

T.C.
ERZİNCAN BİNALİ YILDIRIM ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
YAPAY ZEKA VE ROBOTİK ANABİLİM DALI

**AKILLI ÜRETİM SİSTEMLERİNDE ÇOKLU HATA TEŞHİSİ İÇİN HİBRİT DERİN
ÖĞRENME YAKLAŞIMLARI**

Feyzanur ÖZDEN

Danışman: Dr. Öğr. Üyesi Canan TAŞTİMUR TEMİZ

TEZ JÜRİ ÜYELERİ
Doç. Dr. Volkan KAYA
Dr. Öğr. Üyesi Canan TAŞTİMUR TEMİZ

.....

YÜKSEK LİSANS TEZİ
ERZİNCAN, 2026

© 2026 [Feyzanur ÖZDEN]. Tüm hakları saklıdır.

Kabul ve Onay Sayfası

Dr. Öğr. Üyesi Canan TAŞTİMUR TEMİZ danışmanlığında, Feyzanur ÖZDEN tarafından hazırlanan bu çalışma 16.07.2026 tarihinde aşağıdaki jüri tarafından Yapay Zekâ ve Robotik Anabilim Dalı'nda Yüksek Lisans olarak oybirliği ile kabul edilmiştir.

Başkan : Dr. Öğr. Üyesi Canan TAŞTİMUR TEMİZ İmza:

Üye : Doç. Dr. Volkan KAYA İmza:

Üye : Unvan Ad SOYAD İmza:

Bu tez Enstitü Yönetim Kurulunun / / 20.... Tarih ve/..... Sayılı kararı ile onaylanmıştır.

Prof. Dr. Kemal Volkan ÖZDOKUR
Enstitü Müdür V.

Not: Bu tezde kullanılan özgün ve başka kaynaklardan yapılan bildirişlerin, şekil ve tabloların kaynak olarak kullanımı, 5846 sayılı Fikir ve Sanat Eserleri Kanunundaki hükümlere tabidir.

Bilimsel Etięe Uygunluk Sayfası

“Akıllı üretim sistemlerinde çoklu hata teşhisi için hibrit derin öğrenme yaklaşımları” isimli “Yüksek Lisans” tezım tarafımca intihal tespit programı ile incelenmiştir. Buna göre tezimde bilimsel etik ihlali ve intihal olarak nitelendirilebilecek herhangi bir durum olmadığını taahhüt ederim.

Bu çalışmadaki tüm bilgilerin, akademik ve etik kurallara uygun bir biçimde elde edildiğini; aynı zamanda bu kural ve davranışların gerektirdiğı gibi, bu çalışmanın özünde olmayan tüm materyal ve sonuçları tam olarak aktardığımı ve referans gösterdiğimi beyan ederim. 16/07/2026

Feyzanur ÖZDEN

ÖZET

AKILLI ÜRETİM SİSTEMLERİNDE ÇOKLU HATA TEŞHİSİ İÇİN HİBRİT DERİN ÖĞRENME YAKLAŞIMLARI

Feyzanur ÖZDEN

Yüksek Lisans Tezi

Erzincan Binali Yıldırım Üniversitesi, Fen Bilimleri Enstitüsü,

Yapay Zekâ ve Robotik Anabilim Dalı

Danışman: Dr. Öğr. Üyesi Canan TAŞTİMUR TEMİZ

2026, 97 sayfa

Endüstriyel üretim süreçlerinde akıllı sistemlerdeki ürünün yüzey arızalarının erkenden teşhis edilmesi, kalite kontrol süreçleri otomasyonu, maliyetlerin azaltılması ve kalite standartlarının korunması açısından kritiktir. Akıllı üretim sistemlerinde çoklu hata teşhisi ile birbirinden farklı türdeki arızaların saptanması sağlanmaktadır. Endüstri 4.0 ile üretim hatlarında veri miktarının artması sonucunda, klasik makine öğrenmesi yaklaşımları ile arızanın teşhis edilmesi yetersiz olması sonucunu doğurmuştur. Bu durumda, daha gelişmiş analiz yöntemlerine ihtiyaç artmıştır. Bu kapsamda bu tezde, hibrit derin öğrenme mimarileri ile farklı türdeki arızalı veri örneklerinin sınıflandırılması yüksek doğruluklarla sağlanmıştır. Bu tezde, metal ve kumaş yüzeylerde meydana gelen çoklu kusurların belirlenmesi için hibrit derin öğrenme yaklaşımları incelenmiştir. Önerilen yöntemde, farklı derin öğrenme mimarileri birlikte kullanılarak hem nesne tespiti hem de segmentasyon işlemleri gerçekleştirilmiştir. Bu çalışmada, arızalı görüntülerden elde edilen özellikler konvolüsyonel sinir ağları ile çıkarılmış, ardından bu özellikler farklı sınıflandırıcılar ile analiz edilmiştir. Sınıflandırma aşamasında kullanılan derin mimariler Vision Transformer (ViT) ve dikkat tabanlı derin sinir ağları gibi yenilikçi yaklaşımlardır. Gerçekleştirilen deneysel çalışmalar sonucunda görülmüştür ki önerilen yöntem farklı tipteki arızaları yüksek performans elde edilmiştir. Bu çalışma, akıllı üretim sistemlerinde kalite kontrol süreçlerinin iyileştirilmesine katkı sağlamaktadır.

Anahtar Kelimeler: Akıllı üretim sistemleri, yüzey kusur tespiti, hibrit derin öğrenme, çoklu hata teşhisi, görüntü işleme, kalite kontrol

ABSTRACT

HYBRID DEEP LEARNING APPROACHES FOR MULTIPLE FAULT DIAGNOSTICS IN INTELLIGENT MANUFACTURING SYSTEMS

Feyzanur ÖZDEN

Master's Thesis

Erzincan Binali Yıldırım University, Institute of Science and Technology,

Department of Artificial Intelligence and Robotics

Advisor: Asst. Prof. Canan TAŞTİMUR TEMİZ

2026, 97 pages

Early detection of surface defects in smart systems within industrial production processes is critical for automating quality control processes, reducing costs, and maintaining quality standards. Smart manufacturing systems enable the detection of different types of defects through multiple defect diagnosis. With the increase in data volume on production lines due to Industry 4.0, classical machine learning approaches have proven insufficient for defect diagnosis. This has led to a growing need for more advanced analysis methods. In this thesis, hybrid deep learning architectures are used to classify different types of defective data samples with high accuracy. This thesis examines hybrid deep learning approaches for identifying multiple defects on metal and fabric surfaces. In the proposed method, different deep learning architectures are used together to perform both object detection and segmentation. In this study, features obtained from defective images are extracted using convolutional neural networks, and then these features are analyzed with different classifiers. The deep architectures used in the classification phase are innovative approaches such as Vision Transformer (ViT) and attention-based deep neural networks. Experimental studies have shown that the proposed method achieves high performance in detecting different types of failures. This study contributes to the improvement of quality control processes in intelligent manufacturing systems.

Keywords: Intelligent manufacturing systems, surface defect detection, hybrid deep learning, multiple fault diagnosis, image processing, quality control

TEŞEKKÜR

Bu tez çalışmasının hazırlanması sürecinde bilgi, tecrübe ve değerli katkılarıyla bana her zaman yol gösteren danışman hocam Dr. Öğr. Üyesi Canan TAŞTİMUR TEMİZ'e içten teşekkürlerimi sunarım.

Yüksek lisans eğitimim boyunca bilgi ve deneyimlerinden faydalandığım Erzincan Binali Yıldırım Üniversitesi Yapay Zeka ve Robotik Anabilim Dalı öğretim üyelerine teşekkür ederim.

Çalışmalarım süresince her zaman yanımda olan, desteklerini ve sevgilerini esirgemeyen aileme, yakınlarıma ve arkadaşlarıma sonsuz teşekkürlerimi sunarım.

Feyzanur ÖZDEN

Haziran, 2026

İÇİNDEKİLER

ÖZET	i
ABSTRACT	ii
TEŞEKKÜR	iii
İÇİNDEKİLER	iv
TABLolar DİZİNİ	vi
ŞEKİLLER DİZİNİ	vii
SİMGELER VE KISALTMALAR DİZİNİ	ix
1. GİRİŞ	1
1.1. Araştırmanın Amacı	2
1.2. Araştırmanın Önemi	3
1.3. Varsayımlar	4
1.4. Sınırlılıklar	5
2. LİTERATÜR TARAMASI	6
2.1. Kumaş Yüzeyi Arıza Teşhisi Yaklaşımları	6
2.2. Çelik Yüzeyi Arıza Teşhisi Yaklaşımları	11
3. ÖNERİLEN YAKLAŞIMLAR	18
3.1. Konvolüsyonel Sinir Ağları	19
3.2. Transfer Öğrenme Mimarileri	19
3.2.1. Inception Net Modeli	19
3.2.2. Mobile Net Modeli	20
3.2.3. Dense Net Modeli	20
3.2.4. Efficient Net Modeli	21
3.2.5. ResNet Modeli	21
3.2.6. ConvNeXt Modeli	22
3.3. Vision Transformer Tabanlı Mimariler	23
3.3.1. Data-Efficient Image Transformer	23
3.3.2. Swin Transformer	23
3.4. Önerilen Metal Yüzey Arıza Tespit ve Sınıflandırma Yaklaşımı	24
3.4.1. ConvNeXt-Nano Tabanlı Temel Yapı	25
3.4.2. Mekansal Dikkat Mekanizması	26
3.4.3. Öğrenilebilir Havuzlama Mekanizması	27
3.4.4. Kolmogorov-Arnold Ağ Modeli	28

3.5. Önerilen Kumaş Yüzey Arıza Tespit ve Sınıflandırma Yaklaşımı.....	30
3.5.1. Önerilen Denetimsiz Kumaş Arızası Tespit Yaklaşımı.....	30
3.5.2. Transformer Tabanlı Özellik Temsili ve Anomali Bölgesi Öğrenimi	31
3.5.3. Memory-Bank Tabanlı Anomali Tespiti	33
3.5.4. Mahalanobis Mesafesi ile İstatistiksel Dağılım Modellemesi	35
3.5.5. Öğrenilebilir Füzyon Tabanlı Anomali Skorlama	37
3.5.6. Denetimli Kumaş Arıza Sınıflandırma Sistemi	39
4. DENEYSEL SONUÇLAR	41
4.1. Metal ve Kumaş Veri setleri	41
4.2. Veri Ön İşleme ve Veri Artırma Teknikleri	43
4.3. Deneysel Ortam ve Eğitim Parametreler	44
4.4. Değerlendirme Metrikleri	45
4.5. Metal Yüzey Kusur Tespit ve Sınıflandırma Sonuçları.....	46
4.5.1. Karşılaştırmalı Model Sonuçları	47
4.5.2. Önerilen Modelin Performans Analizi	53
4.5.3. Görsel Dikkat ve Açıklanabilirlik Analizi	58
4.6. Kumaş Yüzey Kusur Tespit ve Sınıflandırma Sonuçları	60
4.6.1. Karşılaştırmalı Model Sonuçları	61
4.6.2. Önerilen Modelin Performans Analizi	66
4.6.3. Denetimsiz Anomali Tespit Sonuçları	70
4.7. Genel Tartışma ve Yorum	72
5. SONUÇLAR ve ÖNERİLER	75
KAYNAKÇA	76

TABLÖLAR DİZİNİ

Tablo 1. Literatürdeki kumaş arıza tespit ve teşhis ile ilgili çalışmalar.....	11
Tablo 2. Literatürdeki çelik yüzey arıza tespit ve teşhis ile ilgili çalışmalar	13
Tablo 3. Önerilen ve CNN modelinin karşılaştırmalı sınıflandırma performansı.....	54
Tablo 4. Önerilen ve CNN modelinin sınıf-bazında sınıflandırma sonuçları	56
Tablo 5. Önerilen modelin anomali tespit performansı	59
Tablo 6. Önerilen modelin kumaş arızası sınıflandırma performansı	68
Tablo 7. Önerilen modelin kumaş arızası için sınıf bazında sınıflandırma performansı	69
Tablo 8. Önerilen hata tespit işlem aşamaları boyunca görsel yorumlanması	71

ŞEKİLLER DİZİNİ

Şekil 1. Literatürdeki Chenab veri setinden örnek görseller	8
Şekil 2. Literatürdeki kullanılan Unet mimarisinin detaylı diyagramı	9
Şekil 3. InceptionV3 modeli.....	20
Şekil 4. DenseNet169 ve DenseNet201 model mimarileri	21
Şekil 5. ResNet mimarisi.....	22
Şekil 6. ConvNeXt mimarisi	22
Şekil 7. Swin transformer mimarisi işleyiş mantığı.....	24
Şekil 8. Metal yüzey arıza teşhisi için önerilen mimarinin genel akışı	25
Şekil 9. ConvNeXt mimari blok şeması.....	26
Şekil 10. Mekansal dikkat mekanizması blok şeması.....	27
Şekil 11. CNN ve KAN mimarilerinin karşılaştırılması	29
Şekil 12. Metal yüzey arıza teşhisi için önerilen mimarinin genel akışı.....	30
Şekil 13. Vision transformer mimarisiyle örnek bir girdinin özellik çıkarım süreci	31
Şekil 14. Memory-bank tabanlı anomali skoru hesaplanması.....	35
Şekil 15. Mahalanobis mesafesi tabanlı anomali skoru hesaplanması	37
Şekil 16. Önerilen üçlü füzyon tabanlı anomali tespit mimarisi	39
Şekil 17. X-SDD veri setinden örnek görseller	42
Şekil 18. Kullanılan kumaş veri setinden örnek görseller.....	42
Şekil 19. Veri setlerine uygulanan ön işleme ve veri artırım teknikleri	44
Şekil 20. Karşılaştırılan modellerinin X-SDD veri setindeki eğitim doğrulukları	48
Şekil 21. Karşılaştırılan modellerinin X-SDD veri setindeki doğrulama doğrulukları ..	48
Şekil 22. Karşılaştırılan modellerinin X-SDD veri setindeki eğitim doğrulama eğrisi ..	49
Şekil 23. X-SDD veri setinde modellerin bar grafikleriyle karşılaştırılması	49
Şekil 24. X-SDD veri setinde modellerin ortak ROC eğrisi karşılaştırılması.....	50
Şekil 25. X-SDD veri setinde modellerin karmaşıklık matrisi karşılaştırılması	52
Şekil 26. Önerilen ve geleneksel CNN modelleri için doğruluk değişimi	53
Şekil 27. Geleneksel CNN modeli için precision, recall ve f1-score değişimleri	54
Şekil 28. Önerilen model için precision, recall ve f1-score değişimleri	54
Şekil 29. Önerilen ve geleneksel CNN modelin karmaşıklık matris karşılaştırılması....	55
Şekil 30. Önerilen ve geleneksel CNN modelin ROC eğrisi karşılaştırılması	56
Şekil 31. Farklı arıza türleri için metrik değerlerinin sınıf bazında karşılaştırılması	56
Şekil 32. Önerilen ve geleneksel CNN modelin UMAP karşılaştırılması	57

Şekil 33. Önerilen model ve geleneksel CNN modelin hata görselleştirme sonuçları ...	58
Şekil 34. Karşılaştırılan modellerinin kumaş veri setindeki eğitim doğrulukları.....	61
Şekil 35. Karşılaştırılan modellerinin kumaş veri setindeki doğrulama doğrulukları	62
Şekil 36. Karşılaştırılan modellerinin kumaş veri setindeki doğruluk eğrisi	62
Şekil 37. Kumaş veri setinde modellerin bar grafikleriyle karşılaştırılması	63
Şekil 38. Kumaş veri setinde modellerin ortak ROC eğrisi karşılaştırılması.....	64
Şekil 39. Kumaş veri setinde modellerin karmaşıklık matrisi karşılaştırılması	66
Şekil 40. Kumaş veri setinde önerilen model için doğruluk eğrisi.....	67
Şekil 41. Kumaş veri setinde önerilen model için kesinlik eğrisi	67
Şekil 42. Kumaş veri setinde önerilen model için hassasiyet eğrisi	68
Şekil 43. Kumaş veri setinde önerilen model için f1-skor eğrisi.....	68
Şekil 44. Kumaş veri setinde önerilen modelin ROC eğrisi	69
Şekil 45. Kumaş veri setinde önerilen modelin karmaşıklık matrisi	69
Şekil 46. Kumaş veri setinde önerilen modelin UMAP görselleştirme sonucu	70

SİMGELER VE KISALTMALAR DİZİNİ

AI	: Artificial Intelligence (Yapay Zekâ)
ARPANET	: Advanced Research Projects Agency Network
BiFPN	: Bidirectional Feature Pyramid Network
CAM	: Class Activation Map
CNN	: Convolutional Neural Network
CPU	: Central Processing Unit
CRF	: Conditional Random Fields
DVM	: Destek Vektör Makinesi
ECA	: Efficient Channel Attention
FCM	: Fuzzy C-Means
FPS	: Frame Per Second
GAN	: Generative Adversarial Network
GC10-Det	: Guangxi Center 10 Defect Dataset
GE	: Gather-Excite
GPU	: Graphics Processing Unit
Grad-CAM	: Gradient-weighted Class Activation Mapping
IoU	: Intersection over Union
KAN	: Kolmogorov-Arnold Network
k-NN	: k-Nearest Neighbor
KSA	: Konvolüsyonel Sinir Ağları
LBP	: Local Binary Pattern
mAP	: Mean Average Precision
MCA	: Multi-Scale Cross-Axis Attention
MNIST	: Modified National Institute of Standards and Technology

NEU : Northeastern University

NEU-Cls : Northeastern University Classification Dataset

NEU-Det : Northeastern University Detection Dataset

RCNN : Region Convolutional Neural Network

ROC : Receiver Operating Characteristic

SE : Squeeze and Excitation

SPPF : Spatial Pyramid Pooling Fusion

SSD : Single Shot Detector

SVM : Support Vector Machine

TL : Transfer Learning

UMAP : Uniform Manifold Approximation and Projection

U-Net : U-Shaped Network

ViT : Vision Transformer

VGG : Visual Geometry Group

X-SDD : X Surface Defect Dataset

YOLO : You Only Look Once

% : Yüzde

sd : Serbestlik Derecesi

Adam : Adaptive Moment Estimation

C2f : Cross Stage Partial Fusion

ConvNeXt : Convolutional Next Network

DEiT : Data-efficient Image Transformer

FPN : Feature Pyramid Network

ImageNet : Image Database for Visual Recognition

LSTM : Long Short-Term Memory

Mask R-CNN : Mask Region Convolutional Neural Network

MobileNet : Mobile Neural Network

ResNet : Residual Network

Swin Transformer : Shifted Window Transformer

VGG : Visual Geometry Group

VGG16 : Visual Geometry Group-16

Xception : Extreme Inception

AlexNet : Alex Network

ConvNeXt-Nano : Convolutional Next Nano

DenseNet : Densely Connected Convolutional Network

EfficientNet : Efficient Neural Network

Faster R-CNN : Faster Region Convolutional Neural Network

Grad-CAM : Gradient-weighted Class Activation Mapping

InceptionV3 : Inception Version 3

MobileNetV2 : Mobile Neural Network Version 2

RegNet : Regular Network

SqueezeNet : Squeeze Neural Network

U-Net : U-Shaped Network

Vanilla CNN : Temel Konvolüsyonel Sinir Ağı

YOLOv5 : You Only Look Once Version 5

YOLOv7 : You Only Look Once Version 7

YOLOv8 : You Only Look Once Version 8

YOLOv11 : You Only Look Once Version 11

1. GİRİŞ

Sanayi devriminin son aşaması olan Endüstri 4.0, üretim süreçlerini sayısallaştırmıştır ve akıllı üretim süreçlerini hızlandırmıştır. Günümüzdeki üretim sistemleri, artan müşteri beklentileri ve rekabet sebebiyle yüksek kalite standartlarını karşılamak durumunda kalmıştır. Teknolojik gelişmeler, akıllı ve otonom üretim sistemlerinin ortaya çıkmasına olanak sağlamıştır.

Böylece akıllı üretim sistemlerindeki üretim hatları daha esnek ve verimli bir hal almıştır. Teknoloji tabanlı yenilikçi üretim anlayışında, büyük veri analitiği, sensörler ve yapay zeka teknolojileri entegre şekliyle uygulanmaktadır. Akıllı üretim hatlarından büyük hacimli verilerin yapay zeka tabanlı modellerle eğitilerek anlamlı bilgilere dönüştürülmesi kalite kontrol sürecini iyileştirmenin yanı sıra sistemin performansını arttırma fırsatını da sunmuştur.

İşletmelerin üretim süreçlerinde karşılaştıkları en önemli problemlerden birisi, ürün yüzeyindeki arızalı bölgenin doğru ve hızlı şekilde tespit edilmesidir. Tekstil, metal ve benzeri farklı malzeme türlerinde oluşan çatlak, delik, leke, çizik gibi yüzey kusurları ekonomik kayıplara neden olup aynı zamanda ürünün kalitesini düşürerek müşteri memnuniyetini de olumsuz etkilemektedir. Bu tür arızaların ürün daha üretim hattındayken erken tespit edilmesi, hem maliyeti düşürmeyi hem de müşteri memnuniyetini arttırmayı hedeflemektedir. Metal yüzeyde oluşan çatlaklar, deformasyonlar ve kumaş yüzeyindeki leke, delik ve iplik hataları ürünün kalitesini doğrudan etkilemektedir. Akıllı üretim sistemleri, bu ihtiyaca cevap veren modern yaklaşımlar arasında yer almakta olup, veri odaklı karar verme süreçleri ile üretim performansını optimize etmeyi amaçlamaktadır.

Geleneksel yöntemlerle yapılan arıza tespisi, yüksek dikkat gerektiren ve uzun zaman almasının yanı sıra bu süreci kontrol eden operatörün dikkatine, deneyimine, insan gözünün sınırlı algılama kapasitesine ve yorgunluğuna bağlı olarak gelişen subjektif bir süreçtir. Ayrıca üretim sistemlerinde üretim hızının artması da manuel kontrol sürecini yine yeteriz kalmasına neden olmaktadır. Bu kapsamda, çeşitli derin öğrenme mimarileri hızlı ve esnek çözümler sunmaktadır. Görüntülerden arızalı bölgelere ait otomatik özniteliklerin çıkarımı için konvolüsyonel sinir ağları (KSA) tabanlı modeller kullanılmaktadır. Nesne tespit ve segmentasyonu için ise çeşitli derin öğrenme yaklaşımları kullanılmaktadır. Farklı veri setleri ve arıza türlerinde tek bir modelin aynı performansı vermesi mümkün olmadığından çeşitli derin sinir ağı mimarilerinden de faydalanılmaktadır. Dikkat mekanizmaları ve bölgesel analiz

teknikleri ile modelin önemli özelliklere odaklanması sağlanmaktadır. Bu durum, özellikle küçük ve karmaşık kusurların tespitinde önemli avantajlar sunmaktadır.

Bu tez kapsamında, metal ve tekstil yüzeylerde oluşan çoklu kusurların tespiti için hibrit bir derin öğrenme modeli geliştirilmesi hedeflenmektedir. Önerilen yaklaşımın, farklı kusur türlerini yüksek doğrulukla tespit edebilmesi ve üretim sistemlerinde otomatik kalite kontrol süreçlerine katkı sağlaması beklenmektedir.

1.1 Araştırmanın Amacı

Bu tezin amacı, akıllı üretim sistemlerinde ürün yüzeyinde oluşan arızaların erken tespiti için yüksek performanslı derin öğrenme modelleri geliştirmektir. Üretim süreçlerinde arızanın erken aşamada tespit edilmesi sayesinde hem maliyet azalmaktadır hem de ürün kalitesi artmaktadır. Günümüzde kalite kontrol süreçlerinin oldukça önemli hale gelmesiyle ve ürün arıza teşhisinin otonom sistemler tarafından yapılması bu alanda yapılan çalışmalara eğilimi arttırmıştır. Farklı yüzeylerdeki farklı arıza türlerinin tespit edilmesi zor bir problemdir ve kapsamlı bir analiz süreci gerektirmektedir.

Bu tezde, sadece arızalı yüzeylerdeki arızanın varlığının tespit edilmesi ile kalınmayıp ayrıca bu arızanın türünü ve konumunu da belirleyen bir sistem geliştirilmesini hedeflemektedir. Bu amaçla, görüntüdeki arızalı bölgelere dair özniteliklerin çıkarılmasının ardından bu özniteliklerin değerlendirilmesi sırasında çeşitli öğrenme yöntemlerine başvurulmuştur. Dikkat mekanizmalarının arıza teşhis süreçlerinde kullanılması ile görüntüdeki arızalı olan bölgelere adaptif olarak daha fazla önem verilmesi ve modelin bu bölgeleri öğrenmesine daha fazla yoğunlaştırmaktadır.

