat çekici bir artış gözlemlenmektedir. 1915-1990 arası dönemde yılda en fazla birkaç yayınlı temsil edilen bu alan, 2000’li yılların başından itibaren artan hesaplama gücü, veri hacmi ve algoritmik gelişmelerin etkisiyle ivme kazanmıştır. 2005 yılında yalnızca 74 olan yayın sayısı, 2010’da 297’ye, 2015’te ise 1.044’e ulaşarak ilk defa dört haneli değerlere erişmiştir. Bu artış, alanın yapay zekâ, makine öğrenimi ve veri bilimi ile entegrasyonu sonucunda daha geniş uygulama alanlarına yayılmasıyla ilişkilidir.

2020 sonrası dönemde ise literatürdeki büyüme dikkat çekici biçimde hızlanmış; 2021 yılında 6.681, 2022’de 7.992, 2023’te 9.679 ve 2024 yılında 13.199 yayına ulaşılmıştır. Bu veriler, sayısal artışın yanında anomali tespitinin merkezî konum kazandığına işaret etmektedir. 2025 yılı verileri henüz yıl ortası itibarıyla değerlendirilmiş olsa da şimdiden 6.404 yayına ulaşılması bu yükseliş eğiliminin sürdüğünü göstermektedir. Bu durum, anomali tespitinin özellikle üretim hatlarında kalite kontrol, siber güvenlikte tehdit izleme, sağlıkta tanı destek sistemleri ve otonom sistemlerde arıza tespiti gibi kritik uygulamalarda stratejik rol üstlendiğini göstermektedir.

Bu artış eğilimi, Şekil 2.1 ’de de açıkça görülebileceği gibi, özellikle 2020 sonrası dönemde yoğun bir büyümeye işaret etmektedir. Söz konusu grafik, çalışmanın ilerleyen bölümlerinde değerlendirilecek olan konu alanı, anahtar kelime ve ülke dağılımları ile ele alındığında, anomali tespiti literatürünün hem küresel düzeyde hem de çok disiplinli olarak genişlediğini ortaya koymaktadır.



Şekil 2.1: Anomali tespitinin yıllara göre yayın dağılımı

2.1.2 Anomali tespitinin konulara göre dağılımı

Çizelge 2.1'den de görüleceği gibi, anomali tespiti alanındaki bilimsel üretim büyük ölçüde sayısal ve uygulamalı bilimler etrafında şekillenmektedir. En yüksek yayın sayısı Bilgisayar Bilimleri alanında gözlemlenmiş olup, toplam 51.478 yayımla bu bilim alandaki araştırmaların temelini oluşturmaktadır. Bu yüksek oran, özellikle yapay zekâ, makine öğrenimi ve veri işleme teknolojilerinin bu alanda yoğun şekilde geliştirilmesinden kaynaklanmaktadır. İkinci sırada yer alan Mühendislik Bilimleri ise 35.921 yayımla dikkat çekmekte; üretim hatları, otonom sistemler, robotik ve akıllı altyapılar gibi doğrudan uygulama alanlarında katkı sunmaktadır.

Kuramsal katkılar bakımından öne çıkan Matematik 15.900 yayımla ile Fizik ve Astronomi 10.015 yayımla gibi kategoriler, özellikle istatistiksel modelleme, sinyal işleme ve sistem dinamikleri çerçevesinde alana entegre olmaktadır. Tıp alanı, 9.788 yayımla beşinci sırada yer almakta ve sağlık teknolojilerinde erken teşhis, biyomedikal görüntüleme ve hasta izleme sistemlerinde anomali tespiti uygulamalarının yaygınlaştığını göstermektedir.

Bunların yanı sıra, Dünya ve Gezegen Bilimleri 7.608, Karar Bilimleri 7.008 ve Malzeme Bilimleri 5.722 gibi farklı kategorilerde de anlamlı düzeyde katkı gözlemlenmektedir. Bu alanlarda uzaktan algılama, çok ölçütlü karar sistemleri ve yapısal analiz gibi konular üzerinden anomali tespitine yönelik çeşitli yöntemler geliştirilmektedir. Enerji sektörü ise 4.723 yayımla özellikle ağ güvenliği, sensör tabanlı izleme ve tüketim anormalliklerinin belirlenmesi gibi temalar etrafında şekillenmektedir.

Ayrıca Sosyal Bilimler 3.315 yayın, Çevre Bilimleri 2.840 yayın ve İşletme Yönetimi 1.691 yayın gibi alanlarda da anomali tespiti çalışmalarına yer verildiği, bu yaklaşımın yalnızca teknik bir problem alanı olmanın ötesine geçtiğini ve sosyal, yönetsel ya da çevresel sorunlara çözüm arayışında da kullanıldığını göstermektedir. Düşük sayıda yayına sahip olmakla birlikte, Sinirbilim 831, Finans 334, Psikoloji 229 ve Veterinerlik 108 gibi uzmanlık alanlarında da uygulama örneklerine rastlanmakta; bu durum anomali tespitinin kapsayıcı, esnek ve giderek genişleyen bir araştırma alanı haline geldiğini ortaya koymaktadır. Bu çeşitlilik, kategoriler arası etkileşimin artmakta olduğunu ve anomali tespiti konusunun çok boyutlu bir yaklaşımla ele alındığını göstermektedir.

Çizelge 2.1: Anomali tespitinin konulara göre dağılımı.

Çalışma Alanı	Yayın Adedi
Bilgisayar Bilimleri	51478
Mühendislik	35921
Matematik	15900
Fizik ve Astronomi	10015
İlaç	9788
Dünya ve Gezegenler	7608
Karar Bilimleri	7008
Malzeme Bilimleri	5722
Enerji	4723
Sosyal Bilimler	3315
Çevre Bilimleri	2840
Biyoloji	2810
İş Yönetimi	1691
Kimya	1589
Kimya Mühendisliği	1267
Tarım	995
Sağlık	984
Çoklu Disiplin	855
Sinirbilim	831
Sanat ve İnsanlık	436
Finans	334
Psikoloji	229
Farmakoloji	196
Mikrobiyoloji	177
Dişçilik	159
Hemşirelik	121
Veterinerlik	108

2.1.3 Anomali tespiti hakkında anahtar kelime dağılımı

Çizelge 2.2 'de sunulan verilere göre, anomali tespiti literatüründe kullanılan anahtar kelimeler, alanın metot yönelimlerini ve uygulama alanlarını doğrudan yansıtmaktadır. En baskın anahtar kelime, doğal olarak Anomali Tespiti kelimesi olup, 41.985 kez kullanılmıştır. Bu değer, diğer tüm terimlerden açık ara yüksektir ve çalışmalarda doğrudan bu kavram etrafında şekillenen bir kuramsal çerçevenin varlığını ortaya koymaktadır.

Bu terimi izleyen ikinci grup ise yönteme ve uygulama konusuna işaret eden kavramlardır. Özellikle Makine Öğrenimi kelimesi 8.745 ve Derin Öğrenme kelimesi 8.363 terimleri, anomali tespitinde kullanılan modern algoritmaların yapay zekâ temelli olduğunu göstermektedir. Bu kavramların yüksek sıklıkla kullanılması, anomali tespitinin geleneksel istatistiksel yaklaşımlardan evrilerek veri odaklı ve kendini optimize edebilen sistemlere dayandığını göstermektedir.

Dikkat çeken bir diğer anahtar kelime İnsan kelimesi 8.499 ve benzeri olan İnsanlar kelimesi 5.068 terimleridir. Bu durum, insan merkezli sistemlerde örneğin sürücü davranışı analizi, sağlıkta hasta izleme, psikolojik durum sınıflandırması gibi anomali tespiti uygulamalarının yaygınlaştığını göstermektedir. Ayrıca Kadın anahtar kelimesi de 5.018 kez geçmiş olup, cinsiyet temelli analizlerin ve sağlık-biyomedikal uygulamaların literatürde belirgin şekilde yer bulduğunu göstermektedir.

Güvenlik uygulamaları kapsamında öne çıkan terimler arasında Saldırı Algılama kelimesi 7.601, Ağ Güvenliği kelimesi 7.358, Bilgisayar Suçu kelimesi 3.365 ve İstila Algılama Sistemleri kelimesi 3.249 defa yer almaktadır. Bu terimler, anomali tespitinin yalnızca endüstriyel süreçlerde değil, aynı zamanda siber tehditlerin izlenmesi ve önlenmesinde de merkezi bir rol üstlendiğini göstermektedir.

Veri işleme sürecine dair kullanılan terimlere bakıldığında ise Öğrenme Sistemleri kelimesi 7.592, Özellik Çıkarma kelimesi 3.767, Aykırı Değer Algılama kelimesi 3.555 ve Veri Madenciliği 3.543 anahtar kelimeleri öne çıkmakta; bu da alandaki araştırmaların temel veri hazırlama ve modelleme aşamalarına güçlü bir şekilde odaklandığını ortaya koymaktadır. Ayrıca Otomatik Kodlayıcılar 3.277 ve Nesnelerin İnterneti 3.261 gibi daha teknik veya uygulama odaklı kavramlar da literatürde giderek artan bir yer edinmektedir.

Genel olarak değerlendirildiğinde, anomali tespiti literatüründe kullanılan anahtar kelimeler hem teorik yaklaşım türlerini hem de pratik uygulama alanlarını yansıtmaktadır. Bu terimlerin dağılımı, alanın birçok kategoride genişliğini, teknolojik gelişmelerle olan yakın ilişkisini ve insan merkezli analizlerin önem kazandığını güçlü biçimde ortaya koymaktadır.

2.1.4 Anomali tespiti hakkında kurumsal katkı dağılımı

Çizelge 2.3 'te sunulan veriler, anomali tespiti alanındaki akademik üretimin kurumsal düzeyde nasıl bir dağılım sergilediğini göstermesi açısından önemlidir. Bu dağılım incelendiğinde, katkı sağlayan kurumların çok büyük bir bölümünün Asya kıtasında, özellikle de Çin Halk Cumhuriyeti'nde konumlandığı görülmektedir. İlk 20 içerisinde yer alan kurumların 15'i Çin merkezlidir ve bu durum, Çin'in yalnızca sayısal anlamda değil, aynı zamanda araştırma altyapısı ve kurumsal kapasite açısından da küresel akademik üretimin merkezine yerleştiğini ortaya koymaktadır.

Çizelge 2.2: Anomali tespitinin anahtar kelime dağılımı.

Anahtar Kelime	Yayın Adedi
Anomali Tespiti	41985
Makine Öğrenimi	8745
İnsan	8499
Derin Öğrenme	8363
İstila Algılama	7601
Öğrenme Sistemleri	7592
Ağ Güvenliği	7358
Makale	7326
İnsanlar	5068
Kadın	5018
Makine Öğrenimi	4828
Özellik Çıkarma	3767
Aykırı Değer	
Algılama	3555
Veri Madenciliği	3543
İstatistik	3469
Bilgisayar Suçu	3365
Otomatik Kodlayıcılar	3277
Nesnelerin İnterneti	3261
İstila Algılama	
Sistemleri	3249
Sinyal Algılama	3162

En yüksek katkıyı sağlayan kurum, Çin Bilimler Akademisi olup, toplamda 1.511 yayına doğrudan katkıda bulunmuştur. Bu kurum, Çin'in en büyük temel araştırma kuruluşu olması dolayısıyla ülkenin yapay zekâ, bilgisayarla görü ve veri bilimi alanındaki stratejik yönelimlerini doğrudan yönlendirmektedir. Onu takip eden Çin Halk Cumhuriyeti Eğitim Bakanlığı 1.062 yayın ve Çin Bilimler Akademisi Üniversitesi 835 yayın gibi kurumlar, akademik ağların devlet destekli yapısını ve merkezi koordinasyonu ortaya koymaktadır.

Çin'in önde gelen teknik üniversiteleri de listede belirgin şekilde yer almaktadır. Örneğin, Tsinghua Üniversitesi 695 yayın, Zhejiang Üniversitesi 531, Harbin Teknoloji Enstitüsü 526, Şanghai Jiao Tong Üniversitesi 509 ve Pekin Posta ve Telekomünikasyon Üniversitesi 477 gibi kurumlar hem temel araştırma hem de uygulamalı teknoloji geliştirme yönünden büyük katkılar sunmaktadır. Bu üniversitelerin çoğu, Çin'in Yeni Nesil Yapay Zekâ Gelişim Planı kapsamında öncelikli fonlanan kurumlardandır.

Avrupa'dan listeye giren tek kuruluş olan Fransa Ulusal Bilimsel Araştırma Merkezi, 749 yayımla dikkat çeken bir konumda yer almakta; bu da Avrupa kıtasının katkısının daha çok ulusal düzeyde organize olmuş merkezi araştırma kurumları üzerinden gerçekleştiğini göstermektedir. CNRS'nin anomali tespiti bağlamındaki üretimi, ağırlıklı olarak bilgisayar bilimi, fiziksel modelleme ve sağlık teknolojileri gibi disiplinlerde yoğunlaşmaktadır.

Amerika kıtasından listeye giren önemli bir istisna ise Carnegie Mellon Üniversitesi'dir. 358 yayımla katkı sunan üniversite, özellikle otonom sistemler, robotik ve siber güvenlik konularında anomali tespiti uygulamalarına öncülük etmektedir. Japonya'dan Tokyo Üniversitesi 334 yayın sayısı ile Asya dışındaki diğer önemli merkezlerden biri olarak listede yer almaktadır.

Bu veriler, anomali tespiti konusundaki kurumsal üretimin coğrafi olarak Çin merkezli bir kümelenme eğilimi sergilediğini, ancak Avrupa, Amerika ve Japonya gibi bölgelerde de nitelikli ve stratejik katkıların sürdüğünü göstermektedir. Çin'in bu alandaki ağırlığı, yayın sayısı yanında; çok branşlı araştırma grupları, devlet destekli projeler ve yüksek lisans, doktora programları aracılığıyla oluşturduğu akademik çevrede de kendisini hissettirmektedir. Bu, anomali tespiti alanının

küresel dağılımı, bilimsel üretim kadar politik ve stratejik araştırma yatırımlarının da bir yansıması olarak değerlendirilebilir.

ABD merkezli Ulusal Bilim Vakfı 2.246 destek ile listenin ikinci sırasında yer almakta ve özellikle makine öğrenimi, otonom sistemler ve güvenlik uygulamaları alanlarında anomali tespiti araştırmalarını fonlamaktadır. Bununla birlikte ABD Enerji Bakanlığı 653, NASA 408 ve ABD Ulusal Sağlık Enstitüsü 324 gibi sektörel odaklı kurumlar da konuya disiplinler arası bir yaklaşım getirmekte, enerji altyapısı, uzay sistemleri ve sağlık bilişimi gibi özel uygulama alanlarında anomali tespiti projelerini desteklemektedir.

Çizelge 2.3: Anomali tespitinin kurumsal katkı dağılımı.

Kurumsal Katkı Sağlayan	Yayın Adedi
Çin Bilimler Akademisi	1511
Çin Halk Cumhuriyeti Eğitim Bakanlığı	1062
Çin Bilimler Akademisi Üniversitesi	835
Fransa CNRS Ulusal Araştırma Merkezi	749
Tsinghua Üniversitesi	695
Zhejiang Üniversitesi	531
Harbin Teknoloji Enstitüsü	526
Şanghai Jiao Tong Üniversitesi	509
Pekin Posta ve Telekomünikasyon Üniversitesi	477
Çin Ulusal Savunma Teknolojisi Üniversitesi	454
Beihang Üniversitesi	437
Xidian Üniversitesi	401
Çin Elektronik Bilim ve Teknoloji Üniversitesi	388
Xi'an Jiaotong Üniversitesi	385
Wuhan Üniversitesi	383
Carnegie Mellon Üniversitesi	358
Huazhong Bilim ve Teknoloji Üniversitesi	337
Tokyo Üniversitesi	334
Pekin Jiaotong Üniversitesi	329
Sun Yat-Sen Üniversitesi	298

Avrupa Birliği düzeyinde Horizon 2020 Çerçeve Programı 1.040 destek ve Avrupa Komisyonu 1.016 destek başta olmak üzere, çeşitli yapılar altında sunulan fonlama mekanizmaları sayesinde çok uluslu projeler teşvik edilmektedir. Avrupa Bölgesel Kalkınma Fonu 548 da bölgesel teknoloji yatırımlarını anomali tespiti gibi dijital dönüşümle doğrudan ilişkili alanlara yönlendirmektedir. Ayrıca Almanya 311

destek, Fransa 350 destek ve Birleşik Krallık 363 destek gibi ülkeler de ulusal fonlama kurumları aracılığıyla sürece katkı sunmaktadır.

Doğu Asya ülkeleri de bu alanda kayda değer bir finansal varlık göstermektedir. Kore Ulusal Araştırma Vakfı 749 ve Kore Bilişim ve Gelecek Planlama Bakanlığı 499 gibi yapılar, özellikle IoT, siber güvenlik ve otomasyon alanlarında çalışan araştırma gruplarına doğrudan destek sağlamaktadır. Japonya Bilimi Geliştirme Derneği 546 destek ile sinyal işleme, sensör teknolojileri ve yapay zekâ tabanlı anomalilerin modellenmesine yönelik projeleri fonlamaktadır.

Bu dağılım, anomali tespitinin devlet politikaları ile örtüşen, yüksek teknoloji temelli, stratejik öncelik haline gelmiş bir araştırma alanı olduğunu ortaya koymaktadır. Aynı zamanda fon sağlayan kurumların geniş yelpazesi, bu konunun sağlık, enerji, güvenlik ve dijitalleşme gibi farklı sektörlerle ne denli entegre olduğunu da göstermektedir.

Çizelge 2.4: Anomali tespitine finansman sağlayan kuruluşlar.

Finansman Sağlayan Kurum	Yayın Adedi
Çin Ulusal Doğal Bilim Vakfı	7449
ABD Ulusal Bilim Vakfı	2246
Çin Ulusal Temel Araştırma ve Geliştirme Programı	2072
Merkezi Üniversiteler için Temel Araştırma Fonları	1085
Ufuk 2020 Çerçeve Programı	1040
Avrupa Komisyonu	1016
Kore Ulusal Araştırma Vakfı	749
ABD Enerji Bakanlığı	653
Avrupa Bölgesel Kalkınma Fonu	548
Japonya Bilimi Geliştirme Derneği	546
Kore Bilişim ve Gelecek Planlama Bakanlığı	499
Çin Doktora Sonrası Bilim Vakfı	438
Kanada Doğa Bilimleri ve Mühendislik Araştırma Konseyi	429
Federal Eğitim ve Araştırma Bakanlığı	413
ABD Ulusal Havacılık ve Uzay Dairesi	408
Bilgi ve İletişim Teknolojisi Geliştirme Enstitüsü	390
Mühendislik ve Fizik Bilimleri Araştırması Konseyi	363
Fransa Ulusal Bilimsel ve Teknolojik Kalkınma Konseyi	350
ABD Ulusal Sağlık Enstitüleri	324
Alman Araştırma Vakfı	311

2.1.5 Anomali tespiti çalışmalarının ülkelere göre dağılımı

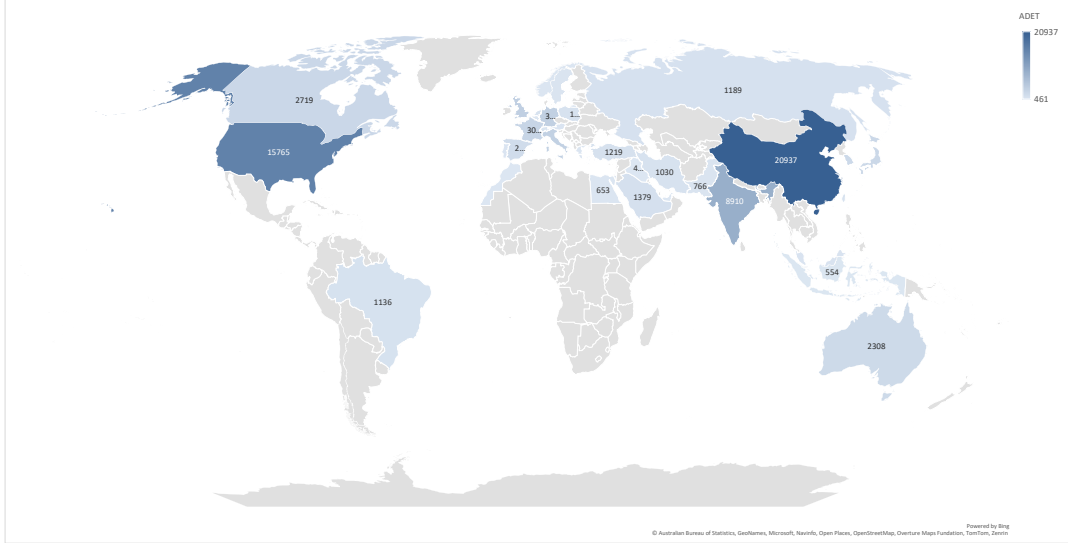
Scopus verileri, anomali tespiti alanındaki bilimsel yayınların küresel ölçekte dağılımında belirli ülkelerin ön plana çıktığını göstermektedir. Ülkeler bazında yapılan analizde, en yüksek yayın üretiminin yine Çin tarafından gerçekleştirildiği görülmektedir. Çin, toplamda 20.937 yayımla bu alanda açık ara lider konumundadır. Bu üretkenliği destekleyen faktörler arasında devlet destekli Ar-Ge programları, ulusal yapay zekâ stratejileri ve geniş araştırma altyapısı yer almaktadır.

Amerika Birleşik Devletleri, 15.765 yayımla ikinci sırada yer almakta olup, özellikle savunma, sağlık ve finans sektörlerinde anomali tespiti uygulamaları geliştiren çok sayıda üniversite ve özel kuruluş bu ülkenin bilimsel etkisini pekiştirmektedir. Hindistan, son yıllarda yapay zekâ alanında ivme kazanan ülkeler arasında yer almakta ve 8.910 yayımla dikkat çekici bir konumda bulunmaktadır.

Diğer önemli ülkeler arasında Fransa 3.955 yayımla, Almanya 3.776 yayımla ve Birleşik Krallık 3.557 yayımla listede yer almakta olup, bu ülkeler genellikle Avrupa Birliği destekli projeler aracılığıyla bilimsel üretim gerçekleştirmektedir. Bu veriler hem Asya hem de Batı dünyasında anomali tespitine yönelik yüksek düzeyde araştırma ve uygulama ilgisi olduğunu ortaya koymaktadır.

Anomali tespiti alanında Türkiye'nin bilimsel katkısı, sayısal olarak ilk 10 ülke arasında yer almamakla birlikte, Şekil 2.2'den de görüleceği gibi bölgesel olarak önemli aktörlerden biridir. Türkiye, savunma sanayii, görüntü işleme, siber güvenlik ve endüstri 4.0 uygulamaları başta olmak üzere birçok stratejik alanda anomali tespitine dayalı sistemler geliştirmektedir. TÜBİTAK[27,28], Savunma Sanayii Başkanlığı[28] ve çeşitli üniversiteler tarafından desteklenen projeler, bu alandaki akademik ve uygulamalı çalışmaları teşvik etmektedir.

Özellikle son beş yılda, Türkiye merkezli yayınlarda derin öğrenme, gömülü sistemlerde anomali analizi ve akıllı üretim hatlarında hata tespiti gibi temaların öne çıktığı gözlemlenmektedir. Bu durum, Türkiye'nin sırf tüketici değil, aynı zamanda teknoloji geliştiricisi bir aktör haline gelmekte olduğunu göstermektedir. Ulusal yapay zekâ stratejisi kapsamında belirlenen hedefler doğrultusunda, anomali tespiti alanındaki yayımların önümüzdeki yıllarda daha da artması beklenmektedir.




Şekil 2.2: Anomali tespiti makalelerinin ülkelere göre dağılımı.

Türkiye, küresel bilimsel üretim merkezlerinden biri olma potansiyelini taşıyan, stratejik coğrafi konumu ve genç araştırmacı nüfusu ile bu alanda yükselen bir aktör olarak değerlendirilmektedir. Özellikle Avrupa ve Asya arasında bir köprü görevi gören Türkiye'nin, çok disiplinli araştırmalar ve uluslararası iş birlikleri aracılığıyla literatürde daha fazla görünür hale gelmesi beklenmektedir.

2.1.6 Anomali tespiti hakkında literatür incelemesi özeti

Bu literatür incelemesi, anomali tespiti alanının kategoriler arası karakterini, küresel üretim dinamiklerini ve araştırma eğilimlerini çok boyutlu veriler ışığında ortaya koymuştur. Elde edilen bulgular, alanın akademik olarak ve uygulamalı olarak bir araştırma eksenine oturduğunu göstermektedir. Kurumsal katkıların büyük ölçüde Asya merkezli oluşu, özellikle Çin'in sistematik bilimsel yatırım politikalarının sonuçlarını yansıtmaktadır. Bununla birlikte, fonlama profilleri incelendiğinde yalnızca sayısal yoğunluk değil, tematik çeşitlilik de dikkat çekmekte; sağlık, enerji, siber güvenlik ve otonom sistemler gibi alanlarda derinleşen uygulamalar ön plana çıkmaktadır. Anahtar kelime analizleri, insan merkezli yaklaşımların, istatistiksel tekniklerle bütünleşerek veri madenciliğinden öğrenen sistemlere evrildiğini göstermektedir. Bu yönleriyle, anomali tespiti alanı önümüzdeki dönemde daha sofistike, açıklanabilir ve gerçek zamanlı çözümler üretmeye odaklanan bir yapıya doğru evrilmektedir. Bu çalışmanın sunduğu çok boyutlu literatür haritası hem akademik hem de sektörel düzeyde yeni araştırma konularının geliştirilmesine katkı sağlamayı planlamaktadır.



Şekil 2.3: Görüntü tabanlı anomali tespiti hakkında literatür analizi.

2.2 Görüntü Tabanlı Anomali Tespiti Hakkında Literatür Analizi

Görüntü temelli anomali tespiti, özellikle derin öğrenme yöntemlerinin yaygınlaşmasıyla birlikte son yıllarda hızla gelişen ve çok disiplinli yapısıyla öne çıkan bir araştırma alanıdır. Scopus veri tabanından 22 Haziran 2025 itibarıyla elde edilen güncel verilere dayanan analizler, bu alanın hem sayısal hem de yapısal olarak genişlediğini ortaya koymaktadır.

Şekil 2.3 'te görüldüğü gibi, 2020 sonrası dönemde yıllık yayın sayısında belirgin bir artış yaşanmıştır. 2021 yılında 693 olan yayın sayısı, 2024'te 1.564'e yükselmiş; 2025'in ilk yarısında ise 880'e ulaşmıştır. Scopus verileri bu artışın, görsel anomali tespitinin özellikle sanayide kalite kontrol, tıpta görüntüleme, güvenlik sistemleri ve otonom teknolojilerde yaygın biçimde kullanılmaya başlandığını göstermektedir.

Çalışmaların büyük kısmı Bilgisayar Bilimleri 5.397 yayın ve Mühendislik 4.027 yayın alanlarında yoğunlaşmakta; Matematik, Fizik ve Yer Bilimleri gibi teorik ve uygulamalı alanlar da önemli katkı sunmaktadır. En sık kullanılan anahtar kelimeler arasında Anomali Tespiti kelimesi 4.253 ve Derin Öğrenme kelimesi 1.571 yer almakta; bunun yanı sıra görüntü işleme, bölütleme (segmentasyon), öznelik çıkarımı ve oto-kodlayıcılar gibi teknik terimlerin sıkça kullanılması, yöntemsel çeşitliliğe işaret etmektedir.

Kurumsal katkı dağılımı incelendiğinde, en fazla yayını yine Çin Bilimler Akademisi 240 üretmiş; bunu Çin Eğitim Bakanlığı, Çin Bilimler Akademisi

Üniversitesi ve Xidian Üniversitesi takip etmiştir. Çin'in bu alandaki liderliği hem araştırma hem de finansman düzeyinde dikkat çekicidir. En çok destek sağlayan kuruluşlar arasında Çin Ulusal Doğa Bilimleri Vakfı 1.099 destek ve Çin Ulusal Ar-Ge Programı 232 destek ile öne çıkarken, ABD merkezli Ulusal Bilim Vakfı da 148 destek ile katkı sağlamaktadır.


Ülke bazında dağılımda Çin 2.763 yayın ilk sırada yer almakta; Amerika Birleşik Devletleri 1.119 ile onu takip ederken, Japonya 322, Rusya 308 ve Türkiye 133 yayını ile önemli ülkeler arasında bulunmaya devam etmektedir. Türkiye'nin üst sıralarda yer alması, özellikle görüntü işleme, savunma sanayii ve yapay zekâ tabanlı sistemlere yönelik ulusal projelerin bilimsel yayınlara dönüşmesiyle ilişkilidir.

Görüntü temelli anomali tespiti alanı, yükselen yayın grafiği ve uygulama çeşitliliği ile önümüzdeki yıllarda da önemini artıracak; gerçek zamanlı, güvenilir ve açıklanabilir sistemlerin geliştirilmesine öncülük edecek stratejik bir araştırma alanı olmaya devam edecektir.


3. GÖRÜNTÜ TABANLI ANOMALİ TESPİTİ

Anomali tespiti, veri kümesinde nadir görülen, normalden sapma gösteren veya beklenmeyen örneklerin belirlenmesi sürecini ifade eder ve siber güvenlikten sağlığa, finanstan üretim hatlarına kadar birçok disiplinde yaygın uygulama alanı bulmaktadır. Görüntü temelli anomali tespiti ise bu süreci görsel veriler üzerinden yürütmeyi hedefler; burada amaç, görüntülerdeki piksel, bölge ya da nesne düzeyindeki olağan dışı oluşumları saptamaktır. Bu tür anomaliler genellikle eğitim sırasında tanımlanan normal veri dağılımından sapmalar şeklinde kendini gösterir. Özellikle endüstriyel kalite kontrol, otonom sistemler, robotik görme ve güvenlik gibi alanlarda görüntü tabanlı anomali tespiti, üretim sürekliliğini sağlamak ve hataları erken evrede yakalamak açısından kritik rol oynamaktadır. Şekil 3.1 'e bu tez çalışmasında oluşturulan AIORCOM-TextileAD veri setinde eğitim aşamasında bir kumaş hatasının tespit edilmesi sürecinin eğitim aşaması gösterilmiştir. Şekil 3.2 'de bu tez çalışmasında oluşturulan modelin gerçek bir kumaş ile canlı ortamda anomali tespiti yapması ve işaretlemesi gösterilmiştir.

Görsel anomali tespiti konusundaki erken dönem yaklaşımlar, geleneksel görüntü işleme ve bilgisayarlı görü tekniklerine dayanmaktadır. Vincent Torre ve ekibi 1986 yılında insan gözü veya kamerada kenar algılamanın Gaussian Filtreler ile nasıl olabileceği hakkında bir yazı kaleme almışlardır[29].



Şekil 3.1: Bir anomalinin ısı haritası ile belirlenmesi örneği.



Şekil 3.2: Bir anomalinin işaretlenmesi örneği.

Kenar algılama konusunda aynı konu ve yöntem hakkında 2025 yılında dahi çalışmalar devam etmektedir. Li, Huanxu ve ekibi bozuk görsellerde Gaussian Filtreler ile kenar algılama konusunda farklı bir çalışma sunmuştur[30].

Pikseller 0 veya 255 arasında bir değer alabilirler. Bu ara değerler arasında hangi değer iyi veya hangi değer anomali olarak isimlendirilebileceği bir eşik değeri belirleme süreci ile belirlenir. Threshold denen bu belirleme görsel ve modele göre yapılır ve anomali tespitinde önemli konulardan biridir. Bu eşikleme video gibi ortamlarda dinamik olarak da yapılabilir [31].

Isı haritası analizleri[32], histogram analizleri[33] ve benzeri yöntemler belirli türdeki kusurları yakalamakta etkili olmuş; ancak karmaşık, değişken veya nadir görülen anomaliler karşısında sınırlı bir başarı sergilemişlerdir. Bu yöntemlerin çoğu, elle tanımlanmış özniteliklere dayanmakta ve çevresel değişkenliklere karşı duyarlılık göstermektedir. Makine öğrenmesine dayalı daha sonraki yaklaşımlar, öznitelik çıkarımında kısmi otomasyon sağlayarak bu sınırlamaları aşmaya çalışsa da veri boyutundaki artış ve kusur çeşitliliği karşısında yeterli esneklik ve genelleme kapasitesi sunamamıştır.

Derin öğrenme yaklaşımlarının hızla gelişmesiyle birlikte, görüntü tabanlı anomali tespiti alanında daha güçlü, genellenebilir ve hesaplama açısından verimli modeller ön plana çıkmıştır. Özellikle Evrimsel Sinir Ağı (CNN) mimarileri, görüntülerin yerel özelliklerini öğrenebilme kabiliyeti sayesinde, yüzey kusurları gibi görsel anomalilerin tanımlanmasında önemli başarılar sağlamıştır. CNN'ler, giriş görüntüsünü evrimsel katmanları aracılığıyla işleyerek kenar, desen ve doku gibi özellikleri çok katmanlı bir yapıda temsil eder. Buna ek olarak, son dönemde

yaygınlaşan transformer tabanlı mimariler, dikkat mekanizmaları sayesinde yalnızca yerel değil, aynı zamanda görüntüdeki uzak bölgeler arasındaki ilişkileri de modelleyerek daha kapsamlı bir temsil gücü sunmaktadır. Bu mimariler, özellikle yüksek boyutlu öznitelik haritaları üzerinden çalışarak normal veri örüntülerini daha isabetli biçimde öğrenebilen sistemlerin inşasına imkân vermektedir.

Bu gelişmeler doğrultusunda, gözetimsiz ve yarı gözetimli öğrenme stratejileri, kusurlu örneklerin sınırlı olduğu ya da hiç bulunmadığı üretim ortamlarında öne çıkan yaklaşımlar haline gelmiştir. Bu stratejilerde modeller yalnızca normal (kusursuz) örneklerle eğitilmekte; test aşamasında bu normal dağılımdan sapma gösteren veriler yüksek yeniden üretim hatası, istatistiksel sapma ya da özellik uyumsuzluğuna göre anomali olarak tanımlanmaktadır. Bu amaçla kullanılan oto kodlayıcı (Autoencoder) ve varyasyonel oto kodlayıcı yapıları, giriş görüntüsünü sıkıştırarak düşük boyutlu bir temsile dönüştürmekte, ardından bu temsilden yeniden üretim gerçekleştirerek orijinal görüntü ile olan fark üzerinden anomali skoru hesaplamaktadır. Generative Adversarial Network (GAN)[34] tabanlı yöntemler ise, normal veri dağılımını öğrenerek gerçekçi örnekler üretmekte; anormal örnekler, model tarafından düşük kaliteyle üretildiği için fark edilebilmektedir.

Son yıllarda geliştirilen PatchCore, FastFlow, EfficientAD ve GLASS gibi modeller, klasik yeniden üretim temelli yapılardan farklı olarak, özellik uzayında yoğunluk tahmini, akış temelli normalleştirme ve yapay anomali sentezi gibi mekanizmalarla çalışarak hem görüntü hem de piksel düzeyinde yüksek doğruluk ve işlem verimliliği sunmaktadır. Bu modellerin bazıları, yüksek hızda çıkarım yapılmasına olanak tanıyarak gerçek zamanlı kalite kontrol uygulamalarında kullanılabilirliğini artırmakta; bazıları ise küçük ve zor algılanan kusurlar üzerinde yüksek hassasiyetle çalışarak tekstil, elektronik ve otomotiv gibi endüstriyel alanlarda başarıyla uygulanmaktadır.

Tüm bu gelişmeler ışığında, görüntü tabanlı anomali tespiti akademik bir araştırma sahası olmaktan çıkıp, endüstride gerçek zamanlı karar destek sistemlerinin önemli bir bileşeni haline gelmiştir. Özellikle Endüstri 4.0 kapsamında, görsel veri temelli hata tespiti sistemleri, üretim süreçlerinin dijitalleşmesi ve akıllı otomasyon altyapılarının kurulmasında temel araçlardan biri olarak konumlanmaktadır. Yakın

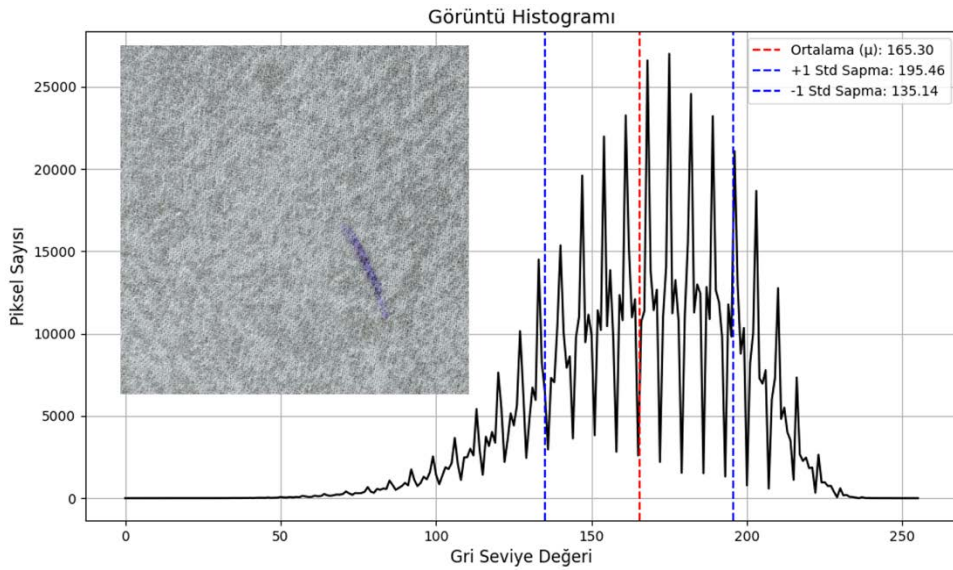
gelecekte model sadeleştirme, çoklu sensör füzyonu, hızlı çıkarım mimarileri gibi yeniliklerin yaygınlık kazanması öngörülmektedir. Bu tez kapsamında incelenen anomali tespiti yöntemleri de söz konusu eğilimlere ve endüstriyel gereksinimlere yanıt verebilecek nitelikteki yaklaşımların değerlendirmesini sunmayı hedeflemektedir.

3.1 Geleneksel Görüntü İşleme Tabanlı Yöntemler

Görüntü tabanlı anomali tespiti uygulamalarında, geleneksel görüntü işleme yöntemleri, çoğunlukla derin öğrenme öncesi dönemde yaygın şekilde tercih edilen yöntemlerdir. Bu yöntemler, görüntünün doğrudan matematiksel ve istatistiksel özelliklerinin çıkarılmasına dayanmakta olup, düşük hesaplama maliyeti, basit uygulanabilirlik ve kolay yorumlanabilirlik gibi avantajlara sahiptir. Temel olarak, istatistiksel ve histogram tabanlı yaklaşımlar ile doku analizi ve filtreleme tabanlı yaklaşımlar şeklinde iki grupta incelenebilir.

3.1.1 İstatistiksel ve histogram tabanlı yaklaşımlar

İstatistiksel yöntemler, görüntünün piksel değerlerinin istatistiksel özelliklerini kullanarak normalden sapmaları belirlemeyi amaçlar. Piksel yoğunluklarının ortalama, standart sapma, varyans, eğiklik ve basıklık gibi temel istatistiksel değerleri hesaplanarak, görüntünün genel dağılım karakteristiği hakkında bilgi



Şekil 3.3: İstatistiksel ve histogram tabanlı yaklaşım örneği.


edinilebilir. Şekil 3.3 'de veri setimizden örnek olarak seçilen hatalı bir görselin istatistiksel ve histogram tabanlı bir yaklaşım ile analiz sonucunu görmekteyiz.

3.1.2 Doku analizi ve filtreleme tabanlı yaklaşımlar


Doku analizi yöntemleri, görüntü üzerindeki dokusal farklılıkları ve anormallikleri belirlemek amacıyla kullanılır. Bu analizlerde sıkça başvurulan tekniklerden ikisi Yerel İkili Örüntüler (LBP) ve Gabor filtreleridir.

LBP yöntemi, Timo Ojala ve ekibi tarafından geliştirilmiş basit ama güçlü bir doku analiz tekniğidir[35]. Temelde görüntüdeki her pikseli kendi çevresindeki komşu pikseller ile karşılaştırarak çalışır. Bir pikselin çevresindeki komşuları, parlaklık değerlerine göre merkez pikselden büyük veya küçük olarak sınıflandırılır ve bu sınıflandırma sonucunda bir ikili sayı dizisi oluşur. Bu ikili sayı dizisi sonrasında ondalık bir değere dönüştürülerek, her pikselin dokusal kimliği belirlenmiş olur. Elde edilen değerler, görüntünün dokusunu tanımlayan bir histogramda birleştirilir. LBP yöntemi özellikle yüz tanıma, kalite kontrol, anomali tespiti ve tıbbi görüntüleme gibi uygulamalarda başarıyla kullanılmaktadır.

