

**GÖRÜNTÜ İŞLEME TEKNOLOJİSİ
KULLANILARAK YÜKSEK
ÇÖZÜNÜRLÜKLÜ KAMERA
GÖRÜNTÜLERİNDEN 3 BOYUTLU
YAZICILARDA ANOMALİ TESPİTİ**

Yüksek Lisans Tezi

Utku ATAMAN

Eskişehir 2025

**GÖRÜNTÜ İŞLEME TEKNOLOJİSİ KULLANILARAK YÜKSEK
ÇÖZÜNÜRLÜKLÜ KAMERA GÖRÜNTÜLERİNDEN 3 BOYUTLU
YAZICILARDA ANOMALİ TESPİTİ**

Utku ATAMAN

Yüksek Lisans Tezi

Bilgisayar Mühendisliği Anabilim Dalı

Bilgisayar Donanımı Bilim Dalı

Danışman: Dr. Öğr. Üyesi Burcu YILMAZEL

Eskişehir

Eskişehir Teknik Üniversitesi

Lisansüstü Eğitim Enstitüsü

Ocak 2025

JÜRİ VE ENSTİTÜ ONAYI

Utku ATAMAN'ın GÖRÜNTÜ İŞLEME TEKNOLOJİSİ KULLANILARAK YÜKSEK ÇÖZÜNÜRLÜKLÜ KAMERA GÖRÜNTÜLERİNDEN 3 BOYUTLU YAZICILARDA ANOMALİ TESPİTİ başlıklı çalışması 16/01/2025 tarihinde aşağıdaki jüri tarafından değerlendirilerek "Eskişehir Teknik Üniversitesi Lisansüstü Eğitim-Öğretim ve Sınav Yönetmeliği"nin ilgili maddeleri uyarınca, Bilgisayar Mühendisliği Anabilim dalında Yüksek Lisans Tezi olarak kabul edilmiştir.

Jüri Üyeleri

Unvan Adı Soyadı

İmza

Üye

: Dr. Öğr. Üyesi Burcu YILMAZEL

Üye

: Doç. Dr. Efnan ŞORA GÜNAL

Üye

: Doç. Dr. Sevcan YILMAZ GÜNDÜZ

Prof. Dr. Harun BÖCÜK

Lisansüstü Eğitim Enstitüsü Müdürü

16/01/2025

DANIŐMAN ONAYI

DaniŐmanlıđını yurüttüğüm Yüksek Lisans öğrencisi Utku ATAMAN, GÖRÜNTÜ İŐLEME TEKNOLOJİSİ KULLANILARAK YÜKSEK ÇÖZÜNÜRLÜKLÜ KAMERA GÖRÜNTÜLERİNDEN 3 BOYUTLU YAZICILARDA ANOMALİ TESPİTİ başlıklı tez çalışmasını tamamlamıştır. Hazırlamış olduđu tez tarafımda incelenmiş ve öğrencinin tez savunma sınavına alınması bilimsel ve etik açıdan uygun görülmüŐtür.

Tez DaniŐmanı
Dr. Öğr. Üyesi Burcu YILMAZEL

ÖZET

GÖRÜNTÜ İŞLEME TEKNOLOJİSİ KULLANILARAK YÜKSEK ÇÖZÜNÜRLÜKLÜ KAMERA GÖRÜNTÜLERİNDEN 3 BOYUTLU YAZICILARDA ANOMALİ TESPİTİ

Utku ATAMAN

Bilgisayar Mühendisliği Anabilim Dalı
Bilgisayar Donanımı Bilim Dalı

Eskişehir Teknik Üniversitesi, Lisansüstü Eğitim Enstitüsü, Ocak 2025

Danışman: Dr. Öğr. Üyesi Burcu YILMAZEL

3D yazıcı teknolojisi, endüstriyel üretimden bireysel kullanıma kadar geniş bir alanda hızla yaygınlaşarak üretim süreçlerini dönüştürmektedir. Prototipleme ve kişiselleştirilmiş üretim gibi avantajlarına rağmen, bu teknoloji baskı sürecinde meydana gelen hatalara karşı hassastır ve genellikle insan gözetimine ihtiyaç duymaktadır. Üretim sırasında sıkça karşılaşılan hatalar, malzeme, enerji ve zaman kaybına neden olmaktadır.

Bu çalışmanın temel amacı, 3D baskı sürecinde oluşabilecek hataları bilgisayarlı görü ve derin öğrenme teknikleri kullanarak gerçek zamanlı olarak tespit etmektir. Bu kapsamda, FDM tipi 3D yazıcılar için iki aşamalı bir hata tespit modeli geliştirilmiştir. İlk aşamada, YOLOv11 modeli kullanılarak baskı alanının segmentasyonu gerçekleştirilmiş, ardından EfficientNet tabanlı sınıflandırma modeli ile baskı hatalarının tespit edilmesi ve sınıflandırılması sağlanmıştır. Önerilen sistem, baskı sürecinde hataları erken aşamada tespit ederek sürecin iyileştirilmesine katkı sunmayı, böylece malzeme, enerji ve zaman israfını azaltarak üretim verimliliğini artırmayı hedeflemektedir. Gerçek zamanlı test ortamında gerçekleştirilen deneyler, önerilen modelin yüksek doğruluk oranlarına ulaştığını ortaya koymuştur. Bu çalışmanın, 3D yazıcılarda anomali tespiti alanında literatüre katkı sunması ve eklemeli üretim süreçlerinin optimizasyonu için yeni bir bakış açısı sağlaması amaçlanmaktadır. Geliştirilen model, ilerleyen çalışmalarda daha geniş veri setleriyle eğitilerek farklı yazıcı türleri ve malzeme çeşitliliğine uyarlanabilir, böylece endüstriyel üretim süreçlerine entegrasyonu desteklenebilir.

Anahtar Sözcükler: 3D yazıcılar, Anomali tespiti, Bilgisayarlı görü, Derin öğrenme, Gerçek zamanlı hata tespiti,

ABSTRACT

ANOMALY DETECTION IN 3D PRINTERS USING IMAGE PROCESSING TECHNOLOGY ON HIGH-RESOLUTION CAMERA IMAGES

Utku ATAMAN

Department of Computer Engineering
Programme in Computer Hardware

Eskişehir Technical University, Institute of Graduate Programs, January 2025

Supervisor: Asst. Prof. Dr. Burcu YILMAZEL

3D printing technology is rapidly expanding from industrial manufacturing to individual use, transforming production processes. Despite its advantages, such as prototyping and personalized manufacturing, this technology is susceptible to errors during the printing process and often requires human supervision. Errors encountered during production lead to material, energy, and time loss.

The primary aim of this study is to detect errors that may occur during the 3D printing process in real time using computer vision and deep learning techniques. In this context, a two-stage fault detection model has been developed for FDM-type 3D printers. In the first stage, the YOLOv11 model is used to segment the printing area, and in the second stage, an EfficientNet-based classification model is employed to detect and classify printing defects. The proposed system aims to improve the printing process by detecting errors at an early stage, thereby reducing material, energy, and time waste while enhancing production efficiency. Real-time experimental results demonstrate that the proposed model achieves high accuracy rates. This study aims to contribute to the literature on anomaly detection in 3D printing and provide a new perspective on optimizing additive manufacturing processes. The developed model can be further trained with larger datasets in future studies, enabling adaptation to different printer types and material variations, thus facilitating its integration into industrial manufacturing processes.

Keywords: 3D Printing, Anomaly detection, Computer vision, Deep learning, Real-time fault detection,

TEŞEKKÜR

Öncelikle, bilgi ve akademik rehberliğiyle sürecimi yönlendiren, titiz değerlendirmeleri ve yapıcı eleştirileriyle çalışmamın bilimsel niteliğini güçlendiren değerli danışman hocam Dr. Öğr. Üyesi Burcu YILMAZEL'e en içten teşekkürlerimi sunarım. Konu seçiminden araştırmanın yürütülmesine kadar bana sağladığı akademik destek, bu çalışmanın gelişimine büyük katkı sağlamıştır.

Tez savunma jürimde yer alarak değerli görüşleriyle araştırmamın şekillenmesinde önemli rol oynayan Doç. Dr. Efnan ŞORA GÜNAL ve Doç. Dr. Sevcan YILMAZ GÜNDÜZ hocalarıma teşekkürü bir borç bilirim.

Ayrıca, test ortamında kullandığım kamera tutucunun tasarımında sağladığı destekle çalışmamın ilerlemesini kolaylaştıran kardeşim Ecem ATAMAN'a teşekkür ederim.

Son olarak, bu süreçte destekleriyle her zaman yanımda olan, sabır ve sevgileriyle bana güç veren anne ve babama en derin şükranlarımı sunarım. Onların desteği olmadan bu süreci başarıyla tamamlamak çok daha zor olurdu.

Utku ATAMAN

ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ

Bu tezin bana ait, özgün bir çalışma olduğunu; çalışmamın hazırlık, veri toplama, analiz ve bilgilerin sunumu olmak üzere tüm aşamalarında bilimsel etik ve kurallara uygun davrandığımı; bu çalışma kapsamında elde edilen tüm veri ve bilgiler için kaynak gösterdiğimi ve bu kaynaklara kaynakçada yer verdiğimi; bu çalışmanın Eskişehir Teknik Üniversitesi tarafından kullanılan “bilimsel intihal tespit programı”yla tarandığını ve hiçbir şekilde “intihal içermediğini” beyan ederim. Herhangi bir zamanda, çalışmamla ilgili yaptığım bu beyana aykırı bir durumun saptanması durumunda, ortaya çıkacak tüm ahlaki ve hukuki sonuçları kabul ettiğimi bildiririm.

Utku ATAMAN

İÇİNDEKİLER

	<u>Sayfa</u>
BAŞLIK SAYFASI	I
JÜRİ VE ENSTİTÜ ONAYI.....	II
DANIŞMAN ONAYI	III
ÖZET	IV
ABSTRACT.....	V
TEŞEKKÜR	VI
ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ.....	VII
İÇİNDEKİLER	VIII
TABLolar DİZİNİ.....	XII
ŞEKİLLER DİZİNİ.....	XIII
GÖRSELLER DİZİNİ	XIV
SİMGELER VE KISALTMALAR DİZİNİ.....	XV
1. GİRİŞ	1
2. 3D YAZICILAR VE ANOMALİLER	3
2.1. Katmanlı Üretim	3
2.2. 3D Baskı Teknolojisi	4
2.3. 3D Yazıcı Türleri.....	8
2.3.1. SLA	8
2.3.2. SLS.....	9
2.3.3. FDM.....	10
2.4. FDM 3D Yazıcıların Bileşenleri.....	12
2.4.1. Yazılımsal bileşenler.....	12
2.4.2. Donanımsal bileşenler	14
2.4.2.1. Çerçeve ve yapısal bileşenler	14
2.4.2.2. Hareketi sağlayan bileşenler	15
2.4.2.3. Filament akışından sorumlu bileşenler	15
2.4.2.4. Isıtıcı bileşenler.....	16

2.4.2.5. Elektronik bileşenler.....	16
2.4.2.6. Fanlar ve soğutma sistemleri	16
2.4.2.7. Sensörler	17
2.5. 3D Yazıcılarda Yaygın Anomali Türleri.....	18
2.5.1. İpliklenme.....	18
2.5.2. Spagetti	19
2.5.3. İlk katman sorunları	19
2.5.4. Aşırı ekstrüzyon ve yetersiz ekstrüzyon	20
2.5.5. Çatlama	20
2.5.6. Katman kayması.....	20
2.5.7. Nozul tıkanması	21
3. 3D YAZICILARDA ANOMALİ TESPİTİ	22
3.1. Bilgisayarlı Görü	22
3.2. Nesne Tespiti ve Segmentasyonu	23
3.2.1. YOLO	24
3.2.2. Faster R-CNN	25
3.2.3. Mask R-CNN.....	26
3.2.4. U-Net.....	26
3.3. Sınıflandırma	26
3.3.1. AlexNet	27
3.3.2. VGGNet.....	27
3.3.3. ResNet.....	27
3.3.4. EfficientNet	29
3.4. 3D Yazıcılarda Anomali Tespit Yaklaşımları.....	30
3.4.1. Sensör tabanlı yaklaşımlar	30
3.4.2. Görüntü işleme ve makine öğrenimi tabanlı yaklaşımlar	31
3.4.3. Ticari çözümler	32
3.5. Derin Öğrenme ile Anomali Tespitinin Avantajları	33
3.6. Literatürde Karşılaşılabilecek Zorluklar	33
4. ÖNERİLEN İKİ AŞAMALI ANOMALİ TESPİT YÖNTEMİ	35
4.1. Problem Tanımı ve Önerilen Yöntem	35
4.2. Baskı Tespiti ve Segmentasyon Modeli	36

4.2.1. Segmentasyon veri seti	36
4.2.1.1. Veri setinin toplanması.....	37
4.2.1.2. Veri setinin etiketlenmesi	37
4.2.1.3. Veri setinin dağılımı	38
4.2.1.4. Ön işleme ve veri arttırma teknikleri.....	39
4.2.2. Segmentasyon modelinin eğitimi.....	40
4.3. Anomali Tespiti ve Sınıflandırma Modeli.....	40
4.3.1. Sınıflandırma veri seti.....	41
4.3.1.1. Veri setinin hazırlanması	41
4.3.1.2. Veri setinin etiketlenmesi	42
4.3.1.3. Veri setinin dağılımı	43
4.3.1.4. Ön işleme ve veri arttırma teknikleri.....	44
4.3.2. Sınıflandırma modelinin eğitimi	44
5. DENEYLER VE BULGULAR	46
5.1. Deneysel Altyapı.....	46
5.2. Baskı Tespiti ve Segmentasyon Modelinin Performansı	48
5.3. Anomali Tespiti ve Sınıflandırma Modellerinin Performansı	50
5.3.1. EfficientNet ve ResNet modellerinin eğitim performansları.....	51
5.3.2. EfficientNet ve ResNet test performansları	52
5.3.3. EfficientNet ve ResNet modellerinin karşılaştırmalı analizi	53
5.4. Önerilen İki Aşamalı Modelin Ek Testler ile Değerlendirilmesi	54
6. TEST ORTAMI MODEL ENTEGRASYONU	55
6.1. Gerçek Zamanlı Test Ortamı ve Yapısı	55
6.1.1. Raspberry Pi üzerinde Klipper firmware kullanımı.....	56
6.1.2. Elektrik kesintilerine karşı UPS ve test ortamının entegrasyonu.....	58
6.1.3. Görüntü akışının alınacağı kameranın sistem ile entegrasyonu	60
6.1.4. Analiz ortamında görüntünün yakalanması ve işlenmesi.....	61
6.2. Gerçek Zamanlı Performans Sonuçları	64
7. SONUÇ VE ÖNERİLER.....	66
KAYNAKÇA.....	68
EKLER	

ÖZGEÇMİŞ



TABLolar DİZİNİ

	<u>Sayfa</u>
Tablo 2.1. AM teknolojileri sınıflandırması	4
Tablo 3.1. Nesne tespiti ve segmentasyonunda kullanılan yaygın algoritmalar	24
Tablo 3.2. Sınıflandırmada kullanılan yaygın algoritmalar	27
Tablo 4.1. Sınıflandırma veri setinin sınıf bazlı dağılımı	43
Tablo 4.2. Sınıflandırma veri setinin bölünmesi	43
Tablo 5.1. Modellerin eğitildiği ve çalıştırıldığı donanım bileşenleri	46
Tablo 5.2. Kullanılan yazılım bileşenleri ve kütüphaneler	47
Tablo 5.3. Model başarımı değerlendirilmede kullanılan metrikler.....	48
Tablo 5.4. YOLOv11 segmentasyon modeli için belirlenen eğitim parametreleri	48
Tablo 5.5. Segmentasyon modeli metriklerinin karşılaştırılması.....	49
Tablo 5.6. Sınıflandırma modelleri için belirlenen eğitim parametreleri.....	51
Tablo 5.7. Sınıflandırma modellerinin eğitim metriklerinin karşılaştırılması	52
Tablo 5.8. Sınıflandırma modellerinin test performanslarının sınıf bazlı karşılaştırması	52
Tablo 6.1. Kamera özellikleri.....	60

ŞEKİLLER DİZİNİ

	<u>Sayfa</u>
Şekil 2.1. 3D baskı teknolojisinin evrimi	6
Şekil 2.2. 3D baskı teknolojisi uygulama alanları	7
Şekil 2.3. Küresel 3D yazıcı pazarı boyutu ve görünümü (KBV Research, 2023)	8
Şekil 2.4. 3D yazıcının yazılımsal süreci	13
Şekil 2.5. FDM tipi 3D yazıcıların donanımsal bileşenleri (Prianto & Pramono, 2021)	14
Şekil 3.1. Bilgisayarlı görü	23
Şekil 3.2. YOLO sürümlerinin performansları (Ultralytics, 2024)	25
Şekil 3.3. ResNet -34 mimarisi (He, Zhang, Ren, & Sun, 2016)	28
Şekil 3.4. ImageNet veri setinde sınıflandırma algoritmalarının performansı (Tan & Le, 2019)	29
Şekil 3.5. EfficientNet blok yapısı (Yahia Ibrahim & Talaat, 2022)	30
Şekil 4.1. D3PAD-X akış şeması	36
Şekil 4.2. Veri setinin dağılımı	38
Şekil 4.3. Veri setinin bölünme oranları	39
Şekil 5.1. Eğitim sürecinde metriklerin değişimi	49
Şekil 5.2. Segmentasyon modeli karmaşıklık matrislerinin karşılaştırılması	50
Şekil 5.3. EfficientNet eğitim sürecinde doğruluk ve kayıp metrikleri	51
Şekil 5.4. ResNet eğitim sürecinde doğruluk ve kayıp metrikleri	52
Şekil 5.5. Sınıflandırma modellerinin doğrulama veri setindeki sınıf bazlı karmaşıklık matrisi	52
Şekil 5.6. Sınıflandırma modellerinin test veri setindeki sınıf bazlı karmaşıklık matrisi	53
Şekil 6.1. Sistemin genel özeti	56
Şekil 6.2. Gerçek zamanlı test ortamında D3PAD-X süreçleri	62

GÖRSELLER DİZİNİ

	<u>Sayfa</u>
Görsel 2.1. Formlabs tarafından üretilen SLA türü 3D yazıcı	9
Görsel 2.2. SLS türü 3D yazıcı	10
Görsel 2.3. FDM türü 3D yazıcı.....	11
Görsel 2.4. PrusaSlicer yazılımının arayüz ekranı	13
Görsel 2.5. FDM türü kartezyen tip bir yazıcının yapısal bileşenleri	15
Görsel 2.6. BMG model bir ekstrüder.....	16
Görsel 2.7. Creality tarafından üretilen bir filament sensörü.....	17
Görsel 2.8. Sensörler	17
Görsel 2.9. 3D yazıcılarda karşılaşılan yaygın anomali türleri	18
Görsel 3.1. Ticari çözümler.....	33
Görsel 4.1. Segmentasyon veri setinden örnek görüntüler	37
Görsel 4.2. Baskı tespiti ve segmentasyon veri seti etiketleme örnekleri.....	38
Görsel 4.3. Sınıflandırma için hazırlanan veri setinden örnek görüntüler	42
Görsel 4.4. Sınıflandırma veri seti etiketleme örnekleri	42
Görsel 5.1. TensorBoard görüntüsü	47
Görsel 5.2. Hiperparametre optimizasyonu	49
Görsel 5.3. Test veri setinde modelin yaptığı tahmin örnekleri.....	50
Görsel 5.4. Açık kaynak görsellerle test edilmesi	54
Görsel 6.1. Makerbase MKS Gen L V1.0 model kontrol kartı	57
Görsel 6.2. Test ortamının Mainsail arayüzü	58
Görsel 6.3. Makro ve python betiği	59
Görsel 6.4. UPS ve test ortamı bağlantısı	60
Görsel 6.5. Kameranın konumlanması.....	61
Görsel 6.6. Yakalanan Görüntü.....	62
Görsel 6.7. Segmentasyon sonrası elde edilen örnek görüntüler	63
Görsel 6.8. Gerçek zamanlı test ortamı “Hatasız baskı” (Good) sınıfına ait örnek çıktı	63
Görsel 6.9. Gerçek zamanlı test ortamı “İpliklenme” (Stringing) sınıfına ait örnek çıktı	64
Görsel 6.10. Modelin gerçek zamanlı çalışma zamanlamaları	65

SİMGELER VE KISALTMALAR DİZİNİ

2D	: Two Dimensions (İki Boyutlu)
3D	: Three Dimensions (Üç Boyutlu)
ABL	: Auto Bed Leveling (Otomatik Yatak Seviyelendirme)
ABS	: Acrylonitrile Butadiene Styrene (Akrilonitril Bütadien Stiren)
AC	: Alternating Current (Alternatif Akım)
AI	: Artificial Intelligence (Yapay Zekâ)
AM	: Additive Manufacturing (Katmanlı Üretim)
API	: Application Programming Interface (Uygulama Programlama Arayüzü)
ASTM	: American Society for Testing and Materials (Amerikan Test ve Malzeme Derneği)
CAD	: Computer Aided Design (Bilgisayar Destekli Tasarım)
CAGR	: Compound Annual Growth Rate (Bileşik Yıllık Büyüme Oranı)
CNN	: Convolutional Neural Network (Evrilmiş Sinir Ağı)
CPU	: Central Processing Unit (Merkezi İşlem Birimi)
CSI	: Camera Serial Interface (Kamera Seri Arayüzü)
CUDA	: Compute Unified Device Architecture (Birleşik Cihaz Hesaplama Mimarisi)
DC	: Direct Current (Doğru Akım)
DED	: Directed Energy Deposition (Yönlendirilmiş Enerji Biriktirme)
FDM	: Fused Deposition Modeling (Eriyik Biriktirmeli Modelleme)
FFF	: Fused Filament Fabrication (Erimiş Filament İmalatı)
FM	: Formative Manufacturing (Biçimlendirici Üretim)
FN	: False Negative (Yanlış Negatif)
FP	: False Positive (Yanlış Pozitif)
G-Code	: Geometric Code (Geometrik Kod)
GPU	: Graphics Processing Unit (Grafik İşlem Birimi)
GUI	: Graphical User Interface (Grafiksel Kullanıcı Arayüzü)
IoU	: Intersection over Union (Birleşim Üzerinde Kesişim)
JSON	: JavaScript Object Notation (JavaScript Nesne Gösterimi)
LSTM	: Long Short-Term Memory (Uzun Kısa Süreli Bellek)

mAP	: Mean Average Precision (Ortalama Kesinlik)
MJPEG	: Motion JPEG (Hareketli JPEG Video Formatı)
OpenCV	: Open Source Computer Vision (Açık Kaynaklı Bilgisayarlı Görü Kütüphanesi)
PSU	: Power Supply Unit (Güç Kaynağı Birimi)
R-CNN	: Region-based Convolutional Neural Network (Bölge Tabanlı Evrilmiş Sinir Ağı)
RAM	: Random Access Memory (Rastgele Erişimli Bellek)
ResNet	: Residual Neural Network (Artık Sinir Ağı)
ROI	: Region of Interest (İlgili Bölge)
SLA	: Stereolithography (Stereolitografi)
SLS	: Selective Laser Sintering (Seçici Lazer Sinterleme)
SM	: Subtractive Manufacturing (Çıkartmalı Üretim)
UPS	: Uninterruptible Power Supply (Kesintisiz Güç Kaynağı)
UV	: Ultraviolet (Ultraviyole veya Morötesi)
VGGNet	: Visual Geometry Group Network (Görsel Geometri Grubu Ağı)
YOLOv11	: You Only Look Once Version 11

1. GİRİŞ

3D yazıcı teknolojisi, esnek üretim kabiliyeti, düşük maliyetli prototipleme imkânı ve kişiselleştirilmiş üretim süreçleri gibi avantajlarıyla üretim alanında önemli bir konuma ulaşmıştır. Havacılık, otomotiv, sağlık ve tüketici elektroniği gibi birçok sektörde kullanılan bu teknoloji, karmaşık ve özelleştirilmiş parçaların üretimini mümkün kılmaktadır. Ancak, 3D baskı süreci belirli sınırlamalar ve teknik zorluklarla karşı karşıyadır. Baskı sırasında meydana gelen hatalar, üretim sürecini olumsuz etkileyerek maliyet artışına, zaman kaybına ve kalite sorunlarına neden olmaktadır. Malzeme, donanım, kalibrasyon ve baskı ayarları gibi birçok faktörden kaynaklanabilen bu hatalar, baskının başarısız olmasına yol açabilir. Hatalı baskılar yalnızca üretim verimliliğini düşürmekle kalmayıp, aynı zamanda uzun vadede yazıcı donanımına zarar verebilmekte ve bakım maliyetlerini artırmaktadır. Bu nedenle, baskı hatalarının erken tespit edilmesi ve gerektiğinde üretim sürecinin durdurulması, malzeme israfını önlemek ve kaliteyi artırmak açısından kritik bir gereklilik olarak değerlendirilmektedir.

Günümüzde 3D baskı sürecinde meydana gelen hatalar çoğunlukla operatörler tarafından gözle tespit edilmektedir. Ancak bu yöntem, zaman alıcı olup insan hatasına açık olduğu için baskı sürecinin güvenilirliğini ve etkinliğini olumsuz etkileyebilmektedir. Ayrıca, sürekli gözlem gerektiren bu yaklaşım, üretim süreçlerinin ölçeklenebilirliğini sınırlandırmaktadır. Baskı sürecini kesintisiz olarak izleyerek hataları otomatik olarak tespit edebilen bir sistem, operatör üzerindeki yükü azaltırken aynı zamanda üretim süreçlerinin daha güvenilir ve verimli hale gelmesini sağlayacaktır.