Bu çalışmanın bir diğer önemli amacı ise şudur ki; kumaş ve metal yüzeyler gibi farklı yüzey türleri arasında modelin genelleme yeteneğinin bulunmasıdır. Her iki yüzeyin farklı özelliklere sahip olması, geliştirilen hibrit derin mimarilerde test edilmesini de gerekli kılmaktadır. Bu kapsamda, farklı veri setleri ile geliştirilen modellerin karşılaştırmalı analizi de sunulması planlanmaktadır.

Bu araştırmada, akıllı üretim sistemlerinde manuel kontrol süreçlerinin yerini alarak; insan kaynaklı hataları azaltması ve üretim hattının hızlanmasını hedeflenmektedir. Geliştirilen

modellerin özellikle gerek zamanlı uygulamalar iin uygun olabilmesi iin hafif ve gvenilir modellerin geliřtirilmesi de hedeflenmektedir ve bylece akıllı retim srelerine kolaylıkla entegre edilebilecek nitelikte ve kalite kontrol srelerinin geliřtirilmesine de katkı saėlayacak nitelikte modeller retilmesi saėlanmış olacaktır.

1.2. Arařtırmanın nemi

Gnmzde retim sektrnde yařanan dijital dnřm, kalite kontrol srelerinin daha hızlı, gvenilir ve otomatik hale getirilmesini zorunlu kılmaktadır. zellikle akıllı retim sistemlerinin yaygınlařmasıyla birlikte, retim hatlarında ortaya ıkan hataların erken ařamada tespit edilmesi hem retim maliyetlerinin azaltılması hem de rn kalitesinin artırılması aısından byk nem tařımaktadır. Bu baėlamda, yzey kusurlarının doėru bir řekilde belirlenmesi, kalite kontrol srelerinin en kritik ařamalarından biri olarak ne ıkmaktadır. Metal ve tekstil gibi farklı sektrlerde yaygın olarak karřılařılan yzey kusurları, rn performansını ve mřteri memnuniyetini doėrudan etkileyen nemli bir faktrdr.

Geleneksel kalite kontrol yntemleri oėunlukla insan gzlemine dayalı olup, bu yntemler hem zaman alıcı hem de hata yapmaya aık bir yapı sergilemektedir. zellikle retim hızının arttığı modern retim hatlarında, manuel kontrol yntemlerinin yetersiz kaldığı aıka grlmektedir. Bu durum, otomatik ve akıllı sistemlerin geliřtirilmesini kaınılmaz hale getirmiřtir. Bu noktada, derin ėrenme tabanlı yntemler, grnt iřleme alanındaki bařarıları sayesinde yzey kusur tespiti probleminin zmnde nemli bir alternatif sunmaktadır. Ancak, farklı kusur trlerinin eřitliliėi ve veri setlerinin karmařıklığı, tek bir modelin yeterli performansı gstermesini zorlařtırmaktadır.

Bu arařtırmanın nemi, hibrit derin ėrenme yaklařımlarını kullanarak bu sınırlılıkları ařmayı hedeflemesinden kaynaklanmaktadır. Farklı derin ėrenme mimarilerinin ve makine ėrenmesi yntemlerinin bir arada kullanılması, modelin daha gl ve esnek bir yapıya sahip olmasını saėlamaktadır. zellikle nesne tespiti, segmentasyon ve zellik ıkarımı gibi farklı grevlerin aynı sistem ierisinde entegre edilmesi, oklu kusur tespitinde daha bařarılı sonular elde edilmesine olanak tanımaktadır. Ayrıca, dikkat mekanizmaları ve blgesel analiz teknikleri, modelin kusurlu alanlara daha etkin bir řekilde odaklanmasını saėlayarak performansı artırmaktadır.

Bu çalışma, yalnızca teorik bir katkı sunmakla kalmayıp aynı zamanda endüstriyel uygulamalar açısından da önemli bir potansiyele sahiptir. Geliştirilecek modelin üretim hatlarında uygulanabilir olması, kalite kontrol süreçlerinin otomatikleştirilmesine katkı sağlayacak ve insan kaynaklı hataların azaltılmasına yardımcı olacaktır. Bunun yanı sıra, üretim süreçlerinde zaman ve maliyet tasarrufu sağlanması, bu çalışmanın pratik önemini artırmaktadır.

Sonuç olarak, bu araştırma, akıllı üretim sistemlerinde yüzey kusur tespiti alanında hem bilimsel hem de uygulamalı açıdan önemli katkılar sunmayı hedeflemektedir. Hibrit derin öğrenme yaklaşımlarının etkinliğini ortaya koyarak, gelecekte geliştirilecek akıllı kalite kontrol sistemleri için güçlü bir temel oluşturması beklenmektedir.

1.3.Varsayımlar

Bu çalışmada, yüzey kusur tespiti için geliştirilen hibrit derin öğrenme yaklaşımının değerlendirilmesi belirli varsayımlar çerçevesinde gerçekleştirilmiştir. İlk olarak, çalışmada kullanılan veri setlerinin yeterli çeşitliliğe sahip olduğu ve farklı kusur türlerini temsil ettiği varsayılmaktadır. Metal ve tekstil yüzeylerde oluşan kusurların veri seti içerisinde dengeli bir şekilde dağıldığı ve bu durumun model performansını olumlu yönde etkilediği kabul edilmektedir.

Veri setinde yer alan görüntülerin doğru şekilde etiketlendiği ve bu etiketlerin modelin öğrenme sürecine katkı sağladığı varsayılmaktadır. Ayrıca, veri setinin eğitim, doğrulama ve test aşamalarında uygun oranlarda bölündüğü ve bu bölünmenin model performansını doğru şekilde yansıttığı kabul edilmektedir.

Bu çalışmada kullanılan derin öğrenme modellerinin, görüntü verilerinden anlamlı ve ayırt edici özellikler çıkarabildiği varsayılmaktadır. Hibrit model yapısında yer alan farklı bileşenlerin birbirini tamamlayıcı nitelikte olduğu ve bu sayede model performansının artırıldığı kabul edilmektedir. Ayrıca, dikkat mekanizmalarının modelin önemli bölgeleri daha iyi analiz etmesine katkı sağladığı varsayılmaktadır.

Modelin eğitim sürecinde kullanılan hiper parametrelerin uygun şekilde seçildiği ve modelin aşırı öğrenme problemlerinden minimum düzeyde etkilendiği kabul edilmektedir. Ayrıca,

kullanılan optimizasyon yöntemlerinin modelin hızlı ve etkili bir şekilde öğrenmesini sağladığı varsayılmaktadır.

Son olarak, elde edilen sonuçların yalnızca kullanılan veri seti ile sınırlı kalmayıp benzer üretim ortamlarında da geçerli olduğu varsayılmaktadır. Bu varsayımlar doğrultusunda, araştırma bulgularının değerlendirilmesi yapılmıştır.

1.4.Sınırlılıklar

- Bu çalışma, kullanılan veri setleri ile sınırlıdır. Veri setlerinde yer alan görüntülerin tüm gerçek üretim koşullarını ve tüm olası kusur türlerini tam olarak temsil etmeyebileceği kabul edilmektedir.
- Veri setlerinin büyük bir kısmı kontrollü ortamlarda elde edilmiş olabilir; bu nedenle gerçek üretim hattındaki değişken aydınlatma, gürültü ve kamera açıları modele tam olarak yansımamış olabilir.
- Veri etiketleme sürecinde insan kaynaklı hatalar bulunabilir ve bu durum model performansını etkileyebilir.
- Çalışma, belirli yüzey türleri (metal ve tekstil) ile sınırlıdır; farklı malzeme türleri için model performansı değişkenlik gösterebilir.
- Kullanılan derin öğrenme mimarileri ve hibrit yapı, belirli model kombinasyonları ile sınırlandırılmıştır; farklı model mimarileri ile daha farklı sonuçlar elde edilebilir.
- Modelin performansı, kullanılan donanım (GPU/CPU) kapasitesi ile sınırlıdır; daha güçlü donanımlarda farklı sonuçlar elde edilebilir.
- Gerçek zamanlı uygulama performansı detaylı olarak test edilmemiş olabilir; bu nedenle endüstriyel ortamlarda gecikme (latency) sorunları oluşabilir.
- Veri dengesizliği (class imbalance) problemi tam olarak giderilememiş olabilir ve bu durum bazı kusur türlerinde performans düşüşüne neden olabilir.

2. LİTERATÜR TARAMASI

Bu bölümde, metal ve kumaş yüzey arıza teşhisi problemleri için derin öğrenme tabanlı çözümler üreten literatürdeki güncel çalışmalara yer verilmiştir.

2.1 Kumaş Yüzeyi Arıza Teşhisi Yaklaşımları

Liu vd., (2022a) endüstriyel kumaş arızalarının otomatik ve güvenilir olarak tespit edilmesine yönelik derin öğrenme tabanlı bir yaklaşım önerdiler. Çalışmanın temelinde karmaşık kumaş arıza tiplerinin bulunması ve bunların farklı boyut ve şekillerde olması bulunmaktadır. Geleneksel yaklaşımlar bu tarz kumaş arızalarını tespit etmekte yetersiz kalmaktadır. Nesne tespit konusunda sıkça kullanılan YOLOv4 (You Only Look Once) modeli, çeşitli iyileştirmeler uygulanarak küçük ve düzensiz arıza durumlarını tespitinde kullanılmıştır. Bu mimari sayesinde hızlı bir şekilde arızanın konumu tespit edilip delik, yağ lekesi, renk hatası ve rulman izi gibi yaygın kumaş arıza türlerinin sınıflandırılması sağlanmıştır. Deneysel sonuçlar, önerilen yöntemin orijinal YOLOv4 modeline kıyasla ortalama doğruluk (mAP) değerinde yaklaşık %6 oranında bir iyileşme sağladığını göstermektedir. Buna karşın, modelin işlem hızı (FPS) yalnızca yaklaşık %2 oranında düşmüş, bu da sistemin gerçek zamanlı uygulamalar için uygun olduğunu ortaya koymuştur.

Geze ve Akbaş (2024) transfer öğrenme yaklaşımıyla VGGNet16, InceptionV3, ve ResNet50 mimarileri kullanılarak 768×512 boyutlu 3200 adet görüntülü 12 farklı arıza sınıflı TILDA veri seti üzerinde kumaş arıza sınıflandırma yapmışlardır. Transfer öğrenme mimarileri ile görüntülerdeki arızalı bölgelerin özellikleri çıkarıldıktan sonra görüntüler k-Neighbor Nearest (k-NN) ve Destek Vektör Makinesi (DVM) ile görüntüleri etiketleme yani sınıflandırma yapılmıştır. En yüksek performansı ResNet50+k-NN modelinde %95,88 doğrulukla elde etmişlerdir.

Arshad ve Shahzad (2023) ise bir diğer transfer öğrenme yaklaşımını benimseyerek kumaş arızalarını sınıflandırmayı hedeflemişlerdir. ResNet ve VGG16Net ile mimarilerini kullanılarak tek-atışta öğrenme (one-shot learning) ile veri setinde üç farklı kumaş arızası sınıfı bulunmaktadır. Bu sınıflarda ise tek örnek içermektedir. Bu yaklaşımda hedeflenen şudur ki modelin daha önceden görmediği arıza türleri için tek örnek üzerinden arızalı etiketlemesinin kabiliyetini sağlamaktır. Bu bağlamda VGG16Net %73,91 doğruluk ulaşırken

ResNet50 %67,59 oranında kalmıştır.

Varjovi vd. (2022) kumaş arızalarının sınıflandırılmasında özelleştirilmiş bir derin sinir ağı tasarlanmıştır. Bu önerilen mimari 13.800 adet kumaş görüntülü 250x256 piksel değerli ve arızalı-sağlıklı olmak üzere iki sınıflı bir veri seti üzerinde değerlendirilmiştir. Önerilen derin model %97 doğruluk oranına ulaşırken aynı veri setini bilinen transfer öğrenme mimarilerinden InceptionV3, MobileNetV2 ve ResNet50 arasından en yüksek performans InceptionV3 mimarisinde %78 doğruluk oranıyla sınırlı kalmıştır.

Bir başka transfer öğrenme yaklaşımı kullanılarak kumaş arızalarının sınıflandırılması çalışması da Şeker tarafından 2018 yılında yapılmıştır. Bu çalışmada, AlexNeti sıfırdan eğitmek yerine önceden eğitilmiş ağırlıkları kullanılmıştır. AlexNet'in sıfırdan eğitimde %75 doğruluk oranı elde edilirken önceden eğitilmiş ağırlıkların kullanıldığı AlexNet ile %98 oranında doğruluk elde edilmiştir. Kullanılan veri setinde yırtık, düğüm, yağ lekesi ve çift dikiş gibi arızalar bulunmaktadır ve toplamda 3725 örnekten oluşmaktadır.

Düz kumaşlar ve baskılı kumaşların her ikisinde de arızalı olan bölgelerin tespit edilmesi için gerçek üretim ortamlarından Chenab Textiles'tan alınan görseller üzerinden değerlendirme yapılmıştır (Nasim vd., 2024). Kumaş arızalarının tespit edilmesi için YOLOv8 hafif modeli eğitilmiştir. Karşılaştırmak için ise YOLOv5 ve Mobilenetv2 SSD FPN lite modelleri aynı veri seti üzerinde eğitilmiştir. MobilenetSSD-FPNLite en düşük %77.09 mAP (Mean Average Precision - Ortalama Ortalama Hassasiyet), bunu takiben %84.5 ile YOLOv5 ve en yüksek oranı ise %84.8 ile YOLOv8 takip etmiştir. Çalışmada kullanılan veri setinde bakraç, renk sorunları, kirlenme, kesik, gri dikiş, kenar ve leke olmak üzere yedi sınıf yer almaktadır. Bu veri setine ait örnek görseller Şekil 1' de verilmiştir.


Kumaş yüzeyindeki arızaların tespiti ve sınıflandırılması için geliştirilmiş bir Mask-RCNN (Convolutional Neural Network) modeli önerdiler (Revathy ve Kalaivani, 2023). Önerilen model küçük arızaları ve karmaşık arka plan durumları için yenilikçi bir çözüm içermektedir. Bu model, öznetelik çıkarımı ve çok-ölçekli özellik birleştirme adımları ile iyileştirilmiştir. Delik, leke, taşıma, iplik hatası, çizgi hataları ve düzensiz desen gibi altı farklı arızayı sınıflandırılması amaçlanmıştır. Modelin performansının değerlendirilmesinde mAP, doğruluk ve IoU (Intersection over Union) metrikleri kullanılmıştır. Bu çalışmada %97,8 doğruluk oranına ulaşılmıştır. Kullanılan veri setinde ise her bir sınıfa ait 50 adet örnek bulunmaktadır.

Mewada vd. (2024) artık ağ tabanlı bir CNN modeli önerdiler. Önceden eğitilmiş artık ağ olarak ResNet50 mimarisi kullanılarak delikler, nesneler, yağ lekeleri ve iplik hataları olmak üzere dört farklı kumaş arızaları %95.36 doğruluk elde edilmiştir. Önerdikleri sistemde hiper parametre ayarlamasında ve uygunluk fonksiyonunda cuckoo arama optimizasyon algoritması uygulanmıştır.



Şekil 1. Literatürdeki Chenab veri setinden örnek görseller

Liu vd. (2022b) denetimsiz UNet ağı kullanılarak sadece kumaş arıza tespiti yapılmıştır (Şekil 2'deki gibi). Arızalı olan bölgenin tespitinde maske görüntülerinden faydalanılmıştır. Tayvan'daki bir firmadan alınan görüntülerle oluşturulan veri setinde 27000 pozitif örnek ve 1040 negatif örnek bulunmaktadır. Bu veri setinde eğitim ve test aşamaları tamamlanmıştır ve IoU skorundan %69 oranında sonuç elde edilmiştir.



Şekil 2. Literatürdeki kullanılan Unet mimarisinin detaylı diyagramı

Li vd. (2025) farklı şekillerdeki kumaş arızalarını etkili şekilde işlemek üzere ve arızaların boyutlarının da farklılığın üstesinden gelebilmek üzere bir kanal değiştirme modülü ve çok ölçekli bir birleştirme modülü birlikte kullanılarak hibrit bir derin model tasarlanmıştır. Bu çalışmada kullanılan veri setinden on iki farklı arıza çeşidi ile 7940 örnekli veri seti üzerinden sınıflandırma yapılmıştır.

Tastimur vd. (2025) Logarithmic Deep Residual Shrinkage ağı ile dört farklı kumaş arızalarının sınıflandırılması sağlanmıştır. Özel olarak oluşturulan bu veri setinde 2500 adet görüntü çoğaltma teknikleri ile elde edilmiştir. Deneysel sonuçlar sonucunda %99,17 doğruluk oranına ulaşılmıştır. Önerilen modelin klasik residual shrinkage ağına kıyasla yaklaşık %3 oranında bir performans kazancı sağlanmıştır.

Tastimur (2026) kumaş arızalarının gerçek zamanlı olarak tespit ve sınıflandırılması için bir diğer çalışma gerçekleştirmiştir. Önerilen model, iki aşamadan oluşmaktadır. İlk aşamada kumaş görüntülerinde Fuzzy C-means, Koşullu rastgele alanlar (CRF-Conditional random fields) ve uzamsal dikkat ile iyileştirilmiş U-Net ile arızalı bölgeler üzerinden segmentasyon uygulanmıştır. Ardından ise kullanılan veri seti arızalı ve sağlıklı olarak iki kümeli 2555 adet kumaş görüntülerinden oluşmaktadır. Elde edilen doğruluk ise %99,92 oranındadır.

İslam vd. (2025) topluluk öğrenme ve derin öğrenme tabanlı hibrit bir yaklaşımla kumaş arızalarının sınıflandırılması yaptılar. Özel olarak oluşturulmuş altı farklı arızadan (broken-button, button-hike, color-defect, foreign-yarn, hole ve sewing-error) oluşan bir veri seti üzerinden eğitimleri gerçekleştirilmiştir. YOLOv8m mimarisi ile arıza tespit uygulanmıştır ve

mAP@50 değeri %89 olarak ölçülmüştür. Sınıflandırma aşamasında ise VGG16, ResNet50, MobileNet, InceptionV3 ve Xception olmak üzere beş farklı transfer öğrenme mimarisinden faydalanılarak bu mimarilerin çıktıları ağırlıklı oylama yöntemi ile birleştirilmiştir. Deneysel çalışmalar sonucunda %90 doğruluk oranı elde edilmiştir.

Guder vd. (2022) kumaş yüzeylerindeki arızaların sınıflandırılması için TILDA ve Wiever veri setleri birleştirilerek özel bir veri seti oluşturdular. Oluşan veri seti 256×256 piksel çözünürlüğündeki görüntülerle çizgi hataları, kırışıklık izleri, makine yağı lekesi, delik ve ağartma hataları olmak üzere beş farklı arızanın bulunduğu toplam 8073 adet görüntüden oluşmaktadır. EfficientNetB4, EfficientNetV2M, ResNet18 ve RegNetZ_E8 gibi farklı transfer öğrenme yaklaşımları ile sınıflandırma yapılarak sonuçlar karşılaştırılmıştır. Ayrıca bu çalışmada optimizier algoritmasının da farklı versiyonlarla (Adam ve Ranger) denenmiştir. En yüksek performansı Adam+ EfficientNetv2m ile %99.42 doğruluk oranına erişilmiştir.

Transfer öğrenme mimarileri ile kumaş arıza sınıflandırması yapan Jing vd. (2019) beş farklı kumaş veri setini eğitim ve test aşamasında karşılaştırmalı olarak kullandılar. Önerilen yaklaşımda önceden MNIST veri seti ile eğitilmiş ön ağırlıklar kullanılarak en iyi başlangıç parametreleri kaydedilmiştir. Daha sonra ise girdi görüntüsü yerel bölgelere ayrılıp bu bölgeler ve ağırlık katsayılar ince-ayar yapılarak eğitilen modele kaydırılmalı pencere metodu sayesinde arızalı alanlar ve arıza türleri tespit edilmiştir. Önerdikleri modelin ulaştığı başarı oranı ise ön-eğitimsiz ağırlıklı model eğitime kıyasla yaklaşık %9 oranında artarak en yüksek %98.62 olarak ölçülmüştür.

Kumaş arızalarının gerçek zamanlı ve otomatik olarak tespiti için önerilen bu çalışmada ise YOLOv11 modeli benimsenmiştir (Machado vd., 2025). Önerilen mimari; delik, renk bozulması ve kırışıklık gibi arızaları beyaz ve keten kumaşlar üzerinde test edilmiştir. Deneyler, kontrollü aydınlatma altında ve kumaştan yaklaşık 1 metre uzaklığa yerleştirilmiş iki RealSense kamera ile gerçek endüstriyel ortamda gerçekleştirilmiştir. Sonuçlar, sistemin %82'nin üzerinde mAP@0.5 değeri ile yüksek doğruluk ve düşük gecikme sunduğunu göstermektedir.

Ananthi vd. (2024) kumaş yüzeylerindeki arıza sınıflandırması için ikili sınıflandırma olarak sağlıklı/arızalı olarak etiketlendirmişlerdir. Kullanılan veri seti örnekleri; delikler, eksik iplikler, ince düzensizlikler gibi arızaları bulundurmaktadır. Bu çalışmada basit bir CNN ağı kullanılarak yaklaşık %80 civarı bir doğruluk oranına ulaşılmıştır.

Tablo 1. Literatürdeki kumaş arıza tespit ve teşhis ile ilgili çalışmalar

Kaynak	Kullanılan yöntem	Veri seti	Metrik
Liu vd. (2022b)	Denetimsiz U-Net (segmentasyon)	27.000 pozitif, 1.040 negatif	IoU: %69
Geze & Akbaş (2024)	VGG16, InceptionV3, ResNet50 + k-NN, SVM	TILDA, 3200 görüntü, 12 sınıf	%95.88 (ResNet50 + k-NN) %73.91
Arshad & Shahzad (2023)	VGG16, ResNet50 (One-shot learning)	3 sınıf (tek örnekli)	(VGG16), %67.59 (ResNet50)
Varjovi vd. (2022)	Özel CNN modeli	13.800 görüntü, 2 sınıf	%97 doğruluk
Şeker (2018)	Transfer öğrenmeli AlexNet	3725 görüntü, çok sınıf	%98 (ön-eğitilmiş)
Nasim vd. (2024)	YOLOv8, YOLOv5, MobileNetSSD	7 sınıf	%84.8 (YOLOv8), %84.5 (YOLOv5), %77.09
Revathy & Kalaivani (2023)	Geliştirilmiş Mask R-CNN	6 sınıf, sınıf başı 50 örnek	%97.8 doğruluk
Mewada vd. (2024)	ResNet50 + Cuckoo Search	4 sınıf	%95.36 doğruluk
Tastimur vd. (2025)	Log Deep Residual Shrinkage	2500 görüntü, 4 sınıf	%99.17 doğruluk
Tastimur (2026)	U-Net + FCM + CRF + Attention	2555 görüntü, 2 sınıf	%99.92 doğruluk
Islam vd. (2025)	YOLOv8 + Ensemble CNN	6 sınıf	mAP: %89, Doğruluk: %90
Guder vd. (2022)	EfficientNet, ResNet, RegNet + Adam/Ranger	8073 görüntü, 5 sınıf	%99.42 doğruluk
Jing vd. (2019)	Transfer öğrenme + sliding window	5 farklı veri seti	%98.62 doğruluk
Ananthi vd. (2024)	Basit CNN	İkili sınıf	~%80 doğruluk

2.2.Çelik Yüzeyi Arıza Teşhisi Yaklaşımları

Zhou vd. (2017) CNN tabanlı bir model geliştirerek çelik yüzeylerindeki arızaları sınıflandırmayı amaçladılar. Hiyerarşik olarak düşük özelliklerden yüksek özelliklere öğrenmenin sağlanması amacıyla beş katmanlı CNN mimarisi tasarlanmıştır. Altı sınıflı NEU(Northeastern University) çelik yüzey arıza veri setinde her sınıfa ait 300 adet görüntü 200x200 piksel boyutuyla bulunmaktadır. Ayrıca önerdikleri modelin gürültülü çalışma koşullarına karşı dayanıklılığını test etmek üzere görüntülere belli miktarda gürültü eklenerek test edilmiştir. Elde edilen gürültüsüz verilerden, ortalama doğruluk oranı %99 olarak ölçülmüştür.

Lee vd. (2019) NEU veri setinin arıza sınıflandırması için VGG-Net' ten ilham alınarak CNN tabanlı yeni bir ağ tasarladılar. Önerilen mimarinin etkinliğini ortaya koyabilmek üzere Grad-CAM görselleştirilmesi kullanılmıştır. Performans değerlendirme sonucunda doğruluk oranı %99.44 olarak elde edilmiştir.