Gabor filtresi[36], Dennis Gabor tarafından ortaya atılan bir matematiksel yöntem olup, görüntü işlemede dokuların analizinde çok popüler hale gelmiştir. Bu filtre, görüntüyü farklı frekans ve yönlerde tarayarak belirli dokusal özellikleri vurgulamak için kullanılır. Gabor filtreleri sayesinde, dokunun hangi yön ve frekanslarda baskın özelliklere sahip olduğu tespit edilir. Özellikle farklı yönlerde tekrar eden desenleri belirlemek için idealdir. Bu özellikleri sayesinde, yüz ifadelerinin tanımlanması, parmak izi analizleri[37], kumaş veya yüzeylerdeki hataların ve kusurların tespiti gibi alanlarda yaygın olarak kullanılır[38]. Bu yöntemlerin her ikisi de basit hesaplama süreçleri ve güçlü analiz yetenekleri nedeniyle, görüntü işleme ve doku analizi alanında yaygın kabul görmüş, endüstriyel kalite kontrol ve anomali tespiti sistemlerinin temel bileşenleri haline gelmiştir. Şekil 3.4 'de LBP yöntemiyle doku analizi sonuçları gösterilmiştir. Şekil 3.5 'de ise Doku Analizi ve Filtreleme tabanlı yaklaşımlardan olan Gabor Filtresi ile filtrelenmiş bir anomali tespit görseli bulunmaktadır.



Şekil 3.4: LBP doku analizi ve filtreleme tabanlı yaklaşım örneği.



Şekil 3.5: Gabor Filtresi uygulama örneği.

3.2 Makine Öğrenmesi Tabanlı Yöntemler

Makine öğrenmesi tabanlı anomali tespiti yöntemleri, görüntülerden elde edilen özniteliklerin analiz edilerek verilerin sınıflandırılması ya da kümelenmesi esasına dayanır. Bu yaklaşımlar, doğrudan piksel düzeyinde işlem yapmak yerine, görüntüden çıkarılan istatistiksel ya da yapay öğrenilmiş özellikleri temel alır. Öğrenme stratejileri genel olarak denetimli, yarı denetimli ve denetimsiz olarak üçe ayrılabilir. Görüntü tabanlı anomali tespitinde kusurlu örneklerin azlığı veya etiketlenmesinin zorluğu nedeniyle denetimsiz ve yarı denetimli yöntemler daha işlevsel bulunmakta ve uygulamalarda daha sık tercih edilmektedir.

3.2.1 Denetimli öğrenme yaklaşımları

Denetimli öğrenme, etiketlenmiş eğitim verileri kullanılarak, giriş verilerinin hangi sınıfa örneğin normal veya anomali olabilir, ait olduğunu belirlemeyi öğrenen yöntemleri ifade eder. Görüntü tabanlı anomali tespitinde denetimli yaklaşımlar, normal ve anormal görüntü örneklerinin önceden net olarak bilindiği durumlarda kullanılabilir. Bu tez çalışmasında seçilen modelde denetimli öğrenme yaklaşımı kullanılmıştır.

Denetimli öğrenme temelli anomali tespiti yöntemleri, önceden etiketlenmiş verilerden öğrenerek yeni örnekleri sınıflandırmak amacıyla geliştirilmiş algoritmalara dayanır. Bu yöntemler, belirli bir sistemin normal ve anormal durumlarını temsil eden etiketli örneklerin kullanılmasıyla eğitilir. Sınıflandırma algoritmaları, verilen bir girdi örneğinin hangi sınıfa ait olduğunu tahmin etmeye çalışır. Sıklıkla kullanılan yöntemler arasında Destek Vektör Makineleri (SVM), Lojistik Regresyon, Karar Ağaçları, Rastgele Ormanlar ve k-En Yakın Komşu (k-NN) yer almaktadır. Her biri farklı prensiplerle çalışsa da temel amaç, veri örneklerini önceden tanımlanmış sınıflara doğru şekilde ayıran karar sınırlarını öğrenmektir.

SVM, 1995 yılında Corinna Cortes ve Vladimir Vapnik tarafından geliştirilmiş olup, iki sınıf arasında maksimum ayrımı sağlayan hiper düzlemi bulmayı amaçlar. Ekip ayrıca çalışmasını R.A. Fisher'in 1936 yılındaki çalışması olan ilk doku algılama algoritmasına dayandırır[39]. SVM, özellikle düşük örnek sayısı ile çalışılan, ancak ayrımın net olduğu problemlerde oldukça başarılıdır.

Lojistik regresyon ise doğrusal bir model olup, girdinin belirli bir sınıfa ait olma olasılığını sigmoid fonksiyonu aracılığıyla tahmin eder. Lojistik regresyon, kökeni 1838 yılına dayanan lojistik fonksiyonun Pierre François Verhulst tarafından nüfus büyümesini modellemek amacıyla geliştirilmesine dayanmakla birlikte[40], modern anlamda istatistiksel sınıflandırma yöntemi olarak kullanımı 1958 yılında İngiliz istatistikçi David Cox tarafından sistematikleştirilmiştir. Cox, ikili sonuç değişkenlerini modellemek için lojistik fonksiyonu kullanan regresyon yapısını tanımlayarak, günümüzde tıp, sosyal bilimler ve makine öğrenmesi gibi birçok alanda yaygın biçimde kullanılan lojistik regresyon modelinin temellerini atmıştır[41].


Karar ağaçları, veriyi belirli özelliklere göre sıralı biçimde dallara ayırarak sınıflandırma veya regresyon yapan, sezgisel olarak anlaşılması kolay ve yorumlanabilir bir makine öğrenmesi yöntemidir. Bu yapı, her bir düğümde bir özellik üzerinden ayırım yapar; veri, bu düğümdeki koşula göre alt dallara ayrılır ve bu işlem, yaprak düğümler elde edilene kadar devam eder. Sonuçta her yaprak, sınıf etiketlerinden birini temsil eder. Karar ağaçları, 1986 yılında Ross Quinlan tarafından geliştirilen ID3 algoritmasıyla modern formuna kavuşmuş[42]. ID3 karar ağaçlarının oluşturulmasında kullanılan öncü bir algoritmadır. Dikotomik terimi, veriyi her adımda ikiye ayırma anlamına gelir; ID3 algoritması da bu prensiple çalışır. Her düğümde en fazla bilgi kazancı sağlayan özelliği seçerek veri kümesini iki alt gruba böler ve bu işlemi yinelemeli olarak sürdürür. “3” ifadesi, bu algoritmanın aynı araştırmacı tarafından geliştirilen üçüncü sürümü olduğunu belirtir. ID3, bilgi teorisine dayalı karar mekanizmasıyla sınıflandırma problemlerinde etkili ve sezgisel bir çözüm sunarak, daha sonra geliştirilen C4.5, C5.0 ve CART (Classification and Regression Trees) gibi daha gelişmiş versiyonlarıyla yaygınlaşmıştır[43]. Bu yöntem, özellikle sınıflandırma kararlarının görselleştirilebilir ve açıklanabilir olması nedeniyle tıp, finans, üretim ve eğitim gibi alanlarda sıklıkla tercih edilmektedir.

Bu yapının istatistiksel varyasyonunu sağlayan Rasgele Orman algoritması ise, birçok karar ağacının birlikte çalıştığı topluluk yöntemlerinden biridir ve genellikle daha yüksek doğruluk sunar. Random Forest algoritması, 2001 yılında Leo Breiman tarafından geliştirilen, birden fazla karar ağacının birlikte çalıştığı bir topluluk öğrenme yöntemidir. Bu yapı, her bir ağacın eğitiminde rastgele seçilen veri alt kümeleri (bootstrap örnekleme) ve özniteliklerin (random feature selection) kullanılmasıyla modelin çeşitliliğini artırır ve aşırı öğrenme (overfitting) riskini azaltır. Her bir karar ağacı, eğitildiği veriyle bağımsız olarak tahmin yapar; sınıflandırma görevlerinde bu tahminler çoğunluk oylamasıyla, regresyon görevlerinde ise ortalama alınarak nihai sonuç belirlenir. Random Forest, özellikle yüksek boyutlu ve karmaşık veri kümelerinde kararlı ve yüksek doğruluklu sonuçlar sunmasıyla, birçok alan için güvenilir bir yöntem haline gelmiştir[44].

K-NN algoritması ise sınıflandırılacak verinin, eğitim veri kümesindeki en yakın komşularının sınıf etiketlerine göre karar verir ve parametresiz yapısı ile dikkat çeker. k-En Yakın Komşu (k-Nearest Neighbors, k-NN) algoritması, 1951 yılında

Evelyn Fix ve Joseph Hodges tarafından ortaya konmuş ve daha sonra 1967’de Thomas Cover ile Peter Hart tarafından geliştirilerek sınıflandırma ve regresyon problemlerinde uygulanabilir hale getirilmiştir[45]. Bu algoritma, öğrenme aşamasında model eğitimi gerçekleştirmez; bunun yerine karar verme işlemi tamamen test verisiyle karşılaşıldığında gerçekleştirilir. Yeni bir veri noktası sınıflandırılmak istendiğinde, bu noktanın eğitim veri kümesindeki tüm örneklerle olan uzaklığı Öklidyen mesafe hesaplanır ve en yakın k adet komşu belirlenir. Bu komşuların sınıf etiketlerine bakılarak çoğunluk oylamasıyla yeni örneğin sınıfı tahmin edilir. Modelin parametresiz olarak kabul edilmesinin nedeni, öğrenme sırasında herhangi bir ağırlık güncellemesi veya parametre optimizasyonu yapılmamasıdır; bu yönüyle k-NN oldukça sezgisel, açıklanabilir ve veri dağılımına duyarlı bir yöntem olarak öne çıkar. Ancak büyük veri kümelerinde hesaplama maliyeti yüksek olabileceği için pratik uygulamalarda uygun mesafe metrikleri ve veri yapıları ile optimize edilmesi gerekebilir.

Denetimli öğrenme yöntemleri güçlü sınıflandırma performansı sunmasına rağmen, bu yaklaşımların temel sınırlılığı, her iki sınıfa (normal ve anormal) ait yeterli sayıda ve dengeli biçimde etiketlenmiş veriye olan bağımlılığıdır. Özellikle üretim



Şekil 3.6 : Denetimli öğrenme yaklaşımları SVM örneği.

hatları, medikal görüntüleme veya siber güvenlik gibi alanlarda anomaliye ait örneklerin nadir olması, denetimli algoritmaların başarısını düşürmekte ve genellikle aşırı öğrenme riskini artırmaktadır. Ayrıca, anomali tiplerinin sürekli değiştiği dinamik sistemlerde, her yeni anomali için yeniden etiketleme ve model eğitimi gerekmesi bu yöntemlerin sürdürülebilirliğini kısıtlamaktadır. Bu nedenlerle, görüntü tabanlı anomali tespitinde denetimsiz ve yarı denetimli yaklaşımlar çoğu zaman daha esnek ve uygulanabilir çözümler sunmaktadır.

Bu tezin ileriki bölümlerinde kullandığımız GLASS modeli bir denetimli öğrenme modeli örneğidir. O kısma geçmeden önce veri setimizde bulunan bariz bir hatayı bulabilecek basit bir SVM Python kodu örnek hata işaretlemesi Şekil 3.6 'da gösterilmiştir.

3.2.2 Yarı denetimli öğrenme yaklaşımları

Görüntü tabanlı anomali tespitinde karşılaşılan temel zorluklardan biri, anomalilere ait örneklerin önceden bulunmasının veya yeterli miktarda toplanmasının zor olmasıdır. Bu zorluğun üstesinden gelmek için yarı denetimli ve denetimsiz öğrenme yöntemleri sıklıkla tercih edilir.

Yarı denetimli öğrenme yaklaşımları, genellikle yalnızca normal sınıfa ait örneklerin mevcut olduğu veya anomalilere ait örneklerin sınırlı ve yetersiz olduğu durumlarda kullanılır. Bu yaklaşımın temel varsayımı, sistemin normal durumun ne olduğunu öğrenmesi ve buna uymayan örneklerin otomatik olarak anomali kabul edilmesidir. Bir başka ifadeyle, yarı denetimli yöntemlerde anomali tanımı, normal davranıştan sapmalar şeklinde gerçekleştirilir. Bu durum, gerçek dünya senaryolarına oldukça uygundur, çünkü genellikle normal örneklerin büyük miktarda bulunduğu ancak anomalilerin nadiren görüldüğü durumlar söz konusudur.

Tek Sınıf Destek Vektör Makineleri ya da kısaca OC-SVM, 1996 yılında Bernhard Schölkopf ve çalışma arkadaşları tarafından geliştirilen ve özellikle denetimsiz anomali tespiti problemleri için önerilen bir yöntemdir. OC-SVM, yalnızca normal (kusursuz) örneklerden oluşan veri kümesini kullanarak, bu örneklerin yer aldığı öznitelik uzayında en iyi sınırlanmış bölgeyi tanımlamaya çalışır. Modelin amacı, normal verilerin çoğunluğunu kapsayan bir karar yüzeyi oluşturmak ve bu yüzeyin dışında kalan verileri olağandışı (anomali) olarak sınıflandırmaktır.

Çekirdek fonksiyonları kullanılarak doğrusal olmayan sınırlar da öğrenilebilir, bu da yöntemin karmaşık veri yapılarıyla başa çıkabilmesini sağlar. Özellikle kusurlu örneklerin nadir veya bilinmediği durumlarda yaygın biçimde kullanılan OC-SVM, endüstriyel kalite kontrol, siber güvenlik ve sağlık gibi alanlarda etkili bir şekilde uygulanmaktadır[46].

Isolation Forest (İzolasyon Ormanı) ise, 2008 yılında Fei Tony Liu, Kai Ming Ting ve Zhi-Hua Zhou tarafından geliştirilmiş, denetimsiz bir anomali tespiti algoritmasıdır. Bu yöntem, geleneksel yoğunluk tahmini ya da mesafe ölçümüne dayalı yaklaşımlardan farklı olarak, anomalileri izole etme prensibiyle çalışır. Temel varsayımı, anormal örneklerin veri kümesinde nadir görülmesi ve diğer örneklerden farklı özelliklere sahip olması nedeniyle daha az bölme (ayırma) işlemiyle izole edilebileceğidir. Algoritma, rastgele alt veri kümeleri seçerek bu alt kümelerde rastgele özellik ve eşik değerleriyle karar ağaçları oluşturur. Her veri örneği için, bu ağaçlarda kaç adımda izole edilebildiği ölçülür; anomali olarak değerlendirilen örnekler genellikle daha kısa yol uzunluklarıyla ayrılabilirdiğinden daha yüksek anomali skoru alır. Ölçeklenebilirliği yüksek, parametrik olmayan ve büyük veri kümelerinde etkin çalışan Isolation Forest, özellikle yüksek boyutlu veri setlerinde anomali tespiti için sıkça tercih edilen bir yöntemdir[47].


Yerel Aykırı Değer Faktörü LOF, 2000 yılında Markus Breunig tarafından geliştirilen ve özellikle yarı denetimli ya da denetimsiz öğrenme senaryolarında kullanılan bir anomali tespiti yöntemidir. Bu algoritma, bir veri noktasının çevresindeki diğer noktalara göre ne kadar yoğunluk dışı olduğunu hesaplayarak aykırılık derecesini belirler. LOF, her veri noktasının yerel yoğunluğunu, komşu noktaların yoğunluğu ile karşılaştırır; yoğunluğu komşularına göre anlamlı biçimde düşük olan noktalar potansiyel aykırı değer olarak işaretlenir. Böylece küresel yapıyı değil, her noktanın bulunduğu bölgedeki yerel yapıyı dikkate alarak değerlendirme yapar ve veri kümesindeki yoğunluk değişimlerine duyarlı bir yaklaşım sunar.

LOF algoritmasının temel avantajı, veri kümesindeki farklı yoğunluk bölgelerine uyum sağlayabilmesi ve yalnızca uç değerleri değil, bağlama göre anomalileri tanımlayabilmesidir. Bu özellik, özellikle karmaşık ve dengesiz dağılımlara sahip veri kümelerinde geleneksel yöntemlere göre daha isabetli anomali tespiti yapılmasını sağlar. Model herhangi bir sınıf etiketine ihtiyaç duymadan

çalışabildiği için çoğunlukla denetimsiz anomali tespiti kapsamında değerlendirilse de yalnızca normal verilerle eğitildiğinde yarı denetimli öğrenme senaryolarında da başarılı şekilde kullanılmaktadır. Özellikle üretim süreçleri, dolandırıcılık tespiti ve ağ güvenliği gibi alanlarda, nadir görülen ancak kritik öneme sahip anomalliklerin belirlenmesinde yaygın olarak tercih edilmektedir[48].

Tekstil sektöründe kumaşın yüzey görüntüleri incelenirken, hatasız kumaşlardan oluşan çok sayıda görüntü ile model eğitilebilir. Bu eğitim sonucunda, kumaşın normal dokusal özelliklerini öğrenen model, daha sonra yeni görüntülerdeki anormal durumları örneğin dokudaki bozuklukları, lekeleri veya farklı desenleri otomatik olarak anomali olarak algılayabilir.

Yarı denetimli öğrenme yöntemlerinden biri olan Isolation Forest (İzolasyon Ormanı) yöntemini kullanarak veri setimizde bulunan görüntü.png dosyasındaki anomalileri tespit eder. Bu yöntem, yalnızca normal bölgelerin çoğunlukta olduğu varsayımıyla, görüntü içindeki nadir bölgeleri (anomali) otomatik olarak bulacaktır. Şekil 3.7 'de Yarı Denetimli bir model olan Isolation Forest ile tespit edilen anomali



Şekil 3.7: Yarı denetimli öğrenme yaklaşımları isolation forest örneği.

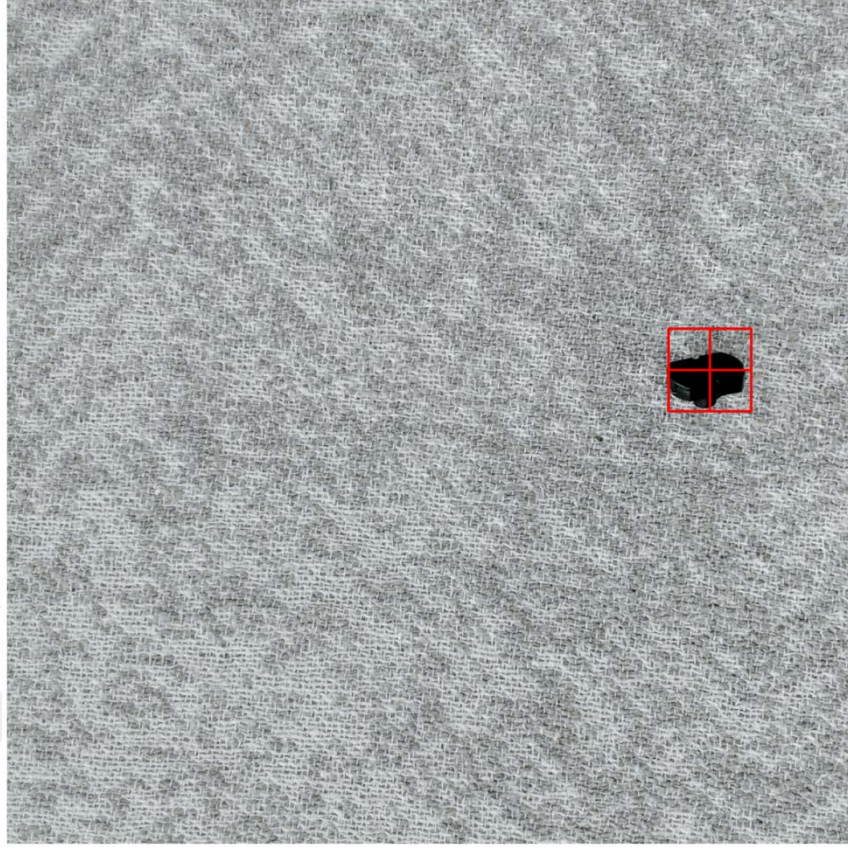
bölgeler görülmüştür. Hatalı pozitif oranı yüksek olsa da anomali bölgesinin de işaretlendiği görülmüştür.

3.2.3 Denetimsiz öğrenme yaklaşımları

Denetimsiz öğrenme, veri üzerinde herhangi bir etiketleme yapılmaksızın, örnekler arasındaki benzerlik ve yapısal örüntülere dayanarak bilgi çıkarmayı amaçlayan bir makine öğrenmesi yaklaşımıdır. Bu yöntemlerde sistem, verinin altında yatan doğal gruplamaları, istatistiksel yapıları veya yoğunluk bölgelerini keşfederek öğrenme sürecini gerçekleştirir. Anomali tespiti bağlamında denetimsiz öğrenme, özellikle kusurlu örneklerin etiketlenmesinin mümkün olmadığı ya da ekonomik olmadığı durumlarda tercih edilir. Görüntü tabanlı uygulamalarda bu yöntemler, görüntüdeki benzer özniteliklere sahip piksellerin veya bölgesel yapıların gruplanmasını sağlar ve normallerle örtüşmeyen yapılar anomali olarak değerlendirilir.

Bu kapsamda kullanılan en yaygın algoritmalarından biri olan k-means kümeleme algoritması, 1967 yılında James MacQueen tarafından tanıtılmıştır. Bu algoritma, veri kümesindeki her bir örneği, önceden belirlenen k sayıda kümenin merkezlerine olan uzaklığına göre atar ve merkezleri yinelemeli olarak güncelleyerek kümeleri optimize eder. Veri kümesinde bu merkezlerden uzak olan ya da hiçbir kümeye net şekilde ait olmayan örnekler, potansiyel aykırı değer olarak kabul edilir. Görüntü analizinde, örneğin dokusal özellikleri farklı olan küçük bölgeler genellikle bu sınırlardan saparak anomali işareti verir[49].

Bir diğer yaygın yöntem olan DBSCAN, Gürültülü Uygulamaların Yoğunluk Tabanlı Mekânsal Kümelenebilirliği 'dir. 1996 yılında Martin Ester ve ekibi tarafından geliştirilmiştir. Bu algoritma, yoğunluk tabanlı bir kümeleme yaklaşımı sunar ve birbirine yeterince yakın olan örnekleri aynı küme içerisinde toplarken, yoğunluk bölgelerinden izole kalan noktaları aykırı değer olarak tanımlar. DBSCAN 'in en önemli avantajı, önceden küme sayısı belirtmeyi gerektirmemesi ve farklı yoğunluk bölgelerini tanıyabilmesidir. Ayrıca hiyerarşik kümeleme yöntemleri, veri noktaları arasındaki benzerliklere göre bir ağaç yapısı oluşturarak, daha üst düzey yapılarla ilişkili kümeleşme desenleri çıkarmaya olanak tanır. Bu yöntem, anomalilerin genellikle küçük ve ayrı kümeler halinde kalmasını temel alarak anomali değerlendirmesi yapar[50].



Şekil 3.8: K-means denetimsiz öğrenme algoritması ile anomali tespiti örneği.

GMM Normal Karışım Modelleri, olasılık temelli denetimsiz öğrenme yöntemleri arasında yer alır. GMM, veri dağılımının birden fazla Gauss dağılımının birleşiminden oluştuğunu varsayar ve her veri noktasının bu dağılımlardan hangisine ait olduğunu istatistiksel olarak değerlendirir. Düşük olasılıkla herhangi bir bileşene ait olan örnekler, sistem tarafından doğal olarak anomali olarak tanımlanır. GMM, özellikle yüksek boyutlu ve sürekli özniteliklere sahip verilerde esnekliği ve yorumlanabilirliği sayesinde sıklıkla tercih edilir. Bu yöntemler, etiketli veriye gerek duymaksızın görüntüdeki olağandışı yapıları tespit etmeye olanak tanıyarak, anomali tespiti problemlerine güçlü bir çözüm sunar.

Şekil 3.8 'de denetimsiz öğrenme yöntemlerinden biri olan k-means algoritmasını kullanarak, veri setimizdeki açık anomali örneği olan bir görüntüdeki anomalileri otomatik olarak tespit eder. K-means kümeleme: Görüntüden çıkarılan özellikleri benzerliklerine göre otomatik olarak kümeler. Kümeler arasında özellikleri açısından farklı olan kümeler, anomali olarak değerlendirilebilir.

3.3 Derin Öğrenme Tabanlı Anomali Tespiti Yöntemleri

Son yıllarda derin öğrenme tabanlı yöntemler, görüntüye dayalı anomali tespiti uygulamalarında önemli ölçüde öne çıkmıştır. Bu yöntemlerin temel avantajı, manuel öznitelik mühendisliğine ihtiyaç duymadan, görüntülerden anlamlı ve çok katmanlı temsilleri otomatik olarak öğrenebilmeleridir. Bu sayede, geleneksel tekniklerin sınırlı kaldığı karmaşık kusur yapıları daha doğru ve güvenilir biçimde tanımlanabilir hale gelmiştir. Derin öğrenmeye dayalı anomali tespiti yaklaşımları, genel olarak yeniden üretim temelli modeller, derin özellik haritaları üzerinden karşılaştırma yapan yapılar, üretici-karşıt öğrenme stratejileri, Öz denetimli ve öğretmen-öğrenci mimarileri ile transformer tabanlı çağdaş yöntemler şeklinde sınıflandırılmaktadır.

3.3.1 Yeniden yapılandırma tabanlı yaklaşımlar

Yeniden yapılandırma (reconstruction) temelli anomali tespiti yaklaşımları, yalnızca normal verilerle eğitilmiş modellerin test aşamasında olağandışı örnekleri yeniden üretmekte zorlanacağı varsayımına dayanır. Bu yöntemlerde model, eğitim sürecinde yalnızca kusursuz (normal) görüntüleri görerek bu sınıfa ait temel özellikleri öğrenir. Ardından test aşamasında verilen her yeni görüntüyü yeniden oluşturmaya çalışır; eğer görüntüde anomali varsa model bu bölgeleri doğru şekilde yeniden oluşturamaz ve ortaya çıkan fark, yani yeniden yapılandırma hatası, anomali skoru olarak kullanılır. Bu çerçevede en yaygın kullanılan yapılardan biri olan Otokodlayıcı modeli, ilk olarak 1980'lerde Geoffrey Hinton öncülüğünde tanımlanmış ve temsil öğrenme alanında önemli bir dönüşüm başlatmıştır[51]. Otokodlayıcı yapısı, giriş verisini sıkıştırarak gizli bir temsile dönüştürür ve bu temsilden yeniden orijinal veriyi üretmeyi amaçlar; bu yapı, anomali içermeyen örneklerde başarılı sonuçlar verirken, anormal örneklerde yüksek hata üretir. Bu yöntem, endüstriyel kalite kontrol sistemlerinden medikal görüntü analizlerine kadar çeşitli alanlarda, etiketli kusurlu veri gerektirmemesi ve yorumlanabilir hata haritaları üretmesi nedeniyle yaygın biçimde tercih edilmektedir.

3.3.2 Özellik haritası ve temsil öğrenme tabanlı yaklaşımlar

Özellik haritası ve temsil öğrenme tabanlı yaklaşımlar, görüntülerin düşük seviyeli piksel bilgileri yerine daha soyut, çok boyutlu ve anlamsal özelliklerle temsil

edilmesini amaçlayan derin öğrenme temelli yöntemlerdir. Bu kavramsal yaklaşım, 2013 yılında Yoshua Bengio ve arkadaşları tarafından ortaya konmuş ve representation learning, yani temsil öğrenimi başlığı altında tanımlanmıştır. Temel fikir, modelin ham veriden otomatik olarak ayrıştırıcı nitelikte özellikleri öğrenmesi ve bu özellikler üzerinden daha isabetli kararlar verebilmesidir. Görüntü işleme alanında bu tür temsil öğrenimi genellikle CNN yapıları aracılığıyla gerçekleştirilir. CNN mimarileri, görüntülerden farklı çözünürlük seviyelerinde öznelikler çıkararak nesne, desen, doku ve yapısal ilişkiler gibi karmaşık örüntüleri yüksek boyutlu özellik haritalarına dönüştürür[52].

Anomali tespitinde kullanılan özellik haritası temelli yöntemler, görüntünün bu temsil uzayındaki dağılımını öğrenerek normal örneklerin oluşturduğu istatistiksel yapıdan sapmaları belirlemeyi hedefler. Özellikle yalnızca normal verilerle eğitilen modeller, test aşamasında karşılaşılan anormal örneklerin bu temsil uzayında daha uzak, seyrek veya olağandışı konumlarda yer almasını bir anomali sinyali olarak algılar. Bu tür modellerde genellikle görüntü özneliklerinin çok katmanlı olarak çıkarılması, global ortalama ve varyans gibi istatistiksel özetlerle temsil edilmesi ve benzerlik metrikleri ile sapma analizinin yapılması temel işlemleri oluşturur. Örneğin PatchCore yöntemi, görüntü yamalarının yüksek boyutlu özneliklerini saklayarak k-en yakın komşu benzeri bir karşılaştırma yapısı kurarken; PaDiM[53] yöntemi ise her konumda Gauss dağılımları öğrenerek test aşamasında Mahalanobis uzaklığı ile anomali skorları üretmektedir.

Temsil öğrenimi tabanlı bu yaklaşımlar, yalnızca yüksek doğrulukta anomali tespiti sunmakla kalmaz, aynı zamanda segmentasyon haritaları ile anomalilerin yerini belirleyebilir, açıklanabilirlik açısından anlamlı görsel çıktılar üretebilir ve geleneksel yeniden yapılandırma tabanlı yöntemlere göre daha az bilgi kaybı ile çalışabilir. Özellikle üretim hatları gibi detaylı yüzey analizi gerektiren alanlarda, bu yöntemler hem işlem verimliliği hem de görsel hassasiyet açısından geniş bir uygulama potansiyeline sahiptir.

3.3.3 Üretici veya karşıt öğrenme tabanlı yaklaşımlar

Üretici ve karşıt öğrenme tabanlı yaklaşımlar, özellikle karmaşık veri dağılımlarını modelleyerek olağandışı örneklerin tanımlanmasında etkili sonuçlar sunan derin öğrenme yöntemlerindedir. Bu yaklaşımların temelini, 2014 yılında Ian

Goodfellow ve çalışma arkadaşları tarafından geliştirilen Generative Adversarial Networks (GAN) modeli oluşturur. GAN, birbirine karşı iki sinir ağından oluşur, biri sahte veri üretmeye çalışan üretici, diğeri ise bu sahte verileri gerçek olanlardan ayırt etmeye çalışan ayırt edicidir. Bu iki ağ, birbirlerine karşı rekabet ederek eğitilir; üretici ağ, zamanla gerçek görüntülere oldukça benzeyen veriler üretmeyi öğrenir[54].

Anomali tespiti olarak GAN tabanlı yöntemler, genellikle yalnızca normal örneklerle eğitilir. Bu sayede üretici ağ, normal örneklere benzer görüntüler üretmeyi öğrenir. Test aşamasında, modele anomali içeren bir görüntü verildiğinde, bu görüntünün yeniden üretiminde zorluk yaşanır ve üretici ağın çıktısı ile gerçek görüntü arasında belirgin farklar oluşur. Bu fark anomali skoru olarak değerlendirilir. Ayrıca, bazı yaklaşımlar bu farkı yalnızca görüntü uzayında değil, ara katmanlardaki öznitelik temsilleri üzerinden de ölçerek daha hassas bir tespit gerçekleştirebilir.

GAN tabanlı modeller, özellikle dokusal bozulmalar ve yapısal anomaliler gibi geleneksel yöntemlerin zorlandığı örüntüleri başarıyla ayırt edebilme yetenekleriyle dikkat çeker. Özellikle yüzey analizi, endüstriyel denetim ve tıbbi görüntüleme gibi alanlarda, GAN mimarileri anomali bölgelerini detaylı biçimde ortaya koyabilmektedir. Ancak eğitim süreci kararsızlık, mod çökmesi, gibi sorunlara açık olduğundan, uygulamada dikkatli hiperparametre seçimi ve denetimli dengeleme stratejileri gerekir. Bu yönleriyle GAN tabanlı anomali tespit yöntemleri, temsil gücü yüksek, ancak dikkatli eğitilmesi gereken güçlü bir araç olarak değerlendirilmektedir. Tez sürecimizde kullandığımız GLASS modeli ayrıca GAN algoritmasını kullanan bir modeldir.

3.3.4 Öz denetimli ve öğretmen öğrenci stratejileri

Öz denetimli (self-supervised) öğrenme stratejileri, etiketlenmiş veri ihtiyacını ortadan kaldırarak modelin veriden kendi iç yapısını öğrenmesini amaçlayan bir yaklaşımdır ve ilk sistematik temelleri 2019 yılında Yann LeCun ve ekibi tarafından ortaya konmuştur. Bu yöntemlerde model, görüntüleri doğrudan yeniden üretmek yerine, belirli bir ön görev aracılığıyla eğitilir. Bu görevler arasında görüntü parçalarının doğru sıraya dizilmesi, döndürülmüş bir görüntünün orijinal yönünün tahmin edilmesi ya da eksik bölümlerin doldurulması gibi basit ama bilgi taşıyan

görevler yer alır. Model yalnızca normal görüntüler üzerinde bu görevleri öğrenir ve test aşamasında anomali içeren görüntüler verildiğinde modelin bu görevlerdeki başarımı düşer. Performanstaki bu sapma, örneğin beklenmeyen bir yön tahmini hatası veya yanlış sıralama, sistem tarafından anomali sinyali olarak değerlendirilir. Öz denetimli yöntemler, özellikle etiketsiz veriyle yüksek doğrulukta tespit yapılabilmesini mümkün kıldığı için son yıllarda anomali tespitinde hızla yaygınlaşmıştır[55].

Öğretmen öğrenci stratejileri ise, ilk olarak 2006 yılında Geoffrey Hinton tarafından bilgi damıtma kavramı altında tanıtılmış ve daha sonra anomali tespitinde özelleştirilmiş versiyonları geliştirilmiştir. Bu yöntemde, yüksek kapasiteli ve iyi eğitilmiş bir öğretmen modeli, normal görüntüler üzerinden elde ettiği temsilleri daha küçük ve hafif bir öğrenci modeline öğretir. Eğitim süreci yalnızca normal örnekler kullanılarak yürütülür ve öğrenci model, öğretmenin çıktılarıyla mümkün olduğunca benzer sonuçlar üretmeyi öğrenir. Test aşamasında ise anormal görüntüler verildiğinde, öğrenci model ile öğretmen modelin çıktıları arasındaki benzerlik bozulur; bu fark, anomali olarak yorumlanır. Öğretmen öğrenci yaklaşımları, özellikle gömülü sistemlerde kullanım için uygun olmaları, küçük model boyutları ve hızlı çıkarım süresi sunmaları nedeniyle gerçek zamanlı kalite kontrol uygulamalarında tercih edilmektedir. Bu strateji aynı zamanda açıklanabilirlik ve düşük kaynak tüketimi gibi mühendislik açısından önemli avantajlar sağlar[56].

3.3.5 Transformer tabanlı yaklaşımlar ve güncel mimari uygulamalar

Transformer tabanlı yaklaşımlar, ilk olarak 2017 yılında Vaswani ve arkadaşları tarafından Google desteği ile yayımlanan “Attention is All You Need” adlı çalışmayla doğal dil işleme alanında tanıtılmış ve dikkat mekanizmasına dayalı mimarisi sayesinde geleneksel sıralı yapılara olan bağımlılığı ortadan kaldırmıştır [57]. Bu yapı, daha sonra görüntü analizine uyarlanarak Vision Transformer (ViT) ve Swin Transformer gibi görsel modellerin geliştirilmesine zemin hazırlamıştır.

Görüntü tabanlı Transformer mimarileri, bir görüntüyü sabit boyutlu küçük parçalara ayırarak her bir parçayı sırasız bir dizi olarak işler; ardından bu parçalar arasındaki bağlamsal ilişkileri dikkat mekanizması aracılığıyla modelleyerek, görüntünün tüm alanlarına dair kapsamlı ve uzun menzilli bağıntılar kurar.

Anomali tespiti bağlamında Transformer tabanlı yöntemler, özellikle görüntünün farklı bölgeleri arasındaki karşılıklı etkileşimleri modelleyebilme kabiliyeti sayesinde, küçük ya da gizli kalmış anomalileri yüksek hassasiyetle ayırt etme imkânı sunar. ViT, 2020 yılında Dosovitskiy ve ekibi tarafından önerilmiş olup, doğrudan saf dikkat mekanizması ile görüntü sınıflandırma görevlerini CNN benzeri yapılara alternatif olarak çözmeyi amaçlamıştır[58].

Swin Transformer ise 2021 yılında Liu ve arkadaşları tarafından yine Google desteği ile geliştirilmiş, dikkat hesaplamasını yerel pencere düzeyine sınırlayarak hem daha düşük hesaplama maliyeti sağlamış hem de çok ölçekli özellik çıkarımı sayesinde görüntüdeki detayların daha verimli temsil edilmesini mümkün kılmıştır. Bu mimariler, görüntü tabanlı anomali tespitinde küçük kusurların bağlamsal olarak anlamlandırılmasını ve konumlandırılmasını sağlayarak, yüksek doğruluk ve açıklanabilirlik açısından önemli avantajlar sunmaktadır[59].

3.4 Transfer Öğrenme ve İnce Ayarlama Teknikleri

Transfer öğrenme (transfer learning), bir modelin daha önce öğrendiği görevlerden edindiği bilgileri, farklı ancak ilişkili yeni görevlerde yeniden kullanmasına olanak tanıyan bir öğrenme yaklaşımıdır. Bu yöntem, özellikle derin öğrenme mimarilerinin büyük miktarda veri gerektirdiği durumlarda, veri kısıtı bulunan özel görevler için büyük avantaj sağlar. Görüntü tabanlı anomali tespitinde transfer öğrenme, genellikle kusurlu örneklerin az olduğu veya etiketli veri bulunmadığı senaryolarda kullanılır. Bu kapsamda, yaygın olarak kullanılan yöntem, ImageNet gibi milyonlarca etiketli görüntüyle eğitilmiş bir CNN modelinin ilk katmanlarını koruyarak yeni bir göreve entegre etmektir. Bu şekilde, modelin daha önce öğrenmiş olduğu kenar, doku ve şekil gibi temel görsel temsiller, yeni görevde doğrudan fayda sağlayacak biçimde yeniden kullanılabilir.

Transfer öğrenme süreci genellikle iki aşamalıdır. İlk aşamada modelin temel katmanları dondurulur ve yalnızca son sınıflandırma katmanları yeni veriyle eğitilir. Bu işlem, özellik çıkarımı olarak adlandırılır. İkinci aşama olan ince ayarlama ise, önceden eğitilmiş modelin bazı veya tüm katmanlarının, hedef görevdeki verilerle düşük öğrenme oranlarıyla yeniden eğitilmesini kapsar. Bu sayede model hem önceden edinilmiş genel bilgiyi korur hem de yeni göreve özgü örüntüleri yakalayarak doğruluğunu artırır. Örneğin, ImageNet üzerinde eğitilmiş

bir ResNet50 modelinin, tekstil kusuru tespiti gibi özel bir görevde küçük bir veri kümesiyle yeniden eğitilmesi hem zaman kazandırır hem de yüksek performans elde edilmesini sağlar. Bu nedenle transfer öğrenme ve ince ayarlama, görüntü tabanlı anomali tespit sistemlerinde veri verimliliğini artıran ve model geliştirme sürecini hızlandıran önemli teknikler arasında yer alır. Bu tezde kullanılan GLASS modeli de bu şekilde eğitimi DTD veri seti ile transfer öğrenme yapmaktadır.

Describable Textures Dataset (DTD), 2014 yılında Mircea Cimpoi, Subhransu Maji ve Andrea Vedaldi tarafından Oxford Üniversitesi Visual Geometry Group (VGG) tarafından yayımlanmış, görsel dokuların sınıflandırılması ve tanımlanabilir özelliklerle incelenmesi amacıyla oluşturulmuş bir veri setidir. VGG tarafından oluşturulmuş olan DTD veri seti, her biri 47 farklı dokusal kategoriye ait 120 görüntüden oluşmak üzere toplam 5.640 yüksek kaliteli renkli görüntü içermektedir. Bu kategoriler çizgili, benekli, pürüzlü, parlak gibi insan tarafından tanımlanabilir sınıflara dayalıdır ve bu yönüyle yalnızca sınıflandırma değil, açıklanabilirlik ve betimsel öznitelik çıkarımı gibi görevler için de uygundur. Genellikle transfer öğrenme, temsili öğrenme, stil tanıma ve anomali tespiti gibi görüntü işleme görevlerinde, özellikle doku çeşitliliğine duyarlı modellerin değerlendirilmesinde referans veri kümesi olarak kullanılmaktadır[60].