Bu çalışmada, baskı sırasında meydana gelen hataların otomatik olarak tespit edilmesi ve sınıflandırılmasına yönelik bir derin öğrenme tabanlı yöntem geliştirilmiştir. Önerilen yöntem, iki aşamalı bir hata tespit sürecine sahiptir. İlk aşamada, baskı alanının çevreden izole edilmesi amacıyla YOLOv11 tabanlı bir segmentasyon modeli kullanılmış ve yalnızca baskıya ait bölgeler ayrıştırılmıştır. Böylece, sınıflandırma modelinin yalnızca baskıya odaklanması sağlanarak yanlış tespitlerin önüne geçilmiştir. Segmentasyon aşamasının ardından, ayrıştırılan baskı alanları EfficientNet ve ResNet modelleri ile sınıflandırılmıştır. Modelin uygulanabilirliğini değerlendirmek amacıyla, gerçek dünya koşullarına uygun bir test ortamı oluşturulmuş ve farklı hata senaryolarında performansı incelenmiştir. Bu süreçte, geliştirilen yöntemin üretim sürecine entegrasyonu ve hataların erken tespiti açısından sağladığı avantajlar gözlemlenmiştir.

Bu tez çalışmasının ana katkıları aşağıda sıralanmıştır:

- İki aşamalı bir hata tespit mekanizması geliştirilmiştir: Literatürde genellikle doğrudan sınıflandırma yöntemleri kullanılmasına karşın, bu çalışmada öncelikle baskı alanı segmentasyon yöntemiyle arka plandan ayrıştırılmış, ardından sınıflandırma işlemi gerçekleştirilmiştir. Bu sayede hata tespit doğruluğu artırılmış ve yanlış sınıflandırmalar minimize edilmiştir.
- Gerçek dünya koşullarına uygun bir test ortamı oluşturulmuştur: Çalışmada yalnızca simülasyon veya statik görüntüler üzerinden bir analiz yapılmamış, fiziksel bir 3D yazıcı ortamında testler gerçekleştirilmiştir. Bu sayede modelin pratikte nasıl çalıştığı gözlemlenmiş ve üretim süreçlerine entegre edilme potansiyeli değerlendirilmiştir.
- Çalışma amacına uygun veri seti oluşturulmuştur: Veri seti, modelin eğitim ve test süreçlerinde kullanılmak hazırlanmıştır.
- Geliştirilen sistem, üretim sürecinin verimliliğini artırmayı hedeflemektedir: Otomatik hata tespiti sayesinde, hatalı baskıların erken aşamada tespit edilerek üretimin durdurulması veya düzeltilmesi sağlanmış, böylece malzeme israfı ve zaman kaybı en aza indirilmeye çalışılmıştır.

Bu tez yedi bölümden oluşmaktadır. İlk bölümde, 3D yazıcı teknolojisinin genel yapısı, avantajları ve karşılaşılan problemler ele alınarak çalışmanın amacı ve önemi açıklanmıştır. İkinci bölümde, 3D yazıcı teknolojisinin tarihçesi ve ilgili teorik çerçeve sunulmuştur. Üçüncü bölümde, baskı hatalarının tespiti ve sınıflandırılmasına yönelik literatürde yer alan çalışmalar incelenmiş ve mevcut yöntemlerin avantajları ile sınırlılıkları değerlendirilmiştir. Dördüncü bölümde, çalışmada önerilen yöntem detaylı olarak açıklanmış, kullanılan veri setleri, derin öğrenme modelleri ve uygulanan teknikler hakkında bilgi verilmiştir. Beşinci bölümde, geliştirilen modelin eğitimi ve performans değerlendirmesi yapılmıştır. Altıncı bölümde, modelin test ortamında ve gerçek dünya senaryolarındaki entegrasyonu ele alınmıştır. Son olarak, yedinci bölümde elde edilen bulgular özetlenerek gelecekte yapılabilecek çalışmalar için öneriler sunulmuştur.

2. 3D YAZICILAR VE ANOMALİLER

Son yıllarda hızla gelişen 3D yazıcı teknolojisi, üretim süreçlerinde devrim niteliğinde yenilikler sunarak hem endüstriyel hem de bireysel kullanım alanlarında yaygınlaşmıştır. Bu bölümde, öncelikle katmanlı üretim teknolojisi ele alınarak, 3D baskı teknolojisinin tarihçesi ve gelişim sürecine değinilecektir. Ardından, günümüzde yaygın olarak kullanılan 3D yazıcı türleri detaylandırılacak, bu çalışmanın temelini oluşturan Eriyik Biriktirmeli Modelleme (*Fused Deposition Modeling*, FDM) tipi 3D yazıcıların yazılımsal ve donanımsal bileşenleri kapsamlı şekilde ele alınacaktır. Ayrıca, 3D yazıcılar ile üretim süreçlerinde sıkça karşılaşılan baskı hataları ve yaygın anomali türleri incelenecek, bu hataların nedenleri ve olası çözümleri değerlendirilecektir. Bu temel bilgiler, çalışmanın ilerleyen bölümlerinde ele alınacak anomali tespit yöntemleri ve yapay zekâ tabanlı çözümler için gerekli teorik altyapıyı oluşturacaktır.

2.1. Katmanlı Üretim

Geleneksel üretim yöntemleri, genellikle malzemeyi şekillendirerek (Biçimlendirici Üretim- *Formative Manufacturing*, FM) veya bir blok malzemedan keserek (Çıkartmalı Üretim- *Subtractive Manufacturing*, SM) parçaların üretilmesini sağlar. Katmanlı Üretim (*Additive Manufacturing*, AM) ise bu yaklaşımlardan farklı olarak malzemenin üst üste katmanlar halinde biriktirilmesi yoluyla üretim yapan modern bir yöntemdir (ASTM International, 2012).

Nesnelerin bilgisayar destekli tasarım (*Computer Aided Design*, CAD) modelini baz alarak, boş platform üzerine katman katman malzeme eklenmesiyle ilgili nesnenin fiziksel olarak üretilmesini sağlayan AM yöntemi, özellikle karmaşık geometrilere sahip nesnelerin üretilmesi için idealdir (Gibson, Rosen, & Stucker, 2015). Bu sayede geleneksel yöntemlerle üretilmesi zor nesneler AM yöntemiyle daha kolay üretilebilir. Ayrıca, sağladığı malzeme verimliliği, özelleştirilebilir üretim ve hızlı prototipleme avantajları, AM yöntemini modern üretim teknolojileri arasında önemli bir konuma taşımaktadır.

AM teknolojileri, malzeme türüne ve üretim yöntemine göre genellikle yedi ana kategori altında sınıflandırılmaktadır (ASTM International, 2012). İlgili kategoriler Tablo 2.1'de sunulmaktadır.

Tablo 2.1. AM teknolojileri sınıflandırması

Kategori	Açıklama
Malzeme Ekstrüzyonu	Malzemenin bir nozul vasıtasıyla eritilmesi sonucu katmanlar halinde eklenerek üretim yapılır. 3D yazıcılarda FDM tipi bu kategoriye dahildir.
Malzeme Püskürtme	Malzemenin püskürtme yoluyla katmanların oluşturulması ile üretim yapılır.
Toz Yatak Füzyonu	Yatak üzerinde bulunan toz haldeki malzemenin bir ışın aracılığıyla seçici şekilde eritilmesiyle üretim yapılır. 3D yazıcılarda SLS tipi bu kategoriye dahildir.
Bağlayıcı Püskürtme	Toz haldeki malzemeye bir bağlayıcı malzeme püskürtülerek üretim yapılır.
Doğrudan Enerji Depolama	Malzeme bir ışın altında eritilerek katmanlar halinde eklenerek üretim yapılır.
Tabaka Laminasyonu	Malzeme katmanlarının yapıştırma gibi yöntemlerle üst üste eklenmesi ile üretim yapılır.
Fotopolimerizasyon	Sıvılaştırılmış reçinenin UV ışınla sertleştirilmesi ile üretim yapılır. 3D yazıcılarda SLA tipi bu kategoriye dahildir.

Bu kategorilerin her biri, üretim hızından yüzey kalitesine kadar farklı avantajlar ve sınırlamalar sunmaktadır. Örneğin, malzeme ekstrüzyonu kategorisinde düşük maliyet ve erişilebilirlik açısından öne çıkarken, yüzey pürüzlülüğü ve hassasiyet açısından sınırlamalar içermektedir (Ngo, Kashani, Imbalzano, Nguyen, & Hui, 2018).

Diğer taraftan, Seçici Lazer Sinterleme (*Selective Laser Sintering*, SLS) ve Doğrudan Enerji Depolama (*Directed Energy Deposition*, DED) gibi yöntemler, havacılık ve otomotiv sektörlerinde yüksek hassasiyet gerektiren parçaların üretimi için yaygın olarak tercih edilmektedir (Gibson, Rosen, & Stucker, 2015). Ayrıca, fotopolimerizasyon yöntemi, medikal uygulamalarda, diş implantları ve protezler gibi yüksek doğruluk gerektiren parçaların üretiminde kullanılmaktadır (Rengier, et al., 2010). Bu yetenekler, AM teknolojisinin farklı endüstriyel sektörlere yanıt verebilmesini sağlamaktadır.

2.2. 3D Baskı Teknolojisi

AM teknolojisinin belirli bir uygulama alanı olan 3D baskı, katmanlı üretimin en yaygın kullanılan hali olarak günümüzde öne çıkmaktadır.

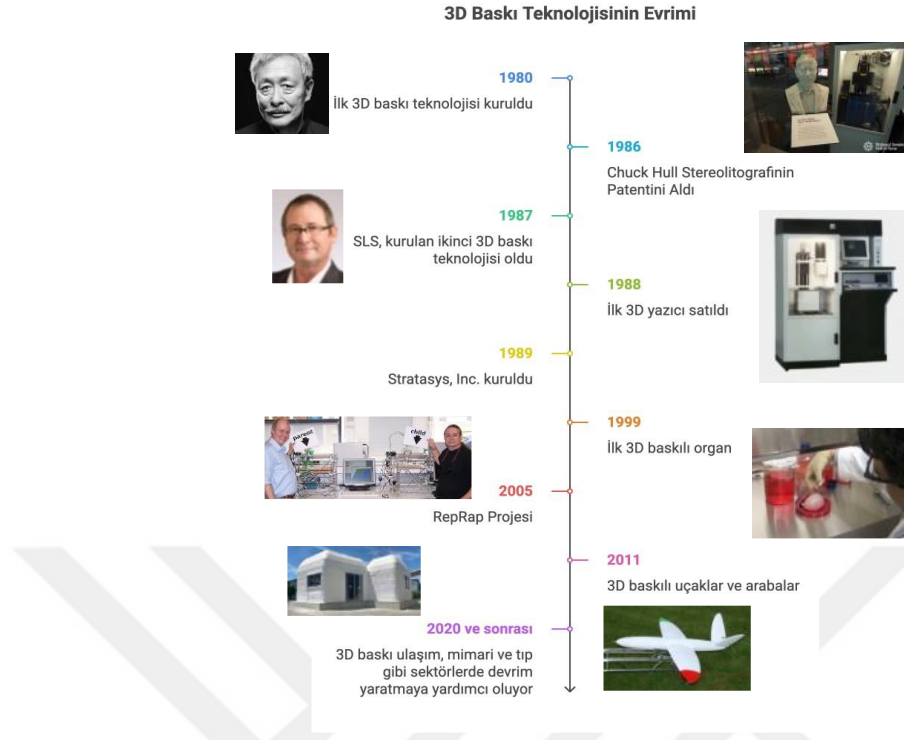
3D baskı teknolojisinin kökenleri, 1980'lerin başlarına kadar uzanmaktadır. Japon araştırmacı Hideo Kodama, Morötesi (*Ultraviyole*, UV) ışığını kullanarak ışığa duyarlı bir reçineyi polimerize eden sistem tasarlayarak, 3D baskı teknolojisinin ilk adımlarını atmıştır. Ancak, bu teknolojinin patentini almayı başaramamıştır (Buj-Corral, Tejo-Otero, & Fenollosa-Artés, 2022).

Charles Hull, mobilya üretiminde ihtiyaç duyduğu küçük ve özel parçaları hızlı bir şekilde temin edebilmek için yeni bir yöntem arayışına girmiştir. Bu doğrultuda geliştirdiği Stereolitografi (*Stereolithography*, SLA) yöntemi, 3D baskı teknolojisinin temellerini atmıştır. 1986 yılında SLA yönteminin patentini alan Hull, bu teknolojiyi ticarileştirmek amacıyla aynı yıl içerisinde “3D Systems” şirketini kurmuştur. Bu şirket, 1988 yılında dünyanın ilk ticari 3D yazıcısı olan SLA-1'i piyasaya sürmüştür (Gibson, Rosen, & Stucker, 2015).

2005 yılında, RepRap Projesi, Dr. Adrian Bowyer liderliğinde geliştirilen ve kendi bileşenlerini üretebilen ilk kendini kopyalayabilen üretim makinesi olarak 3D baskı tarihinde önemli bir dönüm noktası olmuştur. Açık kaynaklı ve erişilebilir üretim hedefiyle ortaya çıkan bu proje, bireylerin ve küçük işletmelerin kendi 3D yazıcılarını üretmelerine olanak tanıyarak AM teknolojisinin yaygınlaşmasını hızlandırmıştır (Sells, Bailard, Smith, Bowyer, & Olliver, 2010).

2011 yılına gelindiğinde, 3D baskı teknolojisinin endüstriyel alandaki potansiyeli daha belirgin hale gelmiş ve Southampton Üniversitesi, ilk insansız hava aracını 3D baskı teknolojiyle üreterek havacılık alanında yeni bir çığır açmıştır. Aynı dönemde, Kor Ecologic şirketi, Urbee adı verilen 3D baskı teknolojiyle üretilmiş bir otomobil prototipi tanıtmış ve otomotiv sektöründe bu teknolojinin kullanımına yönelik önemli bir adım atmıştır (Attaran, 2017).

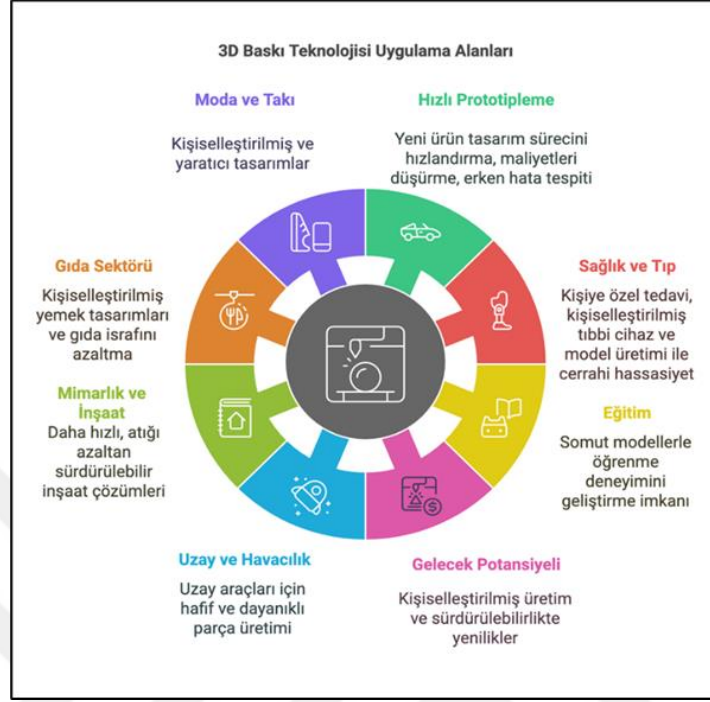
3D baskı teknolojisinin önemli kilometre taşları Şekil 2.1'de özetlenmiştir. Hull tarafından temelleri atılan bu teknoloji, günümüze kadar gelişimini sürdürerek önemli bir konuma ulaşmıştır. SLA üretim yöntemine ek olarak, FDM ve SLS gibi üretim teknikleri de 3D baskı ailesine katılmıştır. Zamanla, maliyetlerin düşmesiyle birlikte bireysel kullanıcıların da bu teknolojiye erişimi kolaylaşmıştır.



Şekil 2.1. 3D baskı teknolojisinin evrimi

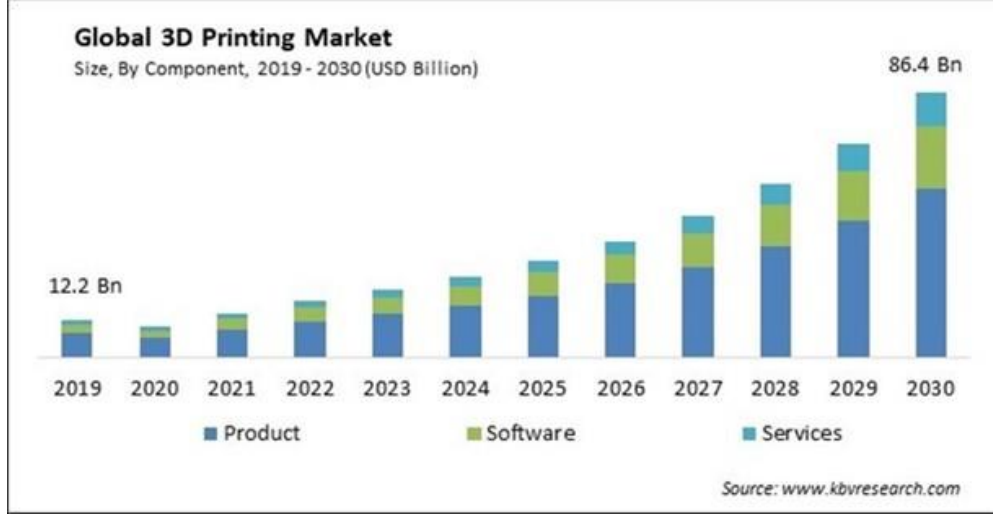
Bu gelişmeler, 3D baskının ileri teknoloji gerektiren sektörlerde de benimsenmeye başlamasına zemin hazırlamıştır. Günümüzde 3D baskı teknolojisi, endüstriyel ihtiyaçlardan bireysel ve ev içi kullanıma kadar farklı amaçlara hizmet etmekte; kullanımı gün geçtikçe yaygınlaşmaktadır. Amerikan Test ve Malzeme Derneği (*American Society for Testing and Materials, ASTM*) tarafından desteklenen ve Wohlers şirketi tarafından yıllık olarak yayımlanan raporlar, 3D baskı ve AM sektörüne yönelik kapsamlı analizler ve geleceğe yönelik öngörüler sunmaktadır (Wohlers Associates, 2020). Raporla, 3D yazıcıların başlangıçta yalnızca prototipleme amacıyla kullanıldığı, ancak zamanla maliyet avantajı, esneklik ve üretim hızındaki gelişmeler sayesinde farklı sektörlerde giderek daha fazla kullanıldığı belirtilmektedir. Havacılık, otomotiv, inşaat, medikal, biyomedikal, doku mühendisliği, tersine mühendislik ve tüketici elektroniği gibi alanlarda, hızlı prototipleme, kişiselleştirilmiş üretim ve düşük maliyetli imalat avantajları sayesinde kullanım alanı giderek genişlemektedir (Ahangar, Cooke, Weber, & Rosenzweig, 2019), (Akman & Sadhu, 2024), (Dutta, Hexiu, Patel, Ganguly, & Lim, 2021), (Iglesias, et al., 2017), (Prasittisopin, 2024), (Rogers, Baricz, & Pawar, 2016), (Wawryniuk, Brancewicz-Steinmetz, & Sawicki, 2024), (Wu, Wang, & Wang, 2016), (Xu, Ding, & Love, 2017).

Şekil 2.2’de 3D baskı teknolojisinin çeşitli sektörlerdeki uygulama alanları gösterilmektedir.



Şekil 2.2. 3D baskı teknolojisi uygulama alanları

3D baskı teknolojisinin geniş uygulama alanlarına sahip olması, küresel pazarda bu teknolojinin benimsenme hızını artırmakta ve pazar büyüklüğünün giderek genişlemesine katkı sağlamaktadır. KBV Research (2023) tarafından yayımlanan rapora göre, 2019 yılında 12,2 milyar dolar seviyesinde olan küresel 3D baskı pazarı, 2024 yılında 22 milyar dolara ulaşmıştır. Yapılan projeksiyonlara göre, 2030 yılına kadar yıllık bileşik büyüme oranının (*Compound Annual Growth Rate, CAGR*) %21,4 seviyelerinde artması ve pazar büyüklüğünün yaklaşık 86,4 milyar dolara ulaşması öngörülmektedir (Şekil 2.3). Bu büyüme trendi incelendiğinde, 3D baskı ekosisteminin üç temel bileşeni olan ürün, yazılım ve hizmet açısından ürün bileşeni kategorisindeki büyümenin daha belirgin olduğu görülmektedir. Özellikle endüstriyel üretim süreçlerinde artan 3D yazıcı kullanımı, teknolojik gelişmeler ve malzeme çeşitliliğindeki artış, pazarın genişlemesini destekleyen temel faktörler arasında yer almaktadır.



Şekil 2.3. Küresel 3D yazıcı pazarı boyutu ve görünümü (KBV Research, 2023)


2.3. 3D Yazıcı Türleri

3D yazıcılar, genel anlamda 3D baskı teknolojisini gerçekleştiren donanımlardır. Temel olarak, bir dijital modelden alınan veriyi kullanarak fiziksel nesnelere üretirler. 3D yazıcılar, farklı malzemelerle (plastik, metal, seramik, biyomalzemeler vb.) ve farklı üretim teknikleriyle çalışabilirler.

SLA, SLS ve FDM, 3D baskı teknolojilerinde yaygın olarak kullanılan farklı üretim yöntemlerindedir. Bunlar, teknik olarak AM yöntemleridir ancak aynı zamanda 3D yazıcı türleri bu üretim tekniklerine göre sınıflandırıldığından, 3D yazıcı türleri olarak da adlandırılabilirler. Bu üç yöntem, baskı sürecinde kullanılan malzeme, üretim hızı, hassasiyet ve uygulama alanları bakımından farklılık gösterir. Bu yazıcı türleri, avantajları ve dezavantajları doğrultusunda çeşitli alanlarda kullanılmaktadır.

2.3.1. SLA

3D yazıcı türleri arasında en eski ve hassas yöntemlerden biri olan SLA yazıcılar, fotopolimerizasyon prensibiyle çalışan ve sıvı haldeki fotopolimer reçinenin UV ışık veya lazer kullanılarak katılaştırılması yoluyla baskı yapan yazıcılardır. Baskı süreci, modelin katman katman sertleştirilmesiyle gerçekleşir ve genellikle bir reçine tankı içinde başlar. Baskı platformu, her katman tamamlandıkça yukarı doğru hareket eder ve böylece modelin istenilen geometrik formda katılaşması sağlanır. SLA yazıcıları, yüksek baskı çözünürlüğü ve pürüzsüz yüzey kalitesi sunması nedeniyle özellikle medikal, dental, mücevher tasarımı ve prototipleme alanlarında yaygın olarak tercih edilmektedir (Wang, Goyanes, Gaisford, & Basit, 2016). Görsel 2.1’de örnek bir SLA yazıcı sunulmuştur.



Görsel 2.1. Formlabs tarafından üretilen SLA türü 3D yazıcı

SLA yazıcılarının başlıca avantajları arasında hassas detayların üretilebilmesi, yüksek yüzey kalitesi ve endüstride prototipleme süreçlerinde sıkça kullanılması yer almaktadır. Bununla birlikte, bu yazıcılarla kullanılan fotopolimer reçinelerin uzun vadeli dayanıklılığının düşük olması, UV ışığına maruz kaldığında sararma ve kırılma eğilimi göstermesi ve kimyasal atık üretiminin yüksek olması gibi bazı dezavantajları bulunmaktadır. Ayrıca, SLA yazıcılarda kullanılan reçine malzemelerinin toksik özellikte olabilmesi, güvenlik önlemleri gerektirmektedir. Bu nedenle SLA yazıcıları, özellikle yüksek hassasiyet gerektiren uygulamalarda tercih edilse de mekanik dayanıklılık gerektiren üretim süreçlerinde sınırlı bir kullanım alanına sahiptir (Gibson, Rosen, & Stucker, 2015).

2.3.2. SLS

SLS yazıcılar, toz yatak füzyonu prensibiyle çalışan ve plastik, metal veya seramik tozlarının yüksek güçlü bir lazer ile seçici olarak sinterlenmesi (eritilerek birleştirilmesi) yoluyla baskı yapan sistemlerdir. Baskı süreci, ince bir toz tabakasının platform üzerine serilmesiyle başlar. Lazer, modelin ilgili katmanını sinterleyerek malzemeyi birleştirir ve platform bir miktar aşağı inerek yeni bir toz tabakasının serilmesine olanak tanır. Bu işlem, model tamamlanana kadar tekrar eder (Prabhakar, Saravanan, Lenin, Mayandi, & Ramalingam, 2021). Görsel 2.2’de örnek bir SLS türü yazıcı sunulmuştur.



Görsel 2.2. SLS türü 3D yazıcı

SLS yazıcılarının en büyük avantajlarından biri, baskı sırasında destek yapısına ihtiyaç duyulmamasıdır. Modelin etrafında kalan toz, doğal bir destek görevi görerek karmaşık ve iç içe geçmiş geometrilerin üretilmesine olanak tanır. Ayrıca, mekanik dayanıklılığı yüksek, fonksiyonel parçalar üretebilmesi, bu yazıcı türünü havacılık, otomotiv, biyomedikal ve mühendislik alanlarında yaygın hale getirmiştir. Metal ve plastik baskı imkânı sunması sayesinde, endüstriyel üretim süreçlerinde de tercih edilmektedir (Gibson, Rosen, & Stucker, 2015). Ancak, SLS yazıcılarının bazı dezavantajları da bulunmaktadır. Makine maliyetleri oldukça yüksektir, bu nedenle genellikle büyük ölçekli üretimler için ekonomik bir seçenek sunar. Ayrıca, baskı sonrası temizlik gerektirmesi, üretilen parçaların çevresindeki fazla tozun temizlenmesi ihtiyacını doğurmaktadır. Buna rağmen, sağlam ve fonksiyonel parçalar üretebilmesi ve destek yapısına ihtiyaç duymadan karmaşık tasarımları gerçekleştirebilmesi, SLS yazıcılarını endüstriyel üretimde önemli bir konuma taşımaktadır (Fina, Goyanes, Gaisford, & Basit, 2017).

