FDM TİPİ 3B YAZICILARDA GERÇEK ZAMANLI GÖRÜNTÜ İŞLEME İLE ÜRETİM OPTİMİZASYONU

Semih AKMEŞE

T.C.
BURSA ULUDAĞ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

FDM TİPİ 3B YAZICILARDA GERÇEK ZAMANLI GÖRÜNTÜ İŞLEME İLE ÜRETİM OPTİMİZASYONU

Semih AKMEŞE
0009-0002-6411-5520

Prof. Dr. M. Cemal ÇAKIR
(Danışman)

YÜKSEK LİSANS
MAKİNE MÜHENDİSLİĞİ ANABİLİM DALI

BURSA – 2024
Her Hakkı Saklıdır

ÖZET

Yüksek Lisans

FDM TİPİ 3B YAZICILARDA GERÇEK ZAMANLI GÖRÜNTÜ İŞLEME İLE ÜRETİM OPTİMİZASYONU

Semih AKMEŞE

Bursa Uludağ Üniversitesi
Fen Bilimleri Enstitüsü
Makine Mühendisliği Anabilim Dalı

Danışman: Prof. Dr. M. Cemal ÇAKIR

Bu çalışmada 3B yazıcılarda üretim sırasında oluşan hataları tespit edebilen gerçek zamanlı görüntü işleme yöntemlerine başvurularak, kullanıcının kablosuz haberleşme ile bilgilendirilmesi ve uzaktan kontrol işlemlerini gerçekleştirebileceği bir sistem geliştirilmiştir.

Çalışmada FDM Tipi 3B yazıcılarda kullanılan malzemeler, sıcaklık, hız, dolgu, geri çekme, duvar sayısı, katman yüksekliği parametreleri ve 3B yazıcılarda sıklıkla görülen hatalar olan, ipliklenme, tabladan kalkma, eksik katman, fazla ekstrüzyon, eksik ekstrüzyon gibi konulara değinilmiştir. İlgili hata ve malzeme özelliklerine göre görüntü işleme modeli ve kullanıcıya bildirim verebilen haberleşme sistemi geliştirilmiştir ve hataların tespiti gerçek zamanlı olarak kullanıcıya bildirilmiştir.

Anahtar Kelimeler: Görüntü İşleme, Eklemeli İmalat, Python, Algoritma, Üretim, Optimizasyon, Haberleşme
2024, xvii + 160 sayfa.

ABSTRACT

MSc Thesis

PRODUCTION OPTIMIZATION WITH REAL-TIME IMAGE PROCESSING IN FDM TYPE 3D PRINTERS

Semih AKMEŞE

Bursa Uludağ University
Graduate School of Natural and Applied Sciences
Department of Mechanical Engineering

Supervisor: Prof. Dr. M. Cemal ÇAKIR

In this study, a real-time image processing based detection system can detect errors occuring during 3D printing production, the system can also inform the user via wireless connection also the system allows the remote control to the 3D Printer from anywhere.

User could perform any changes in the parameters such as Temperature, Layer Height, Speed etc. The system will help users to get rid of any material or time loses by warning when the common 3D printing issues which are “Spaghetti”, “Stringing”, “Over Extrusion”, “Under Extrusion”, “Sticking”, “Missing Layer”. By using this real-time image processing system the user will not lose time and also be notified when any error occurs.

Key words: Image Processing, Additive Manufacturing, Python, Algorithm, Manufacturing, Optimization, Communication
2024, xvii+ 160 pages.

ÖNSÖZ ve/veya TEŞEKKÜR

Tez çalışmam ve eğitim hayatım boyunca bilgisi ve tecrübesi ile bana destek olan, mesleki gelişimimde büyük katkıları olan, çalışmalarımda sürekli olarak beni motive eden çok değerli ve saygıdeğer hocam Prof. Dr. M. Cemal ÇAKIR'a sonsuz teşekkürlerimi sunarım.

Yüksek Lisans çalışmalarım sırasında verdiği yoğun destekleri için parçası olduğum Karsan Otomotiv Sanayii ve Tic. A.Ş' ye teşekkürlerimi sunarım.

Son olarak, bugünleri görebilmem adına büyük emekler sarf eden, maddi ve manevi her zaman yanımda olan saygıdeğer aileme teşekkürlerimi sunarım.

Semih AKMEŞE
24/06/2024

İÇİNDEKİLER

Sayfa

ÖZET viii
ABSTRACT ix
ÖNSÖZ ve/veya TEŞEKKÜR x
SİMGELER ve KISALTMALAR DİZİNİ xii
1. GİRİŞ 1
2. KURAMSAL TEMELLER ve KAYNAK ARAŞTIRMASI 4
3. MATERYAL VE YÖNTEM 8
3.1 Eklemeli İmalat Hakkında Genel Bilgiler 8
3.2 Eklemeli İmalat Yöntemleri 9
3.2.1 Malzeme ekstrüzyonu (Material extrusion) 10
3.2.2 Vat foto polimerizasyonu – Işıkla kürleme (Vat photopolimerization) 13
3.2.3 Malzeme – Bağlayıcı püskürtme (Binder jetting) 16
3.2.4 Malzeme jeti (Material jetting) 18
3.2.5 Yönlendirilmiş enerji birikimi (Directed energy deposition – DED) 21
3.2.6 Levha laminasyonu (Sheet lamination) 24
3.2.7 Toz yataklı füzyon (Powder bed fusion) 26
3.2.8 Eklemeli imalat yöntemleri özeti 28
3.3 Eklemeli İmalat ile Geleneksel İmalatın Karşılaştırılması 29
3.4 Eriyik Birikme Modelleme (FDM) Tipi 3B Yazıcılar ile İlgili Bilgiler 31
3.4.1 Eriyik birikme modelleme (FDM) komponentleri 31
3.4.2 Eriyik birikme modellemesi (FDM) tipi 3b yazıcı çeşitleri 37
3.4.3 FDM malzeme tipleri 42
3.4.4 FDM 3b baskı parametreleri 47
3.4.5 FDM 3b yazdırma sorunları 63
3.5 Görüntü İşleme ve Bilgisayarlı Görü Hakkında Genel Bilgiler 79
3.5.1 Görüntü işleme hakkında genel bilgiler 79
3.5.2 Bilgisayarlı görü hakkında genel bilgiler 91
4. BULGULAR 123
5. SONUÇ ve TARTIŞMA 151
KAYNAKLAR 153
INTERNET KAYNAKLARI 1566
ÖZGEÇMİŞ 160

SİMGELER ve KISALTMALAR DİZİNİ

Simgeler	**Açıklama**
mm	Milimetre
MPa	Mega Paskal
mm/s	Milimetre/Saniye
∑jesj	Tüm Sınıf Skorlarının Üstel Değerleri Toplamı
IoU	Kesişim Üzeri Birleşim
px	Piksel
ms	Milisaniye

Kısaltmalar	**Açıklama**
FDM	Eriyik Birikme Modelleme
ABS	Akrilonitril Bütadiyen Stiren
PLA	Polilaktik Asit
TPU	Termoplastik Poliüretan
ASA	Akrilik Stiren akrilonitril
PETG	Polietilen Tereftalat
FFF	Eriyik Filaman Üretimi
CFF	Kompozit Filaman Üretimi
SLA	Sterolitografi
DLP	Dijital Işık İşleme
CDLP	Sürekli Dijital Işık İzleme
NPJ	Nano Parçacık Püskürtme
DOD	İsteğe Bağlı Püskürtme
UV	Ultraviyole
DED	Yönlendirilmiş Enerji Birikimi
CNC	Bilgisayarlı Sayısal Kontrol
LOM	Lamine Nesne İmalatı
SLCOM	Seçici Laminasyonlu Kompozit Nesne İmalatı
PSL	Plastik Levha Laminasyonu
CAM-LEM	Lamine Mühendislik Malzemelerinin Bilgisayar Destekli Üretimi
SDL	Seçici Birikme Laminasyonu
CBAM	Kompozit Esaslı Eklemeli İmalat
UAM	Ultrasonik Eklemeli Üretim
SLS	Seçici Lazer Sinterleme
SLM	Seçici Lazer Eritme
DMLS	Direkt Metal Lazer Sinterleme
MJ	Materyal Püskürtme
MPJ	Nanopartikül Püskürtme
DOD	İstek Üzerine Püskürtme
DLP	Dijital Işık İşleme
CDLP	Aralıksız Dijital Işık İşleme
BJ	Yapıştırıcı ile Katmanlı İmalat
EBAM	Elektron Işın Eklemeli İmalat
EBM	Elektron Işını Eritme
PEI	Polieterimid

RGB	Kırmızı, Yeşil, Mavi Renk Uzayı
HSV	Renk, Doygunluk, Değer Renk Uzayı
SVM	Destek Vektör Makinesi
mAP	Genel Ortalama Keskinliği
AP	Ortalama Hassasiyet
CNN	Evrişimli Sinir Ağı
RCNN	Bölge Tabanlı Evrişimli Sinir Ağı
RFCN	Bölge Tabanlı Tam Evrişimli Ağlar
KNN	K En Yakın Komşu
YOLO	Yalnızca Bir Kez Bakarsın (Algoritma)
SSD	Tek Atış Dedektörü
FPS	Saniye Başına Kare Hızı
PA12	Poliamid 12
SHS	Seçici Isı Sinterleme
STL	Standart Üçlü Dil – Sterolitografi
CAD	Bilgisayar Destekli Tasarım

ŞEKİLLER DİZİNİ

		Sayfa
Şekil 3.1.	Eklemeli imalat yöntemleri (Erinie ve ark. 2024)…….	10
Şekil 3.2.	Malzeme ekstrüzyonu (Ozdemir.2023).....	11
Şekil 3.3.	FDM çalışma mantığı (URL 51)……...	12
Şekil 3.4.	CFF çalışma mantığı (URL 51)…….....	13
Şekil 3.5.	VAT çalışma mantığı (URL 26)……...	14
Şekil 3.6.	VAT yöntemleri (URL 12)……...	15
Şekil 3.7.	SLA ve DLP yöntemlerinin karşılaştırılması (URL 30)…..	15
Şekil 3.8.	Bağlayıcı püskürtme şematik gösterim (URL 1)……..	17
Şekil 3.9.	Bağlayıcı püskürtme çalışma mantığı (URL 51)……..	18
Şekil 3.10.	Malzeme jeti (URL 12)…….....	19
Şekil 3.11.	PolyJet (URL 12)……..	20
Şekil 3.12.	DED (Ji W., Zhou R., et al. 2023'ten değiştirilerek alınmıştır)……..	22
Şekil 3.13.	Levha laminasyonu (URL 12)……..	25
Şekil 3.14.	Seçiçi lazer eritme (Sidambe A. 2014'ten değiştirilerek alınmıştır)…….	27
Şekil 3.15.	Geleneksel imalat ve eklemeli imalat yöntemlerinin karşılaştırılması (Zheng W., et al. 2018'den değiştirilerek alınmıştır)…….	30
Şekil 3.16.	FDM 3B yazıcı komponentleri…….....	32
Şekil 3.17.	Bowden tüp ve doğrudan tahrikli ekstrüder (URL 18)……	33
Şekil 3.18.	Isıtıcı uç ve komponentleri (URL 25)…….	34
Şekil 3.19.	Baskı tablası…….....	35
Şekil 3.20.	Kartezyen FDM 3B yazıcı (Paoletti I. 2018'den değiştirilerek alınmıştır)…….	38
Şekil 3.21.	Çekirdek XY FDM 3B yazıcı (Paoletti I. 2018'den değiştirilerek alınmıştır)…….	39
Şekil 3.22.	Delta FDM 3B yazıcı (Paoletti I. 2018'den değiştirilerek alınmıştır)……..	40
Şekil 3.23.	Konveyör FDM 3B yazıcı…….....	41
Şekil 3.24.	PLA malzeme özellikleri……	43
Şekil 3.25.	ABS malzeme özellikleri……	45
Şekil 3.26.	PETG malzeme özellikleri…….	46
Şekil 3.27.	TPU malzeme özellikleri……	47
Şekil 3.28.	Artan baskı sıcaklıklarının kaliteye etkisi (PLA)……	49
Şekil 3.29.	Farklı sıcaklık değerlerinde malzemenin mekanik dayanım özellikleri Pang, R. (2022).'den değiştirilerek alınmıştır)..	50
Şekil 3.30.	Farklı katman yüksekliklerinin yüzey kalitesine etkisi…..	51
Şekil 3.31.	Katman yüksekliğinin baskı süresine etkisi (Meram A. ve ark. 2020'den değiştirilerek alınmıştır)……..	52
Şekil 3.32.	Dolgu yoğunluğunun baskı süresine etkisi (Birosz M. ve ark 2022'den değiştirilerek alınmıştır)……..	54
Şekil 3.33.	Dolgu desenleri (URL 47)……..	55
Şekil 3.34.	Dolgu deseninin baskı süresine etkisi (Suteja J. 2021'den değiştirilerek alınmıştır)……..	57
Şekil 3.35.	Dolgu deseninin malzeme kullanımına etkisi (Suteja J.	58

	2021'den değiştirilerek alınmıştır)…….	
Şekil 3.36.	Baskı hızının kalite ve baskı süresine etkisi (URL 10)……..	59
Şekil 3.37.	Baskı hızı ile gerilme kuvveti ilişkisi (Kamer M. 2022'den değiştirilerek alınmıştır)……	60
Şekil 3.38.	Akış parametresinin yüzey kalitesine etkisi…….....	61
Şekil 3.39.	Geri çekme ve ipliklenme (URL 43)……	62
Şekil 3.40.	Geri çekmenin ipliklenmeye etkisi (URL 27)……..	63
Şekil 3.41.	Yatağa yapışmama sorunu (URL 2)…….	66
Şekil 3.42.	Levha yapıştırma (URL 7)……	67
Şekil 3.43.	Eksik ekstrüzyon sorunu…….....	68
Şekil 3.44.	Fazla ekstrüzyon sorunu (URL 13)…….....	69
Şekil 3.45.	Üst ve alt katmanda boşluk sorunu (URL 32)…….	71
Şekil 3.46.	İpliklenme sorunu (URL 39)……	73
Şekil 3.47.	Aşırı ısınma sorunu (URL 36)…….	75
Şekil 3.48.	Malzeme çarpılma sorunu (URL 39)……...	76
Şekil 3.49.	Spagetti sorunu……	78
Şekil 3.50.	Görüntü tonları (Ali M. ve ark. 2022'den değiştirilerek alınmıştır)……	79
Şekil 3.51.	İkili görüntü (URL 23)…….....	80
Şekil 3.52.	Gri tonlamalı görüntü (URL 23)…….	80
Şekil 3.53.	RGB görüntü (URL 6)…….....	81
Şekil 3.54.	RGB ve YCrCb renk uzayı (URL 31)……	90
Şekil 3.55.	Bilgisayarlı görünün bir görüntüyü tanımlaması (URL 44)	93
Şekil 3.56.	Görüntü sınıflandırılması adımları (URL 42)……	94
Şekil 3.57.	Görüntü sınıflandırma ve nesne algılama (URL 42)…….	95
Şekil 3.58.	Görüntü sınıflandırılması temel adımları……..	96
Şekil 3.59.	Kenar tespiti (George M. ve ark. 2013)……	98
Şekil 3.60.	Denetimli öğrenme (URL 21)……..	99
Şekil 3.61.	Lojistik regresyon eğrisi (URL 19)……..	100
Şekil 3.62.	K-en yakın komşular (Agarwal A. ve ark. 2021)….....	101
Şekil 3.63.	Destek vektör makinesi (URL 34)……	102
Şekil 3.64.	Karar ağacı……	103
Şekil 3.65.	K ortalama kümeleme algoritması (Celik S. ve ark. 2021)	104
Şekil 3.66.	Çoklu sınıf nesne algılama (URL 9)…….	105
Şekil 3.67.	Karışıklık matrisi (URL 5)……	107
Şekil 3.68.	Nesne algılama modelleri…….....	109
Şekil 3.69.	SSD mimarisi (Yuan T. 2020)……..	114
Şekil 3.70.	YOLO nesne algılama (URL 52)……..	115
Şekil 3.71.	Sınırlayıcı kutu belirlenmesi (URL 52)……	116
Şekil 3.72.	YOLO sürümleri parametre karşılaştırılması (URL 48)…	119
Şekil 3.73.	YOLO sürümleri hız karşılaştırılması (URL 48)……..	120
Şekil 3.74.	YOLO ve diğer modellerin hız karşılaştırılması (URL 16)	121
Şekil 3.75.	YOLO ve diğer modellerin nesne tanıma başarı karşılaştırılması (URL 16)……	122
Şekil 4.1.	Kamera yerleşimi…….	123
Şekil 4.2.	Spagetti hatası…….....	124
Şekil 4.3.	Çarpılma hatası…….	124
Şekil 4.4.	Yatağa yapışmama hatası…….	125

Şekil 4.5.	Spagetti hatası sınıf verisi etiketleme……	125
Şekil 4.6.	Çarpılma hatası sınıf verisi etiketleme……..	126
Şekil 4.7.	Çarpılma hatası sınıf verisi etiketleme……..	126
Şekil 4.8.	Veri arttırımı…….	128
Şekil 4.9.	YOLO v8x nesne tanıma performansı……..	129
Şekil 4.10.	YOLO v8m nesne tanıma performansı…….	130
Şekil 4.11.	YOLO v8n nesne tanıma performansı……..	130
Şekil 4.12.	Model başlangıç parametreleri…….	132
Şekil 4.13.	Eğitim başlangıç sonuçları……	133
Şekil 4.14.	Eğitilen verilerin tanımlama örneği……..	133
Şekil 4.15.	Eğitim/Kutu kayıp ve validasyon/kutu kayıp sonuçları……	134
Şekil 4.16.	Eğitim/Sınıf kayıp ve validasyon/sınıf kayıp sonuçları……	135
Şekil 4.17.	Eğitim/Dağılım kayıp ve validasyon/dağılım kayıp sonuçları	136
Şekil 4.18.	Modelin hassasiyet (Precision) performansı…….	137
Şekil 4.19.	Modelin geri çağırma-duyarlılık (Recall) performansı…….	137
Şekil 4.20.	Modelin F1 metriği performansı……	138
Şekil 4.21.	Modelin P eğrisi metriği performansı……	140
Şekil 4.22.	Modelin R eğrisi metriği performansı……	141
Şekil 4.23.	Modelin PR eğrisi metriği performansı…….....	143
Şekil 4.24.	Modelin mAP50 Metriği Performansı……	144
Şekil 4.25.	Modelin mAP50-95 metriği performansı……	145
Şekil 4.26.	Modelin karışıklık matrisi performansı……...	147
Şekil 4.27.	Bildirim sistemi tarama örneği……	150