Bir diğer çalışmada NEU ve bu veri seti üzerinde sentetik veri arttırımı ile elde edilen ikinci bir veri seti ile arıza sınıflandırılması yapılmıştır (Nath vd., 2023). Özellik çıkarımı aşamasında ImageNet ve sinirsel yapı öğrenimi birleştirilerek az sayıda eğitim örneği üzerinden model eğitimi sağlanmıştır. Önerdikleri modele histogram eşitleme ve Vanilla sınıflandırıcı eklenmiştir. Sentetik veri setinden elde edilen doğruluk oranı %92.4 iken NEU veri setinden elde edilen doğruluk oranı %99.7 olarak ölçülmüştür.

Liu vd. (2020) çelik yüzey arıza sınıflandırılması için hafif bir CNN model tasarladılar. Farklı görüntü ölçeklerinin eş zamanlı CNN mimarisi üzerinden eğitilmesi sağlanmıştır. 5.58 ms gecikme ve %98.89 doğruluk oranı elde edilmiştir. Altı farklı arıza sınıflı NEU-CIs veri seti üzerinden deneysel çalışmalar yürütülmüştür.

NEU-CIs veri setinin kullanımıyla GoogLeNet, MobileNetV2 ve ResNet18 transfer öğrenme mimarilerinin karşılaştırmalı sonuçlarıyla sınıflandırma performansları analiz edilen bu çalışmada ise bu mimarilerine ek olarak klasik CNN ve Transformer mimarisi de kullanılarak hibrit bir yapı elde edilmiştir (Li vd., 2022). En yüksek performansı ise hibrit CNN-Transformer yapısıyla %98,33 doğruluk oranı elde edilmiştir.

Transformer mimarilerinden son zamanlarda popüler olan Swin-Transformer ile NEU metal yüzey arıza sınıflandırılması yapılan bu çalışmada mAP@50 metrik sonucu %81,23 olarak elde edilmiştir (Zhu vd., 2023). Çalışmanın genellenebilirliğinin ispat edilebilmesi için farklı metal yüzey arıza veri setleri olan GC10-Det üzerinde de model test edilmiştir ve ablasyon çalışmaları analiz edilmiştir.

Bir başka çalışmada; delik, oyuk ve yuvarlanma olmak üzere üç farklı çelik arızasını sınıflandırmak üzere ResNet50 transfer öğrenme mimarisi üzerinden ince-ayar yapılarak arıza sınıflandırma yapılmıştır (Konovalenko vd., 2020). Önerdikleri model %96.91 doğruluk oranı elde edilmiştir.

Transfer öğrenme mimarilerinden bir diğer çalışmada ise SqueezeNet ile öğ-eğitimi olarak NEU veri seti eğitimi yapılmıştır ve %97.5 doğruluk oranı test verisi ile elde edilmiştir (Fu vd., 2019). Çalışmada eğitim ve test aşamalarında kullanılan veri setinin çeşitli aydınlatma, kamera gürültüsü ve harekete bağlı bulanıklık eklenerek görüntü arttırım teknikleri de uygulanmıştır.

Wang vd. (2021) faster region convolutional neural networks (faster R-CNN) yöntemi ile ResNet50 modeli birleştirilerek hem metal yüzeylerindeki arızaları tespit edebilme doğruluğunu arttırmak ve hızını arttırmak üzere kullanmışlardır. Deforme edilebilir sinir ağı ile geliştirilmiş görüntü kırpması sayesinde modelin arızalı ve sağlıklı metal yüzey bölgelerinin sınıflandırılabilmesi için ResNet50 mimarisine girdi görselleri iletilmiştir. Gerçek fabrika ortamından elde edilen metal yüzey arızaları veri seti ile model test edilerek %98.2 doğruluk oranına ulaşılmıştır.

CNN tabanlı yaklaşımla, metal yüzey arızalarının sınıflandırıldığı Demir vd. (2023) paralel dikkat artırmak ağı ile Severstal adındaki public metal yüzey arıza veri seti üzerinde ikili ve çoklu sınıflı sınıflandırma yapmışlardır. Bu çalışmada kullanılan veri seti beş arıza sınıflıdır ve metal yüzey görüntüleri 200x32 boyutlandırılarak toplam 6668 adettir. Yürütülen deneysel çalışmalar sonucunda ikili sınıflandırmadan elde edilen doğruluk oranı % 97.9 iken çok-sınıflı sınıflandırma performansı % 94.5 olarak ölçülmüştür.

Tastimur (2025) mean-shift tabanlı prototip ağı sayesinde metal yüzey arıza sınıflandırması uygulamıştır. Önerilen model altı arıza sınıflı NEU, yedi arıza sınıflı X-SDD ve on arıza sınıflı GC10-Det metal yüzey arıza veri setleri üzerinde test edilmiştir. Ayrıca önerilen model az veriyle eğitim (few-shot learning) imkanı sunması avantajıyla öne çıkmaktadır. Klasik prototip ağı ile önerilen modelin karşılaştırmalı performans sonuçlarının da sunulduğu bu çalışmada önerilen model NEU, X-SDD ve GC10-Det veri setlerinde her birinde üstün olmuştur. Ayrıca sınıf ve örnek sayısının artışı klasik prototip ağı zorlarken ve performansını kötü etkilerken önerilen modelde performans artışı gözlemlenmektedir.

Tablo 2. Literatürdeki çelik yüzey arıza tespit ve teşhis ile ilgili çalışmalar

Kaynak	Kullanılan yöntem	Veri seti	Metrik
Zhou vd. (2017)	5 katmanlı CNN (hiyerarşik özellik öğrenme)	NEU (6 sınıf)	%99 doğruluk
Lee vd. (2019)	VGG-Net tabanlı CNN + Grad-CAM	NEU	%99.44 doğruluk

Nath vd. (2023)	ImageNet + sinirsel yapı öğrenimi + histogram eşitleme + Vanilla classifier	NEU + sentetik veri	%99.7 (NEU), %92.4 (sentetik) doğruluk
Liu vd. (2020)	Hafif CNN + çok ölçekli giriş	NEU-CIs	%98.89 doğruluk 5.58 ms gecikme
Li vd. (2022)	Hibrit CNN + Transformer (GoogLeNet, MobileNetV2, ResNet18 karşılaştırmalı)	NEU-CIs	%98.33 doğruluk
Zhu vd. (2023)	Swin Transformer	NEU + GC10-Det	mAP@50: %81.23
Konovalenko vd. (2020)	ResNet50 (transfer learning, fine-tuning)	Özel veri (3 sınıf)	%96.91 doğruluk
Fu vd. (2019)	SqueezeNet (transfer learning) + veri artırma	NEU	%97.5 doğruluk
Wang vd. (2021)	Faster R-CNN + ResNet50 + deformable CNN	Gerçek fabrika verisi	%98.2 doğruluk
Demir vd. (2023)	Paralel dikkat artık ağı (attention-based CNN)	Severstal (5 sınıf)	%97.9 (ikili), %94.5 (çok-sınıflı) doğruluk
Tastimur (2025)	Mean-shift tabanlı prototip ağı (few-shot learning)	NEU, X-SDD, GC10-Det	Tüm veri setlerinde klasik prototipten daha iyi

Metal yüzeylerindeki arızaların tespit edilmesine yönelik çalışmalarda son zamanlarda YOLO mimari versiyonları sıkça kullanılmaktadır. Sıklıkla YOLOv5 (Lv ve Xu, 2023; Li vd., 2025a), YOLOv7 (Yang vd., 2025), YOLOv8 (Meng ve Wen, 2024; Sun vd., 2025; Sheng vd., 2024; Gan vd., 2025; Xiao, 2026; Wang vd. 2025), YOLOv11 (Li vd., 2025b; Liao vd., 2025; Ren vd., 2025; Chen vd., 2025; Yang, 2025;) versiyonları metal yüzeylerindeki arıza tespitinde kullanılmıştır. İlk çalışmada modelin arızalı olan bölgelere daha fazla dikkat verebilmesi için YOLOv5 omurgasına bir dikkat SE(Squeeze and Excitation) modülü eklenmiştir (Lv ve Xu, 2023). Elde edilen arıza tespitinde ortalama mAP değeri %91.40, precision oranı %88 ve recall oranı ise %83.5 olarak elde edilmiştir. Altı farklı arıza türü içeren ve her sınıfa ait 600 adet görselden toplam 1800 görüntülü NEU-Det veri seti kullanılmıştır. Çeşitli veri artırma teknikleri ile veri setinde 7200 adet görüntü oluşturulmuştur.

Benzer şekilde NEU-Det veri seti ile YOLOv5, YOLOvX ve YOLOv7 karşılaştırmalı olarak performansları analiz edilmiştir (Gao vd., 2024). En yüksek performansı YOLOv5 mimarisine SE(Squeeze and Excitation) modülü eklenerek ve Bidirectional Feature Pyramid Network (BiFPN) ağı da eklenerek standart YOLOv5 mimarisine kıyasla mAP oranı %4.2 artış göstererek %75.7' ye ulaşmıştır.

YOLOv5 ve NEU-Det veri setinin birlikte kullanılarak metal yüzey arıza tespit çalışması için Li vd. (2025a), içerik tabanlı özelliklerin yeniden birleştirilmesi ile YOLOv5 entegre edilerek %82 mAP oranı elde edilmiştir.

YOLOv7 mimarisine bazı iyileştirmeler uygulanarak NEU-Det veri seti üzerinden metal yüzey arıza tespiti gerçekleştirilmiştir (Yang vd., 2025). Efficient Channel Attention(ECA) dikkat modülü ile arızalı bölgelere daha fazla odaklanılmasını, arızalı bölgelerin çerçeveye alındığı anchor kutusunun optimum şekilde çalışabilmesi için K-means algoritmasını ve BiFPN ağı ile de çıkarılan özneteliklerin etkin şekilde birleştirilmesini sağlamıştır. Deneysel çalışmalar sonucunda elde edilen mAP oranı %77.9 olarak ölçülmüştür. Klasik YOLOv7 mimarisinin mAP oranına kıyasla yaklaşık %5 artış gözlemlenmiştir.

YOLOv8 mimarisini kullanılarak bazı iyileştirmelerle metal yüzey arıza tespitini NEU-Det veri seti üzerinde yapılmıştır (Meng ve Wen, 2024). Spatial Pyramid Pooling Fusion (SPPF) modülünün eklenmesiyle klasik YOLOv8n mimarisine kıyasla başarıyı arttırdığı vurgulanmıştır.

Sun vd. (2023), Multi-Scale Cross-Axis Attention (MCA) dikkat mekanizmasının YOLOv8n mimarisine entegre edilerek adaptife özellik piramit ağına dönüştürülmüştür. NEU veri seti ile modelin test edilmesi sonucunda mAP@0.5 değerinin %73.1 oranında elde edilerek ve %91.5 precision ulaşılmıştır.

Sheng vd. (2024) YOLOv8 mimarisine C2f modülü eklenerek klasik YOLOv8 mimarisine kıyasla mAP değeri %60.9' dan %61.5 değerine yükselirken precision değeri %68.5' ten %69.1 yükselmiştir. Deneysel çalışmalar için NEU-Det veri seti kullanılmıştır.

Gan vd. (2025) NEU-Det veri seti kullanılarak YOLOv8 omurgasına ek olarak derinlemesine ayrılabilir konvolüsyon, küresel dikkat ve Gather-Excite(GE) modülün eklenmesiyle karmaşık arka planların kaldırılmasında uygulanmıştır. Temel YOLOv8n mimarisine kıyasla mAP oranı %2,5 artarak %77.6 oranına ulaşılmıştır.

Spatial-Channel Collaborative Attention modülünün YOLOv8n mimarisine entegre edilerek NEU-Det veri seti üzerinden sınıflandırılması sağlanmıştır (Xiao, 2026). Elde edilen mAP oranı ise %78.2 olarak ölçülmüştür ve 6.2M parametrelili kompleks bir mimari elde edilmiştir.

Wang vd. (2025) YOLOv8 ‘nin öznetelik çıkarımını geliştirerek C2f ve fasterNet modülleri eklenmiştir. NEU-Det veri setinde standart YOLOv8n’ ye göre %2.2’lik bir artışla %79.1 mAP elde edilmiştir. Ayrıca mimari basitleştirilerek %36.4 oranında basitleştirilerek 14.3MB boyutuna indirilmiştir, böylelikle modelin hızının artırılması sağlanmıştır.

Li vd. (2025b) MobileNetV3 ve SE blok beraber kullanılarak YOLOv11 ‘ e entegre edilmiştir. Ayrıca metal yüzey arıza tespiti için NEU-Det veri seti üzerinde deneyler gerçekleştirilerek yaklaşık %47 oranında modelin parametre sayısı azaltılmıştır. Standart YOLOv11 modeline kıyasla mAP oranı %2.8 artarak %79 olarak ölçülmüştür.

Liao vd. (2025) ise YOLOv11 mimarisi üzerinde bazı iyileştirmeler uygulanarak hem NEU-Det hem de GC10-Det veri setleri üzerinde test edilmiştir. Uygulanan iyileştirmeler başlıca Gauss dağılımı ile özellik çıkarımının kalite arttırımı, farklı seviyelerden anlamlı özellik birleştirmesi için karışık toplama ağı ve model değişkenlerinin ortama uyarlanabilirliği için de dinamik Tanh aktivasyonu uygulanmıştır. Elde edilen mAP değeri klasik YOLOv11’ e göre %4.4 artarak %81.7 olarak ölçülmüştür.

Ren vd. (2025) arızalı bölgelerin tespitini kolaylaştırmak üzere büyük çekirdekli derinlemesine ayrılabilir evrişimi dikkat mekanizmalarının birden fazla paralel yapıda kullanılarak YOLOv11 ile birleştirilmiştir. NEU-Det ve GC10-Det veri setleri ile model deneysel çalışmaları yürütülmüştür. Klasik YOLOv11 mimarisine göre mAP değeri NEU-Det veri setinde yaklaşık %3 ve GC10-Det veri setinde yaklaşık %4 performans artışı sağlanmıştır.

YOLOv11 mimarisinde özellik çıkarımının iyileştirilerek ve aynı zamanda modelin parametre sayısını da azaltan Gated Bottleneck Convolution entegre edilmiştir (Chen vd., 2025). Global ve yerel özellik temsillerinin de iyileştirilmesi için dikkat modülü entegre edilmiştir. Mekânsal füzyon başlığı ise de örnekler üzerinde yerelleştirme doğruluğu optimize edilmesi için kullanılmıştır. Temel modele göre yaklaşık mAP değeri %7 artarak önerilen modelin mAP oranı %79.1 olarak ölçülmüştür.

Yang (2025) ise çelik yüzey arızalarında NEU-Det veri seti üzerinde YOLOv11 mimarisinde ölçek dizisi özellik füzyonu eklenmiştir. Deneysel çalışmalar sonucunda mAP oranı temel modele kıyasla yaklaşık %2 artarak %72.9 olarak ölçülmüştür.

3. ÖNERİLEN YAKLAŞIMLAR

Bu tez çalışmasında, endüstriyel kalite kontrol süreçlerinde ürün yüzey arızalarının hızlı, etkili ve otomatik olarak teşhis edilmesi için iki farklı derin öğrenme tabanlı yaklaşım önerilmiştir. Metal ve kumaş yüzey arızalarının otomatik olarak tespit ve sınıflandırma yapılması için ileri düzey yapay zeka tabanlı mimariler oluşturulmuştur. İlk bölümde, metal yüzey arızalarının tespit ve sınıflandırılması için dikkat tabanlı Kolmogorov-Arnold ağı mimarisi geliştirilmiştir. Çalışmanın ikinci bölümünde tekstil sektörüne yönelik transformer destekli hibrit bir arıza tespit sistemi geliştirilmiştir. Bahsedilen önerilen modellerle arıza tespiti yapılmasının yanı sıra literatürde sıklıkla kullanılan transfer öğrenme mimarileri ile de karşılaştırmalı deneysel sonuçlara da yer verilmiştir.

Modern endüstriyel üretim süreçlerinde, kalite kontrol mekanizması metal ve kumaş yüzeylerinde meydana gelen arızaların doğru ve hızlı şekilde saptanabilmesi sağlamaktadır. Üretim bantlarında ürünün güvenilirliği ve yüzey kalitesi endüstriyel üretim süreçlerinde kritik değerlendirme parametreleridir. Ürünlerin yüzeylerindeki arızalar, ürünün dayanıklılığını etkilemesinin yanı sıra üretim hattında ciddi kalite kaybına sebep olabilmektedir. Ürün yüzeyindeki arızaların erken aşamada tespit edilememesi; müşteri memnuniyetinin düşmesine ve ürün maliyetinde yükselmeye neden olmaktadır. Geleneksel arıza teşhis yönteminde üretim hattında ilerleyen ürünlerin insan gözlemine dayanarak teşhis edilmesine dayanmaktadır. Ancak bu teknik hem zaman alıcıdır hem de operatörün deneyimi, yorgunluk durumu ve hızına bağlı olarak değişken sonuçlar üretebilmektedir ve dolayısıyla hataya oldukça açık sonuçlar gelişebilmektedir. Ayrıca üretim hatlarının yüksek hızla ürünlerin akması nedeniyle operatör tarafından manuel arıza teşhisi yapılması yetersiz kalıp mikro seviyedeki arızaların kaçmasına neden olabilmektedir. Arıza teşhisinde bu sorunların önüne geçerek yapay zeka destekli otomatik teşhis yaklaşımlarına olan eğilim son yıllarda artmıştır.

Endüstriyel kalite kontrol süreçlerinde bilgisayarlı görü ve derin öğrenme teknikleri ile geliştirilen birçok çözüm bulunmaktadır. Üretim sırasında oluşan çizikler, oksitlenme bölgeleri, baskı deformasyonları ve yüzey bozulmaları çoğu zaman küçük boyutlu ve karmaşık geometrik yapılar içermektedir. Ürün yüzeylerindeki arızaların geometrik düzensizlikte oluşu, kontrast seviyelerinin düşük olması ve farklı üretim ortamlarındaki değişken koşullar sergilemesi gibi nedenlerle mevcut yaklaşımların ötesinde daha efektif bir çözüm önerilmiştir. Tezin bu bölümünde, metal ve kumaş yüzey arızalarının tespit ve sınıflandırılması için yenilikçi derin

öğrenme tabanlı yaklaşımlar geliştirilmiştir. Geliştirilen bu mimarinin yanı sıra klasik CNN yaklaşımı ve transfer öğrenme modelleri ile de metal arıza verisetleri üzerinde test edilerek önerilen modelin etkinliğini ortaya konulması amaçlanmıştır.

3.1. Konvolüsyonel Sinir Ağları

Görüntü işleme ve örüntü tanıma problemlerinin çözümünde sıklıkla kullanılmaktadır. Giriş görüntüsünden yerel özellikler çıkarılarak özellikler hiyerarşik şekilde öğrenme sürecine dahil edilir. Bu yapı sayesinde, manuel özellik çıkarımının yerine özellikle yüksek boyutlu görüntü verilerinde kullanımı oldukça kolaylık sunmaktadır. Temel bir CNN mimarisi, konvolüsyon katmanı, havuzlama katmanı, aktivasyon fonksiyonu ve tam bağlantılı katmanından oluşmaktadır. Konvolüsyon katmanlarında amaç görüntünün piksel matrislerini kullanarak özellik haritalarının çıkarılmasını sağlamaktır.


3.2. Transfer Öğrenme Mimarileri

Transfer Öğrenme (Transfer Learning-TL) bir problemi çözerken elde edilen bilgileri depolayan ve daha sonra bu bilgileri, ilgili başka bir problemi çözmek için uygulayan bir tekniktir. Yani bir görev için eğitilen bir modelin, başka bir görev için yeniden kullanılabilmesi bir makine öğrenme yöntemidir (Ribani ve Marengoni, 2019). Bu yöntemi kullanmanın sayesinde, ağı eğitimi daha az zaman ve hesaplama gücü almaktadır. Ayrıca, bir veri kümesindeki görüntü sayısı sınıflandırma için yetersiz olduğunda TL kullanılabilir. Sonuç olarak küçük veri kümelerini TL ile sınıflandırmak, yüksek performans elde edilmesine yardımcı olabilmektedir.

3.2.1. Inception Net Modeli

Bu model, Google tarafından geliştirilen derin öğrenme konvolüsyon mimarisi serisinin üçüncü versiyonudur (Szegedy vd., 2016). Görüntü sınıflandırma alanında kullanılan, en gelişmiş mimarilerden biridir ve birden fazla farklı boyuttaki konvolüsyonel filtreleri yeni bir filtrede birleştiren bir model içermektedir; böylece hem eğitilecek parametre sayısı hem de hesaplama karmaşıklığı azaltılmıştır. InceptionV3, 22 katman kümesi derinliğine sahiptir ve 144 katman içermektedir (Ucar, 2021). Başlangıç modülünde, boyutu azaltmak için çeşitli filtreler kullanılmaktadır. Başlangıç modülündeki filtre elemanları 1x1, 3x3 ve 5x5 boyutlarındadır. Diğer derin öğrenme mimarilerinden farklı olarak bu model katmanlı bir yapı yerine derin bir

yapı oluşturmaktadır. InceptionResNetV2, InceptionV3'ün bir varyasyonudur; ancak önemli ölçüde daha derin bir yapıya sahiptir. Başlangıç yapısı ve artık bir bağlantının birleşimidir. Çok boyutlu konvolüsyon filtreleri, ağır eğitim süresini azaltan artık bağlantılarla birleştirilmektedir (Nguyen vd., 2018).



Şekil 3. InceptionV3 modeli


3.2.2. Mobile Net Modeli

Bu model, Google tarafından 2017 yılında önerilen bir derin sinir ağıdır. Diğer modellere göre daha küçük ve daha hızlıdır. Derinlemesine ayrılabilir konvolüsyonlar kullanarak her giriş kanalına tek bir filtre uygulamaktadır ve bazı konvolüsyonlarda 1x1 filtre kullanmaktadır (Howard vd., 2017). Ayrılabilir katmanlar, derinlik bakımından konvolüsyon katmanlarına benzemektedir; ancak filtreleme ve birleştirme işlemlerini iki katmana ayırarak gerçekleştirdikleri için farklılık göstermektedirler. Bu mimaride, nokta (point) konvolüsyonları hariç toplam 28 katman bulunmaktadır. Softmax katmanını besleyen tam bağlı katman dışında, her katmanı toplu normalleştirme ve yeniden etkinleştirme katmanları takip etmektedir (Zeren 2019). MobileNetV2 mimarisi ise MobileNet modelinin geliştirilmiş halidir, ancak daha hızlı ve daha verimlidir. Özellik haritalarının boyutu 1x1 konvolüsyon yoluyla küçültülmüştür. Ayrıca ResNet modellerinde kullanılan atlama bağlantı tekniği sayesinde hesaplama işlemi daha hızlı olmaktadır (Baydilli 2021).

3.2.3. Dense Net Modeli

Sinir ağlarını eğitirken konvolüsyon ve alt örnekleme işlemleri nedeniyle özellik haritaları azalmaktadır. Katmanlar arasında geçiş yaparken de görüntü kalitesi kaybı olmaktadır. DenseNet, görüntü özellik bilgilerini daha etkin kullanmak için geliştirilmiştir (Huang vd., 2017). Bu modelde, her katman diğer katmanlara iletilmektedir; böylece herhangi bir katman önceki tüm katmanlardan özellik bilgilerine erişebilmektedir (Aktas 2020). Böylece özelliklerin

ağa yayılma hızı artmaktadır ve parametre sayısı azalmaktadır. DenseNet169 ve DenseNet201 mimarilerindeki katmanların ortak ve farklı parametre sayıları ve değerleri Şekil 4’ te ifade edilmiştir.




Şekil 4. DenseNet169 ve DenseNet201 model mimarileri

3.2.4. EfficientNet Modeli

Bu mimari, sekiz modelden oluşan bir ağıdır. Model sayısı arttıkça hesaplanan parametre sayısı nispeten sabit kalmaktadır (Tan ve Le, 2019). EfficientNet, diğer gelişmiş modellerin aksine modeli küçültmeye çalışırken derinlik, genişlik ve çözünürlük açısından ölçeklendirerek daha verimli sonuçlar üretmektedir. EfficientNet mimarisi, kanal boyutunun sekizin katı olmasını gerektirmektedir. Ağın genişliği, derinliği ve çözünürlüğü, bir dizi sabit ölçeklendirme faktörü tarafından eşit olarak ölçeklenmektedir.

3.2.5. ResNet Modeli

Bu model, sinir ağlarını derinlemesine eğitmenin zorluğunu azaltmak için Microsoft araştırma ekibi tarafından geliştirilen mimaridir. Standart KSA mimarisinden farklı olarak bu mimari kısa yol bağlantıları kullanmaktadır (Bayram vd., 2019). Kısayol bağlantılarının, fazladan parametresi bulunmamaktadır ve hesaplama karmaşıklığını arttırmamaktadır (He vd., 2016). Önemli bilgilerin, bir önceki katmandan diğerine aktarılmasına izin vermektedir. Bu mimari, küresel ortalama havuzlamayı ve ağın sonunda tamamen bağlı katmanları içermektedir. ResNet50 modeli ise 50 ağırlık katmanına sahiptir.