3.4.1 Önceden eğitilmiş modeller ve uygulama alanları

Önceden eğitilmiş modeller, genellikle büyük ölçekli veri kümeleri üzerinde uzun sürede ve yüksek hesaplama kaynakları kullanılarak eğitilmiş derin öğrenme mimarileridir. Bu modellerin en bilinen örnekleri arasında, 2014 yılında Kaiming He ve ekibi tarafından geliştirilen ResNet (Residual Network)[61], 2015'te Karen Simonyan tarafından önerilen VGG[62], 2017'de Gao Huang tarafından tanıtılan DenseNet[63] ve mobil cihazlar için optimize edilmiş MobileNet[64] yer alır. Bu mimariler, ImageNet gibi 1 milyondan fazla etiketli görüntü içeren kapsamlı veri setleri üzerinde eğitilerek, kenar, renk, doku, şekil gibi görsel öğelerin hiyerarşik temsillerini öğrenmiştir. Öğrenilen bu temel görsel öznitelikler, farklı görevlerde yeniden kullanılabilir. Bu sayede araştırmacılar, yalnızca son katmanları güncelleyerek veya kısmi ince ayarlama yaparak yeni görevlerde model eğitimi süresini ve veri ihtiyacını önemli ölçüde azaltabilir.

Önceden eğitilmiş modellerin kullanım alanları oldukça geniştir ve farklı disiplinlere başarıyla uyarlanmıştır. Örneğin, tıbbi görüntü analizinde bir ResNet50[61] modeli, sınırlı sayıda MR ya da patoloji görüntüsünü kullanarak tümör tespiti gibi görevlerde yüksek doğruluk sağlayabilmektedir. Benzer şekilde, elektronik üretim hatlarında anomali içeren devre kartı görüntülerinin sınıflandırılmasında ya da tekstil sektöründe iplik kaçığı ve doku bozukluğu gibi kusurların tespitinde önceden eğitilmiş CNN mimarileri, yüksek performans göstermektedir. Tarımda, yaprak hastalıklarının tespiti için VGG16[65] gibi modeller, çok sayıda çiftçi fotoğrafından öğrenilen genel yaprak desenlerini yeni koşullara başarılı biçimde uyarlayabilmektedir. Ayrıca otonom araç sistemlerinde çevre analizi ve beklenmeyen nesne tespiti gibi görevlerde, MobileNet ve EfficientNet gibi hafif ama güçlü modeller tercih edilmektedir. Bu uygulamalar, etiketli veri eksikliği, yüksek doğruluk ihtiyacı ve düşük donanım gücü gibi sınırlamaların olduğu senaryolarda, önceden eğitilmiş modellerin sunduğu aktarılabılır öğrenme kabiliyetinin pratik etkisini açıkça ortaya koymaktadır.

3.4.2 İnce ayarlama tabanlı anomali tespiti

İnce ayarlama, önceden geniş veri kümeleri üzerinde eğitilmiş bir derin öğrenme modelinin, daha dar kapsamlı ve görev özelinde bir veri kümesine uyarlanması sürecidir. Bu teknik, transfer öğrenmenin ikinci aşamasını oluşturur ve modelin bazı katmanlarının yeniden eğitilmesi yoluyla hem genel bilgilerin korunmasını hem de yeni görevle ilişkili özelliklerin öğrenilmesini hedefler. Genellikle modelin alt katmanları sabit bırakılarak, üst katmanları yeni verilerle eğitilir; ancak görev karmaşıklığına göre bu yapı esnek biçimde tüm katmanlara yayılabilir. Bu yöntem, sınırlı sayıda etiketli veriyle yüksek doğruluk elde etmek isteyen uygulamalarda özellikle tercih edilir.

Görüntü tabanlı anomali tespitinde ince ayarlama, normal ve anormal örneklerin sayıca dengesiz olduğu gerçek dünya senaryoları için önemli avantajlar sunar. Önceden eğitilmiş bir model, genel görsel temsilleri öğrenmiş olduğu için, yeni veri setine yalnızca birkaç örnekle hızla uyum sağlayabilir. Bu sayede hem eğitim süresi kısılır hem de model, veri yetersizliğinden kaynaklanabilecek aşırı öğrenme riskini azaltarak daha güçlü genelleme performansı sergiler. Örneğin, ImageNet üzerinde eğitilmiş bir ResNet50 modeli, tekstil sektöründe sık karşılaşılan kumaş hatalarını

tespit etmek üzere, yalnızca az sayıda etiketli iplik kaçığı veya doku bozukluğu görüntüsüyle yeniden eğitilerek yüksek doğrulukta sonuçlar verebilir. Bu yöntem, özellikle endüstriyel kalite kontrol sistemlerinde hızlı ve etkili model uyarlaması için ideal bir strateji olarak değerlendirilmektedir. Tez kapsamında Hailo 8 ortamında yapılan denemelerde model dönüşümleri esnasında ince ayarlamalar yapılmıştır[66].

3.5 Anomali Skorlama ve Eşikleme Teknikleri

Anomali tespitinde, bir örneğin anormal olup olmadığına karar vermek için bir anomali skorlaması gerçekleştirilir ve ardından eşikleme yöntemi uygulanır. Anomali skoru, bir görüntünün veya görüntünün bir bölgesinin ne kadar anormal olduğunu sayısal olarak belirten bir değerdir. Bu skorlar, çoğu zaman modellerin çıktıklarına veya hata değerlerine dayalı olarak hesaplanır. Hesaplanan anomali skorları üzerinden normal ve anormal durumların ayrımını yapmak için belirli eşik değerleri belirlenir ve bu eşiklerin üzerinde kalan bölgeler veya görüntüler anomali olarak kabul edilir. Bu eşikleme yöntemleri, sabit eşikleme ve adaptif eşikleme olarak iki temel kategoride ele alınabilir. Ayrıca, çeşitli eşikleme yöntemlerinin birlikte kullanıldığı hibrit veya çok aşamalı eşikleme yaklaşımları da olarak tercih edilir.

3.5.1 Sabit ve adaptif eşikleme yöntemleri

Sabit eşikleme yöntemleri, anomali skorlarının değerlendirilmesinde kullanılan en basit eşikleme yöntemidir. Bu yöntemde, belirli bir sabit eşik değeri önceden belirlenir ve tüm veriler için sabit tutulur. Model tarafından hesaplanan anomali skorları, bu önceden belirlenen sabit eşik ile karşılaştırılır. Bu eşik değerinin üzerinde kalan bölgeler veya görüntüler otomatik olarak anomali kabul edilir. Sabit eşikleme yöntemleri genellikle verilerin dağılımının nispeten sabit ve standart olduğu durumlarda tercih edilir. Ancak gerçek dünya verileri genellikle karmaşık ve değişken olduğundan, sabit eşikler, belirli durumlarda hatalı sonuçlar verebilir ve yanlış pozitif veya yanlış negatif oranlarını artırabilir.

Adaptif eşikleme yöntemleri ise, görüntünün veya veri setinin özelliklerine göre eşik değerlerini otomatik olarak belirleyen yöntemlerdir. Bu yöntemlerde, eşik değerleri verinin kendi dağılımı ya da skorların istatistiksel özelliklerine, örneğin

ortalama, medyan, standart sapma gibi değerlere bağlı olarak belirlenir. Adaptif yöntemlerde eşikler dinamik olarak veriye göre değiştiği için daha hassas ve doğru sonuçlar elde edilir. Bu yöntemlerin avantajı, veri dağılımındaki değişimlere karşı daha dayanıklı olması ve genel performansı önemli ölçüde artırmasıdır. Özellikle endüstriyel veya gerçek zamanlı uygulamalarda, değişken koşullara uyum sağlayan adaptif eşikleme yöntemleri daha etkin sonuçlar üretir[67].

3.5.2 Hibrit ve çok aşamalı eşikleme yaklaşımları

Hibrit ve çok aşamalı eşikleme yaklaşımları, tek bir eşikleme yönteminin yeterli olmadığı durumlarda farklı eşikleme yöntemlerinin bir arada kullanılması prensibine dayanır. Hibrit eşikleme yöntemleri, genellikle hem sabit hem de adaptif yöntemlerin güçlü yönlerini birleştirmek amacıyla tercih edilir. Örneğin ilk aşamada adaptif yöntemlerle veriye göre daha hassas eşikler belirlenebilir, ikinci aşamada ise sabit eşiklerle daha tutarlı kararlar verilebilir.

Çok aşamalı eşikleme yaklaşımlarında ise eşikleme işlemi tek bir adımda değil, farklı kriterlere göre birkaç aşamada gerçekleştirilir. Örneğin, birinci aşamada geniş bir eşik aralığı kullanılarak potansiyel anomali bölgeleri belirlenir. Daha sonraki aşamalarda bu bölgeler, farklı eşikler ve farklı kriterlerle tekrar değerlendirilir. Bu sayede yanlış pozitif oranları düşürülür ve anomalilerin doğruluğu artırılır. Çok aşamalı yöntemler, özellikle kritik alanlarda örneğin medikal görüntüleme, üretim hattı denetimi gibi hata oranlarını azaltmak ve güvenilirliği artırmak amacıyla yaygın olarak kullanılır[68].

3.6 Model Açıklanabilirliği ve Sonuçların Görselleştirilmesi

Derin öğrenme modelleri, karmaşık ve yüksek boyutlu verilerden anlamlı sonuçlar üretme konusunda oldukça başarılıdır. Ancak bu modeller genellikle bir kara kutu olarak görülür çünkü nasıl karar verdikleri ya da hangi özelliklere göre hareket ettikleri açıkça görülemeyebilir. Özellikle görüntü tabanlı anomali tespitinde, modelin verdiği kararların anlaşılabilir olması büyük önem taşır. Model açıklanabilirliği, modelin karar alma sürecini daha şeffaf hale getirir ve kullanıcılara, modelin hangi bölgelere ve özelliklere odaklandığını görme imkânı sağlar. Bu şeffaflık, modelin güvenilirliğini artırmakta ve sonuçların daha doğru

değerlendirilmesine yardımcı olmaktadır. Görselleştirme teknikleri de bu amaçla yaygın olarak kullanılır ve modellerin iç işleyişini daha anlaşılır hale getirir[69].

3.6.1 Anomali haritaları ve ısı haritası teknikleri

Anomali haritaları ve ısı haritaları, görüntü temelli anomali tespitinde yaygın kullanılan görselleştirme yöntemleridir. Bu teknikler, modelin anomali olarak belirlediği bölgeleri doğrudan görsel biçimde kullanıcıya sunar. Anomali haritaları, görüntüdeki her bir pikselin anomali olma olasılığını veya anomali skorunu renklerle temsil eder. Yüksek skorlu bölgeler genellikle kırmızı veya parlak renklerle gösterilerek anomalilerin net olarak fark edilmesini sağlar.

Isı haritaları, özellikle derin öğrenme modellerinin dikkat mekanizmalarının ve özellik haritalarının görselleştirilmesinde kullanılır. Bu haritalar, modelin hangi bölgelere daha fazla önem verdiğini renk yoğunluklarıyla gösterir. Böylece kullanıcılar, modelin dikkatini yoğunlaştırdığı alanları ve anomali kararlarını neye göre verdiğini açıkça görebilir. Özellikle endüstriyel kalite kontrol, tıbbi görüntüleme ve güvenlik uygulamalarında bu görsel açıklamalar, karar destek süreçlerinde önemli katkılar sağlar[70].

3.7 Hafifletilmiş Uygulamalar İçin Optimizasyon Teknikleri

Görüntü tabanlı anomali tespit modellerinin endüstriyel ortamlar ve gerçek zamanlı uygulamalarda kullanılabilmesi için hesaplama kaynaklarının etkin biçimde kullanılması gerekmektedir. Özellikle üretim hatları veya mobil uygulamalar gibi hızlı karar verme süreçlerinin kritik olduğu alanlarda, modelin boyutu ve hesaplama hızı önemli kısıtlamalar oluşturabilir. Bu nedenle, modellerin hafifletilmesi yani model küçültme ve gerçek zamanlı uygulamalar için optimize edilmesi kritik bir gerekliliktir.

Hafifletilmiş modeller, genellikle parametre sayısı azaltılmış veya yapısal olarak daha basit hale getirilmiş derin öğrenme mimarileri olarak tanımlanır. Bu tür modellerin avantajı, daha az hesaplama gücü ve bellek kullanarak hızlı ve etkin bir şekilde çalışabilmeleridir. Bu kapsamda MobileNet, EfficientNet gibi mobil uyumlu hafif modeller veya sıkıştırılmış ağlar tercih edilir.

Model optimizasyon teknikleri arasında, ağ seyreltme, nicemleme ya da kuantizasyon ve bilgi damıtma gibi yöntemler bulunur. Ağ seyreltme, modeldeki gereksiz bağlantıların veya katmanların kaldırılmasıyla daha küçük ve hızlı çalışan modeller elde edilmesini sağlar. Nicemleme yöntemleri ise model parametrelerini daha düşük hassasiyetli veri tiplerine örneğin, float32'den int8'e dönüştürerek, bellek ve işlemci kullanımını önemli ölçüde azaltır. Bilgi damıtma tekniğinde büyük ve karmaşık modellerden elde edilen bilgilerin, küçük ve basit modellere aktarılmasıyla yüksek performanslı küçük modeller elde edilir.

Bu teknikler sayesinde, modeller özellikle Raspberry Pi gibi gömülü sistemlerde ve üretim hattı üzerindeki gerçek zamanlı denetim süreçlerinde verimli biçimde kullanılabilir. Böylece yüksek performanslı anomali tespiti, daha düşük maliyet ve enerji tüketimi ile mümkün hale gelir. Bu tez çalışmasında model kuantizasyon ve Hailo 8 gibi Raspberry 5 AI hat modeli denemelerinde hafifletme modelleri olumlu sonuç vermemiş olup bu süreç gelecek çalışma ve öneriler kısmında anlatılmıştır.

3.8 Endüstride ve Tekstil Sektöründe Otomatik Kusur Tespiti Uygulamaları

Görüntü tabanlı anomali tespiti yöntemleri, endüstride kalite kontrol ve üretim süreçlerinin otomasyonu için kritik bir rol üstlenmektedir. Endüstriyel üretimde meydana gelebilecek hataların ve kusurların hızlı ve güvenilir biçimde tespit edilmesi, ürün kalitesini yükseltir, üretim maliyetlerini azaltır ve üretim verimliliğini artırır.

Tekstil sektörü, anomali tespiti yöntemlerinin yaygın olarak kullanıldığı başlıca alanlardan biridir. Kumaş ve dokuma ürünlerindeki dokusal bozukluklar, renk kusurları, leke ve yırtılmalar gibi çeşitli kusurlar, insan gözünün tespitiyle sınırlı kaldığında hata oranlarını artırabilir. Bu nedenle, tekstil sektöründe otomatik anomali tespiti sistemlerinin kullanımı, üretim süreçlerini daha hızlı, tutarlı ve düşük hata oranlarıyla yönetmeyi mümkün kılar.

Tekstil uygulamalarında kullanılan görüntü temelli anomali tespiti sistemleri genellikle üretim hatlarına entegre edilen kamera sistemleri ve gerçek zamanlı analiz araçlarından oluşmaktadır. Bu sistemler, dokuma veya baskı süreçleri sırasında oluşan kusurları anında belirleyerek üretim akışını kontrol eder ve üretim verimliliğini artırır. Derin öğrenme tabanlı yöntemler, dokusal anomalilerin veya

karmaşık desenlerde oluşan bozuklukların tespitinde özellikle yüksek başarı sağlamaktadır.

Benzer şekilde otomotiv, elektronik üretimi, gıda üretimi ve ilaç sanayi gibi farklı endüstrilerde de görüntü temelli anomali tespiti sistemleri kullanılmaktadır. Bu sistemler sayesinde, üretim hatalarında erken teşhis yapılabilmekte ve potansiyel kalite problemleri üretim süreçlerinde oluşmadan veya yayılmadan kontrol altına alınabilmektedir[71].



4. ÜRETİMDE GÖRSEL ANOMALİ TESPİTİ ÖN ÇALIŞMALAR

Bu bölümde, tez kapsamında ele alınan görüntü tabanlı anomali tespit yöntemleri, kullanılan derin öğrenme kütüphaneleri ve değerlendirme yapılan donanım teknolojileri sunulmaktadır. Üretim süreçlerindeki yüzey kusurlarının etkin biçimde tespit edilmesi ve gerçek zamanlı ya da yakın gerçek zamanlı çıkarımların gerçekleştirilebilmesi, yöntemlerin teknolojik altyapıyla bütünleşik biçimde uygulanmasını zorunlu kılmaktadır. Bu çerçevede, ilk olarak Anomalib derin öğrenme kütüphanesi tanıtılarak, PatchCore, FastFlow, EfficientAD ve GLASS gibi içinde barındırdığı çeşitli anomali tespit modellerinin çalışma prensipleri açıklanmaktadır. Ayrıca bu modellerin performanslarını etkileyen özellik çıkarımı aşamasında kullanılan ResNet18, WideResNet50-2 ve ResNet101 gibi backbone mimarilerinin rolleri ve karakteristikleri incelenmektedir.

Endüstriyel ortamda uygulama yaparken, derin öğrenme modellerinin doğruluk değerlerinin yanı sıra, hesaplama karmaşıklığı, bellek tüketimi ve hedef donanımlara uygunluğu da kritik öneme sahiptir. Bu nedenle tezde ele alınan yöntemler yalnızca GPU ve CPU gibi geleneksel bilgi işlem platformlarında değil, gömülü sistemler olarak öne çıkan Raspberry Pi 5 üzerinde de değerlendirilmiştir. Bu kapsamda, model boyutu, parametre miktarı ve kuantizasyon yöntemleri gibi teknik unsurlar, söz konusu platformlarda elde edilecek performansın gerçek zamanlılık ve kararlılık açısından değerlendirilmesinde belirleyici rol oynamaktadır.

Son olarak, bölümde deneysel kurulumun ayrıntıları ve kullanılacak hiperparametrelerin tanımları yapılarak, çalışmanın sonraki bölümlerindeki karşılaştırmalı analizlerin teknik zemini oluşturulmaktadır. Bu sayede yöntem ve teknolojilerin avantajları ve dezavantajları sistematik olarak ortaya konulabilecek ve verimlilik, ölçeklenebilirlik ile endüstriyel entegrasyon gibi temel kriterlere dayalı kapsamlı değerlendirmeler gerçekleştirilebilecektir.

4.1 Anomalib Kütüphanesi ve Bileşenleri

Anomalib, görüntü tabanlı anomali tespiti alanında gerçekleştirilen araştırmaların standardizasyonu, modellerin karşılaştırılması ve endüstriyel uygulamalara yönelik etkin bir biçimde dağıtım amacıyla Intel bünyesindeki bir ekip tarafından geliştirilmiş, 2022 yılı başlarında GitHub üzerinden açık kaynak olarak yayınlanmış kapsamlı bir Python kütüphanesidir. Intel'in OpenVINO[72] ekosistemi kapsamında geliştirilen bu platformun temel hedefi, endüstriyel ölçekte kullanılan derin öğrenme tabanlı uygulamaların kolaylıkla oluşturulmasını, yönetilmesini ve performans optimizasyonunun gerçekleştirilmesini sağlamaktır. Apache License 2.0[73] altında lisanslanmış olan Anomalib, akademik araştırmacılar, endüstriyel uygulayıcılar ve yapay zekâ geliştiricileri için ortak ve standartlaştırılmış bir altyapı sunmaktadır.

Anomalib kütüphanesi, PyTorch[74] ve PyTorch Lightning[75] gibi modern ve yaygın kullanılan derin öğrenme altyapıları üzerine kurulmuştur. Bu sayede, kullanıcıların anomali tespit modellerini ölçeklenebilir, yeniden üretilebilir ve kontrol edilebilir bir ortamda eğitmesi, değerlendirmesi ve test etmesi sağlanmaktadır. Anomalib'in modüler yapısı sayesinde, PatchCore, FastFlow, EfficientAD, Cflow[76] gibi görüntü tabanlı anomali tespiti literatüründe güncel ve popüler olarak kabul gören çok çeşitli derin öğrenme modellerini kolayca entegre etmek ve deneysel olarak kıyaslamak mümkün olmaktadır. Bu modellerin farklı hiperparametre seçenekleri, omurga mimarileri ve eğitim stratejileri, kullanıcı dostu YAML[77] yapılandırma dosyaları ile tanımlanmakta, eğitim ve değerlendirme süreçleri bu dosyalar üzerinden otomatik olarak yönetilebilmektedir.

Anomalib'in önemli avantajlarından biri, MVTecAD gibi endüstriyel senaryolarda standart olarak kabul edilen ve yaygın kullanılan veri setleri için önceden yapılandırılmış veri yükleyiciler sunmasıdır. Bu sayede kullanıcılar, veri hazırlama, ön işleme ve model eğitim süreçlerine hızlıca odaklanabilmekte; veri setlerinin yüklenmesi, piksel veya görüntü düzeyinde anomali etiketlerinin hazırlanması gibi adımlarla zaman kaybetmeden modelleri eğitmeye başlayabilmektedir. Özellikle veri setlerinin yüklenmesi aşamasında sunulan hazır araçlar sayesinde veri etiketleme işlemleri otomatize edilebilmekte ve eğitim veya test aşamaları için

gerekli olan veri bölünmeleri kullanıcı müdahalesine gerek kalmadan standart biçimde uygulanabilmektedir.

Kütüphane tarafından sağlanan kapsamlı metrik hesaplama modülü, görüntü düzeyinde anomali tespit metrikleri ve piksel düzeyinde segmentasyon metrikleri olmak üzere iki temel analiz düzeyinde değerlendirme yapmaktadır. Bu otomatik metrik hesaplama mekanizması, farklı modellerin ve omurga mimarilerinin performanslarının objektif ve kolay biçimde karşılaştırılmasını sağlayarak, modellerin gerçek üretim ortamlarına yönelik güçlü ve zayıf yönlerinin detaylı biçimde analiz edilmesini mümkün kılmaktadır.

Anomalib'in önemli bileşenlerinden biri olan kontrol noktası mekanizması, PyTorch Lightning altyapısının güçlü araçlarından biri olarak öne çıkmaktadır. Eğitim süreci boyunca modelin ara çıktıları, öğrenme eğrileri ve en iyi performans gösteren model parametreleri düzenli olarak kaydedilmekte ve performans kriterlerine göre izlenmektedir. Bu özellik sayesinde modeller, eğitim sürecinin herhangi bir aşamasında kaldığı yerden devam ettirilebilmekte veya performansı en yüksek olan epoch eğitim dönemi üzerinden yeniden yüklenip kullanılabilir. Böylece model geliştirme ve optimizasyon süreçleri çok daha kontrollü ve verimli hâle gelmekte, modellerin eğitim süreleri azaltılarak hızlı iterasyonlar mümkün olmaktadır.

Topluluk desteği ve açık kaynak yaklaşımı, Anomalib'in güçlü yanlarından biridir. Intel'in aktif olarak sürdürdüğü proje, GitHub[78] üzerinde yapılan düzenli güncellemeler, yeni modellerin entegrasyonu ve hata düzeltmeleriyle sürekli olarak iyileştirilmekte ve geliştirilmektedir. Bu aktif geliştirme süreci ve topluluk katılımı sayesinde kullanıcılar, güncel literatürde yayınlanan en son modelleri ve yöntemleri kısa sürede Anomalib ekosistemine dahil ederek hızla uygulama ve test etme imkânı bulmaktadır.

Intel'in OpenVINO ekosisteminin temel amacı olan uç cihazlarda ve endüstriyel ortamlarda hızlı, verimli ve düşük gecikmeli çıkarım uygulamalarını destekleme hedefi, Anomalib'in geliştirilme felsefesiyle doğrudan örtüşmektedir. OpenVINO platformunun sunduğu Model Optimizasyonu ve Çıkarım Motoru bileşenleri ile kullanıldığında, Anomalib ile eğitilen ve optimize edilen modellerin endüstriyel üretim hatlarında, akıllı güvenlik sistemlerinde, robotik uygulamalarda ve IoT

cihazlarında yüksek performansla çalıştırılması mümkün olmaktadır. OpenVINO Hazır çalıştırma motoru ve Model Zoo[79] gibi bileşenlerle entegre olan Anomalib, eğitilmiş modellerin gerçek üretim ortamlarında hızlıca kullanılmasını kolaylaştırmakta, böylece akademik araştırmaların endüstriyel çözümlere dönüşüm sürecini büyük ölçüde hızlandırmaktadır.

Anomalib kütüphanesi, görüntü tabanlı anomali tespiti alanında güncel modellerin akademik araştırma ve endüstriyel uygulamalar için ortak, standartlaştırılmış ve etkin biçimde yönetilebilen bir altyapıda kullanılmasını sağlamaktadır. Bu altyapı, tez kapsamında değerlendirilen PatchCore, FastFlow, EfficientAD modellerinin farklı veri setleri ve senaryolar üzerinden karşılaştırmalı olarak değerlendirilmesini sağlayarak, anomali tespiti çalışmalarına önemli bir katkı sunmaktadır.

4.2 Görsel Anomali Tespiti Modelleri

Görüntü temelli anomali tespitinde derin öğrenme modellerinin kullanımı, son yıllarda önemli gelişmeler göstermiştir. Bu modeller, klasik yöntemlere göre daha yüksek doğruluk ve esneklik sunarak özellikle karmaşık dokulara sahip endüstriyel uygulamalarda kritik bir avantaj sağlamaktadır. Bu bölümde, akademik literatürde ön plana çıkan ve endüstriyel kalite kontrol başta olmak üzere birçok alanda yaygın biçimde kullanılan EfficientAD, FastFlow, PatchCore derin öğrenme modeli ayrıntılı olarak incelenmektedir. Modeller, tasarım felsefeleri, mimari yapıları, temel çalışma prensipleri, avantajları ve dezavantajları açısından ele alınacak; uygulama alanları ile performans ve verimlilik açısından kıyaslanacaktır. Bu analiz, modellerin teorik temellerini ve pratik kullanım alanlarını açıklayarak, endüstriyel senaryolarda anomali tespitine yönelik en uygun model seçiminde yol gösterici olabilecektir.

4.3 EfficientAD Modeli

EfficientAD modeli, 2024 yılında MVTEC şirketi tarafından geliştirilmiş, yüksek doğruluk ve düşük gecikme süresi hedefleyen bir görsel anomali tespiti yaklaşımıdır. Model, öğrenci ve öğretmen yapısına dayalı bir mimari kullanarak yalnızca normal görüntüler üzerinde eğitilir. Öğretmen modeli sabitken, öğrenci modeli öğretmenin çıktısını taklit etmeye çalışır. Anomaliler, test aşamasında

öğretmen ve öğrenci çıktıları arasındaki farkın büyük olmasıyla tespit edilir. EfficientAD ayrıca mantıksal anomalileri yakalamak için bir otomatik kodlayıcı da içerir. Bu yapı, yerel bozulmaların yanı sıra nesnelerin konum ve dizilimindeki mantıksal hataları da tanıyabilir.

Modelin en büyük avantajı milisaniye düzeyinde çalışabilmesi ve saniyede altı yüz görüntü işleyebilmesidir. Bu, onu üretim hatları ve gömülü sistemler gibi kaynak kısıtlı ve zaman duyarlı ortamlar için ideal hale getirir. EfficientAD hem yapısal hem mantıksal anomalilerde yüksek başarı göstermekte, PatchCore, FastFlow ve DSR[80] gibi güncel yöntemleri hem doğruluk hem hız açısından geride bırakmaktadır. Modelin başarısının ardında, yalnızca önemli özelliklere odaklanan sert örnek madenciliği ve öğretmen öğrenciyi gereğinden fazla taklit etmesin diye geliştirilen özel bir eğitim kaybı bulunmaktadır.

EfficientAD modeli, yapısal ve mantıksal anomalilerin etkili şekilde tespit edilmesini sağlayan, milisaniye düzeyinde çalışabilen bir anomali tespiti yöntemidir. Model, öğretmen-öğrenci yapısı ve otomatik kodlayıcı temelli iki farklı tespit yaklaşımını birleştirerek hem lokal hem de global anomalileri kapsayacak şekilde tasarlanmıştır. Bu bölümde modelin adım adım nasıl çalıştığı matematiksel formülasyonlarla birlikte açıklanmaktadır.

4.3.1 Girdi görselinin temsili

Modelin ilk girdisi, renkli bir görüntüdür. Bu görüntü, matematiksel olarak şu şekilde ifade edilir.

$$I \in R^{3 \times 256 \times 256} \quad (4.1)$$

Burada, I Giriş görüntüsüdür. 3, RGB renk kanalları (kırmızı, yeşil, mavi). 256x256, Görüntünün genişliği ve yüksekliği (piksel) 'dir. R ise her pikselin gerçek sayı (float) değer olduğunu ifade eder.

4.3.2 Öğretmen ağı ile özellik çıkartımı

EfficientAD, derin ağır mimariler yerine, önceden WideResNet gibi bir sınıflandırıcıdan öğrenilmiş bilgiyi kullanarak eğitilmiş hafif bir Patch Description Network (PDN) kullanır. Bu ağ, giriş görüntüsünden özellik haritası çıkarır:

$$T(I) \in R^{CxW \times H} \quad (4.2)$$

Burada, $T(I)$ öğretmen ağının girdi görüntü I üzerinden ürettiği özellik haritası, C , özellik vektörlerinin kanal sayısıdır (genellikle 384 alınır). W ve H özellik haritasının genişlik ve yüksekliği (genellikle 64×64)'dir. Bu çıktı, her biri 33×33 piksellik yamalara karşılık gelen 384 boyutlu vektörlerdir.

4.3.3 Öğrenci ağı ile taklit ve fark analizi

Öğretmenin ürettiği özellikleri taklit etmeye çalışan öğrenci ağı S , aynı şekilde görüntü üzerinden özellik haritası üretir.

$$S(I) \in R^{CxW \times H} \quad (4.3)$$

Öğrenci ve öğretmen çıktıları arasındaki kare fark, piksel bazlı anomali haritası üretiminde kullanılır.

$$D_{c,w,h} = (T(I)_{c,w,h} - S(I)_{c,w,h})^2 \quad (4.4)$$

Bu fark, tüm kanallarda ortalamaya tabi tutulduğunda yerel anomali skoru elde edilir.

$$M_{local}(w, h) = \frac{1}{C} \sum_{c=1}^C D_{c,w,h} \quad (4.5)$$

4.3.4 Sert özellik kaybı

Öğrencinin sadece zorlandığı bölgelerden öğrendiği bir kayıp fonksiyonu tanımlanır. Farkların belirli bir üst p_{hard} yüzdelik dilimi seçilerek sadece bu kısımlardan geri yayılım yapılır:

$$L_{hard} = \frac{1}{|M|} \sum_{(c,w,h) \in M} D_{c,w,h} \quad (4.6)$$

Burada M , en büyük farklara sahip özellik konumlarının alt kümesidir.

4.3.5 Öğrencinin genellemesini sınırlama

Öğrencinin sadece normal görüntülerde eğitilmesini sağlamak için, öğretmenin ön eğitim datasından gelen bir görüntü P ile ek bir ceza uygulanır.

$$L_{penalty} = \frac{1}{CWH} \sum_c \|S(P)_c\|_F^2 \quad (4.7)$$

Toplam öğrenci-öğretmen eğitim kaybı aşağıdadır.

$$L_{ST} = L_{hard} + L_{penalty} \quad (4.8)$$

4.3.6 Mantıksal anomaliler için otomatik kodlayıcı

Mantıksal (semantik) anomalileri tespit etmek için otomatik kodlayıcı ağı kullanılır. Bu ağ, öğretmenin özellik haritasını yeniden üretmeye çalışır.

$$A(I) \in R^{C \times W \times H} \quad (4.9)$$

Rekonstrüksiyon hatası ile autoencoder kaybı şu şekilde hesaplanır.

$$L_{AE} = \frac{1}{CWH} \sum_c \|T(I)_c - A(I)_c\|_F^2 \quad (4.10)$$

Öğrencinin autoencoder 'ı da taklit etmesi için ek kayıp aşağıdadır.

$$L_{STAE} = \frac{1}{CWH} \sum_c \|A(I)_c - S'(I)_c\|_F^2 \quad (4.11)$$

Toplam eğitim kaybı aşağıdaki gibidir.

$$L_{total} = L_{ST} + L_{AE} + L_{STAE} \quad (4.12)$$

4.3.7 Anomali haritası ve skoru

Test aşamasında M_{local} öğretmen ve öğrenci farkından ve M_{global} autoencoder ve öğrenci farkından olmak üzere iki ayrı anomali haritası hesaplanır.


Birleşik anomali haritası aşağıdaki gibi olur.

$$M_{combined}(w, h) = \frac{1}{2} (M_{local}(w, h) + M_{global}(w, h)) \quad (4.13)$$

Görüntü seviyesinde anomali skoru aşağıdaki gibidir.

$$S_{image} = \max_{w,h} \max_{combined}(w, h) \quad (4.14)$$

Bu yapı sayesinde EfficientAD hem yapısal hem mantıksal anomalileri çok yüksek doğrulukla ve çok kısa sürede tespit edebilmektedir. Şekil 4.1’de Efficient AD modeli çalışma prensibi gösterilmiştir[7].



Şekil 4.1: Efficient AD Modeli

4.4 FastFlow Modeli

FastFlow modeli, gözetimsiz görsel anomali tespiti ve lokalizasyonu için geliştirilmiş, yüksek doğruluk ve hız sunan bir yöntemdir. Bu model, görüntülerden çıkarılan özellikleri iki boyutlu normalleştirici akışlar aracılığıyla öğrenilebilir bir dağılıma dönüştürerek çalışır. Eğitim sürecinde yalnızca normal görüntüler kullanılır; test aşamasında ise düşük olasılık değerine sahip bölgeler anomali olarak belirlenir. FastFlow, ResNet veya Vision Transformer gibi farklı özellik çıkarıcılarla birlikte çalışabilir ve son derece hafif bir yapıya sahiptir.

En dikkat çekici yönü, tamamen evrişimsel 2D akış mimarisi sayesinde yüksek doğrulukla birlikte milisaniyeler düzeyinde çıkarım yapabilmesidir. Geleneksel yöntemlerin aksine, karmaşık çok ölçekli stratejilere veya kaydırma pencerelerine ihtiyaç duymaz. MVTECAD gibi endüstriyel veri setlerinde yüzde 99'un üzerinde AUC değerine ulaşarak önceki yöntemleri hem doğruluk hem de hız açısından geride bırakmıştır. FastFlow, anomali bölgelerini piksel düzeyinde başarılı şekilde yerleştirirken aynı zamanda gerçek zamanlı uygulamalara da uygundur.

FastFlow modeli, normal verilerin uzamsal yapısını öğrenerek görüntü tabanlı anomalileri tespit etmeye yönelik bir özellik tabanlı yaklaşımdır. Oto-regresif öğrenme temelli bu model, yerel yamalar arasındaki ilişkileri öğrenerek normal dışı (anomali) durumların bu düzeni bozduğunu varsayar. FastFlow, temel olarak bir CNN (ResNet gibi) backbone'un çıktısından elde edilen özellik haritalarının, oto-regresif akış (normalizing flow) modeli aracılığıyla modellenmesini yapar. Bu bölümde FastFlow modelinin çalışma mantığı adım adım formüllerle açıklanacaktır.

4.4.1 Girdi ve özellik haritası

FastFlow modeline girdi olarak bir renkli görüntü aşağıdaki gibi verilir.

$$I \in R^{3 \times H \times W} \quad (4.15)$$

Bu görüntü, önceden eğitilmiş bir CNN backbone (genellikle WideResNet-50-2) aracılığıyla özellik uzayına aktarılır.

$$f = \Phi(I) \in R^{C \times H' \times W'} \quad (4.16)$$

Burada, Φ CNN backbone fonksiyonu, f özellik haritası, C kanal sayısı, $H' \times W'$ ise özellik haritasının boyutlarıdır.

4.4.2 Yamalara ayırma ve vektöre çevirme

Elde edilen f özellik haritası, konum bilgisi korunacak şekilde $N=H' \times W'$ adet vektöre ayrılır.

$$x = [x_1, x_2, \dots, x_N], x_i \in R^C \quad (4.17)$$

Her x_i , ilgili yamanın özniteliğini temsil eder.

4.4.3 Normalizing flow ile yoğunluk modelleme

Amaç, bu x vektörlerinin olasılık yoğunluğunu öğrenmektir. Bu için oto-regresif bir akış modeli (normalizing flow) tanımlanır.

$$z = g(x), x = g^{-1}(z) \quad (4.18)$$

ve

$$\log p(x) = \log p(z) + \log \left| \det \left(\frac{\partial z}{\partial x} \right) \right| \quad (4.19)$$

Burada, g öğrenilebilir tersine çevrilebilir dönüşüm (bijektif fonksiyon), z çıktı latent vektörü, $p(x)$: x vektörlerinin olasılığı, $|\det(\partial_z/\partial_x)|$ ise Jacobian determinantıdır.

4.4.4 Kayıp fonksiyonu

Eğitim sürecinde, normal veriler üzerinden maksimum log-olasılık öğrenmesi yapılır.

$$L_{flow} = - \sum_{i=1}^N \log p(x_i) \quad (4.20)$$

Bu, tüm yama vektörlerinin birlikte normal dağılım altında modellenecek şekilde akış modelinin eğitilmesini sağlar.

4.4.5 Anomali skoru hesaplama


Test aşamasında, her bir yama için log-olasılıklar hesaplanarak anomali skorları elde edilir.

$$s_i = - \log p(x_i) \quad (4.21)$$

Yani, log-olasılığı düşük olan yamalar anormal kabul edilir.

Bu skorlar daha sonra orijinal boyuta geri dönüştürülür ve interpolasyonla tam boyutlu anomali haritası elde edilir. En yüksek skor ise görüntü seviyesinde karar vermede kullanılır: Şekil 4.2’de FastFlow modeli diyagramı gösterilmiştir.

$$S_{image} = \max_i s_i \quad (4.22)$$



Şekil 4.2: FastFlow Modeli

FastFlow modeli, CNN tabanlı özellik çıkartımı ile bağlantılı olarak normalizing flow yapısını birleştirerek, her bir yamanın normalliğini olasılık temelli değerlendirir. Bu mimari, hem segmentasyon (piksel seviyesinde) hem de sınıflandırma (görüntü seviyesinde) için verimli, doğruluk oranı yüksek ve hesaplama açısından hafif bir yaklaşım sunar[5].

4.5 PatchCore Modeli

PatchCore, Yama Çekirdeği 2022 yılında Roth ve çalışma arkadaşları tarafından geliştirilen ve görüntü tabanlı anomali tespitinde yüksek doğruluk ve hızlı çıkarım sağlamak üzere tasarlanmış bellek tabanlı bir derin öğrenme yöntemidir. Bu model, özellikle endüstriyel kalite kontrol senaryolarında küçük ölçekli anomalilerin hassas biçimde tespit edilmesi amacıyla ortaya çıkmıştır.

PatchCore'un temel çalışma prensibi, önceden eğitilmiş derin evrişimli sinir ağlarından elde edilen özelliklerin verimli bir bellek yapısı içerisinde saklanmasına ve bu bellekten en yakın komşuluk prensibine göre anomali skorlarının hesaplanmasına dayanır.

PatchCore modelini diğer yöntemlerden ayıran temel özelliklerden biri, bellek tabanlı yapısının sağladığı verimlilik ve esnekliktir. Özellikle küçük anomalilerin tespitinde, görüntü seviyesi yerine doğrudan yama seviyesinde karşılaştırmalar yapılarak yüksek hassasiyet sağlanmaktadır. Düşük sayıda eğitim verisiyle dahi üstün performans gösterebilmesi ve modele yeni normal örneklerin kolaylıkla eklenebilmesi gibi özellikler, endüstriyel uygulamalarda büyük fayda sağlamaktadır.

Modelin dezavantajı olarak, bellek tabanlı yapının büyük ölçekli veri kümelerinde bellek kullanımının artması söylenebilir. Çok geniş veri tabanları kullanıldığında bellek tüketimi önemli ölçüde artarak, bazı uygulamalarda sınırlayıcı hale gelebilir.

PatchCore modeli, özellikle otomotiv sektörü, elektronik devre kontrolü, tekstil yüzey kalite incelemeleri ve hassas mühendislik süreçlerinde yaygın biçimde kullanılmaktadır. Hızlı ve yüksek doğruluklu çıkarım yeteneği sayesinde gerçek zamanlı ve üretim ortamlarına yönelik uygulamalarda en çok tercih edilen yöntemlerden biridir.