2.3.3. FDM

FDM veya Eriyik Filament İmalatı (*Fused Filament Fabrication- FFF*), malzeme ekstrüzyon teknolojisini temel alan en yaygın 3D baskı yöntemlerinden biridir. Bu teknoloji, termoplastik filamentin (PLA, ABS, PETG vb.) ekstrüder (ısıtıcı uç) aracılığıyla eritilerek katmanlar halinde biriktirilmesi prensibiyle çalışır. Model, yazdırma platformunun üzerine alt kısımdan başlayarak yukarıya doğru katman katman oluşturulur. Ekstrüderin hareketi, G-code adı verilen bir komut setiyle yönlendirilerek baskı işlemi tamamlanır (Ngo, Kashani, Imbalzano, Nguyen, & Hui, 2018). Görsel 2.3'te örnek bir FDM türü yazıcı sunulmuştur.



Görsel 2.3. *FDM türü 3D yazıcı*

FDM yazıcılarının en büyük avantajlarından biri düşük maliyetli ve erişilebilir olmasıdır. Bu nedenle, hobi amaçlı kullanım, prototipleme, eğitim ve düşük maliyetli üretim süreçlerinde sıklıkla tercih edilmektedir. Ayrıca, bakımının ve kullanımının kolay olması, özellikle eğitim kurumlarında ve bireysel kullanıcılar arasında yaygınlaşmasını sağlamaktadır (Ngo, Kashani, Imbalzano, Nguyen, & Hui, 2018). Ancak, FDM yazıcılarının bazı sınırlamaları da bulunmaktadır. SLA veya SLS yazıcılara kıyasla baskı hassasiyeti daha düşüktür ve katmanların belirgin olması nedeniyle yüzey kalitesi daha pürüzlü olabilir, bu nedenle baskı sonrası işlem gerektirebilir. Ayrıca, karmaşık tasarımlar için destek yapıları gerekmektedir, bu da baskı sürecini uzatabilmekte ve ek malzeme tüketimine neden olabilmektedir (He, et al., 2024). Buna rağmen, düşük maliyetli üretim, geniş malzeme seçenekleri, kullanım kolaylığı, düşük malzeme atığı ve baskın çelik malzemelere kıyasla daha yüksek geri dönüştürülebilirliğin getirdiği çevre dostu yapısı nedeniyle FDM yazıcılar hem bireysel hem de endüstriyel alanlarda en yaygın olarak kullanılan 3D yazıcı türlerinden biri olmaya devam etmektedir (Lalegani Dezaki, Mohd Ariffin, & Hatami, 2021), (Li, Yu, Shen, & Zhang, 2019).

Bu tez çalışması, özellikle kartezyen tipi FDM yazıcılara odaklanmaktadır. Kartezyen sistem, X, Y ve Z eksenlerinde doğrusal hareket eden bir yapı temelinde çalışır ve bu eksenlerde adım motorları (step motor) ve lineer kızaklar yardımıyla hareket ederek katmanlı üretim gerçekleştirilmesini sağlar. Kartezyen sistemlerin en büyük

avantajlarından biri, basit ve modüler yapıları sayesinde geniş çapta uyarlanabilir ve kolayca kalibre edilebilir olmalarıdır. Ayrıca, hassasiyet açısından güvenilir sonuçlar vermesi ve piyasada yaygın olarak bulunması, bu yazıcı türünün hem endüstriyel hem de bireysel kullanıcılar tarafından tercih edilmesini sağlamaktadır. Ancak, hareketli parçaların fazla olması nedeniyle hız açısından bazı sınırlamaları bulunmakta ve belirli ölçeklerin üzerindeki baskılarda stabilite sorunları yaşanabilmektedir. Buna rağmen, yüksek doğruluk oranı, ekonomik olması ve açık kaynak yazılım desteği sayesinde Kartezyen tipi FDM yazıcılar, 3D baskı teknolojisinde en yaygın kullanılan sistemlerden biri olmaya devam etmektedir.

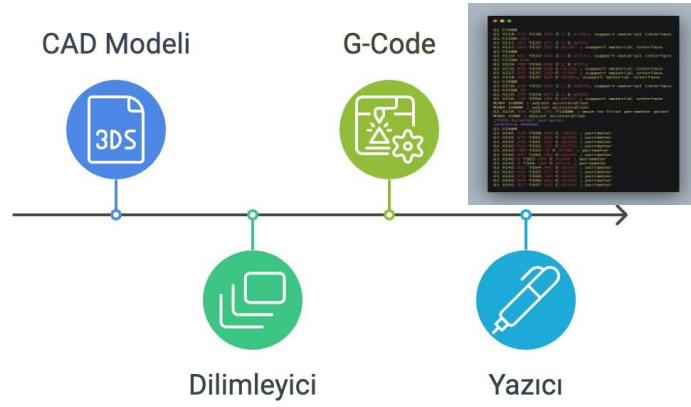
2.4. FDM 3D Yazıcıların Bileşenleri

FDM tipi 3D yazıcılar, yaygın kullanımları, basit tasarımları ve kullanıcı dostu yapılarıyla farklı uygulamalara uygun bir üretim teknolojisi sunmaktadır. Bu yazıcılar, AM sürecini gerçekleştirmek için belirli donanım ve yazılım bileşenlerine sahiptir. Yazıcının temel işleyiş mekanizmasını oluşturan bu bileşenler, tasarım aşamasından fiziksel üretime kadar geçen süreci yöneten kritik unsurlardır.

2.4.1. Yazılımsal bileşenler

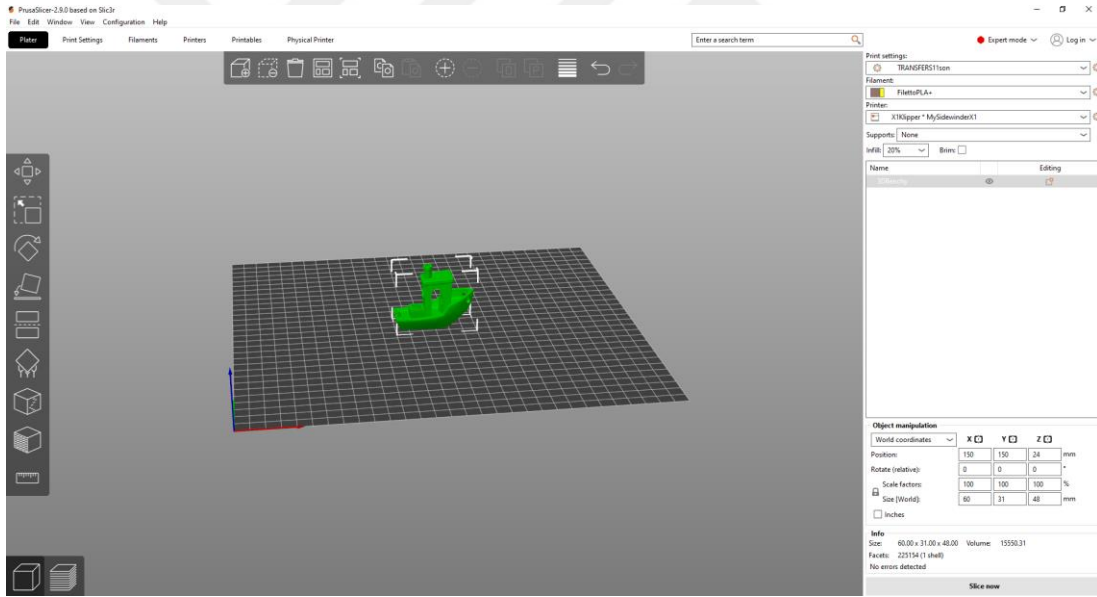
FDM yazıcılar, AM teknolojisinin bir parçası olarak, CAD dosyalarından fiziksel nesnelere üretmek amacıyla kullanılan cihazlardır. CAD dosyaları, dilimleyici (*Slicer*) adı verilen yazılımlar aracılığıyla işlenerek katmanlar halinde iki boyutlu (*Two Dimensions*, 2D) dilimlere ayrılır. Bu işlem, tasarımın 3D yazıcıların mikroişlemcileri tarafından anlaşılabilir hale gelmesini ve donanımların kontrol edilebilmesini sağlayan kritik bir süreçtir.

Dilimleyici yazılımı, kullanıcının belirlediği baskı parametrelerini göz önünde bulundurarak CAD modelini işleyerek yazıcının anlayabileceği G-Code olarak bilinen kodlara dönüştürür. Bu kodlar, 3D yazıcının hareket ve kontrol süreçlerini yöneten bir komut dizisidir. G-Code sayesinde motor hareketleri, malzeme akışı, baskı hızı ve ısıtıcıların sıcaklık değerleri gibi değişkenler kontrol edilir. Bu sayede yazıcı, tasarımın her katmanını belirlenen koordinatlar doğrultusunda üretir. Şekil 2.4'te bu sürecin genel akışı şematik olarak sunulmaktadır.



Şekil 2.4. 3D yazıcının yazılımsal süreci

Prusa Research tarafından geliştirilen “PrusaSlicer” adlı dilimleyici yazılımın arayüzüne ilişkin bir ekran görüntüsü Görşel 2.4’te sunulmuştur. Bu görsel, standart bir dilimleyici yazılımının kullanıcı arayüzü hakkında genel bir fikir vermekte olup, baskı ayarlarının nasıl yapılandırılabileceğini göstermektedir.



Görşel 2.4. PrusaSlicer yazılımının arayüz ekranı

G-Code komutlarının detaylı açıklamalarına ve 3D yazıcı donanımlarının kontrolündeki rollerine dair detaylı bilgi “Marlin Firmware Documentation” kaynağından edinilebilir (Marlin Firmware, 2024). Bu kaynak, FDM yazıcılarda kullanılan G-Code komutlarının işleyişini, kullanım örneklerini ve yazıcı donanımlarıyla entegrasyon süreçlerini kapsamlı şekilde ele almaktadır.

2.4.2. Donanımsal bileşenler

FDM tipi 3D yazıcılar, katmanlı üretim sürecini gerçekleştirmek için çeşitli donanım bileşenlerinden oluşmaktadır. Bu bileşenler, yazıcının mekanik, elektronik ve ısıtma sistemlerini kapsayan temel yapı taşlarını oluşturur. Yazıcının stabilitesi, doğruluğu ve baskı kalitesi, bu bileşenlerin doğru şekilde tasarlanması, kalibre edilmesi ve uyumlu çalışmasına bağlıdır. Detayları alt-bölümlerde verilecek olan FDM tipi 3D yazıcıların temel donanımsal bileşenleri Şekil 2.5'te gösterilmektedir.




Şekil 2.5. FDM tipi 3D yazıcıların donanımsal bileşenleri (Prianto & Pramono, 2021)

2.4.2.1. Çerçeve ve yapısal bileşenler

Çerçeve: FDM yazıcının temel taşıyıcı bileşeni olan çerçeve, tüm mekanik ve elektronik bileşenleri bir arada tutan temel iskelet yapıdır. Özellikle Kartezyen sistemli FDM yazıcılarda, X, Y ve Z eksenlerindeki hareketleri destekleyen rijit bir çerçeve yapısına ihtiyaç duyulmaktadır. Çerçevenin esneme veya titreşim yapması, baskı sırasında anomalilere yol açabilir.

Baskı platformu: Üretimin gerçekleştirildiği yüzeyi oluşturan kritik bir bileşendir. Literatürde baskı yatağı (*print bed*) olarak da adlandırılan bu platform, baskının ilk katmanının yüzeye tutunmasını sağlamak için özel olarak tasarlanır. Yüzeyin düz olması ve malzemenin tutunmasını kolaylaştıracak özelliklere sahip olması, baskının stabilitesini artırır. Aksi takdirde, baskı anomalileri gözlemlenebilir. Görsel 2.5'te, FDM türü bir kartezyen yazıcının yapısal elemanları görselleştirilmiştir.



Görsel 2.5. FDM türü kartezyen tip bir yazıcının yapısal bileşenleri

2.4.2.2. Hareketi sağlayan bileşenler


Step motorlar: Yazıcının eksenler boyunca hareketini sağlayan temel bileşenlerdir. Step motorlar, X, Y ve Z eksenlerinde adım adım hareket ederek hassas hareketlere olanak tanır. Ancak, doğru bir kalibrasyon yapılmadığı durumlarda eksen boyutlarında tutarsızlıklar ve baskı hataları oluşabilir.

Kemerler ve raylar: Hareket sisteminin stabil çalışmasını sağlayan bileşenler arasında kemerler (*belts*) ve raylar (*rails*) yer alır. Step motorlardan gelen hareketi baskı platformuna veya yazıcı kafasına aktaran yardımcı mekanik bileşenlerdir. Bu parçalar, hareketin düzgün ve kararlı bir şekilde gerçekleşmesini sağlar.

2.4.2.3. Filament akışından sorumlu bileşenler

Ekstrüder: Filamenti yazıcıya besleyen dişli mekanizmadır ve kendine ait bir adım motoru bulunmaktadır. Ekstrüder, filamenti istenen miktarda ileterek doğru bir baskı sürecini sağlar. Direkt tahrik (*Direct Drive*) ve Bowden tahrik (*Bowden Drive*) olmak üzere iki ana türü bulunmaktadır. Kalibrasyonun düzgün yapılmadığı durumlarda filament akışında tutarsızlıklar meydana gelebilir ve bu durum baskı anomalilerine yol açabilir. Görsel 2.6'da örnek bir ekstrüder görseli sunulmuştur.

Nozul: Eriyik haldeki filamentin ürüne dönüştüğü uç bileşendir. Nozul çapı ve işlevselliği, yazdırma hızını ve baskının hassasiyetini doğrudan etkiler. Ayrıca, nozul tıkanıklıkları gibi problemler, baskı kalitesini olumsuz yönde etkileyebilir.



Görsel 2.6. *BMG model bir ekstrüder*

2.4.2.4. Isıtıcı bileşenler

Nozul ısıtıcı: Literatürde ve topluluk içinde "hot-end" olarak adlandırılan bu bileşen, filamentin erimesini sağlamak için gerekli ısı enerjisini sağlar. Farklı filament türleri için uygun sıcaklık değerlerine ayarlanabilir.

Isıtıcı yatak: Baskı sırasında ilk katmanın baskı platformuna yapışmasını kolaylaştırır ve baskı esnasında oluşabilecek bükülmeleri önler. Farklı filament türleri için uygun sıcaklık değerlerine ayarlanabilir.

2.4.2.5. Elektronik bileşenler

Kontrol kartı: Yazıcının tüm bileşenlerini koordine eden ana kontrol birimidir. G-Code komutlarını okuyarak motor hareketlerini, ısıtıcıları ve diğer donanımları yönetir.

Güç Kaynağı Ünitesi (Power Supply Unit, PSU): Elektrik enerjisini alternatif akımdan (*Alternating Current, AC*) doğru akıma (*Direct Current, DC*) dönüştürerek yazıcının bileşenlerine çalışmalarını için gerekli elektrik enerjisini sağlar. Güç kaynağının kararlı bir şekilde çalışması, elektrik kesintilerinde yazıcının güvenli bir şekilde kapanmasını da sağlar.

2.4.2.6. Fanlar ve soğutma sistemleri

Nozul soğutma fanı: Nozuldaki sıcak filamentin daha hızlı soğumasını ve katmanların düzgün bir şekilde oturmasını sağlar.

Elektronik soğutma fanı: Kontrol kartı gibi elektronik bileşenlerin ısınmasını önler ve yazıcının güvenli bir şekilde çalışmasını sağlar.

2.4.2.7. Sensörler

Filament sensörü: Filamentin makaradan düzgün bir şekilde ekstrüdere ilerleyip ilerlemediğini kontrol eden bileşendir. Filament tükendiğinde veya hareketinde bir sorun olduğunda yazıcıyı uyararak baskının kesintiye uğramasını önler. Görsel 2.7’de örnek bir filament sensörü görseli sunulmuştur.




Görsel 2.7. Creality tarafından üretilen bir filament sensörü

Yatak seviyesi sensörü: Baskı platformunun yüzeyinin düzgün olup olmadığını kontrol eden bir sensördür. Otomatik yatak seviyelendirme (*Auto Bed Leveling, ABL*) özelliği olan yazıcılarda, platformun doğru şekilde hizalanmasını sağlar ve ilk katman problemlerinin önüne geçmeye yardımcı olur.

Hareket sensörü: Ekstrüder hareketlerinden kaynaklanan ivmelenmeyi tespit eden sensördür. Olağan dışı hareketleri algılayarak baskı sürecinde oluşabilecek hareket kaynaklı sorunları belirlemeye yardımcı olur.

Isı sensörleri: Nozul ve ısıtıcı yatağın sıcaklıklarını ölçmeye yarayan sensörlerdir. Farklı hammadde türleri için gerekli sıcaklık değerlerinin korunmasını sağlar ve ısınma ile ilgili sorunları tespit etmeye yardımcı olur. Görsel 2.8’de yatak seviyesi sensörü, adx1345 model hareket sensörü ve termistör tip ısı sensörü gösterilmektedir.




Görsel 2.8. Sensörler

2.5. 3D Yazıcılarda Yaygın Anomali Türleri

3D yazıcılar bağlamında, baskı kalitesi, üretilen parçanın mekanik, estetik ve işlevsel özelliklerinin doğruluğunu belirleyen kritik bir faktördür. Lakin, baskı süreci sırasında baskı kalitesini doğrudan etkileyebilecek çeşitli anomaliler meydana gelebilmektedir. Bu anomaliler, donanım hataları, malzeme kalitesi, çevresel koşullar veya yazılım ayarları gibi birçok etkene bağlı olarak oluşabilmektedir. Mevcut 3D yazıcıların büyük bir kısmı, baskı sırasında oluşabilecek hataları algılayabilecek sensör ve hata giderme mekanizmalarına (yazılımlara) sahip değildir. Bu nedenle, baskı sırasında meydana gelen hatalar genellikle fark edilmeden üretime devam edilmekte, ancak baskı tamamlandıktan sonra manuel görsel inceleme yoluyla tespit edilebilmektedir. Bu durum, malzeme israfına, üretim sürecinde zaman kaybına ve genel verimlilikte düşüşe yol açmaktadır (Cenedese, 2022).

Oluşan anomalilerin türü ve etkileri, kullanılan baskı tekniği, nozul sistemi ve baskı malzemesine bağlı olarak değişiklik göstermektedir. Ayrıca, bu anomalilerin her biri, operatör veya sistem tarafından farklı düzeyde müdahale gerektiren farklı karakteristiklere sahiptir. Literatürde yaygın olarak karşılaşılan anomali türleri Görsel 2.9'da gösterilmektedir.



Görsel 2.9. 3D yazıcılarda karşılaşılan yaygın anomali türleri

2.5.1. İpliklenme

İpliklenme (*Stringing*), nozuldaki filament akışının kontrolsüz bir şekilde devam etmesi sonucu oluşan bir anomalidir. Bu hatada, yazıcı kafası hareket ederken erimiş filament geride ince iplikler bırakarak örümcek ağı benzeri bir görüntü oluşturur.

İpliklenme, genellikle nozul sıcaklığının fazla yüksek olmasından veya geri çekme (*Retraction*) ayarlarının yetersizliğinden kaynaklanmaktadır. Bu hatanın önlenmesi için nozul sıcaklığının optimize edilmesi ve geri çekme parametrelerinin doğru bir şekilde ayarlanması gerekmektedir (Simplify3D, 2024). İpliklenme hatası genellikle üretim sürecinin sonlandırılmasını gerektirmez; ancak baskı kalitesi açısından önemli sorunlara yol açabilir.

2.5.2. Spagetti

Spagetti (*Spaghetti*), filamentin çeşitli nedenlerle baskı yüzeyine tutunamayarak farklı yönlere rastgele yayılması ve düzensiz yapılar oluşturması sonucu oluşan bir anomalidir. Görüntü olarak spagetti makarnaya benzetildiği için bu adla anılmaktadır.

Spagetti, genellikle filament besleme mekanizmasındaki sorunlardan, baskı parametrelerinin yanlış ayarlanmasından veya baskının ilk katmanının yeterince sağlam olmamasından kaynaklanabilir (Khan, et al., 2021). Filament sensörlerinin düzenli kontrolü, baskı hızının optimize edilmesi ve mekanik bileşenlerin düzenli olarak bakımının yapılması, bu tür hataların önlenmesinde etkili yöntemlerdir (Bambu Lab, 2024). Spagetti hatası, genellikle baskının tamamen kullanılmaz hale gelmesine neden olur ve üretimin sonlandırılmasını gerektirir. Ayrıca, filament yığılmasının ekstrüdere veya nozul gibi mekanik bileşenlere çarpması, daha büyük hasarlara neden olabilir.

2.5.3. İlk katman sorunları

İlk katman, baskının temelini oluşturduğu için tüm baskı sürecinin başarısını doğrudan etkiler. İlk katman sorunları (*First layer issues*) olarak adlandırılan ve bu katmanda karşılaşılan yaygın sorunlar arasında baskı köşelerinin platformdan ayrılarak bükülmesi ile malzemenin baskı platformuna yapışmaması problemleri yer alır.

Baskı köşelerinin kalkması ve bükülmesi (Warping): Baskının alt kısımlarının baskı tablasından kalkarak bükülmesi durumudur. Bu hata, genellikle Akrilonitril Bütadien Stiren (*Acrylonitrile Butadiene Styrene, ABS*) gibi malzemelerde baskı tablasının yetersiz ısıtılması veya ani sıcaklık değişimleri nedeniyle oluşur (Oropallo & Piegl, 2015).

Malzemenin baskı platformuna yapışmaması: İlk katmanın baskı platformuna düzgün yapışmaması, genellikle tablanın düzgün kalibre edilmemesi, yüzeyin kirli olması veya ilk katman sıcaklığının düşük olmasından kaynaklanır.

Kullanılan materyale uygun baskı platformu yüzeyi seçilmesi ve yatak seviyesi sensörü kullanımı ile ilk katman sorunlarının önüne geçileceği değerlendirilmektedir.

2.5.4. Aşırı ekstrüzyon ve yetersiz ekstrüzyon

Aşırı ekstrüzyon (*Over extrusion*), nozuldaki filamentin gereğinden fazla çıkması sonucu yüzeyde çukurlukların ve düzensizliklerin oluştuğu bir durumdur. Genellikle nozul çapının büyük olması veya filament akış hızının doğru ayarlanmaması nedeniyle oluşur (Mehta, et al., 2024).

Yetersiz ekstrüzyon (*Under extrusion*), filamentin nozuldan yeterli miktarda akması sonucu oluşan bir anomalidir. Bu durum, eksik katmanların veya zayıf bir yapının oluşmasına yol açabilir (Khan, et al., 2021).

Bu hata türlerinde baskı devam ettirilebilir ancak son ürünün baskı kalitesini olumsuz etkileyebilir. Dilimleme yazılımında akış oranlarının optimize edilmesi ve uygun nozul çapının belirlenmesi bu hataları önlemek için etkili yöntemlerdir.

2.5.5. Çatlama

Çatlama (*Cracking*) veya katman ayrılması (*Layer Separation*), özellikle ABS gibi termoplastik malzemelerde, üretim sürecindeki baskı parametrelerinin yetersizliği veya çevresel stresler nedeniyle oluşan bir hatadır (Jipa, Reiter, Flatt, & Dillenburger, 2022). Termoplastik malzemelerin soğuma sürecinde ani sıcaklık değişimlerine maruz kalması, baskı sırasında katmanlar arasında bağ kuvvetinin zayıflamasına ve yapısal bütünlüğün bozulmasına neden olabilmektedir. Bu durum, parçalarda dayanıklılık sorunlarına yol açabilmektedir.

Bu tür anomaliyi önlemek amacıyla kapalı baskı odalarının kullanılması, ortam sıcaklığındaki dalgalanmaların azaltılmasına katkı sağlayarak katmanlar arasındaki yapışmanın güçlendirilmesine ve çatlama riskinin en aza indirilmesine yardımcı olabilir (Ramian, Ramian, & Dziob, 2021). Ayrıca, soğutma fanlarının baskının ilk katmanlarında kapalı tutulması, malzemenin kontrollü bir şekilde soğumasını sağlayarak iç gerilmelerin oluşmasını önleyebilir. Çatlama problemi, baskının mekanik dayanıklılığını ciddi şekilde azaltarak ürünün kullanım dışı kalmasına neden olabileceğinden, üretimin sonlandırılmasını gerektirebilir. Bu noktada, baskı devam da ettirilebilir ancak üretilen baskının kalite açısından sorun teşkil etme potansiyeli yüksektir.

2.5.6. Katman kayması

Katman kayması (*Layer shifting*), baskı sırasında katmanların yanlış hizalanması nedeniyle oluşan yapısal bir hatadır. Genellikle mekanik parçaların gevşemesi veya hareket komutlarındaki uyumsuzluklardan kaynaklanır (Mehta, et al., 2024).

Katman kaymalarını önlemek için mekanik bileşenlerin düzenli olarak bakımı yapılmalı ve yazıcının eksen kalibrasyonları doğru bir şekilde yapılmalıdır. Bunun yanı sıra, adım motorların aşırı hızlarla çalıştırılması da bu hatanın oluşmasına neden olabilir. Hareket sensörleri ile bu sorunun önüne geçilebileceği değerlendirilmektedir. Bu hata türü, üretimin sonlandırılmasını gerektirir. Bu noktada, baskı devam da ettirilebilir ancak üretilen baskının kalite açısından sorun teşkil etme potansiyeli yüksektir.

2.5.7. Nozul tıkanması

Nozul tıkanması (*Nozzle clogging*) veya ekstrüder tıkanması (*Extruder clogging*), filamentin düzgün bir şekilde akışını engelleyerek baskının kesintiye uğramasına (ya da baskının tamamen durmasına) neden olan yaygın bir problemdir (Khan, et al., 2021). Bu durum, genellikle düşük kaliteli filament kullanımı, filamentin nemli bir ortamda saklanması, yazıcının yetersiz bakımı veya düzenli temizlik eksikliği gibi faktörlerden kaynaklanmaktadır. Filamentin içerisinde bulunan nem, baskı sırasında buharlaşarak nozul içinde tortu oluşmasına yol açabilir. Ayrıca, uzun süreli kullanım sonucu biriken kalıntılar, nozul çapının daralmasına ve akışın tamamen durmasına neden olabilir.