Şekil 5. ResNet mimarisi

3.2.6. ConvNeXt Modeli

Bu model, modern Transformer tabanlı mimarilerden elde edilen tasarım yaklaşımlarının klasik konvolüsyonel sinir ağlarına uyarlanması amacıyla geliştirilmiş bir derin öğrenme mimarisidir. Bu mimari, özellikle geleneksel CNN yapılarının performansını artırmak ve Vision Transformer (ViT) modelleri ile rekabet edebilecek seviyeye ulaştırmak amacıyla önerilmiştir. Standart konvolüsyonel sinir ağlarından farklı olarak ConvNeXt mimarisi; büyük kernel boyutları, ters darboğaz (inverted bottleneck) yapıları, katman normalizasyonu (Layer Normalization) ve gelişmiş aktivasyon mekanizmaları gibi modern tasarım bileşenlerini içermektedir (Lakshmaiya 2026; Peng vd., 2023). Ayrıca model, daha sade ve optimize edilmiş bir yapı sunarak hesaplama verimliliğini artırmaktadır.

ConvNeXt mimarisinde kullanılan derin konvolüsyon blokları sayesinde görüntü üzerindeki uzamsal özellikler daha etkin şekilde öğrenilebilmektedir. Bununla birlikte model, küresel ortalama havuzlama (Global Average Pooling) katmanı ve son sınıflandırma katmanları ile birlikte çalışmaktadır. Özellikle görüntü sınıflandırma, nesne tespiti ve endüstriyel hata tespiti gibi bilgisayarlı görü uygulamalarında yüksek başarı göstermektedir (Chengfei vd., 2025).



Şekil 6. ConvNeXt mimarisi

3.3. Vision Transformer Tabanlı Mimariler

Vision Transformer modeli, son zamanlarda derin öğrenme mimarilerine alternatif olarak geliştirilmiştir. Girdi görüntüsünün belli sayıdaki parçalara ayrılarak her bir parçanın sırayla işlenerek nesne tespit ve sınıflandırma problemlerine çözümdür. Her bir token(parça) üzerinden CNN mimarisinde bulunan kısıtlı alıcı alan ortadan kaldırılıp küresel bağlamda tokenlar arasındaki ilişkinin de modellenebilmesine olanak tanımaktadır (Komijani vd., 2022; Tang vd., 2025). Pozisyonel öznitelikler bilgilerinin de öz-dikkat (self-attention) entegrasyonu sayesinde tüm token bölgeleri arasında doğrudan bir ilişki kurulabilmektedir. Bu mimari sayesinde özellikle arıza teşhis konusunda oldukça faydalı sonuçlar üretilmiştir. Özellikle büyük veri setleri üzerinde eğitildiğinde yüksek temsil gücü sunan bu yapı, görüntü sınıflandırma, nesne tanıma ve endüstriyel kusur tespiti gibi birçok bilgisayarlı görü probleminde güçlü performans göstermektedir. Ancak ViT mimarisinin yüksek veri ihtiyacı ve hesaplama maliyeti, küçük veri setlerinde performans dalgalanmalarına neden olabilmektedir. Buna rağmen global attention mekanizması sayesinde karmaşık görsel örüntülerin modellenmesinde önemli avantajlar sunmaktadır.


3.3.1. Data-Efficient Image Transformer

Data-efficient Image Transformer (DeiT) mimarisi aslında ViT mimarisindeki veri verimliliği problemini çözmek üzere geliştirilmiştir. Özellikle küçük ve orta ölçekteki veri setleri için yüksek performans imkanı sunmaktadır. Bu model sayesinde büyük veriye olan ihtiyaç azalırken hızlı ve kararlı bir eğitim modeli oluşturmaktadır. ViT yapısına benzer şekilde girdi görüntülerini tokenlara bölerek encoder mimarisi sayesinde görüntüdeki küresel özellik ilişkisini öğrenebilmektedir (Ramachandran vd., 2023). DeiT mimarisi, düşük veri koşullarında dahi yüksek doğruluk oranları elde edebilmesi nedeniyle görüntü sınıflandırma ve kusur tespiti gibi görevlerde yaygın olarak tercih edilmektedir. Ayrıca hesaplama açısından ViT'e kıyasla daha verimli bir yapı sunarak gerçek zamanlı uygulamalara daha uygun hale gelmektedir.

3.3.2. Swin Transformer

ViT mimarisindeki hem hesaplama maliyetini düşürmek hem de yerel-küresel özellik öğrenimini daha dengeli şekilde yapabilmek üzere geliştirilmiştir. Transformer, global self-attention yerine kaydırmalı pencere (shifted window) mekanizması kullanarak görüntü üzerinde yerel bölgeler içinde attention hesaplamakta ve bu pencereleri katmanlar arasında kaydırarak

küresel bilgi akışını sağlamaktadır (Mia ve Li, 2024; Liu vd., 2024). Bu mimari CNN mimarisinin yerel özellik öğrenimini ve Transformerlara özgü uzun menzilli ilişkileri öğrenimini aynı anda yürütebilmektedir. Hesaplama karmaşıklığının global attention'a kıyasla daha düşük olması, modeli büyük çözünürlüklü görüntüler için daha uygun hale getirmektedir. Endüstriyel kusur tespiti uygulamalarında Swin Transformer, hem yerel doku bozulmalarını hem de geniş ölçekli yapısal anomalileri etkili biçimde modelleyebilme yeteneği sayesinde önemli bir alternatif olarak değerlendirilmektedir.



Şekil 7. Swin transformer mimarisi işleyiş mantığı

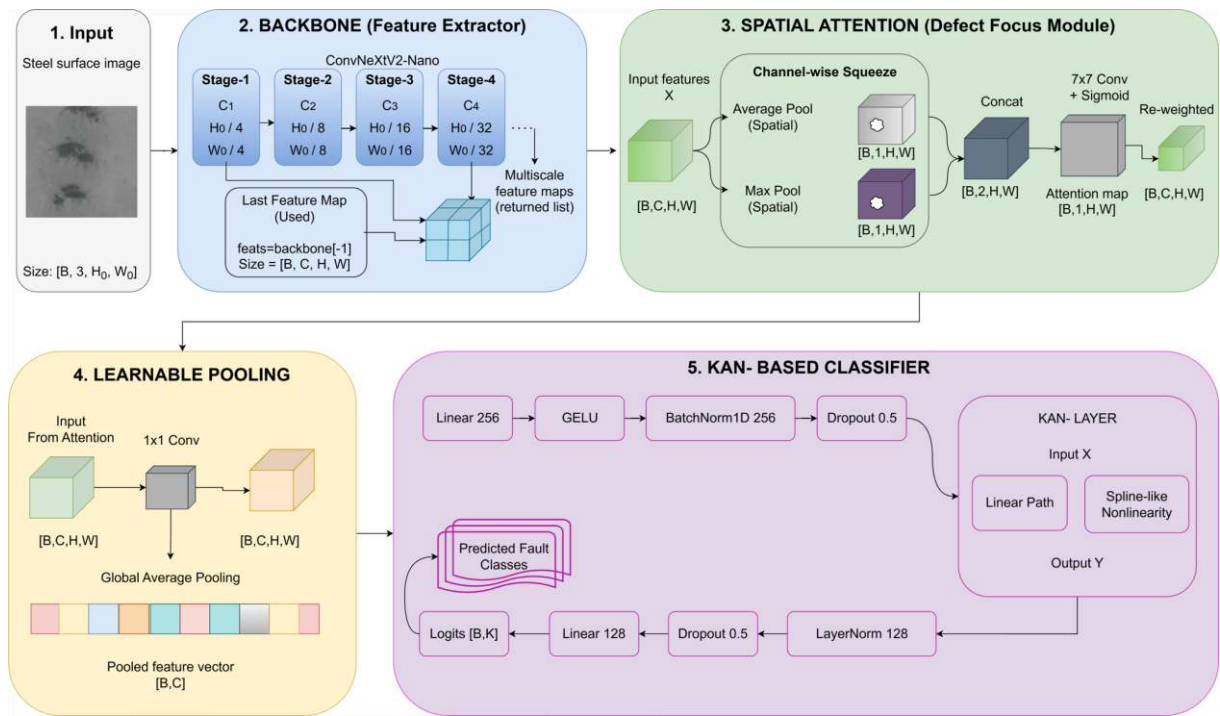
Klasik ViT mimarisinde her görüntü sabit parçalara bölünürken Swin transformer'da önce görüntü küçük parçalara ayırmaya başlanarak daha sonra kademeli olarak bu pencere boyutu arttırılmaktadır; Şekil 7 ise bu durum ifade edilmiştir.

3.4. Önerilen Metal Yüzey Arıza Tespit ve Sınıflandırma Yaklaşımı

Tezin bu bölümünde, akıllı üretim sistemlerinde metal yüzey kusurlarının erken tespiti ve sınıflandırılması amacıyla yüksek performanslı bir derin öğrenme yaklaşımı önermektedir. Metal yüzey arızalarının otomatik olarak bilgisayarlı görü ve derin öğrenme tabanlı yenilikçi bir mimari ile tespit edilmesi ve sınıflandırılması gerçekleştirilmiştir. Geliştirilen bu yenilikçi yaklaşım sayesinde düşük kontrastlı, küçük ölçekli ve düzensiz yapıları arızaların da tespit edilebilmesi hedeflenmiştir. Önerilen yaklaşım; dikkat mekanizması ile desteklenmiş

Kolmogorov-Arnold Network (KAN) tabanlı bir mimari üzerine inşa edilmiştir ve giriş görüntülerinden zengin özellik temsilleri elde edilmesini sağlamaktadır.

Önerilen model, standart derin öğrenme modellerine kıyasla daha esnek fonksiyonlar ile öğrenme sunarak karmaşık yüzey arızalarını daha etkili şekilde modelleyebilmektedir. Modelin temel bileşenleri ConvNeXtV2-Nano tabanlı temel bileşen, uzamsal dikkat modülü ve Kolmogorov-Arnold Network katmanıdır. Bu yapı sayesinde giriş görüntülerinden yüksek seviyeli özellikler elde edilmekte ve dikkat mekanizması ile kusurlu bölgeler ön plana çıkarılmaktadır. Öğrenilen özellikler adaptif havuzlama katmanı ile sıkıştırılarak KAN yapısına aktarılmaktadır. Bu yaklaşım, klasik fully-connected katmanlara kıyasla daha esnek fonksiyon öğrenme yeteneği sunmaktadır. X-SDD metal yüzey arızası veri seti üzerinde yapılan deneylerde model yüksek doğruluk değerlerine ulaşmış ve dikkat haritaları ile kusur bölgelerine odaklandığı doğrulanmıştır.



Şekil 8. Metal yüzey arıza tespiti için önerilen mimarinin genel akışı

3.4.1. ConvNeXt-Nano Tabanlı Temel Yapı

Modern görsel tanıma problem çözümlerinde son zamanlarda transformer seviyesinde performans üretilmesini sağlayan bir derin öğrenme temel yapısıdır. Bu yapı, klasik konvolüsyonel sinir ağlarının yerel özellik çıkarım yeteneğini korurken, Transformer


mimarilerinden ilham alınan tasarım bileşenleri ile temsil gücünü artırmaktadır (Zhang vd., 2025). Temel yapının en önemli bileşeni derin konvolüsyon bloklarıdır; her bloğun modellenmesinde (1) ‘deki formülasyon esas alınmaktadır.

$$y = x + F(LN(x)) \quad (1)$$

Burada x giriş özellik haritasını, $LN(\cdot)$ Layer Normalization işlemini ve $F(\cdot)$ ise konvolüsyonel dönüşüm fonksiyonunu temsil etmektedir. Bu yapı residual learning prensibine dayanarak gradient akışını iyileştirir. Derin konvolüsyon işlemi ise (2)’ deki gibi gerçekleştirilmektedir. Burada, W_k büyük kernel konvolüsyon filtresini, $*$ ise evrişim işlemini temsil etmektedir. Bunların ardından ise Global Response Normalization (GRN) mekanizması ile özellik haritaları (3)’ teki gibi optimize edilmektedir. Daha az katman ve parametre ile optimize edilerek gerçek zamanlı uygulamalar için uygun hale getirilmiştir ve yüksek doğruluk/hesaplama verimliliği dengesi sağlar.

$$F(x) = W_k * x + b \quad (2)$$

$$GRN(x) = \frac{x}{\|x\|_2} \gamma + \beta \quad (3)$$



Şekil 9. ConvNeXt mimari blok şeması

3.4.2. Mekânsal Dikkat Mekanizması

Girdi görüntüsü içindeki önemli olan bölgelerin vurgulanmasını sağlayan dikkat mekanizması ile özellik iyileştirmesi yapılmıştır. Endüstriyel yüzey arızaları çoğunlukla görüntünün belirli bir bölgesinde yoğunlaştığından klasik CNN mimarileri bu arızaları çoğu zaman arka plan olarak yakalayabilmektedir. Bu aşamada, mekânsal dikkat sayesinde önerilen model

görüntüdeki arızalı bölgelere daha fazla odaklanabilmesi ve arızalı bölgelerin yakalanması sağlanmıştır. İlk aşamada kanal boyutu boyunca ortalama ve maksimum havuzlama işlemleri (4) ve (5)' teki gibi gerçekleştirilmektedir. Elde edilen bu iki havuzlama bilgisi kanal ekseninde boyuna birleştirilip dikkat haritası (6) ile üretilmektedir. Denklem (7) sayesinde konvolüsyon uygulandıktan sonra ise mekânsal dikkat haritasına ulaşılmaktadır. Burada W konvolüsyon filtresini, b bias parametresini ifade etmektedir. Son aşamada; (8)' deki gibi dikkat ağırlıkları giriş özellik haritası ile çarpılarak önemli bölgeler güçlendirilmektedir.


$$A_{avg}(x, y) = \frac{1}{C} \sum_{c=1}^C F(c, x, y) \quad (4)$$

$$A_{max}(x, y) = \max_c(F(c, x, y)) \quad (5)$$

$$A_s = [A_{avg} ; A_{max}] \quad (6)$$

$$M_s = \sigma(W * A_s + b) \quad (7)$$

$$F_s = M_s \odot F \quad (8)$$



Şekil 10. Mekânsal dikkat mekanizması blok şeması

3.4.3. Öğrenilebilir Havuzlama Mekanizması

Öğrenilebilir havuzlama ile derin özellik haritalarından elde edilen bilgilerin daha net şekilde vurgulanabilmesi için adaptif bir özellik sıkıştırma işlemi sağlanmaktadır. Geleneksel

havuzlama yaklaşımlarında tüm görüntünün her bölgesine aynı işlem uygulanırken bu mekanizmada havuzlama işlemi veri dağılımına göre optimize edilmektedir. Kritik arızalı bölgelerin görüntü üzerinden daha net şekilde tespit edilebilmesi sağlanmış olmaktadır. Öğrenilebilir havuzlama mekanizmasına girdi olarak verilen $F \in R^{C \times H \times W}$ özellik haritası geleneksel ortalama havuzlama prensibi uygulandığında (9) daki çıktı elde edilirken öğrenilebilir havuzlama prensibi sayesinde (10)'daki çıktı elde edilmektedir. Görüntüdeki uzamsal bölgeler farklı ağırlık değerleri ile (11)'deki gibi modellenmektedir.

$$GAP(F) = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W F(i, j) \quad (9)$$

$$P(F) = \sum_{i=1}^H \sum_{j=1}^W \alpha_{ij} F(i, j) \quad (10)$$

$$\alpha_{ij} = \frac{e^{s_{ij}}}{\sum e^{s_{ij}}} \quad (11)$$

3.4.4. Kolmogorov-Arnold Ağ Modeli


KAN, klasik yapay sinir ağının doğrusal ağırlık tabanlı öğrenme yaklaşımını yeniden güncelleyerek öğrenilebilir fonksiyon temelli dönüşümlerin kullanılarak yeni nesil bir derin öğrenme yaklaşımıdır (Krzywda vd., 2025; Del Rosario vd., 2024). Modelin son aşamasında kullanılan KAN tabanlı sınıflandırma yapısı, en ayırt edici bileşenidir. Geleneksel tam bağlantılı katmanlar, karmaşık ve oldukça doğrusal olmayan yüzey bozulmalarını modelleme yeteneklerini sınırlayabilen sabit aktivasyon fonksiyonlarına dayanır. Buna karşılık, KAN yapısı, spline benzeri fonksiyonlar aracılığıyla daha esnek ve uyarlanabilir bir temsil öğrenimi sunarak düzensiz ve heterojen arıza desenlerinin daha doğru modellenmesini sağlar. Sonuç olarak, önerilen mimari hem temsil öğrenimi hem de karar verme mekanizmaları açısından standart CNN tabanlı yöntemlerin sınırlamalarının üstesinden gelerek daha güçlü, esnek ve uygulamaya uygun bir çözüm sunar. KAN mimarisi, doğrusal ağırlıklar ve sabit aktivasyonlar yerine öğrenilebilir fonksiyonlar kullandığı için klasik CNN'den farklıdır. Klasik çok katmanlı algılayıcıda, aktivasyon fonksiyonları (12) kullanılarak hesaplanır ve daha sonra ReLU veya GELU aktivasyon fonksiyonları uygulanır. Ancak KAN'da, her bağlantı (13)'te bir ağırlık yerine öğrenilebilir bir fonksiyon taşır.

$$y = Wx + b \quad (12)$$


$$y_j = \sum_i \phi_{ij}(x_i) \quad (13)$$

$$f(x_1, x_2, \dots, x_n) = \sum_{q=1}^{2n+1} \phi_q \left(\sum_{p=1}^n \phi_{q,p}(x_p) \right) \quad (14)$$

Burada x_i giriş özellik haritasını, ϕ_{ij} öğrenilebilir doğrusal olmayan fonksiyonu ve y_j çıkış düğümünü temsil eder. KAN'dan elde edilen çıkış özelliği (14)'ten elde edilir.



(a) CNN mimarisi akışı



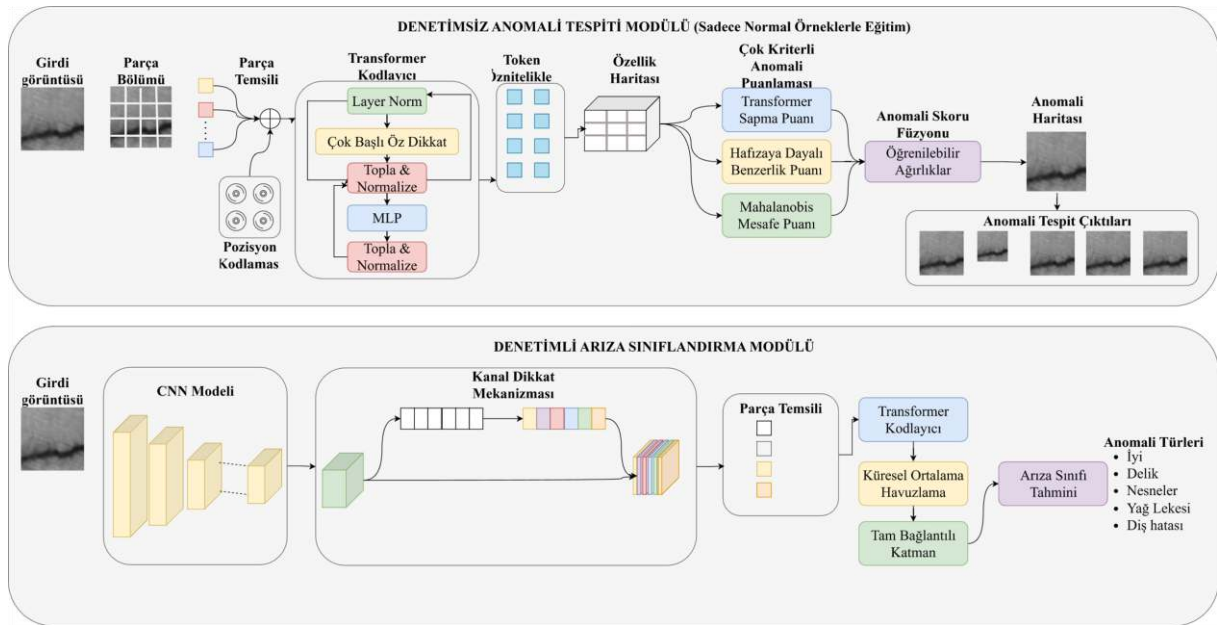
(b) KAN mimarisi akışı

Şekil 11. CNN ve KAN mimarilerinin karşılaştırılması

Bu yapı sayesinde model, karmaşık ve heterojen arıza modellerini daha başarılı bir şekilde öğrenebilir ve klasik MLP tabanlı sınıflandırıcılara kıyasla daha güçlü bir doğrusal olmayan temsil kapasitesi elde eder. Sonuç olarak, önerilen mimari hem temsil öğrenimi hem de karar mekanizması açısından standart CNN tabanlı yöntemlerin sınırlamalarının üstesinden gelerek daha güçlü, esnek ve endüstriyel olarak uygulanabilir bir çözüm sunar.

3.5. Önerilen Kumaş Yüzey Arıza Tespit ve Sınıflandırma Yaklaşımı

Tezin bu bölümünde ise akıllı üretim sistemlerinde ürün yüzeyindeki kusurların erken tespiti için yüksek performanslı derin öğrenme modelleri geliştirilmiştir. Kumaş üretim süreçlerinde arızaların erken tespiti maliyetleri düşürür ve ürün kalitesini artırır. Kalite kontrol süreçlerinin artan önemi ve ürün arızasının teşhisi için otonom sistemlerin kullanımı, bu alandaki araştırmalara olan talebi artırmıştır. Kumaş yüzeylerindeki kusurları sınıflandırmak için yerel özellikleri ve küresel korelasyonları modellemek üzere hibrit bir derin öğrenme mimarisi tasarlanmıştır. Giriş kumaş görüntülerinden çok seviyeli özellikler çıkarılır ve özellik haritaları, kanal dikkat mekanizması kullanılarak adaptif olarak ağırlıklandırılmıştır. Uzun menzilli küresel özellikleri modellemek için Transformer mimarisi kullanılmıştır, böylece hem yerel hem de küresel özellikler birleştirilmiştir. Sınıflandırma katmanına iletilen özellikler, son derece verimli sonuçlar elde edilmiştir. Yöntemin etkinliği, tez kapsamında elde edilen beş sınıflı kumaş arıza veri setimiz üzerinde doğrulanmış ve kapsamlı deneyler, üstün sınıflandırma performansını göstermiştir.



Şekil 12. Kumaş yüzey arıza tespiti için önerilen mimarinin genel akışı


3.5.1. Önerilen Denetimsiz Kumaş Arızası Tespit Yaklaşımı

Önerilen denetimsiz anomali tespit yaklaşımı birkaç aşamadan oluşmaktadır. Bu aşamalar Transformer kodlayıcı ile özellik çıkarımı, çok-kriterli (Transformer-tabanlı sapma puanı, Hafıza-tabanlı benzerlik puanı ve Mahalanobis-tabanlı mesafe puanı) anomali skoru hesaplama

ve öğrenilebilir füzyon-tabanlı anomali skorlama olarak anomali bölgelerin ortaya çıkarılması sağlanmaktadır. Bu yaklaşım sayesinde küçük ve düzensiz yapıda bulunan arızalı bölgelerin görüntüde belirginleştirilerek ortaya çıkarılmıştır.

3.5.2. Transformer Tabanlı Özellik Temsili ve Anomali Bölgesi Öğrenimi

Önerilen denetimsiz anomali tespit yaklaşımının ilk aşaması, Transformer tabanlı özellik temsillerinin öğrenilmesidir. Kumaş yüzeylerindeki arızalar çoğunlukla düzensiz bir yapıdadır ve farklı geometrik yapıdadırlar. Bu arızalar çoğunlukla düşük kontrastlıdır ve tekrar eden dokusal anomaliler barındırmaktadır. Görüntüdeki arızalı bölgeleri yakalamada CNN mimarileri oldukça başarılı sonuçlar üretmesine rağmen uzun menzilli ilişkileri modellemede yetersizdirler. Özellikle kumaş yüzeylerindeki tekrar eden dokusal anomali yapıları küçük anomali yapıların belirlenebilmesi için hem yerel hem de görüntü içerisinde tekrar eden global ilişkilerin de birlikte modellenenebilmesi için Transformer tabanlı bir yapı kullanılmıştır.