PatchCore modeli, görüntü tabanlı anomali tespitinde kullanılan, özellikle az sayıda normal veriden öğrenme ve çok yüksek anomali tespit başarımları ile öne çıkan bir yöntemdir. Bu model, ResNet veya WideResNet gibi bir CNN backbone ile çıkarılan ara katman özelliklerini kullanarak, bu yamaların sıkışık (compact) temsillerini öğrenir ve test aşamasında bu temsillerle test görüntülerindeki yamaları karşılaştırarak anomali skoru hesaplar. PatchCore modelinin adı, yama (patch) seviyesindeki temel temsilleri koruyarak hafızayı verimli şekilde kullanan "core-set" seçme stratejisinden gelmektedir.

4.5.1 Girdi ve özellik çıkartımı

Modelin girdisi, renkli bir görüntü olup aşağıdaki şekilde gösterilir.

$$I \in R^{3 \times H \times W} \quad (4.23)$$

Bu görüntü, önceden eğitilmiş bir CNN backbone ile işlenerek ara katmanlardan özellik haritaları elde edilir. Bu haritalar, yamalara bölünür ve her yama bir vektöre dönüştürülür.

$$x_i \in R^d \quad (4.24)$$

Tüm özellik vektörleri bir araya getirilerek eğitim sürecinde kullanılacak bellek yapısı (feature memory bank) elde edilir.

$$M = x_1, x_2, \dots, x_n \subset R^d \quad (4.25)$$

4.5.2 Core-Set seçimi ile bellek optimizasyonu

PatchCore, tüm eğitim yamalarını bellekte tutmak yerine, temsil edici bir alt küme (core-set) seçer. Bu seçim genellikle "greedy k-Center" algoritmasıyla yapılır. Amaç, minimum örnekle maksimum kapsama elde etmektir.

$$C = CoreSet(M) \subset M \quad (4.26)$$

Bu alt bellek, test aşamasında anomali karşılaştırmaları için kullanılır.

4.5.3 Test aşaması ve benzerlik hesaplama

Test görüntüsü I' için aynı backbone ile özellikler çıkarılır ve yamalar elde edilir. Her test yaması için core-set bellekteki en yakın komşular (k-NN) hesaplanarak anomali skoru elde edilir.

$$s(x') = \min_{x_j \in C} \|x' - x_j\|_2 \quad (4.27)$$

Veya ortalama uzaklık aşağıdaki gibidir.

$$s(x') = \frac{1}{k} \sum_{j=1}^k \|x' - x_j\|_2 \quad (4.28)$$

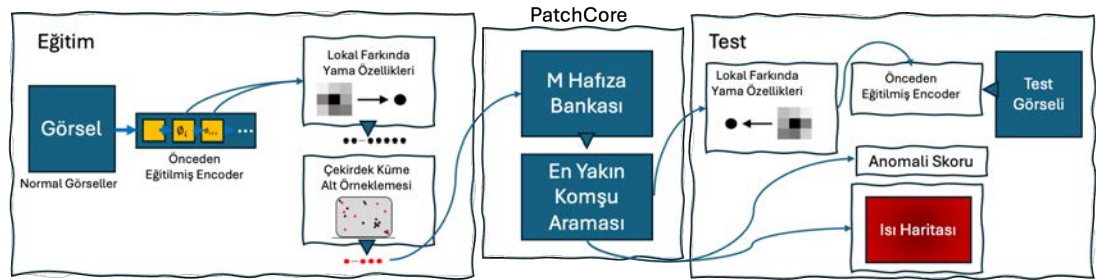
Bu skorlar, yama seviyesindeki anomali yoğunluk haritasını üretmek için interpolasyonla birleştirilir.

4.5.4 Görüntü seviyesi anomali skoru

Tüm yamalar için bulunan skorlar arasından en yüksek olan, görüntü bazında anomali kararı için kullanılır.

$$S_{görsel} = \max_i s(x'_i) \quad (4.29)$$

Alternatif olarak, ortalama skor da kullanılabilir.



Şekil 4.3: PatcCore Modeli

PatchCore modeli, eğitim verisi sırasında sadece normal görüntüleri kullanarak, yama seviyesinde ayrıntılı temsiller öğrenir. Belleği verimli kullanmak için core-set seçimi yaparak test sürecinde hızlı ve doğruluğu yüksek anomali tespiti sağlar.

Parametre gerektirmemesi, eğitim yerine özellik kaydı yapması ve denetimsiz öğrenme doğası ile endüstriyel ortamlarda kullanıma uygundur. Şekil 4.3'te PatchCore Modeli çalışma prensibi gösterilmiştir[3].

4.6 GLASS Modeli

GLASS (Generative Local Features and Adversarially Self-Supervised anomaly detection), Q. Chen ve arkadaşları tarafından 2022 yılında geliştirilen, üretim kalitesi kontrolü gibi endüstriyel görevler için tasarlanmış güçlü bir anomali tespit modelidir. Model hem lokal hem de global seviyede anomalileri sentezleyerek tespit etmeye çalışan, tamamen kendinden denetimli ve üretici yapay örnek üretimi temelli bir derin öğrenme yaklaşımıdır. GLASS, üç temel bileşenden oluşur. Çözücü(E_φ): Görüntüden öznitelik çıkarır. Dikkat modülü (A_φ): Özellikle önemli öznitelikleri vurgular. Ayrımcı (D_ψ): Üretilmiş anomalileri gerçeklerden ayırt etmeye çalışır. Encoder ve attention modülü tarafından üretilen öznitelik haritası üzerinden piksel düzeyinde anomali segmentasyonu yapan bir sınıflayıcı CNN modülüdür. Bu yapı, hem normal görüntüler (negatif örnek) hem de GAS ve LAS modülleriyle üretilen sentetik anomaliler (pozitif örnek) için tahmin yapar ve ikili sınıflandırma veya focal loss kullanılarak eğitilir. Focal Loss, özellikle sınıf dengesizliği (class imbalance) olan durumlarda kullanılan bir kayıp (loss) fonksiyonudur. Özellikle nesne tespiti ve anomali segmentasyonu gibi “az sayıda pozitif örnek, çok sayıda negatif örnek” içeren görevlerde BCE (Binary Cross-Entropy)’nin dezavantajlarını azaltmak için geliştirilmiştir.

Verilen giriş görüntüsü aşağıdaki gibidir.

$$I \in R^{3 \times H \times W} \quad (4.30)$$

Görüntü önce çözücüden geçirilerek özellik haritası aşağıdaki gibi çıkarılır.

$$u_i = A_\varphi \left(E_\varphi(x_i) \right) \in R^{C \times H_m \times W_m} \quad (4.31)$$

Burada $H_m \times W_m$, öznitelik haritasının boyutlarıdır ve C kanal sayısıdır.

4.6.1 Dağılım varsayımları

GLASS, anomaliyi tanımlamak için iki temel dağılım varsayımına dayanır:

Manifold hipotezinde, normal özniteliklerin, düşük boyutlu lineer manifold üzerinde dağıldığı varsayılır.

$$N_a = \left\{ \widetilde{u}_i^{h,w} \mid |\widetilde{u}_i^{h,w} - u_j^{h,w}|_2 > r_1, \forall u_j^{h,w} \in U \right\} \quad (4.32)$$

Burada, N_a anormal olarak sınıflandırılan yamaların (patch'lerin) kümesidir. Yani, eğitimdeki hiçbir normal yamanın yeterince yakın olmadığı (uzaklığı r_1 'den büyük olan) test yamaları bu kümede yer alır. $\widetilde{u}_i^{h,w}$ testte gelen şüpheli anomali yama vektörü, $u_j^{h,w}$ eğitim verisindeki normal yama vektörü, $|\widetilde{u}_i^{h,w} - u_j^{h,w}|_2$ L2 normu (vektörler arası Öklidyen mesafe), r_1 sabit uzaklık eşiği (anormal saymak için minimum mesafe), $\forall u_j^{h,w} \in U$ ise tüm normal yamalar için bu şart geçerli olmalıdır.

Hiperküre hipotezinde, tüm normal öznitelikler, merkezi c olan bir küre içine aşağıdaki gibi yerleştirilebilir.

$$c = \frac{1}{|U|} \sum_{u_{h,w}^i \in U} u_{h,w}^i, \quad N'_a = \left\{ \widetilde{u}_{h,w}^i \mid |\widetilde{u}_{h,w}^i - c|_2 > r'_1 \right\} \quad (4.33)$$

Burada, c normal örneklerin ortalaması (merkez vektör), $|U|$ normal örneklerin sayısı, $\widetilde{u}_{h,w}^i$ bozulmuş ya da aday anomali örnek, $|\widetilde{u}_{h,w}^i - c|_2$ L2 normu (öklidyen uzaklık), r'_1 güncellenmiş eşik, N'_a yeni tanımlanmış anomalous örnek kümesi, c ise ortalama vektör (vektörel gösterim için) dür.

4.6.2 Global anomali üretimi

Gauss gürültüsüyle başlatma aşağıdaki gibi olur.

$$g_{h,w}^i = u_{h,w}^i + \varepsilon_{h,w}^i, \quad \varepsilon \sim \mathcal{N}(\mu_g, \sigma_g^2) \quad (4.34)$$

Burada, $g_{h,w}^i$ anomaliye sahip örnekten türetilmiş yeni vektör, $u_{h,w}^i$ normal örnek, $\varepsilon_{h,w}^i$ rastgele gürültü (perturbation), $\varepsilon \sim \mathcal{N}(\mu_g, \sigma_g^2)$ ise gürültü, normal dağılımdan örneklenir (ortalama: μ_g , varyans: σ_g^2).

4.6.3 Gradyan yükseliş

Anomaliyi artırmak için gradyan yönünde ilerleme aşağıdaki formülle gösterilmiştir.

$$\widehat{g}_i^{h,w} = g_i^{h,w} + \eta \cdot \frac{\nabla L_{\text{gas}}(g_i^{h,w})}{|\nabla L_{\text{gas}}(g_i^{h,w})|} \quad (4.35)$$

Burada, $\widehat{g}_i^{h,w}$ gradyanla itilmiş, anomali yönünde bozulmuş yeni özellik vektörü, $g_i^{h,w}$ orijinal (normal) global özellik vektörü, η gradyan yönünde alınan adımın ölçüğü (küçük sabit adım katsayısı), $\nabla L_{\text{gas}}(g_i^{h,w})$ GAS kaybının $g_i^{h,w}$ noktasındaki gradyanı; anomaliyi en çok artıran yön, $|\nabla L_{\text{gas}}(g_i^{h,w})|$ ise gradyanın L2 normudur, yönü normalize edip yalnızca birim vektör bırakır. Özetle formül, orijinal özellik, gradyanın normalize edilmiş yönünde η kadar itilerek anomali benzeri yeni bir özellik üretilir.

4.6.4 Kesikli projeksiyon

Gradyan yönünde oluşan sapma aşağıdaki formül ile gösterilir.

$$\widetilde{\varepsilon}_{h,w}^t = \widehat{g}_{h,w}^t - u_{h,w}^i \quad (4.36)$$

Burada, $\widetilde{\varepsilon}_{h,w}^t$ anomali-normal farkını gösteren artık vektör, $\widehat{g}_{h,w}^t$ anomali yönünde kaydırılmış global özellik, $u_{h,w}^i$ aynı konumdaki orijinal (normal) özellik vektörüdür. Eşitlik, artık kaydırılmış özellikten normal özelliğin çıkarılmasıyla elde edilir; anomali bileşenini izole eder.

Projeksiyon katsayısı aşağıdaki gibi hesaplanır.

$$\widehat{\varepsilon}_i^{h,w} = \frac{\alpha_i}{|\widehat{\varepsilon}_i^{h,w}|} \widetilde{\varepsilon}_i^{h,w}, \text{ koşullar } \alpha_i = \begin{cases} r_1 & |\widetilde{\varepsilon}_i^{h,w}| < r_1 \\ r_2 & |\widetilde{\varepsilon}_i^{h,w}| > r_2 \\ |\widetilde{\varepsilon}_i^{h,w}| & \text{diğer durumlarda} \end{cases} \quad (4.37)$$

Burada, $\widehat{\varepsilon}_i^{h,w}$ normu sınırlandırılmış (projeksiyon uygulanmış) artık vektör, $\widetilde{\varepsilon}_i^{h,w}$ orijinal residual (perturbed – normal farkı), α_i , $\widetilde{\varepsilon}$ vektörünü r_1 ile r_2 aralığına ölçekleyen çarpandır.

Nihai global anomali özelliği aşağıdaki gibidir.

$$v_{h,w}^i = u_{h,w}^i + \widehat{\varepsilon}_{h,w}^t \quad (4.38)$$

Burada, $v_{h,w}^i$ yeni oluşturulan global özellik vektörüdür; anomali etkisini içerir. $u_{h,w}^i$ ise orijinal (normal) yamaya ait özellik vektörüdür, $\widehat{\varepsilon}_{h,w}^i$ normalize edilmiş ve projeksiyon uygulanmış artık (residual) vektördür; anomalinin katkısını temsil eder, $\widehat{\varepsilon}$ İlk hesaplanan bozulma (perturbasyon) vektörüdür, $\widehat{\varepsilon}$ ise bu vektörün belirli norm aralığına (örneğin r_1, r_2) göre yeniden ölçeklenmiş halidir.

4.6.5 Hiperküre projeksiyonu:

Birinci formül, global anomalileri simüle etmek için gradyan bazlı perturbasyon ve ardından norm tabanlı projeksiyon kullanır. İkinci formül ise yerel anomalileri belirli bir norm aralığında tutarak kontrol altına alır.

$$\widetilde{v}_{h,w}^1 = \text{Proj}_{N'_p} \left(p(\widetilde{g}_{h,w}^1) \right), \quad r'_1 < |\widetilde{g}_{h,w}^1 - c| < r'_2 \quad (4.39)$$

$$u_{h,w}^{i+} = \text{Proj}_{N'_p} \left(u_{h,w}^{i+} \right), \quad r'_2 < |u_{h,w}^{i+} - c| < r'_3 \quad (4.40)$$

Burada, $\widetilde{v}_{h,w}^1$ projeksiyon sonucu elde edilen, bozulmuş (perturbed) global özellik vektörü, $\text{Proj}_{N'_p}(\cdot)$ girdiyi, belirli norm aralığına N'_p projekte eden fonksiyon, $p(\cdot)$: vektör üzerinde uygulanan dönüşüm işlemi (örneğin manifold projeksiyonu), $\widetilde{g}_{h,w}^1$ gradient ile pertürbe edilmiş global özellik vektörü, c eğitim setindeki normal örneklerin merkez vektörü (ortalama), r'_1, r'_2 projeksiyonun gerçekleştiği norm sınırlarını belirleyen eşikler, $u_{h,w}^{i+}$: belirli sınırlar içine projekte edilmiş lokal anomali özelliği, $\text{Proj}_{N'_p}(\cdot)$ özellik vektörünü N'_p norm aralığı içine projekte eden fonksiyon, c eğitim setindeki normal örneklerin merkez (ortalama) vektörü ve r'_2, r'_3 ise projeksiyonun norm aralığını tanımlayan alt ve üst sınırlardır.

4.6.6 LAS: Lokal anomali üretimi

Maske Üretimi aşağıdaki formülde belirtilen şekilde yapılır.

$$m_{i=} \begin{cases} (m_1 \wedge m_2) \wedge m_f & 0 \leq p_m \leq \alpha \\ (m_1 \vee m_2) \wedge m_f & \alpha < p_m \leq 2 \\ m_1 \wedge m_f & 2\alpha < p_m \leq 1 \end{cases} \quad (4.41)$$

Burada, m_i sonuç maske (output maskesi), m_1, m_2 iki farklı ön maske, m_f üçüncü bir filtreleme maskesi, p_m maske birleştirme parametresi, α parametrik eşik değeri, \wedge mantıksal “ve” işlemi (kesişim), \vee mantıksal “veya” işlemi (birleşim), $p_m \sim \mathcal{U}(0,1)$, ve $\alpha = \frac{1}{3}$ ‘dir.

Doku tabanlı anomali, DTD veri setinden alınan dokular, 3 rastgele dönüşüm $T_R \subset T$ ile artırılır aşağıda bu işlem gösterilmiştir.

$$x_i'' = T_R(x_i') \quad (4.42)$$

Görüntü füzyonu ise aşağıdaki gibi gösterilir.

$$x_i^+ = x_i \odot \overline{m}_i + (1 - \beta)x_i'' \odot m_i + \beta x_i \odot m_i \quad (4.43)$$

Burada $\beta \sim \mathcal{N}(\mu_m, \sigma_m^2)$, ve \overline{m}_i maskenin tersi’dir, \odot eleman bazında çarpma (Hadamard çarpımı), $x_i \odot \overline{m}_i$ arka plan (normal) bölgesinin korunması, $x_i'' \odot m_i$ anomali dokusunun maskelenmiş bölgeye uygulanması, $x_i \odot m_i$ ise orijinal görüntünün maskeli kısmının karıştırılmasıdır.

4.6.7 Kayıp fonksiyonları

Normal görüntü ayrımı kaybı, normal örneklerin anomali gibi sınıflandırılmasını engellemek için binary cross-entropy uygulanır:

$$L_n = \sum_{x_i \in X_{train}} \text{BCE}(z_{i,n}, 0) \quad (4.44)$$

Global anomali discriminasyonu, üretilmiş global anomalilerin doğru tanınmasını teşvik eden BCE kaybıdır.

$$L_{gas} = \sum_{x_i \in X_{train}} \text{BCE}(z_{i,gas}, 1) \quad (4.45)$$

Lokal anomali (Focal Loss), gerçekçi lokal anomalileri yakalamak için focal loss uygulanır.

$$L_{las} = \sum_{x_i \in X_{train}} \text{Focal}(z_{i,las}, m_i) \quad (4.46)$$

Toplam kayıp genel eğitim kaybı, OHEM stratejisi ile ağırlıklandırılmış şekilde hesaplanır.

$$L = L_n + L_{gas} + \text{fohem}(L_{las}) \quad (4.47)$$

4.6.8 Çıkarılma ve anomali skorları

Test görüntüsü: $x_i \in X_{test}$ üzerinden çıkarımları aşağıda gösterilmiştir.

Özellik çıkarımı ve diskriminasyon aşağıda gösterilmiştir.

$$z_i = D_\psi \left(A_\phi \left(E_\phi(x_i) \right) \right) \quad (4.48)$$

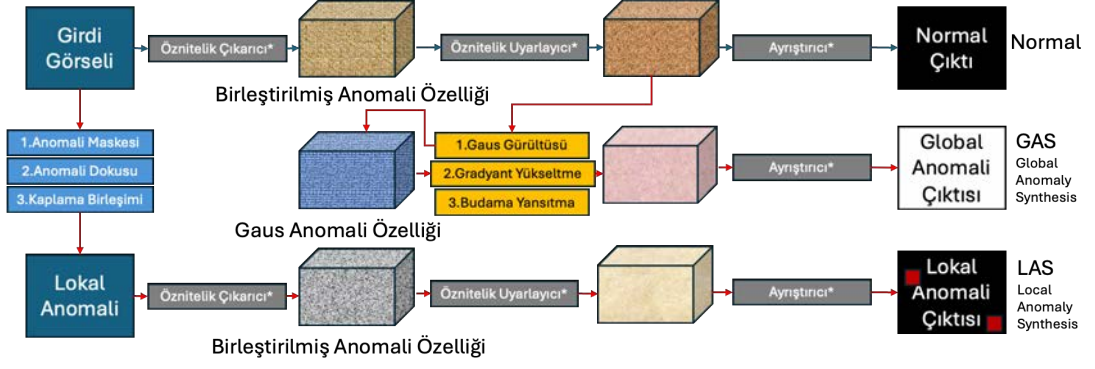
Piksel düzeyinde lokalizasyon (yumuşatma dahil) gösterimi aşağıdaki gibidir.

$$S_{AL} = f_{smooth} \left(f_{resize}^{H_0, W_0}(z_i) \right) \quad (4.49)$$

Görüntü düzeyinde anomali skoru aşağıdaki gibi olur.

$$S_{AD} = \max(z_i) \quad (4.50)$$

GLASS modeli, farklı anomali türlerini üretici yollarla simüle ederek hem lokal hem global seviyede güçlü anomali tespiti gerçekleştiren çok yönlü bir yapıdır. Manifold ve hiperküre varsayımlarına dayalı sentez süreci, modelin hem yüksek doğruluk hem de çeşitlilikte eğitim verisi üretme gücünü ortaya koyar. Bu yapısıyla GLASS, zayıf ve çeşitli kusurları tespit edebilen, yüksek başarılı ve üretime uygun bir sistem sunar. Şekil 4.4 'de GLASS modelinin çalışma diyagramı verilmiştir. Kırmızı ile gösterilen oklar sadece eğitim aşamasında çalışmaktadır. * bulunan şekillerde model ağırlık paylaşım verisi bulunmaktadır[9,10].



Şekil 4.4: Glass Modeli

4.7 Derin Öğrenmede Omurga (Backbone)

Derin öğrenme modellerinde omurga (backbone), giriş verisini (örneğin bir görüntüyü) yüksek düzeyli anlamlı özelliklere dönüştüren, genellikle önceden eğitilmiş bir evrişimli sinir ağı (CNN) mimarisidir. Omurga, modelin temel bilgi çıkarma katmanlarını içerir ve ardından gelen katmanlar (örneğin sınıflandırıcılar, segmentasyon başlıkları vb.) bu çıkarılmış temsilleri kullanarak görev-spesifik işlemleri yürütür. ResNet-18/34/50/101, WideResNet50, EfficientNet, MobileNet, Vision Transformer (ViT) (geleneksel CNN yerine transformer bazlı yapılar) gibi çeşitli omurga türleri mevcuttur. Bir backbone mimarisi f_{θ} , giriş görüntüsü $x \in \mathbb{R}^{3 \times H \times W}$ 'i aşağıdaki şekilde öz nitelik temsiline dönüştürür.

$$f = f_{\theta}(x) \in \mathbb{R}^{C \times H' \times W'} \quad (4.51)$$

Burada, θ backbone'un ağırlıklarıdır, C çıktı öz nitelik haritasının kanal sayısı, H' , W' uzamsal boyutlardır (giriş boyutuna göre düşürülmüş olabilir).

4.7.1 Anomali tespiti modellerinde omurganın rolü

Görüntü tabanlı anomali tespitinde backbone, aşağıdaki işlevleri yerine getirir:

Backbone, yalnızca “normal” (kusursuz) görüntüler üzerinde eğitilerek, bu görüntülerde yaygın olan dokusal ve yapısal örüntüleri çıkarır. Böylece anomali, bu örüntülere uymayan sapma olarak tanımlanabilir. Backbone'un çıkardığı özellikler, modellerin normal dağılım manifoldunu öğrenmesini sağlar. Örneğin: PatchCore: Backbone ile çıkarılan yama (patch) temelli özellikleri yakınlık

ölçütleriyle karşılaştırır. GLASS: Encoder (backbone) ile çıkarılan özellikleri, sentetik anomali üretimi için kullanır. FastFlow: Backbone çıkışlarını akış tabanlı dağılım modellemeye geçirerek normal dağılımı modellemeye çalışır.

4.7.2 3. Transfer öğrenme

Backbone genellikle ImageNet gibi büyük veri kümelerinde önceden eğitilmiş modellerdir. Bu ön eğitim, sınırlı endüstriyel veriyle çalışırken bile güçlü özellik çıkarımını mümkün kılar.

4.7.3 4. Hafifletilmiş hesaplama

MobilNet veya EfficientNet gibi daha hafif backbone'lar kullanılarak inference süresi azaltılabilir ve model, gerçek zamanlı çalıştırılabilir. Omurga (backbone), görüntü tabanlı anomali tespit modellerinin en kritik bileşenlerinden biridir ve modelin başarımı, kullanılan omurganın öznelik çıkarım kalitesiyle doğrudan ilişkilidir. Backbone, giriş görüntülerini temsil eden özellik haritalarını oluşturarak modelin kalan katmanlarına anlamlı bilgi sağlar. Bu yapı, genellikle ResNet, WideResNet, EfficientNet gibi evrimsel sinir ağı mimarilerinden seçilir. Derin yapıllı backbone'lar (örneğin WideResNet50) yüksek doğrulukta özellikler çıkarırken, hesaplama maliyeti ve gecikme süresi artar; bu nedenle üretim hattı gibi zaman duyarlı sistemlerde daha hafif yapılar (örneğin ResNet18 veya EfficientNet-B0) tercih edilir. Omurga seçimi yapılırken üç temel denge gözetilmelidir: Doğruluk ve hız arasında denge kurmak gerekir; çünkü derin backbone'lar doğruluğu artırırken işlem süresini de uzatır. Genelleme açısından, uygun bir backbone sayesinde model farklı ürün türlerine kolayca uyarlanabilir. Donanım uyumluluğu da önemli bir kriterdir; PC veya sunucu sistemlerinde geniş yapılar çalıştırılabilirken, gömülü sistemler (örneğin Raspberry Pi) için daha kompakt ve hafif backbone'lar tercih edilmelidir. Bu bağlamda backbone'lar, endüstriyel uygulamalarda modelin doğruluğu, çalışabilirliği ve uygulama sahasına uygunluğu açısından belirleyici rol oynar. Aşağıdaki örnek tablo, yaygın kullanılan bazı backbone mimarilerini ve bu bağlamda taşıdıkları özellikleri özetlemektedir: ResNet18 düşük parametre sayısı ve hafif yapısı ile gerçek zamanlı kontrol uygulamalarında kullanılırken, ResNet50 orta seviyede hesaplama yükü ile detaylı kalite analizinde tercih edilir. WideResNet50 yüksek doğruluğu sayesinde sunucu

temelli sistemlerde öne çıkarken; EfficientNet-B0 ise çok düşük hesaplama maliyeti sayesinde gömülü sistemler ve IoT cihazlarında yaygın olarak kullanılmaktadır.

4.7.4 Backbone ağların yapısı ve çalışma prensibi: ResNet örneği

Backbone (omurga) yapılar, bir görüntüden çok düzeyli öznelikleri çıkarmak amacıyla yapılandırılmış ardışık konvolüsyonel katmanlardan oluşur. Bu katmanlar görüntünün uzamsal boyutlarını küçültürken derinliğini artırır. Bu yapı içerisinde artık öğrenme sayesinde ağın daha derin hâle gelmesiyle oluşabilecek eğitim zorlukları aşılar. Artık Öğrenme ve ReLU Aktivasyonu 'nu aşağıdaki gibi gösterebilir.

Derin ağlarda optimizasyonun zorlaşması (örneğin vanishing gradient) residual learning ile çözülür. Bunun temel fikri, bir katmanın doğrudan hedef fonksiyonu $H(x)$ öğrenmek yerine, girişe göre farkı olan bir artık fonksiyonu $F(x)$ öğrenmesidir.

$$y = F(x) + x \quad (4.52)$$

$$F(x) = W_2 \cdot \text{ReLU}(W_1 x) \quad (4.53)$$

Burada aktivasyon fonksiyonu olarak ReLU (Rectified Linear Unit) kullanılır.

$$\text{ReLU}(z) = \max(0, z) \quad (4.54)$$

Bu işlem sonrası bazı yapılarda ikinci bir ReLU veya BatchNorm uygulanır. ReLU, doğrusal olmayanlık kazandırırken, öğrenilen fonksiyonun pozitif doğrultuda seyretmesini sağlar ve negatif değerleri sıfıra indirir.

ResNet mimarilerinde (18, 34, 50, 101, 152 katmanlı) backbone aşağıdaki yapıya göre katmanlara ayrılır. Aşağıdaki her bir konvolüsyonel bloğun içinde BatchNorm + ReLU + Conv dizimleri uygulanır. Çizelge 4.1 'de, ResNet mimarilerinde yer alan konvolüsyonel aşamaları ve her bir aşamadaki blok sayılarını göstermektedir. Her "aşama", girişten çıktıya doğru ilerledikçe görüntünün boyutunu küçültüp kanal sayısını artıran bir katman grubudur. "Blok" ise, içinde birkaç konvolüsyon, BatchNorm ve ReLU bulunan ve giriş ile çıkışı arasında artık bağlantı kuran yapısal birimdir. ResNet-18 ve ResNet-34'te her blok, iki adet 3×3 konvolüsyon içerirken; ResNet-50 ve üzerindeki mimarilerde her blok darboğaz olarak adlandırılır ve $1 \times 1 \rightarrow 3 \times 3 \rightarrow 1 \times 1$ şeklinde üç konvolüsyon katmanı içerir. Model derinleştikçe aynı aşamada daha fazla blok kullanılır ve bu sayede ağ daha karmaşık öznelikleri öğrenebilir hale gelir[61].

Çizelge 4.1: Backbone omurga türleri tablosu.

Aşama	Çıkış Boyutu	ResNet-18	ResNet-34	ResNet-50	ResNet-101
conv1	112×112	7×7, 64	7×7, 64	7×7, 64	7×7, 64
conv2_x	56×56	2 blok	3 blok	3 blok	3 blok
conv3_x	28×28	2 blok	4 blok	4 blok	4 blok
conv4_x	14×14	2 blok	6 blok	6 blok	23 blok
conv5_x	7×7	2 blok	3 blok	3 blok	3 blok

4.8 Uygulama Aşamasında Seçilen Model ve Donanımlar

Tez çalışmasının bu aşamasında, görüntü temelli anomali tespiti alanındaki derin öğrenme yöntemlerinin performansları kapsamlı biçimde analiz edilmiştir. Analizlerde, endüstriyel kalite kontrol problemlerini ele almak üzere geliştirilen ve farklı nesne kategorilerindeki anomalilerin algılanmasında standart olarak kabul edilen MVTecAD veri kümesi üzerinde gerçekleştirilen karşılaştırmalı çalışmalara odaklanılmıştır. Bu kapsamda, araştırmacılar ve endüstri profesyonelleri arasında geniş kabul gören ve güncel durum analizi sağlayan Çizelge 4.2 'de Paperswithcode platformundaki performans metrikleri detaylı olarak incelenmiştir. Yapılan incelemelerde, özellikle yüksek AUROC alan altındaki eğri skorları dikkate alınarak modellerin doğruluk ve genelleme yetenekleri karşılaştırılmıştır[81].

Bu değerlendirmeler sonucunda hem yüksek performansları hem de modern donanım platformlarına olan uyumlulukları göz önünde bulundurularak GLASS, PatchCore, FastFlow ve EfficientAD modelleri tez çalışmasının ileri aşamaları için seçilmiştir. PatchCore modeli, hafıza tabanlı bir yaklaşım sunarak eğitim sürecinde normal görüntülerden elde edilen özellikleri kaydeder ve test aşamasında bu özelliklerle uyuşmayan bölgeleri anomaliler olarak tespit eder. GLASS modeli ise, GAN temelli hibrit bir mimariye sahiptir ve aykırı görüntülerin oluşturduğu varyansları azaltarak yüksek doğruluklu anomali haritaları üretir. FastFlow modeli, derin akış tabanlı bir yöntem olup, normal veri dağılımını öğrenerek hızlı ve verimli çıkarımlar gerçekleştirir. EfficientAD ise hafif ve hızlı mimarisi ile özellikle gerçek zamanlı uygulamalar için uygundur ve yüksek doğrulukta anomali tespiti sağlar.

Modellerin seçim kriterlerinde; doğruluk, hesaplama verimliliği, çıkarım hızı ve özellikle yeni nesil donanımlar olan Intel Core Ultra 9 CPU ve Nvidia RTX 5080 GPU ile uyumlu çalışma kriterleri kritik öneme sahip olmuştur. Başlangıçta yapılan denemelerde Intel MacBook Air M2 işlemcisi kullanılmış ancak uyumsuzluk problemleri nedeniyle Intel M4 işlemcili farklı bir platform denenmiştir. Bu süreçte yaşanan donanım uyumsuzlukları, çalışmaların Nvidia 'nın sağladığı Brev platformu üzerinde CUDA destekli güçlü sanal sunucular ile sürdürülmesine yol açmıştır.

Çizelge 4.2: MVTecAD performans tablosu.

Başarı Sırası	Anomali Tespit Modeli	AUROC Performansı	Oluşturulma Yılı
1	GLASS	99,90%	2024
2	EfficientAD	99,80%	2023
3	PatchCore Large	99,60%	2021
4	Reverse Distillation ++	99,44%	2023
5	PatchCore	99,20%	2021
6	EfficientAD-M	99,10%	2024
7	EfficientAD-S	98,70%	2024
8	Reverse Distillation	98,50%	2022
9	PaDiM	97,90%	2020
10	PatchCore (16 shot)	95,40%	2021
11	PaDiM-WR50-Rd550	95,30%	2020
12	Bayes-PFL (Zero-Shot)	92,30%	2025
13	FastFlow+AltUB	98,83%	2022
14	PaDiM-R18-Rd100	96,70%	2020

NVIDIA Brev platformu, kullanıcılara yüksek performanslı donanım kaynaklarına belirli sürelerle bulut tabanlı erişim imkânı sağlayan kapsamlı bir hizmettir. Platformun temel özelliği, kullanıcıların NEBIUS, LambdaLabs, Crusoe, OCI, Google Cloud Platform (GCP), Azure ve Amazon Web Services (AWS) gibi farklı sağlayıcılardan, kendi ihtiyaçları doğrultusunda üst düzey GPU ve CPU konfigürasyonlarını kiralayabilmesidir. Bu özelliğiyle platform, yerel altyapıların yetersiz kalabileceği yoğun hesaplama gerektiren projeler için ideal bir çözüm sunmaktadır.

Sistem üzerinden sunulan donanım seçenekleri, NVIDIA 'nın en yeni GPU modellerinden oluşmakta olup, özellikle NVIDIA H100, L40S ve A100 gibi ileri

seviye grafik işlem birimlerini içermektedir. Kiralanan sistemler, yüksek VRAM kapasitesine, çok çekirdekli işlemcilere ve geniş veri depolama alanlarına sahip olup, kullanıcıların yapay zekâ, derin öğrenme ve görsel anomali tespiti gibi karmaşık görevleri etkili bir şekilde gerçekleştirebilmelerine olanak tanır.

Brev platformundan sağlanan sistemler varsayılan olarak Ubuntu işletim sistemi üzerine kurulu ve hazır yapılandırılmış bir Jupyter Notebook ortamıyla birlikte gelir. Bu hazır altyapı, kullanıcıların donanım ve yazılım kurulumlarıyla zaman kaybetmeden doğrudan akademik araştırmalarına veya endüstriyel uygulamalarına başlayabilmelerini sağlar. Böylece araştırmacılar ve geliştiriciler, güçlü donanım kaynaklarına kısa sürelerde erişerek projelerinin performansını artırabilir ve geliştirme süreçlerini hızlandırabilirler. Bu hizmet sayesinde yeni donanıma geçme öncesinde önemli ilerlemeler kaydedilmiştir[82].

Bulut tabanlı çözümlerin yüksek maliyetleri nedeniyle, Intel Core Ultra 9 CPU ve Nvidia RTX 5080 GPU donanımına sahip, Windows 11 Home işletim sistemli HP bilgisayar temin edilmiştir. Yeni nesil BIOS ve donanım bileşenlerindeki sürüm uyumsuzlukları, Python ortam bileşenleriyle ilgili sıkıntılar ve sık karşılaşılan mavi ekran hataları, başlangıçta çalışmaların verimliliğini azaltmış olsa da zaman içinde BIOS ve donanım güncellemeleri ile bu sorunlar çözülebilmiştir. Özellikle Nvidia RTX 5080 GPU güncellemeleri ve Python ortamı sürüm optimizasyonları, çalışma ortamının istikrarını sağlamıştır. Yeni yayınlanmış donanım kullanımının avantajları yanında dezavantajlarının da olduğu planlanacak çalışmalar için göz önünde bulundurulmalıdır.

Yapılan yoğun eğitim ve test döngülerinde, performans ve stabilite bakımından en başarılı bulunan GLASS, PatchCore, FastFlow ve EfficientAD modelleri ile ilk eğitim safhası tamamlanmış ve elde edilen sonuçlar karşılaştırmalı olarak analiz edilmiştir. Böylece sonraki adımlar için en uygun model kombinasyonları ve optimizasyon stratejileri belirlenmiştir.

5. DEĞERLENDİRME METRİKLERİ

Derin öğrenme tabanlı anomali tespiti uygulamalarında, geliştirilen modellerin performansını değerlendirmek amacıyla çeşitli ölçütler kullanılmaktadır. Bu değerlendirme metrikleri, genel olarak iki düzeyde incelenir: Görüntü düzeyi (Image-level) ve piksel düzeyi (Piksel-level). Görüntü düzeyi metrikler, modelin bir görüntünün tamamını normal ya da anormal olarak doğru sınıflandırma başarısını ortaya koyarken; piksel düzeyi metrikler, kusurun bulunduğu konumun ne ölçüde doğru tespit edildiğini ölçer. Her iki düzeydeki değerlendirme, yalnızca modelin doğruluğunu değil, aynı zamanda üretim ortamında güvenilir bir şekilde uygulanabilirliğini de belirlemek açısından önem taşımaktadır. Bu bölümde, söz konusu metriklerin anlamları ve hesaplanma yöntemleri ayrıntılı biçimde ele alınacaktır.

5.1 Image Level Metrikler

Bu metrikler, tüm görüntü bazında modelin doğru sınıflandırma yapıp yapmadığını ölçer. Yani bu görüntü kusurlu mu, yoksa kusursuz mu sorusunun cevabını ne kadar isabetle verdiğini değerlendirmeye yöneliktir. Örneğin Şekil 5.2 'de tez aşamasında oluşturduğumuz kusursuz görsel örneği verilmiştir. Şekil 5.1 'de ise tez aşamasında oluşturduğumuz kusurlu görsel örneği verilmiştir.


5.1.1 Image level AUROC performans hesaplaması

AUROC, bir sınıflandırma modelinin farklı eşik değerleri altında gösterdiği genel ayırtma başarısını nicel olarak ifade eden yaygın bir değerlendirme ölçütüdür. AUROC, ROC eğrisi altında kalan alandır. ROC ise modelin TRP Doğru Pozitif Oranı ve FPR Yanlış Pozitif Oranı değerlerini, çeşitli eşik seviyeleri boyunca grafiksel olarak temsil eder.

Bir görüntü tabanlı anomali tespit modeli, her görüntüye ait bir anomali skoru üretir. Bu skor, görüntünün kusurlu olma ihtimalini temsil eder ve genellikle $[0, 1]$ aralığında normalize edilir. Bu skorlar belirli bir eşik değeri threshold ile



Şekil 5.2: AIORCOM-TextileAD normal görsel örneği.



Şekil 5.1: AIORCOM-TextileAD kusurlu görsel örneği.

karşılaştırılarak sınıflandırma gerçekleştirilir: skor eşikten büyükse görüntü kusurlu, değilse normal kabul edilir. Model farklı eşik değerleri altında test edilerek her biri için TPR ve FPR değerleri hesaplanır: TPR, gerçek kusurlu görüntüler arasından doğru şekilde kusurlu olarak etiketlenenlerin oranıdır.

$$TPR = \frac{\text{Doğru Pozitifler}}{\text{Doğru Pozitifler} + \text{Yanlış Negatifler}} \quad (5.1)$$

$$FPR = \frac{\text{Yanlış Pozitifler}}{\text{Yanlış Pozitifler} + \text{Doğru Negatifler}} \quad (5.2)$$

Bu TPR-FPR çiftleri koordinat düzlemine işlenerek ROC eğrisi elde edilir. Eğri genellikle (0,0) noktasından başlayarak (1,1) noktasına doğru yükselir.

ROC eğrisinin altında kalan alanın büyüklüğü AUROC değerini verir ve bu değer [0, 1] aralığındadır. AUROC \approx 1.0 ise model, tüm eşik değerlerinde yüksek duyarlılık ve düşük hata oranı ile çalışmaktadır; ideal durumdur. AUROC \approx 0,5 ise model, rastgele tahmin yapıyor demektir; ayırt ediciliği yoktur. AUROC $<$ 0,5 ise model, yanlış yönlü sınıflama yapmaktadır; anomali skorları tersine çevrildiğinde performans artar.

Bu hesaplama, sadece belirli bir eşik değeri için geçerlidir. Tüm olası eşikler için benzer hesaplamalar yapılarak ROC eğrisi elde edilir ve eğrinin altındaki alan numerik integrasyon ile hesaplanarak AUROC bulunur. AUROC, özellikle veri seti dengesiz olduğunda, yani kusurlu ve normal örnek sayısı birbirinden çok farklıysa dahi anlamlı bir genel performans ölçüsü sunar. Bu nedenle görüntü tabanlı anomali tespit modellerinin başarımını karşılaştırmak için oldukça yaygın olarak kullanılmaktadır.