Bu sorunun önlenmesi için filamentlerin nem almayacak şekilde kapalı ve kuru ortamlarda saklanması, nozulun belirli aralıklarla temizlenmesi ve yazıcının düzenli bakım prosedürlerine uygun şekilde kullanılması gerekmektedir. Ayrıca yazıcılarda bulunan filament sensörü aracılığı ile akış takip edilerek bu hatanın önüne geçilebileceği değerlendirilmektedir. Nozul tıkanıklığı genellikle baskının tamamen durmasına yol açtığından, manuel müdahale gerektiren bir sorun olup üretim sürecinde aksamalara neden olabilmektedir.

3. 3D YAZICILARDA ANOMALİ TESPİTİ

3D yazıcılarda baskı süreci, donanım bileşenlerinin hassas koordinasyonu ile gerçekleşen karmaşık bir üretim yöntemidir. Ancak, baskı sürecinde çeşitli nedenlerden kaynaklanan anomaliler meydana gelebilmektedir. Bu anomalilerin tespiti, baskı kalitesinin artırılması, malzeme israfının önlenmesi ve üretim verimliliğinin iyileştirilmesi açısından kritik bir öneme sahiptir. Bu bölümde, 3D yazıcılarda anomali tespitinde kullanılan temel yöntemler incelenmektedir.


Öncelikle, bilgisayarlı görü tekniklerinin anomali tespit sürecindeki rolü ele alınacaktır. Ardından, nesne tespiti ve segmentasyon algoritmaları detaylandırılarak, özellikle YOLO, Faster R-CNN, Mask R-CNN ve U-Net gibi yaygın kullanılan modellerin işleyişi açıklanacaktır. Daha sonra, sınıflandırma aşamasında kullanılan AlexNet, VGGNet, ResNet ve EfficientNet gibi derin öğrenme tabanlı modellerin anomali tespitindeki performansları değerlendirilecektir. Bölümün ilerleyen kısımlarında, 3D yazıcılarda anomali tespitinde literatürde yaygın olarak kullanılan sensör tabanlı ve görüntü işleme tabanlı yaklaşımlar karşılaştırılacak, ticari çözümler ve mevcut sistemlerin avantajları ile kısıtları ele alınacaktır. Son olarak, derin öğrenme teknikleri ile yapılan anomali tespit süreçlerinin avantajları tartışılacak ve literatürde karşılaşılan temel zorluklara değinilecektir.

Bu bölüm, önerilen modelin geliştirildiği çerçeveyi anlamak için temel bilgileri sunmakta ve mevcut yöntemleri detaylandırarak modelin konumlandırıldığı literatürel bağlamı ortaya koymaktadır.

3.1. Bilgisayarlı Görü

Bilgisayarlı görü (*Computer vision*), dijital görüntülerin veya videoların işlenmesi, analizi ve yorumlanmasıyla ilgilenen bir yapay zekâ (*Artificial intelligence*, AI) alanıdır. Bu teknoloji, insan görme yetisini taklit ederek bilgisayarların çevresindeki nesnelere ve sahneleri anlamlandırmasını sağlar. Bilgisayarlı görü, nesne algılama, tanıma, sınıflandırma ve takip gibi geniş bir uygulama yelpazesine sahiptir (Szeliski, 2022).

Bilgisayarlı görünün temel amacı, görsel veriyi yapılandırılmış bilgiye dönüştürmektir. Bu üç temel adımdan oluşan süreç Şekil 3.1'de özetlenmiştir (Gonzalez & Woods, 2018).



Şekil 3.1. Bilgisayarlı görü

Bilgisayarlı görünün sağlık, otomotiv, güvenlik, perakende ve tarım gibi alanlardaki yaygın uygulamaları akademik kaynaklarda genişçe tartışılmıştır. Sağlık sektöründe, tıbbi görüntü analizi ve hastalık teşhisi için önemli bir araç olarak kullanılan bu teknoloji, otomotiv sektöründe otonom araçlarda nesne algılama, şerit takip ve trafik işareti tanıma gibi uygulamalarda öne çıkmaktadır. Güvenlik alanında, yüz tanıma sistemleri ve güvenlik kameralarıyla bütünleşmiş nesne algılama işlemleri bilgisayarlı görünün yaygın kullanım alanlarından biridir. Perakende sektöründe raf yönetimi ve müşteri davranış analizinde etkili bir şekilde uygulanırken, tarım alanında ürün kalite kontrolü, zararlı tespiti ve hasat değerlendirme gibi süreçlerde de yaygın olarak kullanılmaktadır (Szeliski, 2022).

3.2. Nesne Tespiti ve Segmentasyonu

Nesne tespiti ve segmentasyon, bilgisayarlı görü alanında görüntülerdeki nesnelerin tanımlanması, sınıflandırılması ve görsel ayrıntıların belirlenmesini sağlayan iki temel tekniktir.

Nesne tespiti (*Object detection*), dijital görüntülerde veya videolarda nesnelerin yerlerini ve sınıflarını belirleme sürecidir. Bu işlem sırasında her bir nesne için sınır kutuları (*Bounding boxes*) oluşturulur ve belirli kategorilere atanır. Günümüzde, derin öğrenme yöntemleri sayesinde nesne tespitinde hem doğruluk hem de hız açısından önemli ilerlemeler sağlanmıştır (Zou, Chen, Shi, Guo, & Ye, 2023).

Tablo 3.1. Nesne tespiti ve segmentasyonunda kullanılan yaygın algoritmalar

Algoritma	Mimari Türü	Güçlü Yönleri	Zayıf Yönleri	Kullanım Alanı
<i>YOLOv11</i>	Tek aşamalı + Segmentasyon	- Gerçek zamanlı tespit - Segmentasyon ve poz tahmini	- Küçük nesnelere doğruluk düşebilir	Endüstriyel üretim, güvenlik, otonom sürüş
<i>Faster R-CNN</i>	İki aşamalı dedektör	- Yüksek doğruluk - Küçük nesnelere etkili	- Yavaş işleme - Hesaplama maliyeti	Uydu görüntüleri, hassas nesne tespiti
<i>Mask R-CNN</i>	İki aşamalı + Segmentasyon	- Piksel seviyesinde segmentasyon - Nesne şekillerini tam belirleme	- Yavaş işleme hızı - Daha karmaşık yapı	Tıbbi segmentasyon, kalite kontrol
<i>U-Net</i>	Segmentasyon ağı	- Detaylı piksel seviyesinde segmentasyon - Küçük veri setleriyle eğitilebilir	- Doğrudan nesne tespiti için optimize edilmemiş	Tıbbi görüntüleme, biyomedikal analiz

Segmentasyon, bir görüntünün piksel düzeyinde analiz edilmesi ve her pikselin bir sınıfa veya nesneye atanmasını hedefler. Bu yöntem, görüntülerde ayrıntılı bilgi elde edilmesini sağlar ve iki ana kategoriye ayrılır:

Anlamsal segmentasyon (Semantic segmentation): Görüntüdeki tüm nesnelere sınıflandırır, ancak aynı sınıfa ait nesnelere birbirinden ayırt etmez. Örneğin, tüm araçlar tek bir sınıf olarak işlenir (He, Gkioxari, Dollár, & Girshick, 2017).

Örnek segmentasyonu (Instance segmentation): Aynı sınıfa ait nesnelere birbirinden ayırarak her nesneyi bağımsız bir örnek olarak ele alır. Örneğin, bir görüntüdeki her araç ayrı birer nesne olarak sınıflandırılır (He, Gkioxari, Dollár, & Girshick, 2017).

Nesne tespiti ve segmentasyon için kullanılan yaygın algoritmalar Tablo 3.1’de sunulmuştur.


3.2.1. YOLO

YOLO, nesne tespiti alanında yüksek hız ve doğruluk sağlayan bir algoritmadır. Joseph Redmon ve Ali Farhadi tarafından 2015 yılında geliştirilen bu algoritma, kısa sürede popülerlik kazanmış ve birçok bilgisayarlı görü uygulamasında kullanılmaya

başlanmıştır (Redmon & Farhadi, 2016). Modern sürümleri, derin öğrenme alanındaki yenilikleri entegre ederek performans açısından sürekli olarak geliştirilmiştir.

YOLO algoritmasının segmentasyon özelliği, 2022 yılında yayımlanan YOLOv5'in 7.0 sürümüyle tanıtılmıştır (Ultralytics, 2024). Bu sürüm, örnek segmentasyon modellerini içeren ilk YOLOv5 sürümü olarak dikkat çekmiştir. Daha sonra, 2023 yılında piyasaya sürülen YOLOv8, segmentasyon yeteneklerini daha da geliştirerek optimize edilmiş bir yapı ve verimlilik sağlamıştır (Ultralytics, 2024). YOLOv8, özellikle modelin taşınabilir cihazlarda etkili çalışabilmesi için optimize edilmiş mimarisıyla dikkat çekmektedir.

YOLOv11, nesne tespiti, segmentasyon ve poz tahmini gibi çoklu görevlerde yüksek doğruluk oranları ile dikkat çeken en güncel modeldir. Daha az parametre kullanarak yüksek bir ortalama doğruluk (mAP) elde etmesi, bu sürümü hem hız hem de doğruluk açısından önceki modellerden üstün kılmaktadır. Ayrıca, YOLOv11'in çok yönlü yapısı, endüstriyel üretim, güvenlik sistemleri ve sağlık alanlarında geniş bir uygulama yelpazesi sunmaktadır (Ultralytics, 2024). YOLOv11 ve eski sürümlerinin COCO veri seti üzerindeki performansları Şekil 3.2'de sunulmuştur.



Şekil 3.2. YOLO sürümlerinin performansları (Ultralytics, 2024)

Bu çalışmada, yöntemin ilk basamağı olan segmentasyon için YOLOv11 algoritması tercih edilmiştir. YOLOv11'in hız ve doğruluk avantajları, gerçek zamanlı baskı süreçlerinin izlenmesi ve anormalliklerin tespit edilmesinde etkili olacağı değerlendirilmiştir.

3.2.2. Faster R-CNN

Faster R-CNN, bölge öneri ağları (*Region proposal networks*) kullanarak nesne tespiti için yüksek doğruluk ve hız sunan bir algoritmadır. Bu yöntem, önceki R-CNN

tabanlı yaklaşımlara kıyasla daha verimli bir yapı sunmuş ve bölge önerisi adımını ağın bir parçası haline getirmiştir. Özellikle büyük veri kümelerinde etkili sonuçlar sağlaması nedeniyle yaygın olarak tercih edilmektedir. Faster R-CNN, gerçek zamanlı nesne tespiti gerektiren uygulamalar için optimize edilmemiş olsa da yüksek doğruluk gerektiren görevlerde etkileyici sonuçlar sunmaktadır (Ren, He, Girshick, & Sun, 2015).

3.2.3. Mask R-CNN

Mask R-CNN, Faster R-CNN üzerine geliştirilmiş ve örnek segmentasyonu için optimize edilmiş bir yöntemdir. Bu algoritma, nesnelere sınır kutularını belirlemenin yanı sıra piksel düzeyinde segmentasyon sağlayarak her bir nesnenin maskesini oluşturur. Mask R-CNN, ayrıca ilgi alanı hizalama (*Region of Interest Align, ROIAlign*) adlı yenilikçi bir teknik kullanarak segmentasyon doğruluğunu artırır. Bu yöntem, özellikle tıbbi görüntüleme, otonom araçlar ve robotik gibi yüksek hassasiyet gerektiren alanlarda yaygın olarak kullanılmaktadır (He, Gkioxari, Dollár, & Girshick, 2017).

3.2.4. U-Net

U-Net, segmentasyon amacıyla geliştirilmiş ve özellikle tıbbi görüntüleme alanında sıklıkla kullanılan bir mimaridir. U-Net'in basit ve etkili tasarımı, piksel düzeyinde hassas segmentasyon yapmasına olanak tanır. Özellikle sınırlı sayıda etiketli veriye sahip alanlarda yüksek doğruluk sağlaması nedeniyle tercih edilmektedir. Tıbbi görüntüleme dışında, uzaktan algılama, biyomedikal analiz ve otonom sistemlerde de yaygın olarak kullanılmaktadır (Ronneberger, Fischer, & Brox, 2015).

3.3. Sınıflandırma

Sınıflandırma, makine öğrenimi ve AI alanlarında, bir nesneyi veya veriyi önceden belirlenmiş kategorilerden birine atama sürecidir. Bu süreç hem denetimli öğrenme yöntemleri hem de derin öğrenme tabanlı modeller kullanılarak gerçekleştirilir. Özellikle görüntü sınıflandırma, bilgisayarlı görünümün temel problemlerinden biri olarak öne çıkar. Görüntü sınıflandırma, dijital görüntülerden anlamlı bilgiler çıkarma sürecinde kritik bir rol oynar ve nesne algılama, tıbbi görüntüleme, yüz tanıma gibi uygulamalarda yaygın olarak kullanılmaktadır (Goodfellow, Bengio, & Courville, 2016). Sınıflandırma amacıyla kullanılan yaygın algoritmalar Tablo 3.2'de sunulmuştur.

Tablo 3.2. Sınıflandırmada kullanılan yaygın algoritmalar

Model	Öne Çıkan Özellikler	Kullanım Alanı
<i>AlexNet</i>	<ul style="list-style-type: none">- Derin öğrenmede çığır açan ilk model- GPU kullanımıyla yüksek performans- <i>ImageNet</i> başarısı	Görüntü sınıflandırma, genel bilgisayarlı görü uygulamaları
<i>VGGNet</i>	<ul style="list-style-type: none">- Derin ve basit bir yapı- 3x3 filtrelerle daha küçük özellikleri yakalama- Geniş uygulama alanı	Görüntü sınıflandırma, nesne tespiti
<i>ResNet</i>	<ul style="list-style-type: none">- Artık bağlantılar ile gradyan kaybını önleme- Çok derin yapılar için uygun- Yüksek doğruluk	Görüntü sınıflandırma, nesne tespiti, segmentasyon
<i>EfficientNet</i>	<ul style="list-style-type: none">- Genişlik, derinlik ve çözünürlük ölçeklendirme- Verimli hesaplama ve yüksek doğruluk- Esnek yapı	Tıbbi görüntü analizi, otonom araçlar, sınıflandırma görevleri

3.3.1. AlexNet

Derin öğrenme alanında çığır açan bir modeldir. AlexNet, derin sinir ağlarının potansiyelini göstererek görüntü sınıflandırma görevlerinde yüksek doğruluk oranlarına ulaşmıştır. Özellikle ImageNet yarışmasında kazandığı başarı, büyük veri kümeleri üzerinde etkili bir şekilde çalıştığını kanıtlamıştır. Bu model, GPU (Graphics Processing Unit, Grafik İşlem Birimi) kullanımıyla derin öğrenme performansını artırmış ve CNN (Convolutional Neural Network, Evrilmiş Sinir Ağı) mimarisinin popülerleşmesine öncülük etmiştir (Krizhevsky, Sutskever, & Hinton, 2012).

3.3.2. VGGNet


Daha derin bir mimari ile sınıflandırma doğruluğunu artırmayı başarmıştır. VGGNet, her biri 3x3 boyutunda filtrelerden oluşan katmanlara sahip olmasıyla dikkat çeker. Bu yapı, modelin daha küçük alansal özellikleri yakalamasına ve böylece sınıflandırma doğruluğunu artırmasına olanak tanımıştır. Ayrıca, derinliği artırırken basit bir yapı koruyarak geniş bir uygulama alanı bulmuştur (Simonyan & Zisserman, 2015).

3.3.3. ResNet

Artık bağlantılar (*Residual connections*), derin sinir ağlarının eğitim sürecinde oluşabilecek gradyan kaybı problemini çözmek için geliştirilmiştir. ResNet, bu bağlantılar sayesinde daha derin mimarilerde bile öğrenme kapasitesini artırmış ve

yüksek doğruluk oranlarına ulaşmıştır. Bu yenilikçi mimari, özellikle görüntü sınıflandırma ve nesne tespiti gibi görevlerde çığır açan bir performans sergilemiştir. ResNet, yalnızca derinliği artırmakla kalmamış, aynı zamanda daha verimli ve etkili modellerin tasarlanmasına öncülük etmiştir (He, Zhang, Ren, & Sun, 2016).

ResNet modelinin genel mimari yapısı Şekil 3.3'te gösterilmektedir. Bu mimari, VGG-19'dan esinlenerek başlangıçta 34 katmanlı düz bir ağ yapısı olarak tasarlanmış, ancak modelin derinleşmesine rağmen gradyan kaybolma (*vanishing gradient*) sorununu önlemek amacıyla atlamalı bağlantılar (*skip connections*) eklenmiştir. Bu atlamalı bağlantılar sayesinde, modelin öğrenme süreci iyileştirilmiş ve katmanlar arasında bilgi akışının korunması sağlanarak mimari residual bir yapıya dönüştürülmüştür. Bu yaklaşım, özellikle derin ağların eğitim sürecinde karşılaşılan optimizasyon zorluklarını azaltarak, modelin daha etkili ve verimli bir şekilde öğrenmesini mümkün kılmaktadır.




Şekil 3.3. ResNet -34 mimarisi (He, Zhang, Ren, & Sun, 2016)

ResNet, sağladığı artık bağlantılar sayesinde, derin sinir ağlarının eğitiminde ortaya çıkan gradyan kaybı ve aşırı uyum (*Overfitting*) gibi sorunları büyük ölçüde minimize etmektedir. Bu mimari, özellikle daha az parametre kullanarak derin ağların karmaşık görevlerde daha yüksek doğruluk oranlarına ulaşmasını mümkün kılmıştır. Ayrıca, ResNet ölçeklenebilir yapısı sayesinde, farklı derinliklerde (örneğin ResNet-50, ResNet-101) ağlar oluşturularak çeşitli görevler ve veri kümelerine uyarlanabilir. Görüntü sınıflandırma, nesne tespiti ve segmentasyon gibi bilgisayarlı görü uygulamalarında yaygın bir şekilde kullanılmaktadır. Bu çalışmada ResNet mimarisi, 3D yazıcılarda oluşan anomalilerin tespiti ve sınıflandırılması için uygun bir çözüm olarak tercih edilmiştir.

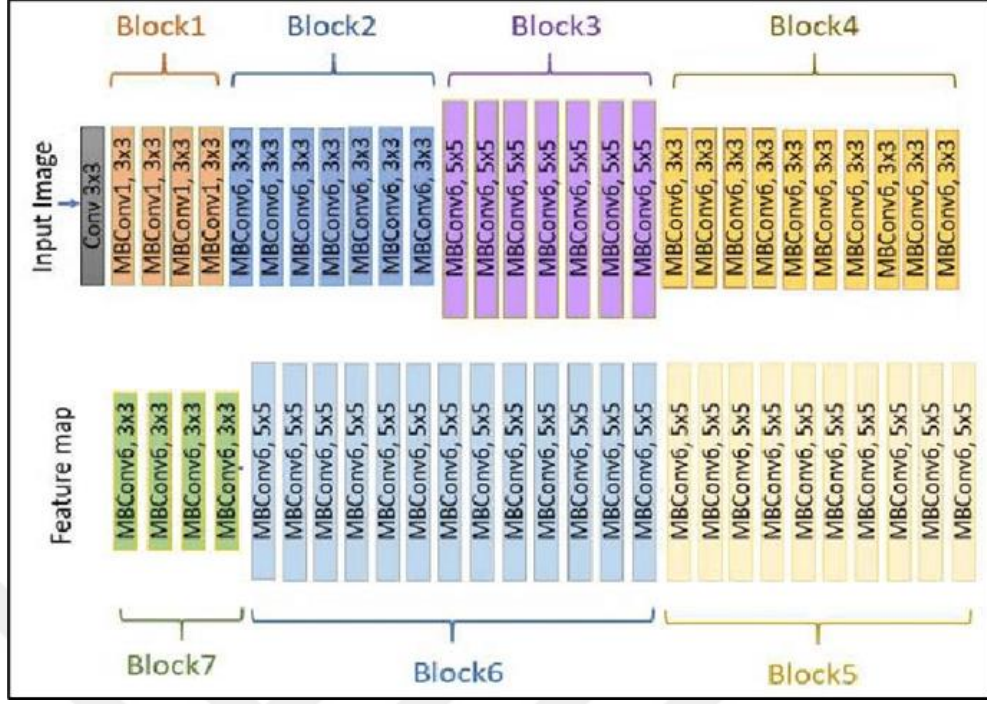
3.3.4. EfficientNet

EfficientNet, sınıflandırma doğruluğunu artırırken hesaplama maliyetlerini optimize eden bir mimari sunar. Modelin temelini, ağın genişliği, derinliği ve çözünürlüğü arasında dengeli bir ölçekleme yaklaşımı oluşturur. Geleneksel derin öğrenme modelleri, genellikle bu üç parametreden sadece birine odaklanırken, EfficientNet her üçünü de optimize ederek daha verimli bir yapı sunar. Bu özellikleri sayesinde EfficientNet hem yüksek doğruluk oranlarına ulaşmış hem de donanım kaynaklarını verimli kullanmasıyla dikkat çekmiştir. Tan ve Le (2019) tarafından gerçekleştirilen çalışmada, *EfficientNet* modeli *ImageNet* veri setinde yüksek doğruluk (%84,3 doğruluk) ve düşük parametre sayısı (66M) ile diğer CNN mimarilerine kıyasla üstün performans göstermiştir. Tan ve Lee tarafından ImageNet veri seti üzerinde sınıflandırma algoritmalarının performansı Şekil 3.4'te sunulmuştur. Model, tıbbi görüntü analizi, otonom araçlar ve diğer sınıflandırma görevleri gibi birçok uygulama alanında yaygın olarak kullanılmaktadır (Tan & Le, 2019).

Özellikle, modelin daha az parametre kullanarak yüksek performans sunabilmesi, büyük veri kümeleri üzerinde çalışırken zaman ve kaynak tasarrufu sağlamak açısından önemli bir avantaj sunmaktadır. EfficientNet'in sunduğu hesaplama verimliliği ve doğruluk optimizasyonu, bu çalışmada 3D yazıcı anomalilerinin tespit edilmesinde modelin tercih edilmesinin temel nedenlerinden biri olmuştur. EfficientNet B7'nin genel yapısı Şekil 3.5'te sunulmaktadır.



Şekil 3.4. ImageNet veri setinde sınıflandırma algoritmalarının performansı (Tan & Le, 2019)



Şekil 3.5. *EfficientNet* blok yapısı (Yahia Ibrahim & Talaat, 2022)

3.4. 3D Yazıcılarda Anomali Tespit Yaklaşımları

3D yazıcılarda baskı süreci sırasında oluşabilecek anomaliler, üretim kalitesini olumsuz etkileyebilecek önemli sorunlar arasında yer almaktadır. Bu tür anomalilerin erken tespiti hem üretim maliyetlerini azaltmak hem de baskı süreçlerinin verimliliğini artırmak açısından kritik öneme sahiptir (Rishi Kumar, Gligorijevic, Ismail, Diller, & Ramsburg, 2024). Özellikle karmaşık geometriye sahip baskılarda, hatalar baskının ilerleyen aşamalarında fark edildiğinde malzeme kaybı kaçınılmaz hale gelmektedir.

Literatürde, 3D yazıcılarda anomali tespiti için kullanılan yaklaşımlar genellikle üç ana başlık altında incelenmektedir: sensör tabanlı yaklaşımlar, görüntü işleme tabanlı ve makine öğrenimi tabanlı modeller ve ticari çözümler. Bu yaklaşımlar, 3D yazıcı süreçlerinde hataları tespit ederek baskı kalitesini artırmayı ve süreçleri optimize etmeyi hedefler. Bu bölümde, bu yaklaşımlar detaylı bir şekilde ele alınacaktır.

3.4.1. Sensör tabanlı yaklaşımlar

Sensör tabanlı yaklaşımlar, 3D yazıcılardaki donanımsal sensörlerden alınan verilerle anormalliklerin tespit edilmesine dayanır. Bu sensörler, yazıcının sıcaklık, basınç, titreşim ve malzeme akışı gibi önemli parametrelerini ölçerek baskı sürecini izler.

Filament sensörleri: Filament akışının düzgün olup olmadığını kontrol ederek tıkanıklık veya kesinti gibi sorunları algılar.

Titreşim sensörleri: Hareketli parçaların mekanik performansını değerlendirerek anormal titreşimlerden kaynaklanan hataları tespit eder (Rishi Kumar, Gligorijevic, Ismail, Diller, & Ramsburg, 2024).

Isı sensörleri: Nozul ve yatak sıcaklıklarının hedeflenen aralıkta olup olmadığını izleyerek, sıcaklığa bağlı sorunların önüne geçer.

Bu veriler hem gerçek zamanlı izleme hem de geçmiş verilere dayalı analizlerle, baskı süreçlerindeki potansiyel anormallikleri tespit etmek için kullanılabilir. Örneğin, bir çalışmada titreşim sensörlerinden alınan veriler, LSTM gibi zaman serisi analiz algoritmaları ile işlenmiş ve anomali tespiti yapılmıştır (Rishi Kumar, Gligorijevic, Ismail, Diller, & Ramsburg, 2024).

Ancak, sensör tabanlı yaklaşımlar genellikle yalnızca belirli türdeki anormalliklerin tespitinde etkili olup, görsel hatalar gibi fiziksel anomalilerin doğrudan tespitinde yetersiz kalabilir (Zhang, He, Huang, & Wang, 2020). Sendorek ve arkadaşları tarafından yapılan çalışmada, sensör verilerinin yalnızca mekanik hataları tespit edebildiği, ancak baskıya bağlı görsel hataları tespit edemediği belirtilmiştir (Sendorek, Szydlo, Windak, & Brzozawoch, 2021).