Şekil 13. Vision transformer mimarisiyle örnek bir girdinin özellik çıkarım süreci

Transformer mimarisindeki temel görev, görüntüdeki farklı bölgeler arasındaki uzun menzilli ilişkileri self-attention(öz-dikkat) mekanizmasıyla öğrenebilmektedir (Sravanı vd., 2025; Nikolakis vd., 2025; Hanbay vd., 2016). Girdi görüntüsü öncelikle sabit boyutlu parçalara ayrılmaktadır. İlk aşamada, giriş görüntüsü $I \in \mathbb{R}^{H \times W \times C}$, anomali bölgelerini denetimsiz olarak tespit etmek için $P \times P$ boyutunda yamalara bölünür. Görüntüde elde edilen toplam yama sayısı $N = \frac{H \times W}{P^2}$ dir. Parça tabanlı temsil yaklaşımı sayesinde görüntü daha düzenli ve düşük boyutlu alt bileşenlere ayrıştırılmakta, böylece Transformer yapısının uzun menzilli ilişkileri daha etkin

biçimde öğrenmesi sağlanmaktadır. Ayrıca parça tabanlı yapı, yüzey üzerindeki küçük anomalilerin ayrı bölgesel temsiller halinde analiz edilmesine imkân tanımaktadır. Görüntüdeki yerel desenler, alt ve düzenlilik özellik temsillerine aktarılır. Parça temsilleri, (15)'teki temsil vektörünü elde etmek için evrişimsel projeksiyondan geçirilir.

$$Z_i = W_p X_i + b_p \quad (15)$$

Burada, X_i giriş temsili; W_p öğrenilebilir projeksiyon ağırlıklarını; b_p sapma terimini ve Z_i elde edilen temsil vektörünü ifade eder. Bu dönüşüm sayesinde görüntü yamaları, Transformer encoder katmanları tarafından işlenebilecek latent temsil vektörlerine dönüştürülmektedir. Öğrenilebilir projeksiyon işlemi, farklı kumaş dokularına ait ayırt edici özelliklerin otomatik olarak öğrenilmesini sağlamaktadır. Transformer mimarisinde yalnızca patch içerikleri değil, aynı zamanda yamaların uzamsal konum bilgileri de önem taşımaktadır. Çünkü Transformer yapısı doğrudan konvolüsyon işlemleri kullanmadığından, doğal olarak uzamsal ilişki bilgisine sahip değildir. Bu nedenle embedding vektörlerine konumsal kodlama (positional encoding) (16)'daki gibi eklenmektedir. Başlangıç temsil vektörü aşağıdaki şekilde oluşturulmaktadır:

$$z_0 = [x_{class}; x_p^1 E; x_p^2 E; \dots ; x_p^N E] + E_{pos} \quad (16)$$

Burada E_{pos} , konumsal kodlama matrisini temsil etmektedir. Konumsal kodlama sayesinde model, parçaların görüntü üzerindeki göreceli konumlarını öğrenebilmekte ve uzamsal ilişkileri daha doğru biçimde modelleyebilmektedir.

Transformer mimarisindeki öz dikkat sayesinde, giriş görüntülerindeki uzun menzilli ilişkiler, sorgu, değer ve anahtar matrisleri aracılığıyla (17)'deki gibi modellenir. Burada, Q, K ve V sırasıyla sorgu (query), anahtar (key) ve değer (value) matrislerini; ve d_k ölçeklendirme faktörünü temsil eder. Anomali yeri testi için transformer kodlayıcı katmanından elde edilen çıktılar kullanıldı.

$$Attention(Q, K, V) = Softmax\left(\frac{QK^T}{\sqrt{d_k}}\right)V \quad (16)$$

Sorgu ve anahtar matrislerinin çarpımı sayesinde parçalar arasındaki benzerlik ilişkileri hesaplanmaktadır. Softmax işlemi ile dikkat ağırlıkları normalize edilmekte ve elde edilen ağırlıklar değer matrisi ile çarpılarak dikkat çıktısı elde edilmektedir. Bu mekanizma sayesinde

model, görüntü üzerindeki önemli dokusal bölgeleri daha yüksek ağırlıklarla temsil edebilmekte ve kusurlu alanlara odaklanabilmektedir.

Özellikle kumaş yüzey kusurlarında çizgisel deformasyonlar, düzensiz doku bozulmaları ve tekrar eden anomaliler farklı uzamsal bölgelerde ortaya çıkabilmektedir. Self-attention mekanizması sayesinde uzak bölgeler arasındaki ilişkiler aynı anda öğrenilmekte ve global bağlamsal temsil oluşturulmaktadır. Bu durum, yalnızca yerel filtreleme yapan klasik CNN tabanlı yapılara kıyasla önemli bir avantaj sağlamaktadır.

Transformer kodlayıcı blokları içerisinde ayrıca artık(residual) bağlantılar ve katman normalizasyonu kullanılmaktadır. Residual bağlantı gradient kaybını azaltmaktadır ve katman normalizasyonu ise öğrenme sürecinde istikrarı sağlamaktadır. Residual bağlantı ve katman normalizasyonu sırasıyla (17) ve (18)'de elde edilmektedir. Residual bağlantı ve katman normalizasyonu sayesinde derin Transformer katmanlarında bilgi akışı korunabilmektedir.

$$Z'_l = \text{Attention}(Z_{l-1}) + Z_{l-1} \quad (17)$$

$$Z_l = \text{LayerNorm}(Z'_l) \quad (18)$$

Önerilen Transformer tabanlı yapı sayesinde hem yerel dokusal örüntüler hem de küresel bağlamsal ilişkiler birlikte öğrenilerek daha güçlü ve genelleştirilebilir anomali temsilleri elde edilmektedir.

3.5.3. Memory-Bank Tabanlı Anomali Tespiti

Tezin bu bölümünde geliştirilen denetimsiz arıza tespit modülünde en kilit özellik şudur ki sadece sağlıklı kumaş görselleri kullanılarak arızalı olan tüm örneklerin tespitinin sağlanmasıdır. Böylelikle daha önceden görülmemiş ya da az sayıda nadir örnek bulunduran kumaş arızaları durumlarının da etkili şekilde tespit edilebilmektedir (Li vd., 2024). Bu durum ise endüstriyel çözüm geliştiren uygulamalar için büyük bir fırsat sunmaktadır. Çünkü endüstriyel uygulamalarda bazı kumaş arızalarının örnek sayısı oldukça azdır veya bulunmamaktadır. Literatürdeki birçok uygulama kumaş arızalı bölgelerin tespit veya sınıflandırılması için ise derin öğrenme tabanlı modelleriyle büyük miktarda arızalı görüntü örneklerine ihtiyaç duymaktadır. Transformer özellik çıkarım işleminin ardından elde edilen normalize edilmiş özellik vektörleri memory-bankta saklanmıştır. Özellik vektörü x 'in normalize edilmesi (19) ile yapılarak $\hat{x}$ elde edilmektedir. Normalize edilen özellikler sayesinde

farklı örnekler arasındaki ölçek farklılıkları azaltılarak daha kararlı benzerlik hesaplamaları gerçekleştirilmektedir.

$$\hat{x} = \frac{x}{\|x\|_2} \quad (18)$$

Memory bank yapısı yalnızca normal örneklerin temsil vektörlerini içermektedir. Test aşamasında elde edilen özellikler ile memory bank içerisindeki referans özellikler arasındaki benzerlik hesaplanmaktadır. Bu işlem için (19)'daki Öklid mesafesi kullanılmaktadır.


$$d(x, m_i) = \|x - m_i\|_2 \quad (19)$$

Burada m_i , memory bank içerisindeki referans özelliği temsil etmektedir. Eğer test görüntüsünden elde edilen özellikler normal veri dağılımından uzaklaşıyorsa, bu durum anomali bölgesinin varlığına işaret etmektedir.

Her parça için en yakın komşuların ortalama uzaklığı hesaplanarak similarity tabanlı anomali skoru (20) ile elde edilmektedir.

$$S_{mem}(x) = \frac{1}{k} \sum_{i=1}^k d(x, m_i) \quad (20)$$

Bu yaklaşım sayesinde normal veri dağılımından sapma gösteren bölgeler yüksek anomali skoru üretmektedir. Özellikle dokusal bozulmaların bulunduğu kumaş yüzeylerinde bu yapı oldukça etkili sonuçlar vermektedir.



Şekil 14. Memory-bank tabanlı anomali skoru hesaplanması

3.5.4. Mahalanobis Mesafesi ile İstatistiksel Dağılım Modellemesi

Kumaş yüzeylerindeki arızalar çoğunlukla düzensiz yapıda olması, düşük kontrastlı olması ve normal kumaş görüntüleriyle arızalı kumaş görüntülerinin birbirine yüksek benzerlikte olması sebepleriyle sadece Öklid mesafesi yöntemiyle normal ve arızalı kumaş ayırımı yapabilmek oldukça güç ve yetersizdir. Özellikle veri dağılımının varyans yapısını dikkate almayan klasik benzerlik ölçümleri, karmaşık yüzey yapılarında yanlış pozitif sonuçların artmasına yol açabilmektedir. Bu nedenle önerilen yöntemde, normal veri dağılımının kovaryans yapısını dikkate alan Mahalanobis mesafesi kullanılarak daha güçlü bir istatistiksel anomali modelleme yaklaşımı geliştirilmiştir.

Mahalanobis mesafesi, bir örneğin veri dağılımının merkezinden ne kadar uzaklaştığını ölçen istatistiksel bir uzaklık metriğidir (Hou vd., 2020; Kamoi ve Kobayashi, 2020). Bu yöntem klasik Öklid mesafesinden farklı olarak yalnızca iki nokta arasındaki geometrik uzaklığı değil, aynı zamanda veri dağılımının varyansını ve özellikler arasındaki korelasyonu da dikkate almaktadır. Böylece veri dağılımında doğal olarak yüksek varyansa sahip özelliklerin etkisi azaltılırken, düşük varyanslı ve ayırt edici özelliklerin etkisi artırılmaktadır. Bu durum özellikle

küçük ölçekli ve düşük kontrastlı kumaş kusurlarının daha hassas biçimde belirlenmesine önemli katkı sağlamaktadır.

Önerilen yöntemde ilk olarak yalnızca sağlıklı kumaş örneklerinden elde edilen parça tabanlı temsil vektörleri kullanılmaktadır. Transformer kodlayıcı katmanlarından elde edilen bu özellikler, normal veri dağılımının öğrenilmesi amacıyla istatistiksel analiz sürecine aktarılmaktadır. Sağlıklı örneklerden elde edilen özellik vektörlerinin ortalama temsili (21)'deki gibi hesaplanmaktadır.

$$\mu = \frac{1}{N} \sum_{i=1}^N m_i \quad (21)$$

Denklem (21)'deki N , memory bank içerisindeki toplam örnek sayısı iken her bir normal özellik vektörü ise m_i 'dir. Ortalama vektör μ sağlıklı örneklerin genel özellik dağılımının merkezini temsil etmektedir. Böylelikle modelimiz, normal özellikteki kumaşın istatistiksel merkezini öğrenebilmektedir. Sadece normal özellikteki kumaşın istatistiksel ortalama değerinin bilinmesi arızalı örnekleri saptayabilmek için yeterli olmamaktadır. Bu nedenle veri dağılımının varyans ve korelasyon yapısını modellemek amacıyla kovaryans matrisi (22)'deki gibi hesaplanmaktadır.

$$\Sigma = \frac{1}{N-1} \sum_{i=1}^N (x_i - \mu)(x_i - \mu)^T \quad (22)$$


Denklem (22)'deki Σ , kovaryans matrisini temsil etmektedir. Kovaryans matrisi, özellikler arasındaki ilişkileri ve dağılımın yayılım yapısını modellemektedir (Kaynar vd., 2017; Tastimur vd., 2023). İki özelliğin aynı anda değişim göstermesi halinde kovaryans değeri yüksek olur ancak bağımsız şekilde özellikler değişim gösterirse kovaryans özellikleri düşük olur. Böylelikle modelimizi özellikler arasındaki istatistiksel özelliklerini de öğrenebilmektedir.

Kovaryans matrisinin hesaplanmasının ardından test görüntüsünden elde edilen özelliklerin normal veri dağılımından ne kadar saptığı Mahalanobis mesafesi ile ölçülmektedir. Mahalanobis mesafesi (23)'teki gibi hesaplanmaktadır.

$$D_M(x) = \sqrt{(x - \mu)^T \Sigma^{-1} (x - \mu)} \quad (23)$$

Burada x , test görüntüsünden elde edilen özellik vektörünü; μ , normal veri dağılımının ortalama vektörünü ve Σ^{-1} , kovaryans matrisinin tersini temsil etmektedir. Mahalanobis mesafesi, test örneğinin normal veri dağılımına olan istatistiksel uzaklığını ölçmektedir. Eğer elde edilen mesafe değeri yüksekse, bu durum ilgili parça bölgesinin normal veri dağılımından önemli ölçüde saptığını ve potansiyel bir kusur içerdiğini göstermektedir.

Mahalanobis tabanlı analiz yapılmasının katkılarında birisi de şudur ki düşük kontrastlı görüntülerde normal özellikteki yüzey yapısı anomali yapılarla benzerlik gösterse de istatistiksel açıdan incelendiğinde değerlerde bazı sapmalar olduğu fark edilebilmektedir. İnce arızaların dağılımını etkili şekilde tespit edilebilmesiyle ince iplik hataları ve küçük dokusal anomalilerin tespitinde model performansını önemli ölçüde artırmaktadır.



Şekil 15. Mahalanobis mesafesi tabanlı anomali skoru hesaplanması

3.5.5. Öğrenilebilir Füzyon Tabanlı Anomali Skorlama

Önerilen denetimsiz anomali yaklaşımında sadece tek bir anomali skoruna göre değerlendirme yapılmayıp birkaç temsil mekanizmasından elde edilen bilgiler birlikte kullanılarak güvenli ve kararlı anomali tespiti yapılmıştır. Kumaş yüzeyindeki küçük ölçekteki arızaları, düşük kontrastlı arızaları ve düzensiz yapıdaki deformasyonların tespiti sağlanmıştır. Memory-bank tabanlı benzerlik analizi ile normal veri örneklerinden uzaklaşan anomalilerin; Mahalanobis uzaklık hesabıyla ise veri dağılımı dikkate alınıp düşük kontrastlı anomalilerin tespitinde, farklı anomali skorlarının adaptif şekilde birleştirilmesiyle sağlanmıştır.

Önerilen füzyon yaklaşımının ilk basamağı, transformer kodlayıcı çıkışından elde edilen temsil sapma skorunun bulunmasıdır. Görüntü içindeki uzun menzilli bağlamsal ilişkiler öğrenilerek normal yüzey arızalarından farklılık gösterilen bölgelerin yüksek temsil sapması üretmektedir.

Bu yapı özellikle küresel dokusal bozulmaların ve geniş alanlı anomalilerin belirlenmesinde etkili sonuçlar vermektedir.

İkinci aşamada ise memory-bank tabanlı benzerlik analizinin; sağlıklı görüntülerin özellik vektörlerinin hafıza yapısında saklanmasıyla oluşmaktadır. Test görüntüsünden elde edilen özellikler ile memory bankta bulunan normal özellik haritaları karşılaştırılıp benzerlik tabanlı bir anomali skoru hesaplanmaktadır. Memory bank yapısı özellikle normal veri dağılımından lokal olarak sapma gösteren küçük kusur bölgelerinin belirlenmesinde önemli avantaj sağlamaktadır.

Son anomali ölçütünde ise Mahalanobis mesafesi ile veri dağılımdaki kovaryans hesabındaki istatistiksel sapmalardan yalnızca geometrik uzaklık değil, aynı zamanda özellikler arasındaki korelasyon yapıları da analiz edilmektedir. Bu yaklaşım düşük kontrastlı ve karmaşık yüzey örüntülerine sahip anomalilerin daha hassas biçimde belirlenmesine katkı sağlamaktadır.

Farklı anomali skorların geleneksel füzyon yaklaşımda sabit ağırlık değerleriyle birleştirilmesi yerine bu çalışmada, eğitim sürecinde otomatik olarak optimize edilen öğrenilebilir parametreler kullanılmıştır. İlk olarak füzyon ağırlıkları (24)'teki gibi normalize edilmektedir.


$$w_i = \frac{e^{\alpha_i}}{\sum_{j=1}^n e^{\alpha_j}} \quad (24)$$

Burada α_i , öğrenilebilir parametreleri; w_i ise normalize edilmiş füzyon ağırlıklarını temsil etmektedir. Softmax tabanlı normalizasyon işlemi sayesinde tüm ağırlıkların toplamı 1'e eşitlenmektedir. Bu yapı sayesinde model, farklı anomali ölçütlerinin önem derecelerini veri dağılımına göre otomatik olarak öğrenebilmektedir. Normalize edilen ağırlıklar kullanılarak nihai anomali skoru (25)'teki gibi elde edilmektedir.

$$S_{final} = w_1 S_{trans} + w_2 S_{mem} + w_3 S_{mah} \quad (25)$$

Burada S_{trans} , Transformer temsil sapmasını; S_{mem} , memory bank benzerlik skorunu ve S_{mah} , Mahalanobis mesafesi tabanlı istatistiksel anomali skorunu temsil etmektedir. Bu hibrit yapı sayesinde farklı anomali analiz yöntemlerinin tamamlayıcı özellikleri birlikte kullanılmakta ve daha güçlü anomali temsilleri elde edilmektedir.

Önerilen füzyon yapısı sayesinde, her veri setinin özelliklerine göre adaptif olarak ağırlık dağılımların belirlenmesi avantajı bulunmaktadır. Veri dağılımına adaptif şekilde uyum sağlayarak kumaştaki dokusal bozulmalar daha baskın hale gelirken istatistiksel dağılım farklılıkları daha belirgin hale gelmektedir. Böylece modelin genelleme performansı artarken farklı arıza türlerine karşın daha kararlı sonuçlar üretebilmektedir. Farklı anomali analiz skorlarının birleştirilmesiyle daha güvenilir anomali haritaları oluşturulmuştur. Bu yapı sayesinde hem yerel dokusal anomalilerin hem de küresel bağlamsal sapmaları aynı anda analiz edilebilmesi sağlanmıştır.



Şekil 16. Önerilen üçlü füzyon tabanlı anomali tespit mimarisi

3.5.6. Denetimli Kumaş Arıza Sınıflandırma Sistemi

Önerilen kumaş arızası metodolojisinin ikinci aşamasında, arıza türlerinin sınıflandırılması hedeflenmiştir. Endüstriyel akıllı üretim süreçlerinde arızanın sadece tespit edilmesi yeterli olmamakla birlikte arızanın hangi kategoriye ait olduğunun da belirlenmesi büyük önem taşımaktadır. Çünkü farklı kumaş kusurları üretim süreçlerinde farklı kalite problemlerine işaret etmekte ve uygulanacak düzeltici işlemler kusur türüne göre değişmektedir. Bu nedenle önerilen çalışmada hem yerel dokusal özellikleri hem de görüntü genelindeki bağlamsal

ilişkileri birlikte öğrenebilen hibrit bir CNN-Transformer tabanlı derin öğrenme mimarisi geliştirilmiştir.

Sınıflandırmanın ilk aşamasında giriş görüntüsü CNN tabanlı bir yapı ile özellik çıkarımı yapılmaktadır. Konvolüsyon filtreleri ile görüntüdeki kenar, köşe, doku ve şekillerin çıkarılması gerçekleştirilmiştir. CNN katmanları sayesinde kumaş yüzeyindeki küçük arızalar, dokusal bozulmalar etkin şekilde öğrenilebilmektedir. CNN tarafından elde edilen özellikler Kanal dikkat mekanizmasına aktarılır. Kanal dikkat mekanizmasının amacı, özellik haritalarındaki önemli kanalların adaptif olarak ağırlıklandırılarak arızalı bölgelerin ayırt edici hale gelmesi sağlanmıştır. Görüntüdeki önemli olan özelliklerin etkisi artırılıp gereksiz arka plan bölgelerin etkisi azaltılmaktadır.

Kanal dikkat mekanizmasıyla önemli yerlerin vurgulandığı görüntüler, Transformer kodlayıcı katmanına aktararak görüntüdeki tüm bölgeler arasındaki ilişkiler self-attention mekanizmasıyla desteklenmektedir. Self-attention mekanizması sayesinde model, görüntü içerisindeki uzak bölgeler arasındaki ilişkileri aynı anda analiz edebilmekte ve küresel bağlamsal özellikleri öğrenebilmektedir.

Transformer kodlayıcı ile elde edilen özellikler ise global ortalama havuzlama katmanına ve tam bağlantılı katmana iletilmiştir. Daha sonra da Softmax sınıflandırıcı ile çok-sınıflı arıza sınıflandırma işlemi tamamlanmıştır.

4. DENEYSEL SONUÇLAR

Tezin bu bölümünde, metal ve kumaş yüzey arızalarının otomatik tespit ve sınıflandırılması sırasında elde edilen ayrıntılı deneysel sonuçlara yer verilmiştir. Kumaş ve metal yüzey arızası bulunduran veri setlerinin özellikleri hakkında detaylı bilgiler, veri setindeki görüntülerin önerilen modellerle eğitilmesinde hazır hale getirme için uygulanan ön işleme teknikleri, eğitim sırasında kullanılan hiper parametre değerleri ve performans değerlendirme metrikleri hakkında detaylı bilgiler de sunulmuştur.

İlk olarak metal yüzey arızalarının tespit ve sınıflandırıldığı yönteme ilişkin hem literatürdeki (state-of-the-art) SOTA modelleriyle hem de klasik CNN mimarisiyle karşılaştırmalı olarak performans analizi gerçekleştirilmiştir. Benzer şekilde; önerilen kumaş yüzey arıza tespit ve sınıflandırma performansı SOTA modellerin performansları karşılaştırılmıştır.


4.1. Metal ve Kumaş Veri setleri

Metal yüzey arızalarının analiz edilmesi için literatürde yaygın olarak kullanılan yedi farklı arıza bulunduran X-SDD veri seti kullanılmıştır. Kumaş veri setleri için ise birisi normal dördü arızalı olmak üzere beş farklı sınıfın bulunduğu yeni bir kumaş arıza veri seti bu çalışma için oluşturulmuştur. Kullanılan veri setleri, farklı yüzey yapıları, dokusal örüntüler ve kusur karakteristikleri içermesi nedeniyle önerilen modellerin genelleme performansını değerlendirmek açısından önemli avantaj sağlamaktadır.


X-SDD veri seti (Feng vd., 2021) oxide scale of temperature system, finishing roll printing, oxide scale of plate system, surface scratches, iron sheet ash, red iron sheet ve slag inclusions türündeki arızaları içermektedir. Metal yüzeylerindeki farklı geometrik şekiller, kontrast seviyeleri ve yüzey bozulmaları barındırmaktadır. Bu durumlar veri setindeki arızaların etkili şekilde sınıflandırılabilmesini karmaşık bir problem haline getirmektedir. Bu nedenle veri seti, önerilen attention destekli Kolmogorov-Arnold ağı tabanlı modelin performansını değerlendirmek için uygun bir test ortamı sunmaktadır. Şekil 17’ de metal yüzey arıza X-SDD veri setinden örnek görseller paylaşılmıştır.

Kullanılan kumaş veri setindeki arızalarından birisi normal türdeki kumaş görsellerinden oluşurken diğer dört arıza ise hole, horizontal, stain ve wrinkle türündedir. Veri setindeki görsellerde arızalı bölgeler farklı yönelimlerde ve değişken kontrast seviyelerinde olduğundan

sınıflandırma aşamasını zorlaştırmaktadır. Şekil 18’ de kumaş yüzey arızası veri setine ait örnek görseller sunulmuştur.



Şekil 17. X-SDD veri setinden örnek görseller. a) finishing roll printing, b) inclusion, c) iron sheet ash, d) oxide scale of plate system, e) oxide scale of temperature system, f) red iron sheet, g) scratches




Şekil 18. Kullanılan kumaş veri setinden örnek görseller. a) good, b) hole, c) horizontal, d) stain, e) wrinkle

Çalışmada kullanılan tüm veri setleri eğitim, doğrulama ve test olmak üzere farklı alt kümelere ayrılmıştır. Eğitim kümesi model parametrelerinin öğrenilmesi amacıyla kullanılırken, doğrulama kümesi hiper parametre optimizasyonu ve aşırı öğrenmenin kontrol edilmesi amacıyla değerlendirilmiştir. Test kümesi ise modelin daha önce görmediği görüntüler üzerindeki genelleme performansını ölçmek amacıyla kullanılmıştır. Veri setlerinin dengeli biçimde ayrılması sayesinde model performansının daha güvenilir biçimde değerlendirilmesi hedeflenmiştir.