ÇİZELGELER DİZİNİ

			Sayfa
Çizelge	3.1.	Metal malzemeler……	23
Çizelge	3.2.	Levha laminasyonu malzeme seçenekleri (Karagöz İ. ve ark. 2021)……...	25
Çizelge	3.3.	Metal eklemeli imalatta kullanılan malzemeler (Karagöz İ. ve ark. 2021)…….	28
Çizelge	3.4.	Eklemeli imalat yöntemleri özet bilgiler (Karagöz İ. ve ark. 2021)……	29
Çizelge	3.5.	Eklemeli imalatın avantaj ve dezavantajları…….....	31
Çizelge	3.6.	Kartezyen 3B FDM yazıcı……..	39
Çizelge	3.7.	Çekirdek XY 3B FDM yazıcı…….	40
Çizelge	3.8.	Delta 3B FDM Yazıcı……	41
Çizelge	3.9.	Konveyör 3B FDM yazıcı…….....	42
Çizelge	3.10.	PLA malzeme avantaj ve dezavantajları…….....	44
Çizelge	3.11.	ABS malzeme avantaj ve dezavantajları…….....	45
Çizelge	3.12.	PETG malzeme avantaj ve dezavantajları……..	46
Çizelge	3.13.	TPU malzeme avantaj ve dezavantajları……	47
Çizelge	3.14.	Farklı malzemelerin sıcaklık değerleri (URL 30)……..	49
Çizelge	3.15.	PLA (210°C ekstrüzyon sıcaklığı – 0,10 mm katman yüksekliği) (Zisopol D. ve ark. 2022'den değiştirilerek alınmıştır)……...	53
Çizelge	3.16.	PLA (210°C ekstrüzyon sıcaklığı – 0,20 mm katman yüksekliği) (Zisopol D. ve ark. 2022'den değiştirilerek alınmıştır)…….....	53
Çizelge	3.17.	Dolgu oranının dayanıma etkisi (Birosz M. ve ark 2022'den değiştirilerek alınmıştır)……	54
Çizelge	3.18.	Dolgu desenlerinin maksimum yükleme / ağırlığa etkisi (Pernet B. ve ark. 2022'den değiştirilerek alınmıştır).....	56
Çizelge	3.19.	RCNN temeline sahip modellerin karşılaştırılması….....	112
Çizelge	3.20.	YOLO v8 modellerinin karşılaştırılması (URL 48).....	120
Çizelge	4.1.	YOLO modelleri performans karşılaştırılması…….....	131

1. GİRİŞ

Görüntü işleme, birçok alanda kendine yer bulan bir analiz ve manipülasyon yöntemi olarak tanımlanabilir. Özellikle Endüstri 4.0 ile görüntü işleme teknolojilerinin öneminin de ciddi oranda arttığı görülmektedir. Bu yöntem ile çeşitli fotoğraf ve videolar üzerinde canlı veya kayıtlı veriler ile istenilen tanıma, takip, sınıflandırma, segmentasyon gibi işlemler gerçekleştirilebilmektedir. Bu operasyonlar sayesinde, görüntü işlemenin elde edilecek ürünün ve/veya prosesin; verimliliği, güvenliği arttırılabilmekte, hata oranları ciddi oranda azaltılabilmektedir.

Görüntü işlemenin kullanılabildiği alanlara örnek verilecek olursa;

- Tıp
- Biyomedikal
- Otomotiv
- Üretim
- Otonom Araçlar
- Sinyal İşleme
- Mekanik
- Yazılım
- Kalite Kontrol
- İnsan – Bilgisayar Arayüzü (Human Computer Interface)
- Bilgisayarlı Görü
- Sensör Kontrol

gibi uygulamaları görmek mümkündür.

Görüntü işlemenin kontrol sistemleri olarak kullanılmasının yaygınlaşması ile farklı alanlarda da kullanılması konusu gündeme gelmiştir. Özellikle Plastik Enjeksiyon üretim teknolojileri ile gündeme gelen görüntü işleme destekli kalite kontrol sistemleri, gelişen diğer üretim sistemleri konusunda da kullanılabileceği fikrini de ortaya atmaktadır.

Endüstri 4.0 gelişimiyle öne çıkan teknolojilerden bir diğeri de Eklemeli İmalat (Katmanlı İmalat) teknolojileridir. Eklemeli İmalat teknolojileri, sıklıkla kullanılan bir katının, katı

bloktan kesilerek elde edilmesinin aksine, yeni katmanlar oluşturarak ürün eldesine olanak sağlar. Bu teknoloji sayesinde üretilebilirlik sınırları büyük ölçüde genişlemiştir. Eklemeli İmalatın, Endüstri 4.0 geçişi ile kullanımı ve dolayısı ile endüstriyel alanda rekabet gücü artmıştır.

Eklemeli imalat teknolojisi sebebiyle aşağıdaki gibi avantajlara sahiptir.

- Kompleks Geometri Eldesi
- Düşük Adetli Üretimde Düşük Maliyet
- Hızlı Prototipleme
- Kalıpsız Üretim
- Düşük Malzeme Kullanımı
- Tek Parça Mesnetli Üretim

Eklemeli imalat teknolojilerinin avantajları olduğu gibi dezavantajları da bulunmaktadır. Bu dezavantajlardan en önemlilerinden biri de üretim doğruluğu ve sürdürülebilirliğidir. Eklemeli imalat yöntemleri, geleneksel metotlara göre daha yeni teknolojiler barındırdığı için özellikle düşük bütçeli cihazlarda, geleneksel metotlar kadar hassas ve doğru üretimler yapamamaktadır. Bu nedenle üretim sırasında, sürecin izlenmesi ve doğruluğundan emin olması önem arz etmektedir. Yüksek baskı süresi gerektiren üretimlerde, üretimin takip edilmemesi halinde; hatalı üretim söz konusu olabilmekte ve bu nedenle;

- Zaman Kaybı
- Malzeme Kaybı
- Teslimat Gecikmeleri
- Makine Arızaları

Gibi konulara sebebiyet verebilmektedir.

Bu çalışmada, endüstriyel ve bireysel kullanımda en sık kullanılan eklemeli imalat yöntemi olan Eriyik Birikme Modellemesi (Fused Deposition Modelling – FDM) temeli ile çalışan ürünlerin üretim prosesinde bilgisayarlı görü teknolojisi kullanılarak, gerçek zamanlı üretim süreci gözlemlenecek ve hata tespit çalışmaları gerçekleştirilecektir. Üretim sırasında prosesi canlı olarak gözlemleyecek olan otomasyon sistemi geliştirilmiş ve çalışmada görüntü işleme modeli olarak YOLO-V8 kullanılacaktır. Öncelikle

Eklemeli İmalat prosesi detaylıca anlatılmış ve parametreler belirlenmiştir. Sıcaklık, Katman Yüksekliği, Hız, Akış, Geri Çekilme, Katman Yapışması, Destek Yapıları, Dolgu, Dolgu Tipi, Duvar Kalınlığı parametrelerinin tanımı ve etkileri aktarılmıştır. Eklemeli İmalat prosesleri sırasında ortaya çıkan hata tipleri incelenmiş ve sebepleri açıklanmıştır. Eklemeli imalat prosesleri sırasında hata tespitini gerçekleştirecek olan otomasyon sistemi geliştirilmiş ve oluşturulan yapay zeka modeli ile parçaya özel görüntü işleme modeli kullanılarak hata tespit çalışmaları gerçekleştirilmiştir.

2. KURAMSAL TEMELLER ve KAYNAK ARAŞTIRMASI

Koubaa ve Baklouti yaptıkları çalışmada *(S. Koubaa ve M. Baklouti 2021),* yüksek çözünürlüklü kamera kullanarak gerçek zamanlı bilgisayarlı görü sistemi kurmuştur. Yapılan araştırmada, kusurların tespit edilebilmesi adına sisteme sürekli olarak görüntü beslenmekte ve gerçek zamanlı veri işleme kullanılarak hata oranları 5% oranına kadar düşürülebilmiştir. Sistem, STL dosyalarından alınan üç boyutlu veriler ile görüntü arasındaki farklılıkları tespit etmeye çalışmakta ve kullanıcıya bildirim vermektedir.

Agarval ve ekip arkadaşları yaptıkları çalışmada *(Agarval A. et al. 2021),* makine öğrenimi tabanlı sınıflandırma modeli eğiterek doğruluk oranlarını arttırmayı hedeflemişlerdir. Destek vektör makinelerini yöntem olarak seçen ekip, çalışmalarına karar ağaçları ve rastgele ormanlar tekniklerini de dahil etmiştir. Test ettikleri veri setleri üzerinde 92% başarı oranına erişmişlerdir. Çalışma, özellikle siber güvenlik tehditlerinin tespitinde makine öğrenmesi modellerinin etkinliğini ortaya koymuşlardır.

Zubayer ve arkadaşları çalışmalarında *(Zubayer, M.H., et al. 2024),* sürekli karbon fiber takviyeli polimerlerin üretimi için akıllı denetim ve optimizasyon yöntemleri geliştirmişlerdir. Derin öğrenme ve bilgisayarlı görü teknikleri kullanarak 90% üzerinde doğruluk oranına ulaşmışlardır.

Petrović ve arkadaşları yaptıkları çalışmada *(Petrović, I., et al. (2020),* katkı imalatındaki kusurların tespiti için bilgisayarlı görü sistemlerinin kullanımını incelemişlerdir. Yüksek çözünürlüklü kameralar ve görüntü işleme algoritmaları kullanılarak 90%'a varan doğruluk oranı ile kusurların tespiti sağlanmıştır. Bu sistemler kullanılarak, üretim süreçlerinde kalite kontrol süreçlerinin kolaylaştırıldığı gösterilmiştir.

Lee ve Chung yaptıkları çalışmada *(D. Lee ve M. Chung 2019)*, metal katmanlı imalat için özel olarak geliştirilmiş evrişimsel algoritmalar ve derin öğrenme algoritmalarını sistemlerine entegre ederek, bir izleme sistemi tasarlamışlardır. Bu sistem, sürecin farklı aşamaları sırasında veriler toplamakta ve üretim sürecini alınan verileri analiz ederek dinamik biçimde optimize etmektedir. Araştırma içerisinde, algoritmaların geliştirme

süreçleri ve uygulamalarına detaylı biçimde yer verilmiş ve çalışmaların sonucunda 90% oranında kusurların tespit edilebildiği vurgulanmıştır.

Khan ve ekibi yaptıkları çalışmada *(M. Farhan Khan ve ekibi 2021)*, 3B baskılardaki kusurların tespit edilebilmesi adına derin öğrenme tabanlı bir görüntü işleme modeli geliştirmişlerdir. Model, baskı süreci sırasında elde edilen görüntüleri, evrişimli sinir ağları (CNN – Convolutional Neural Network) kullanarak, geometrik doğruluk ve dolgu desenlerindeki görsel sapmaları analiz etmektedir. Yapılan araştırma, eğitilen görüntü işleme modelinin 94% başarı oranında hata tespiti yapabildiğini göstermekte ve baskı parametrelerinin optimize edilebilmesi adına kullanıcıya öneri vermektedir.

Pham ve Chang çalışmalarında *(Pham, D.L., Chang, T.W. 2023),* YOLO algoritması kullanarak gerçek zamanlı paketleme kusur tespit sistemi geliştirmişlerdir. Sistem, nesne tespiti ve kusur analizi için geliştirilmiş olup, 92% doğruluk oranına ulaşarak paketleme süreçlerindeki kusurların tespitini sağlamıştır. Çalışma, endüstriyel kalite kontrol sistemlerinin önemini vurgulamıştır.

Garfo ve ekibi yaptıkları çalışmada *(Selorm Garfi ve ekibi 2020)*, beton yapılar ve 3B baskı teknolojileri ile elde edilen ürünlerde yüzey kusurlarının tespit edilebilmesi adına MobileNet – SSD modeli kullanmışlardır. Model 20.000'den fazla eğitim verisi kullanılarak eğitilmiş ve 97% oranında kusur tespiti sağlayabilmişlerdir. Araştırma içerisinde modelin detaylarına ve veri setinin özelliklerine de yer verilmiştir.

Roberts ve Turner çalışmalarında *(N. Roberts ve G. Turner 2017)*, endüstriyel 3B eklemeli imalat sistemlerine entegre edilmiş bir bilgisayarlı görü sistemi tasarlanmıştır. Geliştirilen sistem sayesinde, üretim sırasında oluşan hataların tespit edilmesi amaçlanmaktadır. Araştırmanın kapsamı içerisinde, kalibrasyon süreçleri, sensörler ve görüntü işleme algoritmalarına dair detay bilgilere yer verilmiştir. Sonuçlar, sistemin mikron seviyesinde doğruluklarla tespit yapabildiğini ve üretim hata oranının 1% oranı altına indirilebildiğini göstermektedir.

Wang ve arkadaşları yaptıkları çalışmada *(Wang G., et al. 2023),* tel ve ark katkı imalatı için derin öğrenme tabanlı çevrimiçi metal yüzey kusur tespit yöntemi geliştirmişlerdir. Derin sinir ağları kullanılarak, yüzey kusurları 89% oranında doığruluk ile tespit edilmiştir.

Li ve ekibi yaptıkları çalışmada *(Chen Li ve ekibi 2018)*, lazer tabanlı katmanlı imalat süreçlerinde yerinde izleme için derin öğrenme tekniklerine başvurmuşlardır. Araştırma kapsamında, CNN ve RNN derin öğrenme modellerini kullanılmış ve 95% doğrulukla hata tespiti sağlanmıştır. Çalışma içerisinde, modelin eğitim süreci ve sonuçlara dair detay bilgilere yer verilmiştir.

Zhang ve Wang çalışmalarında *(T. Zhang ve L.Wang 2020)*, gerçek zamanlı hata tespiti için derin öğrenme tabanlı bir model kullanmışlardır. Bu modelin öncelikli amacı yüzey kusurlarını tespit etmek olup, sistemde CNN algoritmasını kullanarak üretim sürecinde ortaya çıkan tüm sorunları tespit etmekte ve sınıflandırmaktadır. Araştırma içerisinde, model eğitimi için kullanılan veri setinin hazırlanması, model optimizasyonu ve hiper parametre ayarlarına yer verilmiş ve 98% oranında doğruluk oranına ulaşılmıştır.

Zubayer, Xiong, Wang ve Imdadul çalışmalarında *(MH Zubayer, Y Xiong, Y Wang, HM Imdadul 2024)*, sürekli karbon fiber takviyeli polimerlerin eklemeli imalat yöntemi ile üretiminde kusursuz ürün eldesi için YOLO tabanlı bir nesne algılama sistemini kullanarak gerçek zamanlı hata tespiti yapmaktadır. Sistem, imalat sürecinde oluşabilecek hizalama problemlerini tespit etmek üzerine kurgulanmış olup, testler sonucunda hataların azaldığı ve kusurların tespit edilebildiği gözlemlenmiştir.

Wang ve Cheung yaptıkları araştırmada *(R. Wang ve CF Cheung 2022)*, CenterNet tabanlı bir algoritma kullanarak eklemeli imalat süreçlerinde oluşan hataları tespit etmeye çalışmıştır. Bu algoritma ile özellikle serbest form yüzeylerdeki kusurların tespit edilmesi amaçlanmış olup, çalışma içerisinde algoritmanın çeşitli eklemeli imalat yöntemleri ve malzemeleri üzerinde test edilmiştir. Algoritmanın hata tespitinde 93% doğruluk elde ettiği ve tespit süresinin önemli ölçüde azaltılabildiği gözlemlenmiştir.

Zhang, Chen, Granland ve Yang çalışmalarında *(S. Zhang, Z. Chen, K. Granland, Y.Tang 2022)*, YOLO algoritmasını kullanarak katmanlı imalat sonrası ürünlerde kusur tespiti için geliştirilmiş bir tarama stratejisini benimsemişlerdir. Araştırmacılar, ürünler üzerinde oluşacak mikro yapıda hataların belirlenebilmesi adına, yüksek çözünürlüklü kameralar aracılığı ile elde edilen veriler analiz ederek, üretim sonrası kalite kontrol süreçlerini optimize etmişlerdir. Bu çalışma ile, karmaşık geometrilere sahip ürünler incelenmiş ve 96% başarı oranı ile hata tespiti gerçekleştirmişlerdir.

3. MATERYAL VE YÖNTEM

3.1 Eklemeli İmalat Hakkında Genel Bilgiler

Eklemeli İmalat, geleneksel üretim yöntemlerinin kullanmış olduğu katı bloktan malzemenin çıkarılmasına dayanan üretim yöntemlerinin aksine; malzemelerin 3 boyutlu model verilerinden nesneler üretmek adına genellikle üst üste katmanlar şeklinde birleştirilmesi sürecini esas almaktadır.

Bu süreç genellikle tasarlanmış olan 3B modelin dilimleyici adı verilen bir program yardımı ile gcode dosya uzantısına sahip bir formata dönüştürülmesi ile eklemeli imalat üretim cihazında gönderilmektedir. Cihaz gcode içerisinde verilen mekanik konum ve eyleyici talimatlarını izleyerek üretimi gerçekleştirmektedir.