3.4.2. Görüntü işleme ve makine öğrenimi tabanlı yaklaşımlar

Görüntü işleme ve makine öğrenimi tabanlı yaklaşımlar, 3D yazıcı baskı süreçlerinde oluşabilecek anomalilerin tespiti için yaygın olarak kullanılan yöntemlerdendir. Bu yaklaşımlar, görsel ve sensör verilerinin analiz edilmesi yoluyla baskı sırasında meydana gelebilecek hataların belirlenmesini hedefler.

Katman bazlı hata tespiti için G-Code ile görsel eşleştirme yöntemleri önerilmiş, sanal üstten görünüm ve yan görünüm teknikleri kullanılarak baskı deformasyonları analiz edilmiştir. Bu yaklaşım, baskı sırasında üretilen katmanların konturlarını, G-Code'dan türetilen referans katman sınırlarıyla karşılaştırarak olası konumlandırma hatalarını ve şekil bozulmalarını tespit etmektedir. Bu yöntem, özellikle geometrik doğruluğun kritik olduğu uygulamalarda, baskının gerçek zamanlı izlenmesini ve anomali tespitini mümkün kılmaktadır (Petsiuk & Pearce, 2020).

Khan ve ekibi bir çalışmada, hataların tespiti için CNN tabanlı bir model geliştirilmiş ve dolgu (Infill) desenlerindeki bozulmalar analiz edilmiştir (Khan, et al., 2021). Çalışma, dolgu desenlerindeki anomalileri tespit etmeye odaklanmıştır. Literatürde nozul kamerası ile filament akışındaki anomalilerin tespitine yönelik çalışmalar da yapılmıştır. Bu yöntem nozula yakın yerleştirilen bir kamera ile akış

tutarsızlıklarını tespit etmeye odaklıdır. CNN yöntemleri görsel verilerin işlenmesinde yüksek doğruluk sunar (Lalitha, Shree, Sivasankar, & Ramachandran, 2022). Rachmawati ve ekibi, hatalı ve hatasız şekilde ikili sınıflandırma üzerine çalışmış ve yüksek doğruluk oranları elde edilmiştir (Rachmawati, Hidayat, & Abdullah, 2021).


Karna ve arkadaşları tarafından yapılan bir çalışmada, YOLOv8 modeli, FDM tipi 3D yazıcıların baskı süreçlerindeki hataları tespit etmek amacıyla optimize edilmiştir. Modele eklenen özellik çıkarım katmanı sayesinde düşük seviyeli veriler daha iyi analiz edilerek, 640 piksel giriş boyutu ve 16 batch size ile %89,7 mAP (50-95) model doğruluğu elde etmiştir (Karna, Putra, Rachmawati, Abisado, & Sampedro, 2023).

3.4.3. Ticari çözümler

3D yazıcılarda anomali tespiti amacıyla geliştirilen ticari yazılımlar, baskı süreçlerinin izlenmesini, potansiyel hataların tespit edilmesini ve kullanıcıların yazıcılarına uzaktan erişim sağlamalarını kolaylaştırır. Bu yazılımlar, kullanıcıların baskı süreçlerini daha verimli ve güvenli hale getirmelerine yardımcı olmayı hedefler. Ayrıca, gerçek zamanlı izleme, hata bildirimini ve süreç optimizasyonu gibi özellikleriyle baskı kalitesini artırır. Öne çıkan birkaç örnek aşağıda verilmiştir:

- *Obico*: AI destekli bir platformdur. Spagetti hatasını tespit ederek kullanıcıyı uyarır. Obico, özellikle amatör ve profesyonel kullanıcılar için uygun bir çözüm sunmaktadır.
- *Cloud 3D Print*: Bulut tabanlı bir yazılım olarak baskı süreçlerini izleme ve optimizasyon araçları sağlar. Kullanıcıların birden fazla yazıcıyı merkezi bir panelden yönetmesine olanak tanır.
- *OctoEverywhere*: OctoPrint ile entegre çalışan bir yazılımdır. Uzaktan izleme ve hata tespiti özellikleri sunarak, kullanıcıların yazıcılarına her yerden erişmesini sağlar. Bu platform, kullanıcı dostu bir arayüzle baskı süreçlerini optimize etmeye yönelik araçlar içerir.

Bu tür yazılımlar, kullanıcıların baskı süreçlerini daha verimli ve güvenli hale getirmelerine yardımcı olmaktadır. İlgili çözümlere ait ekran görüntüleri Görsel 3.1’de sunulmuştur.



Görsel 3.1. Ticari çözümler

3.5. Derin Öğrenme ile Anomali Tespitinin Avantajları

3D yazıcılarda baskı sırasında oluşan anomalilerin tespiti için derin öğrenme yöntemleri, görüntü işleme temelli yaklaşımlar açısından güçlü bir araçtır. Özellikle kamera tabanlı izleme ve bilgisayarla görü teknikleriyle birleştiğinde, derin öğrenme modelleri geleneksel yöntemlere kıyasla daha yüksek doğruluk ve otomasyon sunar. Bu avantajlar, baskı süreçlerinin daha güvenilir ve verimli hale getirilmesine olanak tanır. Derin öğrenme yöntemlerinin avantajları aşağıdaki gibi listelenebilir.

- *Karmaşık görsel verilerle çalışma yeteneği:* Derin öğrenme modelleri, kamera aracılığıyla elde edilen görsellerdeki desenler, şekiller ve piksel düzeyindeki detaylar gibi karmaşık bilgileri işleyebilir.
- *Yüksek doğruluk:* Özellikle CNN tabanlı modeller, görsel tabanlı anomali tespitinde yüksek başarı oranlarıyla dikkat çeker. Bu sayede baskı hataları erken aşamada tespit edilebilir.
- *Özelleştirilmiş model geliştirme:* Derin öğrenme, belirli bir yazıcı türü, baskı malzemesi veya anomali tipi için optimize edilerek kullanılabilir.
- *Gerçek zamanlı analiz:* Kamera görüntülerinin işlenmesi sırasında modern donanımlarla sağlanan hız sayesinde, baskı sırasında anomaliler anında tespit edilebilir.

3.6. Literatürde Karşılaşılabilecek Zorluklar

3D yazıcılarda anomali tespiti üzerine yapılan çalışmalar, genellikle sınırlı kapsam ve veri eksikliği gibi sorunlarla karşı karşıya kalmaktadır.

Derin öğrenme tabanlı yöntemler, genellikle güçlü donanım ve büyük veri kümelerine ihtiyaç duymaktadır.

Gerçek zamanlı uygulamalar için kullanılan verilerin büyük bir kısmı, kontrollü laboratuvar ortamlarında toplanmaktadır. Bu veriler, genellikle ideal koşullar altında elde edildiği için gerçek üretim ortamlarının karmaşıklığını yansıtamamaktadır. Üretim ortamlarında sıkça karşılaşılan değişkenlikler, sıcaklık dalgalanmaları, malzeme türlerindeki farklılıklar gibi faktörler, laboratuvar ortamında toplanan verilerle eğitilen modellerin performansını olumsuz etkileyebilmektedir.

Görsel veri tabanlarının sınırlı olması da literatürdeki önemli bir sorun olarak dikkat çekmektedir. Anomali tespiti için kullanılan mevcut veri setleri, genellikle belirli yazıcı türleri veya belirli anomali türleriyle sınırlı kalmaktadır. Daha geniş ve çeşitlilik içeren veri kümelerinin eksikliği, geliştirilen modellerin farklı üretim senaryolarında genelleme yapabilme kapasitesini azaltmaktadır. Özellikle açık ve kullanıma uygun veri setlerinin azlığı, araştırmacıların kendi veri setlerini oluşturmasını zorunlu hale getirmekte ve bu durum zaman ve maliyet açısından ek bir yük yaratmaktadır.

Bu zorluklar, 3D yazıcılarda anomali tespiti konusunda daha kapsamlı, dayanıklı ve genelleme yeteneği yüksek modellerin geliştirilmesi ihtiyacını ortaya koymaktadır. Açık erişimli, geniş ve çeşitlendirilmiş veri tabanlarının oluşturulması, bu alandaki ilerlemeyi hızlandırmak için önemli bir adım olacaktır.

4. ÖNERİLEN İKİ AŞAMALI ANOMALİ TESPİT YÖNTEMİ

Bu bölümde, 3D yazıcılarda anomali tespiti için tez çalışması kapsamında önerilen iki aşamalı anomali tespit ve sınıflandırma yönteminin detayları ele alınacaktır. Öncelikle yöntemin geliştirilme süreci ve motivasyonuna değinilecektir. Baskının çevreden izole edilerek veri kalitesinin artırılması için geliştirilen baskı tespiti ve segmentasyon modelinin ardından anomali türlerinin tespitinin hedeflendiği anomali tespit ve sınıflandırma aşaması detaylandırılacaktır.


4.1. Problem Tanımı ve Önerilen Yöntem

3D baskı sırasında oluşan hataların doğru bir şekilde tespit edilmesi, üretim verimliliğinin artırılması ve baskı kalitesinin sağlanması açısından kritik öneme sahiptir. Bu çalışma, kartezyen FDM tipi 3D yazıcılarda baskı sırasında meydana gelen anomalilerin tespit edilmesine odaklanmaktadır.

İlk olarak, açık kaynaklardan elde edilen veri setleriyle (Ek 1.1) ön çalışmalar gerçekleştirilmiş ve tek aşamalı hata tespiti ve sınıflandırma modellerinde önemli doğruluk problemleri yaşandığı gözlemlenmiştir. Özellikle, arka planın yanlışlıkla hata olarak algılanması sonucu yüksek yanlış pozitif (*False Positive, FP*) oranları ve gerçek hataların gözden kaçırılması nedeniyle yüksek yanlış negatif (*False Negative, FN*) oranları tespit edilmiştir. Bu durum, modelin genel doğruluk oranlarını da olumsuz yönde etkilemiştir. Bu veri setleriyle eğitilmiş modellerin karmaşıklık matrisleri Ek 1.2’de, diğer model performans metrikleri ise Ek 1.3’te sunulmaktadır.

Bu sorunları gidermek amacıyla, veri seti manuel olarak yeniden etiketlenerek, çok sınıflı problem yerine yalnızca hatalı ve hatasız baskıları ayırt edecek şekilde ikili sınıflandırma problemi olarak ele alınarak yeni bir model eğitilmiştir. Ancak bu düzenlemeye rağmen arka planın yanlış tahmin edilme oranının hala yüksek olduğu gözlemlenmiştir (Ek 1.4). Bu durum, öncelikle arka planın ayrıştırılması ve ardından hata tespitinin gerçekleştirilmesinin daha iyi sonuçlar üreteceği değerlendirilmesine yol açmıştır.

Bu bağlamda, çalışmada **D3PAD-X** (*Dual-Stage 3D Print Anomaly Detection & eXtraction*) olarak isimlendirilen iki aşamalı bir anomali tespit sistemi önerilmektedir. D3PAD-X yöntemine ait akış şeması Şekil 4.1’de gösterilmektedir.



Şekil 4.1. D3PAD-X akış şeması

Yöntemin ilk aşamasında YOLOv11 segmentasyon yeteneği kullanılarak baskı alanının çevreden izole edilmesiyle arka plan karışıklığının önlenilebileceği ve sınıflandırma doğruluğunun artabileceği değerlendirilmiştir. Bu sayede ikinci aşamada kullanılan sınıflandırma modeline, arka plandan ayrıştırılmış ve baskıya odaklanmış temiz veriler sağlanmıştır. İkinci aşamada, *EfficientNet* ve *ResNet* modelleri kullanılarak segmentasyon sonrası elde edilen veriler üzerinde anomali tespiti ve sınıflandırma işlemleri gerçekleştirilmiştir. Bu modeller arasında en yüksek performans gösteren sınıflandırma modeli seçilerek test ortamında uygulanmıştır. Bu iki aşamalı yaklaşım, baskı süreçlerinde meydana gelen anomalilerin daha yüksek doğruluk oranlarıyla sınıflandırılmasına olanak tanımaktadır.

4.2. Baskı Tespiti ve Segmentasyon Modeli

Bu aşamada, baskı alanının tespit edilmesi ve çevresinden izole edilmesini sağlayacak segmentasyon modeli eğitilmiştir. Segmentasyon modelinin başarılı bir şekilde çalışabilmesi için öncelikle yeni bir veri seti oluşturulmuş, bu veri seti poligon tabanlı etiketleme yöntemi kullanılarak manuel olarak işlenmiş ve eğitim, doğrulama ve test setlerine ayrılmıştır. Ayrıca, modelin performansını artırmak amacıyla ön işleme ve veri artırma teknikleri uygulanmıştır.

Model eğitimi sürecinde, YOLOv11 modelinin segmentasyon yeteneklerinden yararlanılarak baskı alanının arka plandan doğru bir şekilde ayrıştırılması hedeflenmiştir. Bu süreçte, hiperparametre optimizasyonu gerçekleştirilmiş ve modelin farklı yazıcı ortamları ile değişken ışık koşullarında yüksek doğruluk oranlarına ulaşması sağlanmıştır. YOLOv11 modelinin esnek ve güçlü segmentasyon yetenekleri, önerilen yöntemde tercih edilmesinin temel nedenleri arasında yer almaktadır.


4.2.1. Segmentasyon veri seti

Açık kaynaklardaki veri setlerinin hem sayısal olarak hem de örneklem büyüklüğü açısından sınırlı kaldığı görülmüştür. Ayrıca, mevcut veri setlerinde segmentasyon

amacıyla poligon tabanlı (*Polygon Tool*) etiketleme yapılmadığı ve çoğunlukla sınır kutuları (*Bounding Boxes*) ile sınırlı kaldığı tespit edilmiştir. Bu durum, modelin baskı alanını hassas bir şekilde belirlemesini ve arka plan etkilerini minimize etmesini engelleyebileceğinden bu sınırlamaları aşmak ve daha geniş bir kullanım senaryosuna uyum sağlayabilecek bir model geliştirmek amacıyla, farklı yazıcı ortamlarını kapsayan ve poligon tabanlı segmentasyon etiketlemesine uygun yeni bir veri setinin oluşturulmasına karar verilmiştir.

4.2.1.1. Veri setinin toplanması

Tez çalışması kapsamında oluşturulan segmentasyon veri seti, farklı kaynaklardan elde edilmiştir. Ağırlıklı olarak internet üzerindeki açık erişimli veri setlerinden ve çeşitli görsel kaynaklardan temin edilmiş olan bu veri seti, farklı yazıcı modelleri, malzeme renkleri ve baskı koşullarını kapsayacak şekilde çeşitlendirilmiştir. Bu sayede, modelin genelleme yeteneğinin artırılması ve farklı çevresel koşullarda başarılı segmentasyon yapabilmesi hedeflenmiştir. Bunun yanı sıra, çalışmanın ihtiyaçlarına özel olarak, test ortamındaki yazıcının baskı alanını gören bir kameradan elde edilen görüntüler de veri setine eklenmiştir. Test ortamına yerleştirilen bu kamera, farklı açılardan ve değişken ışık koşullarında görüntü toplayarak veri setinin çeşitliliğini artırmıştır. Oluşturulan veri setine ait örnek görüntüler Görsel 4.1’de sunulmuştur.




Görsel 4.1. Segmentasyon veri setinden örnek görüntüler

4.2.1.2. Veri setinin etiketlenmesi

Veri seti etiketleme süreci Roboflow platformu kullanılarak gerçekleştirilmiştir. Segmentasyon modelinin yüksek hassasiyetle çalışabilmesini sağlamak amacıyla, nesne tespitinde yaygın olarak kullanılan sınır kutuları yerine, daha ayrıntılı ve doğru bir

etiketleme imkânı sunan poligon aracı tercih edilmiştir. Bu doğrultuda, her bir görüntü dikkatlice analiz edilerek baskı alanı, poligon aracı ile manuel olarak tek tek etiketlenmiştir.

Etiketleme aşamasında yalnızca baskı alanına odaklanılmış, arka plan ve diğer nesnelere dikkate alınmamıştır. Bu seçim, modelin sınıflandırma öncesinde baskı alanını çevreden en iyi şekilde ayırt etmesini sağlamak amacıyla yapılmıştır. Dikdörtgen sınırlayıcı kutular yerine poligon tabanlı etiketleme yönteminin kullanılması, baskı alanının sınırlarının daha doğru belirlenmesini sağlayarak modelin segmentasyon doğruluğunu da artıracaktır. Daha hassas bir maskeleyme işleminin, sınıflandırma aşamasındaki genel doğruluk oranına da olumlu katkı sağlayacağı öngörülmektedir. Etiketlemenin nasıl yapıldığının anlaşılması için örnekler Görsel 4.2’de sunulmuştur.



Görsel 4.2. Baskı tespiti ve segmentasyon veri seti etiketleme örnekleri

4.2.1.3. Veri setinin dağılımı

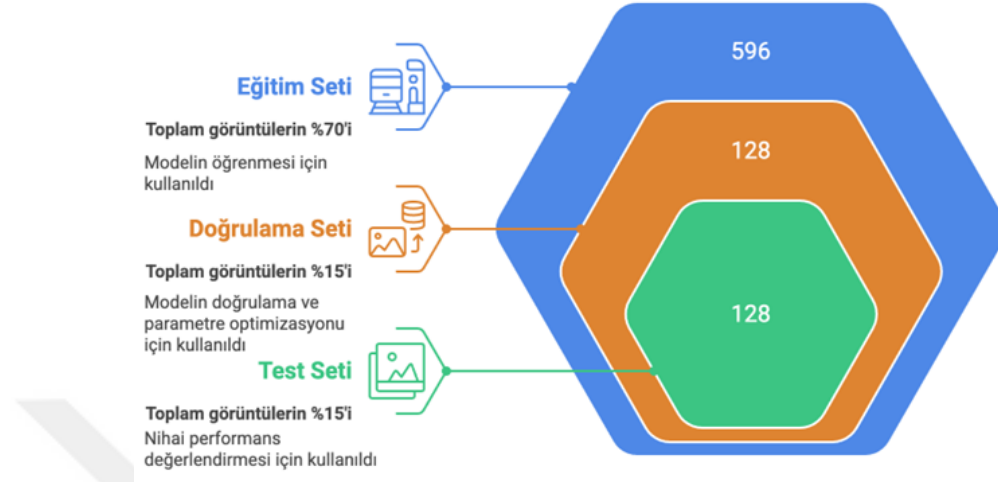
Farklı kaynaklardan toplanıp etiketlenen segmentasyon veri setinde toplam 852 görüntü bulunmaktadır. Hazırlanan veri seti, modelin hem hatalı hem de hatasız baskı alanlarını öğrenebilmesi adına dengeli olacak şekilde oluşturulmuş olup bu görüntülerden 428 tanesi hatasız baskı alanını, 424 görüntü ise hata içeren baskı alanını içermektedir (Şekil 4.2). Bu aşamada, yalnızca baskı alanının çevreden ayrılması hedeflenmekte olup, herhangi bir sınıflandırma işlemi gerçekleştirilmemektedir.



Şekil 4.2. Veri setinin dağılımı

Modelin sağlam ve geliştirilebilir bir segmentasyon başarısı elde etmesi amacıyla, veri seti Roboflow platformu üzerinde %70 eğitim, %15 doğrulama ve %15

test olarak rastgele bölünmüştür. Bu bölme işlemi, modelin farklı baskı ortamlarını öğrenmesini sağlamak ve aşırı uyum riskini azaltmak amacıyla gerçekleştirilmiştir. Şekil 4.3'te veri setinin bölünme durumu özetlenmiştir.



Şekil 4.3. Veri setinin bölünme oranları

4.2.1.4. Ön işleme ve veri artırma teknikleri

Bu aşamada, toplanan görüntüler üzerinde ön işleme (*Preprocessing*) ve veri artırma (*Data augmentation*) işlemleri uygulanmıştır.

Ön işleme aşamasında, görüntülerin uygun formatta işlenebilmesi için otomatik yönlendirme (*Auto Orient*) işlemi uygulanmış ve tüm görüntüler 640x640 piksel boyutuna ölçeklendirilmiştir.

Veri artırma işlemleri, yalnızca eğitim verilerine uygulanmış olup, modelin farklı koşullarda daha genelleştirilmiş bir performans sergilemesi amaçlanmıştır. Kullanılan veri artırma teknikleri aşağıda listelenmiştir.

- *Saturation*: Renk doygunluğu $\pm\%34$ oranında artırılmış veya azaltılmıştır.
- *Brightness*: Parlaklık seviyeleri $\pm\%25$ oranında değiştirilmiştir.
- *Exposure*: Pozlama seviyeleri $\pm\%15$ oranında değiştirilmiştir.
- *Blur*: Görüntülere 1 piksel çapında hafif bulanıklık eklenerek, modelin farklı odak koşullarına uyum sağlaması amaçlanmıştır.

Bu veri artırma teknikleri, farklı görüntülere rastgele şekilde uygulanarak veri setinin çeşitliliği artırılmış ve modelin farklı ortamları daha iyi öğrenmesi sağlanmıştır. Bu işlemler sonucunda, eğitimde kullanılacak toplam görüntü sayısı 1788 olmuştur.

Sonuç olarak, izlenen bu süreçler neticesinde veri seti üzerindeki işlemler tamamlanmıştır. Segmentasyon veri setinin hazırlanmasındaki temel hedef, eğitilecek segmentasyon modeline yalnızca baskı alanını çevreden ayırmayı öğretebilmek ve ikinci

aşamadaki sınıflandırma modeline daha odaklı bir veri seti sunmaktır. Veri setinin, yalnızca sınıflandırma işlemlerine hazırlık amacıyla değil, aynı zamanda baskı alanındaki anomalilerin belirginleştirilmesi için de önemli olduğu düşünülmüştür.

4.2.2. Segmentasyon modelinin eğitimi

Bu çalışmada, segmentasyon modelinin eğitimi için YOLOv11 algoritması tercih edilmiştir. YOLOv11 modeli, nesne tespiti ve segmentasyon görevlerinde başarılı sonuçlar veren, geniş ölçekli veri setleri üzerinde eğitilmiş bir derin öğrenme modelidir. Modelin, farklı yazıcı ortamları ve değişken ışık koşulları altında yüksek doğruluk oranlarıyla segmentasyon gerçekleştirme yeteneği, çalışmada kullanılmasının başlıca nedenleri arasındadır. Ayrıca, modelin sunduğu hız ve doğruluk avantajlarının, baskı sürecinin gerçek zamanlı izlenmesi ve anomali tespit süreçlerinde önemli katkılar sağlayacağı öngörülmüştür.

Segmentasyon modelinin eğitimi, çalışma kapsamında oluşturulan veri seti kullanılarak gerçekleştirilmiştir. Modelin optimal performansa ulaşmasını sağlamak amacıyla hiperparametre optimizasyonu uygulanmıştır. Eğitim sürecinde, modelin öğrenme kapasitesini artırmak ve aşırı öğrenme (overfitting) problemini önlemek için eğitim veri seti kullanılmış; doğrulama veri seti aracılığıyla modelin performansı düzenli olarak izlenmiştir. Model parametreleri ve ağırlıkları, doğrulama sürecinde elde edilen sonuçlara dayanarak optimize edilmiş ve nihai model eğitimi bu ayarlarla tamamlanmıştır.

Eğitim sürecinin ardından, modelin genel başarımını test veri seti üzerinde değerlendirilmeye tabi tutulmuştur. Bu aşama, modelin gerçek dünya koşullarında segmentasyon görevini beklenen doğruluk oranlarıyla gerçekleştirebildiğini doğrulamak ve sistem entegrasyonuna geçmeden önce güvenilir sonuçlar elde etmek amacıyla yürütülmüştür. Böylece, segmentasyon modelinin hem eğitim hem de test aşamalarında sağlam ve genelleştirilebilir bir performans sergilemesi hedeflenmiştir.

4.3. Anomali Tespiti ve Sınıflandırma Modeli

Bu aşamada, YOLOv11 segmentasyon modelinin çıktısı olarak elde edilen arka plandan ayrıştırılmış (maskelenerek izole edilmiş) temiz veriler, anomali tespiti ve sınıflandırma modeline girdi olarak verilmektedir.

Anomali tespit ve sınıflandırma modelinin başarılı bir şekilde çalışabilmesi için öncelikle veri seti hazırlığı süreci yürütülmüştür. Bu çalışma kapsamında, 3D yazıcılarda yaygın olarak karşılaşılan üç anomali türü ile doğru baskıların tespitine odaklanılmıştır.

Veri seti, bu dört sınıf (“Doğru baskı” (*Good*), “İpliklenme” (*Stringing*), “Çatlama” (*Cracking*), “Spagetti” (*Spaghetti*)) göz önünde bulundurularak, manuel olarak tek tek etiketlenmiştir. Ayrıca, veri dağılımı göz önünde bulundurularak, veri seti, eğitim, doğrulama ve test setlerine ayrılmış, ardından da geliştirilecek sınıflandırma modelinin performansını artırmak amacıyla ön işleme ve veri artırma teknikleri uygulanmıştır.

Anomali tespit ve sınıflandırma modelinin eğitim sürecinde, literatürde yaygın olarak kullanılan ve güçlü yönleriyle öne çıkan ResNet ve EfficientNet modelleri tercih edilmiştir. Bu iki model, önceden eğitilmiş ağırlıklar kullanılarak, bu çalışmada oluşturulan veri seti bazında yeniden eğitilmiş, modelleri başarılarını artırmak için hiperparametre optimizasyonları gerçekleştirilmiştir. En yüksek performansı gösteren model, iki aşamalı anomali tespit sisteminin sınıflandırma adımı için tercih edilecektir.


4.3.1. Sınıflandırma veri seti

Sınıflandırma modelinin eğitimi için kullanılacak veri seti, seçilen algoritmalara uygun olacak şekilde, segmentasyon aşamasından elde edilen maskelenmiş baskı alanlarını içerecek biçimde yeniden düzenlenmiştir. Bu veri seti, modelin baskı alanındaki farklı anomali türlerini daha doğru bir şekilde ayırt edebilmesi için dengeli olacak şekilde oluşturulmuş ve sınıflandırma performansını artırmaya yönelik optimizasyonlar uygulanmıştır.