4.2. Veri Ön İşleme ve Veri Artırma Teknikleri

Metal ve kumaş yüzey arızalarının tespit edilmesinde farklı aydınlatma koşulları ve çözünürlük özellikte olduğundan tüm görüntülerin ortak bir standartta olması için veri ön işleme adımları uygulanmıştır. İki veri setine de veri miktarının sınırlı olması, kusurların düşük kontrastlı yapıda bulunması ve bazı kusur türlerinin sınıf dengesizliği içermesi nedeniyle veri artırma işlemleri gerçekleştirilmiştir. Her görüntü öncelikle standart bir görüntü boyutuna yeniden ölçeklendirilmiştir. Veri artırma işlemi için öncelikle görüntüyü rastgele yatay çevirme, sınırlı ölçüde dikey çevirme, parlaklık ve kontrast dönüşümü de uygulanmıştır. Böylece modellerin farklı aydınlatma koşullarına karşı dayanıklılık sağlandığı ve modelin görüntüler üzerinde dayanıklılığı arttırılmıştır. Ayrıca veriler üzerinde modelin aşırı öğrenmeyi engellenmesi için düşük olasılıklı olarak görüntüdeki küçük bölgelerin rastgele silme işlemi yapılmıştır. Farklı görüntüler arasındaki piksel dağılımları dengelenmiş ve eğitim sürecinin daha kararlı hale gelmesi için görüntüler normalize edilmiştir. Bu sayede görüntünün farklı görüntü varyasyonlarına karşı dayanıklılığı arttırılıp modelin genelleme performansı güçlendirilmiştir.



Şekil 19. Veri setlerine uygulanan ön işleme ve veri artırım teknikleri

4.3. Deneysel Ortam ve Eğitim Parametreler

Önerilen metal ve kumaş yüzey kusur analiz sistemlerinin eğitimi ve performans değerlendirilmesinde grafik işlem birimi destekli bir derin öğrenme ortamı kullanılmıştır. Modellerin geliştirilmesinde Python programlama dili, Pytorch, OpenCV, NumPy, torchvision ve scikit-learn kütüphanelerinden faydalanılmıştır. Önerilen çalışmalar, SOTA yöntemlerinden transfer öğrenme mimarileri ile performans çıktıları karşılaştırılmıştır. Eğitim sürecinde adil bir karşılaştırma olabilmesi için önerilen yöntem ve SOTA modellerinin ortak parametrelerle kurulmuştur. Test kümesi ise modellerin daha önce görmediği görüntüler üzerindeki genelleme performansını analiz etmek amacıyla kullanılmıştır.

Optimizasyon aşamasında AdamW optimizasyon algoritması, sınıflandırma aşamasında kayıp fonksiyonu olarak çapraz entropi kaybı, aşırı öğrenmenin engellenmesi için Dropout katmanları

ve veri arttırım işlemleri, 224x224 boyutlu girdi görüntüleri, 32 batch boyutu, ReLU aktivasyon fonksiyonu, Metal arızaların sınıflandırılmasında 20 iterasyon ve Kumaş arızaların sınıflandırılmasında 50 iterasyon ile önerilen modellerin eğitim gerçekleştirilmiştir.

4.4. Değerlendirme Metrikleri

Bu çalışmada önerilen metal ve kumaş yüzey kusur analiz sistemlerinin performansını değerlendirebilmek amacıyla farklı performans metrikleri kullanılmıştır. Sınıflandırma ve anomali tespit problemlerinde yalnızca doğruluk oranının değerlendirilmesi yeterli olmadığından, modelin farklı açılardan analiz edilebilmesi için precision, recall, F1-score ve ROC-AUC gibi metriklerden yararlanılmıştır. Ayrıca karmaşıklık matrisi (confusion matrix), attention haritaları ve anomali yoğunluk görselleri kullanılarak modellerin görsel açıklanabilirlik performansları da değerlendirilmiştir.

Sınıflandırma performansının değerlendirilmesinde kullanılan temel metriklerden biri doğruluk oranıdır. Accuracy, doğru sınıflandırılan örneklerin toplam örnek sayısına oranını ifade etmektedir. Bu metrik (26) ile hesaplanmaktadır.

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (26)$$

Burada TP doğru pozitif, TN doğru negatif, FP yanlış pozitif ve FN yanlış negatif değerlerini temsil etmektedir. Accuracy metriği genel performansı göstermesine rağmen özellikle sınıf dengesizliği bulunan veri setlerinde tek başına yeterli olmamaktadır.

Bu nedenle precision metriği de değerlendirilmiştir. Precision, modelin pozitif olarak tahmin ettiği örneklerin ne kadarının gerçekten doğru olduğunu göstermektedir. Precision değeri (27) ile hesaplanmaktadır.

$$Precision = \frac{TP}{TP + FP} \quad (27)$$

Yüksek precision değeri modelin yanlış alarm üretme oranının düşük olduğunu göstermektedir. Özellikle endüstriyel hata tespit sistemlerinde yanlış pozitif tahminlerin azaltılması büyük önem taşımaktadır. Bir diğer önemli değerlendirme metriği recall değeridir. Recall, gerçek

pozitif örneklerin ne kadarının doğru şekilde tespit edildiğini göstermektedir. Recall metriği (28)' deki gibi ifade edilmektedir.

$$Recall = \frac{TP}{TP + FN} \quad (28)$$

Yüksek recall değeri modelin kusurlu bölgeleri kaçırmadan tespit edebildiğini göstermektedir. Özellikle düşük kontrastlı ve küçük ölçekli kusurların bulunduğu yüzey analizlerinde recall metriği kritik öneme sahiptir.

Precision ve recall değerlerinin dengeli biçimde değerlendirilebilmesi amacıyla F1-score metriği kullanılmıştır. F1-score, precision ve recall değerlerinin harmonik ortalamasını (29)'daki gibi ifade etmektedir.

$$F1 = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (29)$$

F1-score metriği özellikle sınıf dağılımının dengesiz olduğu veri setlerinde daha güvenilir performans değerlendirmesi sağlamaktadır.

Denetimsiz anomali tespit sisteminin performansını değerlendirebilmek amacıyla ROC-AUC metriği de kullanılmıştır. ROC eğrisi, farklı eşik değerlerinde doğru pozitif oranı ile yanlış pozitif oranı arasındaki ilişkiyi göstermektedir. Eğri altında kalan alan (AUC) değeri modelin ayırt edici performansını ifade etmektedir. Yüksek AUC değeri modelin normal ve anomalili örnekleri başarılı şekilde ayırabildiğini göstermektedir.

Bunun yanında önerilen modellerin sınıf bazlı performanslarını daha ayrıntılı inceleyebilmek amacıyla karmaşıklık matrisi (Confusion Matrix) analizleri gerçekleştirilmiştir. Karmaşıklık matrisi sayesinde hangi kusur sınıflarının daha başarılı öğrenildiği ve hangi sınıflar arasında karışmalar olduğu analiz edilmiştir. Özellikle benzer dokusal yapılara sahip kusur türlerinin sınıflandırılması sırasında oluşan hata dağılımları detaylı biçimde incelenmiştir.


4.5. Metal Yüzey Kusur Tespit ve Sınıflandırma Sonuçları

Bu bölümde, metal yüzey arızalarının tespitinde ve sınıflandırılmasında önerilen attention-tabanlı Kolomogorov-Arnold ağı ile SOTA modellerinin kıyaslanması için detaylı performans


sonuçları sunulmuştur. Deneysel çalışmalar sırasında literatürde metal yüzey arızaları için sıklıkla kullanılan X-SDD arıza veri seti kullanılmıştır. Düşük kontrastlı yapılar, düzensiz geometrik örüntüler, karmaşık yüzey deformasyonları ve küçük ölçekli anomaliler içermesi nedeniyle sınıflandırma açısından oldukça zor bir problem oluşturmaktadır. Çalışmada önerilen modelin performansını değerlendirmek amacıyla ResNet50, DenseNet121, DenseNet169, EfficientNetV2-S, MobileNetV3, ConvNeXtV2-Nano, Vision Transformer (ViT), DeiT ve Swin Transformer gibi farklı derin öğrenme mimarileri ile karşılaştırmalı analizler gerçekleştirilmiştir. Tüm modeller aynı veri bölünmeleri, benzer eğitim parametreleri ve aynı veri artırma stratejileri kullanılarak eğitilmiştir. Böylece elde edilen sonuçların adil ve güvenilir biçimde değerlendirilmesi amaçlanmıştır.

4.5.1. Karşılaştırmalı Model Sonuçları


Metal yüzey arızası X-SDD veri seti ve önerilen modelle ortak parametreler kullanılarak Swin transformer, Vision transformer, DeiT transformer, ResNet50, Inception V3, MobileNetV3, EfficientNet, DenseNet169, DenseNet121 ve ConvNeXt mimarileri seçilmiştir. Bu modellerin 20 epoch(iterasyon) boyunca eğitim ve doğrulama doğruluk eğrileri karşılaştırmalı olarak Şekil 20, Şekil 21, Şekil 22 ve Şekil 23'te karşılaştırmalı olarak verilmiştir. Bu modellerin X-SDD ile eğitimi sırasında transfer öğrenme ile sıfırdan eğitim gerçekleştirilmiştir. Önerilen modelde olduğu gibi bu modellerde de sıfırdan X-SDD veri setindeki arızaların öğrenilmesi amaçlanmıştır.




Şekil 20. Karşılaştırılan modellerinin X-SDD veri setindeki eğitim doğrulukları



Şekil 21. Karşılaştırılan modellerinin X-SDD veri setindeki doğrulama doğrulukları




Şekil 22. Karşılaştırılan modellerinin X-SDD veri setindeki eğitim ve doğrulama eğrisi



Şekil 23. X-SDD veri setinde modellerin bar grafikleriyle karşılaştırılması

En iyi performansı %83,4 eğitim doğruluğu oranıyla DenseNet169 mimarisi ulaşırken diğer modellerin ise ortalama %70 civarında başarı elde edebildiği gözlemlenmiştir. Swin transformer, DeiT transformer ve klasik transformer mimarileri ise ortalama bir performans göstermiştir. Ancak en düşük performansı %59 eğitim doğruluk oranıyla ConvNeXt mimarisi elde etmiştir. Şekil 24’ te ise tüm karşılaştırılan modellerin ortak ROC eğrileri sunulmuştur. Eğitim ve doğrulama doğrularından elde edilen performansa paralel olarak ROC eğrisinde de en iyi performansı %94,7 AUC değeriyle yine Swin transformer ulaşabilmiştir.



Şekil 24. X-SDD veri setinde modellerin ortak ROC eğrisi karşılaştırılması

Şekil 25’ te ise her bir modelin karışıklık matrisleri tek tek sunulmuştur. Toplam 194 adet test örneği içerisinde ConvNeXt mimarisi 104 adet yanlış pozitif örneklere rastlanmıştır. Burada büyük oranda modelin yanlış sınıflara yanlış örnekler atadığı anlamına gelmektedir. Deit mimarisinde 90 adet yanlış atanmış örnekler bulunmaktadır. Yine çoğunlukla ConvNeXt mimarisindeki yanlış atanan sınıflara benzer bir paralellik göstermektedir. Diğer mimarilere göre nispeten yüksek başarı gösteren DenseNet121 ve DenseNet169 mimarilerinden yanlış atanan örneklerin sayısı sırasıyla 38 ve 46’ dır. EfficientNet mimarisinde 80 örnek yanlış sınıflandırılırken InceptionV3 mimarisinde 56 örnek yanlış sınıflandırılmıştır. MobileNet

modelinden 96 örnek, ResNet50 modelinden 76 örnek yanlış sınıflandırılmıştır. Swin transformer mimarisinden 70 örnek ve 76 örnek yanlış sınıflandırılmıştır. Tüm bu sonuçlar göz önüne alındığından ROC eğrisi ve eğitim-doğrulama doğruluk eğrisi sonuçlarına paralel şekilde en iyi sonucu DenseNet mimarileriyle elde edildiği ortaya çıkmıştır.

Tüm sonuçlar incelendiğinde; tüm modellerin genellikle ‘finishing roll printing’ sınıfını ve ‘red iron sheet’ arıza sınıflarını kolaylıkla ayırt edebildiği fark edilmiştir. Ancak ayırt ediciliği en düşük olan sınıflar da mevcuttur: ‘oxide scaled plate system’ sınıfında modellerin neredeyse bir veya iki örneği ayırt edebildiği ancak diğer tüm örnekleri diğer arızalarla karıştırarak yanlış etiketlediği fark edilmiştir.

Gerçek Etiket	FinishingRollPrinting	Inclusion	IronSheetAsh	oxideScaledPlateSystem	oxideScaledTemperatureSystem	redIronSheet	scratches
FinishingRollPrinting	23 (79.3%)	1 (3.4%)	0 (0.0%)	0 (0.0%)	5 (17.2%)	0 (0.0%)	0 (0.0%)
Inclusion	2 (5.9%)	14 (41.2%)	0 (0.0%)	0 (0.0%)	7 (20.6%)	11 (32.4%)	0 (0.0%)
IronSheetAsh	2 (12.5%)	6 (37.5%)	0 (0.0%)	0 (0.0%)	7 (43.8%)	1 (6.2%)	0 (0.0%)
oxideScaledPlateSystem	0 (0.0%)	7 (87.5%)	0 (0.0%)	0 (0.0%)	1 (12.5%)	0 (0.0%)	0 (0.0%)
oxideScaledTemperatureSystem	10 (34.5%)	1 (3.4%)	0 (0.0%)	0 (0.0%)	16 (55.2%)	2 (6.9%)	0 (0.0%)
redIronSheet	2 (3.6%)	10 (18.2%)	0 (0.0%)	0 (0.0%)	6 (10.9%)	37 (67.3%)	0 (0.0%)
scratches	8 (44.4%)	5 (27.8%)	0 (0.0%)	0 (0.0%)	4 (22.2%)	1 (5.6%)	0 (0.0%)
Tahmin Edilen Etiket	FinishingRollPrinting	Inclusion	IronSheetAsh	oxideScaledPlateSystem	oxideScaledTemperatureSystem	redIronSheet	scratches

(a) ConvNeXt

Gerçek Etiket	FinishingRollPrinting	Inclusion	IronSheetAsh	oxideScaledPlateSystem	oxideScaledTemperatureSystem	redIronSheet	scratches
FinishingRollPrinting	28 (96.6%)	0 (0.0%)	0 (0.0%)	0 (0.0%)	1 (3.4%)	0 (0.0%)	0 (0.0%)
Inclusion	2 (5.9%)	13 (38.2%)	2 (5.9%)	0 (0.0%)	1 (2.9%)	16 (47.1%)	0 (0.0%)
IronSheetAsh	0 (0.0%)	7 (43.8%)	7 (43.8%)	0 (0.0%)	2 (12.5%)	0 (0.0%)	0 (0.0%)
oxideScaledPlateSystem	0 (0.0%)	7 (87.5%)	0 (0.0%)	0 (0.0%)	0 (0.0%)	1 (12.5%)	0 (0.0%)
oxideScaledTemperatureSystem	19 (65.5%)	0 (0.0%)	0 (0.0%)	0 (0.0%)	9 (31.0%)	1 (3.4%)	0 (0.0%)
redIronSheet	7 (12.7%)	5 (9.1%)	0 (0.0%)	0 (0.0%)	2 (3.6%)	40 (72.7%)	1 (1.8%)
scratches	6 (33.3%)	1 (5.6%)	0 (0.0%)	0 (0.0%)	6 (33.3%)	4 (22.2%)	1 (5.6%)
Tahmin Edilen Etiket	FinishingRollPrinting	Inclusion	IronSheetAsh	oxideScaledPlateSystem	oxideScaledTemperatureSystem	redIronSheet	scratches

(b) DeiT

Gerçek Etiket	FinishingRollPrinting	Inclusion	IronSheetAsh	oxideScaledPlateSystem	oxideScaledTemperatureSystem	redIronSheet	scratches
FinishingRollPrinting	29 (100.0%)	0 (0.0%)	0 (0.0%)	0 (0.0%)	0 (0.0%)	0 (0.0%)	0 (0.0%)
Inclusion	1 (2.9%)	30 (88.2%)	0 (0.0%)	0 (0.0%)	0 (0.0%)	2 (5.9%)	1 (2.9%)
IronSheetAsh	14 (87.5%)	0 (0.0%)	2 (12.5%)	0 (0.0%)	0 (0.0%)	0 (0.0%)	0 (0.0%)
oxideScaledPlateSystem	0 (0.0%)	3 (37.5%)	3 (37.5%)	2 (25.0%)	0 (0.0%)	0 (0.0%)	0 (0.0%)
oxideScaledTemperatureSystem	2 (6.9%)	0 (0.0%)	0 (0.0%)	0 (0.0%)	27 (93.1%)	0 (0.0%)	0 (0.0%)
redIronSheet	2 (3.6%)	2 (3.6%)	0 (0.0%)	0 (0.0%)	1 (1.8%)	44 (80.0%)	6 (10.9%)
scratches	0 (0.0%)	1 (5.6%)	0 (0.0%)	0 (0.0%)	0 (0.0%)	0 (0.0%)	17 (94.4%)
Tahmin Edilen Etiket	FinishingRollPrinting	Inclusion	IronSheetAsh	oxideScaledPlateSystem	oxideScaledTemperatureSystem	redIronSheet	scratches

(c) DenseNet121

Gerçek Etiket	FinishingRollPrinting	Inclusion	IronSheetAsh	oxideScaledPlateSystem	oxideScaledTemperatureSystem	redIronSheet	scratches
FinishingRollPrinting	25 (86.2%)	0 (0.0%)	1 (3.4%)	0 (0.0%)	3 (10.3%)	0 (0.0%)	0 (0.0%)
Inclusion	0 (0.0%)	31 (91.2%)	0 (0.0%)	0 (0.0%)	0 (0.0%)	2 (5.9%)	1 (2.9%)
IronSheetAsh	12 (75.0%)	1 (6.2%)	3 (18.8%)	0 (0.0%)	0 (0.0%)	0 (0.0%)	0 (0.0%)
oxideScaledPlateSystem	0 (0.0%)	4 (50.0%)	0 (0.0%)	1 (12.5%)	1 (12.5%)	0 (0.0%)	2 (25.0%)
oxideScaledTemperatureSystem	2 (6.9%)	0 (0.0%)	0 (0.0%)	0 (0.0%)	27 (93.1%)	0 (0.0%)	0 (0.0%)
redIronSheet	1 (1.8%)	1 (1.8%)	0 (0.0%)	0 (0.0%)	2 (3.6%)	43 (78.2%)	8 (14.5%)
scratches	0 (0.0%)	5 (27.8%)	0 (0.0%)	0 (0.0%)	0 (0.0%)	0 (0.0%)	13 (72.2%)
Tahmin Edilen Etiket	FinishingRollPrinting	Inclusion	IronSheetAsh	oxideScaledPlateSystem	oxideScaledTemperatureSystem	redIronSheet	scratches

(d) DenseNet169

Gerçek Etiket	FinishingRollPrinting	27 (91.1%)	0 (0.0%)	1 (3.4%)	0 (0.0%)	1 (3.4%)	0 (0.0%)	0 (0.0%)
	Inclusion	0 (0.0%)	17 (50.0%)	1 (2.9%)	0 (0.0%)	4 (11.8%)	12 (35.3%)	0 (0.0%)
	IronSheetAsh	1 (6.2%)	7 (43.8%)	3 (18.8%)	0 (0.0%)	3 (18.8%)	1 (6.2%)	1 (6.2%)
	oxideScaledPlateSystem	0 (0.0%)	3 (37.5%)	0 (0.0%)	0 (0.0%)	1 (12.5%)	4 (50.0%)	0 (0.0%)
	oxideScaledTemperatureSystem	13 (44.8%)	1 (3.4%)	0 (0.0%)	0 (0.0%)	12 (41.4%)	0 (0.0%)	3 (10.3%)
	redIronSheet	3 (5.5%)	5 (9.1%)	0 (0.0%)	0 (0.0%)	3 (5.5%)	42 (76.4%)	2 (3.6%)
	scratches	4 (22.2%)	4 (22.2%)	0 (0.0%)	0 (0.0%)	5 (27.8%)	1 (5.6%)	4 (22.2%)
		Tahmin Edilen Etiket						

(e) EfficientNet

Gerçek Etiket	FinishingRollPrinting	24 (82.8%)	2 (6.9%)	0 (0.0%)	0 (0.0%)	3 (10.3%)	0 (0.0%)	0 (0.0%)
	Inclusion	0 (0.0%)	28 (82.4%)	0 (0.0%)	0 (0.0%)	0 (0.0%)	5 (14.7%)	1 (2.9%)
	IronSheetAsh	7 (43.8%)	1 (6.2%)	0 (0.0%)	0 (0.0%)	1 (6.2%)	3 (18.8%)	4 (25.0%)
	oxideScaledPlateSystem	1 (12.5%)	2 (25.0%)	0 (0.0%)	1 (12.5%)	0 (0.0%)	3 (37.5%)	1 (12.5%)
	oxideScaledTemperatureSystem	4 (13.8%)	0 (0.0%)	0 (0.0%)	0 (0.0%)	25 (86.2%)	0 (0.0%)	0 (0.0%)
	redIronSheet	5 (9.1%)	2 (3.6%)	0 (0.0%)	0 (0.0%)	0 (0.0%)	48 (87.3%)	0 (0.0%)
	scratches	5 (27.8%)	7 (38.9%)	0 (0.0%)	0 (0.0%)	0 (0.0%)	1 (5.6%)	5 (27.8%)
		Tahmin Edilen Etiket						

(f) InceptionV3

Gerçek Etiket	FinishingRollPrinting	25 (86.2%)	2 (6.9%)	0 (0.0%)	0 (0.0%)	2 (6.9%)	0 (0.0%)	0 (0.0%)
	Inclusion	10 (29.4%)	14 (41.2%)	0 (0.0%)	0 (0.0%)	1 (2.9%)	9 (26.5%)	0 (0.0%)
	IronSheetAsh	10 (62.5%)	0 (0.0%)	0 (0.0%)	0 (0.0%)	5 (31.2%)	1 (6.2%)	0 (0.0%)
	oxideScaledPlateSystem	3 (37.5%)	1 (12.5%)	0 (0.0%)	0 (0.0%)	2 (25.0%)	2 (25.0%)	0 (0.0%)
	oxideScaledTemperatureSystem	8 (27.6%)	0 (0.0%)	0 (0.0%)	0 (0.0%)	14 (46.3%)	7 (24.1%)	0 (0.0%)
	redIronSheet	9 (16.1%)	2 (3.6%)	0 (0.0%)	0 (0.0%)	3 (5.4%)	41 (73.2%)	1 (1.8%)
	scratches	17 (94.4%)	0 (0.0%)	0 (0.0%)	0 (0.0%)	1 (5.6%)	0 (0.0%)	0 (0.0%)
		Tahmin Edilen Etiket						

(g) MobileNet

Gerçek Etiket	FinishingRollPrinting	23 (79.3%)	0 (0.0%)	0 (0.0%)	0 (0.0%)	6 (20.7%)	0 (0.0%)	0 (0.0%)
	Inclusion	1 (2.9%)	27 (79.4%)	0 (0.0%)	0 (0.0%)	1 (2.9%)	5 (14.7%)	0 (0.0%)
	IronSheetAsh	10 (62.5%)	2 (12.5%)	0 (0.0%)	0 (0.0%)	4 (25.0%)	0 (0.0%)	0 (0.0%)
	oxideScaledPlateSystem	0 (0.0%)	3 (37.5%)	0 (0.0%)	0 (0.0%)	2 (25.0%)	3 (37.5%)	0 (0.0%)
	oxideScaledTemperatureSystem	5 (17.2%)	0 (0.0%)	0 (0.0%)	0 (0.0%)	22 (75.9%)	2 (6.9%)	0 (0.0%)
	redIronSheet	1 (1.8%)	4 (7.3%)	0 (0.0%)	0 (0.0%)	8 (14.5%)	41 (74.5%)	1 (1.8%)
	scratches	12 (66.7%)	5 (27.8%)	0 (0.0%)	0 (0.0%)	1 (5.6%)	0 (0.0%)	0 (0.0%)
		Tahmin Edilen Etiket						

(h) ResNet50

Gerçek Etiket	FinishingRollPrinting	24 (82.8%)	0 (0.0%)	0 (0.0%)	0 (0.0%)	3 (10.3%)	0 (0.0%)	2 (6.9%)
	Inclusion	2 (5.9%)	20 (58.8%)	5 (14.7%)	0 (0.0%)	0 (0.0%)	6 (17.6%)	1 (2.9%)
	IronSheetAsh	0 (0.0%)	1 (6.2%)	15 (93.8%)	0 (0.0%)	0 (0.0%)	0 (0.0%)	0 (0.0%)
	oxideScaledPlateSystem	0 (0.0%)	3 (37.5%)	5 (62.5%)	0 (0.0%)	0 (0.0%)	0 (0.0%)	0 (0.0%)
	oxideScaledTemperatureSystem	7 (24.1%)	0 (0.0%)	1 (3.4%)	0 (0.0%)	20 (69.0%)	0 (0.0%)	1 (3.4%)
	redIronSheet	3 (5.5%)	5 (9.1%)	1 (1.8%)	0 (0.0%)	2 (3.6%)	40 (72.7%)	4 (7.3%)
	scratches	5 (27.8%)	2 (11.1%)	1 (5.6%)	0 (0.0%)	3 (16.7%)	0 (0.0%)	7 (38.9%)
		Tahmin Edilen Etiket						

(i) Swin Transformer

Gerçek Etiket	FinishingRollPrinting	28 (96.6%)	1 (3.4%)	0 (0.0%)	0 (0.0%)	0 (0.0%)	0 (0.0%)	0 (0.0%)
	Inclusion	2 (5.9%)	25 (73.5%)	1 (2.9%)	0 (0.0%)	0 (0.0%)	0 (0.0%)	6 (17.6%)
	IronSheetAsh	2 (12.5%)	2 (12.5%)	12 (75.0%)	0 (0.0%)	0 (0.0%)	0 (0.0%)	0 (0.0%)
	oxideScaledPlateSystem	0 (0.0%)	6 (75.0%)	2 (25.0%)	0 (0.0%)	0 (0.0%)	0 (0.0%)	0 (0.0%)
	oxideScaledTemperatureSystem	13 (44.8%)	2 (6.9%)	0 (0.0%)	0 (0.0%)	12 (41.4%)	0 (0.0%)	2 (6.9%)
	redIronSheet	6 (10.9%)	14 (25.5%)	1 (1.8%)	0 (0.0%)	2 (3.6%)	31 (56.4%)	1 (1.8%)
	scratches	5 (27.8%)	5 (27.8%)	1 (5.6%)	0 (0.0%)	6 (33.3%)	0 (0.0%)	1 (5.6%)
		Tahmin Edilen Etiket						


(j) Vision Transformer

Şekil 25. X-SDD veri setinde modellerin karmaşıklık matrisi karşılaştırılması


4.5.2. Önerilen Modelin Performans Analizi

Önerilen metal yüzey arıza tespiti ve sınıflandırılması için X-SDD veri setinden deneysel sonuçlar üretilmiştir. Önerilen attention-tabanlı KAN mimarisi ile klasik bir CNN mimarisi ile ortak hiper parametre ve katman bilgisi sayesinde adil bir karşılaştırma ortamı hazırlanmıştır. Elde edilen sonuçlar önerilen mimarinin daha yüksek performanslı sonuçlar ürettiğini ortaya koymuştur. Şekil 26’ da klasik CNN ile önerilen modelin eğitim ve doğrulama doğruluklarının karşılaştırılması sunulmuştur. Klasik CNN modelinin X-SDD arıza sınıflandırılmasında elde edilen eğitim doğruluğu %82.4 iken önerilen modelin eğitim doğruluk oranı %99.1 olarak elde edilmiştir. Şekil 27’ de klasik CNN’in ve Şekil 28’ de önerilen modelin eğitim ve doğrulama kesinlik, hassasiyet ve f1-score metrikleri açısından karşılaştırılması sunulmuştur.