Eklemeli imalat ile;

- Daha hafif
- Daha dayanıklı
- Daha kompleks
- Az Atık
- Kişiselleştirilmiş Üretim

Ürün eldesi mümkün olmaktadır.

Eklemeli İmalat günümüzde birçok sektörde aktif olarak kullanılmaktadır.

- Hızlı Prototipleme Çözümleri
- Havacılık ve Uzay
- Otomotiv
- İnşaat ve Mimari
- Tıp
- Diş
- Mücevherat
- Biyomedikal

Bu sektörlere örnek olarak gösterilebilir.

Eklemeli İmalat teknolojileri, Endüstri 4.0 geçişi ile endüstriyel ve gündelik hayatta büyük bir yer edinmeye başlamıştır. 2021 yılı içerisinde yapılan 3D Hubs araştırması verilerine göre;

- Dünya çapında eklemeli imalat yöntemleri kullanan firma sayısı bir önceki yıla göre 34% oranında artış göstermiştir.
- Bu artışın büyük bir kısmı biyoteknoloji, taşımacılık ve otomotiv sektörlerinde gerçekleşmiştir.
- General Electrics (GE), Eklemeli İmalat prosesleri için 3 Trilyon dolar değerinde bir yatırım gerçekleştirmiş, jet motorları ve medikal sektöründeki ürünlerini bu teknoloji ile üreteceğini açıklamıştır.
- Boeing, eklemeli imalat ile üretilmiş parçaları Dreamliner 787 uçağında kullanarak, bir hava aracında eklemeli imalat teknolojileri kullanan ilk firma ve Dreamliner 787 de bu ürünleri kullanan ilk uçak olma unvanını kazanmıştır.

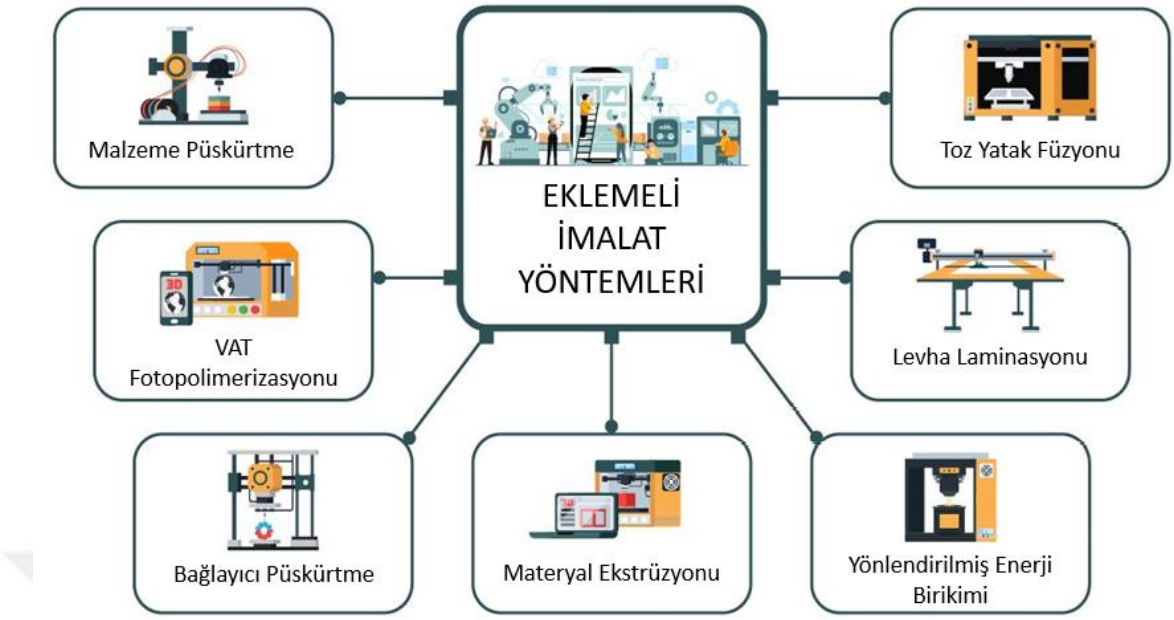
Yapılan araştırmalar ışığında, eklemeli imalat sektörünün 2026 yılı itibari ile 41 Milyar $ Pazar değerine sahip olacağı tahmin edilmektedir.

3.2 Eklemeli İmalat Yöntemleri

Eklemeli İmalat, Endüstriyel ve bireysel üretimde devrim niteliğinde değişiklik getiren yenilikçi çözümlere sahiptir. Bu yöntemler temelde katmanlı üretim esaslarına dayanmakta ancak farklı amaç ve gereksinimleri bünyesinde barındırır. Bu yöntemler;

- Kullanılan Malzeme
- Üretim Hızı
- Ürün Kalitesi
- Ürünün Kullanım Amacı
- Maliyet

Gibi parametrelere bağlı olarak değişkenlik gösterebilmektedir.

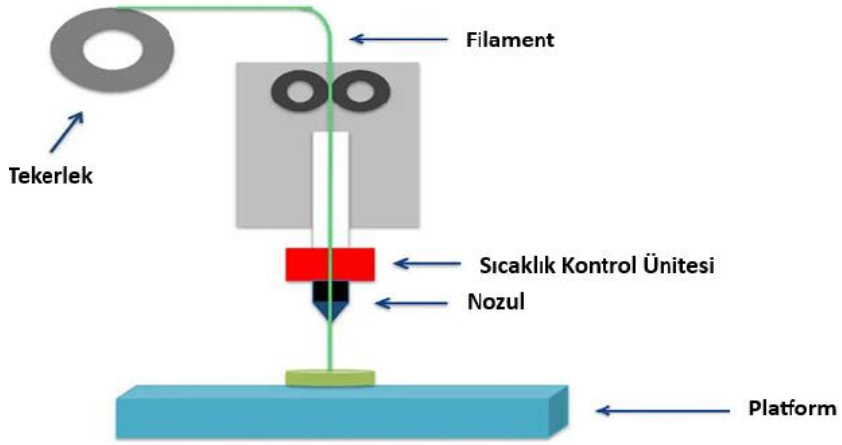


Şekil 3. 1 Eklemeli imalat yöntemleri (Erinie ve ark. 2024)

Eklemeli İmalat, Şekil 3.1'de görüldüğü üzere 7 (yedi) ana başlık altında incelenebilir. Bu bölümde, yaygın eklemeli yöntemleri genel hatları ile açıklanacak olup, sonraki bölümlerde, projenin temelini oluşturan FDM (Fused Deposition Modelling) daha detaylı olarak irdelenecektir.

3.2.1 Malzeme ekstrüzyonu (Material extrusion)

Malzeme Ekstrüzyonu, 3 boyutlu parçaları katman katman üretebilmek adına sürekli bir kompozit veya termoplastik malzeme (genellikle filament) kullanan bir katmanlı imalat tekniğidir. Termoplastik malzeme, sıcak uç (hotend) denilen bir yapı aracılığıyla ısıtılır ve erimesi sağlanır. Eriyik malzeme yapı tablasına aktarılarak, ekstrüzyon yolu ile üretim sağlanır.



Şekil 3. 2 Malzeme ekstrüzyonu (Ozdemir. 2023)

Malzeme Ekstrüzyonu, diğer katmanlı imalat yöntemlerine göre genellikle ucuz olmakla beraber, hobi ve ev kullanıcıları tarafından da sıklıkla kullanılan bir yöntemdir. Endüstriyel alanda da hızlı prototipleme çözümleri için sıklıkla kullanılır. Malzeme Ekstrüzyonunun, diğer eklemeli imalat yöntemlerine göre avantajları aşağıdaki gibi sıralanmıştır.

- Düşük Kurulum ve İşletme Maliyetleri
- Yüksek Termoplastik Malzeme Yelpazesi
- Kullanıcı Dostu
- Düşük Bakım Maliyetleri
- ± 0,1 mm Üretim Hassasiyeti
- İnce ve Küçük Parçalar için Hızlı Baskı Süresi
- Düşük Sıcaklık Prosesi
- Düşük Güç Tüketimi

Malzeme Ekstrüzyonu yönteminin, diğer eklemeli imalat yöntemlerine göre dezavantajları ise;

- ABS, TPU, ASA gibi termoplastik malzemeler sıcaklık ve basınç etkisi ile insan sağlığına zararlı, zehirli gazlar açığa çıkarabilmektedir.
- Üretilen parçalarda ardıl işlem yapılmadığı takdirde, katman izleri görünebilmekte ve kozmetik açıdan dezavantaj oluşturabilmektedir.
- Bazı ürünlerin eldesi için destek materyal gereksinimi oluşabilmektedir.

- Ürünler, mekanik strese karşı yüksek dayanıma sahip değildirler.

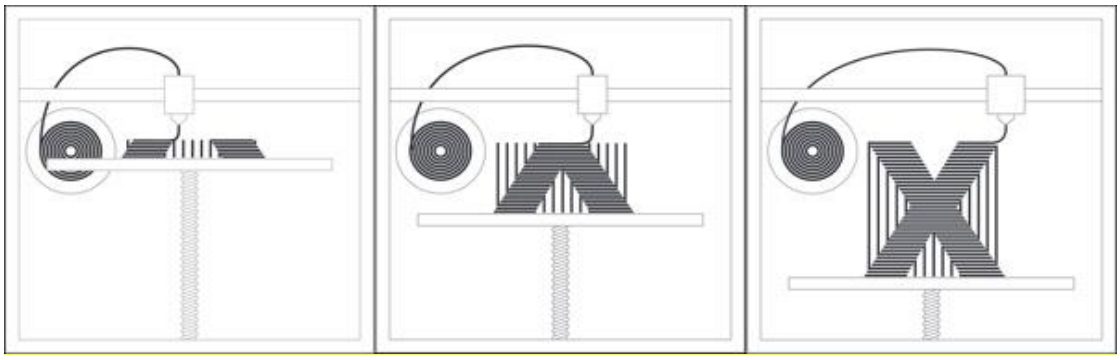
Şeklinde sıralanabilir.

Malzeme Ekstrüzyonu, kompleks ürün eldesi, uygulama kolaylığı ve malzeme çeşitliliği sayesinde, ticari ve hobi sektörlerinde yaygınlıkla kullanılmaktadır.
Malzeme ekstrüzyon teknolojisinin örnekleri arasında;

- Eriyik Filaman Üretimi (FFF – Fused Filament Fabrication)
- Eriyik Biriktime Modelleme (FDM – Fused Deposition Modelling)
- Kompozit Filaman Üretimi (CFF – Continious Filament / Fiber Fabrication)

Gibi yöntemler kullanılabilmektedir.

Bu yöntemler temel olarak, malzemenin ısıtılması ve nozul aracılığıyla istenen çap değerlerinde katmanlı üretimin sağlanmasını esas alır. Nozul her katman biriktirildiğinde, yukarı ve aşağı hareket eden tabla boyunca hareket edebilmektedir.
Sıklıkla kullanılan iki yöntem olan FFF ve FDM arasında teknik açıdan bir fark bulunmamaktadır. FDM terimi Stratasys tarafından 1989 yılında üretilmiş olduğu 3B yazıcı ile türe verilen bir isim olarak bilinmektedir.

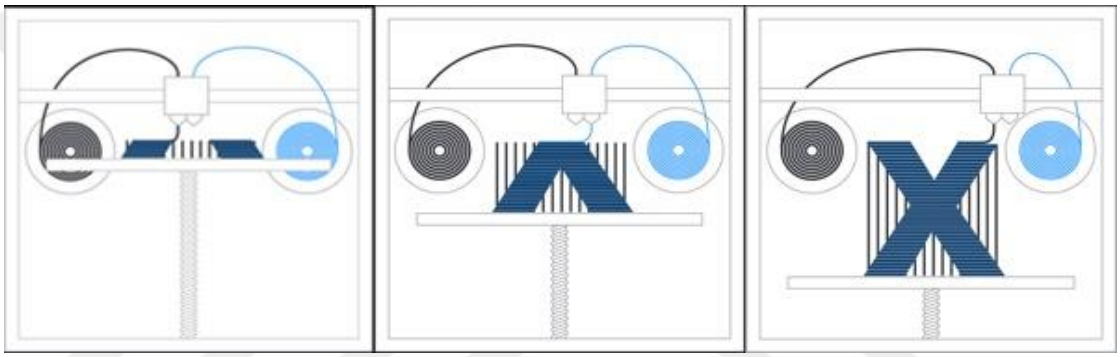


Şekil 3. 3 FDM çalışma mantığı (URL 51)

FFF ise, bu teknolojinin genel bir adıdır ve 2009 yılında Stratasys şirketinin patent haklarının dolması ile RepRap topluluğu üyeleri türün, telif haklarını ihlal edilmeden kullanılmasını sağlamak adına FFF (Fused Filament Fabrication) – Eriyik Filament İmalatı ismini belirlemişlerdir. Bu sayede ilgili üretim metodunun birçok kullanıcı ve marka tarafından kullanılabilmesi sağlanmıştır.

Üretim yönteminin telif hakkı olmadan kullanılabilmesi ile; üretim maliyetleri yaklaşık 90% oranında düşerken, bu yöntem birçok hobi kullanıcısı tarafından da benimsenmeye başlanmıştır.

Sürekli Filament Üretimi (CFF – Continious Filament/Fiber Fabrication) yöntemi ise, standart bir FDM sürecine eklenen bir işlem olarak tanımlanabilir ve bu işlemin gerçekleştirilebilmesi için ek bir ekstrüzyon kafasına ihtiyaç duyulur. Bu işlem sayesinde, standart baskı kafası dış kabuk ve iç matrisi oluştururken; ek kafa, ürüne sürekli bir kompozit fiber ipliği yerleştirerek ek mukavemet sağlanabilir. Bu sayede metal dayanımına benzer dayanımlara ulaşmak mümkün kılınmaktadır.

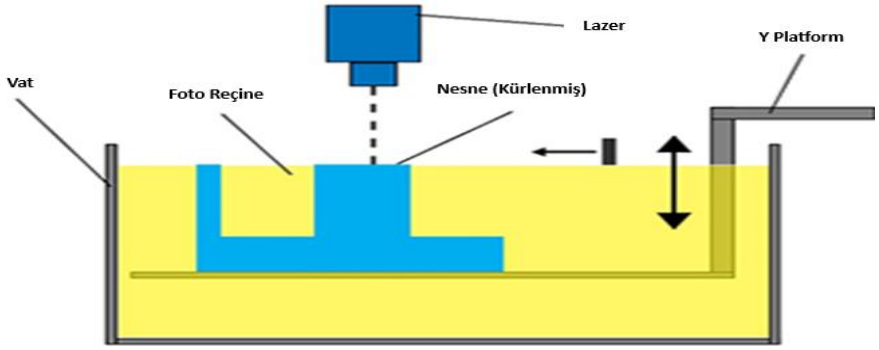


Şekil 3. 4 CFF çalışma mantığı (URL 51)

3.2.2 Vat foto polimerizasyonu – Işıkla kürleme (Vat photopolimerization)

Foto polimerizasyon prosesinde kullanılan reçine ve foto polimerler tekne adı verilen bir platform içerisinde; belirli dalga boylarında UV ışık yardımı ile kürlenmekte ve her bir katmanın kürlenmesi sonrasında baskı platformu aşağıya doğru hareket ederek, üretim tamamlanmaktadır. Kürlenme işlemi sonrasında sertleşmiş ürün eldesi mümkün kılınabilmektedir.

Ürün eldesi için, sıvı materyal kullanıldığı için toz bazlı materyallerin aksine, herhangi fiziksel destek unsuru yoktur. Bu nedenle FDM yönteminde olduğu gibi üretilecek geometriye bağlı olarak harici destek yapılarına ihtiyaç duyulabilmektedir.



Şekil 3. 5 VAT çalışma mantığı (URL 26)

Foto polimerizasyon tekniğinde, nesne genellikle reçine içinde kalan fazla sıvının uzaklaştırılması adına UV ışığı altında son bir sertleştirme işlemi için yıkama gerçekleştirilir.

VAT Foto polimerizasyon tekniği özellikle, kozmetik açıdan kusursuz ve yüksek çözünürlükte olması istenen ürünlerin eldesinde, hızlı prototipleme, takı üretimi ve dental uygulamalarda yaygın şekilde kullanılmaktadır.

Foto polimerizasyon yönteminin, diğer eklemeli imalat yöntemlerine göre avantajları aşağıdaki gibidir.

- Yüksek Doğruluk ve Çözünürlükte Ürün Eldesi
- Kaliteli Yüzey Tamamlama
- Nispeten Hızlı Üretim ve Prototipleme

Foto polimerizasyon yönteminin, diğer eklemeli imalat yöntemlerine göre dezavantajları ise;

- Yüksek Maliyet
- Uzun Ardıl İşlem (Ek Kürleme) Süreci
- Malzemelerin Kullanım Alanlarının Sınırlı Olması
- Düşük Yapısal Dayanım
- Baskı Sonrası UV Işık Hassasiyetli Ürünler

Şeklinde sıralanabilir.

Foto polimerizasyon tekniği, yüksek çözünürlükte ve nispeten hızlı üretimi sayesinde hızlı prototipleme çözümü olarak yaygın biçimde kullanılmaktadır.