4.3.1.1. Veri setinin hazırlanması

Anomali tespiti ve sınıflandırma aşamasında, YOLOv11 segmentasyon modeli tarafından izole edilen baskı alanları kullanılmaktadır. Bir başka ifadeyle, segmentasyon modelinin çıktısı olarak elde edilen görüntüler, sınıflandırma modelinin girdisi olarak kullanılmaktadır.

Bu aşamada, sınıflandırma modelinin doğrudan segmente edilmiş görüntülerle çalışacağı göz önünde bulundurularak, veri setinin bu yapıya uygun olacak şekilde düzenlenmesi amaçlanmıştır. Bu doğrultuda, modelin giriş formatına uygun hale getirilen veri setine ait örnek görüntüler Görsel 4.3’te sunulmuştur.




Görsel 4.3. Sınıflandırma için hazırlanan veri setinden örnek görüntüler

4.3.1.2. Veri setinin etiketlenmesi

Veri seti, 3D yazıcılarda yaygın olarak karşılaşılan “İpliklenme” (*Stringing*), “Çatlama” (*Cracking*) ve “Spagetti” (*Spaghetti*) anomali türleri ile “Doğru baskı” (*Good*) sınıfına odaklanılarak manuel olarak etiketlenmiştir.

Her sınıf, baskı hatalarının belirgin özellikleri göz önünde bulundurularak tanımlanmış ve bu doğrultuda etiketlenmiştir. Etiketleme işlemi, Roboflow platformu kullanılarak, her bir görüntü tek tek analiz edilerek gerçekleştirilmiştir. Bu süreçte, sınıflandırma modelinin sınıf türlerini daha doğru ayırt edebilmesi için her görüntünün ait olduğu kategori titizlikle belirlenmiştir. Etiketlemenin nasıl yapıldığının anlaşılması için sırasıyla “Doğru baskı” (*Good*), “Çatlama” (*Cracking*), “Spagetti” (*Spaghetti*) ve “İpliklenme” (*Stringing*) sınıflarını temsil eden bazı örnekler Görsel 4.4’te sunulmuştur.



Görsel 4.4. Sınıflandırma veri seti etiketleme örnekleri

4.3.1.3. Veri setinin dağılımı

Sınıflandırma veri setinde toplam 622 görüntü bulunmaktadır. Veri seti oluşturulurken, modelin doğru baskılar ile üç farklı anomali türüne ait hatalı baskıları dengeli bir şekilde tahmin edebilmesi hedeflenmiş olup, sınıfların dağılımı buna uygun olarak seçilmiştir. Bu sayede, modelin, ağırlıklı olarak belli sınıfların tahminine yönlendirilmesini önlenmesi ve tüm sınıflar arasında dengeli bir öğrenme sağlanması amaçlanmıştır. Bu doğrultuda gerçekleştirilen etiketleme işlemi sonucunda, elde edilen veri setinin sınıf-bazlı dağılımı Tablo 4.1’de verilmiştir. Buna göre sınıflandırma veri setindeki görüntülerden 300 tanesi “Doğru baskı” (*Good*), 101 tanesi “Çatlama” (*Cracking*), 98 tanesi “Spagetti” (*Spaghetti*) ve geri kalan 123 görüntü ise “İpliklenme” (*Stringing*) sınıfına aittir.

Tablo 4.1. Sınıflandırma veri setinin sınıf bazlı dağılımı

Sınıf Türü	Görüntü Sayısı
Doğru baskı (<i>Good</i>)	300
Çatlama (<i>Cracking</i>)	101
Spagetti (<i>Spaghetti</i>)	98
İpliklenme (<i>Stringing</i>)	123
Toplam	622

Modelin, daha iyi ve genelleştirilebilir sınıflandırma başarısı elde etmesi amacıyla, sınıflandırma veri seti Roboflow platformu üzerinde %70 eğitim, %15 doğrulama ve %15 test olarak rastgele bölünmüştür. Bu bölünme sonrasında her bir veri setindeki görüntü sayıları Tablo 4.2’de sunulmuştur.

Tablo 4.2. Sınıflandırma veri setinin bölünmesi

Veri Seti	Görüntü Sayısı
Eğitim	422
Doğrulama	100
Test	100

Sınıflar kendi içlerinde de dengeli bir dağılımla bölünmüştür. Bu dengeleme işlemi, modelin belirli bir sınıfa yönelik aşırı eğilim göstermesini önleyerek tüm sınıfların öğrenme sürecine eşit katkı sağlamasını amaçlamaktadır. Böylece, modelin her sınıfa

yönelik ayırt edici özellikleri daha etkili bir şekilde öğrenmesi ve genelleme performansının artırılması hedeflenmiştir.

4.3.1.4. Ön işleme ve veri artırma teknikleri

Toplanan görüntüler üzerinde ön işleme ve veri artırma işlemleri uygulanmıştır.

Ön işleme aşamasında, görüntülerin uygun formatta işlenebilmesi için otomatik yönlendirme işlemi uygulanmış ve tüm görüntüler 480x480 piksel boyutuna ölçeklendirilmiştir.

Veri artırma işlemleri, sınıflandırma performansını arttıracak şekilde seçilmiş ve yalnızca eğitim verilerine uygulanmış olup, bu sayede modelin farklı koşullarda daha geliştirilmiş bir performans sergilemesi amaçlanmıştır. Kullanılan veri artırma teknikleri aşağıda listelenmiştir.

- *Grayscale*: %25 oranında grileştirme uygulanmıştır.
- *Hue*: Görüntülerin renk tonları ± 25 derece değiştirilmiştir.
- *Saturation*: Renk doygunluğu $\pm \%34$ oranında artırılmış veya azaltılmıştır.
- *Brightness*: Parlaklık seviyeleri $\pm \%25$ oranında değiştirilmiştir.
- *Exposure*: Pozlama seviyeleri $\pm \%15$ oranında değiştirilmiştir.

Bu veri artırma teknikleri, farklı görüntülere rastgele şekilde uygulanarak veri setinin çeşitliliği artırılmış ve modelin farklı türdeki anomalileri daha iyi öğrenmesi sağlanmıştır. Bu işlemler sonucunda, eğitimde kullanılacak toplam görüntü sayısı 1688 olmuştur.

4.3.2. Sınıflandırma modelinin eğitimi

Bu çalışmada, anomali tespit ve sınıflandırma modelinin eğitimi için alanda yaygın olarak kullanılan ve güçlü yönleriyle öne çıkan ResNet ve EfficientNet modelleri tercih edilmiştir.

ResNet, derin yapısı ve artık bağlantıları sayesinde karmaşık desenleri öğrenme yeteneğine sahiptir. Bu özellik, baskı hatalarının detaylı biçimde ayırt edilmesine olanak tanımaktadır. Özellikle ince detaylara sahip anomali türlerinde yüksek doğruluk oranları sunması nedeniyle tercih edilmektedir.

EfficientNet, verimli hesaplama gücü ve ölçeklenebilir yapısı ile farklı veri türlerine uyum sağlayabilen modern bir sınıflandırma modelidir. Daha düşük parametre sayısı ile daha yüksek doğruluk elde etme potansiyeli, sınıflandırma aşamasında tercih edilme sebeplerinden biridir.

Bu iki model, aktarım öğrenmesi (*Transfer Learning*) yöntemi kullanılarak, önceden eğitilmiş ağırlıklar (*Pretrained Weights*) bazında yalnızca bu çalışmada oluşturulan sınıflandırma veri setine özel olarak yeniden eğitilmiştir. Böylece modeller, hem barındırdıkları genel görüntü sınıflandırma yeteneklerine sahip olur, hem de 3D yazıcı baskı hatalarının tespitine odaklı tekrar eğitilmiş olur.

Her iki model de oluşturulan sınıflandırma veri seti üzerinde ayrı ayrı eğitilmiş, eğitim sırasında modellerin optimal performansa ulaşmasının sağlanması adına hiperparametre optimizasyonu uygulanmıştır. Eğitim sürecinin ardından, modellerin genel başarımları test veri seti üzerinde değerlendirilmeye tabi tutulmuştur. Bu noktada, ResNet ve EfficientNet sınıflandırma modellerinin başarımları kıyaslanarak, en yüksek performansa sahip model, iki aşamalı anomali tespit sisteminin sınıflandırma adımı için tercih edilmiştir.

5. DENEYLER VE BULGULAR

Bu bölümde, gerçekleştirilen deneylerin teknik altyapısı, kullanılan donanım ve yazılım bileşenleri, çalışmada kullanılan segmentasyon ve sınıflandırma modellerinin eğitim ve değerlendirme süreçleri açıklanmış; modellerinin performansları, belirlenen metrikler doğrultusunda analiz edilerek sunulmuştur. İlk olarak, YOLOv11 tabanlı segmentasyon modelinin eğitim süreci açıklanmış, modelin eğitimi için belirlenen parametreler, hiperparametre optimizasyonu ve modelin eğitim sonrası performans değerlendirmesi detaylandırılmıştır. Ardından, EfficientNet ve ResNet modellerinin eğitim süreçleri ele alınmış, her bir model için kullanılan eğitim parametreleri ile birlikte, eğitim ve test veri setleri üzerindeki performansları raporlanmıştır. Bu analiz doğrultusunda, anomali tespitinde en yüksek başarıyı sağlayan model belirlenerek modellerin karşılaştırmalı değerlendirmesi sunulmuştur. Son olarak, önerilen iki aşamalı anomali tespit modeli (D3PAD-X), veri setine dahil olmayan açık kaynak görseller üzerinde test edilmiş ve modelin genelleme yeteneği değerlendirilmiştir. Elde edilen sonuçlar, modelin gerçek dünya koşullarında ne derece tutarlı ve güvenilir tahminler yapabildiğini ortaya koymak amacıyla sunulmuştur.

5.1. Deneysel Altyapı

Derin öğrenme modellerinin eğitimi yüksek hesaplama gücü gerektirdiğinden, deneyler Birleşik Cihaz Hesaplama Mimarisi (*Compute Unified Device Architecture, CUDA*) destekli GPU hızlandırması ile gerçekleştirilmiştir. Deneylerde kullanılan donanım bileşenleri Tablo 5.1'de, yazılım bileşenleri ve kütüphaneler ise Tablo 5.2'de detaylandırılmıştır.

Tablo 5.1. Modellerin eğitildiği ve çalıştırıldığı donanım bileşenleri

Donanım	Model
İşlemci (CPU)	AMD Ryzen 5600
GPU	NVIDIA RTX 4060 Ti (16 GB VRAM)
Bellek (RAM)	32 GB DDR4

Bu altyapı sayesinde YOLOv11 segmentasyon modeli ile EfficientNet ve ResNet sınıflandırma modellerinin eğitimi verimli bir şekilde gerçekleştirilmiştir. Model eğitim süreçleri boyunca TensorBoard kullanılarak eğitim kayıpları, doğruluk değerleri ve diğer metrikler düzenli olarak izlenmiş ve analiz edilmiştir. Eğitim sürecinde takip edilen örnek TensorBoard ekran görüntüsü Görsel 5.1'de sunulmuştur.

Tablo 5.2. Kullanılan yazılım bileşenleri ve kütüphaneler

Yazılım/Kütüphane	Sürüm
İşletim Sistemi	Windows 10 64 Bit
Python	3.11.10
Pytorch	2.5.1
Torchvision	0.20.1
OpenCV	4.10.0
NumPy	1.26.4
Pandas	2.2.3
Matplotlib	3.9.2
Scikit-learn	1.5.2



Görsel 5.1. TensorBoard görüntüsü

Eğitim ve test süreçlerinde, modellerin başarımını değerlendirmek amacıyla farklı metrikler kullanılmıştır. YOLOv11 tabanlı segmentasyon modelinin başarımı, karmaşıklık matrisi üzerinden Kesinlik (*Precision*), Duyarlılık (*Recall*), F1-Skor (*F1-Score*) ve Ortalama Hassasiyet (*Mean Average Precision, mAP*) metrikleri ile ölçülmüştür. EfficientNet ve ResNet sınıflandırma modellerinin başarımı ise karmaşıklık matrisi üzerinden Kesinlik, Duyarlılık ve F1-Skor metrikleri kullanılarak değerlendirilmiştir. Bu metrikler ve tanımları Tablo 5.3'te sunulmuştur.

Tablo 5.3. Model başarımlı deęerlendirmede kullanılan metrikler

Terim	Açıklaması
Kesinlik (<i>Precision</i>)	Modelin tespit ettięi nesnelere kaçının doęru olduęunu ölçer.
Duyarlılık (<i>Recall</i>)	Modelin tüm gerçek nesnelere ne kadar iyi yakalayabildięini gösterir.
F1-Skor (<i>F1-Score</i>)	Kesinlik ve Duyarlılık arasındaki dengeyi ölçen bir metrik olup, modelin genel performansını deęerlendirir.
Ortalama Hassasiyet (<i>Mean Average Precision, mAP</i>)	Modelin genel doęruluk performansını gösteren ortalama doęruluk deęeri olup, çeşitli Birleşim Üzerinde Kesişim (<i>Intersection Over Union, IoU</i>) eşiklerinde hesaplanmıştır.
Karmaşıklık Matrisi (<i>Confusion Matrix</i>)	Modelin hangi sınıflarda doęru ve yanlış tahminler yaptığını gösteren görselleştirilmiş matristir.

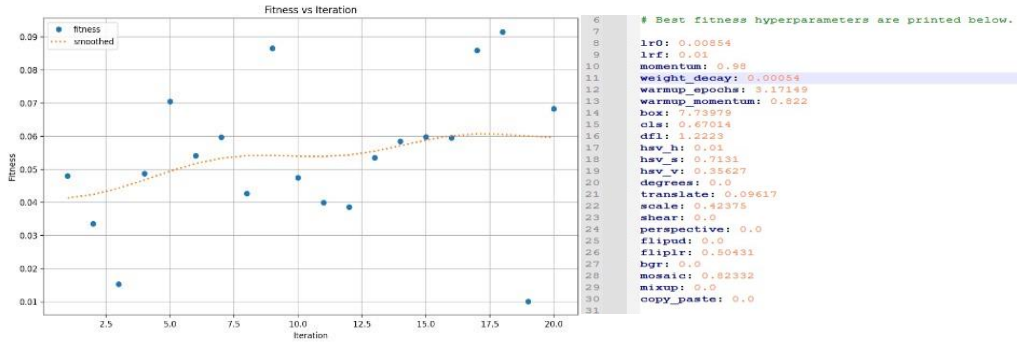
5.2. Baskı Tespiti ve Segmentasyon Modelinin Performansı

YOLOv11m-seg tabanlı segmentasyon modeli kullanılarak baskı alanının çevreden izole edilmesi hedeflenmiştir. Modelin eğitimi öncesinde, veri setindeki yollar kontrol edilmiş, eksik veya hatalı dosyaların varlığı doęrulanmıştır. Eğitimde kullanılan temel hiperparametreler ve eğitim sürecinde izlenen parametreler Tablo 5.4'te sunulmaktadır.

Tablo 5.4. YOLOv11 segmentasyon modeli için belirlenen eğitim parametreleri


Parametre	Deęer
Model Versiyonu	YOLOv11m-seg (Medium Segmentasyon)
Giriş Boyutu	640x640 piksel
Batch Size	32
Optimizer	AdamW (Adaptive Moment Estimation with Weight Decay)
Learning Rate	0,001 (dinamik olarak ayarlanan)
Epoch Sayısı	100
Kayıp Fonsiyonu	Cross-Entropy ve IoU Loss kombinasyonu
İşçi Sayısı	8 (paralel işleme için)

Segmentasyon modelinin performansını artırmak amacıyla, hiperparametre optimizasyonu gerçekleştirilmiştir. Bu süreçte, YOLOv11'in otomatik tuning özellięi kullanılmış ve en iyi hiperparametre deęerleri belirlenerek eğitim sürecine entegre edilmiştir. Hiperparametre optimizasyonuna ilişkin görseller Görsel 5.2'de sunulmuştur.



Görsel 5.2. Hiperparametre optimizasyonu

Hiperparametre optimizasyonu sonucu belirlenen parametreler doğrultusunda segmentasyon modelinin eğitim süreci tamamlanmıştır. Şekil 5.1’de, model eğitimi sırasında, modele ait metriklerinin değişimini gösteren grafikler sunulmaktadır. Eğitim süresince kayıp (*loss*) değerlerinde sürekli bir iyileşme gözlemlenmiş ve modelin öğrenme sürecini başarıyla tamamladığı değerlendirilmiştir.



Şekil 5.1. Eğitim sürecinde metriklerin değişimi

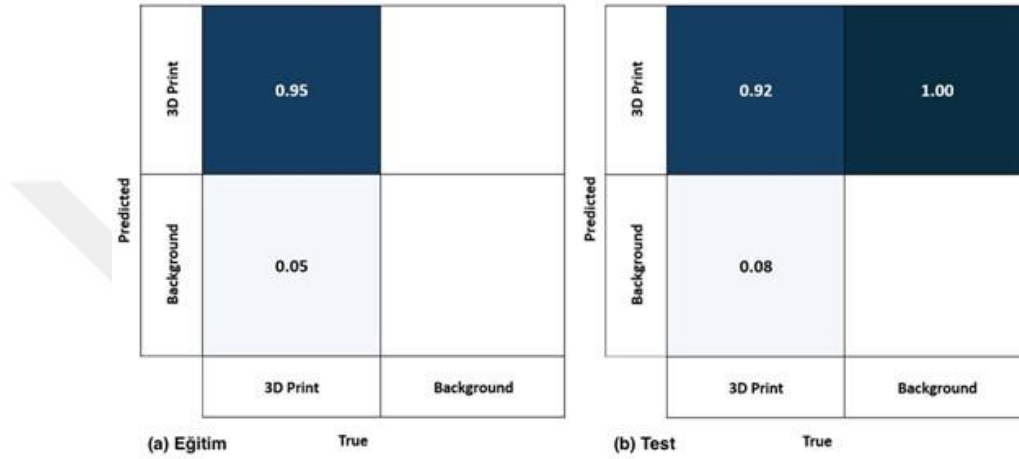
Modelin genel performansını değerlendirmek amacıyla, eğitilen segmentasyon modeli, test veri seti üzerinde doğrulama sürecine tabi tutulmuştur. Elde edilen metriklerin karşılaştırmalı analizine Tablo 5.5’te yer verilmiştir.

Tablo 5.5. Segmentasyon modeli metriklerinin karşılaştırılması

Metrik	Eğitim	Test
Keskinlik (<i>Precision</i>)	%95,8	%96,1
Duyarlılık (<i>Recall</i>)	%94,3	%94,8
F1-Skor (<i>F1-Score</i>)	%95,0	%95,4
mAP	%94,7	%94,9


Modelin farklı sınıflardaki tahmin başarılarını detaylı bir şekilde analiz etmek amacıyla karmaşıklık matrisleri oluşturulmuş ve bu matrisler Şekil 5.2’de sunulmuştur. Bu analiz, modelin hangi sınıflarda doğru ve yanlış tahminler yaptığını göstererek

modelin hata dağılımını anlamada önemli bir referans sağlamaktadır. Elde edilen normalize edilmiş karmaşıklık matrisleri, segmentasyon modelinin baskı alanını çevreden doğru bir şekilde ayırdığını göstermektedir. Model, test verilerinde düşük hata oranıyla çalışmış ve genel performansını eğitim sırasında elde edilen sonuçlarla tutarlı bir şekilde korumuştur. Bu modelin hedeflendiği gibi yüksek hassasiyet ve doğrulukla maskeleme yaparak sınıflandırma modeline besleyeceği girdiyi başarıyla sağlayacağını göstermektedir.



Şekil 5.2. Segmentasyon modeli karmaşıklık matrislerinin karşılaştırılması

Segmentasyon modelinin test veri setinde gerçekleştirdiği maskeleme tahminlerinden örnekler Görsel 5.3'te sunulmuştur.



Görsel 5.3. Test veri setinde modelin yaptığı tahmin örnekleri

5.3. Anomali Tespiti ve Sınıflandırma Modellerinin Performansı

Bu bölümde, EfficientNet ve ResNet sınıflandırma modellerinin eğitim ve test aşamalarında gösterdiği performans detaylandırılmıştır. Öncelikle modellerin eğitim süreçleri, belirlenen hiperparametreler doğrultusunda analiz edilerek sunulmuştur.

Ardından test veri seti üzerindeki performansları değerlendirilmiş ve her iki modelin sınıflar bazında gösterdiği başarı oranları karşılaştırılmıştır.


5.3.1. EfficientNet ve ResNet modellerinin eğitim performansları

EfficientNet ve ResNet sınıflandırma modellerinin eğitim süreci, CUDA destekli GPU ortamında gerçekleştirilmiş olup, model performansını artırmak amacıyla doğrulama kaybı ve doğruluk oranları sürekli izlenmiştir. Aşırı öğrenmeyi önlemek için erken durdurma (*Early Stopping*) mekanizması kullanılmıştır. EfficientNet ve ResNet sınıflandırma modellerinin eğitim parametreleri Tablo 5.6’da sunulmaktadır.


Tablo 5.6. Sınıflandırma modelleri için belirlenen eğitim parametreleri

Parametre	EfficientNet	ResNet
Model Versiyonu	EfficientNet-B7	ResNet-101
Giriş Boyutu	480x480 piksel	480x480 piksel
Batch Size	16	32
Optimizer	AdamW (<i>weight decay: 1e-4</i>)	AdamW (<i>weight decay: 1e-4</i>)
Learning Rate	0,0001 (dinamik olarak azalan)	0.0001
Epoch Sayısı	100	100
Kayıp Fonsiyonu	Cross-Entropy Loss	Cross-Entropy Loss
Scheduler	ReduceLRonPlateau (Patience: 5, Factor: 0.1)	ReduceLRonPlateau (Patience: 5, Factor: 0.1)
Dropout Oranı	%50	%50

Her iki model, dört sınıfı kapsayacak şekilde son sınıflandırma katmanları değiştirilerek yeniden eğitilmiştir. Eğitim sürecinde takip edilen metrikler ve kayıpların değişimi, Şekil 5.3’te EfficientNet ve Şekil 5.4’te ResNet modeli için sunulmuştur.



Şekil 5.3. EfficientNet eğitim sürecinde doğruluk ve kayıp metrikleri

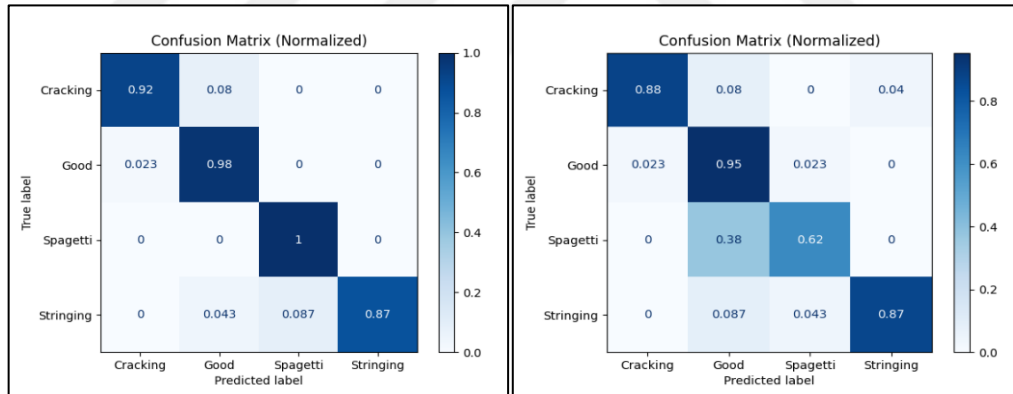


Şekil 5.4. ResNet eğitim sürecinde doğruluk ve kayıp metrikleri

EfficientNet ve ResNet sınıflandırma modellerinin eğitim sürecinde elde edilen karmaşıklık matrisleri Tablo 5.7’de karşılaştırmalı olarak sunulmuştur. Ayrıca, doğrulama veri seti üzerinde sınıf bazlı doğruluk analizleri Şekil 5.5’te sırasıyla EfficientNet ve ResNet için görselleştirilmiştir.

Tablo 5.7. Sınıflandırma modellerinin eğitim metriklerinin karşılaştırılması

	EfficientNet	ResNet
Precision	%94,0	%92,0
Recall	%93,0	%90,0



Şekil 5.5. Sınıflandırma modellerinin doğrulama veri setindeki sınıf bazlı karmaşıklık matrisi

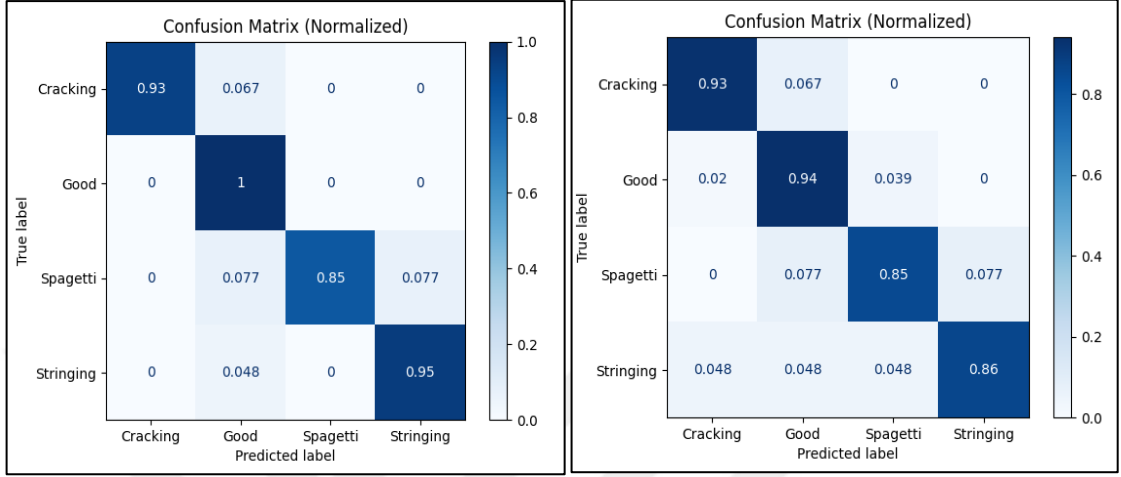
5.3.2. EfficientNet ve ResNet test performansları

EfficientNet ve ResNet modellerinin test veri seti üzerindeki performansları, Kesinlik (*Precision*), Duyarlılık (*Recall*) ve F1-Skor (*F1-Score*) metrikleri kullanılarak değerlendirilmiştir. Elde edilen performans sonuçları Tablo 5.8’de sunulmuştur.