Elde edilen sonuçlar incelendiğinde bu performans farkı, önerilen mimarinin karmaşık yüzey kusurlarına ait hem yerel hem de küresel özellikleri daha etkili biçimde öğrenebildiğini göstermektedir. Geleneksel CNN tabanlı modeller çoğunlukla lokal konvolüsyon işlemlerine dayalı özellik çıkarımı gerçekleştirdiğinden özellikle düşük kontrastlı, düzensiz geometrik yapıya sahip ve küçük ölçekli kusurların modellenmesinde sınırlı kalabilmektedir. Buna karşın önerilen modelde kullanılan ConvNeXtV2-Nano tabanlı backbone yapısı, mekânsal dikkat mekanizması ve Kolmogorov-Arnold ağı birlikte çalışarak daha güçlü temsil öğrenimi sağlamaktadır. Özellikle dikkat mekanizması sayesinde modelin kusurlu bölgelere odaklanabilmesi, arka plan etkilerini azaltarak ayırt edici özelliklerin daha belirgin hale gelmesine katkı sağlamıştır. Ayrıca KAN tabanlı doğrusal olmayan temsil öğrenme yaklaşımı sayesinde karmaşık yüzey örüntüleri ve sınıflar arası ince farklılıklar daha başarılı biçimde modellenenmiştir.




(a) CNN modeli




(b) Önerilen model

Şekil 26. Önerilen ve geleneksel CNN modelleri için doğruluk değişimi




Şekil 27. Geleneksel CNN modeli için precision, recall ve f1-score değişimleri




Şekil 28. Önerilen model için precision, recall ve f1-score değişimleri

Tablo 3. Önerilen ve CNN modelinin karşılaştırmalı sınıflandırma performansı

Metrikler	CNN-model		Önerilen model	
	Eğitim	Doğrulama	Eğitim	Doğrulama
Accuracy	0.8238	0.8466	0.9894	0.9841
Precision	0.8173	0.8688	0.9894	0.9845
Recall	0.8238	0.8466	0.9894	0.9841
F1-Score	0.8188	0.8346	0.9894	0.9839
Specificity	0.9696	0.9742	0.9982	0.9971





(a) Geleneksel CNN modeli



(b) Önerilen model


Şekil 29. Önerilen ve geleneksel CNN modelin karmaşıklık matris karşılaştırılması






(b) Önerilen model

Şekil 30. Önerilen ve geleneksel CNN modelin ROC eğrisi karşılaştırılması



(a) Geleneksel CNN model




(b) Önerilen model


Şekil 31. Farklı arıza türleri için metrik değerlerinin sınıf bazında karşılaştırılması

Tablo 4. Önerilen ve CNN modelinin sınıf-bazında sınıflandırma sonuçları

Arıza sınıfları	CNN modeli			Önerilen model		
	P	R	F1	P	R	F1
Finishing roll printing	0.9524	0.6897	0.8000	0.9667	1.0000	0.9831
Inclusion	0.7692	0.8824	0.8219	0.9714	1.0000	0.9855
Iron sheet ash	0.7619	1.0000	0.8649	1.0000	1.0000	1.0000
Oxide scale of plate system	1.0000	0.1250	0.2222	1.0000	0.8750	0.9333
Oxide scale of temperature system	0.8529	1.0000	0.9206	1.0000	0.9310	0.9643
Red iron sheet	0.9592	0.8545	0.9038	0.9821	1.0000	0.9910
Scratches	0.7083	0.9444	0.8095	1.0000	1.0000	1.0000




(a) Geleneksel CNN modeli




(b) Önerilen model

Şekil 32. Önerilen ve geleneksel CNN modelin UMAP karşılaştırılması



(a) Geleneksel CNN modeli



(b) Önerilen model

































Şekil 33. Önerilen model ve geleneksel CNN modelin hata görselleştirme sonuçları. Soldan sağa doğru ham CNN özellikleri, model tarafından öğrenilen özellikler ve hata analizi.


Şekil 32 ve Şekil 33’ teki görselleştirme sonuçları incelendiğinde önerilen modelin sınıflar arasındaki dağılımları geleneksel CNN modeline kıyasla daha iyi şekilde ayırt edebildiği anlaşılmaktadır. Bu durum modelin yüksek temsil gücüne sahip olduğunu ve farklı kusur türlerini daha kararlı biçimde ayırt edebildiğini göstermektedir. Özellikle klasik CNN modelinde karışma gösteren bazı arıza sınıflarının önerilen KAN tabanlı yapıda belirgin biçimde ayrıştığı görülmektedir. Elde edilen görsel analizler, önerilen yaklaşımın yalnızca yüksek doğruluk performansı sunmadığını, aynı zamanda daha güçlü ve açıklanabilir bir özellik öğrenme yapısına sahip olduğunu doğrulamaktadır.

4.5.3. Görsel Dikkat ve Açıklanabilirlik Analizi

Önerilen modelin anomali tespit yaklaşımının farklı görselleştirme çıktıları Tablo 5’ te sunulmuştur. Orijinal görüntüler üzerinde gerçekleştirilen analizlerde ilk olarak yoğunluk tabanlı özellik haritaları oluşturulmuş, ardından anomali skor haritası sonucuyla arızalı bölgelere modelin nasıl dikkat ettiği ve yine benzer şekilde attention füzyonu işlemi ile yoğunluk haritası ve attention haritası birleştirilerek arızalı olan bölgelerin daha fazla vurgulanması sağlanmıştır. En son aşamada ise orijinal görüntü üzerinde arızalı olan bölgelerin belirtilmesiyle tüm bu görseller verilmiştir. Böylelikle önerilen modelin farklı arıza türleri üzerinde yüksek performansla arızalı olan bölgeleri tespit edebildiği gözlemlenmiştir.

Tablo 5. Önerilen modelin anomali tespit performansı

Giriş Görüntüsü	Yoğunluk Tabanlı Özellik Haritası	Anomali Yoğunluk Haritası	Füzyon Tabanlı Dikkat Haritası	Kusur Tespit Sonucu
				
				
				
				
				
				
				
				




4.6. Kumaş Yüzey Kusur Tespit ve Sınıflandırma Sonuçları

Bu bölümde, kumaş yüzey arızalarının tespitinde ve sınıflandırılmasında önerilen denetimsiz arıza tespit sistemi ve denetimli CNN-Transformer hibrit ağı ile SOTA modellerinin kıyaslanması için detaylı performans sonuçları sunulmuştur. Deneysel çalışmalar sırasında kumaş yüzey arızaları için tez kapsamında oluşturulmuş arıza veri seti kullanılmıştır. Düşük kontrastlı yapılar, düzensiz geometrik örüntüler, karmaşık yüzey deformasyonları ve küçük ölçekli anomaliler içermesi nedeniyle sınıflandırma açısından oldukça zor bir problem oluşturmaktadır.


Çalışmada önerilen modelin performansını değerlendirmek amacıyla ResNet50, DenseNet121, DenseNet169, EfficientNetV2-S, MobileNetV3, ConvNeXtV2-Nano, Vision Transformer (ViT), DeiT ve Swin Transformer gibi farklı derin öğrenme mimarileri ile karşılaştırmalı analizler gerçekleştirilmiştir. Tüm modeller aynı veri bölünmeleri, benzer eğitim parametreleri ve aynı veri artırma stratejileri kullanılarak eğitilmiştir. Böylece elde edilen sonuçların adil ve güvenilir biçimde değerlendirilmesi amaçlanmıştır.

4.6.1. Karşılaştırmalı Model Sonuçları


Kumaş yüzey arızasında kullanılan veri seti ve önerilen modellerle ortak parametreler kullanılarak Swin transformer, Vision transformer, DeiT transformer, ResNet50, Inception V3, MobileNetV3, EfficientNet, DenseNet169, DenseNet121 ve ConvNeXt mimarileri seçilmiştir. Bu modellerin 50 epoch boyunca eğitim ve doğrulama doğruluk eğrileri karşılaştırmalı olarak Şekil 34, Şekil 35, Şekil 36 ve Şekil 37’de karşılaştırmalı olarak verilmiştir. Bu modellerin eğitimi sırasında transfer öğrenme ile sıfırdan eğitim gerçekleştirilmiştir. Önerilen modelde olduğu gibi bu modellerde de sıfırdan kumaş arıza veri setindeki arızaların öğrenilmesi amaçlanmıştır.




Şekil 34. Karşılaştırılan modellerinin kumaş veri setindeki eğitim doğrulukları



Şekil 35. Karşılaştırılan modellerinin kumaş veri setindeki doğrulama doğrulukları




Şekil 36. Karşılaştırılan modellerinin kumaş veri setindeki doğruluk eğrisi



Şekil 37. Kumaş veri setinde modellerin bar grafikleriyle karşılaştırılması

En iyi performansı %92,8 eğitim doğruluğu oranıyla Swin transformer mimarisi ulaşırken diğer modellerin ise ortalama %85 civarında başarı elde edebildiği gözlemlenmiştir. Swin transformer, DeiT transformer ve klasik transformer mimarileri ise ortalama bir performans göstermiştir. Ancak en düşük performansı %72,2 eğitim doğruluk oranıyla MobileNetV3 mimarisi elde etmiştir. Şekil 38’ te ise tüm karşılaştırılan modellerin ortak ROC eğrileri sunulmuştur. Eğitim ve doğrulama doğrularından elde edilen performansa paralel olarak ROC eğrisinde de en iyi performansı %99,5 AUC değeriyle yine Swin transformer ulaşabilmektedir.




Şekil 38. Kumaş veri setinde modellerin ortak ROC eğrisi karşılaştırılması


Şekil 39’ da ise her bir modelin karışıklık matrisleri tek tek sunulmuştur. Toplam 541 adet test örneği içerisinde ConvNeXt mimarisi 66 adet yanlış pozitif örneklere rastlanmıştır. Burada büyük oranda modelin yanlış sınıflara yanlış örnekler atadığı anlamına gelmektedir. Deit mimarisinde 89 adet yanlış atanmış örnekler bulunmaktadır. Yine çoğunlukla ConvNeXt mimarisindeki yanlış atanan sınıflara benzer bir paralellik göstermektedir. Diğer mimarilere göre nispeten yüksek başarı gösteren DenseNet121 ve DenseNet169 mimarilerinden yanlış atanan örneklerin sayısı iki modelde de 58’ dir. EfficientNet mimarisinde 126 örnek yanlış sınıflandırılırken InceptionV3 mimarisinde 95 örnek yanlış sınıflandırılmıştır. MobileNet modelinden 173 örnek, ResNet50 modelinden 103 örnek yanlış sınıflandırılmıştır. Swin transformer mimarisinden 39 örnek ve 92 örnek yanlış sınıflandırılmıştır. Tüm bu sonuçlar göz önüne alındığından ROC eğrisi ve eğitim-doğrulama doğruluk eğrisi sonuçlarına paralel şekilde en iyi sonucu Swin transformer ve DenseNet mimarileriyle elde edildiği ortaya çıkmıştır.

Tüm mimarilerin Good-sağlıklı sınıfını çok rahat şekilde arızalardan ayırt edebildiği halde arızalı olan sınıfları ayırt etmekte zorlandığı görülmektedir. Good sınıfından sonra en iyi ayırt


edilebilen sınıflar Horizontal ve Wrinkle sınıflarıdır. Bu sınıfların ayırt ediciliği diğer sınıflar arasında daha belirgin bir arıza görüntüsünde olduğundan yüksektir. Arıza sınıfları arasında ayırt etmekte en çok zorlanılan sınıflar ise Hole ve Stain sınıflarıdır. Bu sınıfların özellikleri incelendiğinde; ortak noktalarının hem birbirlerine benzerlik göstermesi hem de düşük kontrastlı ve düzensiz yapıda olmalarıdır.




(a) ConvNeXt




(b) DeiT




(c) DenseNet121




(d) DenseNet169




(e) EfficientNet




(f) InceptionV3




(g) MobileNet



(h) ResNet50



(i) Swin Transformer




(j) Vision Transformer

Şekil 39. Kumaş veri setinde modellerin karmaşıklık matrisi karşılaştırılması

4.6.2. Önerilen Modelin Performans Analizi

Önerilen kumaş arızalarının sınıflandırılmasıyla ilgili olarak elde ettiği doğruluk, kesinlik, geri çağırma ve fl-score metriklerinin eğitim ve doğrulama sonuçları eğim grafiği şeklinde sırasıyla Şekil 40, 41, 42 ve 43'te sunulmuştur. Ayrıca elde edilen performans çıktılarının Tablo 6' da sunulurak eğim grafikleri desteklenmiştir. Önerilen modelin %97,72 eğitim, %95,31 doğrulama ve %97,78 test doğruluğuna ulaşmıştır. Önerilen modelin ROC eğrisi Şekil 44'te ve karmaşıklık matrisi Şekil 45'te sunulmuştur. Bu matris incelendiğinde 405 adet örnekten sadece 12 adedi yanlış pozitif olarak etiketlendiği gözlemlenmiştir. Tablo 7'de ise önerilen modelin sınıf bazlı olarak sınıflandırma sonuçları verilmiştir. Şekil 46' te ise UMAP görselleştirmeleriyle sınıflar arasındaki ayrımı etkili ve başarılı şekilde yapabildiğini ispatlanmıştır.




Şekil 40. Kumaş veri setinde önerilen model için doğruluk eğrisi



Şekil 41. Kumaş veri setinde önerilen model için kesinlik eğrisi




Şekil 42. Kumaş veri setinde önerilen model için hassasiyet eğrisi




Şekil 43. Kumaş veri setinde önerilen model için f1-skor eğrisi

Tablo 6. Önerilen modelin kumaş arızası sınıflandırma performansı

Metrikler	Eğitim	Doğrulama	Test
Doğruluk	0.9772	0.9531	0.9778
Kesinlik	0.9773	0.9548	0.9779
Hassasiyet	0.9772	0.9531	0.9778
F1-Skor	0.9773	0.9530	0.9778




Şekil 44. Kumaş veri setinde önerilen modelin ROC eğrisi



Şekil 45. Kumaş veri setinde önerilen modelin karmaşıklık matrisi

Tablo 7. Önerilen modelin kumaş arızası için sınıf bazında sınıflandırma performansı

Sınıf	Precision	Recall	F1	Örnek
Good	1.0000	1.0000	1.0000	44
Hole	0.9216	0.9792	0.9495	96
Horizontal	0.9753	1.0000	0.9875	79
Stain	0.9655	0.8936	0.9282	94
Wrinkle	1.0000	0.9891	0.9945	92



Şekil 46. Kumaş veri setinde önerilen modelin UMAP görselleştirme sonucu. (a) ham örnek noktaları ve (b) öğrenilmiş özellik uzayı

4.6.3. Denetimsiz Anomali Tespit Sonuçları

Önerilen çerçevenin yerleştirme yeteneğini ve karar verme davranışını daha iyi analiz etmek için, kusur inceleme hattına çeşitli görselleştirme ve yorumlanabilirlik stratejileri entegre edilmiştir. Önerilen yöntem, normalleştirilmiş anomali ısı haritaları, uyarlanabilir ikili

yerelleştirme maskeleri, kontur tabanlı kusur sınırları, şeffaf anomali kaplamaları ve kenar geliştirilmiş kusur temsilleri de dahil olmak üzere çok sayıda anomaliye duyarlı görselleştirme çıktısı üretir. Tablo 8’ de gösterildiği gibi, görselleştirme çerçevesi orijinal giriş görüntüsünden, uyarlanabilir anomali birleştirme modülünden üretilen anomali ısı haritalarından, eşik tabanlı ikili maskelerden, kontur yerelleştirme çıktılarından, şeffaf kaplama haritalarından ve son birleştirilmiş kusur görselleştirme sonuçlarından oluşmaktadır.

Anomali yerelleştirme süreci, Transformer tabanlı özellik sapmaları, bellek güdümlü benzerlik yanıtları ve Mahalanobis istatistiksel mesafe ölçümlerini birleştiren önerilen uyarlanabilir çok kriterli anomali analiz stratejisi tarafından yönlendirilmektedir. Oluşturulan anomali aktivasyon haritaları, öğrenilen normal özellik dağılımından sapmaları temsil eder ve potansiyel yüzey kusurlarıyla ilişkili uzamsal bölgeleri vurgular. Daha yüksek aktivasyon yoğunlukları, füzyon mekanizması tarafından üretilen daha güçlü anomali güven puanlarını gösterir. Anormal bölgelerin görsel ayrımını iyileştirmek ve lokalizasyon yorumlanabilirliğini artırmak için Inferno, Turbo ve Magma tabanlı ısı haritaları da dahil olmak üzere farklı renk haritası gösterimleri kullanılır.

Daha uzamsal olarak tutarlı lokalizasyon sonuçları elde etmek için, anomali haritalarına adaptif eşikleme ve morfolojik iyileştirme işlemleri uygulanır. Anomali puanı dağılımına dayalı istatistiksel eşik tahmini kullanılarak ikili kusur maskeleri oluşturulurken, morfolojik açma ve kapama işlemleri gürültüyü bastırır ve yapısal sürekliliği iyileştirir. Ek olarak, kusur sınırlarını açıkça görselleştirmek ve yüzeydeki geometrik düzensizlikleri vurgulamak için kontur çıkarımı kullanılır. Gradyan tabanlı kenar çıkarımı yoluyla elde edilen kenar geliştirilmiş gösterimler, ince kusur yapılarının ve sınır geçişlerinin görünürlüğünü daha da iyileştirir.

Son olarak, önerilen füzyon görselleştirme stratejisi, kapsamlı ve açıklanabilir bir kusur lokalizasyon çıktısı oluşturmak için anomali ısı haritalarını, kontur bilgilerini, şeffaf katmanları ve kenar geliştirilmiş gösterimleri entegre eder. Farklı özellik gösterimlerinden gelen tamamlayıcı uzamsal ve istatistiksel bilgileri birleştirerek, önerilen görselleştirme hattı, kusur bölgelerinin daha sağlam bir şekilde yorumlanabilirliğini ve daha doğru bir şekilde sınırlandırılmasını sağlar. Bu görselleştirme sonuçları, önerilen çerçevenin, endüstriyel yüzey dokularının yapısal özelliklerini korurken, kusura duyarlı bölgeleri etkili bir şekilde vurgulayabildiğini göstermektedir.

Tablo 8. Önerilen hata tespit çerçevesinin işlem aşamaları boyunca görsel yorumlanması

Orijinal	İnferno Isı Haritası	Turbo Isı Haritası	İkili Maske	Kontur	Kaplama	Füzyon Çıktısı

4.7. Genel Tartışma ve Yorum

Bu çalışmada metal ve kumaş yüzey kusurlarının tespiti ve sınıflandırılması amacıyla derin öğrenme tabanlı iki farklı yaklaşım geliştirilmiş ve kapsamlı deneysel analizler gerçekleştirilmiştir. İlk yaklaşımda attention destekli Kolmogorov-Arnold ağı tabanlı bir metal yüzey kusur sınıflandırma sistemi önerilmiş, ikinci yaklaşımda ise Transformer tabanlı denetimsiz anomali tespit sistemi ile CNN-Transformer hibrit yapısına sahip denetimli kumaş kusur sınıflandırma sistemi birlikte kullanılmıştır. Elde edilen deneysel sonuçlar, önerilen yöntemlerin hem doğruluk performansı hem de açıklanabilirlik açısından başarılı sonuçlar sunduğunu göstermektedir.

Metal yüzey kusur sınıflandırma deneylerinde önerilen attention destekli KAN mimarisi, klasik CNN tabanlı modellere göre belirgin performans artışı sağlamıştır. Özellikle düşük kontrastlı, karmaşık geometrik yapıya sahip ve küçük ölçekli kusurların sınıflandırılmasında önerilen modelin daha başarılı sonuçlar ürettiği görülmüştür. ConvNeXtV2-Nano tabanlı backbone yapısı sayesinde güçlü yerel özellik temsilleri elde edilirken, mekânsal dikkat mekanizması modelin kusurlu bölgelere yoğunlaşmasını sağlamıştır. Ayrıca Kolmogorov-Arnold ağı tabanlı doğrusal olmayan temsil öğrenme yapısı sayesinde yüzey kusurlarına ait karmaşık örüntüler daha başarılı biçimde modellenebilmiştir.

UMAP ve t-SNE görselleştirme sonuçları incelendiğinde önerilen modelin özellik uzayında sınıfları daha belirgin biçimde ayırttığı gözlemlenmiştir. Klasik CNN modelinde bazı kusur sınıfları arasında örtüşmeler oluşurken, önerilen KAN tabanlı yapıda daha kompakt sınıf kümeleri elde edilmiştir. Bu durum modelin yüksek ayırt edici temsil öğrenme kapasitesine sahip olduğunu göstermektedir. Özellikle attention mekanizması sayesinde kusurlu bölgelerin ön plana çıkarılması, sınıflar arası ayrımın güçlenmesine katkı sağlamıştır.

Kumaş yüzey analizlerinde geliştirilen Transformer tabanlı denetimsiz anomali tespit sistemi, normal veri dağılımını başarılı biçimde öğrenerek kusurlu bölgeleri yüksek doğrulukla belirleyebilmiştir. Memory bank yapısı sayesinde normal örneklerle ait temsil uzayı oluşturulmuş, Transformer temsil sapmaları ve Mahalanobis mesafesi kullanılarak anomalili bölgeler tespit edilmiştir. Özellikle Mahalanobis tabanlı istatistiksel dağılım modellemesinin düşük kontrastlı ve karmaşık yüzey kusurlarının belirlenmesinde önemli katkı sağladığı görülmüştür.

Öğrenilebilir füzyon mekanizması sayesinde farklı anomali skorları adaptif biçimde birleştirilmiş ve daha kararlı anomali haritaları elde edilmiştir. Transformer temsil sapması, memory bank uzaklığı ve Mahalanobis skorlarının birlikte değerlendirilmesi, tek bir anomali kriterine dayalı sistemlere kıyasla daha güçlü performans sağlamıştır. Görsel sonuçlar incelendiğinde attention fusion yapısının kusurlu bölgeleri daha belirgin hale getirdiği ve yanlış pozitif bölgeleri azalttığı gözlemlenmiştir.