Malzeme ekstrüzyon teknolojisinin örnekleri arasında;

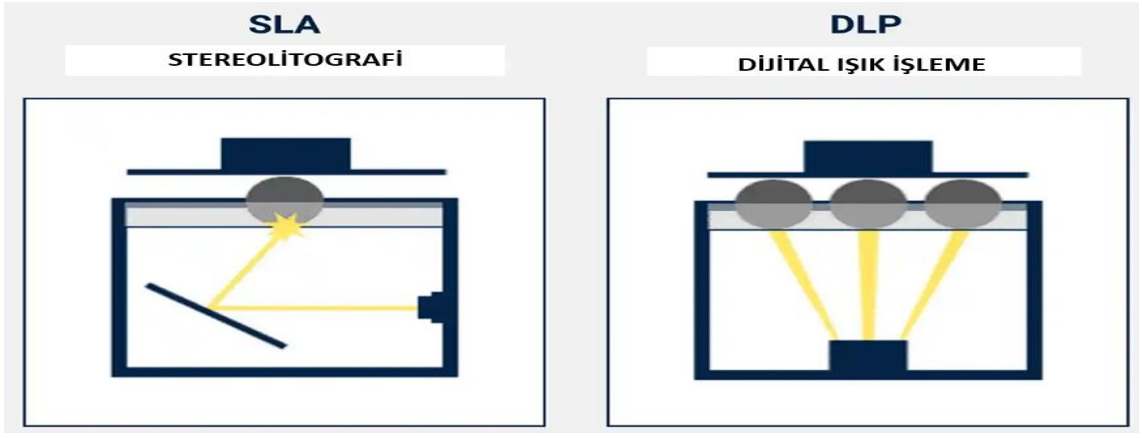
- Sterolitografi (SLA- Stereolithography)
- Dijital Işık İşleme (DLP – Digital Light Processing)
- Sürekli Dijital Işık İşleme (CDLP – Continious Digital Light Processing)

Gibi yöntemler kullanılabilmektedir.



Şekil 3. 6 VAT yöntemleri (URL 12)

Bu yöntemlerden biri olan Sterolitografi (SLA) yönteminde şeffaf sıvı bir foto polimer reçine içeren bir platforma daldırılır. Platform içerisinde yer alan lazer (tek nokta) tabanda bulunun tasarımın alanını kürleyerek sertleştirir. Platform ilgili katmanın tamamlanması ile bir kademe yukarı hareket eder ve benzer lazer ile kürleme işlemi devam eder. Bu döngünün devamı ile ürünün eldesi sağlanır. Ürünün eldesi sonrasında, mekanik dayanımın arttırılabilmesi adına, UV radyasyonu kullanılarak ek bir kürleme işlemi gerçekleştirilir.



Şekil 3. 7 SLA ve DLP yöntemlerinin karşılaştırılması (URL 30)

Doğrudan Işık İşleme yönteminde ise, SLA yöntemine çok benzer bir süreç gerçekleştirilir. Bu iki yöntem arasındaki temel fark ise; DLP yönteminde her katmanın resmini görüntülemek için ışık projektör ekranlarının kullanılıyor olmasıdır. Projektör kullanımı ile görsel pikseller ile ifade edilir ve piksellerin birleşimi ile Voksel ismi verilen 3 boyutlu tuğla benzeri yapıları içeren katmanlar oluşturulur. Bazı geometrilerde DLP teknolojisi kullanılarak SLA teknolojisine oranla daha hızlı ürün eldesi mümkün olabilmektedir.

Sürekli Doğrudan Işık İşleme (CDLP) yöntemi temel anlamda, DLP ile çok benzer olarak görülmektedir. İki yöntem arasındaki temel fark ise baskı plakasının Z yönündeki sabit hareketi olarak ifade edilebilir. Bu sayede yazıcı her katman oluşumu sonrası bileşenleri baskı plakasından çıkarmak zorunda kalmamakta ve baskı sürelerinin daha kısa olmasına olanak tanımaktadır.

3.2.3 Malzeme – Bağlayıcı püskürtme (Binder jetting)

Bağlayıcı püskürtme; toz malzeme ile üretimi esas alan ve 3 boyutlu ürün eldesi için bağlayıcı bir sıvının kullanıldığı eklemeli imalat yöntemi olarak tanımlanmaktadır. Günümüz eklemeli imalat teknolojileri düşünüldüğünde; Malzeme Püskürtme yöntemi çok farklı bir kurguya sahiptir. Diğer yöntemlerin aksine; bu yöntemde malzemeyi eritmek için herhangi ısı kaynağı kullanılmaz. Bu işlem sırasında iki tip malzeme kullanımı mevcuttur. Bunlar;

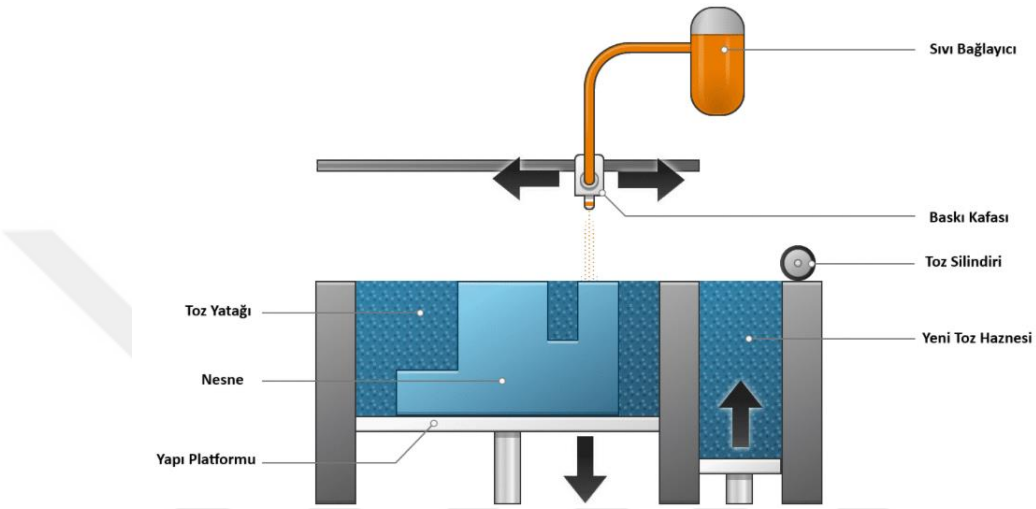
- Toz formda malzeme
- Bağlayıcı malzeme

Bağlayıcı malzeme, genellikle sıvı formda olup, yapı malzemesi ise toz formunda olmaktadır. Bir yazıcı kafası X ve Y eksenlerinde gerçekleştirdiği hareket sırasında, yapı malzemesi ile bağlayıcı malzemenin katmanlarını birleştirir. İlgili yöntem, malzeme özellikleri dolayısı ile yapısal parçalar için her zaman uygun olmamaktadır. Diğer toz bazlı üretim yöntemlerine benzer olarak, bu yöntemde herhangi fiziksel destek yapısına ihtiyaç duyulmamaktadır. Üretilen ürün toz malzeme ile dolu olan havuzdan çıkarılır ve ardıl işlemleri gerçekleştirilerek, final halini almaktadır.

Bağlayıcı püskürtme metodu ile renkli baskı alınabilmektedir.

- Metal
- Polimer
- Seramik

Malzemeler ile üretim mümkündür.



Şekil 3. 8 Bağlayıcı püskürtme şematik gösterim (URL 1)

Bağlayıcı ve Toz malzemenin farklı oranlarda kullanımı ile, elde edilecek ürünün çeşitli mekanik özelliklerin sağlanması mümkündür. Bu nedenle, iç yapının kalitesinin belirlenmesi gereken durumlarda bu yöntemin kullanımı tercih edilebilmektedir.
Bağlayıcının sertleşebilmesi için gerekli işlem sonrasında, ürün bir süre makine içerisinde soğuması için bekletilmektedir. Bu sayede ürün, daha iyi mekanik ve yapısal özelliklere sahip olabilmektedir.

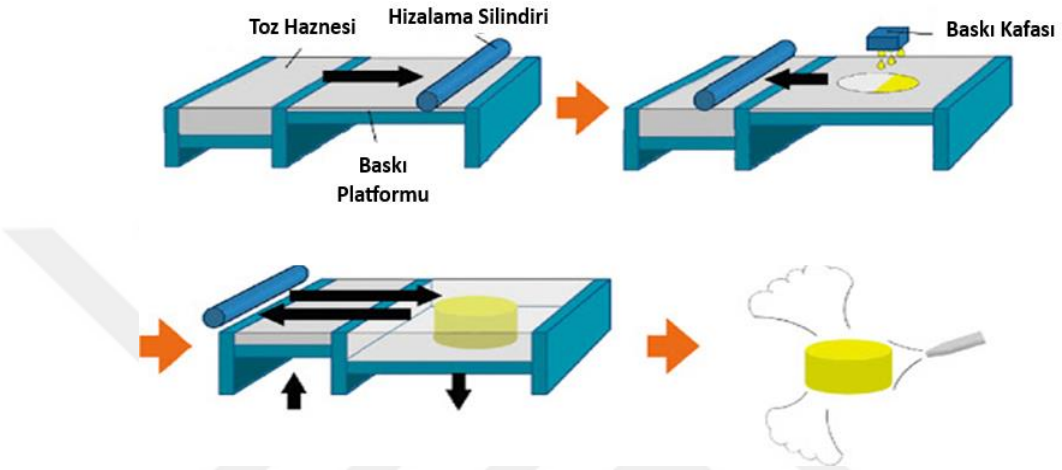
Materyal Püskürtme yönteminin, diğer eklemeli imalat yöntemlerine göre avantajları aşağıdaki gibidir.

- Farklı Renklerde Ürün Eldesi
- Geniş Malzeme Yelpazesi: Metal, Polimer, Seramik
- Hızlı Üretim Süreci
- İki Malzeme Yönetimi ile Farklı Kombinasyonlarda Farklı Mekanik Özellik Eldesi

Dezavantajları ise;

- Bağlayıcı Malzeme Kullanımı Dolayısıyla Yapısal Açıdan Uygun Olmayabilen Ürün Eldesi
- Ardıl İşlemlerin Ek Süre Gereksinimi

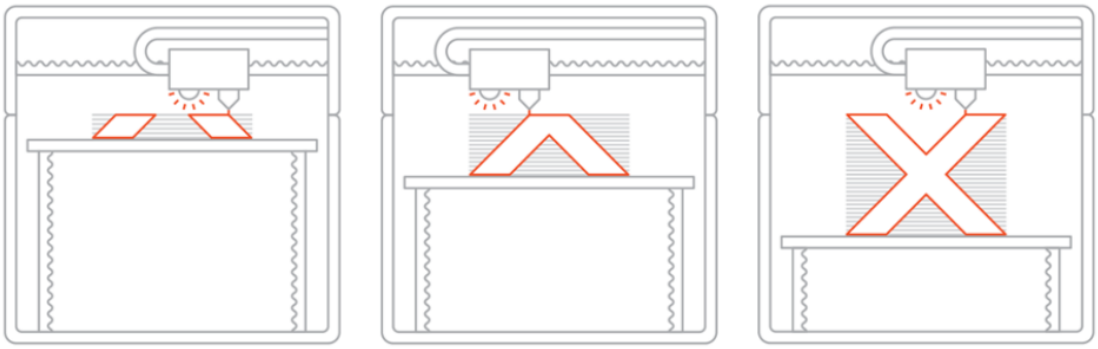
Olarak sıralanabilmektedir.



Şekil 3. 9 Bağlayıcı püskürtme çalışma mantığı (URL 51)

3.2.4 Malzeme jeti (Material jetting)

Malzeme Jeti, nesneleri mürekkep püskürtme yöntemiyle çalışan iki boyutlu yazıcılara benzerliği ile tanınmaktadır. Malzeme, sürekli veya isteğe bağlı bırakma yaklaşımı ile baskı platformuna püskürtülür. Püskürtülen malzeme, baskı tablasında katılaşır ve bu işlem her bir katmanda devam eder. Katılanan malzeme, sterolitografi yöntemine benzer şekilde üretim sonrasında UV ışık kullanılarak kürlenmekte ve dayanımı artırılmaktadır.



Şekil 3. 10 Malzeme jeti (URL 12)

Bu yöntemde, malzeme damla damla bırakılacağından, malzeme çeşitliliği sınırlı olup;

- Polimer
- Mumlar

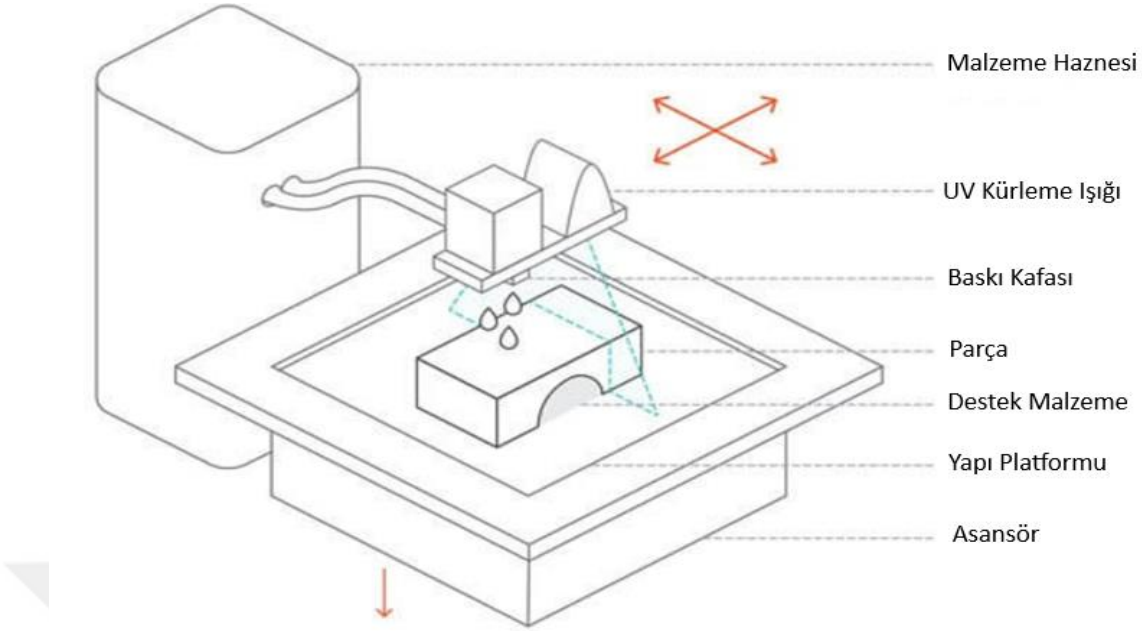
yapıları gereği en yaygın kullanılan malzemeler olarak bilinmektedir.

Malzeme jetleme tekniği, birçok alanda farklı amaçlarla kullanılabilmektedir. Bu nedenle malzeme püskürtme tekniğini temel alan, malzemenin kürlenmesi ve nasıl biriktirildiği konusunda farklılık gösteren teknolojiler geliştirilmiştir.

Bu teknolojiler;

- PolyJet
- Nano Parçacık Püskürtme (NPJ)
- İsteğe Bağlı Püskürtme (DOD)

PolyJet yöntemi, Stratasys şirketi tarafından geliştirilen ve mürekkep ile kağıda baskı alan standart yazıcılara benzerliği ile bilinmektedir. Püskürtülen damla formundaki ultra ince foto polimer malzeme, baskı tablasına püskürtülür. Her bir katman, püskürtme işlemi sonrası ultraviyole (UV) ışık ile kürlenerek katı parça eldesi sağlanır. Karmaşık geometrilerde üretilen jel benzeri destek malzemesi; elle veya su jeti ile rahatlıkla parçadan ayrılabilir.



Şekil 3. 11 PolyJet (URL 12)

PolyJet teknolojisi ile çalışan cihazlarda;

- Baskı kafası, bir adet yapı bölmesi, malzeme kabı ve UV kürleme ışığı yer alır.
- Kabın içinde bulunan sıvı formdaki reçine, ısıtılır.
- Baskı kafasından püskürtülen ultra ince foto polimer damlacıklar püskürtülür.
- UV ışığı kullanılarak, biriken malzeme katılaşarak katmanları oluşturur.

Nano parçacık püskürtme teknolojisi ise XJet şirketi tarafından geliştirilen ve malzemenin yapı tablasına dağılımında, diğer yöntemlerden farklı bir yol izleyen materyal püskürtme yöntemidir. Yapı malzemesinin katı nano partikülleri bir sıvı içinde tutularak, daha sonra yapı tepsisine püskürtülür. Bu malzemeler, diğer yöntemlerden farklı olarak kapalı kartuşlarda muhafaza edilir.

Yapı sürecinin tamamlanmasının ardından, sinterleme işlemi ile destek malzemesi, elde edilen üründen ayrılabilir. Bu yöntemde, PolyJet yönteminden farklı olarak; binlerce püskürtme ucuna sahip iki adet yazıcı kafası bulunur ve yapı ile destek yapıları eş zamanlı olarak baskı tablasına püskürtülür.

İsteğe Bağlı Püskürtme (DOD – Drop on Demand) yönteminde ise; damlama işlemi sürekli değil, yalnızca gerektiği durumlarda, belirli noktalara küçük damlalar halinde gerçekleştirilir. DOD teknolojisine sahip cihazlarda, her bir yapı için iki adet kafa ve bir

adet destek malzemesi kullanılır. Viskoz sıvıyı üretebilme yetenekleri dolayısıyla, özellikle mücevherat ve hassas döküm ürünlerinde sıklıkla kullanılır.

- DOD yöntemini kullanan cihazlarda bir adet baskı plakası, iki adet baskı kafası, kesici kafa düzeneği ve yapı ile destek malzemeleri için iki adet kartuştan oluşur.
- Balmumu malzeme, yazıcıya toz halinde yüklenirken, ısıtılmış tankın içine giren malzeme sıvı forma geçer.
- Destek malzemesi, otonom olarak serilir ve destek yapı tasarımı gereksinimi bulunmaz.
- Bitmiş parça sıvı banyosu kullanılarak, destek yapılarından ayrıştırılır.
- İşlemler sonrasında temiz ve yüksek doğruluklu, mum model eldesi sağlanır.

Materyal Jetleme yönteminin, diğer eklemeli imalat yöntemlerine göre avantajları aşağıdaki gibi sıralanmıştır.