Tablo 5.8. Sınıflandırma modellerinin test performanslarının sınıf bazlı karşılaştırması

	EfficientNet-B7					ResNet-101				
	Cracking	Good	Spagetti	Stringing	Overall	Cracking	Good	Spagetti	Stringing	Overall
Precision	%100.0	%94.44	%100.0	%95.23	%97.41	%87.50	%94.11	%78.57	%94.73	%90.22
Recall	%93.33	%100.0	%84.61	%95.23	%93.29	%93.33	%94.11	%84.61	%85.71	%89.44
F1-Score	%96.55	%97.14	%91.66	%95.23	%95.14	%90.32	%94.11	%81.48	%90.00	%88.97

Test veri seti üzerindeki karmaşıklık matrisleri, modellerin hangi sınıflarda daha iyi veya daha düşük doğrulukta tahminler yaptığı konusunda detaylı bilgi sağlamaktadır. Bu doğrultuda, EfficientNet ve ResNet sınıflandırma modellerinin test veri seti üzerindeki sınıf bazlı karmaşıklık matrisi sırasıyla Şekil 5.6’da verilmiştir.



Şekil 5.6. Sınıflandırma modellerinin test veri setindeki sınıf bazlı karmaşıklık matrisi

Deney sonuçları, EfficientNet modelinin genel doğruluk ve sınıf bazlı doğruluk oranlarında ResNet modeline kıyasla daha iyi performans gösterdiğini ortaya koymuştur. Ancak, özellikle Spagetti sınıfında her iki modelin de diğer sınıflara kıyasla daha düşük doğruluk oranına sahip olduğu gözlemlenmiştir.

5.3.3. EfficientNet ve ResNet modellerinin karşılaştırmalı analizi

EfficientNet-B7 modelinin, dengeli ölçekleme stratejisi sayesinde hesaplama kaynaklarını optimize ederken yüksek doğruluk oranı sağladığı gözlemlenmiştir. Model, anomali tespiti gibi karmaşık bir görevde verimli bir şekilde çalışarak yüksek güvenilirlik sunmuş; Kesinlik (*Precision*), Duyarlılık (*Recall*) ve F1-Skor (*F1-Score*) metrikleri açısından ResNet-101 modeline kıyasla daha iyi bir performans sergilemiştir.

ResNet-101 modelinin derin mimarisi ve atlamalı bağlantıları, modelin stabil bir öğrenme süreci geçirmesine olanak tanımış olsa da çalışmada kullanılan veri setinde genel başarımı EfficientNet-B7 modelinin gerisinde kalmıştır.


Modellerin sınıf bazlı performansı üzerine değerlendirme yapıldığında, “Başarılı Baskı” (*Good*) sınıfında her iki modelin de yüksek doğruluk oranlarına ulaştığı görülmektedir. “Spagetti” (*Spagetti*) sınıfında ise genel doğruluk oranlarının görece düşük olduğu gözlemlenmiştir. Bu durumun, sınıfın diğer anomalilere olan görsel benzerliğinden veya sınırlı veri miktarından kaynaklanabildiği değerlendirilmektedir.

Her iki sınıflandırma modelinde de eğitim ve test doğrulukları arasında tutarlı sonuçlar elde edilmiştir. Bu da eğitim süreçlerinin dikkatli bir şekilde yürütüldüğünü ve modellerin veri setinde iyi bir genelleme sağladığını destekler niteliktedir.

Bu sonuçlar dayanarak, EfficientNet-B7 modeli, önerilen anomali tespit sisteminde daha güvenilir bir sınıflandırma modeli olarak öne çıkmaktadır.

5.4. Önerilen İki Aşamalı Modelin Ek Testler ile Değerlendirilmesi

Önerilen iki aşamalı modelin genelleme yeteneğini değerlendirmek amacıyla, eğitim veri setine dahil edilmeyen açık kaynak görseller üzerinde testler gerçekleştirilmiştir. Bu test sürecinde modelin, daha önce (eğitimde) görmediği baskıları doğru bir şekilde sınıflandırma performansı analiz edilmiştir. Görsel 5.4'te, farklı anomalileri içeren test görselleri ve önerilen modelin tahminleri gösterilmektedir.



Görsel 5.4. Açık kaynak görsellerle test edilmesi

Model, farklı sınıflarda başarılı tahminler yapmıştır. “Spagetti” (*Spaghetti*) ve “Çatlama” (*Cracking*) anomalileri model tarafından yüksek güven seviyeleriyle (%98-%99) doğru sınıflandırılmıştır. “Başarılı baskı” (*Good*) sınıfında model, %94 ve %63 güven seviyeleriyle tahmin yapmıştır. “İpliklenme” (*Stringing*) anomalileri model tarafından %98 güven seviyelerinde tanımlanmıştır, bu da modelin bu tür ince ipliklenme hatalarını yüksek doğrulukla ayırt edebildiğini göstermektedir. Model, test edilen açık kaynak görsellerde yüksek doğruluk göstermiş ve eğitim veri setine bağımlı olmaksızın başarılı genelleme yapmıştır.

Bu sonuçlar, modelin eğitim veri setine bağımlı olmadan genelleme yapabildiğini ve yeni veriler üzerinde başarılı tahminler gerçekleştirdiğini göstermektedir. Önerilen model, baskı sırasında ortaya çıkabilecek farklı anomalileri yüksek doğruluk oranlarıyla tespit ederek, gerçek dünya uygulamaları için uygun bir yaklaşım sunma potansiyeline sahiptir.


6. TEST ORTAMI MODEL ENTEGRASYONU

Bu bölümde, önerilen iki aşamalı modelin gerçek dünya koşullarında nasıl test edildiği, hangi donanım ve yazılım bileşenleriyle entegre edildiği ve gerçek zamanlı kullanım için nasıl optimize edildiği detaylandırılmaktadır. Önerilen sistem, tasarlanan gerçek zamanlı test ortamına entegre edilerek 3D yazıcının baskı süreci boyunca anlık gözlemler yapılması sağlanmıştır. Bu şekilde modelin başarımı yalnızca eğitim ve test veri setleriyle değil, dinamik ve değişken baskı süreçlerinde de değerlendirilmiştir. Bu doğrultuda, segmentasyon ve sınıflandırma aşamalarının gerçek zamanlı çalışabilirliği, işleme süresi, donanımsal gereksinimler ve hesaplama verimliliği gibi faktörler dikkate alınmıştır. Bulgular, önerilen modelin gerçek zamanlı kullanım potansiyelini anlamak açısından önemlidir.

6.1. Gerçek Zamanlı Test Ortamı ve Yapısı

Bu çalışmada, önerilen modelin gerçek dünya koşullarında test edilmesi ve performansının değerlendirilmesi amacıyla özel bir test ortamı tasarlanmıştır. Bu ortam, modelin teorik başarısının pratikte ne kadar uygulanabilir olduğunu değerlendirmek ve gerçek zamanlı kullanım için uygunluğunu sınamak amacıyla oluşturulmuştur. Test ortamı hem donanımsal hem de yazılımsal bileşenleri içermekte olup, baskı sırasında meydana gelebilecek anomalilerin tespiti için gerekli veri akışını sağlamak ve analiz sürecine katkıda bulunmaktadır.

Test ortamı, (1) *FDM tipi 3D yazıcı*, (2) *Raspberry Pi tabanlı bir kontrol birimi*, (3) *bütünleşmiş bir kamera sistemi* ve (4) *UPS* bileşenlerini içerecek şekilde tasarlanmıştır. Yazıcının hareket kontrolü ve baskı yönetimi Klipper firmware aracılığıyla gerçekleştirilirken, görüntü işleme ve analiz süreçleri derin öğrenme tabanlı algoritmalarla desteklenmiştir. Kamera sistemi, baskı sürecini gerçek zamanlı olarak izleyerek anomalilerin tespit edilmesine olanak tanımaktadır. Tez çalışması kapsamında tasarlanan gerçek zamanlı test ortamı ve yapısı, Şekil 6.1'de özetlenmiştir. Test ortamının tüm bileşenleri detaylı bir şekilde alt bölümlerde ele alınarak, her bir bileşenin sistem içindeki işlevi açıklanacaktır.




Şekil 6.1. Sistemin genel özeti

6.1.1. Raspberry Pi üzerinde Klipper firmware kullanımı

FDM tipi 3D yazıcılar için en yaygın kullanılan firmware seçenekleri arasında Marlin ve Klipper bulunmaktadır. Bu çalışmada, yazıcının mikrodenetleyici sınırlamalarını aşmak ve daha fazla özelleştirme imkânı sağlayabilmek amacıyla Klipper firmware tercih edilmiştir. Klipper, yazıcının mikrodenetleyicisini yalnızca hareket kontrolü için kullanırken, işlem yükünü Raspberry Pi gibi harici bir bilgisayara aktararak sistemin genel performansını artırır. Bu yapı, yazıcının hareket doğruluğunu artırırken, hız ve stabilite açısından daha iyi sonuçlar elde edilmesine olanak tanır. Ayrıca, Klipper’ın gelişmiş hareket planlama yetenekleri sayesinde, baskı sürecinde daha tutarlı ve hassas sonuçlar alınmaktadır (Klipper Documentation, 2024).

Kullanılan 3D yazıcı, 8-bit bir mikrodenetleyici kartına sahiptir. Geleneksel 8-bit donanımlar, karmaşık hareket planlama gerektiren işlemlerde sınırlamalar gösterebilir ve yüksek hızlarda tutarsız baskı kalitesine yol açabilir. Klipper’ın sunduğu “*Input Shaping*” ve gelişmiş ivme yönetimi gibi özellikler sayesinde, baskı sırasında oluşabilecek titreşimler en aza indirilerek hareket doğruluğu artırılmaktadır. Özellikle yüksek hızlarda baskı alınırken, bu optimizasyonlar sayesinde katman kaymaları ve mekanik titreşimler önemli ölçüde azaltılmaktadır. Yazıcının sahip olduğu mikrodenetleyici kartı, Görsel 6.1’de sunulmuştur.



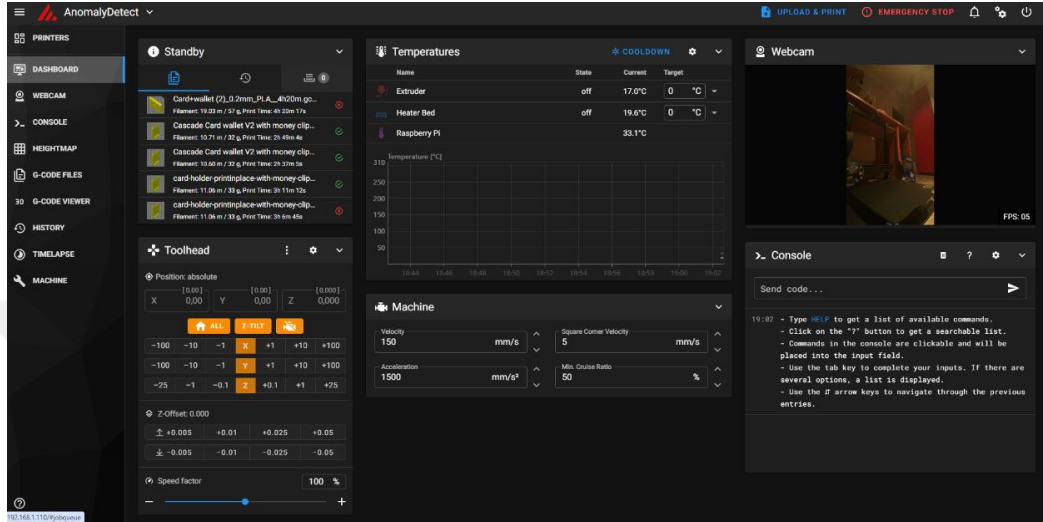
Görsel 6.1. Makerbase MKS Gen L V1.0 model kontrol kartı

Bu çalışmada, Raspberry Pi 2 Model B üzerine Klipper kurulmuş, sistem yapılandırması Moonraker Uygulama Programlama Arayüzü (*Application Programming Interface, API*) ve Mainsail web arayüzü ile desteklenmiştir. Raspberry Pi, yazıcıya hem kontrol hem de izleme için bir merkez görevi görmüş, yazıcı ile bilgisayar arasında iletişim kuran bir köprü olarak çalışmıştır. Klipper'in bu şekilde yapılandırılması, yazıcı donanımının sınırlamalarını aşarak hareket doğruluğunu artırmış ve sistemin daha stabil bir şekilde çalışmasını sağlamıştır.

Moonraker, Klipper ile entegre çalışarak yazıcının durumunun API tabanlı olarak izlenmesine ve kontrol edilmesine olanak tanımaktadır. Kullanıcılar, Moonraker aracılığıyla yazıcı parametrelerini dinamik olarak değiştirebilir, baskı sürecinin anlık durumunu izleyebilir ve süreçle ilgili detaylı verilere erişebilir. API desteği sayesinde sıcaklık, hız, ivme gibi kritik parametreler gerçek zamanlı olarak toplanmakta ve sistemin anlık olarak optimize edilmesine imkân tanımaktadır. Tez çalışması kapsamında, Moonraker, yazıcının daha etkin bir şekilde kontrol edilmesi ve durumunun izlenmesi için temel bir bileşen olarak kullanılmıştır (Moonraker Documentation, 2024).

Mainsail, Klipper ve Moonraker ile entegre çalışan, kullanıcı dostu bir web tabanlı arayüz sağlamaktadır. Bu arayüz, kullanıcıların yazıcının durumunu gerçek zamanlı olarak izlemesine, baskı süreçlerini başlatıp durdurmasına ve parametreleri anında düzenlemesine olanak tanımaktadır. Ayrıca, sistemin sunduğu anlık geri bildirimler

sayesinde, kullanıcılar baskı sürecindeki değişiklikleri hızlı bir şekilde takip edebilmekte ve gerektiğinde müdahale edebilmektedir. Bu çalışmada, Mainsail'in modern ve sezgisel arayüzü, yazıcının yönetimini ve kontrolünü kolaylaştırarak baskı süreçlerinin daha etkin bir şekilde takip edilmesini sağlamıştır (Mainsail Documentation, 2024). Kullanılan test ortamının arayüzü, Görsel 6.2'de sunulmuştur.



Görsel 6.2. Test ortamının Mainsail arayüzü

Klipper, kullanıcıya özelleştirilmiş makrolar yazma imkânı tanımaktadır. Bu bağlamda, filament değişimi, baskı sırasındaki hız ve sıcaklık değişiklikleri gibi süreçler makrolar aracılığıyla çalışma kapsamında kolayca yönetilebilmiştir.

Raspberry Pi üzerine kurulan sistem hem yazıcının yönetimini hem de kamera üzerinden yayın yapmayı tek bir platformda birleştirerek, ekstra bir sistem kurma ihtiyacını ortadan kaldırmıştır.

6.1.2. Elektrik kesintilerine karşı UPS ve test ortamının entegrasyonu

Bu çalışmada, baskı süreçlerinin elektrik kesintilerinden etkilenmeden devam edebilmesi için test ortamına bir UPS sistemi entegre edilmiştir. Elektrik kesintileri, özellikle uzun süren baskı süreçlerinde malzeme israfı, zaman kaybı ve üretim hataları gibi ciddi sorunlara yol açabilmektedir. Bu tür problemlerin önüne geçebilmek amacıyla, UPS bağlantısı entegre edilerek, kesinti anında sistemin güvenliğini sağlayan bir izleme ve kontrol mekanizması geliştirilmiştir.

Sistemde kullanılan UPS, Raspberry Pi 2 Model B ve 3D yazıcının güç ihtiyacını aynı anda karşılayabilecek kapasitede seçilmiştir. UPS, elektrik kesintisi sırasında sistemi belirli bir süre çalışır durumda tutarak, yazıcı ve Raspberry Pi'nin güvenli bir şekilde kapanmasını veya baskıya devam etmesini sağlamaktadır. Çalışma kapsamında, UPS

yalnızca bir güç kaynağı olarak değil, Raspberry Pi üzerinde çalışan özel bir izleme sistemi ile entegre edilerek yapılandırılmıştır. Bu sistem, elektrik kesintilerini algılayarak Moonraker API aracılığıyla Klipper üzerinde özel olarak yazılmış bir makroyu tetiklemektedir. Bu kapsamda, geliştirilen Makro ve Python betikleri Görsel 6.3'te sunulmuştur.



```
[gcode_macro UPS_ON_BATTERY]
description: Save power by turning off heaters and fans while keeping motors energized
gcode:
  # Call the PAUSE macro to pause the print
  PAUSE

  # Turn off all heaters
  SET_HEATER_STATE HEATER=extruder STATE=0
  SET_HEATER_STATE HEATER=bed STATE=0

  # Turn off all fans using M107
  M107

  # Keep stepper motors powered
  RESPOND PREFIX="The Outage is Over" MSG="UPS ON LINE"
  RESPOND MSG="Energy saving initiated, motors remain powered"

[gcode_macro UPS_ON_LINE]
gcode:
  RESPOND PREFIX="The Outage is Over" MSG="UPS ON LINE"
```

```
import os
import time
import subprocess

def check_ups():
    on_battery = False # Başlangıçta UPS'in batarya modunda olmadığını varsayıyoruz

    while True:
        result = subprocess.run(['upsc', 'myups@localhost'], stdout=subprocess.PIPE)
        status = result.stdout.decode('utf-8')

        if '0B' in status: # 0B: On Battery
            if not on_battery: # Daha önce batarya moduna geçemediysek
                os.system('curl -X POST http://localhost:7125/printer/gcode/script?script=UPS_ON_BATTERY')
                on_battery = True # Artık batarya modundayız
            else: # Elektrik geri geldi
                if on_battery: # Daha önce batarya modunda idiysek
                    os.system('curl -X POST http://localhost:7125/printer/gcode/script?script=UPS_ON_LINE')
                    on_battery = False # Artık batarya modunda değiliz

                time.sleep(10) # Kontrol süresini 10 saniye olarak ayarladık

if __name__ == "__main__":
    check_ups()
```

Görsel 6.3. Makro ve python betiği

Geliştirilen bu yapı şu şekilde çalışmaktadır: Raspberry Pi'ye bağlı UPS izleme yazılımı, kesintiyi algıladığında anında harekete geçer ve Moonraker API aracılığıyla Klipper'a sinyal göndererek özel bir makroyu tetiklemektedir. Bu makro, yazıcıyı güvenli bir şekilde durdurur ve mevcut baskı durumunu kaydeder. Elektrik geri geldiğinde, sistem otomatik olarak başlatılarak baskının kesintisiz bir şekilde kaldığı yerden devam etmesi sağlanır. Klipper'ın varsayılan bir "Resume On Power Loss" özelliği olmamasına rağmen, geliştirilen bu çözüm sayesinde kesintilere karşı güvenilir bir mekanizma oluşturulmuştur. Böylece baskı süreçlerinin sürekliliği sağlanmış, veri kaybı ve donanım zararları önlenmiştir.

Klipper'ın UPS ile uyumlu çalışmasını sağlamak amacıyla firmware entegrasyonu gerçekleştirilmiştir. Raspberry Pi'ye bağlı bir UPS izleme modülü kullanılarak, elektrik kesintisi algılandığında, Klipper üzerinden baskıyı güvenli bir şekilde durduran ve ardından devam ettiren komutlar tanımlanmıştır. Bu süreç, Moonraker API aracılığıyla entegre edilerek gerçek zamanlı olarak takip edilmiştir. Böylece, sistem kesintiler sırasında veri kaybını ve donanım zararını önleyecek şekilde yapılandırılmıştır.

Bu yapılandırma, baskı süreçlerinin sürekliliğini sağlamanın yanı sıra, sistemin güvenliğini ve verimliliğini artırmıştır. UPS bağlantısının yazıcı ve Raspberry Pi ile entegrasyonu Görsel 6.4'te sunulmuştur.



Görsel 6.4. UPS ve test ortamı bağlantısı

6.1.3. Görüntü akışının alınacağı kameranın sistem ile entegrasyonu

Bu çalışmada, baskı süreçlerini izlemek ve anomali tespitini gerçekleştirmek amacıyla kullanılan kamera, sistemle entegre edilerek sürekli görüntü akışı sağlanmıştır. Baskı alanını geniş açılı lensi ve yüksek çözünürlüğü ile net bir şekilde görüntüleyebilen Raspberry Pi Camera 3 Wide modeli tercih edilmiştir. Kamera, yazıcı üzerinde bulunan baskı alanını sürekli gözlemleyerek gerçek zamanlı video akışı sağlamaktadır. Raspberry Pi Camera 3 Wide modelinin özellikleri Tablo 6.1'de sunulmuştur.

Tablo 6.1. Kamera özellikleri


	Camera Module 3	Camera Module 3 NoIR	Camera Module 3 Wide	Camera Module 3 Wide NoIR
Focus range	10cm-∞	10cm-∞	5cm-∞	5cm-∞
Focal length	4.74mm	4.74mm	2.75mm	2.75mm
Diagonal field of view	75 degrees	75 degrees	120 degrees	120 degrees
Horizontal field of view	66 degrees	66 degrees	102 degrees	102 degrees
Vertical field of view	41 degrees	41 degrees	67 degrees	67 degrees
Focal ratio (F-stop)	F1.8	F1.8	F2.2	F2.2
Infrared-sensitive	No	Yes	No	Yes

Kamera, sistemle entegre edilirken, Raspberry Pi Camera 3 Wide, CSI portu aracılığıyla Raspberry Pi 2 Model B'ye fiziksel olarak bağlanmış ve kameranın donanım kontrolü gerçekleştirilmiştir. Görüntü akışı, Raspberry Pi üzerinde çalışan MJPEG

Streamer aracılığıyla yönlendirilmiş, video akışı sıkıştırılarak Mainsail arayüzü üzerinden de erişime sunulmuştur. Aynı zamanda, Moonraker API ile entegrasyon sağlanarak, görüntü akışı ve baskı kontrolü tek bir platform üzerinden yönetilmiştir.

Sistem şu şekilde yapılandırılmıştır: Raspberry Pi Camera 3 Wide, CSI portu aracılığıyla Raspberry Pi'ye fiziksel olarak bağlanmış ve donanım kontrolü tamamlanmıştır. Raspberry Pi üzerinde çalışan bir görüntü akışı yazılımı, video akışını sıkıştırarak Mainsail web arayüzüne entegre etmiştir. Ayrıca, Moonraker API aracılığıyla sistem, görüntü akışı ve baskı kontrolü süreçlerini tek bir platformda birleştirecek şekilde yapılandırılmıştır. Ayrıca, video yayını, yerel ağ üzerinden anomali tespiti yapacak bir masaüstü bilgisayara aktarılacak şekilde yapılandırılmıştır. Böylece, sistem hem kullanıcıya gerçek zamanlı izleme imkânı sunmuş, hem de baskı süreçlerinde oluşabilecek sorunların erken tespitini sağlamıştır.

Bu sistem, ek bir görüntü işleme altyapısına gerek kalmadan, baskı süreçlerinin kolayca izlenmesine ve yönetilmesine olanak tanımıştır. Kullanılan geniş açılı lens ve yüksek çözünürlük, baskı sırasında oluşabilecek anomalilerin görsel olarak tespit edilmesini ve hızlı müdahale edilmesini sağlamıştır. Kameranın sistem üzerindeki konumu Görsel 6.5'te sunulmuştur.



Görsel 6.5. *Kameranın konumlanması*

6.1.4. Analiz ortamında görüntünün yakalanması ve işlenmesi

Bu çalışmada, baskı sürecinde oluşabilecek anomalileri tespit etmek amacıyla görüntü işleme teknikleri kullanılmış ve analiz ortamı bu doğrultuda yapılandırılmıştır. Görüntüler, Raspberry Pi Camera 3 Wide ile yakalanmış ve video akışı masaüstü bilgisayarda analiz edilmiştir. Bu yapılandırma, anomali tespiti için verimli bir veri işleme hattı sağlamaktadır.

Kamera, baskı alanını gerçek zamanlı olarak gözlemlemiş ve video akışını Raspberry Pi 2 Model B üzerinden sıkıştırarak yerel ağ bağlantısı aracılığıyla masaüstü bilgisayara iletmiştir. Masaüstü bilgisayarda, bu görüntüler OpenCV kütüphanesi kullanılarak alınmış ve analiz için ön işleme tabi tutulmuştur. Ön işleme aşamasında, görüntülerin çözünürlüğü optimize edilmiş, gereksiz veriler temizlenmiş ve analiz için uygun formatlara dönüştürülmüştür. Bu işlem, görüntü kalitesini artırarak daha doğru sonuçlar elde edilmesini sağlamıştır. Masaüstü bilgisayar tarafından yakalanan örnek bir görüntü, Görsel 6.6’da görülmektedir.

Yakalanan görüntü, tez çalışması kapsamında geliştirilen iki aşamalı anomali tespit modeli, D3PAD-X, aracılığıyla gerekli işlem adımlarına tabi tutulmaktadır. Bu adımlar, genel hatlarıyla, (1) *Segmentasyon*, (2) *Sınıflandırma* ve (3) *Kullanıcının bilgilendirilmesi* olarak listelenebilir (Şekil 6.2).



Şekil 6.2. Gerçek zamanlı test ortamında D3PAD-X süreçleri



Görsel 6.6. Yakalanan Görüntü

D3PAD-X yöntemi ilk aşaması – Segmentasyon: Segmentasyon işlemi için tez çalışması kapsamında eğitilen YOLOv11 modeli kullanılmış ve yazdırılan nesne çevresinden ayrıştırılmıştır. Model, bir sonraki aşama olan sınıflandırma modeline, arka plandan ayrıştırılmış ve baskıya odaklanmış temiz veriler sağlamak, dolayısıyla yalnızca yazdırılan nesneyi tespit etmek için eğitildiğinden, bu aşamada anomali türlerini

doğrudan sınıflandırmamaktadır. Segmentasyon sonrasında elde edilen örnek görüntüler Görsel 6.7’de verilmiştir.