5.1.2 Image level F1-score performans hesaplaması

F1-Score, bir sınıflandırma modelinin kesinlik (Precision) ve duyarlılık (Recall) değerleri arasındaki harmonik ortalamayı ifade eder. Özellikle dengesiz veri kümelerinde, modelin hem doğru şekilde pozitif sınıfı yakalama (Recall) hem de yaptığı pozitif tahminlerin ne kadarının doğru olduğu (Precision) açısından dengeli bir ölçüm sunar. Hesaplanması şu şekildedir, Precision, kusurlu diye işaretlenen tüm görüntülerin ne kadarının gerçekten kusurlu olduğu aşağıda gösterilmiştir.

$$Precision = \frac{Doğru\ Pozitif}{Doğru\ Pozitif + Yanlış\ Pozitif} \quad (5.3)$$

Recall, gerçek kusurlu görüntülerin ne kadarının doğru yakalandığını ifade eder. Formülü aşağıda gösterilmiştir.

$$Recall = \frac{Doğru\ Pozitif}{Doğru\ Pozitif + Yanlış\ Negatif} \quad (5.4)$$

F1-Score ise Precision ve Recall 'in harmonik ortalamasıdır; formülü aşağıda verilmiştir.

$$F1 - Score = 2x \frac{(Precision \times Recall)}{(Precision + Recall)} \quad (5.5)$$

Burada, Image-level düzeyde değerlendirme yapılır. Yani bir görüntünün kusurlu tahmini yaptığımızda, gerçekte o görüntü kusurluysa Doğru Pozitif, gerçekte normale Yanlış Pozitif, eğer model normal deyip görüntü aslında kusurluysa Yanlış Negatif 'tir.

5.2 Piksel Level Metrikler

Anomali tespiti yalnızca görüntü kusurlu mu, değil mi? sorusuna değil, kusurun hangi piksel veya bölgelerde olduğunu da bulmaya çalışabilir. Böylece modelin segmentasyon kalitesi, yani kusurlu alanları doğru biçimde işaretlemesi test edilir.


5.2.1 Piksel level AUROC hesaplaması

Piksel-Level AUROC, bir görüntüdeki her pikselin kusurlu ya da kusursuz olma olasılığına dayalı olarak modelin ayrıştırma performansını ölçen bir değerlendirme metriğidir. Görüntü düzeyindeki AUROC 'dan temel farkı, hesaplamaların tek tek pikseller üzerinde gerçekleştirilmesidir. Bu yaklaşım, özellikle yüzeysel ya da ince dokusal kusurların tespiti gereken uygulamalarda, modelin lokal düzeyde ne derece başarılı olduğunu anlamaya olanak tanır.

Model, her bir piksel için 0 ile 1 arasında bir anomali skoru üretir. Bu skorlar, o pikselin ne ölçüde kusurlu olabileceğine dair bir olasılık tahminidir. Öte yandan, her pikselin gerçek durumu, o görüntüye ait ground truth (gerçeklik) maskesi sayesinde bilinmektedir. Maskedeki etiketleme, piksellerin kusurlu (1) ya da kusursuz (0) olup olmadığını belirtir. Bu yapı sayesinde, modelin verdiği skorlar farklı eşik (threshold) değerleriyle karşılaştırılarak piksel düzeyinde sınıflandırma yapılabilir. Eşik değerinin altında kalan pikseller normal, üstünde kalanlar ise kusurlu olarak kabul edilir. Şekil 5.3 'de kusurlu bir görsel örneği verilirken Şekil 5.4 'de bu görselin model eğitimi sırasında başarısını ölçmek için kullanılan Ground_truth maskesi verilmiştir. Bu maske tez aşamasında Photoshop programı ile hazırlanmıştır.



Şekil 5.3: Kusurlu bir görsel örneği.



Şekil 5.4: Kusurlu bir görsel Ground_truth örneği.

Bu eşik değerleri değiştirildikçe, modelin ne kadar doğru ya da yanlış tahminlerde bulunduğu yeniden değerlendirilir. Böylece her bir eşik için True Positive Rate (TPR) ve False Positive Rate (FPR) değerleri hesaplanır. TPR, modelin gerçekten kusurlu pikselleri ne oranda doğru tespit ettiğini; FPR ise aslında normal olan piksellerin ne kadarının yanlışlıkla kusurlu olarak sınıflandırıldığını gösterir. Elde edilen bu TPR-FPR çiftleriyle oluşturulan ROC eğrisi, modelin farklı eşiklerdeki davranışını grafiksel olarak yansıtır. Bu eğrinin altında kalan alan, yani Piksel-Level AUROC değeri, modelin genel piksel düzeyindeki ayrıştırma başarısını özetleyen tek bir sayısal ölçüdür. Eğri altında kalan alan 1,0'a ne kadar yakınsa, modelin pikselleri doğru şekilde ayırma yeteneği de o derece güçlüdür.

Piksel-Level AUROC, özellikle kusurların lokal olarak ve sınırlı bölgelerde olduğu durumlarda önemli bir değerlendirme ölçütü sağlar. Aynı zamanda modelin yanlış alarm üretme eğilimini de ortaya koyar. Dolayısıyla bu metrik,

anomali tespit sistemlerinin genel başarımı hakkında daha detaylı ve hassas bilgi sunar. Görüntü düzeyindeki AUROC 'un aksine, bu metrik sayesinde modelin kusur haritalarındaki yoğunluk, biçim ve sınır ayırt etme kapasitesi ayrıntılı biçimde analiz edilebilir.

5.2.2 Piksel level F1-score hesaplanması

Piksel-level F1-Score, bir görüntüdeki her pikselin sınıflandırma doğruluğunu ölçmek amacıyla, piksel düzeyinde hesaplanan precision ve recall değerlerinin harmonik ortalamasıdır. Bu metrik, modelin yalnızca kusurlu pikselleri ne ölçüde doğru yakalayabildiğini değil, aynı zamanda normal pikselleri ne sıklıkla hatalı şekilde kusurlu olarak etiketlediğini de değerlendirir. Dolayısıyla F1-Score, hem duyarlılığı (kusurlu olanları kaçırmama) hem de özgülüğü (yanlış alarm üretmeme) tek bir sayısal değer altında dengeli biçimde ifade eder.

Hesaplama öncelikle, modelin kusurlu olarak işaretlediği piksellerin ne kadarının gerçekten kusurlu olduğu belirlenir. Bu oran precision değerini verir. Diğer yandan, ground truth maskesiyle gerçekten kusurlu olduğu bilinen piksellerin ne kadarının model tarafından doğru şekilde etiketlendiği ise recall değerini temsil eder. Bu iki değer harmonik ortalaması alınarak Piksel-level F1-Score elde edilir. Söz konusu hesaplamalarda kullanılan true positive (TP), false positive (FP) ve false negative (FN) değerleri her piksel için ayrı ayrı değerlendirilir.

Piksel-level F1-Score, yalnızca modelin kusurlu bölgeleri saptayıp saptayamadığını değil, aynı zamanda bu kusurların başlangıç ve bitiş sınırlarını ne kadar hassas şekilde belirleyebildiğini de yansıtır. Bu nedenle, özellikle segmentasyon tabanlı anomali tespitinde modelin çıktılarının kalitesini değerlendirmek için sıklıkla tercih edilir. F1 skoru 1,0'a ne kadar yakınsa, model hem çok az yanlış pozitif üretmiş hem de kusurlu piksellerin büyük çoğunluğunu doğru şekilde tespit etmiş demektir.

AUROC metriği, modele çeşitli eşik değerleri üzerinden genel bir perspektif sunarken, F1-Score belirli bir eşik değeri altında modelin doğruluk ve hata dağılımını daha somut biçimde ortaya koyar. Bu açıdan, deneysel çalışmaların sonuçları yalnızca AUROC ile değil, Piksel-level F1-Score ile değerlendirilmelidir. Böylece modelin anomali tespit performansı hem bütünsel hem de ayrıntılı düzeyde güvenilir biçimde raporlanabilir.

Piksel-level Precision, modelin kusurlu olarak işaretlediği piksellerin yüzde kaçının gerçekten kusurlu olduğunu gösterir. Başka bir deyişle, modelin ürettiği pozitif tahminlerin ne kadarının doğru olduğunu ifade eder. Aşağıda Precision Piksel 'in hesaplanması gösterilmiştir.

$$Precision_{pixel} = \frac{Doğru\ Pozitif_{pixel}}{Doğru\ Pozitif_{pixel} + Yanlış\ Pozitif_{pixel}} \quad (5.6)$$

Piksel-level Recall, gerçekten kusurlu piksellerin yüzde kaçını doğru biçimde işaretledik? sorusunun cevabıdır. Aşağıda Recall Piksel 'in hesaplanması gösterilmiştir.

$$Recall_{pixel} = \frac{Doğru\ Pozitif_{pixel}}{Doğru\ Pozitif_{pixel} + Yanlış\ negatif_{pixel}} \quad (5.7)$$

F1-Score ise precision ve recall değerlerinin harmonik ortalaması olarak tanımlanır ve modelin hem doğru pozitif tahmin yapma yeteneğini hem de gerçek pozitifleri yakalama başarısını dengeli bir şekilde ölçen tek bir performans göstergesidir. Aşağıda F1 Score Piksel hesaplanışı anlatılmıştır.

$$F1Score_{pixel} = 2x \frac{(Precision_{pixel} \times Recall_{pixel})}{(Precision_{pixel} + Recall_{pixel})} \quad (5.8)$$

5.3 Mühendislik Kriterleri

Derin öğrenme modellerinin endüstriyel ortamlarda uygulanabilirliğini değerlendirirken, yalnızca doğruluk veya F1-Score gibi performans metriklerine değil, aynı zamanda modelin kaynak tüketimi, işlem süresi ve dağıtım kolaylığı gibi mühendislik kriterlerine de bakmak gerekir. Bu kriterler, modelin yüksek doğruluk elde etmesinin yanı sıra, gerçek zamanlı bir üretim hattına veya gömülü bir cihaza entegrasyonunda hangi kısıtları barındıracağını ortaya koyar. Aşağıda bu kriterler ve tez kapsamında ele alınan ölçütler detaylıca açıklanır. Tezin 2. adımında final modeli seçerken mühendislik kriterleri de değerlendirme parametrelerine eklenmiştir.

5.3.1 Parametre sayısı

Bir derin öğrenme modelinin sahip olduğu toplam öğrenilebilir ağırlık sayısı, yani parametre sayısı, modelin hesaplama karmaşıklığını ve kapasitesini doğrudan

yansıtan temel göstergelerden biridir. Parametre sayısı arttıkça modelin öğrenme yeteneği genellikle artmakla birlikte, bu durum beraberinde daha uzun eğitim sürelerini, daha yüksek bellek kullanımını ve daha yavaş çıkarım süreçlerini de getirebilir. Bu nedenle, özellikle kaynak kısıtlı ortamlarda örneğin gömülü sistemlerde ya da üretim hatlarında gerçek zamanlı karar vermenin kritik olduğu uygulamalarda modelin parametre sayısının sınırlı tutulması, sistem performansı ve uygulanabilirlik açısından büyük önem taşır.

Örneğin, mobil cihazlar için optimize edilmiş MobileNet[64] gibi modeller yalnızca birkaç milyon parametre içerirken, daha derin ve karmaşık yapılara sahip olan ResNet101[14] gibi modeller 40 ila 50 milyon arasında parametre barındırabilir. Bu fark, yalnızca modelin doğruluk potansiyelini değil, aynı zamanda eğitim sürecinde ihtiyaç duyulan işlem gücü ile dağıtım aşamasında hedef cihazın işlem kapasitesini de doğrudan etkiler. Bu nedenle, bir modelin parametre büyüklüğü yalnızca doğruluk açısından değil, sistem tasarımı, zaman kısıtları ve donanım uyumluluğu gibi pek çok açıdan stratejik bir rol oynar. WFDD veri seti üzerinde test edilen GLASS modeli (ResNet18 backbone ile), yaklaşık 12,22 milyon parametreye sahiptir. Aynı backbone ile çalışan FastFlow modeli 7,67 milyon, PatchCore ise yalnızca 2,78 milyon parametre ile oldukça hafif bir mimariye sahiptir. Bu farklılık, modellerin öğrenme esnekliği kadar, eğitim ve çıkarım sırasında ihtiyaç duydukları hesaplama gücünü de etkiler.

5.3.2 Model boyutu

Bir derin öğrenme modelinin disk üzerinde kapladığı alan veya bellekte (RAM) çalışırken işgal ettiği yer, genellikle modelin dosya boyutu olarak ifade edilir. Bu boyut, çoğunlukla modelin sahip olduğu parametre sayısı ile doğru orantılı olmakla birlikte, kullanılan veri temsil biçimi ve sıkıştırma teknikleri gibi faktörlerden de etkilenir. Özellikle kuantizasyon, örneğin 32-bit kayan noktalı sayıların 8-bit tamsayıya dönüştürülmesi ve model budama gibi optimizasyon yöntemleri, aynı parametre sayısına sahip iki modelin oldukça farklı dosya boyutlarına sahip olmasına yol açar.

Örneğin, parametrelerin 32-bit float (float32) formatında saklandığı bir modelde, 10 milyon parametre yaklaşık 40 megabayt yer kaplar (10 milyon \times 4 bayt). Ancak bu modelde 8-bit tamsayı kuantizasyonu uygulanırsa, aynı parametreler yalnızca 10

megabayt civarında bir alana sığdırılabilir. Bu fark, modelin farklı donanım ortamlarında taşınabilirliğini ve çalıştırılabilirliğini doğrudan etkiler.

Model boyutu, özellikle gömülü sistemler, mobil cihazlar veya hafıza kısıtlı platformlar gibi sınırlı depolama ve bellek kapasitesine sahip ortamlarda kritik bir parametredir. Modelin bu tür platformlara dağıtılabilmesi için flash bellek, SD kart ya da RAM sınırlarını aşmaması gerekir. Ayrıca, modelin internet üzerinden güncellenmesi gereken senaryolarda, örneğin bulut tabanlı uygulamalarda ya da çevrim içi servislerde, dosya boyutunun küçük olması hem iletim süresini hem de kullanıcı deneyimini doğrudan iyileştirir. Bu nedenle model boyutu, mimari büyüklük yanında, aynı zamanda dağıtılabilirlik, kullanılabilirlik ve sistem entegrasyonu açısından da stratejik öneme sahiptir. Bu tezde GLASS modeli 46.6 MB'lık boyutuyla en yüksek alana sahipken, FastFlow yaklaşık 30.7 MB, PatchCore ise yalnızca 10.6 MB ile en kompakt yapıdadır.

5.3.3 Çıkarım süresi

Bir derin öğrenme modelinin, tek bir görüntüyü veya veri örneğini işleyip sonuç üretmesi için geçen süre, inference süresi olarak adlandırılır ve genellikle milisaniye cinsinden ifade edilir. Bu süre, modelin eğitimi tamamlandıktan sonra, gerçek kullanım ortamlarında ne kadar hızlı yanıt verebildiğini gösterdiği için, özellikle gerçek zamanlı uygulamalarda en kritik performans ölçütlerinden biridir.

GPU tabanlı çıkarım (inference), modern derin ağların yüksek hesaplama yoğunluklu doğası nedeniyle genellikle tercih edilen yöntemdir. Grafik işlem birimlerinin paralel işlem kapasitesi sayesinde, büyük modeller çok daha kısa sürede sonuç üretebilir. Ancak bu süre, yalnızca GPU kullanımına değil, kullanılan donanımın özelliklerine de bağlıdır. Örneğin bir NVIDIA RTX serisi ekran kartı ile Jetson gibi gömülü bir GPU arasında ciddi süre farkları olabilir. GPU'nun bellek bant genişliği, CUDA çekirdek sayısı ve termal sınırlamaları da inference süresini doğrudan etkileyen faktörlerdendir.

CPU üzerinde yapılan çıkarım ise donanım erişiminin kısıtlı olduğu ya da enerji verimliliğinin öncelikli olduğu durumlarda önem kazanır. Ancak paralel işlem yeteneğinin sınırlı olması nedeniyle, CPU tabanlı inference süresi genellikle daha uzundur. Yine de güçlü sunucu işlemcileri veya yüksek frekanslı mobil CPU'lar, küçük boyutlu modeller için tatmin edici performans sunabilir. Bununla birlikte,

büyük ve karmaşık modellerin CPU üzerinde çalıştırılması hem gecikmeye neden olabilir hem de pratik olmayabilir. Bu tezde, NVIDIA RTX 5080 GPU üzerinde yapılan testlerde, GLASS modeli bir görüntüyü ortalama 12.78 ms sürede işlerken, FastFlow 72.73 ms, PatchCore ise 77.31 ms sürede sonuç üretmiştir. Bu veriler, GLASS modelinin GPU üzerinde oldukça hızlı çalıştığını ve gerçek zamanlı uygulamalar için daha uygun bir yapı sunduğunu göstermektedir. Ancak aynı modellerin Intel Core Ultra 9 işlemci ile çalıştırıldığında, inference sürelerinde ciddi artışlar gözlenmektedir. CPU ortamında GLASS modeli 98.25 ms, FastFlow 82.62 ms, PatchCore ise 80.76 ms sürede inference gerçekleştirmiştir. Bu durumda GPU'ya göre çıkarım süresi farkı GLASS modelinde yaklaşık 7,7 kat, diğer modellerde ise daha sınırlıdır.

5.3.4 Bellek kullanımı

Derin öğrenme modellerinin çıkarım sürecinde ihtiyaç duyduğu bellek miktarı, sistemin performansı ve uygulanabilirliği açısından kritik öneme sahiptir. Bu bellek kullanımı, modelin eğitiminde değil; çıkarım (inference) aşamasında, yani modelin bir görüntüyü işleyip sonuç üretmesi sırasında ölçülür. Modeller GPU üzerinde çalıştırıldığında, bu ölçüm grafik işlem biriminin belleği olan VRAM üzerinden yapılır. CPU tabanlı sistemlerde ise sistem belleği olan RAM kullanımı dikkate alınır. Bu çalışma bağlamında verilen tüm bellek değerleri, modellerin NVIDIA RTX 5080 GPU üzerindeki VRAM kullanımını göstermektedir.

Bellek tüketimi; yalnızca modelin parametre sayısı ile değil, aynı zamanda ara katmanlarda üretilen aktivasyon haritalarının boyutu, veri akış biçimi ve aynı anda işlenen görüntü sayısı (batch size) gibi faktörlerle de şekillenir. Özellikle derin ve geniş yapılara sahip modeller, çıkarım sırasında bellekte geçici olarak tutulması gereken büyük boyutlu ara temsiller (feature maps) üretir. Bu durum, modelin doğruluk performansı yüksek olsa bile bellek açısından yoğun kaynak gereksinimi doğurabilir.

WFDD veri seti üzerinde ResNet18 tabanlı üç farklı model karşılaştırıldığında, bu fark açık biçimde gözlemlenmektedir. GLASS modeli çıkarım sırasında yaklaşık 5578 MB VRAM tüketimiyle en yüksek belleğe ihtiyaç duyan model olarak öne çıkmaktadır. Bu yüksek tüketim, modelin yapısal karmaşıklığına ve ara katmanlarda taşıdığı bilgi yoğunluğuna işaret etmektedir. Aynı omurgası kullanan

PatchCore modeli ise yalnızca 1699 MB, FastFlow modeli ise oldukça düşük bir değer olan 337 MB VRAM kullanımıyla dikkat çekmektedir. Özellikle FastFlow'un akış tabanlı yapısı, veriyi bellekte daha kompakt biçimde işlemesine olanak tanımaktadır.

Bu veriler, modellerin yalnızca doğruluk ya da segmentasyon başarısı açısından değil, donanımsal uygulanabilirlik açısından da dikkatle değerlendirilmesi gerektiğini göstermektedir. Gömülü sistemler, üretim hatları ya da mobil cihazlar gibi belleği sınırlı platformlarda, yüksek doğruluğa sahip fakat yoğun bellek tüketen modellerin kullanımı pratik olmayabilir. Böyle durumlarda, daha düşük bellek profiline sahip modellerin tercih edilmesi sistem kararlılığı ve enerji verimliliği açısından zorunlu hâle gelir.

Bu nedenle, tez kapsamında yapılan değerlendirmelerde yalnızca geleneksel doğruluk metriklerine değil; parametre sayısı, model boyutu, inference süresi ve özellikle bellek kullanımı (VRAM) gibi mühendislik metriklerine de yer verilmiştir. Böylece geliştirilen ya da test edilen modellerin, yalnızca teorik değil, aynı zamanda endüstriyel ve saha uygulamaları açısından da bütünsel biçimde değerlendirilebilirliği sağlanmıştır.

5.4 Eşik Seçimi ve Model Davranışı

Derin öğrenmeye dayalı anomali tespiti modelleri, her bir görüntü veya piksel için sürekli bir anomali skoru üretir. Bu skorlar, genellikle 0 ile 1 arasında normalize edilmiştir ve tek başlarına bir karar üretmezler. Modelin bir örneği normal mi yoksa anormal mi olarak sınıflandıracığı, bu skorun belirli bir eşik değerine (threshold) göre değerlendirilmesiyle mümkün olur. Eşik değeri, modelin duyarlılığı (recall) ve özgüllüğü (precision) arasında nasıl bir denge kuracağına doğrudan etki eder.

Düşük eşik değerleri, modelin küçük riskleri dahi anomali olarak yorumlamasına neden olur; bu durum yüksek duyarlılık sağlar ancak yanlış pozitiflerin artmasına yol açar. Buna karşın yüksek eşik değerlerinde model yalnızca çok yüksek skorlu örnekleri kusurlu olarak işaretler; bu da yanlış alarm riskini azaltırken bazı gerçek kusurların gözden kaçmasına neden olabilir. Eşik belirleme süreci, dolayısıyla yalnızca istatistiksel performans açısından değil, uygulama bağlamının risk toleransı ve operasyonel ihtiyaçları açısından da kritik bir karardır.

Tez kapsamında kullanılan modellerin eğitim ve doğrulama aşamalarında, optimum eşik değerleri ROC eğrisi veya Precision-Recall eğrisi üzerinden otomatik olarak belirlenmiştir. Bu süreçte, genellikle F1-Score 'un maksimum olduğu nokta referans alınarak karar verilmiştir. Ancak modelin gerçek zamanlı test ortamında gösterdiği davranışlar doğrultusunda, sahadaki performans farklılıkları gözlemlenmiştir. Özellikle canlı inference testleri sırasında yapılan denemelerde, sabit bir 0,99 eşik değeri ile modelin hem yanlış pozitif oranını düşürdüğü hem de kusurları isabetli biçimde tespit ettiği görülmüştür. Bu durum, eğitim sürecinde otomatik olarak seçilen eşik değerlerinin her zaman sahadaki koşullarla birebir örtüşmeyebileceğini ve uygulamaya özel ayarlamaların gerekebileceğini ortaya koymaktadır.

Sonuç olarak, eşik seçimi yalnızca modelin eğitildiği veri kümesine bağlı olarak değil, uygulama alanının dinamikleri, hata toleransı ve işlem maliyetleri dikkate alınarak belirlenmelidir. Bu kapsamda, canlı test verilerinden elde edilen gözlemlerle eşik değerinin manuel olarak 0.99'a ayarlanması, modelin gerçek dünyadaki kararlılığını ve güvenilirliğini önemli ölçüde artırmıştır.

6. SEÇİLEN MODELLERİN ANALİZİ

Bu bölümde, tez kapsamında ele alınan görüntü tabanlı anomali tespit modellerinin performansı üç aşamalı bir süreçte incelenmiştir. İlk aşamada literatürde yaygın olarak referans alınan MVTEC AD veri seti kullanılarak PatchCore, FastFlow, EfficientAD ve GLASS modellerinin farklı backbone mimarileri (ResNet18, WideResNet50, WideResNet50-2, ResNet101) ile performansları analiz edilmiş ve karşılaştırılmıştır. Bu karşılaştırma sonucunda en başarılı üç model belirlenmiş ve sonraki aşamalara bu modeller ile devam edilmiştir.

İkinci aşamada, seçilen üç modelin performansı gerçek dokuma kumaş kusurlarını içeren WFDD (Woven Fabric Defect Detection) veri setinin Gri Kumaş kategorisi kullanılarak değerlendirilmiştir. Son aşamada ise, bu tez kapsamında özel olarak hazırlanmış AIORCOM-TextileAD veri seti üzerinde modellerin performansı analiz edilmiştir. Bu süreçte modellerin farklı veri setleri üzerindeki performans tutarlılığı, genelleme yeteneği ve pratik uygulanabilirliği değerlendirilmiş, her veri seti özelindeki sonuçlar karşılaştırmalı olarak sunulmuş ve model seçimi ve sonraki uygulama adımları için temel oluşturulmuştur.

6.1 Kullanılan Donanım ve Yazılım Altyapısı

Tez kapsamında gerçekleştirilen model eğitimleri ve analizleri için performanslı bir donanım ortamı kullanılmıştır. Deneylerin yürütüldüğü donanım platformu olarak dizüstü bilgisayar tercih edilmiş olup, sistem 24 çekirdekli Intel Core Ultra 9 275HX işlemcisi ve NVIDIA RTX 5080 24GB GPU 'su ile kullanılmıştır. Yüksek sayılabilecek işlem gücü ve grafik kapasitesine sahip bu donanım sayesinde, derin öğrenme modellerinin eğitim süreçlerinde yazılım donanım uyum sorunları yaşansa da gelen güncellemelerle birlikte performans değerlendirmelerinde ortaya çıkan hesaplama yoğun işlemler hızlı ve verimli bir biçimde tamamlanabilmiştir.

Yazılım tarafında ise Microsoft Windows 11 işletim sistemi üzerinde Python programlama dili kullanılarak geliştirme ortamı kurulmuştur. Model eğitimleri ve analiz süreçleri için Anaconda[83] tabanlı özel sanal ortamlar oluşturulmuş ve

PyTorch, Anomalib gibi derin öğrenme kütüphaneleri ile OpenCV[84,85], NumPy, Pandas[86], Scikit-learn[87] gibi veri analizi araçları entegre edilmiştir. Deneylerin yürütülmesi ve sonuçların raporlanması süreçlerinde ise Jupyter Notebook[88] kullanılarak daha hızlı prototipleme ve sonuçların daha kolay görselleştirilmesi sağlanmıştır. Ayrıca, tüm süreç boyunca karşılaşılan teknik problemlerin kayıtları tutulmuş, sorunlara yönelik çözümler detaylandırılarak süreçlerin tekrarlanabilirliği garanti altına alınmıştır.

6.1.1 Karşılaşılan teknik sorunlar ve çözüm yolları

Bu tez çalışması kapsamında yürütülen derin öğrenme modeli eğitimleri, performans değerlendirme süreçleri ve deneysel analizler sırasında çeşitli teknik sorunlarla karşılaşılmıştır. Bu sorunlar, ağırlıklı olarak donanım yazılım uyumsuzlukları, paket bağımlılıkları, bellek yönetimi ve model davranışı gibi alanlarda yoğunlaşmıştır. Her bir sorun, sistematik biçimde analiz edilerek uygun çözüm yöntemleri geliştirilmiş ve çalışmanın sürdürülebilirliği sağlanmıştır.

İlk olarak, Apple M1 Ultra[89] işlemci, Apple M2[90] işlemci, M4[91] işlemcileri ile donanım uyumsuzluk sorunları yaşanmış ve ancak belirli bir ölçüde çözülebilmıştır. Sonrasında Intel işlemci ve Cuda destekli Nvidia ekran kartlı Ubuntu işletim sistemli sanal sunucular denenmiştir. Sanal sunucu kullanımının sürdürülebilir olmaması nedeniyle fiziksel olarak Intel işlemci ve Nvidia ekran kartı olan bir bilgisayar temin edilmiştir.

Model eğitimi esnasında CUDA sürüm uyumsuzlukları ve PyTorch 'un GPU desteğine ilişkin yapılandırma hataları önemli bir engel teşkil etmiştir[92]. Özellikle NVIDIA RTX 5080 GPU 'nun yalnızca CUDA 12.1 ile tam uyumlu çalışması, uygun sürücü ve kütüphane sürümlerinin birlikte kullanılmasını zorunlu kılmıştır. Bu kapsamda, uyumsuzluklardan kaynaklanan derleyici hataları ve GPU tanınmıyor türündeki problemlerle karşılaşılmıştır. Söz konusu sorun, NVIDIA 'nın resmi kaynakları kullanılarak güncel CUDA Toolkit 12.1 ve ilgili GPU sürücülerinin kurulmasıyla giderilmiş; ardından PyTorch 'un CUDA 12.1 destekli özel sürümü edinilerek sistemde yapılandırılmıştır[93].

Python ortamında kullanılan kütüphaneler arasında yaşanan bağımlılık (dependency) çatışmaları, özellikle Anomalib v2.0.0'ın kurulumu sırasında zaman kayıplarına yol açmıştır. Bazı paketlerin mevcut Python sürümüyle ya da

birbirleriyle uyumsuz olması, yüklemelerin başarısız olmasına ve çalışma ortamlarının dengesizleşmesine neden olmuştur. Bu problemi önlemek amacıyla, her bir deney için izole edilmiş Anaconda sanal ortamları oluşturulmuş ve yalnızca ihtiyaç duyulan kütüphaneler, belirtilen sürümleriyle birlikte kurulmuştur. Ayrıca, bu ortamlar için oluşturulan requirements.txt dosyaları sayesinde tüm kurulum süreçleri tekrarlanabilir ve tutarlı hâle getirilmiş, potansiyel hata kaynakları azaltılmıştır.

6.2 İlk Model Analizi MVTecAD Veri Seti

Anomali tespiti alanında derin öğrenme modellerinin performans değerlendirmesinde referans olarak kabul edilen standart veri setlerinin kullanımı, çalışmaların güvenilirliğini, karşılaştırılabilirliğini ve akademik tutarlılığını artırmaktadır. Bu tez çalışmasının ilk analiz aşamasında kullanılan MVTec Anomaly Detection (MVTecAD) veri setinin, tekstil yüzey kusurlarını temsil eden Kumaş (halı/kumaş) kategorisi tercih edilmiştir. MVTecAD veri seti, özellikle endüstriyel kalite kontrol uygulamaları için geliştirilmiş olup, akademik ve endüstriyel çevrelerde yaygın olarak kabul görmekte ve kullanılan anomali tespiti yöntemlerinin değerlendirilmesi için standartlaştırılmış bir referans veri seti olarak görev yapmaktadır.

MVTecAD veri setinin Kumaş kategorisi, dokuma yüzeylerde sık karşılaşılan gerçek üretim kusurlarının çeşitli görünümünü içermektedir. Bu kategori içerisinde bulunan görseller, dokuma yüzeylerde oluşabilen iplik kaçıkları, dokuma hataları, renk tonu farklılıkları, kir ve diğer fiziksel kusurları temsil eden gerçekçi anomalileri kapsamaktadır. Veri setinde toplam 280 adet eğitim amaçlı normal (iyi) görüntü ve test aşamasında kullanılmak üzere 28 normal ve 89 anomalili görüntü yer almaktadır. Buna ek olarak, anomalileri tanımlayan piksel seviyesinde maskeler de mevcut olup, bu maskeler model performanslarının hem piksel bazında hem de görüntü bazında hassas ve güvenilir biçimde değerlendirilmesini sağlamaktadır.

Kumaş kategorisinin standart veri seti olarak seçilmesinin temel avantajlarından biri, literatürde sıkça atıfta bulunulan akademik çalışmalar ile sonuçların doğrudan karşılaştırılabilir olmasıdır. Böylece tez kapsamında kullanılan PatchCore, FastFlow, EfficientAD ve GLASS modellerinin farklı backbone mimarileri ile elde edilen sonuçların, mevcut yöntemler ile kıyaslanarak değerlendirilmesi mümkün

hale gelmektedir. Ayrıca MVTecAD veri setinin bu standardizasyon özelliği sayesinde, farklı çalışmalar arasında elde edilen performans sonuçlarının tutarlılığı garanti altına alınmaktadır.

6.2.1 PatchCore ResNet18 MVTecAD kumaş analizi


PatchCore modelinin ResNet18 omurgası ile MVTecAD veri setinin Kumaş kategorisi üzerinde gerçekleştirdiği deneysel analiz, modelin sınırlı parametre sayısına (2,78M) ve düşük model boyutuna (11,13 MB) rağmen yüksek düzeyde sınıflama başarısı elde ettiğini göstermektedir. Görüntü düzeyindeki AUROC ve F1 skorları sırasıyla 0,98 ve 0,97 gibi oldukça yüksek değerlere ulaşmıştır. Bu sonuçlar, modelin anomalileri genel olarak başarılı biçimde ayırt ettiğini göstermektedir. Ancak, piksel düzeyindeki F1 skoru 0,57 ile görece düşüktür; bu durum modelin lokal anomalileri sınırlı doğrulukla tespit edebildiğine işaret etmektedir. Ayrıca, 458,37 ms 'lik inference süresi ve 687,77 MB'lık bellek kullanımı, modelin gömülü sistemlerde kullanımında verimlilik açısından dikkatle değerlendirilmesi gerektiğini ortaya koymaktadır. Sonuçlar Şekil 6.2, Çizelge 6.1 'de detaylı olarak aşağıda verilmiştir.

Çizelge 6.1: PatchCore ResNet18 MVTecAD kumaş analizi.


Özellik	Değer
Parametre Sayısı (M)	2,78
Model Boyutu (MB)	11,13
Inference Süresi (ms/görüntü)	458,37
Bellek Kullanımı (MB)	687,77
Image_AUROC	0,98
Image_F1Score	0,97
Piksel_AUROC	0,98
Piksel_F1Score	0,57

6.2.2 PatchCore ResNeXt101 MVTecAD kumaş analizi

PatchCore modeli, daha derin ve geniş omurgalarla kullanıldığında anomali tespit performansını artırabilmektedir. Bu nedenle, ResNeXt101 omurgası ile



Şekil 6.2: PatchCore ResNet18 MVTECAD kumaş analizi.



Şekil 6.1: PatchCore ResNeXt101 MVTECAD kumaş sonuçları.

yapılandırılmış PatchCore modelinin, MVTECAD veri setinin Kumaş kategorisinde nasıl bir sonuç verdiği incelenmiştir.

Modelin çıktılarına ilişkin nicel bulgular Çizelge 6.2’de detaylandırılmış, görsel sonuçlar ise Şekil 6.1 ’de verilmiştir. Görüntü düzeyinde elde edilen Image_AUROC (0,99) ve Image_F1Score (0,98) değerleri, modelin genel anomalili ve anomalisiz örnekleri oldukça yüksek doğrulukla ayırt edebildiğini göstermektedir. Piksel düzeyinde AUROC değeri 0,98 ile yüksekliğini korurken, F1 skoru 0,59’a yükselmiş; bu da daha isabetli lokalizasyon sağlandığına işaret etmektedir.

Buna karşın, modelin 57,99 milyon parametreye ve 231,98 MB’lık dosya boyutuna sahip olması, kaynak gereksinimlerinin arttığını göstermektedir. Ayrıca 1286,25 MB’lık bellek kullanımı görece yüksektir. Ancak dikkat çekici biçimde, inference

süresi yalnızca 50,25 ms olarak ölçülmüştür; bu da modelin derinliğine rağmen hızlı çıkarım yapabildiğini göstermektedir., Şekil 6.1 ve Çizelge 6.2’de sunulan sonuçlar, ResNeXt101 temelli PatchCore modelinin Kumaş kategorisinde yüksek doğruluk ve hızlı işlem avantajını birlikte sunduğunu ortaya koymaktadır.

Çizelge 6.2: PatchCore ResNeXt101 MVTECAD kumaş sonuçları.


Özellik	Değer
Parametre Sayısı (M)	57,99
Model Boyutu (MB)	231,98
Inference Süresi (ms/görüntü)	50,25
Bellek Kullanımı (MB)	1286,25
Image_AUROC	0,99
Image_F1Score	0,98
Piksel_AUROC	0,98
Piksel_F1Score	0,59

6.2.3 PatchCore WideResNet101 MVTECAD kumaş analizi

PatchCore modelinin performansı, kullanılan backbone mimarisine bağlı olarak önemli ölçüde değişiklik gösterebilmektedir. Bu nedenle, Şekil 6.3 ve Çizelge 6.3’te sunulan sonuçlar, Anomalib PatchCore modelinin WideResNet101 omurgasıyla MVTECAD veri setinin Kumaş kategorisi üzerindeki başarımını ortaya koymaktadır.

Model, Image düzeyinde AUROC ve F1 skorları açısından sırasıyla 0,98 ve 0,96 değerleriyle güçlü bir genel anomali tespiti performansı sergilemiştir. Piksel düzeyinde AUROC yine 0,98 ile oldukça yüksek kalmış, ancak F1 skoru 0,56 ile görece düşük kalmıştır. Bu durum, modelin lokal anomalileri belirleme yeteneğinin backbone derinliğine rağmen sınırlı kaldığını göstermektedir.

Modelin 82,86 milyon parametreye ve 331,46 MB dosya boyutuna sahip olması, oldukça yüksek kapasitede bir yapı olduğunu ortaya koymaktadır. Bu büyüklüğe rağmen, inference süresi 477,13 ms gibi kabul edilebilir bir seviyededir. Bellek kullanımı ise ResNeXt101 modelinde olduğu gibi 1286,25 MB düzeyindedir. Bu sonuçlar, Şekil 6.3 ve Çizelge 6.3 ’de detaylandırıldığı üzere, PatchCore modelinin WideResNet101 ile yüksek doğruluk sunduğunu ancak piksel düzeyinde bazı sınırlamalar barındırdığını ve kaynak tüketimi açısından dikkatli değerlendirilmesi gerektiğini göstermektedir.



Şekil 6.3: PatchCore WideResNet101 MVTecAD kumaş analizi.


Çizelge 6.3: PatchCore WideResNet101 MVTecAD kumaş analizi.

Özellik	Değer
Parametre Sayısı (M)	82,86
Model Boyutu (MB)	331,46
Inference Süresi (ms/görüntü)	477,13
Bellek Kullanımı (MB)	1286,25
Image_AUROC	0,98
Image_F1Score	0,96
Piksel_AUROC	0,98
Piksel_F1Score	0,56

6.2.4 PatchCore WideResNet50-2 MVTecAD kumaş analizi

PatchCore modelinin farklı omurga mimarileriyle performansı değerlendirilirken, WideResNet50-2 seçeneği dengeli bir yapı sunmasıyla öne çıkmaktadır. Şekil 6.4 ve Çizelge 6.4 'de sunulan sonuçlara göre, bu yapı MVTecAD veri setinin Kumaş kategorisinde yüksek başarı elde etmiştir. Model, Image düzeyinde 0,99 AUROC ve 0,98 F1 skoru ile oldukça güçlü bir sınıflama performansı sergilemiştir. Piksel düzeyinde ise AUROC yine 0,98 olarak korunmuş; F1 skoru ise 0,60 ile önceki modeller arasında en yüksek değere ulaşmıştır. Bu durum, modelin yalnızca genel anomali tespitinde değil, aynı zamanda lokal anomalilerin yerini belirlemede de oldukça başarılı olduğunu göstermektedir.

Dikkat çekici bir diğer unsur ise modelin verimliliğidir: 24,86 milyon parametre ve 99,45 MB model boyutuna sahip olan yapı, yalnızca 46,06 ms 'lik inference süresi ile en hızlı çıkarım yapan model olmuştur. Bellek kullanımı ise 1286,25 MB ile



Şekil 6.4: PatchCore WideResNet50-2 MVTecAD kumaş analizi.

diğer büyük omurgalarla benzerdir. Şekil 6.4 ve Çizelge 6.4 'den de görülebileceği üzere, WideResNet50-2 omurgası, yüksek doğruluk, düşük gecikme ve görece düşük model boyutunu bir arada sunarak performans/verimlilik açısından en dengeli seçeneklerden biri olarak öne çıkmaktadır.


Çizelge 6.4: PatchCore WideResNet50-2 MVTecAD kumaş analizi.

Özellik	Değer
Parametre Sayısı (M)	24,86
Model Boyutu (MB)	99,45
Inference Süresi (ms/görüntü)	46,06
Bellek Kullanımı (MB)	1286,25
Image_AUROC	0,99
Image_F1Score	0,98
Piksel_AUROC	0,98
Piksel_F1Score	0,60

6.2.5 EfficientAd MVTecAD kumaş analizi

EfficientAD modeli, düşük kaynak tüketimi ile hızlı ve taşınabilir çözümler sunmak amacıyla geliştirilmiş hafif bir yapıdır. Şekil 6.5 ve Çizelge 6.5 'de sunulan sonuçlar, modelin MVTecAD veri setinin Kumaş kategorisindeki performansını gözler önüne sermektedir.

Modelin parametre sayısı 13,08 milyon ve boyutu yalnızca 45,41 MB olup, bu değerler önceki modellerle karşılaştırıldığında oldukça küçüktür. Bellek kullanımı



Şekil 6.5: Anomalib EfficientAd MV TecAD kumaş analizi.

da yalnızca 150,61 MB ile minimum düzeydedir. Ayrıca, 156,99 ms 'lik inference süresi, makul kabul edilebilecek bir gecikme seviyesi sunmaktadır.