- 14 mikrona kadar çözünürlükte hassas parça eldesi
- Enjeksiyon kalıp yöntemine yakın kalitede pürüzsüz yüzeyli parça eldesi
- Aynı baskı hacminde çeşitli renk ve malzeme çeşitliliği

Dezavantajları ise;

- Nispeten zayıf mekanik dayanıma sahip parçalar
- Yüksek maliyet
- Genel olarak destek yapı gereksinimi
- Damlama yöntemi kullanımı dolayısıyla, sınırlı malzeme çeşitliliği (polimer ve mum)

Olarak sıralanabilmektedir.

3.2.5 Yönlendirilmiş enerji birikimi (Directed energy deposition – DED)

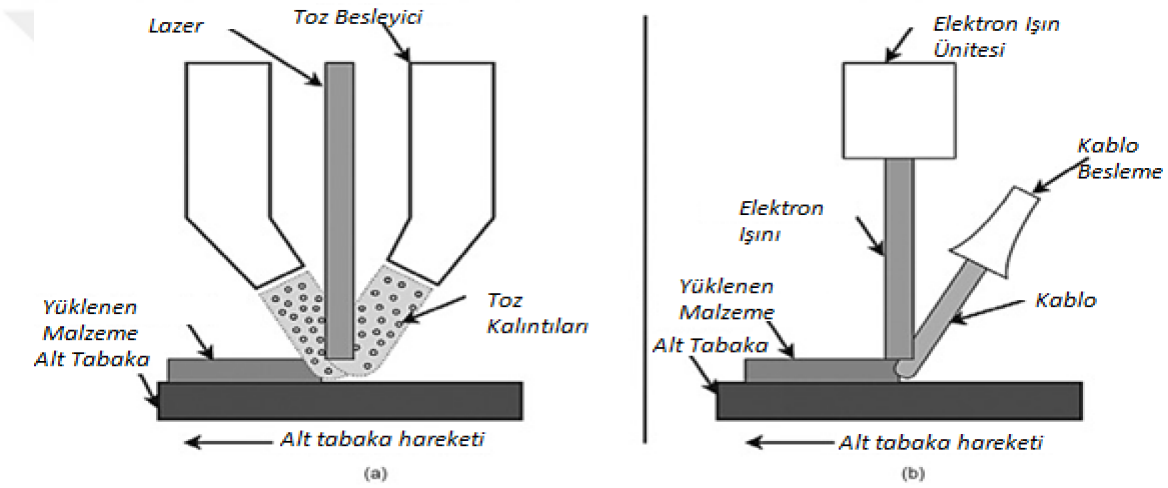
Yönlendirilmiş Enerji Birikimi yöntemi, elektron ışını veya plazma arkı kullanılarak malzemenin eritilmesi ve katmanlı üretim yapılması esasına dayanmaktadır. Enerji kaynağı bir robotik kod kullanılarak yönlendirilmektedir. Günümüzde yönlendirilmiş enerji birikimi yöntemi genellikle hibrit üretim yöntemlerinde ve sıfırdan parça oluşturmak yerine daha çok türbin kanadı onarım gibi mevcut parçaya malzeme ekleyerek tamir işlemlerinde kullanılmaktadır.

Yönlendirilmiş Enerji Birikimi yöntemi, ağırlıklı olarak metal malzeme ile kullanılsa da seramik ve polimer malzemeler ile de kullanılabilmektedir.

Bu yöntem, çeşitli enerji kaynakları kullanarak aşağıda bulunan farklı gruplara ayrılmıştır.

- Lazer tabanlı yönlendirilmiş birikim sistemi
- Elektron ışınına dayalı yönlendirilmiş birikim sistemi
- Plazma veya elektrik ark bazlı yönlendirilmiş birikim sistemi

Yukarıda belirtilen yöntemler, temel işleyiş anlamında birbirine çok benzer olup, yöntemin işleyişi aşağıda açıklanmıştır.



Şekil 3. 12 DED (Ji W., Zhou R., et al. 2023'ten değiştirilerek alınmıştır)

Erimiş bir metal havuzu içerisinde, titanyum gibi reaktif malzemelerin metal ile oksitlenmesini durdurmak için lazer ve ark enerji kaynağı, inert gazla hava geçirmez bir odada gerçekleşir.

Bir yönlendirilmiş enerji birikimi sisteminde;

- Nozul başlığı, üç boyutlu geometrik özelliklerin oluşturulması adına hareket ettirilir.
- Lazer ışını ile yüzeyi eritir ve başlangıç noktasında alt tabaka üzerinde erimiş malzeme havuzu oluşturur.
- Besleyiciler, tozu nozuldan erimiş havuza besler.

- CNC kontrolü ile hareket eden nozul kafası, baskı tablası veya her ikisi de metal parçanın üretilebilmesi adına hareket ettirilir.

Yönlendirilmiş enerji birikimi yönteminde Çizelge 3.1'de de görüldüğü gibi metal malzemelerin kullanımı tercih edilmektedir. Bu metaller, DED yönteminin de baz aldığı kaynak yönteminde rahatlıkla kullanılabilmesi nedeniyle tercih edilir.

Çizelge 3. 1 Metal malzemeler

Titanyum ve Titanyum alaşımları	Niyobyum
İnkonel 718, 625	Paslanmaz Çelikler (300 serisi)
Hastelloy	Alüminyum alaşımı 2319, 4043
Tantal	Çinko Alaşım
Tungsten	Bakır-Nikel alaşımları

Yönlendirilmiş enerji birikimi yönteminin, diğer eklemeli imalat yöntemlerine göre avantajları aşağıdaki gibidir.

- Yüksek yapım hızları
- Yoğun ve güçlü parçalar
- Yüksek üretim doğruluğu
- Çoklu malzeme yelpazesi
- Düşük malzeme tüketimi

Dezavantajları ise;

- Yüksek sermaye maliyeti
- Zayıf yüzey kalitesi
- Destek yapısının kullanılamaması dolayısıyla çıkıntılı parça üretiminin imkansızlığı

Olarak sıralanabilmektedir.

3.2.6 Levha laminasyonu (Sheet lamination)

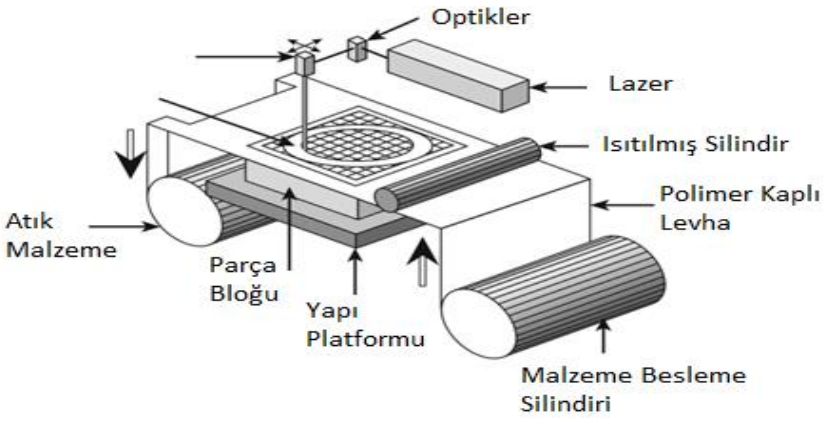
Levha Laminasyonu; kağıt, plastik veya metal folyo gibi malzemeleri istifleyerek ve bunları kaynak, ısı ve basınç kullanarak üç boyutlu nesnelerin oluşturulmasını sağlayan yöntem olarak bilinmektedir.

Bu yöntemde, ince tabakalı malzemeler istiflenerek üç boyutlu bir nesne oluşturulur. Laminasyon yönteminde yapıştırma, ultrasonik kaynak veya lehim ile birleştirme işlemi tamamlanırken; lazer kesim veya cnc işleme ile son ürün eldesi sağlanmaktadır.

Levha laminasyonu yöntemi kullanılan malzemelere göre kategorize edilebildiği gibi, kullanmış olduğu birleştirme yöntemlerine göre de kategorize edilebilmektedir.

- Lamine Nesne İmalatı (LOM)
- Seçici Laminasyonlu Kompozit Nesne İmalatı (SLCOM)
- Plastik Levha Laminasyonu (PSL)
- Lamine Mühendislik Malzemelerinin Bilgisayar Destekli Üretimi (CAM-LEM)
- Seçici Birikme Laminasyonu (SDL)
- Kompozit Esaslı Eklemeli İmalat (CBAM)
- Ultrasonik Eklemeli Üretim (UAM)

Levha laminasyonu yönteminde öncelikle silindirden ince bir malzeme tabakası beslenir ve yapım platformuna konumlandırılır. Levha laminasyonunun türüne bağlı olarak, bir sonraki katman önceki tabakaya yerleşebilir ya da yapıştırılmayabilir. SDL ve UAM yöntemlerinde katmanlar birbirine bağlanır ve ardından geometri kesilir. CAM-LEM yönteminde ise; katmanlar öncelikle kesilir ve ardından katmanlar birbirine bağlanır. Tüm katmanlarda işlemler tamamlanana kadar bu süreç devam eder.



Şekil 3. 13 Levha laminasyonu (URL 12)

Polimer malzemelerde, tabakaları aynı anda eritilmesi temeline dayandığı için, yapıştırıcı kullanılmaksızın, ısı ve basınç kullanılarak işlem gerçekleştirilir. Metal levhalar, ultrasonik kaynak kullanılarak bağlanırken, fiber ve seramik bazlı malzemeler ise katmanları birleştirmek için fırında pişirme benzeri bir termal enerji kullanılarak işlem tamamlanır.

Çizelge 3. 2 Levha laminasyonu malzeme seçenekleri (Karagöz İ. ve ark. 2021)

İşlem	Malzeme Seçenekleri
LOM	Sac Levha
PSL	Polimer
SLCOM	Karbon Fiber, Fiberglas, Aramid Fiber, Çelik, Alüminyum, Titanyum
CAM-LEM	Zirkonya, Zirkonya ile Sertleştirilmiş Alümina (ZTA), Silika
SDL	Standart Sac
CBAM	Termoplastik destekli elyaflı kumaş, PA12, Cam Elyafı
UAM	Tek parçada kaynak yapılabilen herhangi malzeme

Levha Laminasyonu yönteminin, diğer eklemeli imalat yöntemlerine göre avantajları;

- Yüksek yapım hızları
- Hibrit üretime entegre edilebilirliği
- Düşük maliyet

- Çoklu malzeme yelpazesi
- Desteksiz üretim yeteneği
- Tam renkli baskı (LOM-SDL)
- Geri dönüştürülebilir malzeme kullanımı

Dezavantajları ise;

- Katman yüksekliğinin, kullanılan malzeme kalınlığına bağlı olması
- Ardıl işlem gereksinimi
- Uzun kullanımda yapıştırma teknolojisinin yetersiz gelmesi
- Yüksek malzeme israfı

Olarak sıralanabilmektedir.

3.2.7 Toz yataklı füzyon (Powder bed fusion)

Toz yatağı füzyonu, üç boyutlu bir parça oluşturmak için malzemeyi eritmek ve kaynatmak için lazer, termal enerji veya elektron ışını kullanılan bir eklemeli imalat tekniğidir.

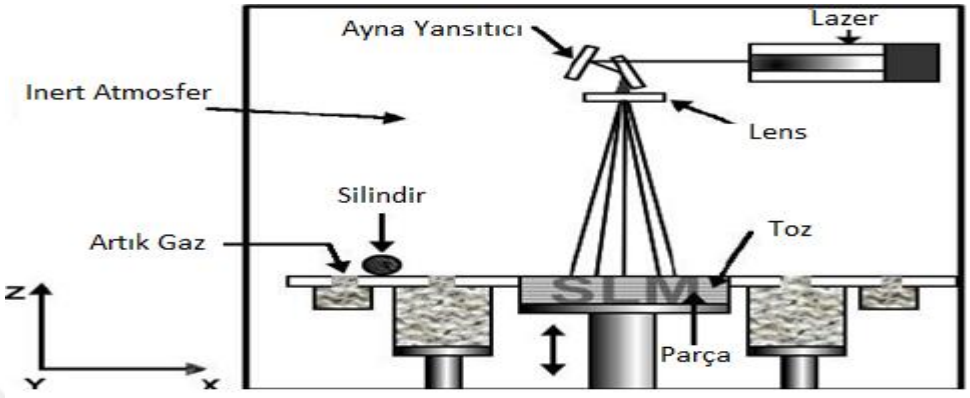
Bu teknik ile metal malzemelerin kullanılabilmesinin yanında plastik parçalarda kullanılarak ürün eldesi sağlanabilmektedir. Kullanılan enerji kaynağına bağlı olarak dört grupta sınıflandırılmaktadır.

- Lazer Kaynaştırma Tekniği
- Elektron Işın Kaynaştırma Tekniği
- Ajan ve Enerji Kaynaştırma Tekniği
- Termal Kaynaştırma Tekniği

Bu yöntemler arasında bulunan “Lazer Kaynaştırma Tekniği”, metallerin baskı alınabildiği ve çeşitli farklılıklar gösteren “Seçici Lazer Sinterleme (SLS)” ve “Seçici Lazer Eritme (SLM)” gibi yöntemler olarak alt kategorilere ayrılmaktadır.

“Elektron Işını Eritme (EBM)” ise metal tozunun yüksek vakum altında elektron ışını kullanarak kaynaştırıldığı bir yöntem olarak bilinmektedir. HP tarafından geliştirilen “Multi Jet Fusion” ise toz yatağının başlangıçta bir hazne içerisinde eşit şekilde ısıtıldığı ve üç boyutlu parçalar oluşturmak üzere genellikle PA12 malzemenin kaynaştırılması ile son ürün eldesinin sağlandığı yöntemdir.

Blueprinter tarafından geliştirilen “Seçici Isı Sinterleme (SHS)” ise termal termal kaynaştırma tekniği ile parça oluşturan ve ürün eldesinde termoplastik toz ile sinterlemenin gerçekleştirildiği bir yöntem olarak bilinmektedir.



Şekil 3. 14 Seçiçi lazer eritme (Sidambe A. 2014’ten değiştirilerek alınmıştır)

Şekil 3.14’te görüldüğü üzere; toz yataklı füzyon yazıcıları, toz malzemeyi hareket ettirebilmek ve yaymak için bir silindirin kullanıldığı, yapı bölmesi ve toz bölmesi adı verilen iki adet bölmeye sahiptir. Bazı üreticiler cihazlarında yapı bölmesinin her iki tarafında veya aynı tarafında toz bölmesine sahip yapıları da tercih edebilmektedir. Toz ve yapı odaları +Z ve -Z eksenlerinde hareket kabiliyetine sahiptir. Yukarıda bahsedilen yöntemler farklı teknolojilere sahip olsalar da benzer temellere sahiptir.

- 3B CAD modeller STL formatında dönüştürülür.
- Yapım alanı optimizasyonu yapılarak üretilecek ürünler sanal ortamda konumlandırılır.
- Dilimleyici programa yerleştirilerek makine diline dönüştürülür.
- Toz haznesi yapı malzemesi ile doldurulur.
- Lazer veya elektron ışın kaynağı ile metal tozu biriken yapı tablasında katmanlı üretime başlanır.
- Her bir katman üretimi sonrasında, yapı platformu z ekseninde kademeli olarak aşağı indirilir, eş zamanlı olarak toz haznesi de aynı miktarda yükseltilir.
- Kaplama silindiri, platform boyunca bir katman kalınlığında kaynaşmış bölümün üstünde ince bir metal tozu katmanı bırakır.

- Bu işlem son ürün eldesine kadar devam eder.
- İşlem sonunda toz hazne içerisinde gömülü olan ürünler, süpürülme yardımı ile fazla tozdan arındırılır.
- Ardından ürüne yapışmış olan ürünler kumlama yöntemi yardımı ile yapışan tozdan da arındırılarak son ürün eldesi sağlanır.

Belirtilen yöntemler, farklı malzeme çeşitleri ile uyumlu çalışabilmekte ve bu uyumluluklar Çizelge 3.3'te gösterilmiştir.

Çizelge 3. 3 Metal eklemeli imalatta kullanılan malzemeler (Karagöz İ. ve ark. 2021)

Yöntem	Kullanılan Malzeme
Seçici Isı Sinterleme (SHS)	Naylon (Tek renkli termoplastik toz)
DMLS, SLS, SLM	Paslanmaz Çelik, Titanyum, Al Alaşım, Kobalt, Krom, Çelik
EBM	Paslanmaz Çelik, Titanyum, Al, Kobalt, Krom, Bakır

Toz yatağı füzyonu yönteminin, diğer eklemeli imalat yöntemlerine göre avantajları;

- Düşük Maliyet
- Desteksiz veya az destekle üretim yeteneği
- Geniş malzeme yelpazesi
- Geri dönüştürülebilir ve kullanılabilir malzeme

Dezavantajları ise;

- Uzun baskı süresi
- Ardıl işlem gereksinimi
- Zayıf yapısal özellikler
- Termal bozulma

Olarak sıralanabilmektedir.

3.2.8 Eklemeli imalat yöntemleri özeti

Eklemeli imalat yöntemleri, ilgili kısımlarda da aktarıldığı üzere, farklı teknoloji ve gereksinimlere bağlı olarak değişkenlik gösterebilmektedir. Çizelge 3.4'te kullanıcıların

kullanabilmesi adına üretim yöntemleri, teknolojisi ve kullanılan malzemeler paylaşılmıştır.