Denetimli kumaş kusur sınıflandırma aşamasında CNN-Transformer hibrit yapısı kullanılarak hem yerel dokusal özellikler hem de küresel bağlamsal ilişkiler birlikte öğrenilmiştir. CNN katmanları ince dokusal detayları başarılı şekilde çıkarırken, Transformer yapısı görüntü içerisindeki uzun menzilli ilişkileri modelleyebilmiştir. Kanal dikkat mekanizması ise önemli özellik kanallarını ön plana çıkararak modelin ayırt edici temsil öğrenme kapasitesini artırmıştır. Elde edilen sonuçlar hibrit yapının geleneksel CNN ve yalnızca Transformer tabanlı modellere göre daha başarılı performans sunduğunu göstermektedir.

Çalışmada attention haritaları, anomali yoğunluk haritaları ve kusur bindirme sonuçları kullanılarak modellerin görsel açıklanabilirlik performansları da değerlendirilmiştir. Görsel analizler incelendiğinde önerilen modellerin karar verme sürecinde kusurlu bölgelere yoğunlaştığı görülmüştür. Bu durum geliştirilen sistemlerin yalnızca yüksek doğruluk sunmadığını, aynı zamanda güvenilir ve açıklanabilir yapılar ortaya koyduğunu göstermektedir. Özellikle endüstriyel kalite kontrol uygulamalarında açıklanabilir yapay zekâ sistemleri büyük önem taşımaktadır.

Bununla birlikte çalışmanın bazı sınırlılıkları da bulunmaktadır. Kullanılan veri setleri belirli yüzey türleri ile sınırlıdır ve farklı üretim ortamlarında oluşabilecek değişken aydınlatma, sensör gürültüsü ve karmaşık yüzey yapıları performansı etkileyebilir. Ayrıca Transformer tabanlı yapıların yüksek hesaplama maliyetine sahip olması gerçek zamanlı uygulamalarda ek optimizasyon ihtiyacı doğurabilmektedir.

Gelecek çalışmalarda daha büyük ve farklı endüstriyel veri setleri üzerinde çapraz veri seti analizleri gerçekleştirilebilir. Ayrıca hafifletilmiş Transformer mimarileri, self-supervised öğrenme yaklaşımları ve çok ölçekli attention mekanizmaları kullanılarak daha güçlü ve daha

hızlı sistemler geliştirilebilir. Bunun yanında gerçek zamanlı üretim hatlarına entegre edilebilecek optimize edilmiş gömülü sistem çözümleri üzerine çalışmalar yapılabilir.

Sonuç olarak bu tez çalışmasında geliştirilen attention destekli KAN tabanlı metal yüzey kusur sınıflandırma sistemi ile Transformer destekli kumaş yüzey anomali tespit ve sınıflandırma sistemlerinin yüksek performanslı, açıklanabilir ve genelleştirilebilir yapılar sunduğu görülmüştür. Elde edilen deneysel bulgular, önerilen yöntemlerin akıllı kalite kontrol sistemleri ve endüstriyel otomasyon uygulamaları için etkili bir çözüm ortaya koyduğunu göstermektedir.

5. SONUÇLAR ve ÖNERİLER

Akıllı üretim sistemlerinde ürün arızalarının teşhisinin otomatik olarak belirlenebildiği yenilikçi çözümlere olan ihtiyaç son zamanlarda artmıştır. Bu bağlamda son yıllarda endüstriyel süreçlerdeki ürün arıza tespit ve sınıflandırılması ile ilgili olarak geliştirilmiş birçok çalışma mevcuttur. Geliştirilen yöntemlerin büyük çoğunluğu ise derin öğrenme modellerine dayanmaktadır. Endüstriyel üretim süreçlerinde yüzey kusurlarının erken aşamada doğru şekilde belirlenmesi, ürün kalitesinin artırılması, üretim maliyetlerinin azaltılması ve insan kaynaklı hata oranlarının düşürülmesi açısından büyük önem taşımaktadır. Geleneksel görüntü işleme yöntemleri; karmaşık yüzey yapıları, düşük kontrastlı kusurlar ve değişken üretim koşulları karşısında sınırlı performans gösterebildiğinden, bu çalışmada modern derin öğrenme mimarileri kullanılarak daha güçlü ve genelleştirilebilir sistemler geliştirilmiştir.

Tez çalışmasında metal ve kumaş yüzeylerindeki arızaların tespit ve sınıflandırılması için iki farklı yenilikçi çözümler geliştirilmiştir. Çalışmanın ilk bölümünde metal yüzey arızalarının tespisi için attention destekli Kolmogorov-Arnold ağı tabanlı yeni bir derin öğrenme mimarisi önerilmiştir. Önerilen yapıda ConvNeXtV2-Nano tabanlı backbone mimarisi kullanılarak yüksek seviyeli özellik temsilleri elde edilmiş, ardından mekânsal dikkat mekanizması ile kusurlu bölgelerin ön plana çıkarılması sağlanmıştır. Elde edilen özellikler öğrenilebilir havuzlama mekanizması ile sıkıştırılmış ve son aşamada Kolmogorov-Arnold ağına aktarılmıştır. KAN tabanlı yapı sayesinde klasik tam bağlantılı katmanlara göre daha esnek doğrusal olmayan temsil öğrenimi gerçekleştirilmiştir.

X-SDD çelik yüzey kusur veri seti üzerinde gerçekleştirilen deneysel çalışmalar sonucunda önerilen modelin oldukça yüksek doğruluk performansı sergilediği görülmüştür. Eğitim doğruluğu %98,94, doğrulama doğruluğu ise %98.41 olarak elde edilmiştir. Ayrıca klasik CNN tabanlı modeller ile gerçekleştirilen karşılaştırmalı analizlerde önerilen yaklaşımın belirgin performans üstünlüğü sağladığı gözlemlenmiştir. Özellikle düşük kontrastlı ve karmaşık geometrik yapıya sahip yüzey kusurlarının sınıflandırılmasında attention mekanizmasının ve KAN tabanlı doğrusal olmayan öğrenme yapısının önemli katkı sağladığı belirlenmiştir.

Çalışmanın ikinci bölümünde ise kumaş yüzey arızalarının tespit ve tespisi için Transformer tabanlı denetimsiz bir mimari oluşturulmuştur. Bu çalışmanın ana katkısı şudur ki modelin sadece normal kumaş görüntülerini kullanarak arızalı olan örnekleri tespit edilebilmesini sağlamaktır. Böylece nadir görülen arızalarda veya arıza görüntüsü fazla olmayan durumlarda

bu arızaların da tespit edilebilmesi avantajı sunmaktadır. Önerilen modelin kanal dikkat mekanizması ile önce önemli olan arızalı bölgelerin vurgulandığı sonra da bu özellik haritalarının, Memory bank tabanlı temsil öğreniminden elde edilen özelliklerin ve Mahalanobis mesafesinden elde edilen özelliklerin adaptif füzyon yaklaşımıyla birleştirilerek arıza kayıp fonksiyonu oluşturulmuştur. Öğrenilebilir füzyon mekanizması ile farklı anomali skorlarının adaptif biçimde birleştirilmesi sistemin lokalizasyon başarısını artırmıştır.

Denetimli sınıflandırma aşamasında geliştirilen CNN-Transformer hibrit yapısı sayesinde hem lokal dokusal özellikler hem de küresel bağlamsal ilişkiler birlikte modellenmiştir. Kanal dikkat mekanizması sayesinde önemli özellikler ön plana çıkarılmış ve modelin sınıflandırma performansı artırılmıştır. Elde edilen %97,78 test doğruluğu önerilen yaklaşımın etkinliğini göstermektedir.

Her iki çalışmada da önerilen modellerin girdi test görüntüleri üzerinde anomali bölgelerin tespit edildiği bölgelerin vurgulandığı çıktılar verilmiştir. Özellikle endüstriyel kalite kontrol sistemleri açısından önemli katkılar sunmaktadır. Açıklanabilir attention haritaları sayesinde modellerin karar verme süreçleri analiz edilebilmekte ve sistem güvenilirliği artırılmaktadır. Ayrıca geliştirilen yöntemler yalnızca metal ve kumaş yüzeyleriyle sınırlı olmayıp farklı endüstriyel yüzey analiz problemlerine de uyarlanabilecek potansiyele sahiptir.

Gelecek çalışmalarda multimodal veri yapıları, self-supervised öğrenme yaklaşımları ve gerçek zamanlı gömülü sistem optimizasyonları üzerine çalışmalar gerçekleştirilebilir. Ayrıca federated learning ve edge AI tabanlı sistemler kullanılarak üretim hatlarında düşük gecikmeli akıllı kalite kontrol sistemleri geliştirilebilir.

KAYNAKÇA

- Aktas, A. (2020). *Image processing applications with deep learning methods*. Yüksek Lisans Tezi, Marmara Üniversitesi, Bilgisayar Mühendisliği.
- Ananthi, S., Preetha, R., Soundharya, S., Swathi, S., & Vanitha, M. V. (2024). *Smart Fabric Inspector System using Deep Learning Algorithm*. In 2024 3rd International Conference on Automation, Computing and Renewable Systems (ICACRS) (pp. 1493-1500). IEEE.
- Arshad, S. R., & Shahzad, M. K. (2024). *Deep learning based fabric defect detection*. Research Reports on Computer Science, 1-11.
- Baydilli, Y. Y. (2021). *Polen Taşıyan Bal Arılarının MobileNetV2 Mimarisi ile Sınıflandırılması*. European Journal of Science and Technology, 21, 527-533.
- Bayram, B., Kılıç, B., Özoğlu, F., Erdem, F., Sivri, S., Delen, A., & Bayrak, O. C. (2019). *A study on object recognition with deep learning*. 10. Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği Teknik Sempozyumu (TUFUAB 2019).
- Chen, Z., Fan, W., & Guo, B. (2025). *ELG-YOLO: Multi-Scale Feature Fusion and Attention Mechanisms for Enhanced Steel Surface Defect Detection*. IEEE Access, 14, 5660-5674.
- Del Rosario, C. A., Camaclang, R. C., Prieto-Araujo, E., & Gomis-Bellmunt, O. (2024). *Kolmogorov-Arnold network for machine learning-based motor condition diagnosis*. In 2024 IEEE 7th International Conference on Electrical, Electronics and System Engineering (ICEESE) (pp. 1-5). IEEE.
- Demir, K., Ay, M., Cavas, M., & Demir, F. (2023). *Automated steel surface defect detection and classification using a new deep learning-based approach*. Neural Computing and Applications, 35(11), 8389-8406.
- Feng, X., Gao, X., & Luo, L. (2021). *X-SDD: A New Benchmark for Hot Rolled Steel Strip Surface Defects Detection*. Symmetry, 13(4), 706.
- Fu, G., Sun, P., Zhu, W., Yang, J., Cao, Y., Yang, M. Y., & Cao, Y. (2019). *A deep-learning-based approach for fast and robust steel surface defects classification*. Optics and Lasers in Engineering, 121, 397-405.
- Gan, Z., Dong, H., Wang, R., Wu, H., Tan, Z., & Zhao, X. (2025). *Steel Surface Defect Detection Based on GAE-YOLO Algorithm*. In 2025 7th International Conference on Internet of Things, Automation and Artificial Intelligence (IoTAAI) (pp. 215-218). IEEE.
- Gao, Y., Lv, G., Xiao, D., Han, X., Sun, T., & Li, Z. (2024). *Research on steel surface defect classification method based on deep learning*. Scientific Reports, 14(1), 8254.
- Geze, R. A., & Akbaş, A. (2024). *Detection and classification of fabric defects using deep learning algorithms*. Journal of Polytechnic, 27(1), 371-378.

Guder, O., Isik, S., & Anagun, Y. (2025). *Fabric defects identification for textile industry with a deep learning approach*. *The Journal of The Textile Institute*, 116(8), 1493-1502.

Hanbay, K., Talu, M. F., & Özgüven, Ö. F. (2016). *Fabric defect detection systems and methods—A systematic literature review*. *Optik*, 127(24), 11960-11973.

He, K., Zhang, X., Ren, S., & Sun, J. (2016). *Deep residual learning for image recognition*. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition* (pp. 770-778).

Hou, Y., Chen, Z., Wu, M., Foo, C. S., Li, X., & Shubair, R. M. (2020). *Mahalanobis distance based adversarial network for anomaly detection*. In *ICASSP 2020* (pp. 3192-3196). IEEE.

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*. arXiv preprint arXiv:1704.04861.

Huang, G., Liu, Z., Maaten, L. V. D., & Weinberger, K. O. (2017). *Densely Connected Convolutional Networks*. In *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*.

Islam, R., Ullah, S., Rahaman, S., Sheebly, J., Rahman, S., & Rahman, R. (2024, October). *Ensemble deep learning for real-time textile fabric defect detection and classification using YOLOv8 and CNNs*. In *Proceedings of the 3rd International Conference on Computing Advancements* (pp. 939-945).

Jing, J. F., Ma, H., & Zhang, H. H. (2019). *Automatic fabric defect detection using a deep convolutional neural network*. *Coloration Technology*, 135(3), 213-223.

Kamoi, R., & Kobayashi, K. (2020). *Why is the mahalanobis distance effective for anomaly detection?* arXiv preprint arXiv:2003.00402.

Kaynar, O., Işık, Y. E., Görmez, Y., & Demirkoparan, F. (2017, September). *Fabric defect detection with LBP-GLMC*. In *2017 International Artificial Intelligence and Data Processing Symposium (IDAP)* (pp. 1-5). IEEE.

Komijani, A., Vafaeinezhad, F., Khoramdel, J., Borhani, Y., & Najafi, E. (2022, December). *Multi-label classification of steel surface defects using transfer learning and vision transformer*. In *2022 13th International Conference on Information and Knowledge Technology (IKT)* (pp. 1-5). IEEE.

Konovalenko, I., Maruschak, P., Brezinová, J., Viňáš, J., & Brezina, J. (2020). *Steel Surface Defect Classification Using Deep Residual Neural Network*. *Metals*, 10(6), 846.

Krzywda, M., Wermiński, M., Łukasik, S., & Gandomi, A. H. (2025). *Kolmogorov-Arnold networks for metal surface defect classification*. arXiv preprint arXiv:2501.06389.

- Lakshmaiya, N. (2026, April). *Ensemble ConvNeXt-LSTM Framework for Smart Surface Defect Detection in Hot-Rolled Steel Strips*. In 2026 6th International Conference on Trends in Material Science and Inventive Materials (ICTMIM) (pp. 21-26). IEEE.
- Lee, S. Y., Tama, B. A., Moon, S. J., & Lee, S. (2019). *Steel Surface Defect Diagnostics Using Deep Convolutional Neural Network and Class Activation Map*. Applied Sciences, 9(24), 5449.
- Li, C., Huang, H., Mo, H., Wen, Z., Zhou, S., & Zhu, Z. (2025). *Novel Efficient Steel Surface Defect Detection Model Based on ConvNeXt v2 and Squeeze Aggregated Excitation Attention*. IEEE Access.
- Li, J., Luo, X., Liu, X., Liu, X., & Chen, J. (2025b). *MCS-YOLOv11: A Lightweight Model for Steel Surface Defect Detection*. In 2025 4th International Conference on Image Processing, Computer Vision and Machine Learning (ICICML) (pp. 1285-1289). IEEE.
- Li, L., Ma, Y., & Su, L. (2025a). *CM-YOLO: A Highly Accurate YOLOv5 S-Based Model for Steel Surface Defect Detection*. In 2025 8th International Conference on Advanced Algorithms and Control Engineering (ICAACE) (pp. 972-976). IEEE.
- Li, M., Han, D., Shao, R., & He, J. (2024, August). *Feature Aggregation Network for Memory-Based Industrial Anomaly Detection*. In 2024 IEEE 9th International Conference on Data Science in Cyberspace (DSC) (pp. 677-683). IEEE.
- Li, S., Wu, C., & Xiong, N. (2022). *Hybrid Architecture Based on CNN and Transformer for Strip Steel Surface Defect Classification*. Electronics, 11(8), 1200.
- Li, S., Sun, W., Liang, Q., Sun, J., & Liu, C. (2024). *Multimodal fabric defect classification using channel switching and multiscale feature fusion*. IEEE Transactions on Instrumentation and Measurement, 74, 1-12.
- Liao, S., Yu, X., & Liu, Y. (2025). *Improved YOLOv11 for Steel Surface Defect Detection Based on PMDT-YOLO*. In 2025 IEEE International Conference on Pattern Recognition, Machine Vision and Artificial Intelligence (PRMVAI) (pp. 1-5). IEEE.
- Liu, C., Duan, S., & Pang, H. (2024, November). *ARDSwin-Unet: A Variant Swin Transformer for Fabric Defect Detection*. In 2024 International Symposium on Digital Home (ISDH) (pp. 13-18). IEEE.
- Liu, K. H., Chen, S. J., & Liu, T. J. (2022b). *Unsupervised Unet for fabric defect detection*. In 2022 IEEE International Conference on Consumer Electronics-Taiwan (pp. 205-206). IEEE.
- Liu, Q., Wang, C., Li, Y., Gao, M., & Li, J. (2022a). *A fabric defect detection method based on deep learning*. IEEE Access, 10, 4284-4296.
- Liu, Y., Yuan, Y., Balta, C., & Liu, J. (2020). *A Light-Weight Deep-Learning Model with Multi-Scale Features for Steel Surface Defect Classification*. Materials, 13(20), 4629.
- Ly, X., & Xu, J. (2023). *Steel plate surface defect detection method-based on improved YOLO algorithm*. In 2023 China Automation Congress (CAC) (pp. 1331-1335). IEEE.

- Machado, R., Barros, L. A. M., Vieira, V., Silva, F. D. d., Costa, H., & Carvalho, V. (2025). *Textile Defect Detection Using Artificial Intelligence and Computer Vision—A Preliminary Deep Learning Approach*. *Electronics*, 14(18), 3692.
- Meng, J., & Wen, S. (2024). *Detection of steel surface defects based on improved YOLOv8n algorithm*. In 2024 2nd International Conference on Algorithm, Image Processing and Machine Vision (AIPMV) (pp. 8-12). IEEE.
- Mewada, H., Pires, I. M., Engineer, P., & Patel, A. V. (2024). *Fabric surface defect classification and systematic analysis using a cuckoo search optimized deep residual network*. *Engineering Science and Technology, an International Journal*, 53, 101681.
- Mia, M. S., & Li, C. (2024). *STD2: Swin transformer-based defect detector for surface anomaly detection*. *IEEE Transactions on Instrumentation and Measurement*, 74, 1-15.
- Nasim, M., Mumtaz, R., Ahmad, M., & Ali, A. (2024). *Fabric Defect Detection in Real World Manufacturing Using Deep Learning*. *Information*, 15(8), 476.
- Nath, V., Chattopadhyay, C., & Desai, K. A. (2023). *NSLNet: An improved deep learning model for steel surface defect classification utilizing small training datasets*. *Manufacturing Letters*, 35, 39-42.
- Nguyen, L. D., Lin, D., Lin, Z., & Cao, J. (2018). *Deep CNNs for microscopic image classification by exploiting transfer learning and feature concatenation*. In 2018 IEEE International Symposium on Circuits and Systems (ISCAS) (pp. 1-5). IEEE.
- Nikolakis, N., Catti, P., Fabbro, L., & Alexopoulos, K. (2025). *Adapting Vision Transformers for Cross-Product Defect Detection in Manufacturing*. *Procedia Computer Science*, 253, 2693-2702.
- Şeker, A. (2018). *Evaluation of fabric defect detection based on transfer learning with pre-trained AlexNet*. In 2018 International Conference on Artificial Intelligence and Data Processing (IDAP) (pp. 1-4). IEEE.
- Sheng, W., Lu, M., & Zou, Y. (2024). *Steel Surface Defect Detection Based on Improved YOLOv8 Algorithm*. In 2024 4th International Conference on Industrial Automation, Robotics and Control Engineering (IARCE) (pp. 109-113). IEEE.
- Sravani, T., Reddy, C. T., Harini, P., & Chaithanya, S. (2025). *Fabric Defect Detection Using Vision Transformer Algorithm*. *International Journal of Innovative Research in Technology (IJIRT)*, 11(12), 7444–7448.
- Sun, Z., Zhan, H., & Yang, K. (2025). *Multi-Scale Cross-Axis Attention Enhanced YOLOv8 for Robust Steel Surface Defect Detection in Industrial Manufacturing*. In 2025 7th International Symposium on Robotics and Intelligent Manufacturing Technology (ISRIMT) (pp. 39-43). IEEE.
- Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., & Wojna, Z. (2016). *Rethinking the inception architecture for computer vision*. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition* (pp. 2818-2826).

- Tan, M., & Le, Q. V. (2019). *EfficientNet: Rethinking model scaling for convolutional neural networks*. Proceedings of the 36th International Conference on Machine Learning (ICML), 10691-10700.
- Tang, H., Zhao, Y., Yang, P., Li, G., & Yan, H. (2025). *Classification of surface defects in hot-rolled steel strips using contrastive learning image pre-trained models*. In 2025 5th International Conference on Neural Networks, Information and Communication Engineering (NNICE) (pp. 1578-1581). IEEE.
- Taştimur, C. (2025). *Mean shift based prototypical network for steel surface anomaly recognition*. Scientific Reports, 15(1), 45097.
- Taştimur, C. (2026). *Automated fabric defect inspection with fuzzy c-means, conditional random fields and refined U-Net*. Journal of Mechanical Science and Technology, 40, 597-607.
- Taştimur, C., Ağrikli, M., & Akın, E. (2023). *Anomaly Detection in Yarn Tension Signal Using Independent Component Analysis*. Turkish Journal of Science and Technology, 18(1), 33-43.
- Taştimur, C., Akın, E., & Ağrikli, M. (2025). *Fabric Faults Robust Classification Based on Logarithmic Residual Shrinkage Network in a Four-Point System*. Applied Sciences, 15(12), 6783.
- Ucar, M. (2021). *Diagnosis of Glaucoma Disease using Convolutional Neural Network Architectures*. Dokuz Eylül University Faculty of Engineering Journal of Science and Engineering, 23(68), 521-529.
- Varjovi, M. H., Talu, M. F., & Hanbay, K. (2022). *Fabric defect detection using customized deep convolutional neural network for circular knitting fabrics*. Türk Doğa ve Fen Dergisi, 11(3), 160-165.
- Wang, C., Wang, H., Jiang, Y., Yu, L., & Wang, X. (2025). *CSCP-YOLO: A lightweight and efficient algorithm for real-time steel surface defect detection*. IEEE Access.
- Wang, P., Ou, Y., & He, J. (2023). *Fault location in distribution network with high penetration distributed generations based on wavelet ConvNeXt network*. In 2023 China Automation Congress (CAC) (pp. 8444-8449). IEEE.
- Wang, S., Xia, X., Ye, L., & Yang, B. (2021). *Automatic Detection and Classification of Steel Surface Defect Using Deep Convolutional Neural Networks*. Metals, 11(3), 388.
- Xiao, W. (2026). *SD-YOLO: A Lightweight Network for Steel Surface Defect Detection with Enhanced Feature Representation*. 2026 International Conference on Communication Networks and Machine Learning (CNML), Chongqing, China, 713-716.
- Yang, Y. (2025). *Research on Steel Surface Defect Detection Based on YOLOv11*. In 2025 5th International Conference on Artificial Intelligence and Industrial Technology Applications (AIITA) (pp. 844-847). IEEE.

Yang, Y., Huang, W., Lu, X., Liu, J., Han, S., & Bai, Y. (2025). *The Method for Steel Surface Defect Detection and Classification Based on the Improved YOLOv7*. In 2025 6th International Conference on Computer Engineering and Application (ICCEA) (pp. 253-257). IEEE.

Zeren, M. T. (2020). *Comparison of SSD and Faster R-CNN algorithms to detect the airports with data set which obtained from unmanned aerial vehicles and satellite images*. Yüksek Lisans Tezi, Beykent Üniversitesi.

Zhang, N., Liu, Z., Zhang, E., et al. (2025). *An ESG-ConvNeXt network for steel surface defect classification based on hybrid attention mechanism*. Scientific Reports, 15, 10926.

Zhou, S., Chen, Y., Zhang, D., Xie, J., & Zhou, Y. (2017). *Classification of surface defects on steel sheet using convolutional neural networks*. Materials Technology, 51(1), 123-131.

Zhu, W., Zhang, H., Zhang, C., Zhu, X., Guan, Z., & Jia, J. (2023).

Surface defect detection and classification of steel using an efficient Swin Transformer. Advanced Engineering Informatics, 57, 102061.