Ancak bu verimlilik, doğruluk açısından belirli ödünlerle gelmiştir. Image_AUROC ve Image_F1Score değerleri sırasıyla 0,82 ve 0,86 olarak ölçülmüş; bu da genel anomali sınıflandırma başarısının daha düşük düzeyde kaldığını göstermektedir. Piksel düzeyinde ise AUROC yine 0,82 iken, F1 skoru yalnızca 0,42'ye düşmüştür. Bu durum, modelin lokal anomalileri tespit etmede belirgin zayıflıkları olduğunu ortaya koymaktadır.

Şekil 6.5 ve Çizelge 6.5 'den de anlaşılacağı üzere, EfficientAD modeli düşük kaynak tüketimi ve kompakt yapısıyla öne çıkarken, yüksek doğruluk gerektiren senaryolarda yetersiz kalabilir. Bu nedenle, modelin kullanım alanı özellikle kaynak kısıtlı, ancak yüksek doğruluk gerektirmeyen uygulamalarla sınırlı tutulmalıdır.

Çizelge 6.5: EfficientAd MV TecAD kumaş analizi.

Özellik	Değer
Parametre Sayısı (M)	13,08
Model Boyutu (MB)	45,41
Inference Süresi (ms/görüntü)	156,99
Bellek Kullanımı (MB)	150,61
Image_AUROC	0,82
Image_F1Score	0,86
Piksel_AUROC	0,82
Piksel_F1Score	0,42


6.2.6 FastFlow ResNet18 MVTecAD kumaş analizi

FastFlow modeli, normal görsellerden öğrenerek hızlı ve etkin anomali haritaları üreten akış tabanlı bir yaklaşımdır. Bu bölümde, ResNet18 omurgası ile yapılandırılan FastFlow modelinin MVTecAD veri setinin Kumaş kategorisindeki performansı analiz edilmiştir. Eğitim ve test süreçlerine ait görsel sonuçlar Şekil 6.6 'da ve sayısal değerlendirmeler ise Çizelge 6.6 'da sunulmaktadır.

Model, 7,66 milyon parametre ve 30,67 MB'lık model boyutuyla hafif sayılabilecek bir yapıdadır. Bellek kullanımını sadece 56,98 MB ile oldukça düşüktür ve bu, modeli kaynak kısıtlı sistemler için cazip kılmaktadır. Bununla birlikte, 489,17 ms 'lik inference süresi görece uzundur; bu durum, modelin akış temelli hesaplamalarının yüksek gecikmeye neden olabileceğini göstermektedir.

Başarım açısından değerlendirildiğinde, Image_AUROC (0,98) ve Image_F1Score (0,96) değerleri, modelin genel anomali sınıflandırmada yüksek doğruluk sağladığını göstermektedir. Piksel düzeyindeki AUROC değeri yine 0,98 ile güçlü kalmakta, F1 skoru ise 0,58 ile lokal anomalilerin belirlenmesinde tatmin edici bir sonuç sunmaktadır.

Şekil 6.6 ve Çizelge 6.6 'ya bakıldığında, FastFlow modelinin özellikle düşük bellek kullanımı ve yüksek sınıflama doğruluğuyla öne çıktığı, ancak inference süresi nedeniyle zaman kritik uygulamalarda dikkatli değerlendirilmesi gerektiği sonucuna varılabilir.



Şekil 6.6: FastFlow ResNet18 MVTecAD kumaş analizi.

Çizelge 6.6: FastFlow ResNet18 MVTecAD kumaş analizi.

Özellik	Değer
Parametre Sayısı (M)	7,66
Model Boyutu (MB)	30,67
Inference Süresi (ms/görüntü)	489,17
Bellek Kullanımı (MB)	56,98
Image_AUROC	0,98
Image_F1Score	0,96
Piksel_AUROC	0,98
Piksel_F1Score	0,58


6.2.7 FastFlow WideResNet50-2 MVTecAD kumaş analizi

FastFlow modelinin daha güçlü bir omurga ile nasıl bir performans sergilediğini değerlendirmek amacıyla bu çalışmada WideResNet50-2 omurgası kullanılmış ve MVTecAD veri setinin Kumaş kategorisinde test edilmiştir. Modelin performansı Çizelge 6.7 'de, görsel çıktıları ise Şekil 6.7 'de yer almaktadır.

Modelin parametre sayısı 91,89 milyon ve boyutu 367,56 MB gibi oldukça yüksek düzeyde olsa da inference süresi sadece 47,27 ms 'dir. Bu sonuç, modelin hem yüksek kapasiteli hem de hızlı çalışabildiğini göstermektedir. Bellek kullanımı 705,12 MB ile orta düzeyde kalmış; bu da modelin verimli bir şekilde çalıştırılabileceğini ortaya koymaktadır.

Başarım açısından model, Image düzeyinde 0,97 AUROC ve 0,96 F1Score değerleriyle yüksek sınıflama doğruluğu sunmuştur. Piksel düzeyinde ise 0,98 AUROC ve 0,60 F1Score elde edilerek lokal anomalilerin tespitinde de başarılı bir sonuç ortaya konmuştur. Özellikle Piksel_F1Score değerinin önceki FastFlow-ResNet18 konfigürasyonuna kıyasla artmış olması, daha derin omurganın detaylı lokalizasyon kabiliyetini güçlendirdiğini göstermektedir.

Şekil 6.7 ve Çizelge 6.7 incelendiğinde, FastFlow WideResNet50-2 modeli; yüksek doğruluk, düşük çıkarım süresi ve dengeli bellek kullanımı ile hem performans hem verimlilik açısından güçlü bir alternatif olarak öne çıkmaktadır.



Şekil 6.7: FastFlow WideResNet50-2 MVTecAD kumaş analizi.


Çizelge 6.7: FastFlow WideResNet50-2 MVTecAD kumaş analizi.

Özellik	Değer
Parametre Sayısı (M)	91,89
Model Boyutu (MB)	367,56
Inference Süresi (ms/görüntü)	47,27
Bellek Kullanımı (MB)	705,12
Image_AUROC	0,97
Image_F1Score	0,96
Piksel_AUROC	0,98
Piksel_F1Score	0,60

6.2.8 GLASS ResNet18 MVTecAD kumaş analizi

GLASS modeli, düşük bellek kullanımı ve hızlı çıkarım süresiyle öne çıkan, eşikleme ve segmentasyon başarımını optimize etmeye odaklı güncel bir anomalilik tespit yaklaşımıdır. Bu bölümde, ResNet18 omurgası ile yapılandırılmış GLASS modelinin MVTecAD veri setinin Kumaş kategorisindeki performansı analiz edilmiştir. İlgili görsel çıktılar Şekil 6.8 'de, sonuçlar ise Çizelge 6.8 'de sunulmuştur.

Modelin parametre sayısı 44,89 milyon ve dosya boyutu yalnızca 46,6 MB olup, bu kompakt yapı performanstan ödün vermemektedir. GPU üzerinde ölçülen inference süresi 80,56 ms gibi oldukça düşük bir seviyededir. Aynı zamanda 55,78 MB'lık bellek kullanımı, GLASS modelini özellikle gömülü sistemler ve kaynak kısıtlı donanımlar için ideal hâle getirmektedir.



Şekil 6.8: GLASS ResNet18 MVTecAD kumaş analizi.


Performans açısından değerlendirildiğinde, Image düzeyinde AUROC ve F1Score 'un 0,99 gibi neredeyse kusursuz değerlere ulaşması, modelin genel anomalilik sınıflamasında son derece başarılı olduğunu ortaya koymaktadır. Piksel düzeyinde ise AUROC değeri yine 0,99 olarak ölçülmüş, F1Score ise 0,71 ile önceki tüm modellerin üzerinde bir doğruluk sergilemiştir. Bu sonuçlar, GLASS modelinin hem genel hem de lokal anomalilik tespitinde oldukça güçlü olduğunu göstermektedir.6.8 ve Çizelge 6.8 'e bakıldığında, GLASS modelinin yüksek doğruluk, düşük gecikme süresi ve son derece düşük bellek kullanımı sayesinde hem akademik hem de uygulamalı sistemlerde dikkat çekici bir çözüm sunduğu söylenebilir.

Çizelge 6.8: GLASS ResNet18 MVTecAD kumaş analizi.

Özellik	Değer
Parametre Sayısı (M)	44,89
Model Boyutu (MB)	46,6
GPU Inference Süresi (ms/görüntü)	80,56
Bellek Kullanımı (MB)	55,78
Image_AUROC	0,99
Image_F1Score	0,99
Piksel_AUROC	0,99
Piksel_F1Score	0,71

6.2.9 GLASS WideResNet50 MVTecAD kumaş analizi

GLASS modelinin daha derin bir omurga ile performansı değerlendirilmek üzere WideResNet50 omurgası ile yapılandırılmış versiyonu, MVTecAD veri setinin



Şekil 6.9: GLASS WideResNet50 MVTecAD kumaş analizi.

Kumaş kategorisinde test edilmiştir. Modelin görsel sonuçları Şekil 6.9 'da, ayrıntılı metrikleri ise Çizelge 6.9 'da sunulmuştur.

Modelin parametre sayısı 72,82 milyon ve boyutu 277,79 MB olup, önceki ResNet18 sürümüne kıyasla daha yüksek kapasiteye sahiptir. Buna rağmen, GPU üzerinde inference süresi yalnızca 76,35 ms olup, bu düşük gecikme süresi verimli hesaplama yapabildiğini göstermektedir. Bellek kullanımı ise 302,71 MB ile orta seviyede kalmıştır.

Performans değerlendirmesi açısından, Image_AUROC 0,98 ve Image_F1Score 0,99 gibi yüksek sınıflama başarımı elde edilmiştir. Piksel düzeyinde ise AUROC değeri 0,98, F1 skoru ise 0,70 olarak ölçülmüştür. Bu sonuçlar, GLASS WideResNet50 modelinin hem genel hem lokal anomalilerin tespitinde güçlü bir performans sunduğunu, ancak ResNet18 sürümüne göre piksel düzeyinde çok belirgin bir iyileşme sağlamadığını göstermektedir.

Çizelge 6.9: GLASS WideResNet50 MVTecAD kumaş analizi.

Özellik	Değer
Parametre Sayısı (M)	72,82
Model Boyutu (MB)	277,79
GPU Inference Süresi (ms/görüntü)	76,35
Bellek Kullanımı (MB)	302,71
Image_AUROC	0,98
Image_F1Score	0,99
Piksel_AUROC	0,98
Piksel_F1Score	0,70

Şekil 6.9 ve Çizelge 6.9 dikkate alındığında, GLASS modelinin WideResNet50 ile yapılandırılmış versiyonu, yüksek doğruluk, makul bellek kullanımı ve düşük çıkarım süresi ile yüksek performanslı sistemlerde uygulanabilir bir çözüm olarak öne çıkmaktadır. Ancak, daha kompakt ve verimli olan ResNet18 sürümünün benzer sonuçlar verdiği göz önünde bulundurularak model seçiminde sistem kaynakları ve uygulama ihtiyaçları birlikte değerlendirilmelidir.

6.2.10 MVTecAD Kumaş analizi özeti

Bu çalışmada karşılaştırılan anomali tespit modelleri; mimari karmaşıklıkları, kaynak tüketimleri ve başarımları açısından kapsamlı biçimde analiz edilmiştir. Öncelikle, GLASS modeli her iki omurga yapısıyla (WideResNet50 ve ResNet18) son derece yüksek bir görüntü düzeyinde AUROC ve F1 skoru sunmaktadır (sırasıyla 0,98–0,99 ve 1,00), bu da modelin görüntü sınıflandırmasında yüksek doğruluk sağladığını ortaya koymaktadır. Özellikle ResNet18 omurgasıyla çalışan GLASS modeli, yalnızca 12,22 milyon parametre ve 46.60 MB model boyutu ile en düşük kaynak gereksinimine sahip olmakla birlikte, inference süresi açısından da en hızlı modeldir (42.00 ms). Bu kapsamda, kaynak kısıtlı ortamlarda gerçek zamanlı uygulamalar için oldukça uygun bir mimari olduğu değerlendirilmektedir.

Öte yandan, PatchCore modelleri geniş ve derin omurga yapıları (WideResNet50-2, ResNeXt101) kullanmaları nedeniyle yüksek parametre sayısı (örneğin 58,00M) ve model boyutlarına (231,99 MB) sahiptir. Bu modeller, AUROC açısından 0,99–1,00 seviyelerinde başarılı sonuçlar verse de oldukça uzun inference süreleri (yaklaşık 460–502 ms) ve yüksek bellek kullanımları (1286,25 MB) ile öne çıkmaktadır. Dolayısıyla bu modellerin yüksek donanım gerektirdiği ve düşük gecikme gerektiren sistemler için uygun olmadığı anlaşılmaktadır.

FastFlow modelleri de benzer biçimde yüksek görüntü ve piksel düzeyi AUROC değerleri sunmakla birlikte, inference süresi açısından (yaklaşık 489 ms) etkinlik gösterememektedir. Buna karşın ResNet18 omurgası ile çalıştırıldığında oldukça düşük parametre sayısı (7,67M) ve bellek kullanımı (56,98 MB) dikkat çekmektedir. Bu durum, modelin optimizasyon açısından bazı avantajlar sunduğunu ancak hesaplama süresi bakımından verimlilikten uzaklaştığını göstermektedir.

EfficientAD modeli ise 11,35 milyon parametre ile oldukça hafif bir yapıda olup 156,99 ms gibi makul bir inference süresine sahiptir. Modelin özellikle piksel düzeyinde gösterdiği yüksek F1 skoru (0,89), segmentasyon görevleri açısından dikkat çekicidir. Ancak görüntü düzeyinde AUROC (0,82) ve F1 (0,87) skorlarının diğer modellere kıyasla daha düşük olması, genel sınıflandırma performansında sınırlayıcı bir faktör olarak değerlendirilebilir.

Sonuç olarak, düşük kaynak tüketimi, hızlı çalışabilirlik ve yüksek doğruluk arasında denge kurmak açısından GLASS modelinin ResNet18 tabanlı versiyonu öne çıkmaktadır. Segmentasyon başarımının öncelikli olduğu senaryolarda ise EfficientAD modeli tercih edilebilirken, kaynak sınırlaması olmayan ve en yüksek AUROC değerinin hedeflendiği uygulamalarda PatchCore' un derin omurgalı sürümleri uygun bir alternatif sunmaktadır. Çizelge 6.10 'da bu özet gösterilmiştir.

Çizelge 6.10: MVTecAD kumaş analizi özeti.

Model	OM	PS	MB	IS	BK	IA	IF	PA	PF
GLASS	Wideresnet50	72	277	76	302	0,98	1	0,99	0,71
GLASS	ResNet18	12	46	42	55	0,99	1	0,98	0,67
PatchCore	WideResNet50-2	24	99	460	1286	0,99	0,98	0,99	0,61
PatchCore	ResNeXt101	58	231	502	1286	1	0,98	0,99	0,59
FastFlow	ResNet18	7	30	489	56	0,98	0,96	0,99	0,61
FastFlow	WideResNet50-2	91	367	472	705	0,98	0,96	0,99	0,59
PatchCore	ResNet18	2	11	458	687	0,98	0,97	0,99	0,58
PatchCore	WideResNet101	82	331	477	1286	0,99	0,97	0,98	0,56
EfficientAD	EfficientAD	11	45	156	150	0,82	0,87	0,83	0,89

6.3 En Başarılı Üç Modelin Seçilmesi ve WFDD Veri Seti ile Analizi

Tez çalışmasının önceki aşamalarında gerçekleştirilen kapsamlı değerlendirmeler sonucunda, görüntü tabanlı anomali tespitinde en iyi performans gösteren üç model belirlenmiştir. Bu modeller sırasıyla GLASS, PatchCore ve FastFlow olarak seçilmiştir. Seçim kriterleri arasında görüntü ve piksel tabanlı AUROC skorları, F1 skorları, GPU inference süreleri ve bellek kullanımları dikkate alınmıştır. Bu kriterler ışığında modellerin genel performanslarının yanı sıra, endüstriyel uygulamadaki uygulanabilirliği ve sürdürülebilirliği değerlendirilmiştir. Özellikle GLASS modelinin yüksek görüntü ve piksel AUROC performansı,

PatchCore 'un stabil görüntü tabanlı sonuçları ve FastFlow 'un hızlı inference yeteneği bu modellerin seçiminde temel belirleyici faktörler olarak rol oynamıştır.

Seçilen üç modelin performansı daha sonra gerçek endüstriyel kusurları içeren WFDD veri seti üzerinde Gri Kumaş kategorisinde test edilerek, modellerin farklı veri setlerinde genelleme yeteneği ve gerçek endüstriyel ortamlardaki etkinlikleri incelenmiştir. WFDD veri seti, tekstil sektöründeki dokuma kumaş yüzeylerinde sıkça rastlanan kusurları içeren gerçekçi ve zorlu bir veri setidir. Bu veri setinde bulunan anomaliler arasında iplik kaçıkları, doku düzensizlikleri, iplik kopmaları, lekeler ve çeşitli mekanik kusurlar yer almaktadır. WFDD, özellikle tekstil sektörü için geliştirilmiş ve literatürde kabul gören bir veri seti olarak modellerin gerçek dünya senaryolarındaki başarısını ölçmek açısından kritik bir öneme sahiptir.

GLASS modelinin WFDD veri seti üzerindeki analizlerinde, modelin hem görüntü tabanlı hem de piksel tabanlı AUROC değerlerinde yüksek skorlar elde edilmiştir. Ancak özellikle küçük kusurların piksel bazında tespitinde sınırlı başarı göstermiştir. Bu sorunun temelinde modelin eşikleme yöntemlerinde yaşadığı zorluklar yatmaktadır. Çözüm olarak sabit eşikleme yöntemlerinin uygulanması, segmentasyon sonuçlarında belirgin bir iyileşme sağlamıştır.

PatchCore modeli WFDD üzerinde yapılan değerlendirmelerde, genel olarak istikrarlı sonuçlar sergilemiştir. Görüntü bazlı AUROC ve F1 skorları açısından oldukça tatmin edici sonuçlar vermesine rağmen, piksel bazlı segmentasyon performansı GLASS modeline kıyasla daha düşük kalmıştır. Buna rağmen, modelin stabil çalışma performansı ve düşük hata oranları, pratik uygulamalar için avantajlı bir özellik sunmaktadır.

FastFlow modeli ise WFDD veri setinde hızlı inference süreleri ve nispeten düşük bellek tüketimi ile dikkat çekmiştir. Özellikle GPU kaynaklarının sınırlı olduğu gerçek zamanlı endüstriyel uygulamalarda avantajlı konumdadır. Ancak piksel bazında segmentasyon başarısının daha düşük olması, modelin küçük anomalileri tanımlama yeteneğini sınırlandırmaktadır. Bu durumun iyileştirilmesi amacıyla eşikleme yöntemlerinde ve eğitim parametrelerinde yapılacak iyileştirmeler gelecekteki çalışmalarda değerlendirilmelidir.

WFDD veri seti ile gerçekleştirilen karşılaştırmalı analiz, seçilen modellerin endüstriyel gerçekliğe uygunluklarını ortaya koymuş ve farklı modellerin hangi

koşullarda daha etkili olabileceği konusunda netlik sağlamıştır. Bu kapsamda GLASS modeli genel performans açısından öne çıkarken, PatchCore modelinin stabilitesi ve FastFlow modelinin ise hız odaklı uygulamalarda sunduğu avantajlar, farklı endüstriyel gereksinimlere yönelik etkin çözümler sunmaktadır. Bu analiz, tez çalışmasının bir sonraki aşaması olan özel olarak hazırlanan AIORCOM-TextileAD veri seti üzerindeki detaylı değerlendirmeler için de önemli bir temel teşkil etmektedir

6.3.1 Seçilen modellerin belirlenme kriterleri

Bu tez kapsamında kullanılan görüntü tabanlı anomali tespit modellerinin belirlenme süreci, çeşitli teknik ve uygulama odaklı kriterlere göre gerçekleştirilmiştir. Yapılan detaylı analizler sonucunda GLASS, PatchCore ve FastFlow modelleri, performans, kullanılabilirlik ve uygulanabilirlik açısından en yüksek potansiyeli gösteren modeller olarak seçilmiştir. Model seçiminde dikkate alınan temel kriterler; görüntü ve piksel tabanlı performans metrikleri, donanım kaynaklarının etkin kullanımı, çıkarım (inference) hızları, bellek tüketimi ve modellerin gerçek endüstriyel senaryolara olan uyumluluğudur.

İlk kriter olarak, modellerin anomali tespit başarısını ölçmek üzere görüntü bazında AUROC ve görüntü bazında F1 skorları kullanılmıştır. Bu metrikler, modellerin kusurlu ve normal görüntüleri ayırt etme yeteneklerini doğrudan yansıtmaktadır. GLASS modeli, bu metriklerde %99'un üzerinde yüksek ve stabil sonuçlar sunarak performans açısından ilk sırayı almıştır. PatchCore modeli ise görüntü bazlı performansta istikrarlı ve tatmin edici sonuçlar göstererek, özellikle pratik uygulamalarda güvenilirlik sağladığı için tercih edilmiştir. FastFlow modeli ise bu kriterde tatmin edici skorlar sunmakla birlikte, özellikle hız odaklı gerçek zamanlı uygulamalara yönelik avantajları ile dikkat çekmiştir.

İkinci temel kriter olan piksel tabanlı performans, anomalilerin lokalizasyon başarısını ölçmek için piksel bazında AUROC ve F1 skorları ile değerlendirilmiştir. Piksel tabanlı metriklerde, genel olarak tüm modellerin performansı görüntü tabanlı sonuçlara göre daha düşük kalmıştır. GLASS modelinin piksel tabanlı AUROC değerlerinin yüksek olması, anomalileri doğru lokalize etme yeteneği açısından önemli bir avantaj sağlamıştır. PatchCore ve FastFlow modelleri, piksel bazlı segmentasyonda daha sınırlı başarı göstermesine rağmen, yine de belli bir seviyede

stabil performans sunmuştur. Modellerin piksel bazında segmentasyon performansları, daha sonraki optimizasyon çalışmaları için önemli bir gösterge olarak değerlendirilmiştir.

Üçüncü temel kriter olarak donanım kaynaklarının etkin kullanımı ve modellerin gerçek endüstriyel ortamlarla uyumluluğu dikkate alınmıştır. GPU inference süreleri, bellek kullanımı ve parametre sayıları bu açıdan kritik faktörler olarak değerlendirilmiştir. FastFlow modeli, diğer modellere kıyasla hızlı inference süreleri ve düşük bellek tüketimi ile bu alanda önemli avantajlar sunmuştur. PatchCore modeli, bellek tüketimi ve parametre büyüklüğü açısından dengeli bir performans sergilerken, GLASS modeli özellikle parametre sayısı yüksek omurgalarla kullanıldığında nispeten daha yüksek bellek tüketmiştir. Ancak GLASS modelinin genel performansının yüksekliği, bu dezavantajları telafi ederek modelin tercih edilmesini sağlamıştır.

Son olarak, seçilen modellerin literatürdeki referans çalışmalarda yaygın kullanımı ve endüstriyel uygulamalarda kanıtlanmış güvenilirliği de karar sürecinde etkili olmuştur. Bu kapsamda, GLASS modelinin yakın dönemde yüksek akademik atıflar alması, PatchCore modelinin endüstriyel kalite kontrol uygulamalarındaki başarısı ve FastFlow modelinin gerçek zamanlı sistemlerde kanıtlanmış uygulanabilirliği önemli rol oynamıştır.

Tüm bu kriterlerin sistematik ve detaylı değerlendirilmesi sonucunda, tez çalışmasının ileri aşamalarında kullanılmak üzere GLASS, PatchCore ve FastFlow modelleri belirlenmiş ve sonraki analizlerde bu modeller üzerinden ilerlenmiştir. Bu modeller, daha sonraki analiz aşamalarında WFDD ve özel olarak hazırlanan AIORCOM-TextileAD veri setleri üzerinde performans ve genelleme yetenekleri açısından kapsamlı biçimde test edilmiştir.

6.3.2 GLASS Resnet18 WFDD performans analizi

GLASS modelinin genel geçerliliğini değerlendirmek amacıyla, ResNet18 omurgası kullanılarak WFDD veri seti üzerinde testler gerçekleştirilmiştir. Bu deneysel çalışma sonucunda elde edilen nicel performans değerleri Çizelge 6.11 'de görsel analiz çıktıları ise Şekil 6.10 'da sunulmuştur.


Modelin parametre sayısı 12,22 milyon ve model boyutu 46,6 MB olup, oldukça kompakt bir yapı sergilemektedir. GPU üzerinde yapılan çıkarımda yalnızca 12,78

ms gibi son derece düşük bir inference süresi elde edilirken, CPU üzerinde bu süre 98,25 ms 'ye çıkmaktadır. Bellek kullanımı ise yalnızca 55,78 MB ile minimum seviyededir. Bu özellikler, modeli gömülü sistemler ve düşük güçlü cihazlarda gerçek zamanlı kullanım için ideal hâle getirmektedir.

Çizelge 6.11: GLASS Resnet18 WFDD performans analizi.

Veri Seti	WFDD
Model	GLASS
Backbone	Resnet18
Parametre Sayısı (M)	12,22
Model Boyutu (MB)	46,6
Inference Süresi (ms/görüntü) GPU	12,78
Inference Süresi (ms/görüntü) CPU	98,25
Bellek Kullanımı (MB)	55,78
Image AUROC	0,99
Image F1Score	0,99
Piksel AUROC	0,99
Piksel F1Score	0,82

Başarım açısından değerlendirildiğinde, model Image düzeyinde 0,99 AUROC ve 0,99 F1 skoru ile son derece yüksek sınıflama doğruluğu sağlamıştır. Bu değerler, literatürde bildirilen (PAPER Image AUROC: 99.1) sonuçlarla büyük ölçüde örtüşmektedir. Piksel düzeyinde de model 0,99 AUROC ve 0,82 F1 skoru ile oldukça güçlü bir lokal anomalilik tespiti sunmuştur. Özellikle Piksel F1 skorundaki bu yüksek değer, GLASS modelinin segmentasyon kabiliyetinin WFDD gibi gerçek dünya verilerinde de etkili olduğunu göstermektedir.




Şekil 6.10: GLASS Resnet18 WFDD performans analizi.

Şekil 6.10 ve Çizelge 6.11 'e bakıldığında, GLASS ResNet18 modelinin sadece MVTEcAD değil, aynı zamanda WFDD gibi daha karmaşık ve gerçekçi veri setlerinde de üstün performans sergilediği görülmektedir.

6.3.3 PatchCore Resnet18 WFDD performans analizi

PatchCore modeli, segmentasyon temelli örnekleme ve bellek tabanlı çıkarım yapısıyla anomali tespiti alanında sıkça başvurulan yöntemlerden biridir. Bu analizde, ResNet18 omurgası ile yapılandırılan PatchCore modelinin WFDD veri setindeki başarımı değerlendirilmiştir. Model, yalnızca 2,78 milyon parametreye ve 10,61 MB'lık model boyutuna sahip olup, oldukça hafif bir yapı sunmaktadır. GPU üzerinde 77,31 ms, CPU üzerinde ise 80,76 ms gibi dengeli ve orta seviyeli çıkarım süreleri elde edilmiştir. Ancak bellek kullanımını 1699,32 MB gibi oldukça yüksek bir düzeydedir; bu durum, özellikle PatchCore 'un geniş özellik yığını oluşturma süreci nedeniyle kaynak tüketiminin arttığını göstermektedir. Performans açısından



Şekil 6.11: PatchCore Resnet18 WFDD performans analizi.

model, Image düzeyinde 0,99 AUROC ve 0,98 F1Score ile yüksek doğruluk

sağlamış, literatürde bildirilen değerlere (PAPER Image AUROC: 0.97, F1Score: 0.94) göre daha iyi sonuçlar üretmiştir. Ancak piksel düzeyine gelindiğinde AUROC değeri 0,96'ya düşerken, F1 skoru yalnızca 0,43 olarak kalmıştır. Bu durum, modelin anomali yerelleştirme konusunda zayıf performans sergilediğine işaret etmektedir. Literatürde bu kategori için bildirilen Piksel_AUROC değeri 0,98 olsa da F1 skoru rapor edilmemiştir. Şekil 6.11 ve Çizelge 6.12 'ye bakıldığında, PatchCore ResNet18 modeli görüntü bazlı sınıflandırmada güçlü bir performans gösterse de piksel düzeyinde segmentasyon başarımı açısından GLASS gibi alternatif yöntemlere kıyasla önemli ölçüde geride kalmaktadır. Özellikle yüksek bellek gereksinimi, modelin gömülü sistemlerde kullanımı açısından dikkatle değerlendirilmelidir.


Çizelge 6.12: PatchCore Resnet18 WFDD performans analizi.

Model	PatchCore
Backbone	Resnet18
Parametre Sayısı (M)	2,78
Model Boyutu (MB)	10,61
Inference Süresi (ms/görüntü) GPU	77,31
Inference Süresi (ms/görüntü) CPU	80,76
Bellek Kullanımı (MB)	1699,32
Image AUROC	0,99
Image F1Score	0,98
Piksel AUROC	0,96
Piksel F1Score	0,43

6.3.4 FastFlow Resnet18 WFDD performans analizi

FastFlow modeli, akış tabanlı dağılım modellemesi ile hem sınıflandırma hem de segmentasyon görevlerinde hızlı ve etkili sonuçlar üretmeyi amaçlayan modern bir anomali tespit yöntemidir. Bu bölümde, ResNet18 omurgası ile yapılandırılmış FastFlow modelinin WFDD veri seti üzerindeki performansı değerlendirilmiştir. Görsel sonuçlar Şekil 6.12 'de, sayısal metrikler ise Çizelge 6.13 'de sunulmuştur.

Model 7,67 milyon parametreye ve 30,68 MB boyuta sahip olup, orta ölçekli ve taşınabilir bir yapıya sahiptir. GPU üzerinde 72,73 ms, CPU üzerinde ise 82,62 ms inference süresi ile çalışarak dengeli bir işlem süresi ortaya koymaktadır. Bellek kullanımı ise 337,68 MB ile kabul edilebilir seviyededir ve özellikle düşük bellekli cihazlarda da çalışabilirliğe imkân tanımaktadır.



Şekil 6.12: FastFlow Resnet18 WFDD performans analizi.

Başarım açısından değerlendirildiğinde, model Image düzeyinde 1,00 AUROC ve 0,99 F1 skoru ile literatürdeki sonuçların (PAPER AUROC: 0,98, F1: 0,96) dahi üzerine çıkmıştır. Bu, modelin genel anomalili - normal görüntüleri neredeyse kusursuz şekilde ayırt edebildiğini göstermektedir. Ancak piksel düzeyinde AUROC 0,97 ile güçlü kalmasına karşın, F1 skoru 0,43 gibi görece düşük bir değerde kalmıştır. Literatürde bildirilen Piksel F1 değeri 0,57 olup, bu fark modelin eşikleme yöntemine ve uygulama ayarlarına duyarlı olabileceğini düşündürmektedir.

Şekil 6.12 ve Çizelge 6.13 dikkate alındığında, FastFlow ResNet18 modeli görüntü düzeyinde yüksek doğruluk ve taşınabilir yapı avantajlarını bir araya getirmektedir. Ancak piksel düzeyindeki F1 skorunun düşüklüğü, lokal segmentasyon performansının daha gelişmiş yöntemlerle (örneğin GLASS) desteklenmesi gerekebileceğine işaret etmektedir.

Çizelge 6.13: FastFlow Resnet18 WFDD performans analizi.

Veri Seti	WFDD
Model	FastFlow
Backbone	Resnet18
Parametre Sayısı (M)	7,67
Model Boyutu (MB)	30,68
Inference Süresi (ms/görüntü) GPU	72,73
Inference Süresi (ms/görüntü) CPU	82,62
Bellek Kullanımı (MB)	337,68
Image AUROC	1,00
Image F1Score	0,99
Piksel AUROC	0,97
Piksel F1Score	0,43

6.3.5 WFDD sonuçlarının genel değerlendirilmesi ve model seçimi

WFDD veri seti üzerinde gerçekleştirilen 2. ve son olan kıyaslama deneysel çalışmalar performans kıyaslamalarının doğru olarak yapılabilmesi için sadece ResNet18 omurgası üzerinden gerçekleştirmiştir. Ayrıca MVTecAD Kumaş ile kıyaslama çalışmalarında seçilen en başarılı 3 modelin WFDD Gri Kumaş kategorisinde nasıl davrandığı da bu çalışma ile daha detaylı olarak görülmüştür.

Bu kısımda GLASS, PatchCore ve FastFlow modellerinin ResNet18 omurgasında hem sınıflandırma hem de segmentasyon düzeyinde başarımları değerlendirilmiştir. Model karşılaştırmalarında sadece metrikler değil, aynı zamanda kaynak tüketimi (parametre sayısı, bellek kullanımı, inference süresi) gibi operasyonel veriler de göz önünde bulundurulmuştur.

Çizelge 6.11–6.13 'de sunulan deneysel verilere göre, GLASS ResNet18 modeli Image düzeyinde AUROC: 0,99, F1Score: 0,99 gibi neredeyse mükemmel skorlar üretmiştir. Bu sonuçlar, literatürde bildirilen GLASS Makale_Image_AUROC değeri olan 99.1 ile büyük ölçüde uyumlu; hatta Image_F1Score açısından bildirilen değer üzerinde bir başarı sunmaktadır. Piksel düzeyinde ise AUROC: 0,99 ile yine oldukça yüksek bir doğruluk sağlanmış, F1 skoru ise 0,82 ile segmentasyon açısından tatmin edici bir düzeyde kalmıştır. Bu değer, literatürde bildirilen Piksel_AUROC skoru olan 98,0'ı doğrularken, F1 skor açısından yayınlanmış karşılık bulunmamaktadır. GLASS modelinin 4 metrik üzerinden hesaplanan ortalama başarı skoru 0,95 ile en yüksek değere ulaşmıştır. Buna ek olarak, sadece 12,78 ms GPU ve 98,25 ms CPU inference süresi ile çalışabilmesi ve sadece 55,78 MB bellek kullanması, modeli gerçek zamanlı ve gömülü sistemler için ideal hâle getirmiştir.

Diğer taraftan, PatchCore ResNet18 modeli Image düzeyinde 0,99 AUROC ve 0,98 F1 skorları ile güçlü bir sınıflama performansı sunmuş, literatürdeki değerlerle (AUROC: 0,97; F1: 0,94) uyumlu veya daha iyi sonuçlar üretmiştir. Ancak piksel düzeyinde F1 skoru yalnızca 0,43 olarak kalmış, bu da segmentasyon performansının sınırlı olduğunu göstermektedir. Ayrıca modelin 1699 MB gibi son derece yüksek bir bellek kullanımıyla çalışıyor olması, özellikle düşük kaynaklı ortamlarda kullanımını kısıtlamaktadır. Ortalama 4 metrik başarı skoru 0,845'tir.

FastFlow ResNet18 modeli ise Image AUROC: 0,99 ve F1Score: 0,99 gibi çok yüksek sınıflama doğruluğu sağlasa da piksel F1 skoru sadece 0,42 olarak kalmıştır. Literatürde bildirilen karşılıklar (AUROC: 0,97; F1: 0,95 / Piksel AUROC: 0,98; F1: 0,57) ile karşılaştırıldığında, Image düzeyinde daha yüksek ancak segmentasyon düzeyinde daha düşük bir doğruluk gözlemlenmiştir. Ortalama skor ise 0,84 olarak hesaplanmıştır. Bellek kullanımı (337,68 MB) PatchCore 'dan düşük olsa da GLASS 'a göre oldukça yüksektir ve inference süreleri de daha uzundur (GPU: 72,73 ms).

Tüm bu veriler ışığında, model seçimi açısından değerlendirildiğinde, yalnızca yüksek doğruluk değil, aynı zamanda düşük kaynak tüketimi, hız ve genellenebilirlik gibi kriterler de göz önünde bulundurulmalıdır. Bu çerçevede, GLASS modeli WideResNet50-2 backbone ile yeniden eğitilmiş ve ana model olarak seçilmiştir. Bunun nedeni, ResNet18 sürümünün sunduğu yüksek doğruluk seviyesinin daha güçlü bir backbone ile korunduğu ve segmentasyon başarımının optimize edildiğidir. Ayrıca inference süresi GPU ile hâlâ düşük düzeyde kalmakta ve bellek kullanımı sistem gereksinimlerini aşmamaktadır.

WFDD veri seti üzerinde yapılan karşılaştırmalı analizler, GLASS WideResNet50-2 modelini hem akademik hem uygulamalı kullanım için en dengeli ve verimli çözüm olarak ön plana çıkarmıştır.

7. AIORCOM-TEXTILEAD ÖZEL VERİ SETİNİN OLUŞTURULMASI

Gerçek üretim koşullarını yansıtan bir değerlendirme ortamı sunmak amacıyla, bu tez kapsamında tekstil sektörüne özgü kusurları içeren AIORCOM-TextileAD adlı özel bir veri seti oluşturulmuştur. Veri seti, Logitech Brio 4K kamera ile sabit 8mm odakta ve 1024×1024 çözünürlükte gündüz ışığı koşullarında çekilen yüksek kaliteli görsellerden oluşmaktadır. Görüntüleme sürecinde sabit tripod ve özel ışıklandırma kullanılarak tutarlı veri elde edilmiştir.

Toplamda 782 görselden oluşan veri setinin 301'i kusursuz eğitim örnekleri, 60'ı kusursuz test, 60'ı ise gerçek anomalili test örneklerinden oluşmaktadır. Anomalili görseller için piksel düzeyinde toplam 60 test ve 301 eğitim segmentasyon maskesi, Adobe Photoshop ile manuel olarak hazırlanmıştır. Bu maskeler, piksel bazlı anomali lokalizasyonunun hassasiyetini artırmak amacıyla titizlikle düzenlenmiştir.

Veri artırımı amacıyla döndürme, kontrast-parlaklık ayarı ve kırpma gibi teknikler uygulanmış; eğitim, doğrulama ve test alt kümeleri rastgele bölünmüştür. Oluşturulan bu veri seti üzerinde GLASS, PatchCore ve FastFlow modelleri eğitilmiş; parametrik optimizasyonlar ve eşikleme stratejileriyle segmentasyon başarımı artırılmaya çalışılmıştır. İlk sonuçlar, özellikle görüntü bazlı anomali tespitinde yüksek başarı sağlandığını, ancak küçük anomalilerde segmentasyon performansının daha fazla iyileştirme gerektirdiğini göstermiştir.

7.1 Özel Veri Setinin Gerekçesi ve Genel Özellikleri

Standart veri setleri, model karşılaştırmaları için önemli bir temel sunsa da gerçek üretim ortamlarının karmaşıklığını yansıtmakta yetersiz kalabilmektedir. Bu nedenle tez kapsamında, tekstil üretim hatlarında karşılaşılan özgün kusurları içeren ve gerçek senaryoları temsil eden AIORCOM-TextileAD veri seti oluşturulmuştur. Bu özel veri seti, yüksek çözünürlüklü görseller, manuel segmentasyon maskeleri ve dengeli anomali dağılımı gibi nitelikleriyle, derin öğrenme tabanlı modellerin endüstriyel uygulamalara yönelik başarımını daha gerçekçi biçimde ölçmeyi amaçlamaktadır. Eğitim, doğrulama ve test bölümleri titizlikle yapılandırılan veri

seti, model genelleme kabiliyetini artırmak için çeşitli veri artırma teknikleriyle desteklenmiştir.

7.1.1 Logitech Brio 4K kamera

AIORCOM-TextileAD veri setinin oluşturulmasında kullanılan Logitech Brio 4K kamera, yüksek çözünürlüklü görüntüleme kapasitesi ve endüstriyel düzeyde netlik sağlaması nedeniyle tercih edilmiştir. 4K Ultra HD çözünürlük (4096×2160 piksel) sunabilen bu kamera, HDR desteği ve otomatik ışık dengeleme özellikleri sayesinde farklı aydınlatma koşullarında dahi tutarlı ve detaylı görseller elde edilmesini mümkün kılar. Sabit odak mesafesi, düşük distorsiyon seviyesi ve tripod uyumluluğu ile Brio 4K, yüzey kusurlarının hassasiyetle tespit edilmesini gerektiren anomali tespiti uygulamaları için uygun bir donanım sunmaktadır.

7.1.2 K&F Concept SA254T2 alüminyum kompakt tripod

Veri toplama sürecinde kullanılan K&F Concept SA254T2 alüminyum kompakt tripod, sağlam ve esnek yapısıyla kamera konumlandırmasında yüksek stabilite sağlamıştır. Ayarlanabilir bacak açıları ve döner merkez kolu sayesinde, çekim açısı ve yüksekliği hassas biçimde optimize edilmiş; böylece ışık yansıması ve gölgelenme minimize edilerek homojen görüntüleme koşulları elde edilmiştir. Bu tripodun sağladığı esneklik, her bir görselde tutarlı kalite ve anomali görünürlüğü açısından önemli avantaj sunmuştur.