Çizelge 3. 4 Eklemeli imalat yöntemleri özet bilgiler (Karagöz İ. ve ark. 2021)

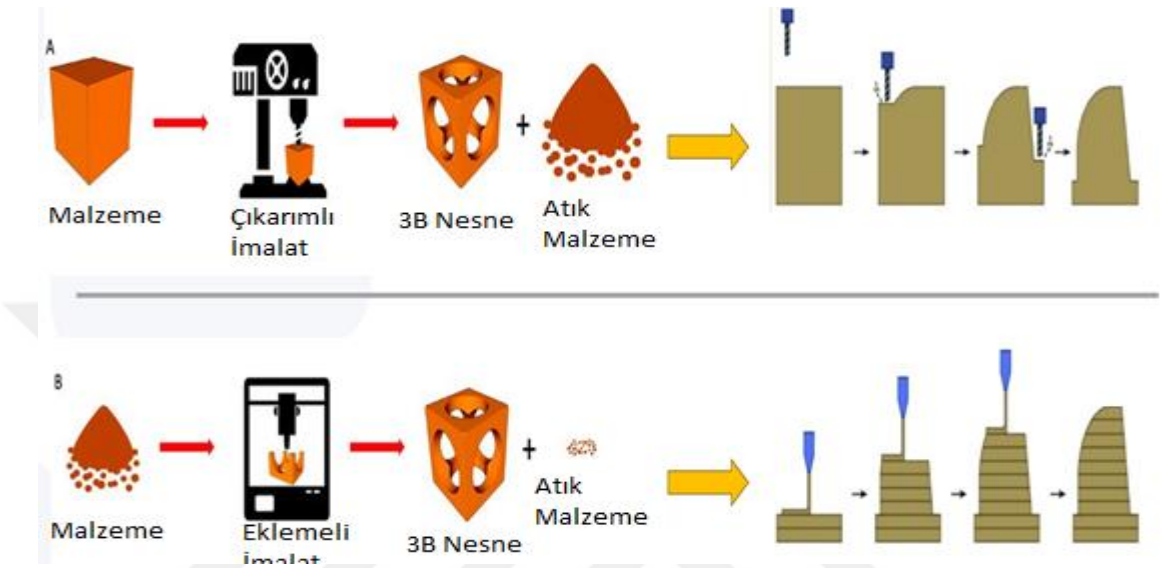
Tip	Proses	Teknoloji	Malzeme
Malzeme Püskürtme	UV ile Sertleştirme Isı ile Sertleştirme Kesici ile Sertleştirme	Materyal Püskürtme (MJ) Nanopartikül Püskürtme (MPJ) İstek Üzerine Bırakma (DOD)	Reçine Metal Vaks
Foto polimerizasyon	Lazer ile Sertleştirme LED ve Oksijenle Sertleştirme	Stereolitografi (SLA) Dijital Işık İşleme (DLP) Aralıksız D. İşleme (CDLP)	Reçine Vaks Seramik
Yapıştırıcılarla K. İmalat	Bağlayıcı (Binder) Madde ile Birleştirme	Yapıştırıcı ile Katmanlı İmalat (BJ)	Alçı Kum Metal
Malzeme Ekstrüzyonu	3B Yazıcı	Eriyik Birikme Modelleme (FDM)	Termoplastik Vaks
Yönlendirilmiş Enerji Birikimi	Lazer ile Eritme Elektron Işınıyla Eritme	Lazer Toz Şekillendirme (LENS) Elektron Işın Eklemeli İmalat (EBAM)	Metal
Toz Yataklı Eritme	Lazer ile Sertleştirme Elektron Işınıyla Eritme	Multijet Ertitme (MJF) Seçici Lazer Sinterleme (SLS) Direkt Metal Lazer Sinterleme (DMLS) Seçici Lazer Eritme (SLM)	Metal

3.3 Eklemeli İmalat ile Geleneksel İmalatın Karşılaştırılması

Eklemeli İmalatın ortaya çıkması ile tasarım özgürlüğü, hızlı prototipleme ve gelişmiş kişiselleştirilmiş üretim yetenekleri gibi konular günümüz üretim teknolojileri içerisinde önemli yer edinmiştir.

Geleneksel imalat; işleme, döküm, kalıplama gibi çok çeşitli malzemeden çıkarma esasına dayanan yöntemleri kullanırken, eklemeli imalat; nesneleri dijital tasarımlardan

katman katman oluşturarak, esneklik, karmaşıklık ve malzeme kullanımı açısından benzersiz avantajlar sunabilmektedir. Geleneksel imalat ile üretimi mümkün olmayan ürünlerin, eklemeli imalat yöntemleri ile üretilebilmesi mümkün olabilmektedir.



Şekil 3. 15 Geleneksel imalat ve eklemeli imalat yöntemlerinin karşılaştırılması (Zheng W., et al. 2018'den değiştirilerek alınmıştır)

Geleneksel imalat ve eklemeli imalat,

- Havacılık
- Otomotiv
- Sağlık

Gibi çeşitli sektörlerde kullanılabilmektedir.

Geleneksel imalat, özellikle hassasiyet ve verimliliğin çok önemli olduğu endüstrilerde tercih edilirken, standartlaşmış bileşenlerin seri üretiminde vazgeçilmez bir yöntem olarak öne çıkmaktadır. Eklemeli imalat ise; hızlı prototipleme, düşük hacimli üretim ve kişiselleştirme konusunda benzer bir üretim yöntemi olarak tanımlanmaktadır.

Ancak malzeme sınırlamaları, yapı boyutu kısıtlamaları ve ardıl işlem gereksinimi ve maliyet gibi konulardan dolayı eklemeli imalatın; henüz geleneksel imalat kadar yaygınlaşamadığı görülmektedir.

Eklemeli imalat ve geleneksel imalatın birbirlerine karşı olan avantaj ve dezavantajları Çizelge 3.5'te gösterilmektedir.

Çizelge 3. 5 Eklemeli imalatın avantaj ve dezavantajları

Eklemeli İmalatın, Geleneksel İmalata göre	
Avantajlar	**Dezavantajlar**
Düşük Malzeme Tüketimi	Yüksek Maliyet
Kalıpsız Üretim Kabiliyeti	Yavaş Üretim
Kompleks Yapı Üretim Kabiliyeti	Ardıl İşlem Gereksinimi
Hızlı Prototipleme	Nispeten Düşük Boyutsal Doğruluk
Tam Hareketli Baskı	Sınırlı Boyutlarda Üretim

3.4 Eriyik Birikme Modelleme (FDM) Tipi 3B Yazıcılar ile İlgili Bilgiler

Eriyik Birikme Modelleme (Fused Deposition Modelling – FDM) bir makaradan çözülen ve filament adı verilen termoplastik malzemenin ısıtılarak, istenen çaplarda nozul ile eriyik halde tablaya ekstrüze edilmesi ve ardından soğutularak sertleştirilmesi esasına dayanan eklemeli imalat yöntemi olarak bilinmektedir.

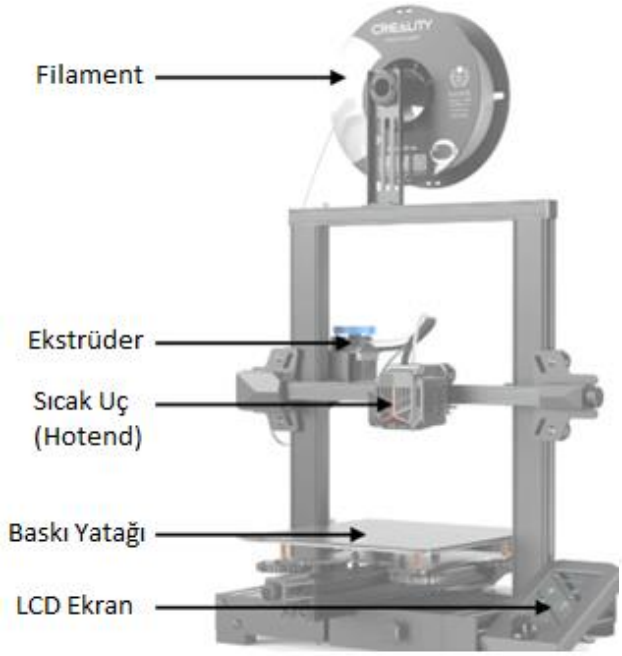
Eriyik Birikme Modelleme yöntemi birçok komponenti kullanmaktadır. Bu komponentler alt başlıklar halinde de incelenecektir.

- Ekstrüder
- Sıcak Uç (Hotend) ve Nozul
- Baskı Yatağı
- Anakart
- Kullanıcı Paneli

Olarak sıralanabilmektedir.

3.4.1 Eriyik birikme modelleme (FDM) komponentleri

Bu bölümde, Eriyik Birikme Modelleme (FDM) tipi eklemeli imalat yönteminde kullanılan komponentlere ait detaylar verilecektir.



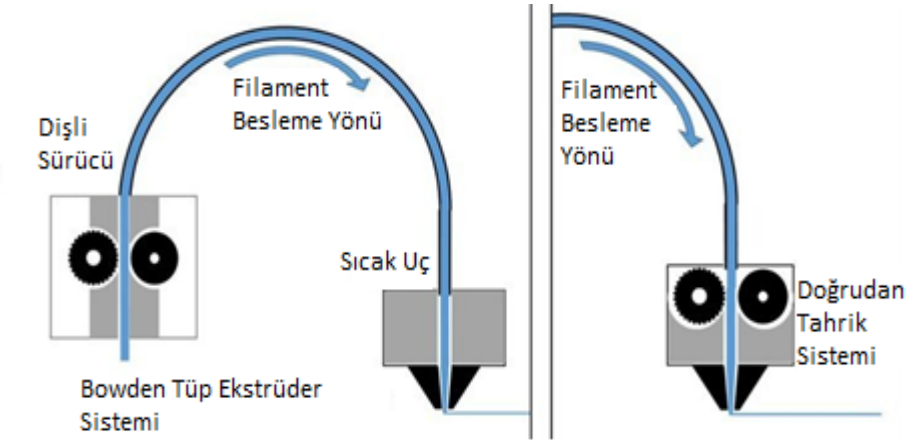
Şekil 3. 16 FDM 3B yazıcı komponentleri

1) Ekstrüder

Ekstrüder, filament adı verilen ve makaraya sarılı halde bulunan termoplastik malzemenin sıcak uç adı verilen ve malzemenin ısıtılarak eritildiği komponente iletilmesinden sorumlu komponent olarak bilinmektedir. Bu iletim bir motorun filamenti hareket ettirmesi ile sağlanmaktadır. Ekstrüderin işlemini başarılı olarak gerçekleştirmesinin kriteri ise, uygun hız ve miktarda malzemenin iletilmesi olarak tanımlanmaktadır. Günümüz teknolojisinde iki tip ekstrüder yapısından bahsetmek mümkündür. Bunlar;

- Bowden Tüp Ekstrüder
- Doğrudan Tahrikli Ekstrüder

Bu ekstrüder tipleri arasındaki en temel fark, doğrudan tahrikli sistemlerde, ekstrüder sürücü, yazıcı kafası üzerinde bulunur ve malzeme direkt olarak yazıcı kafasına iletilirken, bowden tüplü sistemlerde, ekstrüder genellikle z eksen motoru üzerinde bulunur ve filament bir tüp içerisinden yazıcı kafasına iletilmektedir.



Şekil 3. 17 Bowden tüp ve doğrudan tahrikli ekstrüder (URL 18)

Doğrudan tahrikli bir ekstrüder, direkt olarak yazıcı kafası üzerinde yerleştirilmektedir. Yazıcı kafası üzerinde bulunan ekstrüder motoru ile nozul arasındaki mesafe azalabilmekte, malzemenin akışı ve geri çekilmesi üzerinde hassas bir kontrol sağlanabilmektedir. Bu sayede malzemenin sıkışması engellenebilmekte ve TPU gibi esnek malzemelerin rahatlıkla kullanılabilmesi sağlanabilmektedir.

Doğrudan tahrikli ekstrüderler yapıları gereği;

- Yüksek besleme hızı
- Hassas geri çekme yeteneği
- Karmaşık geometrilerde tutarlı ekstrüzyon

Gibi konularda öne çıkmaktadır.

Ancak, ekstrüder motorunun, yazıcı kafasında konumlandırılması sebebiyle;

- Ekstrüder motoru, yazıcı kafasına ek bir ağırlık getirmekte ve bu nedenle baskının stabilizasyonunu olumsuz etkileyebilmekte
- Yüksek sıcaklıklara sahip, ekstrüder motorunun sıcaklığının artmasına sebep olabilmekte ve elektronik komponentlerin ömrünü azaltabilmektedir.

Bowden tüplü ekstrüder kurulumunda ise, ekstrüder motoru, yazıcı kafasından uzakta bulunmakta ve genellikle yazıcı z eksen çerçevesine monte edilmektedir. Malzeme, ekstrüder motoru tarafından esnek bir tüp içerisinde yazıcı kafasına iletilmektedir.

Bowden tüplü ekstrüder sistemleri;

- Yazıcı kafasına uzak konumlandırılan motor sayesinde daha stabil baskı alınabilmesi
- Motorun, yazıcı kafasından uzak konumlandırılması sebebiyle daha serin baskı ortamı sağlanabilmesi

Sayesinde avantajlar sunabilmektedir.

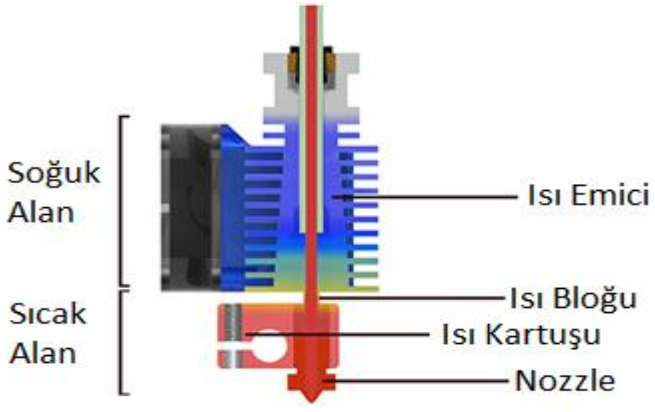
Ancak, bowden tüplü ekstrüder sistemlerinde, motor ile yazıcı kafası arasında bulunan uzun mesafe sebebiyle;

- Esnek ve aşınmaya müsait malzemelerin kullanım zorluğu
- Daha yüksek geri çekme mesafelerinin gereksinimi

Gibi konularda ise olumsuz özelliklere sahiptir.

2) Sıcak uç (Hotend) ve nozul

FDM Tipi 3B Yazıcılarda, sıcak uç, bir nesnenin ardışık katmanlarını oluşturmak için filament malzemenin ısıtılması ve ekstrüzyona tabi tutulmasından sorumlu ekipman olarak tanımlanmaktadır. Sıcak uç, katmanlar arasında tutarlı ekstrüzyon ve yapışma sağlamak için hassas sıcaklık kontrolünün sağlanması ve bu sayede yüksek yüzey kalitesine sahip ürünlerin oluşturulmasından sorumlu komponenttir.



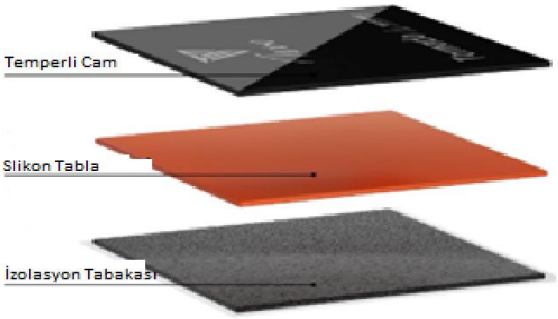
Şekil 3. 18 Isıtıcı uç ve komponentleri (URL 25)

Sıcak uç (Hotend) aşağıdaki bileşenlerden oluşmaktadır.

- Isıtıcı Blok: Isıtıcı blok, termoplastik malzemenin erime sıcaklığına kadar ısıtılmasından sorumlu olan bileşendir. Genellikle kartuş adı verilen bir ısıtma elemanı içermektedir.
- Nozul: Nozul, ısıtıcı bloğun ucuna takılan küçük, hassas bir şekilde tasarlanmış bir bileşendir. Erimiş malzeme, nozul üzerinde bulunan açıklık sayesinde istenen çap değerlerinde baskı tablasına katman katman aktarılabilmektedir.
- Termal Bariyer / Boğaz: Boğaz adı verilen yapı, ısıtılmış kısmı, soğuk alan adı verilen kısımdan ayırmak için kullanılan bir bölümdür. Isının malzeme yolunda çok fazla ilerlemesini önleyerek, ısının yayılması ve malzeme sıkışması risklerini azaltmaktadır.
- Termistör / Termokupl: Sıcak uç, ısıtıcı bloğun sıcaklığını izleyen ve ısıtma elemanını buna göre düzenleyen termistör adı verilen sıcaklık sensörü ile kontrol edilmektedir. Bu geri bildirimler neticesinde, sıcak uç, baskı işlemi istenilen sıcaklıkta tutulabilmektedir.

3) Baskı Tablası

Baskı tablası, 3B yazıcı teknolojilerinde kullanılan, üzerinde üretilecek nesnenin katman katman konumlandırıldığı yüzey olarak tanımlanmaktadır. Baskı tablasının temel görevi ise; baskı alınacak ürünün ısıtmalı bir yüzey kullanarak özellikle ilk katmanının yüzeye yapışması ve sağlam bir temel oluşturulması olarak ifade edilebilmektedir.



Şekil 3. 19 Baskı tablası

Baskı tablası da diğer komponentlerde de görüleceği üzere, farklı amaçlar için farklı özelliklere sahiptir. Baskı için kullanılacak malzemenin karakteristiği, istenen yüzey kalitesi ve kullanım kolaylığına bağlı olarak farklı türde komponentlerin kullanılması mümkündür.

- Tabla Malzemesi: Cam, alüminyum, çelik ve PEI (Polieterimid) gibi özel yapı yüzeyleri tercih edilebilir. Bu malzemelerin kullanımı ile farklı seviyede yüzey kalitesi ve yapışma kabiliyetlerini gözlemlemek mümkündür.
- Kalibrasyon Mekanizması: Baskının ilk katmanının yüzeye eşit bir biçimde yapışması önem arz etmekte ve bu nedenle tabla kalibrasyonu gerçekleştirilmelidir. Bu kapsamda, manuel hizalamaya izin veren sistemler ve genellikle sensör yardımıyla hizalama yapabilen otomatik tabla kalibrasyon sistemleri kullanılmaktadır.
- Isıtmalı Yatak: Eğilme ve zayıf yapışma, tabladan kalkma gibi sorunları azaltabilmek adına ısıtmalı yatak yoğunlukla tercih edilmektedir. Özellikle ABS gibi hava akımından etkilenen malzemeler kullanılarak yapılacak üretimlerde, ısıtılan yatak sayesinde, tabladan kalkma problemleri ciddi oranda azaltılabilmektedir.
- Baskı Taban Alanı: 3B yazıcılar, baskı alanları ile de farklılıklar göstermektedir. Yüksek alana sahip tablalar sayesinde yazdırılabilir alan ve dolayısıyla ürün boyutlarının artması sağlanabilmektedir.