Görsel 6.7. Segmentasyon sonrası elde edilen örnek görüntüler

D3PAD-X yöntemi ikinci aşaması – Sınıflandırma: Sınıflandırma işlemi için tez çalışması kapsamında eğitilen ve başarımının ResNet modeline kıyasla daha yüksek olduğu tespit edilen EfficientNet modeli kullanılmıştır. Segmentasyon işleminin çıktısı olarak elde edilen veriler, EfficientNet modeli ile analiz edilerek olası anomaliler sınıflandırılmıştır. Bu model, baskı sırasında meydana gelebilecek “İpliklenme” (Stringing), “Çatlama” (Cracking) veya “Spagetti” (Spaghetti) türündeki anomalileri doğru bir şekilde tespit edebilmek için eğitilmiş ve optimize edilmiştir.

D3PAD-X yöntemi çıktısı – Kullanıcıya bilgi sağlama: Segmentasyon ve sınıflandırma işlemleri tamamlandıktan sonra, D3PAD-X yönteminin çıktısı olarak elde edilen sonuçlar, masaüstü bilgisayar ekranında kullanıcıya görsel ve metin tabanlı olarak sunulmuştur. Bu sistem, tespit edilen anomali türünü ekranda göstererek kullanıcıya müdahale imkânı sağlamaktadır. Sınıflandırma sonrasında elde edilen “Hatasız baskı” (Good) sınıfına ait örnek çıktı Görsel 6.8’de ve “İpliklenme” (Stringing) sınıfına ait örnek çıktı Görsel 6.9’da verilmektedir.



Görsel 6.8. Gerçek zamanlı test ortamı “Hatasız baskı” (Good) sınıfına ait örnek çıktı



Görsel 6.9. Gerçek zamanlı test ortamı “İpliklenme” (Stringing) sınıfına ait örnek çıktı

Bu yapılandırma, gerçek zamanlı görüntü işleme ile baskı süreçlerinin yakından izlenmesine ve sorunların erken aşamalarda tespit edilmesine olanak tanımaktadır. Ayrıca, OpenCV tabanlı ön işleme süreci sayesinde veriler, derin öğrenme modellerine uygun hale getirilebilmekte ve analiz sonuçlarının doğruluğu artırılabilir. Sonuç olarak, tasarlanan gerçek zamanlı test ve analiz ortamı, baskı sürecinde meydana gelebilecek sorunların erken tespiti açısından önemli olup, sistemin genel performansının artmasında ve kullanıcıya daha güvenilir bir baskı deneyimi sunulmasında faydalı olacaktır.

6.2. Gerçek Zamanlı Performans Sonuçları

Test ortamından alınan gerçek zamanlı görüntüler, geliştirilen D3PAD-X iki aşamalı anomali tespit sistemine anlık olarak iletilmiş ve model performansı değerlendirilmiştir. Yapılan ölçümler sonucunda, segmentasyon modelinin ortalama işlem süresi frame başına 20 ms, sınıflandırma modeli olarak kullanılan EfficientNet'in işlem süresi ise 80 ms olarak gözlemlenmiştir. Çalışma hızlarına ilişkin ekran görüntüsü Görsel 6.10'da sunulmuştur.

```
0: 640x640 1 3dPrint, 18.0ms
Speed: 2.0ms preprocess, 18.0ms inference, 1.0ms postprocess per image at shape (1, 3, 640, 640)

0: 640x640 1 3dPrint, 18.0ms
Speed: 2.0ms preprocess, 18.0ms inference, 1.0ms postprocess per image at shape (1, 3, 640, 640)

0: 640x640 1 3dPrint, 19.0ms
Speed: 1.0ms preprocess, 19.0ms inference, 2.0ms postprocess per image at shape (1, 3, 640, 640)

0: 640x640 1 3dPrint, 18.0ms
Speed: 1.0ms preprocess, 18.0ms inference, 3.0ms postprocess per image at shape (1, 3, 640, 640)

0: 640x640 1 3dPrint, 19.0ms
Speed: 1.0ms preprocess, 19.0ms inference, 2.0ms postprocess per image at shape (1, 3, 640, 640)

0: 640x640 1 3dPrint, 17.0ms
Speed: 1.0ms preprocess, 17.0ms inference, 1.0ms postprocess per image at shape (1, 3, 640, 640)

0: 640x640 1 3dPrint, 18.0ms
Speed: 1.0ms preprocess, 18.0ms inference, 3.0ms postprocess per image at shape (1, 3, 640, 640)

0: 640x640 1 3dPrint, 19.0ms
Speed: 1.0ms preprocess, 19.0ms inference, 2.0ms postprocess per image at shape (1, 3, 640, 640)
```

Görsel 6.10. Modelin gerçek zamanlı çalışma zamanlamaları

Gerçek zamanlı izleme ve analiz yetenekleri sayesinde, önerilen iki aşamalı modelin hem segmentasyon hem de sınıflandırma süreçlerinde yüksek doğruluk oranlarına ulaşabileceği değerlendirilmiştir. Bu bulgular, modelin baskı sürecini takip edebilme ve anomali tespitinde hızlı ve etkili bir performans sergileyebilme potansiyelini işaret etmektedir.

7. SONUÇ VE ÖNERİLER

Bu tez çalışmasında, kartezyen FDM tipi 3D yazıcılarda baskı sürecinde meydana gelen anomalilerin tespit edilmesi ve sınıflandırılması amacıyla derin öğrenme tabanlı iki aşamalı bir anomali tespit modeli önerilmiştir. Önerilen model, baskı alanının çevreden izole edilerek temiz verilerle sınıflandırma yapılmasını sağlayarak, hata tespitinde daha yüksek doğruluk oranlarına ulaşmayı hedeflemiştir.

Önerilen yaklaşım kapsamında, ilk aşamada YOLOv11 modeli kullanılarak segmentasyon işlemi gerçekleştirilmiş ve baskı alanı çevreden ayrıştırılmıştır. İkinci aşamada ise, segmentasyon ile elde edilen temiz verilere EfficientNet ve ResNet sınıflandırma modelleri uygulanarak anomalilerin tespiti gerçekleştirilmiştir. Eğitim süreçleri boyunca hiperparametre optimizasyonu yapılmış, model performansları Precision, Recall ve F1-Score gibi metrikler ile değerlendirilmiştir.

Deneysel sonuçlar, önerilen iki aşamalı yöntemin tek aşamalı modellere kıyasla daha başarılı sonuçlar verdiğini göstermiştir. Segmentasyon işlemi sayesinde arka plan kaynaklı hatalar azaltılmış ve modelin gerçek hataları daha güvenilir şekilde tespit etmesi sağlanmıştır. EfficientNet-B7 sınıflandırma modeli, test verisinde daha yüksek doğruluk oranları elde ederek anomali tespiti için en başarılı model olarak belirlenmiştir.

Ayrıca, modelin genelleme yeteneğini değerlendirmek amacıyla veri setine dahil edilmemiş açık kaynak görsellerle ek testler yapılmış ve modelin farklı baskı senaryolarında da başarılı tahminler yapabildiği gözlemlenmiştir. Gerçek zamanlı test ortamına entegre edilen sistem, anomali tespit sürecini anlık olarak çalıştırabilmiş ve görüntü işleme süreleri açısından düşük gecikme süreleriyle verimli bir performans sergilemiştir.

Bu çalışma, 3D baskı süreçlerinde görüntü işleme ve derin öğrenme tekniklerini birleştirerek yenilikçi bir yaklaşım sunmaktadır. Geliştirilen sistem, gerçek zamanlı izleme ve otomatik hata tespiti için bir temel oluşturmakta olup, operatörlerin baskı sürecini daha verimli yönetmelerine ve olası hataları erken aşamalarda tespit etmelerine olanak tanımaktadır. Ancak, çalışma belirli sınırlamalara da sahiptir. Model, yalnızca üç farklı anomali türünü (İpliklenme, Çatlama, Spagetti) ve hatasız baskıyı kapsayacak şekilde eğitilmiştir ve diğer olası baskı hataları dahil edilmemiştir. Ayrıca, veri seti farklı yazıcı modellerinden ve malzeme türlerinden alınmış verilerle genişletilmemiş, bu nedenle modelin farklı baskı sistemlerine olan adaptasyon yeteneği test edilmemiştir.

Gelecekteki çalışmalar kapsamında, modelin farklı yazıcı türleri, malzeme çeşitliliği ve daha geniş anomali türlerini içerecek şekilde geliştirilmesi önerilmektedir. Bu doğrultuda, farklı anomali türleri için ek veri setleri oluşturularak modelin kapsamı genişletilebilir ve sınıflandırma doğruluğunun artırılması sağlanabilir. Bunun yanı sıra, oluşturulan veri setinin genişletilerek modelin genelleme yeteneğinin artırılması hedeflenebilir. Daha büyük ve çeşitli veri setleriyle eğitilmesi, modelin farklı üretim senaryolarına uyarlanabilirliğini ve güvenilirliğini artıracaktır.

Buna ek olarak, alternatif derin öğrenme mimarileri test edilerek, mevcut modelin başarımı farklı yöntemlerle karşılaştırılabilir ve segmentasyon ile sınıflandırma süreçlerinin daha verimli hale getirilmesi sağlanabilir. Özellikle hafif ve düşük maliyetli modellerin test edilmesi, modelin donanım bağımlılığını azaltarak daha geniş bir kullanıcı kitlesine erişimini mümkün kılabilir. Ayrıca, modelin yazıcı donanımıyla entegre edilerek otomatik hata bildirim sistemleri veya baskıyı durdurma mekanizmalarıyla desteklenmesi, uygulama alanını genişletebilir ve baskı sürecinin daha güvenilir hale gelmesini sağlayabilir.

Son olarak, donanım gereksinimlerini azaltmaya yönelik optimizasyon çalışmaları yürütülerek sistemin daha hızlı çalışması ve enerji tüketiminin azaltılması sağlanabilir. Bu tür optimizasyonlar, modelin mobil platformlara veya gömülü sistemlere entegre edilmesine olanak tanıyabilir. Böylece, geliştirilen modelin yalnızca araştırma laboratuvarlarında değil, endüstriyel üretim süreçlerinde ve ticari uygulamalarda da yaygın olarak kullanılabilir hale gelmesi sağlanabilir.

KAYNAKÇA

- Ahangar, P., Cooke, M. E., Weber, M. H., & Rosenzweig, D. H. (2019). Current biomedical applications of 3D printing and additive manufacturing. *Applied Sciences*, 9(8).
- Akman, A., & Sadhu, A. (2024). Recent Development of 3D-printing technology in construction engineering. *Practice Periodical on Structural Design and Construction*, 29(1).
- ASTM International. (2012). *Standard Terminology for Additive Manufacturing Technologies (ASTM F2792-12a)*. West Conshohocken, PA: ASTM International.
- Attaran, M. (2017). Additive manufacturing: the most promising technology to alter the supply chain and logistics. *Journal of Service Science and Management*, 10(03), 189.
- Bambu Lab. (2024). *Common Print Quality Problems*. <https://wiki.bambulab.com/en/knowledge-sharing/common-print-quality-problem adresinden alindi>
- Buj-Corral, I., Tejo-Otero, A., & Fenollosa-Artés, F. (2022). Evolution of Additive Manufacturing Processes: From the Background to Hybrid Printers. J. Davim içinde, *Mechanical and Industrial Engineering, Materials Forming, Machining and Tribology* (s. 95-110). Springer, Cham.
- Cenedese, E. (2022). 3D Printing Anomaly Detection: Implementation of a ML system using YOLOv5 and EfficientNet-Lite. *Doctoral dissertation*. Politecnico di Torino.
- Dutta, S. D., Hexiu, J., Patel, D. K., Ganguly, K., & Lim, K. T. (2021). 3D-printed bioactive and biodegradable hydrogel scaffolds of alginate/gelatin/cellulose nanocrystals for tissue engineering. *International Journal of Biological Macromolecules*, 167, 644-658.
- Fina, F., Goyanes, A., Gaisford, S., & Basit, A. W. (2017). Selective laser sintering (SLS) 3D printing of medicines. *International Journal of Pharmaceutics*, 529(1-2), 285-293.
- Gibson, I., Rosen, D. W., & Stucker, B. (2015). *Additive Manufacturing Technologies: 3D Printing, Rapid Prototyping, and Direct Digital Manufacturing*. New York: Springer.
- Gonzalez, R. C., & Woods, R. E. (2018). *Digital Image Processing* (4th Edition ed.). Pearson.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press.
- He, H., Zhu, Z., Zhang, Y., Zhang, Z., Famakinwa, T., & Yang, R. (2024). Machine condition monitoring for defect detection in fused deposition modelling process: a review. *The International Journal of Advanced Manufacturing Technology*, 132(7), 3149-3178.
- He, K., Gkioxari, G., Dollár, P., & Girshick, R. (2017). Mask R-CNN. *Proceedings of the IEEE International Conference on Computer Vision (ICCV)*, 2961–2969.

- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep Residual Learning for Image Recognition. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 770–778.
- Iglesias, D., Bunting, P., Esquembri, S., Hollocombe, J., Silburn, S., Vitton-Mea, L., & Valcarcel, D. (2017). Digital twin applications for the JET divertor. *Fusion Engineering and Design*, 125, 71-76.
- Jipa, A., Reiter, L., Flatt, R. J., & Dillenburger, B. (2022). Environmental stress cracking of 3D-printed polymers exposed to concrete. *Additive Manufacturing*, 102603.
- Karna, N. B., Putra, M. A., Rachmawati, S. M., Abisado, M., & Sampedro, G. A. (2023). Toward Accurate Fused Deposition Modeling 3D Printer Fault Detection Using Improved YOLOv8 With Hyperparameter Optimization. *IEEE Access*.
- KBV Research. (2023). *Global 3D Printing Market Size, Share & Industry Trends Analysis Report By Component*. KBV Research. Kasım 2024 tarihinde <https://www.kbvresearch.com/3d-printing-market/> adresinden alındı
- Khan, M. F., Alam, A., Siddiqui, M. A., Siddiqui, S. Z., Ahmed, S., & Shah, M. (2021). Real-time defect detection in 3D printing using machine learning. *Materials Today: Proceedings*, 521–528.
- Klipper Documentation. (2024, Aralık). *Klipper 3D Printer Firmware*. <https://www.klipper3d.org/> adresinden alındı
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). ImageNet Classification with Deep Convolutional Neural Networks. *Advances in Neural Information Processing Systems (NIPS)*, 25.
- Lalegani Dezaki, M., Mohd Ariffin, M. K., & Hatami, S. (2021). An overview of fused deposition modelling (FDM): Research, development and process optimisation. *Rapid Prototyping Journal*, 27(3), 562-582.
- Lalitha, T., Shree, S. V., Sivasankar, M., & Ramachandran, B. (2022). Deep Learning-based Automatic 3D Printer Anomaly Detection during the Printing Process. *Proceedings of the Third International Conference on Smart Electronics and Communication (ICOSEC 2022)*, IEEE.
- Li, F., Yu, Z., Shen, X., & Zhang, H. (2019). Status recognition for fused deposition modeling manufactured parts based on acoustic emission. *E3S Web of Conferences*. 95, s. 01005. EDP Sciences.
- Mainsail Documentation. (2024, Aralık). *Mainsail Web Interface for 3D Printing*. <https://docs.mainsail.xyz/> adresinden alındı
- Marlin Firmware. (2024). *G-code Reference*. <https://marlinfw.org/meta/gcode/> adresinden alındı
- Mehta, P., Mujawar, M. A., Lafrance, S., Bernadin, S., Ewing, D., & Bhansali, S. (2024). Sensor-Based and Computational Methods for Error Detection and Correction in 3D Printing. *ECS Sensors Plus*, 3.
- Moonraker Documentation. (2024, Aralık). *API-Based Printer Monitoring and Control*. <https://moonraker.readthedocs.io/> adresinden alındı

- Ngo, T. D., Kashani, A., Imbalzano, G., Nguyen, K. T., & Hui, D. (2018). Additive manufacturing (3D printing): A review of materials, methods, applications and challenges. *Composites Part B: Engineering*, 172-196.
- Oropallo, W., & Piegler, L. A. (2015). Ten challenges in 3D printing. *Engineering with Computers*, 135-148.
- Petsiuk, A., & Pearce, J. M. (2020). Open-source computer vision-based layer-wise 3D printing analysis. *Additive Manufacturing*.
- Prabhakar, M. M., Saravanan, A. K., Lenin, A. H., Mayandi, K., & Ramalingam, P. S. (2021). A short review on 3D printing methods, process parameters and materials. *Materials Today: Proceedings*, 45, 6108-6114.
- Prasittisopin, L. (2024). How 3D printing technology makes cities smarter: a review, thematic analysis, and perspectives. *Smart Cities*, 7(6), 3458-3488.
- Prianto, E., & Pramono, H. S. (2021). IOT-based 3D printer development for Student Competence Improvement. *Journal of Physics: Conference Series* (s. 012002). IOP Publishing.
- Rachmawati, S. M., Hidayat, R., & Abdullah, S. (2021). Fine-Tuned CNN with Data Augmentation for 3D Printer Fault Detection. *Materials Today Proceedings*, 521-528.
- Ramian, J., Ramian, J., & Dziob, D. (2021). Thermal deformations of thermoplast during 3D printing: warping in the case of ABS. *Materials*, 14(22), 7070.
- Redmon, J., & Farhadi, A. (2016). YOLO9000: Better, Faster, Stronger. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, (s. 7263-7271).
- Ren, S., He, K., Girshick, R., & Sun, J. (2015). Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks. *Advances in Neural Information Processing Systems (NIPS)*.
- Rengier, F., Mehndiratta, A., von Tengg-Kobligk, H., Zechmann, C. M., Unterhinninghofen, R., Kauczor, H. U., & Giesel, F. L. (2010). 3D printing based on imaging data: Review of medical applications. *International Journal of Computer Assisted Radiology and Surgery*, 335-341.
- Rishi Kumar, D., Gligorijevic, V., Ismail, M., Diller, T., & Ramsburg, M. (2024). Development and comparison of machine-learning algorithms for anomaly detection in 3D printing using vibration data. *Progress in Additive Manufacturing*.
- Rogers, H., Baricz, N., & Pawar, K. S. (2016). 3D printing services: classification, supply chain implications and research agenda. *International Journal of Physical Distribution & Logistics Management*, 46(10), 886-907.
- Ronneberger, O., Fischer, P., & Brox, T. (2015). U-Net: Convolutional Networks for Biomedical Image Segmentation. : *Proceedings of the International Conference on Medical Image Computing and Computer-Assisted Intervention (MICCAI)*, 9351, 234-241.
- Sells, E., Bailard, S., Smith, Z., Bowyer, A., & Olliver, V. (2010). RepRap: the replicating rapid prototyper: maximizing customizability by breeding the means of

- production. In *Handbook of Research in Mass Customization and Personalization: (In 2 Volumes)* (pp. 568-580).
- Sendorek, J., Szydło, T., Windak, M., & Brzoza-Woch, R. (2021). Dataset for Anomalies Detection in 3D Printing. *International Conference on Computer Science*, 647–653.
- Simonyan, K., & Zisserman, A. (2015). Very Deep Convolutional Networks for Large-Scale Image Recognition. *arXiv Preprint arXiv:1409.1556*.
- Simplify3D. (2024). *Print Quality Troubleshooting Guide*. <https://www.simplify3d.com/resources/print-quality-troubleshooting> adresinden alındı
- Szeliski, R. (2022). *Computer Vision: Algorithms and Applications* (2nd Edition b.). Springer.
- Tan, M., & Le, Q. V. (2019). EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks. *Proceedings of the 36th International Conference on Machine Learning (ICML), 2019*, 6105-6114.
- Ultralytics. (2024, Aralık). *Introducing instance segmentation in YOLOv5 v7.0*. Ultralytics Blog: <https://www.ultralytics.com/blog/introducing-instance-segmentation-in-yolov5-v7-0> adresinden alındı
- Ultralytics. (2024, Aralık). *Segmentation with pre-trained Ultralytics YOLOv8 models in Python*. Ultralytics Blog: <https://www.ultralytics.com/tr/blog/segmentation-with-pre-trained-ultralytics-yolo8-models-in-python> adresinden alındı
- Ultralytics. (2024, Kasım). *Ultralytics YOLO11*. <https://docs.ultralytics.com/tr/models/yolo11/> adresinden alındı
- Ultralytics. (2024, Aralık). *YOLO: A Brief History*. Ultralytics Documentation: <https://docs.ultralytics.com/tr/#yolo-a-brief-history> adresinden alındı
- Wang, J., Goyanes, A., Gaisford, S., & Basit, A. W. (2016). Stereolithographic (SLA) 3D printing of oral modified-release dosage forms. *International Journal of Pharmaceutics*, 503(1-2), 207-212.
- Wawryniuk, Z., Brancewicz-Steinmetz, E., & Sawicki, J. (2024). Revolutionizing transportation: An overview of 3D printing in aviation, automotive, and space industries. *The International Journal of Advanced Manufacturing Technology*, 134(7), 134.
- Wohlers Associates. (2020). *Wohlers Report 2020: 3D Printing and Additive Manufacturing State of the Industry*. Wohlers Associates.
- Wu, P., Wang, J., & Wang, X. (2016). A critical review of the use of 3-D printing in the construction industry. *Automation in Construction*, 68, 21-31.
- Xu, J., Ding, L., & Love, P. E. (2017). Digital reproduction of historical building ornamental components: From 3D scanning to 3D printing. *Automation in Construction*, 76, 85-96.
- Yahia Ibrahim, N., & Talaat, A. S. (2022). An enhancement technique to diagnose colon and lung cancer by using double CLAHE and deep learning. *International Journal of Advanced Computer Science and Applications*.

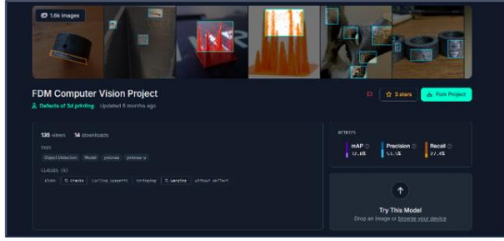
Zhang, X., He, Y., Huang, W., & Wang, S. (2020). Dataset for anomalies detection in 3D printing. *arXiv preprint arXiv:2004.08817*.

Zou, Z., Chen, K., Shi, Z., Guo, Y., & Ye, J. (2023). Object Detection in 20 Years: A Survey. *Proceedings of the IEEE*, 257-276.




EKLER

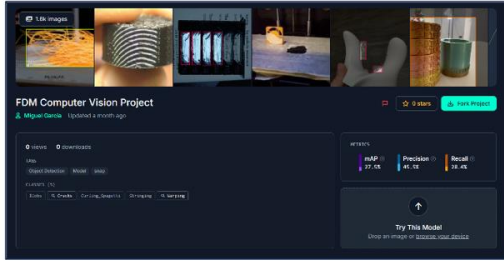
EK-1. Açık kaynak veri setlerinde elde edilen ön değerlendirme sonuçları



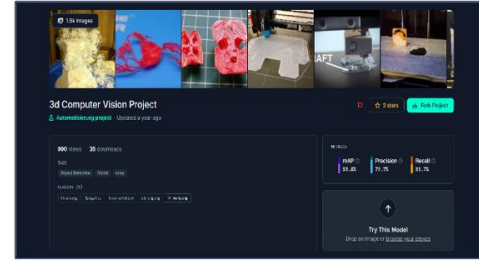
(a) FDM Computer Vision Project



(b) 3d Print Detector Computer Vision Project



(c) FDM Computer Vision Project




(d) 3d Computer Vision Project

Görsel.E.1.1. Roboflow platformundaki önceden oluşturulmuş verisetleri ve modelleri

Predicted	True					
	Cracking	Spagatti	Kein-problem	Stringing	Warping	Background
Cracking	0.58					0.19
Spagatti		0.87	0.01			0.11
Kein-problem		0.01	0.93			0.12
Stringing				0.66		0.47
Warping					0.60	0.11
Background	0.42	0.12	0.07	0.33	0.40	

Şekil.E.1.1. Tek aşamalı hata tespiti ve sınıflandırma modeline ait karmaşıklık matrisi



Şekil.E.1.2. Tek aşamalı hata tespiti ve sınıflandırma modeline ait eğitim metrikleri

Predicted	Fail	0.36		0.78
	No-Fail	0.01	0.72	0.22
	Background	0.63	0.28	
		Fail	No-Fail	Background
		True		

Şekil.E.1.3. İkili sınıflandırma için eğitilen modele ait karmaşıklık matrisi

ÖZGEÇMİŞ

ORCID NO: 0009-0001-4902-1991

Ad Soyad : Utku ATAMAN

Yabancı Dil : İngilizce

Eğitim ve Mesleki Geçmişi:

- 2021-2025, Eskişehir Teknik Üniversitesi, Lisansüstü Eğitim Enstitüsü, Bilgisayar Mühendisliği Anabilim Dalı
- 2018-2021, Vardiya Zabiti/Silah Subayı, Deniz Kuvvetleri Komutanlığı
- 2012-2016, Celal Bayar Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü
- 2007-2011, Gazi Anadolu Lisesi, Ankara

Utku Ataman, 1993 yılında Ankara'da doğmuştur. 2016 yılında Celal Bayar Üniversitesi Mühendislik Fakültesi Bilgisayar Mühendisliği Bölümünden mezun olmuştur. 2021 yılında Eskişehir Teknik Üniversitesi Bilgisayar Mühendisliği Anabilim Dalında tezli yüksek lisans eğitimine başlamış ve çalışmalarını 3D yazıcılarda hata tespiti üzerine yoğunlaştırmıştır. Akademik kariyeri boyunca yazılım geliştirme, gömülü sistemler ve bilgisayarlı görü alanlarında çeşitli projeler gerçekleştirmiştir. İş deneyimleri arasında yazılım geliştirme stajları ve Deniz Kuvvetleri Komutanlığı'ndaki görevleri bulunmaktadır.