7.1.3 Görüntülerin fotoğraflanması ve saklama prosedürleri

Bu çalışmada kullanılan görüntüler, Logitech Brio 4K harici web kamerası aracılığıyla, sabit odaklama ve kontrollü aydınlatma koşulları altında, 1024x1024 piksel çözünürlükte elde edilmiştir. Görüntü yakalama süreci, özel olarak geliştirilen bir grafik arayüz (GUI) uygulaması üzerinden yürütülmüş olup, her manuel tetikleme ile kamera ön izlemesinden alınan görüntü, benzersiz bir dosya ismiyle doğrudan kayıt altına alınmıştır. Kullanıcı etkileşimine dayalı bu yöntem, veri toplama sürecinde sistematik ve denetlenebilir bir yapı sunmakta; görüntülerin hem format hem de çözünürlük açısından homojen olmasını garanti etmektedir. Böylelikle eğitim ve test aşamasında karşılaşılan varyasyonların yalnızca kusur tipine veya yüzey yapısına bağlı olması sağlanmıştır.

Elde edilen her görüntü, sistemde tanımlı bir dizin yapısı içerisinde ardışık olarak adlandırılan dosyalar halinde saklanmış, aynı zamanda görüntülerin etiketlenmesine olanak sağlayacak biçimde giriş (ham görüntü) ve çıkış (tahmin sonucu) klasörleri ayrıştırılmıştır. Bu yapılandırma sayesinde hem model değerlendirmeleri hem de görsel analizler için yüksek doğrulukta ve tekrarlanabilir veri işleme süreçleri oluşturulmuştur. Ayrıca görüntü kayıt prosedürüne entegre edilen zaman damgası ve sınıflandırma bilgisi gibi yardımcı öznitelikler, deneysel tekrarların izlenmesini ve belgelendirilmesini kolaylaştırmıştır. Saklama prosedürleri, veri güvenliği ve bütünlüğünü esas alan bir yaklaşım çerçevesinde planlanmış ve araştırmanın şeffaflığı açısından kritik bir unsur olarak değerlendirilmiştir. Şekil 7.1 'de çekilen görsellerin fotoğraflanması ve sistematik ardışık isimlerle kaydedilme sürecinde kullanılan arayüz fotoğrafı gösterilmiştir.



Şekil 7.1: Görüntülerin fotoğraflanması ve saklanması arayüzü.

Her fotoğraf çek ve kaydet tuşuna basıldığında fotoğraflar 1024x1024 boyutunda 000.png'den başlayarak ve 1 atılarak kaydedilmeye başlanacaktır. Buradaki temel nokta aynı fotoğrafların çekilmemesi kumaşın farklı yönlerde hareket ettirilmesidir.

7.1.4 Photoshop ile segmentasyon maskeleri ve etiketleme

AIORCOM-TextileAD veri setinde yer alan anomalili görüntüler için piksel düzeyinde segmentasyon maskeleri oluşturularak, kusurların konumlarının yüksek doğrulukla belirlenmesi sağlanmıştır. Bu amaçla Adobe Photoshop yazılımı kullanılmış, her görüntü yüksek yakınlaştırma ile detaylı şekilde incelenmiş ve anomaliler dikkatle işaretlenmiştir. Her maske, görüntü ile aynı çözünürlükte ve siyah-beyaz formatta hazırlanmış; beyaz alanlar anomalileri, siyah alanlar ise normal bölgeleri temsil etmiştir. Maskeler, ait oldukları orijinal görüntülerle birebir eşleşecek biçimde adlandırılmış ve ayrı klasörlerde saklanmıştır. Tüm bu süreçte titiz bir çalışma yürütülmüş, eksik ya da hatalı işaretleme modelin piksel düzeyindeki performansını olumsuz etkilememesi için özen gösterilmiştir. Doğru hazırlanmış bu segmentasyon maskeleri, modelin hem eğitim kalitesini hem de değerlendirme aşamasındaki güvenilirliğini önemli ölçüde artırmıştır.

7.2 Veri Setinin Eğitim, Doğrulama ve Test Bölümlemesi ile Veri Artırımı

AIORCOM-TextileAD veri seti, eğitim, doğrulama ve test süreçleri için ayrı bölümlere ayrılarak yapılandırılmıştır. Eğitim setinde yalnızca normal görüntüler yer alırken, test seti hem normal hem de anomalili görüntüleri içermektedir. Eğitim setinden bağımsız olarak, model eğitim sürecindeki parametrelerin optimizasyonu için ayrıca doğrulama seti oluşturulmuştur.

Modellerin genelleme yeteneğini artırmak ve aşırı öğrenme problemini engellemek amacıyla veri artırımı yöntemleri uygulanmıştır. Bu süreçte görüntülere çeşitli açılarda döndürme parlaklık ve kontrast ayarlamaları, yatay ve dikey çevirme ve rastgele kırma gibi yöntemler uygulanarak veri çeşitliliği artırılmıştır. Böylece modellerin farklı durumlarda daha kararlı çalışması sağlanmıştır.

Eğitim, doğrulama ve test kümeleri arasındaki oranlar, genel kabul gören standartlar doğrultusunda belirlenmiş ve tüm görüntüler rastgele ancak dengeli biçimde dağıtılmıştır. Bölümleme işlemi sırasında görseller ve maskeler arasındaki

eşleşmeler korunarak, eğitim ve değerlendirme süreçlerinde tutarlılık sağlanmıştır. Bu sistematik yaklaşım, veri setinin kullanımını kolaylaştırmış ve modellerin performans değerlendirmelerini objektif hale getirmiştir.

7.2.1 Veri bölümlenme stratejileri

AIORCOM-TextileAD veri setinin bölümlenme süreci, literatürde sıklıkla kullanılan MVTECAD Kumaş kategorisinin yaklaşımı örnek alınarak tasarlanmıştır. Veri setinde yer alan tüm görüntüler, standart gündüz ışığı koşullarında, 8 mm sabit odaklı kamera ayarında ve 1024x1024 piksel çözünürlükte elde edilmiştir. Bu standartlaştırılmış görüntüleme süreci, görüntü kalitesi ve veri seti tutarlılığını güvence altına almıştır.

Eğitim, doğrulama ve test bölümlerinin oluşturulmasında, eğitim kümesi yalnızca kusursuz tekstil yüzeyi görüntülerini içerecek biçimde düzenlenmiştir. Bu yapı sayesinde modeller, yalnızca normal dokusal özellikleri öğrenmiş ve anomalileri, öğrenilen bu standart yapıya göre ayırt etmiştir. Test kümesi, modellerin hem normal hem de anomalili görüntüleri doğru biçimde sınıflandırma yeteneğini değerlendirmek amacıyla, normal ve anomalili görüntüleri dengeli bir şekilde içermektedir.

Doğrulama kümesi ise eğitim kümesinden ayrı olarak rastgele seçilen normal görüntülerle oluşturulmuş ve eğitim sırasında model parametrelerinin optimizasyonunda kullanılmıştır. Bu veri bölümlenme stratejisi, modellerin performansını doğru biçimde ölçmekte ve genelleme yeteneğini artırmaktadır. Ayrıca veri setindeki tüm görüntüler ve maskeler, sistematik isimlendirme ve klasör yapısı ile düzenlenmiş, böylece model eğitimi ve değerlendirme süreçlerinde karışıklık önlenmiştir.

7.2.2 Veri artırımı yöntemleri

Görüntü tabanlı yapay zekâ uygulamalarında, model başarımını artırmak ve aşırı öğrenme gibi sorunların önüne geçebilmek için veri artırımı teknikleri kritik bir rol oynar. Özellikle sınırlı sayıda örneğe sahip veri setlerinde, modelin genelleme yeteneğini yükseltmek amacıyla mevcut görseller üzerinde çeşitli dönüşümler uygulanır. Bu dönüşümler, görüntünün anlamını koruyacak biçimde fakat görsel varyasyon oluşturarak gerçekleştirilir. Döndürme, yatay simetri alma, parlaklık

değiştirme gibi işlemler sayesinde model, aynı sınıfa ait farklı görünümü tanımayı öğrenir. Böylelikle eğitim sürecinde, model sadece belirli açılara veya aydınlatmalara duyarlı hale gelmez; daha esnek, dayanıklı ve gerçek dünya koşullarına uyum sağlayabilen bir hale gelir.

Bu çalışmada uygulanan augmentasyon süreci, Logitech Brio 4K kamera ile çekilmiş görsellerin bulunduğu klasörde gerçekleştirilmiş ve her görüntü için altı farklı varyasyon üretilmiştir. Döndürme işlemleri (90° , 180° , 270°) ile görüntünün yön değişimlerine karşı modelin adaptasyonu hedeflenmiş; yatay simetri ile yapay veri çeşitliliği sağlanmıştır. Ek olarak, parlaklık artırma ve azaltma gibi aydınlatma koşullarına yönelik dönüşümlerle modelin ışık değişimlerine karşı toleransı yükseltilmiştir. Her bir yeni görüntü, dosya ismi sıralamasına uygun biçimde mevcut veri setine eklenmiş ve bu sayede veri seti genişletilmeden önceki yapı bozulmadan korunmuştur. Bu otomatikleştirilmiş süreç, özellikle endüstriyel kusur tespiti gibi hassas alanlarda model eğitime zengin ve dengeli bir örnekleme tabanı sağlar.

8. AIORCOM-TEXTILEAD VERİSETİ GLASS EĞİTİMİ

GLASS eğitim süreci kullandığınız donanıma özel doğru Python ortamının kurulabilmesi koşuluyla oldukça kolaydır. Bu tez sürecinde süreç Apple M1 Ultra, Apple M2, Apple M4 işlemcilerle başlamış olup yaşanan sorunlar nedeniyle Nvidia sanal donanımlarla devam etmiştir. GLASS modeli Apple Silikon[94] işlemcilerde çalışsa da gerek yaşanan sorunlar gerek deney düzeneği fazlalığı nedeniyle Intel işlemcili ve CUDA destekli bir Nvidia ekran kartlı donanıma sahip ortamda çalışmak konforu arttırmaktadır. GLASS modelinde sorun olmamasına rağmen Apple Silikon işlemcilerin daha önceki bölümlerde denediğimiz bazı model ve omurga varyasyonlarını çalıştıramadığı açıkça görülmüştür.

8.1 GLASS Modeli Eğitim Ortamları

GLASS modelini çalıştırabilmemiz için, geliştirici Github sayfasında bulunan requirements.txt dosyasını donanımınıza uygun olarak kurmanız gerekmektedir[9]. Uzun denebilecek ayarlardan sonra model M1, M2 ve M4 işlemcilerde denenmiştir ve çalışmaktadır fakat daha hızlı ve kolay denemeler için Intel işlemci ve Cuda destekli Nvidia Ekran kartlı bir bilgisayar önerilmektedir.

8.2 GLASS Modeli Çalıştırılması

GLASS modelini ortamınıza indirip gerekli Python enviromenti donanımınıza uygun olarak kurduktan sonra model calistir.py ortamında çalıştırılabilir. Kod içerisindeki gerekli olan veri seti yollarını sisteminize uygun olarak ayarlamanız gerekmektedir.

DTD, 2014 Oxford Üniversitesi tarafından yayınlanmıştır. Görsel dokuların tanımlanabilir niteliklerine dayalı olarak sınıflandırılmasını hedefleyen, kapsamlı ve standart bir görüntü veri setidir.

Veri seti, 47 farklı betimleyici doku kategorisinde, her biri farklı sahnelerden alınmış en az 120 görüntü olmak üzere toplamda yaklaşık 5.640 görsel


içermektedir. Görseller çeşitli doğal, yapay ve karmaşık yüzeylerden oluşmakta ve her biri RGB formatındadır[95]. Kod çalıştırma sonrası doğru ayarların yapılması ve donanıma uygun doğru ortamın oluşturulması ardından eğitime başlayacaktır. Seçtiğiniz parametrelere ve donanımıza göre eğitim 10dk'dan başlayıp 3 güne kadar süren uzunluklarda çalışacaktır.

8.3 GLASS Modeli Çalışma Prensipleri

GLASS modelinin eğitimi, main.py dosyası üzerinden çağrılan çok sayıda yardımcı modül ve alt bileşenin koordinasyonu ile yürütülen bir süreçtir. Python betiği, model parametrelerinin dinamik olarak dışarıdan tanımlanmasını sağlayan bir yapıdadır ve sistemdeki GPU kaynaklarının etkin kullanımı amacıyla alt proses modülüyle birlikte çalışmaktadır. Python betiği, belirli bir görevi veya işlemi otomatikleştirmek için yazılmış ve doğrudan çalıştırılabilen Python program dosyasıdır. Söz konusu komut, modelin temel bileşenlerini, ağ mimarisini, eğitim hiperparametrelerini ve veri yollarını içeren yapılandırmaları alarak, merkezi kontrol noktasından modelin eğitim fazını başlatmaktadır. Bu yönüyle komut, sadece GLASS modelinin değil, aynı zamanda öğrenme sürecine entegre edilmiş veri artırımı, gömme uzayı yapılandırması ve ayrıştırıcı modülünün bütün parametrelerini içerecek şekilde sistematik bir çağrı yapısı sunmaktadır.

8.4 GLASS Modeli Eğitim Süresi

Eğitim süresi, kullanılan donanım mimarisi ve belirlenen hiperparametre setine bağlı olarak değişkenlik göstermektedir. Bu tez çalışmasında, modelin özgün çalışmasında tanımlanan 640 epoch 'luk eğitim döngüsünün tamamlanması yaklaşık üç gün sürmüştür, bu sürecin tamamı boyunca sistem kesintisiz olarak çalıştırılmıştır. Eğitim süresince modelin en yüksek başarı düzeyine 513. epoch 'ta ulaştığı gözlemlenmiştir. Eğitim tamamlandığında, modelin tüm çıktıları ve en iyi ağırlık dosyaları otomatik olarak results dizin yapısı altında ilgili alt klasörlere kaydedilmiştir. Şekil 8.1 'de sunulan örnek görselde de görüldüğü üzere, GLASS modeli AIORCOM-TEXTILEAD veri setinde yer alan bir iplik kaçığını yüksek doğrulukla tespit etmiş; bu da modelin detay düzeyindeki yüzey kusurlarını ayrıştırma yeteneğini açık biçimde ortaya koymuştur. Bu bulgu, GLASS



Şekil 8.1: GLASS model eğitimi sonuçlar görseli örneği.

mimarisinin endüstriyel tekstil hatlarında kullanılabilirliğine yönelik güçlü bir kanıt niteliğindedir.

8.5 GLASS Eğitimi Model Saklanması ve En İyi Model

Eğitim süreci tamamlandığında, oluşturulan model ağırlıkları models klasörü altında iki ayrı dosya olarak kaydedilir: Son epoch 'ta eğitilen model (ckpt_last.pth) ve doğrulama performansı en yüksek olan model (ckpt_best_XX.pth). Burada ckpt_best_44.pth gibi adlandırılan dosya, modelin en iyi sonuç verdiği epoch 'a karşılık gelir ve test veya gerçek uygulamalarda tercih edilmesi gereken ağırlık dosyasıdır. Bu yapı, eğitim sürecinin izlenebilirliğini ve geriye dönük analizleri kolaylaştırmak amacıyla uygulanmıştır.

9. AIORCOM-TEXTILEAD GLASS CANLI ORTAM TESTİ

GLASS modelinin yalnızca eğitim ve test veri setleri üzerinde değil, aynı zamanda gerçek zamanlı üretim ortamlarında da kullanılabilirliğini gösterebilmek amacıyla, modelin eğitilmiş ağırlıklarıyla çalışacak özel bir canlı çıkarım sistemi geliştirilmiştir. Bu sistem, kullanıcıdan kamera aracılığıyla anlık olarak alınan görüntüleri doğrudan modele aktararak, ilgili segmentasyon maskelerini üretmekte ve sonuçları hem görsel olarak kullanıcıya sunmakta hem de disk ortamına kaydetmektedir. Sistem tasarımı, PyTorch tabanlı bir modelin GUI[96] aracılığıyla bütünleşmiş çalışmasını gerektirdiğinden, gerçek zamanlı görüntü işleme, donanım seçimi (CPU/GPU/kuantize), eşik tabanlı karar verme ve görsel notasyon gibi çok katmanlı süreçlerin eşgüdüm içinde yönetilmesini zorunlu kılmıştır. Kamera seçimi, çözünürlük ayarları, görüntü ön işleme adımları ve inference optimizasyonları da sistemin başarımı üzerinde belirleyici olmuştur.


Bu canlı çalışabilir sistemin geliştirilmesi, tez sürecinde en fazla zaman ve emek gerektiren adımlardan biridir. Özellikle GLASS mimarisinin modüler yapısı ve CUDA destekli donanımların yüksek hesaplama kapasitesi, gerçek zamanlı uygulama açısından avantaj sağlasa da bu avantajlardan etkin biçimde yararlanabilmek için modelin kod düzeyinde yeniden yapılandırılması ve grafik arayüzle bütünleştirilmesi gerekmiştir. Oluşturulan `calistir_gui.py` adlı bu özel betik, kullanıcıya hem canlı analiz hem de manuel görüntü yakalama imkânı sunmakta; elde edilen segmentasyon çıktıları üzerine etiket ve skor bindirmeleri yaparak son kullanıcıya açık ve yorumlanabilir bir çıktı sağlamaktadır. Böylece GLASS modeli, sadece teorik doğruluk metrikleriyle değil, aynı zamanda pratik uygulanabilirlik açısından da üretim sahasında kullanılabilir bir teknoloji olduğunu kanıtlamıştır.

9.1 GLASS Modeli Inference Kodu Oluşturulması

GLASS modelinin canlı ortamda kullanılabilmesi için klasik eğitim ve test döngüsünün ötesinde, doğrudan kamera görüntüsünü işleyebilen ve anomali

segmentasyonunu anlık olarak gerçekleştirebilen özel bir çıkarım (inference) kodunun geliştirilmesi gereklidir. Oluşturulan `calistir.py` adlı betik dosyası, hem gerçek zamanlı görüntü akışını alıp modelle bütünleşmiş bir biçimde analiz edebilen hem de kullanıcı arayüzü (GUI) üzerinden interaktif kontrol sağlayan kapsamlı bir uygulamadır. Kod, GLASS modelinin ihtiyaç duyduğu yapılandırma parametrelerini içerir; örneğin giriş görüntüsünün boyutlandırılması, backbone mimarisinin yüklenmesi, model ağırlıklarının `ckpt_best_XX.pth` dosyasından çekilmesi gibi karar mekanizmalarının belirlenmesi bu yapı içinde entegre olarak yürütülmektedir.

Betik, Python programlama dili kullanılarak `tkinter`[97], `OpenCV`, `PyTorch` ve `PIL`[98] gibi kütüphanelerin birlikte çalıştığı bir çatı altında yazılmıştır. Arayüz üzerinden kullanıcı, Fotoğraf Çek ya da Canlı Analiz seçeneklerinden birini kullanarak anlık görüntüleri modelden geçirebilir, segmentasyon sonuçlarını görselleştirilmiş biçimde inceleyebilir ve çıktıları sistem klasörüne kaydedebilir. Modelin çıktı maskesi, belirli bir görünürlük eşiğine göre renklendirilerek orijinal görüntü üzerine bindirilmekte; ayrıca skor bazlı sınıflandırma sonucu (GOOD/ANOMALY) ve inference süresi ya da FPS bilgisi görsel üzerine yazılmaktadır. Sistem, aynı zamanda CPU, GPU ve kuantize modlarda çalışabilme esnekliğine sahip olup; inference cihazı GUI üzerinden değiştirilebilmektedir. Bu kodun geliştirilmesi sırasında segmentasyon doğruluğunun korunması, inference hızının optimize edilmesi ve görsel çıktının kullanıcı açısından anlaşılabilir biçimde sunulması temel öncelikler arasında yer almıştır. Böylece, GLASS modelinin pratik kullanım senaryoları için uygun, ölçeklenebilir ve yeniden yapılandırılabilir bir inference altyapısı elde edilmiştir. Şekil 9.1 'de GLASS Modeli inference ortamında canlı olarak denenen model performansı sonuçları paylaşılmıştır.



Şekil 9.1: GLASS modeli canlı ortam anomali tespiti.

9.2 GLASS Modeli Canlı Ortam Sonuçları

Geliştirilen canlı çıkarım sistemi, farklı donanım yapılandırmaları üzerinde test edilerek modelin gerçek zamanlı performansı değerlendirilmiştir. GLASS modeli, NVIDIA RTX 5080 ekran kartı ile donatılmış bir sistemde çalıştırıldığında, ortalama olarak 15 kare/saniye (FPS) hızında çalışarak yüksek çözünürlüklü görüntüler üzerinde kesintisiz segmentasyon sağlayabilmektedir. Bu performans seviyesi, modelin üretim hattı benzeri dinamik ortamlarda gecikme olmaksızın karar verebilmesini mümkün kılmakta ve sistemin gerçek zamanlı analiz koşullarına uygunluğunu ortaya koymaktadır.

Buna karşılık olarak, aynı modelin Intel Ultra 9 işlemciye sahip ancak GPU desteği olmayan bir sistemde çalıştırılması halinde, ortalama 8 FPS düzeyinde bir işlem hızı elde edilmiştir. Bu değer, GPU ile elde edilen performansın yaklaşık yarısına karşılık gelse de düşük sistem kaynaklarıyla dahi modelin çevrim içi olarak kullanılabilirliğini göstermektedir. Her iki sistemde de segmentasyon doğruluğu korunmuş, yalnızca işlem süresinde farklılık gözlemlenmiştir. Elde edilen bu sonuçlar, GLASS modelinin hem yüksek performanslı GPU sistemlerinde hem de optimize edilmiş CPU altyapılarında canlı ortamda başarıyla uygulanabileceğini ortaya koymuştur.

10. GÖMÜLÜ SİSTEM UYGULAMALARI VE RASPBERRY PI 5 TESTİ

Tezin bu bölümünde, AIORCOM-TextileAD veri seti üzerinde eğitilmiş derin öğrenme modellerinin gömülü sistem ortamlarında ve özellikle Raspberry Pi 5 platformunda çalışma performansları detaylı biçimde değerlendirilmiştir. Endüstriyel kalite kontrol uygulamalarında gerçek zamanlı ve düşük kaynak tüketimi gerektiren senaryolara yönelik olarak, modellerin gömülü sistemlerdeki performansının incelenmesi büyük önem taşımaktadır.

Bu kapsamda seçilen Raspberry Pi 5 platformu, kompakt yapısı, düşük güç tüketimi ve nispeten yüksek işlem gücüyle gömülü uygulamalar için ideal bir ortam sağlamaktadır. Modellerin Raspberry Pi 5 üzerinde çalıştırılabilmesi için öncelikle optimizasyon ve adaptasyon süreçleri gerçekleştirilmiştir. Bu süreçlerde model boyutunun küçültülmesi, işlem hızının artırılması ve bellek tüketiminin minimize edilmesi hedeflenmiştir.

Modellerin Raspberry Pi 5 üzerinde kurulum ve çalıştırma süreçleri detaylı olarak anlatılmış, kamera entegrasyonu ve gerçek zamanlı görüntü işleme performansları analiz edilmiştir. Bu analizler sırasında, özellikle Logitech Brio 4K kameranın Raspberry Pi 5 ile uyumu test edilmiş ve kameradan alınan görüntüler üzerinde anlık anomali tespiti gerçekleştirilmiştir.

Performans değerlendirmesi sırasında görüntü işleme hızları (FPS), modellerin doğru sınıflandırma ve piksel bazlı segmentasyon yetenekleri ölçülmüş, elde edilen sonuçlar masaüstü platformundaki performanslarıyla karşılaştırılmıştır. Bu süreçte Raspberry Pi 5 platformunda model performanslarının, gömülü sistemlerin gerçek zamanlı ihtiyaçlarını ne ölçüde karşılayabildiği analiz edilmiştir.

Son bölümde, Raspberry Pi 5 üzerindeki testlerde ortaya çıkan bulgulara dayanarak, modellerin endüstriyel uygulamalarda kullanım potansiyelleri değerlendirilmiş ve gelecekte gerçekleştirilebilecek iyileştirme çalışmaları için öneriler sunulmuştur. Böylece, tez çalışmasının gömülü sistemlerde gerçekleşmesi ve endüstriyel alanda uygulanabilirliği detaylı biçimde ortaya konmuştur.

10.1 Raspberry Pi 5 Donanım Yapısı ve Kamera Kullanımı

Raspberry Pi 5, önceki nesillere kıyasla önemli donanımsal iyileştirmeler sunarak yapay zekâ ve görüntü işleme uygulamaları için daha elverişli bir platform haline gelmiştir. Şekil 10.1 'de denemelerde kullanılan Raspberry 5 bileşeni gösterilmiştir.

64-bit dört çekirdekli ARM Cortex-A76 mimarili işlemcisi, artırılmış saat frekansı ve gelişmiş önbellek yapısı sayesinde daha yüksek hesaplama performansı sağlamaktadır. Donanım hızlandırılmalı grafik birimi (VideoCore VII GPU), görüntü işleme ve görsel çıktı işlemlerinde daha etkin kullanım sunarken, LPDDR4X bellek modülü ile bellek erişim hızları da ciddi şekilde iyileştirilmiştir. PCIe 2.0 desteğiyle donanım genişletilebilirliği artmış, USB 3.0 portları ve yüksek hızlı GPIO pinleri sayesinde dış çevre birimleriyle iletişim daha stabil ve hızlı hale gelmiştir. Bu yapıyla Raspberry Pi 5, düşük güç tüketimiyle birlikte sınırlı kaynaklara rağmen oldukça yüksek performanslı yapay zekâ uygulamalarına olanak tanımaktadır.

Raspberry Pi 5 üzerinde kamera kullanımı, özellikle CSI-2 arayüzü üzerinden bağlanan resmi Raspberry Pi kameraları ile oldukça optimize edilmiştir. Yeni nesil RP1 I/O kontrolcüsü sayesinde kamera veri akışı daha verimli bir şekilde işlenebilmekte, bu da gerçek zamanlı görüntü işleme ve anomali tespiti gibi uygulamalarda gecikmeleri azaltmaktadır. Şekil 10.2 'de Raspberry 5 ile yayımlanan Camera Module 3 geniş aç kamera gösterilmiştir. Logitech Brio 4K kamera ile



Şekil 10.1: Raspberry 5 gömülü sistem modülü.



Şekil 10.2: Raspberry Camera Module 3 geniş açılı kamera.

eğitilmiş modellerde verdiği performans olumsuzdur. Eğitim kamerası ve test kamerasının aynı kamera olması gerektiği denemelerde görülmüştür.

Ayrıca, Raspberry Pi OS ve libcamera[99] gibi açık kaynaklı yazılım araçlarıyla birlikte, kullanıcılar kameranın çözünürlüğünü, kare hızını ve otomatik odaklama gibi özelliklerini kolaylıkla kontrol edebilmektedir. Raspberry Pi 5 ile kullanılan yüksek çözünürlüklü kameralarda, düşük ışık koşullarında dahi yüksek kaliteli görüntüler elde edilebilmekte, bu da özellikle endüstriyel görsel denetim gibi görevlerde güvenilirliği artırmaktadır.

10.1.1 Raspberry Pi 5 teknik özellikleri ve donanım seçimi

Raspberry Pi 5'in 16 GB RAM kapasitesine sahip versiyonu, önceki modellere kıyasla önemli bir bellek artışı sunarak görüntü işleme ve derin öğrenme gibi bellek yoğunluklu uygulamalar için daha elverişli bir ortam sağlamaktadır. Dört çekirdekli ARM Cortex-A76 işlemcisi 2.4 GHz saat hızında çalışmakta olup, LPDDR4X-4267 bellek mimarisi sayesinde bant genişliği optimize edilmiştir. Bu donanım, segmentasyon tabanlı anomali tespiti gibi görevlerde teorik olarak daha yüksek performans beklentisi oluştursa da yapılan testlerde 8 GB versiyonuna kıyasla anlamlı bir hız artışı gözlemlenmemiştir; sistem yalnızca 1 FPS hızında çalışabilmiştir. PCIe 2.0 desteği ile harici NVMe depolama birimlerinin veya genişletici kartların entegre edilebilmesi, USB 3.0 portları ile yüksek veri aktarımının sağlanabilmesi, ayrıca GPIO üzerinden aktif soğutma ve kamera modülü gibi çevresel bileşenlerin bağlanabilmesi, cihazı hem deneysel hem de

uygulama odaklı geliştirme ortamları için uygun hale getirmektedir. Ancak, mevcut konfigürasyonda bellek artışının işlem süresine doğrudan katkı sağlamadığı, performans darboğazının daha çok işlemci mimarisi ve yazılım optimizasyonlarıyla ilişkili olduğu görülmüştür.

10.1.2 Raspberry Pi 5 ortamında Logitech Brio 4K yapılandırması

Raspberry Pi 5 ile Logitech Brio 4K kamera entegrasyonu oldukça kolaydır. Neredeyse tak çalıştır mantığı ile oluşturulan ortamlarda kamera rahatlıkla kullanılabilir. Logitech Brio, USB 3.0 arayüzü üzerinden doğrudan bağlanarak 4K çözünürlüğe kadar yüksek kaliteli ve detaylı görseller sağlayabilmektedir. Raspberry Pi 5'in USB 3.0 portları bu tür geniş bant veri akışlarını kesintisiz destekleyebilecek şekilde tasarlanmıştır. Kamera, UVC (USB Video Class) standardını desteklediği için Raspberry Pi OS üzerinde ek sürücü yüklemesine gerek kalmadan v4l2 (Video4Linux2) altyapısıyla otomatik olarak tanınır. Libcamera, OpenCV ve ffmpeg[100] gibi popüler görüntü işleme kütüphaneleriyle tam uyumlu çalışması, yapay zekâ temelli uygulamaların entegrasyonunu kolaylaştırmaktadır.


Yapılandırma aşamasında v4l2-ctl aracı kullanılarak çözünürlük, kare hızı ve odaklama parametreleri manuel olarak özelleştirilebilmektedir. Özellikle otomatik odaklamanın devre dışı bırakılması, sabit mesafeden yapılan endüstriyel görüntüleme uygulamalarında daha kararlı ve tutarlı veri elde edilmesini sağlar. Kamera, MJPEG ve H.264 gibi donanımsal sıkıştırma formatlarını desteklediği için işlemci üzerindeki yük azaltılabilir, bu da özellikle kaynak kısıtlı gömülü sistemlerde önemli bir avantaj sunar. Cv2.VideoCapture arayüzüyle Python ortamında doğrudan kare bazlı veri alımı gerçekleştirilebilmekte; bu kareler üzerinde gerçek zamanlı anomali segmentasyonu ve sınıflandırma işlemleri uygulanabilmektedir. Bu yapılandırma, taşınabilirliği, düşük maliyeti ve entegrasyon kolaylığı sayesinde, gömülü sistemlerde endüstriyel kalite kontrol çözümleri için etkili bir temel oluşturmaktadır.

10.2 Raspberry Pi 5 GLASS Modelinin Çalıştırılması

Raspberry Pi 5 üzerinde GLASS modelinin çalıştırılmasına yönelik geliştirilen arayüz uygulaması, gerçek zamanlı görüntü akışı üzerinden anomali tespiti

gerçekleştirebilen, kullanıcı etkileşimli bir grafik arayüz sunmaktadır. Python programlama dili ile geliştirilen bu sistem, tkinter kütüphanesi kullanılarak masaüstü GUI formunda tasarlanmıştır; OpenCV, Pillow ve PyTorch gibi kütüphaneler aracılığıyla görüntü yakalama, ön işleme, model yükleme ve sonuç görselleştirme işlemleri entegre edilmiştir. Uygulama, Logitech Brio 4K kamera ile elde edilen görüntüleri USB 3.0 üzerinden alarak belirlenen çözünürlükte işleyebilmekte ve GLASS modeline ait eğitilmiş ağırlıkları yükleyerek, her bir kare için segmentasyon tabanlı anomali analizi yapabilmektedir. Modelin ResNet tabanlı mimarisi, 288x288 çözünürlüklü girişler üzerinden çalışacak şekilde optimize edilmiş ve inference süreci CPU tabanlı olarak yapılandırılmıştır.


Sistem arayüzü, cihaz seçimi (örneğin "Cpu", "Gpu-quantized"), odak kontrolü, canlı analiz başlatma ve manuel görüntü yakalama gibi etkileşimli kontrollerle donatılmıştır. Görüntü üzerindeki anomaliler, renkli ısı haritası ve metin etiketleme (GOOD / ANOMALY) yoluyla anlık olarak kullanıcıya sunulmakta; istenirse giriş ve çıkış görselleri disk ortamına kaydedilmektedir. Testlerde, 16 GB belleğe sahip Raspberry Pi 5 cihazında yalnızca CPU üzerinde yapılan çalıştırmalarda modelin ortalama 1 FPS hızında çalıştığı tespit edilmiş olup, bu durum düşük güç tüketimli cihazlarda gerçek zamanlılığa yakın ancak sınırlı hızda çalışan derin öğrenme temelli bir segmentasyon sisteminin elde edilmesini mümkün kılmıştır. Bu yapılandırma, modelin gömülü sistemlerdeki uygulanabilirliğini göstermesi açısından önemli bir örnek teşkil etmektedir. Şekil 10.4 'de eğitilen GLASS modelinin Raspberry 5 16 GB gömülü sistemi ile çalıştırılması anında canlı görüntüsü gösterilmiştir. Şekil 10.3 'de ise gölge oluşturmayan ve sağlam ve ayarlanabilir yapısıyla tüm deneme sürecinde sorunları çözmeye yardımcı olmuş olan tripod ve anlık olarak canlı ortamda veri setimizde bulunan bir anomalinin canlı ortamda tespit edilmesi gösterilmiştir. Şekil 10.5 'de, tüm hazırlık, eğitim, performans değerlendirme, ilk eleme, ikinci eleme ve sonraki denemeler sonucunda elde edilen modelin, Raspberry Pi 5 (16 GB) üzerinde çalışan gömülü sistem uygulamasındaki gerçek zamanlı çıktısı gösterilmektedir.



Şekil 10.4: GLASS modelinin Raspberry 5 ile çalıştırılması.



Şekil 10.3: Tripod Logitech kamera ve Raspberry 5 ile canlı sistem.



Şekil 10.5: Raspberry 5 canlı deneme görüntüsü.

10.2.1 Raspberry Pi 5 ortamında çıkarım süreleri

GLASS modelinin Raspberry Pi 5 üzerinde çalıştırılmasıyla elde edilen ölçümler, cihazın yalnızca CPU kaynaklarını kullanarak yüksek çözünürlüklü görüntüler üzerinde gerçek zamanlı çıkarım yapma konusunda önemli sınırlamalara sahip olduğunu göstermektedir. Yapılan testlerde, 288×288 piksel boyutundaki giriş görüntüleri için ortalama çıkarım süresi 900 ila 1100 milisaniye arasında değişmiş ve bu da yaklaşık 1 FPS (değerine karşılık gelmiştir). Elde edilen bu değer, anlık karar vermeyi gerektiren uygulamalar için yeterli olmamakla birlikte, Raspberry Pi 5 gibi sınırlı donanım kaynaklarına sahip sistemlerde modelin bütünsel işlevselliğini koruyarak çalışabildiğini ortaya koymaktadır. Ayrıca çıkarım süresine, maskeleye, segmentasyon sonrası görselleştirme ve diğer ön işleme adımları da dahil edildiğinde, toplam işlem süresi daha da artmakta ve sistemin yanıt verme süresi gecikmeli hâle gelmektedir.

Bu performans sınırlılıklarını aşmak adına çeşitli optimizasyon stratejileri incelenmiş ve modelin hesaplama yükünü azaltmaya yönelik yöntemler değerlendirilmiştir. Ancak yapılan denemelerde, sadece CPU mimarisi üzerinde

çalışan sistemde bu stratejilerin etkisi sınırlı kalmış; paralel işlem kapasitesinin düşüklüğü nedeniyle saniyede işlenebilen kare sayısı anlamlı ölçüde artırılamamıştır. Bu durum, gerçek zamanlılık gerektiren uygulamalarda ek donanımsal hızlandırıcılar (örneğin yerleşik GPU 'lar, NPU 'lar veya harici hızlandırıcı modüller) kullanılmadığı sürece, çıkarımın düşük hız toleransına sahip senaryolarla sınırlı kalacağını göstermektedir. Dolayısıyla, gömülü sistemlerde model doğruluğu ile hesaplama verimliliği arasında dengeli bir yapı kurmak kritik bir gereklilik olarak ortaya çıkmaktadır.

10.2.2 Raspberry Pi 5 ve dizüstü bilgisayar performans karşılaştırılması

Raspberry Pi 5 ile Windows tabanlı yüksek donanımlı bir bilgisayar arasında yapılan karşılaştırmalı performans analizleri, gömülü sistemlerin sınırlarını ve potansiyelini ortaya koymaktadır. GLASS modeli, Windows ortamında RTX 5080 GPU ile ortalama 15 FPS (görüntü/saniye) hızında çalışabilirken, aynı model Raspberry Pi 5'in dört çekirdekli ARM işlemcisi üzerinde ortalama 1 FPS ile çalışmaktadır. Bu fark, özellikle gerçek zamanlılık gereksinimi olan uygulamalarda Windows tabanlı sistemlerin yüksek paralel işlem gücünün avantajlarını gözler önüne sermektedir. Ancak, Raspberry Pi 5'in düşük enerji tüketimi, taşınabilirliği ve gömülü sistemlerde kullanım kolaylığı gibi avantajları, onu kaynak kısıtlı ortamlarda tercih edilebilir kılmaktadır.

Ek olarak, GLASS modeli her iki ortamda da başarılı segmentasyon sonuçları üretmiş, ancak inference süreleri açısından belirgin farklılık göstermiştir. Windows ortamında CUDA destekli GPU kullanımının sağladığı donanım hızlandırma sayesinde, yüksek çözünürlüklü görüntüler üzerinde bile hızlı çıkarsama mümkün olmuştur. Raspberry Pi 5'te ise yalnızca CPU kaynaklarının kullanılması nedeniyle işlem süresi uzamış, ancak model optimizasyonları ve düşük çözünürlüklü veri kullanımı ile bu fark kısmen telafi edilebilmiştir. Bu sonuçlar, endüstriyel uygulamalarda donanım seçiminin kullanım senaryosuna göre dikkatle yapılması gerektiğini ortaya koymaktadır.

10.3 Raspberry Pi 5 Üzerinde Sonuçlar ve İyileştirme Önerileri

Raspberry Pi 5 üzerinde çalıştırılan GLASS modeli, sınırlı donanım kaynaklarına rağmen temel segmentasyon görevlerini başarıyla yerine getirmiştir. Ancak yapılan

testlerde ortalama 1 FPS hızında çalışması, gerçek zamanlı uygulamalar için yetersiz kalmıştır. Ayrıca modelin inference süresinin yüksek olması, kullanıcı etkileşiminde belirgin gecikmelere neden olmuştur. Bu darboğazın temel sebepleri arasında CPU tabanlı işlemenin yüksek yoğunluklu tensör hesaplamalarında yetersiz kalması ve GLASS modelinin oldukça derin ve parametre yoğun bir mimariye sahip olması gösterilebilir. Segmentasyon doğruluğu bakımından tatmin edici sonuçlar elde edilse de yüksek çözünürlüklü görüntülerde anomali haritalarının üretilmesi uzun zaman almakta ve sistem belleği zorlanmaktadır. Aynı zamanda, Raspberry Pi 5’te kullanılan OpenCV tabanlı görüntü işleme işlemleri de CPU’ya ek yük bindirerek genel sistem performansını olumsuz yönde etkilemiştir.


İyileştirme önerileri doğrultusunda ilk adım, GLASS modelinin Raspberry Pi 5 için optimize edilmesidir. Bu kapsamda modelin pruning (budama) ve quantization-aware training (QAT) yöntemleriyle daha hafif hale getirilmesi performans kazancı sağlayacaktır.

10.4 Model Kuantizasyon Sonuçları

GLASS modeli üzerinde Raspberry Pi 5 ortamında gerçekleştirilen Float32 → Int8 kuantizasyon denemeleri sonucunda, bazı örneklerde minimal performans artışı gözlemlenmiş olsa da genel ortalama değerlerde anlamlı bir fark oluşmamıştır. Bu denemelerde, özellikle inference süresi açısından hafif iyileşmeler elde edilse de segmentasyon doğruluğu ve anomali skoru istikrarı açısından kuantize model ile orijinal model arasında önemli bir fark bulunmamıştır.