4) Anakart

Anakart, 3B yazıcıların çeşitli bileşenlerini koordine ve kontrol eden merkezi bir yapı olarak tanımlanabilmektedir. Anakart, step motorların hareketi, sıcaklıkların düzenlenmesi ve kullanıcı etkileşimini sağlamak için kullanılmaktadır. Anakartın temel bileşenleri ve işlevleri aşağıdaki gibidir.

- Mikrodenetleyici: Özel olarak tasarlanmış bir çipe benzer yapıdadırlar. Ürün yazılımının doğru biçimde çalışmasından, giriş komutlarının işlenmesine ve hatta gerçek zamanlı kontrolü sağlayan bileşendir.
- Adım (step) Motor Sürücüleri: Mikrodenetleyiciden gelen dijital sinyaller ile adım motorların hareketini sağlayarak elektriksel akıma dönüştüren; motorun

hızı, yönü ve konumunu düzenleyerek, yazıcı kafasının ve yapı platformunun uygun şekilde hareket etmesini sağlayan bileşendir.

- Genişletme Yuvaları ve Konektörler: Malzeme akış sensörü, otomatik seviyelendirme sensörü veya ikili ekstrüder gibi ek özellikleri ve çevre birimleri kullanabilmek adına bazı anakartlar ek konektörler içerebilmektedirler.

5) Kullanıcı Paneli

Kullanıcı paneli, kullanıcıların 3B yazıcı ile etkileşimde bulunabildiği, işlevlerini kontrol edebildiği, yazdırma süreçlerini canlı olarak takip edebildiği ve çeşitli ayarları gerçekleştirebildiği bir araç olarak tanımlanabilmektedir.
Kullanıcı paneli üzerinden kullanıcının takip edebildiği ve müdahale edebildiği parametreler aşağıdaki gibidir.

- Sıcak Uç (Hotend) Sıcaklığı
- Baskı Tablası Sıcaklığı
- Motor Step Hızları
- Fan Hızları
- Z Adım Ayarları
- Baskı Süresi ve Kalan Süre
- Güncel Sıcaklık Değerleri
- Baskı İsmi

3.4.2 Eriyik birikme modellemesi (FDM) tipi 3b yazıcı çeşitleri

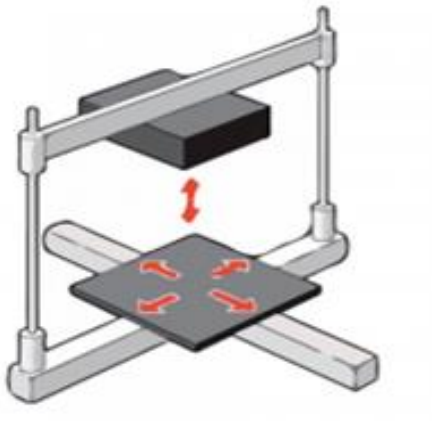
Eklemeli İmalat, özellikle Eriyik Birikme Modelleme (FDM) teknolojisini baz alan cihazların gelişmesi ile toplum tarafından daha ulaşılabilir bir üretim yöntemi haline gelmiştir. Eriyik Birikme Modelleme, kullanıcıların; maliyet, verimlilik ve erişilebilirlik anlamında ihtiyaçlarını giderebilmekte ve bu nedenle de sıklıkla tercih edilmektedir. Önceki bölümlerde farklı üretim yöntemlerinin farklı etkileri olduğu gösterilmiştir. Bu bölümde ise, temeli Eriyik Birikme Modelleme olan farklı cihaz türleri;

- Maliyet
- Baskı kalitesi
- Yazdırma hızı
- Yazıcı yeteneği
- Pratiklik

Gibi konularda karşılaştırmalı inceleme yapılacaktır.

1) Kartezyen 3B Yazıcı

Kartezyen tip 3B yazıcılar, dik eksenler boyunca doğrusal hareketleri ile tanınan ve katmanlı imalat teknolojileri arasında en çok tercih edilen kategori olarak bilinmektedir. Kartezyen koordinat sistemi kullanmasından dolayı bu isimle anılmaktadırlar. Hassasiyet ve tekrarlanabilirlik özellikleri ve düşük maliyetleri ile hobi ve endüstriyel alanda sıklıkla tercih edilmektedir.



Şekil 3. 20 Kartezyen FDM 3B yazıcı (Paoletti I. 2018'den değiştirilerek alınmıştır)

Kartezyen 3B yazıcılar, yazıcının kafa ve tablasının hareket ettiği 3 dik eksende çalışmaktadır. X ve Y ekseni tablanın yatay hareketini temsil ederken, Z ekseninde genellikle yazıcı kafasının hareketi gözlenmektedir.
Kartezyen 3B yazıcıların diğer FDM tip yazıcılara göre avantajlı ve dezavantajlı olduğu durumlar Çizelge 3.6'da belirtilmiştir.

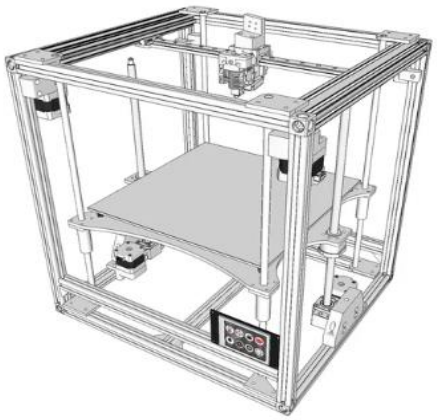
Çizelge 3. 6 Kartezyen 3B FDM yazıcı

Avantajları	Dezavantajları
Düşük Maliyet	Nispeten Yavaş Baskı Hızı
Acemi Kullanıcılar için İdeal	Sınırlı Baskı Boyutları
Güncelleme ve Hata Çözümleri Basit	Sınırlı Baskı Malzeme Çeşitliliği
Topluluk Desteği Yüksek	

Kartezyen 3B yazıcılar, çeşitli endüstrilerde, prototipleme, ürün geliştirme ve eklemeli imalat başlangıç eğitimlerinde sıklıkla kullanılmakta olan FDM eklemeli imalat yöntemlerinden biridir.

2) Çekirdek (Core) XY 3B Yazıcı

Çekirdek XY 3B yazıcılar, yenilikçi kinematik yapıları ve geliştirilmiş hareket kabiliyetleri sayesinde katmanlı imalat teknolojisine yeni bir bakış açısı kazandırmıştır. Kartezyen tip sistemlere bir alternatif olarak geliştirilen "Çekirdek XY" 3B yazıcılar, kullanıcılara yüksek hız seçeneği yanında daha büyük baskı alanı opsiyonlarını da beraberinde getirmiştir.



Şekil 3. 21 Çekirdek XY FDM 3B yazıcı (Paoletti I. 2018'den değiştirilerek alınmıştır)

Kartezyen 3B yazıcılardan farklı olarak; X ve Y eksenlerinde senkronize olarak hareket sağlayan kayış kasnak mekanizmasını esas almaktadır. Bu sayede hareket motorlardan ayrılarak, mekanik titreşimler azaltılmış ve baskı kalitesinin arttırılması amaçlanmıştır.

Çekirdek XY 3B yazıcıların diğer FDM tip yazıcılara göre avantajlı ve dezavantajlı olduğu durumlar Çizelge 3.7'de belirtilmiştir.

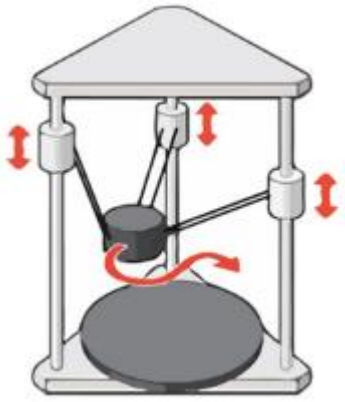
Çizelge 3. 7 Çekirdek XY 3B FDM yazıcı

Avantajları	**Dezavantajları**
Geniş Baskı Alanı	Nispeten Pahalı
Düşük Titreşim	Güçlü Anakart Gereksinimi
Yüksek Ölçüsel Doğruluk	Düşük Enerji Verimliliği
Yüksek Yüzey Kalitesi	

Çekirdek XY 3B yazıcılar, hassaslık, hız ve kaliteli yüzey eldesi için gerekli kombinasyonların sağlandığı bir eklemeli imalat teknolojisi olarak tanınmaktadır.

3) Delta 3B Yazıcı

Delta 3B yazıcılar, benzersiz kinematik yapıları ve olağanüstü hızlarda baskı alabilme kabiliyetleri sayesinde katmanlı imalat teknolojisinde öne çıkan ürünlerden bir tanesidir. Delta robot sistematiğini baz alan Delta 3B yazıcılar, karmaşık geometrileri olağanüstü hızlarda yüksek kalitelerde üretebilmektedir. Merkezi bir platformdan uzanan üç kola sahip ve üçgen formda çalışan cihazlar, kademeli motorları kullanarak koordineli bir biçimde ürün eldesine olanak sağlamaktadır.



Şekil 3. 22 Delta FDM 3B yazıcı (Paoletti I. 2018'den değiştirilerek alınmıştır)

Yazıcı, kolların uzunluk ve açısını ayarlayarak, yazıcı kafasının istenilen koordinatlara hızla ulaşmasına olanak tanır. Bu sayede, kartezyen ve çekirdek XY sistemlerine nazaran daha yüksek hızlara, kaliteden ödün vermeden ulaşabilmektedir.
Delta 3B yazıcıların diğer FDM tip yazıcılara göre avantajlı ve dezavantajlı olduğu durumlar Çizelge 3.8'de belirtilmiştir.

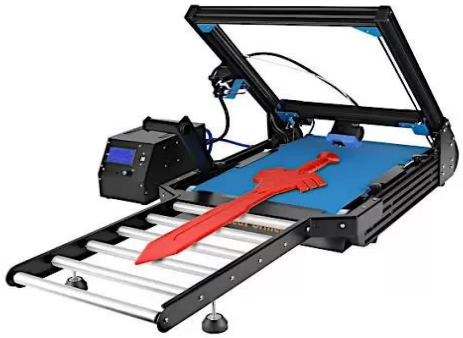
Çizelge 3. 8 Delta 3B FDM Yazıcı

Avantajları	**Dezavantajları**
Çok Hızlı Ürün Eldesi	Nispeten Pahalı
Yüksek Baskı Kalitesi	Geliştirme ve Hata Çözümleri Zor
Uzun Sürelerde Baskı Alabilme Kabiliyeti	Küçük İnşa Alanı

Özellikle mimari, sanat ve mühendislik alanlarının da içerisinde bulunduğu çeşitli endüstrilerde uygulama alanı bulunan delta 3b yazıcılar, hızlı ve yüksek kalitede üretim kabiliyetleri sayesinde dikkat çekmekte ve kullanım sıklıkları günden güne artmaktadır.

4) Konveyör (Belt) 3B Yazıcı

Konveyör tip olarak adlandırılan ve konveyör sistemine benzerliği ile tanınmakta olan bu yazıcılar, geleneksel yapı platformlarından farklı olarak tekil üretim kısıtlarına takılmadan sürekli imalata imkan tanıyan bir sistemi benimsemektedir. Sistemin içerisinde bulunan kayış, genellikle sürekli çalışmanın zorluklarına dayanabilecek poliüretan veya kauçuk gibi malzemelerden üretilmektedir.



Şekil 3. 23 Konveyör FDM 3B yazıcı

Bir kızak veya taşıma sistemine monte edilen baskı kafası, bant boyunca hareketini sağlayarak istenen ürünün üretilmesine olanak tanır. Elde edilen ürünler kayışın hareketi ile baskı tablasında ayrılabilmekte ve yeni herhangi ek işlem olmaksızın yeni ürün eldesi sağlanabilmektedir. Aynı zamanda hareket eden baskı tablası sayesinde tabla baskı alanından daha büyük ve uzun ürünlerin de üretilmesi mümkün olabilmektedir.
Konveyör 3B yazıcıların diğer FDM tip yazıcılara göre avantajlı ve dezavantajlı olduğu durumlar Çizelge 3.9'da belirtilmiştir.

Çizelge 3. 9 Konveyör 3B FDM yazıcı

Avantajları	Dezavantajları
Sürekli Yazdırma Kabiliyeti	Yavaş Baskı
Müdahalesiz Baskı Ayırabilme	Baskı Tablası Yapışmama Sorunları
	Uzun Süre Baskı Alınamama Problemi

Eklemeli imalatın, geleneksel imalat yöntemlerine göre en büyük problemlerinden biri olan seri imalat için uygun olmama problemine karşılık, konveyör 3B yazıcıların bu probleme bir çözüm olması beklenmektedir.

3.4.3 FDM malzeme tipleri

FDM 3B eklemeli imalat teknolojilerinin gelişmesi ile türe olan ilgi de artmış ve farklı malzeme ile üretim talepleri oluşmuştur. Teknoloji ve topluluğun da gelişimi ile termoplastiklerden, elastomerlere birçok malzeme ile farklı karakteristiğe sahip ürünlerin üretilmesi mümkün olmaktadır. Bu kısımda FDM 3B yazıcılar ile kullanılabilen malzemeler;

- Kullanım Alanı
- Yazdırma Zorluğu
- Sıcaklık Dayanımı
- UV Dayanımı
- Çarpılma Davranışı
- Koku
- Baskı Hızı

- Esneklik
- Ekstrüzyon Sıcaklığı
- Tabla Sıcaklığı

Gibi konularda karşılaştırmalı inceleme yapılacaktır.

1) PLA (Polilaktik asit)

Polilaktik Asit (PLA), FDM 3B Baskı teknolojileri alanında en yaygın kullanılan ve çok yönlü malzemelerden biri olarak tanınmaktadır. Biyolojik olarak parçalanabilir olması sayesinde insan sağlığına etkileri çok az olmakta ve gıdaların muhafaza edildiği ürünlerde de kullanılabilmektedir.

PLA, mısır nişastası veya şeker kamışı gibi malzemelerden üretilen bir biyopolitik malzemedir. Özellikle bu sebeple, petrol türevi malzemelere nazaran daha güvenilirdir. Sağlıklı olmasının yanında kolay baskı alınabilmesi ve temel görevler için uygun mekanik özellikleri sayesinde özellikle hobi kullanıcıları tarafından sıklıkla tercih edilmektedir.

Şekil 3.24'te PLA malzeme ile ilgili özellikler daha detaylı biçimde aktarılmaktadır.

	PARAMETRE	DEĞER
1.	*Darbe Dayanımı*	**Orta**
2.	*Esneklik*	**Düşük**
3.	*Kullanım Zorluğu*	**Kolay**
4.	*Baskı Sıcaklığı*	**180 - 230 °C**
5.	*Tabla Sıcaklığı*	**30 – 70 °C**
5.	*Çarpılma*	**Düşük**
6.	*Çözünürlük*	**Hayır**
7.	*Sağlık Güvenilirliği*	**Organik (Düşük Zarar)**

Şekil 3. 24 PLA malzeme özellikleri

FDM 3B yazıcı teknolojileri arasında en sık kullanılan malzemelerden biri olan PLA, tercih edilmesini sağlayan birçok avantajlı özelliğe sahiptir ancak her malzemenin olacağı gibi PLA malzemenin de her uygulama için uygun olması mümkün değildir. Çizelge 3.10'da PLA malzemenin avantaj ve dezavantajları irdelenecektir.

Çizelge 3. 10 PLA malzeme avantaj ve dezavantajları

Avantajları	**Dezavantajları**
Baskı Kolaylığı	Kırılgan
Düşük Maliyet	Düşük Isı Dayanımı
Düşük Sıcaklıklarda Baskı Alınabilmesi	Nispeten Düşük Mukavemet
Kokusuz	Bozulmaya El Verişli
Sağlıklı	Düşük Nem Direnci
Geniş Renk Yelpazesi	
Katkılı Ürün Opsiyonu (Mermer, Ahşap)	

PLA malzeme, biyolojik içeriği, parçalanabilirlik, boyutsal doğruluk ve özellikle kolay üretilebilirlik özellikleri sayesinde günümüzde en sık kullanılan malzeme olarak öne çıkmaktadır. Ancak düşük ısı direnci ve kırılgan karakteristiği sebebiyle, endüstriyel uygulamalarda kullanıcılar tarafından yoğun şekilde tercih edilmemektedir.

2) ABS (Akrilonitril bütadien stiren)

ABS, FDM 3B baskı teknolojileri alanında PLA malzeme sonrasında en sık tercih edilen malzeme olarak bilinmektedir. Özellikle, çok yönlülüğü, yüksek darbe dayanımı, yüksek ısıl direnç ve birçok sektörde kullanılabilmesi sebebiyle, endüstriyel alanda sıklıkla kullanılan ABS, geniş bir ısı aralığında mekanik yapısını bozulmadan koruyabilmektedir. Günümüzde özellikle otomotivde kullanılan birçok plastik parçanın da hammaddesi olan ABS, birçok sektörde de öncü termoplastik malzemelerden biri olarak kullanılmaya devam etmektedir.
Şekil 3.25'te ABS malzeme ile ilgili özellikler daha detaylı biçimde aktarılmaktadır.