Bu durum, GLASS modelinin mevcut mimarisinin kuantizasyon sonrası hassasiyet kaybına dirençli olduğunu ancak düşük gecikme ihtiyacı olan sistemlerde bu işlemin tek başına yeterli hız avantajı sağlamadığını göstermektedir.

Şekil 10.6 ’da gösterilen GLASS kuantize model sonuçları incelendiğinde, kuantize modelin orijinal modelle neredeyse aynı seviyede kaldığı gözlemlenmiştir. Bu nedenle, kuantizasyonun performansa etkisinin daha net anlaşılabilmesi için farklı omurga (backbone) mimarileriyle tekrar denemesi önerilmektedir. Özellikle daha küçük ve kuantizasyon dostu mimariler olan MobileNetV2 gibi alternatiflerin GLASS çerçevesine entegre edilerek QAT ile eğitilmesi hem model doğruluğunu



Şekil 10.6: GLASS modeli kuantize model sonuçları.

koruyarak hem de inference süresini azaltarak Raspberry Pi gibi kaynak kısıtlı cihazlarda daha etkili sonuçlar verebilir.

10.4.1 Gömülü sistemde elde edilen sonuçların genel değerlendirilmesi

Raspberry Pi 5 üzerinde gerçekleştirilen GLASS modeli uygulamaları, sınırlı donanımsal kaynaklara rağmen temel anomalilik tespit fonksiyonlarını başarıyla yerine getirmiştir. Ancak elde edilen sonuçlar, modelin mevcut haliyle gömülü sistemler için optimize edilmediğini ve gerçek zamanlılık kriterlerini tam olarak karşılayamadığını ortaya koymaktadır. Ortalama 1 FPS ile çalışan sistem, segmentasyon doğruluğunu büyük ölçüde korusa da kullanıcı deneyimi ve endüstriyel uygulamalarda gerekli olan tepki süresi açısından yetersiz kalmaktadır. Özellikle yüksek çözünürlüklü görüntüler üzerinde yapılan işlemlerde CPU kullanım oranı maksimum seviyeye yaklaşmakta, bu da sistemin uzun süreli stabilitesini ve enerji verimliliğini olumsuz etkilemektedir. Ayrıca, görüntü işleme, segmentasyon, eşikleme ve sonuç bindirme işlemlerinin tamamının aynı işlemci üzerinde yürütülmesi, darboğaz oluşturarak modelin gecikme süresini artırmaktadır.

Sistemin başarıyla çalışması, GLASS modelinin gömülü sistemlere entegre edilebilirliğini göstermesi açısından önemli bir referans niteliğindedir. Kuantizasyon, çözünürlük düşürme ve ön işleme optimizasyonlarıyla sistemin tepkime süresi düşürülmüş, ancak bu işlemlerin etkisi sınırlı kalmıştır. Gömülü sistemin gerçek zamanlı uygulamalar için yeterli hale getirilebilmesi adına, modelin daha hafif mimarilerle yeniden eğitilmesi, quantization-aware training (QAT) gibi gelişmiş tekniklerin uygulanması ve mümkünse donanım hızlandırıcılardan (örneğin Hailo-8, Coral TPU) yararlanılması önerilmektedir.

Mevcut yapı gömülü sistemlerde görsel anomali tespiti uygulamalarının mümkün olduğunu kanıtlamış; ancak üretim ortamına alınmadan önce dikkatli model optimizasyonu ve donanım seçimi yapılması gerektiğini açıkça göstermiştir.

11. DENEY SONUÇLARI VE ANALİZLER

Bu bölümde, tez kapsamında uygulanan GLASS modelinin, üç farklı veri seti üzerindeki genel performansı; doğruluk, çıkarım süresi, parametre verimliliği ve donanımsal uyumluluk gibi temel mühendislik ölçütleri çerçevesinde kapsamlı şekilde analiz edilmiştir. Model, literatürde yaygın olarak kullanılan MVTecAD ve WFDD veri setlerinin yanı sıra, bu çalışma kapsamında özgün olarak geliştirilen AIORCOM-TextileAD veri seti üzerinde de test edilmiştir. AIORCOM-TextileAD, gerçek ortamdaki yüksek çözünürlüklü görüntülerle oluşturulmuş, tekstil yüzeylerine özgü kusurları içeren ve hem segmentasyon maskeleri hem de sınıf etiketleri barındıran yeni bir veri kümesidir. Bu yönüyle, GLASS modelinin hem akademik karşılaştırma senaryolarında hem de endüstriyel gerçeklikleri yansıtan özel veri üzerinde değerlendirilmesi sağlanmıştır.

Yapılan analizler, GLASS modelinin yüksek doğruluk düzeyini düşük parametre sayısı ve kısa çıkarım süresiyle birleştirdiğini göstermiştir. WideResnet50-2 omurgasıyla çalıştırmayı seçtiğimiz model, MVTecAD ve WFDD veri setlerinde yüksek Image-level ve Piksel-level AUROC değerlerine ulaşmış, AIORCOM-TextileAD üzerinde de benzer başarıyı sürdürmüştür. Özellikle AIORCOM-TextileAD veri setinde yapılan testler, modelin gerçek dünyaya yakın koşullarda da yüksek performans sergileyebildiğini ortaya koymuştur. Ayrıca, geliştirilen veri setiyle entegre çalışan bir grafik arayüz aracılığıyla modelin canlı kamera görüntüsü üzerinde gerçek zamanlı testleri gerçekleştirilmiş ve ortalama 15 FPS hız ile istikrarlı segmentasyon çıktıları elde edilmiştir. Sonuçlar, GLASS modelinin uygulama verimliliği ve sistem entegrasyonu bakımından dengeli ve güçlü bir çözüm sunduğunu ortaya koyarken; AIORCOM-TextileAD veri seti ise bu tür modellerin gerçek senaryolarda sınanması için bir kaynak sunmaktadır.

11.1 Model Performanslarının Genel Değerlendirmesi

Tez kapsamında uygulanan GLASS, PatchCore ve FastFlow modelleri, MVTecAD, WFDD ve AIORCOM-TextileAD veri setleri üzerinde gerçekleştirilen

anomali tespiti görevlerinde hem görüntü düzeyinde hem de piksel düzeyinde yüksek doğruluk oranları elde etmiştir. MVTECAD veri seti üzerinde yapılan testlerde, tüm modeller Image-level AUROC açısından %98'in üzerinde başarı göstermiş; ancak segmentasyon doğruluğu açısından GLASS modeli, özellikle piksel düzeyinde elde ettiği yüksek F1 skorları ile öne çıkmıştır. FastFlow modeli, sade mimarisi sayesinde işlem hızı ve parametre verimliliği bakımından avantaj sunarken; PatchCore modeli, bellek-tabanlı yaklaşımı ile genel doğrulukta güçlü sonuçlar üretmiş ancak detaylı segmentasyon görevlerinde bazı sınırlamalar sergilemiştir.

Model karşılaştırmaları doğruluk metrikleriyle sınırlı kalmamış; parametre sayısı, model boyutu, çıkarım süresi ve bellek kullanımı gibi mühendislik ölçütleriyle birlikte değerlendirilmiştir. GLASS modeli, yüksek doğruluk ve güçlü segmentasyon kabiliyeti sunmuştur. Donanım açısından gömülü sistemlerde çalıştırılabilecek düzeyde verimlilik sağlamıştır. FastFlow, düşük parametre sayısı ve düşük bellek tüketimi ile kaynak kısıtlı sistemler için uygun bir seçenek olarak öne çıkmıştır. PatchCore, kararlı sonuçlar üretmesine karşın, yüksek bellek gereksinimi nedeniyle sınırlı donanımlarda verimli çalışmayacağı düşünülmüştür.

11.2 Backbone Mimarilerinin Etkisi ve Kıyaslanması

Derin öğrenme tabanlı anomali tespiti modellerinde kullanılan backbone mimarileri, modelin temsil kapasitesi, segmentasyon doğruluğu ve hesaplama verimliliği üzerinde doğrudan belirleyici rol oynamaktadır. Bu tez kapsamında uygulanan GLASS, FastFlow ve PatchCore modelleri; ResNet18, WideResNet50-2, ResNeXt101 ve WideResNet101 gibi farklı omurga yapılarıyla test edilmiş, her bir mimarinin doğruluk metriklerine ve donanımsal maliyetlere etkisi karşılaştırmalı olarak incelenmiştir. Daha derin ve geniş yapılar, özellikle piksel düzeyindeki AUROC ve F1 skorlarında belirgin bir artış sağlamış; ancak bu artış, daha uzun çıkarım süreleri ve yüksek bellek tüketimi gibi önemli sınırlamaları da beraberinde getirmiştir. Örneğin, WideResNet50-2 mimarisi segmentasyon başarımını artırsa da inference süresinin uzaması nedeniyle gömülü sistemlerde uygulama zorlukları yaratmıştır.

Daha hafif mimariler olan ResNet18 gibi yapılar; düşük parametre sayısı ve küçük model boyutları sayesinde daha hızlı çıkarım süreleri ve düşük bellek gereksinimi

ile çalışmış, bu da özellikle kaynak kısıtlı donanımlarda önemli bir avantaj sunmuştur. Ancak bu mimarilerle yapılan testlerde, küçük ölçekli anomalilerin tespitinde ve segmentasyon detaylarında kısmi doğruluk kayıpları gözlemlenmiştir. Bu nedenle backbone mimarisi seçimi, yalnızca doğruluk odaklı yapılmamalı; aynı zamanda hedef uygulamanın işlem süresi gereksinimleri, bellek kapasitesi ve donanım uyumluluğu gibi pratik kısıtları da dikkate alarak belirlenmelidir. Sonuçlar, yüksek temsil gücüne sahip geniş mimariler ile hız ve verimlilik sunan hafif yapılar arasında uygulama senaryosuna özel bir denge kurulmasının gerekli olduğunu göstermektedir.

11.3 Gömülü Sistemlerde Uygulanabilirlik Analizi

Görüntü tabanlı anomali tespiti modellerinin endüstriyel ortamlarda gerçek zamanlı olarak uygulanabilmesi, yalnızca doğruluk kriterleriyle değil; aynı zamanda hesaplama yükü, bellek tüketimi, model boyutu ve çıkarım süresi gibi mühendislik parametreleriyle de doğrudan ilişkilidir. Bu kapsamda yapılan değerlendirmelerde, GLASS ve FastFlow gibi hafif modellerin, özellikle ResNet18 gibi kompakt omurgalarla kullanıldığında, gömülü sistem ortamlarında çalışma potansiyeli taşıdığı gözlemlenmiştir. Raspberry Pi 5 üzerinde yapılan testlerde, CPU ile çalışan modellerde 1 ve maksimum 1.5 FPS aralığında ortalama hızlar elde edilmiş; bu değer, düşük bant hızına sahip üretim hatları için minimum düzeyde kullanılabilirlik sunmuştur.

Modelin başarılı bir şekilde gömülü ortama aktarılabilmesi için öncelikle boyutunun küçültülmesi, çıkarım süresinin kısaltılması ve bellek kullanımının optimize edilmesi gerekmektedir. Bu doğrultuda uygulanan yeniden boyutlandırma, sadeleştirilmiş backbone mimarileri ve verimli tensör işleme stratejileri, Raspberry Pi gibi düşük güçlü cihazlarda temel düzeyde anomali tespiti uygulamalarının mümkün olduğunu göstermiştir. Ancak gerçek zamanlılık ve yüksek doğruluk gerektiren üretim hatlarında, donanımsal hızlandırma (örneğin GPU veya AI modülleri) desteği olmadan performansın yetersiz kalabileceği açıktır. Bu nedenle, gömülü sistemlerde uygulanabilirlik analizi, yalnızca modelin doğruluk skorlarına değil, aynı zamanda donanım uygulama uyumuna ve enerji verim / dengesine göre yapılmalıdır.

12. TARTIŞMA

Bu bölümde, tez kapsamında elde edilen deneysel bulgular çok yönlü olarak değerlendirilmiştir. Modellerin başarımı, yalnızca metrik doğruluk açısından değil; aynı zamanda mühendislik ölçütleri ve saha uygulamaları bağlamında da karşılaştırılmıştır. Kullanılan üç farklı veri seti MVTecAD, WFDD ve AIORCOM-TextileAD sayesinde, modellerin çeşitli yüzey dokuları ve anomali türleri karşısındaki davranışları ayrıntılı biçimde incelenmiştir. Bu sayede, her bir modelin sınıflandırma performansının yanı sıra segmentasyon hassasiyeti, çıkarım süresi, bellek kullanımı ve donanım uyumluluğu gibi yönleriyle güçlü ve sınırlayıcı tarafları belirlenmiştir.

Model değerlendirmelerinde standart metrik değerler tek başına yeterli bulunmamış kaynak verimliliği, işlem hızı ve sistem entegrasyon kolaylığı gibi uygulamaya dönük gereksinimler de dikkate alınmıştır. Teorik başarı gösteren gerçek zamanlı üretim ortamlarında istikrarlı çalışabilecek çözümler geliştiren modellerin önemi vurgulanmıştır.

12.1 Deney Sonuçlarının Yorumlanması

Üretimde görüntü tabanlı anomali tespiti ve derin öğrenme modellerinin tekstil verisi üzerinde analizi ile gömülü sistem uygulaması başlığı altında yürütülen bu çalışmada, model seçimi, ortam kurulumu, donanım uyumluluğu ve performans ölçümleri aşamalarında çeşitli deneyimler edinilmiştir. Süreç, literatür taraması ile başlamış ve Anomalib kütüphanesi temel alınarak modellenmiştir. Bu çerçevede farklı mimarilerle geliştirilen pek çok model test edilmiş, bazıları başarıyla çalıştırılmış, bazıları ise donanım sınırlamaları nedeniyle devreye alınamamıştır. Değerlendirme sürecinde yalnızca performans metrikleri değil, mühendislik koşulları da karar ölçütü olarak ele alınmıştır.

MVTecAD veri setinde yürütülen ilk testler, GLASS modelinin geniş yapılı omurgalarla yüksek sınıflandırma ve segmentasyon başarımı sağladığını ortaya koymuştur. Örneğin, WideResnet50-2 ile Image AUROC 0,99, Image F1 0,90,

Piksel AUROC 0,99, Piksel F1 ise 0,99 olarak ölçülmüştür. Daha hafif bir mimari olan Resnet18 ile elde edilen skorlar Image düzeyinde benzer düzeyde kalmış, ancak Piksel F1 değeri 0,66 seviyesinde gerçekleşmiştir. PatchCore modeli Image AUROC açısından güçlü sonuçlar vermiş olsa da Piksel F1 skorları 0,5760 ile 0,6080 aralığında sınırlı kalmıştır. EfficientAD modeli Piksel f1 açısından 0,8934 değeriyle dikkat çekmiş, ancak diğer metriklerde belirgin gerileme göstermiştir.

En başarılı üç modelin ResNet18 omurgasıyla yeniden test edilmesiyle WFDD veri seti üzerinde ek ölçümler gerçekleştirilmiştir. Bu deneylerde GLASS modeli Image AUROC 0,99, Image F1 0,99, Piksel AUROC 0,99 ve Piksel F1 0,82 değerlerine ulaşmıştır. PatchCore Image AUROC 0,9984 ve Piksel F1 0,4329 ile daha dengesiz bir çıktı üretmiş, FastFlow ise Image AUROC 1,00 gibi teorik olarak mükemmel yakın bir değer sunmasına karşın Piksel F1 0,4270 düzeyinde kalmıştır. Bu sonuçlar, sınıflandırma metriklerinin yeterli bir değerlendirme ölçütü olmadığını, özellikle segmentasyon kalitesi için ayrı analizler yapılması gerektiğini göstermiştir.

WFDD testlerinden sonra, uygulama açısından en dengeli sonuçları üreten GLASS modeli WideResnet50-2 omurgasıyla seçilmiş ve AIORCOM-TextileAD veri seti üzerinde uygulanmıştır. Bu testlerde GPU ile ortalama 15 FPS, CPU ile ise 8 FPS işlem hızı elde edilmiştir. Model aynı zamanda Raspberry pi 5 cihazlarında da değerlendirilmiş, burada yaklaşık 1 FPS hızında çalışmıştır. Float32'den Int8'e dönüştürme teorik olarak performans artışı vadetse de bu yapı için belirgin bir kazanç sağlanmamıştır. Ayrıca, Raspberry pi 5'te 8 Gb ve 16 Gb ram farkı da pratikte anlamlı bir hız avantajı üretmemiştir.

13. SONUÇLAR

Bu tez çalışmasında, görüntü tabanlı anomali tespiti alanında son yıllarda öne çıkan derin öğrenme tabanlı yöntemler, özellikle tekstil endüstrisindeki yüzey kusurlarının tespiti amacıyla kapsamlı biçimde değerlendirilmiştir. Çalışmada literatürde yaygın olarak kullanılan MVTec AD ve WFDD gibi standart veri setleriyle sınırlı kalınmamış; gerçek üretim hattından elde edilen görsellerle oluşturulan ve sektöre özel anomalileri içeren AIORCOM-TextileAD veri seti oluşturularak özgün bir karşılaştırma yapılmıştır. GLASS, PatchCore ve FastFlow modelleri esas alınarak yürütülen deneylerde, modellerin sınıflandırma (Image-level) ve segmentasyon (Piksel-level) başarımı AUROC hem de F1 skorları temelinde ölçülmüştür. Ayrıca model boyutu, parametre sayısı, çıkarım süresi ve bellek kullanımı gibi mühendislik ölçütleri analiz edilmiştir.

Elde edilen sonuçlar, model başarımının doğruluk metrikleriyle değerlendirilmesinin yetersiz olduğunu; pratik uygulamalarda hız, kaynak verimliliği, donanım uyumluluğu ve entegrasyon kolaylığı gibi çok boyutlu faktörlerin göz önünde bulundurulması gerektiğini ortaya koymuştur.

GLASS modeli, zayıf anomalilerin segmentasyonundaki başarısı ve sentetik veri üretim stratejisiyle genel performans açısından öne çıkmıştır. PatchCore modeli görüntü düzeyinde yüksek doğruluk sağlamasına rağmen yüksek bellek tüketimi ve uzun çıkarım süreleri ile sınırlayıcı bir profil çizmiştir. FastFlow modeli düşük parametre sayısı ve hızlı çıkarım yeteneği sayesinde gömülü sistemler için önemli bir aday olarak değerlendirilmiştir. Endüstriyel uygulamalarda model seçimi performans metriklerinin yanında sistem gereksinimlerine, işlem kapasitesine, hata çeşitliliğine ve uygulama ortamına uyum düzeyine göre çok yönlü olarak yapılması gerektiği ortaya konmuştur.

13.1 Çalışmanın Genel Değerlendirmesi ve Katkıları

Bu tez çalışması, görüntü tabanlı anomali tespiti alanında derin öğrenme modellerinin tekstil sektörüne uygulanabilirliğini çok yönlü olarak değerlendirmiş

ve bu alana hem akademik hem de pratik düzeyde anlamlı katkılar sunmuştur. Standart veri setlerine ek olarak, gerçek üretim ortamından elde edilen örneklerle oluşturulan özgün AIORCOM-TextileAD veri seti sayesinde modellerin sahaya yakın koşullarda test edilmesi mümkün olmuş; böylece akademik başarımlar ile endüstriyel gereksinimler arasındaki farklar somut biçimde ortaya konmuştur. GLASS, PatchCore ve FastFlow modelleri doğruluk, hız, bellek kullanımı ve mimari verimlilik açısından kapsamlı şekilde karşılaştırılmış; model seçiminin yalnızca istatistiksel metriklere değil, aynı zamanda uygulama bağlamına ve sistem kısıtlarına göre yapılması gerektiği vurgulanmıştır. Elde edilen bulgular, özellikle GLASS modelinin zayıf anomalilere karşı yüksek hassasiyeti ve sınırlı veri ile genelleme kabiliyeti sayesinde öne çıktığını göstermiş; bu da çalışmanın hem özgün veri katkısı hem de metodolojik derinliği bakımından alana değerli bir katkı sunduğunu teyit etmiştir.

13.2 GLASS Modelinin Üstünlüğü ve Gömülü Sistem Uygulamaları

GLASS modeli, bu çalışma kapsamında yapılan deneylerde özellikle zayıf ve düşük kontrastlı anomalilerin segmentasyonunda sağladığı yüksek hassasiyet ile dikkat çekmiş; sentetik anomali üretimine dayalı genelleme yeteneği sayesinde, sınırlı etiketli veri koşullarında dahi güçlü performans sergilemiştir. Diğer modellere kıyasla daha dengeli bir doğruluk-hız-maliyet profili sunan GLASS, hem akademik doğruluk metriklerinde başarılı sonuçlar elde etmiş hem de hesaplama verimliliği açısından gömülü sistem uygulamaları için umut vadeden bir mimari ortaya koymuştur. Özellikle modelin özelleştirilebilir yapısı ve düşük parametre gereksinimi, gerçek zamanlı izleme sistemleri, üretim hattı entegrasyonları ve kaynak kısıtlı platformlarda (örneğin Raspberry Pi 5 gibi donanımlarda) uygulanabilirliğini artırmakta; böylece yalnızca araştırma ortamlarında değil, pratik endüstriyel senaryolarda da doğrudan kullanılabilir hale gelmesini sağlamaktadır.

14. GELECEK ÇALIŞMALAR

Bu tez çalışmasında, görüntü tabanlı anomali tespiti amacıyla GLASS modeli tercih edilmiş ve Anomalib çatısı altındaki birçok güncel modelle yapılan karşılaştırmalarda üstün başarı göstermiştir. Başlangıçta MVTecAD veri seti ile yapılan deneyler, ardından WFDD veri seti ile sürdürülen testler, GLASS modelinin hem sınıflandırma hem de segmentasyon düzeyinde yüksek doğruluk sağladığını ortaya koymuştur. Akademik metriklerin yanı sıra, karşılaştırma sonuçları da bu başarıyı desteklemektedir. Bu doğrultuda, modelin nihai performansını artırmak amacıyla yapılan ayrıntılı deneylerde genişletilmiş mimari yapıya sahip WideResnet50-2 omurgası tercih edilmiştir. Bu omurga, masaüstü sistemlerde (GPU destekli) oldukça yüksek doğruluk ve kararlılık sergilemiş; ancak Raspberry Pi 5 gibi kaynak kısıtlı gömülü sistemlerde, özellikle çıkarım süresi açısından yetersiz kalmıştır.

Bu durum, GLASS modelinin gömülü sistemlerde uygulanabilirliğini artırmak için daha hafif omurgalarla eğitilmesini gerekli kılmaktadır. Raspberry Pi 5 üzerinde kullanılan Hailo-8 AI Hat modülü, referans demo basit modellerde etkileyici performans göstermesine rağmen, GLASS modeli için yapılan dönüştürme girişimlerinde istenen sonuçlara ulaşamamıştır.

Geliştirici erişimleri sağlanmasına ve farklı yapılandırmalarla çok sayıda deneme yapılmasına rağmen, ONNX formatına dönüştürülen modellerin Hailo derleyici tarafından doğru şekilde optimize edilemediği gözlemlenmiştir. Gelecek çalışmalarda, Hailo platformunun yazılım güncellemeleriyle birlikte bu dönüşüm süreçlerine odaklanılması, modelin taşınabilirliğini ve uygulama alanlarını genişletme açısından önemli bir adım olacaktır.

Yapılan testler, Raspberry Pi 5 + Hailo-8 AI Hat kombinasyonunun teorik olarak 18 FPS 'e kadar çıkarım gerçekleştirme kapasitesine sahip olduğunu, ancak mevcut durumda anomalileri doğru şekilde tespit edemediğini göstermiştir. Bu nedenle, model mimarisinin donanıma uygun biçimde sadeleştirilmesi ve dönüştürme süreçlerinin iyileştirilmesi, sistemin endüstriyel düzeyde kullanılabilirliği açısından kritik önemdedir.

KAYNAKLAR

- [1] **INTEL Corporation** <https://www.intel.com/content/www/us/en/company-overview/company-overview.html>, erişim tarihi 30.06.2025.
- [2] **Anomalib Documentation** <https://anomalib.readthedocs.io/en/v2.0.0/>, erişim tarihi 21.06.2025.
- [3] **PatchCore**
<<https://anomalib.readthedocs.io/en/v2.0.0/markdown/guides/reference/models/image/patchcore.html>>, erişim tarihi 21.06.2025.
- [4] **Roth, K., Pemula, L., Zepeda, J., Scholkopf, B., Brox, T., Gehler, P.** (2021). PatchCore: Towards Total Recall in Industrial Anomaly Detection. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 2022-June, 14298–14308. doi:10.1109/CVPR52688.2022.01392.
- [5] **FastFlow**
<https://anomalib.readthedocs.io/en/v2.0.0/markdown/guides/reference/models/image/fastflow.html>, erişim tarihi 21.06.2025.
- [6] **Yu, J., Kim, Y., Park, S., Yu, H., Paik, J., Kim, J.** (2021). FastFlow: Unsupervised Anomaly Detection and Localization via 2D Normalizing Flows. Erişim: 21 Haziran 2025, *arXiv preprint*, [Çevrim içi]. Available: <https://arxiv.org/abs/2111.07677v2>
- [7] **EfficientAD**
https://anomalib.readthedocs.io/en/v2.0.0/markdown/guides/reference/models/image/efficient_ad.html, erişim tarihi 21.06.2025.
- [8] **Batzner, K., Heckler, L., König, R.** (2025). EfficientAD: Accurate Visual Anomaly Detection at Millisecond-Level Latencies. Şubat
- [9] **GLASS** <<https://github.com/cqylunlun/GLASS>>, erişim tarihi 21.06.2025.
- [10] **Chen, Q., Luo, H., Lv, C., Zhang, Z.** (2024). GLASS: A Unified Anomaly Synthesis Strategy with Gradient Ascent for Industrial Anomaly Detection and Localization. Temmuz. doi: 10.1007/978-3-031-72855-6_3.
- [11] **Resnet18** <<http://image-net.org/challenges/LSVRC/2015/>>, erişim tarihi 21.06.2025.
- [12] **Torchvision**
https://docs.pytorch.org/vision/main/models/generated/torchvision.models.wide_resnet50_2.html, erişim tarihi 22.06.2025.
- [13] **Zagoruyko, S., Komodakis, N.** (2017). Wide Residual Networks. Haziran.
- [14] **Resnet 101** <<http://image-net.org/challenges/LSVRC/2015/>>, erişim tarihi 21.06.2025.
- [15] **MVTecAD** <<https://www.mi.imati.cnr.it/ettore/NanoTWICE/>>, erişim tarihi 21.06.2025.
- [16] **Bergmann, P., Batzner, K., Fauser, M., Sattlegger, D., Steger, C.** (2021). The MVTec Anomaly Detection Dataset: A Comprehensive Real-World Dataset for Unsupervised Anomaly Detection. *International*

- Journal of Computer Vision*, 129, 1038–1059. Ocak. doi: 10.1007/s11263-020-01400-4.
- [17] **WFDD** <<https://github.com/cqylunlun/GLASS>>, erişim tarihi 21.06.2025.
- [18] **Logitech BRIO** <<https://www.logitech.com/tr-tr/products/webcams/brio-4k-hdr-webcam.960-001746.html>>, erişim tarihi 21.06.2025.
- [19] **Raspberry** <<https://www.raspberrypi.com>>, erişim tarihi 22.06.2025.
- [20] **GeForce RTX 5080** <https://www.nvidia.com/tr-tr/geforce/graphics-cards/50-series/rtx-5080/>, erişim tarihi 21.06.2025.
- [21] **Intel® Core™ Ultra 9 Processor 185H** <<https://www.intel.com/content/www/us/en/products/sku/236849/intel-core-ultra-9-processor-185h-24m-cache-up-to-5-10-ghz/specifications.html>>, erişim tarihi 21.06.2025.
- [22] **Raspberry Pi 5** <<https://www.raspberrypi.com/products/raspberry-pi-5/>>, erişim tarihi 21.06.2025.
- [23] **Scopus** <<https://www.scopus.com/home.uri>>, erişim tarihi 21.06.2025.
- [24] Y. Shafranovich, ‘Common Format and MIME Type for Comma-Separated Values (CSV) Files’. Accessed: Jun. 30, 2025. [Online]. Available: <https://datatracker.ietf.org/doc/html/rfc4180>
- [25] **Excel** <<https://www.microsoft.com/tr-tr/microsoft-365/excel>>, erişim tarihi 29.06.2025.
- [26] **What is Scopus Preview?** <https://service.elsevier.com/app/answers/detail/a_id/15534/supporthub/scopus/#tips>, erişim tarihi 21.06.2025.
- [27] **TÜBİTAK**, <www.tubitak.gov.tr/1511>, erişim tarihi 21.06.2025.
- [28] **Savunma Sanayii Başkanlığı** (2024). Rapor: Geleceğin Harekât Ortamını Şekillendirecek Teknolojiler (GHOST) Raporu (Tasnif Dışı).
- [29] **Torre, V., Poggio, T. A.** (1986). On Edge Detection. Mart.
- [30] **Li, H., Xu, K.** (2025). Innovative adaptive edge detection for noisy images using wavelet and Gaussian method. doi: 10.1038/s41598-025-86860-9.
- [31] **Jia, D., Zhang, X., Zhou, J. T., Lai, P., Wei, Y.** (2022). Dynamic thresholding for video anomaly detection. *IET Image Processing*, 16(11), 2973–2982. Eylül. doi: 10.1049/IPR2.12532.
- [32] **Wang, Y., Zhang, X., Li, H., Chen, M., Liu, Y., Zhao, Q.** (2024). Heatmap Explainable Anomaly Detection in Images and Videos: A Survey.
- [33] **Holub, O.** (2006). Quantitative histogram analysis of images.
- [34] **Akcay, S., Atapour-Abarghouei, A., Breckon, T. P.** (2018). GANomaly: Semi-Supervised Anomaly Detection via Adversarial Training.
- [35] **Mäenpää, T., Ojala, T., Pietikäinen, M., Soriano, M.** (2000). Robust texture classification by subsets of local binary patterns. *Proceedings - International Conference on Pattern Recognition*, 15(3), 935–938. doi: 10.1109/ICPR.2000.903698.
- [36] **Gabor, D.** (1944). Gabor Filter – Theory of Communication
- [37] **Yang, J., Liu, L.** (2003). A modified Gabor filter design method for fingerprint image enhancement.
- [38] **Jing, J., Yang, P., Li, P., Kang, X.** (2014). Supervised defect detection on textile fabrics via optimal Gabor filter. *Journal of Intelligent Material Systems and Structures*, 44(1), 40–57. doi: 10.1177/1528083713490002.

- [39] **C. Cortes, V. Vapnik, and L. Saitta**, ‘Support-Vector Networks Editor’, *Machine Learning*, vol. 20, pp. 273–297, 1995.
- [40] **Crammer, J. S.** (2002). The Origins of Logistic Regression.
- [41] **Reid, N.** (1994). A Conversation with Sir David Cox. *Statistical Science*, 9(3), 439–455.
- [42] **Quinlan, J. R.** (1986). Induction of Decision Trees. *Machine Learning*, 1, 81–106.
- [43] **Grajski, K. A., Breiman, L., Viana, G., Prisco, D. I., Freeman, W. J.** (1986). CART Classification of EEG Spatial Patterns with a Tree-Structured Methodology: CART. *IEEE Transactions on Biomedical Engineering*, 33(12).
- [44] **Breiman, L.** (2001). Random Forests. *Machine Learning*, 45, 5–32.
- [45] **Cover, T.** (1967). k-NN Nearest Neighbor Pattern Classification.
- [46] **Schölkopf, B., Sung, K., Burges, C., Girosi, F., Poggio, T., Vapnik, V.** (1996). Comparing Support Vector Machines with Gaussian Kernels to Radial Basis Function Classifiers.
- [47] **Liu, F. T., Ting, K. M., Zhou, Z.-H.** (2008). Isolation Forest.
- [48] **Breunig, M. M., Kriegel, H.-P., Ng, R. T., Sander, J.** (2000). LOF: Identifying Density-Based Local Outliers.
- [49] **MacQueen, J.** (1967). k-Means: Some Methods for Classification and Analysis of Multivariate Observations.
- [50] **Ester, M., Kriegel, H.-P., Sander, J., Xu, X.** (1996). DBSCAN: A Density-Based Algorithm for Discovering Clusters in Large Spatial Databases with Noise.
- [51] **Kosiorrek, A. R., Sabour, S., Teh, Y. W., Hinton, G. E.** (2019). Stacked Capsule Autoencoders. *Advances in Neural Information Processing Systems*, 32. Haziran.
- [52] **Bengio, Y., Courville, A., Vincent, P.** (2014). Representation Learning: A Review and New Perspectives.
- [53] **Defard, T., Setkov, A., Loesch, A., Audigier, R.** (2020). PaDiM: a Patch Distribution Modeling Framework for Anomaly Detection and Localization.
- [54] **Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., Courville, A., Bengio, Y.** (2020). Generative Adversarial Networks. *Communications of the ACM*, 63(11). doi: 10.1145/3422622.
- [55] **Balestriero, R., Zhao, K., Alahi, A., Belongie, S., Blankevoort, T., Bruna, J., Courville, A., Dai, B., Fogel, S., Goyal, P., He, K., Heek, J., LeCun, Y., Misra, I., Sminchisescu, C., Szegedy, C., Wang, X., Xie, S., Zisserman, A., Mnih, V.** (2023). A Cookbook of Self-Supervised Learning.
- [56] **Hinton, G., Vinyals, O., Dean, J.** (2015). Distilling the Knowledge in a Neural Network. *Mart*.
- [57] **Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, Ł., Polosukhin, I.** (2017). Attention Is All You Need.
- [58] **Raghu, M., Unterthiner, T., Kornblith, S., Zhang, C., Dosovitskiy, A.** (2021). Do Vision Transformers See Like Convolutional Neural Networks?
- [59] **Liu, Z., Ning, J., Cao, Y., Wei, Y., Zhang, Z., Lin, S., Hu, H.** (2022). Video Swin Transformer.

- [60] **Khudanpur, S., Hager, G.** (2014). Describable Textures Dataset.
- [61] **He, K., Zhang, X., Ren, S., Sun, J.** (2015). Deep Residual Learning for Image Recognition.
- [62] **Simonyan, K., Zisserman, A.** (2015). Very Deep Convolutional Networks for Large-Scale Image Recognition.
- [63] **Huang, G., Liu, S., Van Der Maaten, L., Weinberger, K. Q.** (2017). CondenseNet: An Efficient DenseNet using Learned Group Convolutions.
- [64] **Howard, A. G., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T., Andreetto, M., Adam, H.** (2017). MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications.
- [65] **Qassim, H., Verma, A., Feinzimer, D.** (2018). Compressed residual-VGG16 CNN model for big data places image recognition. 2018 *IEEE 8th Annual Computing and Communication Workshop and Conference (CCWC)*, 2018-January, 169–175. Şubat. doi: 10.1109/CCWC.2018.8301729.
- [66] **HAILO** <<https://hailo-ai.translate.google/products/ai-accelerators/hailo-8-ai-accelerator>>, erişim tarihi 21.06.2025.
- [67] **Bradley, D., Roth, G.** (2007). Adaptive Thresholding Using the Integral Image. *Journal of Graphics, GPU, and Game Tools*. doi: 10.1080/2151237X.2007.10129236.
- [68] **Li, Q., Lu, W., Yang, J.** (2011). A Hybrid Thresholding Algorithm for Cloud Detection on Ground-Based Color Images. doi: 10.1175/JTECH-D-11-00009.1.
- [69] **Li, Z., Zhu, Y., Van Leeuwen, M.** (2023). A Survey on Explainable Anomaly Detection. *arXiv preprint*, 1, 1. doi: 10.48550/arXiv.2210.06959.
- [70] **Liznerski, P., Ruff, L., Vandermeulen, R. A., Franks, B. J., Kloft, M.** (2021). Explainable Deep One-Class Classification.
- [71] **Simon, T., Hichem, S.** (2024). Distillation-based fabric anomaly detection.
- [72] **OpenVINO** <<https://www.intel.com/content/www/us/en/developer/tools/opencvino-toolkit/overview.html>>, erişim tarihi 21.06.2025.
- [73] **Apache** <<https://www.apache.org/licenses/LICENSE-2.0>>,
- [74] **PyTorch Docs** <<https://docs.pytorch.org/docs/stable/index.html>>, erişim tarihi 21.06.2025.
- [75] **Lightning** <<https://lightning.ai/docs/pytorch/stable/>>, erişim tarihi 21.06.2025.
- [76] **Gudovskiy, D., Ishizaka, S., Kozuka, K.** (2021). CFLOW-AD: Real-Time Unsupervised Anomaly Detection with Localization via Conditional Normalizing Flows.
- [77] **YAML** <<https://yaml.org/>>, erişim tarihi 21.06.2025.
- [78] **GitHub** <<https://github.com/>>, erişim tarihi 21.06.2025.
- [79] **Model Zoo** <<https://modelzoo.co/>>, erişim tarihi 27.06.2025.
- [80] **Zavrtanik, V., Kristan, M., Skočaj, D.** (2022). DSR: A Dual Subspace Re-Projection Network for Surface Anomaly Detection.
- [81] **Paperswithcode** <<https://paperswithcode.com/sota/anomaly-detection-on-mvtec-ad>>, erişim tarihi 21.06.2025.
- [82] **Brev.dev** <<https://brev.nvidia.com/environment/new/public>>, erişim tarihi 21.06.2025.
- [83] **Anaconda** <<https://www.anaconda.com/>>, erişim tarihi 26.06.2025.

- [84] **OpenCV** <https://opencv.org/>, erişim tarihi 21.06.2025.
- [85] **NumPy** <https://numpy.org/>, erişim tarihi 21.06.2025.
- [86] **Pandas** <https://pandas.pydata.org/>, erişim tarihi 21.06.2025.
- [87] **Scikit-Learn** <https://scikit-learn.org/stable/>, erişim tarihi 26.06.2025.
- [88] **Project Jupyter** <https://jupyter.org/>, erişim tarihi 21.06.2025.
- [89] **Apple M1 Ultra** <https://www.apple.com/newsroom/2022/03/apple-unveils-m1-ultra-the-worlds-most-powerful-chip-for-a-personal-computer/>, erişim tarihi 21.06.2025.
- [90] **Apple M2** <https://www.apple.com/tr/newsroom/2022/06/apple-unveils-m2-with-breakthrough-performance-and-capabilities/>, erişim tarihi 21.06.2025.
- [91] **Apple M4** <https://www.apple.com/tr/newsroom/2024/05/apple-introduces-m4-chip/>,
- [92] **PyTorch Get Started** <https://pytorch.org/get-started/locally/>, erişim tarihi 21.06.2025.
- [93] **CUDA** <https://developer.nvidia.com/cuda-12-1-0-download-archive>, erişim tarihi 22.06.2025.
- [94] **Apple Silicon** <https://support.apple.com/tr-tr/116943>, erişim tarihi 22.06.2025.
- [95] **DTD Dataset** <https://www.robots.ox.ac.uk/~vgg/data/dtd/releases.html>, erişim tarihi 24.06.2025.
- [96] **Martinez, W. L.** (2011). Graphical user interfaces: Graphical user interfaces. *Wiley Interdisciplinary Reviews: Computational Statistics*, 3(2), 119–133. Şubat. doi: 10.1002/wics.150.
- [97] **Tkinter** <https://docs.python.org/3/library/tkinter.html>, erişim tarihi 21.06.2025.
- [98] **Pillow** <https://pillow.readthedocs.io/en/stable/>, erişim tarihi 21.06.2025.
- [99] **Libcamera** <https://libcamera.org/>, erişim tarihi 21.06.2025.
- [100] **FFMPEG** <https://ffmpeg.org/>, erişim tarihi 22.06.2025.

ÖZGEÇMİŞ

Ad-SOYAD : Veysel AKBAŞ

ÖĞRENİM DURUMU:

- **Lisans** : 2009 Yıldız Teknik Üniversitesi, Makine Fakültesi, Makine Mühendisliği
- **Yüksek Lisans** : 2025 Bursa Teknik Üniversitesi, Mekatronik Anabilim Dalı, Mekatronik Mühendisliği Tezli Yüksek Lisans Programı

MESLEKİ DENEYİM VE ÖDÜLLER:

- Aior.com – Mühendis- Halen
- Bosch Sanayi ve Ticaret AŞ – Üretim Mühendisi- 2023
- Hyundai AŞ – Üretim Mühendisi- 2014
- Vakıflar Genel Müdürlüğü – Makine Mühendisi- 2012
- Karsan AŞ – Proje Satın alma Mühendisi -2010

TEZDEN TÜRETİLEN ESERLER, SUNUMLAR VE PATENTLER:

- AIORCOM-TextileAD Veri seti hazırlandı
- Üretimde Yapay Zekâ Kullanımı: Güncel Durum, Potansiyel ve Gelecek Perspektifler- 5th International Symposium of Scientific Research and Innovative Studies (ISSRIS'25)