	PARAMETRE	DEĞER
1.	*Darbe Dayanımı*	**Yüksek**
2.	*Esneklik*	**Orta**
3.	*Kullanım Zorluğu*	**Orta**
4.	*Baskı Sıcaklığı*	**210 - 270 °C**
5.	*Tabla Sıcaklığı*	**80 – 110 °C**
5.	*Çarpılma*	**Yüksek**
6.	*Çözünürlük*	**Ester, Keton, Aseton'da**
7.	*Sağlık Güvenilirliği*	**Sağlığa Zararlı**

Şekil 3. 25 ABS malzeme özellikleri

ABS, özellikle endüstriyel alanda sıklıkla kullanılan bir malzeme olmakla birlikte, dayanım, geniş ısı aralığında yapısal bütünlüğünü koruma gibi olumlu özelliklerinin yanı sıra, üretim zorluğu ve toksik koku yayması sebebiyle de olumsuz özelliklere sahiptir. Çizelge 3.11'de ABS malzemenin avantaj ve dezavantajları irdelenecektir.

Çizelge 3. 11 ABS malzeme avantaj ve dezavantajları

Avantajları	Dezavantajları
Yüksek Darbe Dayanımı	Baskı Zorluğu
Yüksek Isı Dayanımı	Zehirli Koku ve Duman Salınımı
Endüstriyel Üretime Uygun	Yüksek Çarpılma Davranışı
	Kapalı Kasa ile Üretim Gereksinimi

3) PETG (Polietilen tereftalat)

PETG, FDM 3B Baskı teknolojileri arasında özellikle su geçirmezlik ve UV ışık dayanım özellikleri ile öne çıkmıştır. Suya dayanımının yanı sıra yüksek darbe dayanımı ve şeffaflığı sayesinde endüstride birçok alanda kullanılabilmektedir. PETG, geleneksel PET malzeme ile karşılaştırıldığında PET malzemeye Glikol eklenmesi ile elde edilmiş ve daha yüksek mukavemet, daha yüksek darbe dayanımı, yüksek kimyasal direnç özelliklerine ek olarak, baskı tablasına mükemmel yapışması sayesinde PET yerine tercih edilen malzeme durumunu almıştır.

Şekil 3.26'da PETG malzeme ile ilgili özellikler daha detaylı biçimde aktarılmaktadır.

	PARAMETRE	DEĞER
1.	*Darbe Dayanımı*	**Yüksek**
2.	*Esneklik*	**Orta**
3.	*Kullanım Zorluğu*	**Kolay**
4.	*Baskı Sıcaklığı*	**220 - 250 °C**
5.	*Tabla Sıcaklığı*	**50 – 75 °C**
5.	*Çarpılma*	**Düşük**
6.	*Çözünürlük*	**Hayır**
7.	*Sağlık Güvenilirliği*	**Az Zararlı**

Şekil 3. 26 PETG malzeme özellikleri

PETG özellikle şeffaflık özelliği sayesinde, optik sektörü olmak üzere, şeffaf ve yarı saydam malzeme özellikleri gerektiren birçok sektörde sıklıkla tercih edilmektedir. Çizelge 3.12'de PETG malzemenin avantaj ve dezavantajları irdelenecektir.

Çizelge 3. 12 PETG malzeme avantaj ve dezavantajları

Avantajları	Dezavantajları
Yüksek Darbe Dayanımı	Neme Karşı Hassas
Esnek	Yapışkan Yapısından Dolayı Destek için Uyumsuz
Baskı Kolaylığı	Çizilmeye Karşı Hassas

4) TPU (Termoplastik elastomer)

TPU, FDM 3B baskı teknolojileri arasında özellikle esneklik özelliği ile öne çıkan malzemedir. Esnekliğinin yanı sıra, yüksek darbe dayanımı ile de tanınan TPU, bu sebeple birçok sektör ve uygulamada tercih edilmektedir. Kauçuk türevi elastomer temeline dayanan malzeme, plastik deformasyona uğramadan yüksek ölçüde şekil değiştirebilme kabiliyetine sahiptir. Bu özelliği sayesinde, conta gibi sızdırmazlık

elemanlarının üretiminde de sıklıkla kullanılmaktadır. Şekil 3.27'de TPU malzeme ile ilgili özellikler daha detaylı biçimde aktarılmaktadır.

PARAMETRE		DEĞER
1.	*Darbe Dayanımı*	**Çok Yüksek**
2.	*Esneklik*	**Çok Yüksek**
3.	*Kullanım Zorluğu*	**Orta**
4.	*Baskı Sıcaklığı*	**210 - 230 °C**
5.	*Tabla Sıcaklığı*	**30 - 60 °C**
5.	*Çarpılma*	**Düşük**
6.	*Çözünürlük*	**Hayır**
7.	*Sağlık Güvenilirliği*	**Zararlı**

Şekil 3. 27 TPU malzeme özellikleri

TPU malzeme esnekliği yanında darbe dayanımı ile de öne çıkan malzemelerden biridir. Darbelere karşı direnci Shore sertliği adı verilen parametre ile ifade edilmektedir. Yumuşak ve esnek malzemelerde shore değeri daha düşük olurken (Shore 30A), daha sert ve daha rijit malzemelerde bu değer artmaktadır. (Shore 95A).
Çizelge 3.13'te TPU malzemenin avantaj ve dezavantajları irdelenecektir.

Çizelge 3. 13 TPU malzeme avantaj ve dezavantajları

Avantajları	Dezavantajları
Çok Esnek	Baskı Zorluğu
Bükülme Sıkışma Gerektiren Yapılarda Mükemmel Sonuç	Doğrudan Tahrikli Sürücü Gereksinimi
Yüksek Isı Dayanımı	Düşük Baskı Hızı

3.4.4 FDM 3b baskı parametreleri

FDM Tipi Eklemeli İmalat ile üretimin gerçekleştirilebilmesi için, 3B ortamda tasarlanan modelin, yazdırma talimatlarına dönüştürülmesi gerekmektedir. Bu talimatların

oluşturulması işlemine “dilimleme” ismi verilmektedir. Bu talimatlar ile 3B nesneler, 2B yatay katmanlar haline getirilmektedir. Dilimleme işlemi ile 3B nesnelerin 2B nesnelere dönüştürülmenin yanı sıra, baskıyı etkileyen parametrelerde makineye aktarılmaktadır. Bu bölümde baskı parametreleri ve üretime etkileri irdelenecektir.

1) Sıcaklık

Sıcaklık, FDM Tipi 3B yazıcı teknolojisi ile elde edilen ürünlerin; kalite ve başarısında çok önemli rol oynamaktadır. Bu parametre, ekstrüderden baskı yatağına geçen plastik malzemeye iletilen ısıyı ifade etmektedir. Sıcaklık kontrolü, daha sonra da bahsedilecek olan, malzeme akışı, yapışma, katmanlar arası bağlanma hususlarını da etkileyen temel bir parametredir.

Nozul ucundan çıkan malzemenin sıcaklığı, o malzemenin viskozitesini, akış hızını ve kalitesini doğrudan etkiler. Daha yüksek sıcaklıklar, daha düşük viskoziteyi beraberinde getirirken, gereğinden yüksek sıcaklıklar, fazla ekstrüzyon sorunlarına dolayısı ile kalitesiz ürün eldesine sebebiyet verebilmektedir. Farklı malzeme türleri, farklı viskozite ve erime sıcaklıklarına sahip olduğundan, ekstrüzyon sıcaklık değerleri değişkenlik göstermektedir.

Sıcaklığın etki ettiği bir diğer komponent de baskı tablasıdır. Baskı tablası ısıtılarak, ilk katmanın tablaya yapışması dolayısıyla, baskının tamamlanabilmesi sağlanmaktadır. Farklı malzemelerin yüzeye tutunmak için ihtiyaç duyduğu sıcaklık değerleri farklılık gösterebilmektedir. PLA gibi malzemeler, açık kasa yazıcılarda ortalama 55-60 °C sıcaklık değerlerinde tablaya tutunabilirken, ABS ve ASA gibi mühendislik filamentleri ortam sıcaklığının korunabildiği kapalı kasa yazıcılarda, 100-110 °C sıcaklık değerlerinde tablaya tutunabilmektedir. Çizelge 3.20’de farklı malzemelerin farklı sıcaklık parametrelerine yer verilmiştir.

Çizelge 3. 14 Farklı malzemelerin sıcaklık değerleri (URL 30)

Malzeme	Ekstrüzyon Sıcaklığı (°C)	Baskı Tablası Sıcaklığı (°C)	Yatak Isıtılmalı mı?
PLA	190-230	45-60	Opsiyonel
ABS	220-250	95-110	Gerekli
TPU	225-245	45-60	Opsiyonel
PETG	230-250	75-90	Gerekli
ASA	235-255	90-110	Gerekli
CF	200-230	45-60	Opsiyonel

Çizelge 3.14'te verilen değerler, genel değerler olup, makine ve üretici markaya göre değişiklikler gösterebilmektedir.

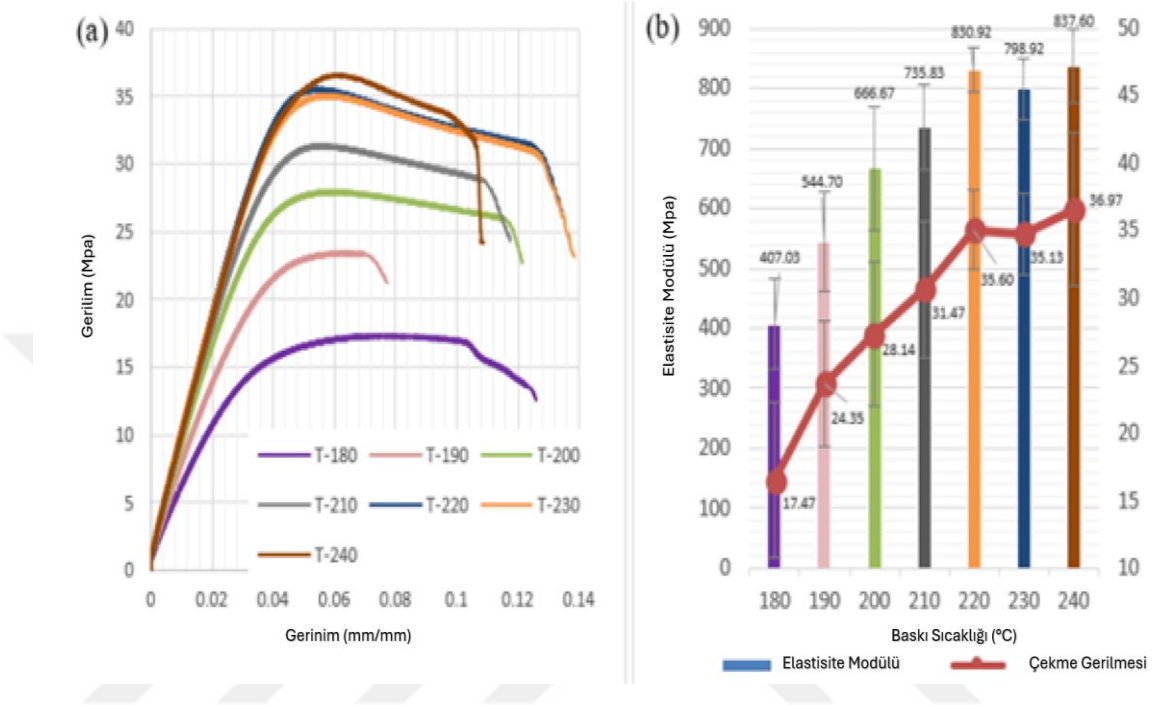
Yapılan araştırmalar sonucunda, sıcaklık değerlerinin ürünlerin ölçüsel doğruluğuna, kalitesine, mekanik dayanımı ve baskı hızına doğrudan etkisi olduğu gözlemlenmiştir. Gerçekleştirilen testlerde PLA malzeme ile alınan baskılarda 180°C ve 190°C sıcaklıklarda alınan baskılarda, yan duvarlarda zayıflama ve eksik ekstrüzyon sorunları görülürken, artan baskı sıcaklığı ile malzemenin kalitesi artmış ve eksik ekstrüzyon sorunlarının azaldığı gözlemlenmiştir.



Şekil 3. 28 Artan baskı sıcaklıklarının kaliteye etkisi (PLA)

Şekil 3.28'de a. görselinde 180°C ekstrüzyon sıcaklığı kullanılmış ve duvarlarda eksik ekstrüzyon ve düzensizlik görülmektedir. b. görselinde 190°C ekstrüzyon sıcaklığı ile baskı alınmış ve sorunun tam olarak çözülemese de belli oranda azaldığı ve c. görselinde ise 220°C ekstrüzyon sıcaklığı ile baskı alınmış ve duvarda eksik ekstrüzyon sorunun ortadan kalktığı ve düzenli bir yapı oluştuğu gözlenmektedir.

Farklı sıcaklık değerlerinde, ürün kalite değişiminin yanı sıra, ürünün dayanım değerlerinin de değişebildiğinden bahsedilmişti. Şekil 3.29'da ise, farklı sıcaklık değerlerinde malzemenin mekanik dayanım özelliklerindeki değişim gösterilmektedir.



Şekil 3. 29 Farklı sıcaklık değerlerinde malzemenin mekanik dayanım özellikleri Pang, R. (2022).'den değiştirilerek alınmıştır)

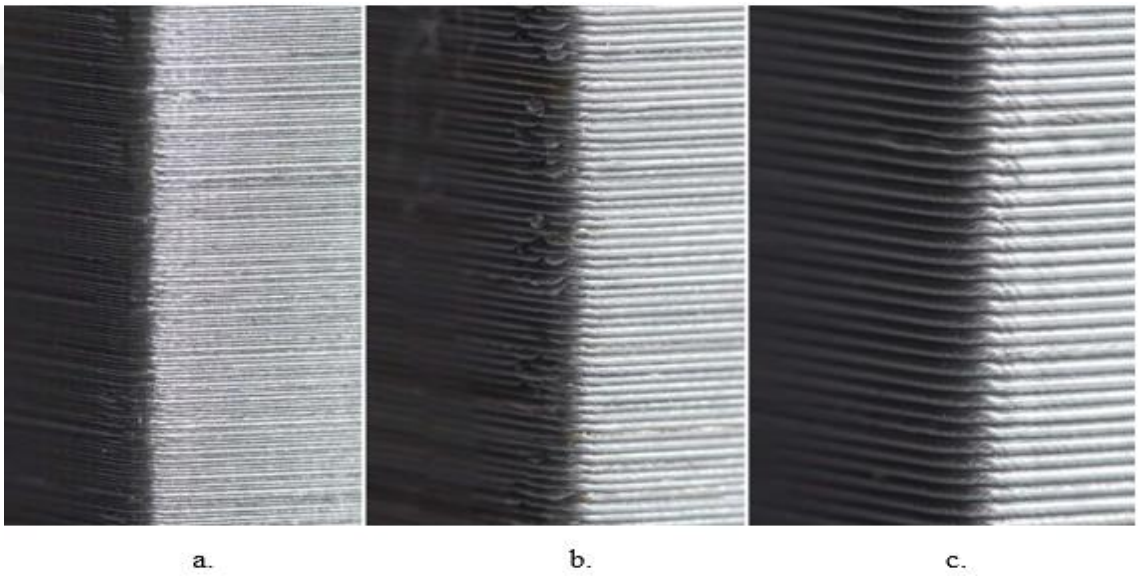
Malzemenin ekstrüzyon sıcaklığı değeri arttıkça, Gerilim/Gerinim grafiğinde daha yüksek değerlere sahip olduğu gözlemlenebilmektedir. 190°C ekstrüzyon sıcaklığında alınan numunelerde, kopma anında en düşük gerilim değerine sahipken, 220°C ekstrüzyon sıcaklığında, kopma anındaki gerilim değerinin yükseldiği gözlenmiştir. Bu sonuçlar ile baskı sıcaklığı arttıkça malzemenin viskozitesinin azaldığı ve bu da eriyik malzemenin birbirine kaynaşma oranın arttığı görülmüştür.

2) Katman yüksekliği

Katman yüksekliği, FDM 3B eklemeli imalat proseslerinde sıcaklık gibi temel parametrelerden bir tanesidir. Baskı kalitesi, baskı süresi ve doğruluğunda önemli role sahip olan katman yüksekliği, püskürtme ucundan çıkarılan her bir katman arasındaki

dikey mesafeyi ifade etmektedir. Genellikle mm cinsinden değer almakta ve 0,12 mm ile 0,8 mm arasında sıklıkla tercih edilmektedir.

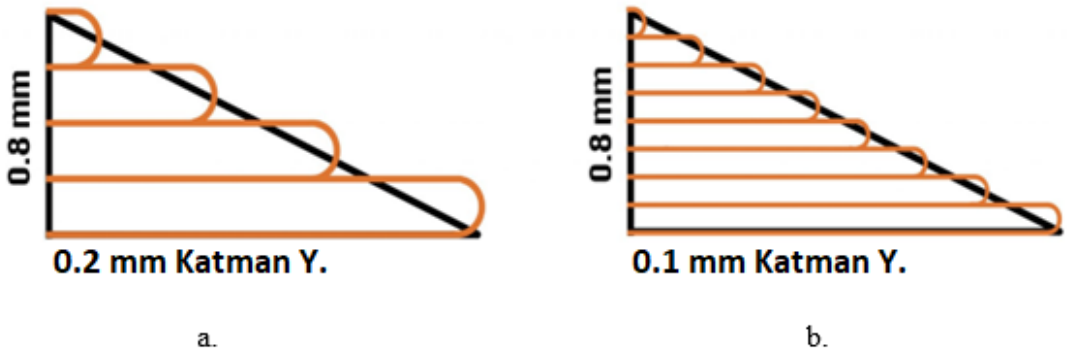
Katman yüksekliği, ürünün yüzey kaplamasını önemli ölçüde etkilemektedir. Daha düşük katman yüksekleri ile elde edilen ürünlerde, daha ince katman çizgileri ve daha düzgün yüzeylerin eldesi mümkün olurken, daha yüksek katman yüksekleri ile elde edilen ürünlerde, katman çizgileri daha belirgin hale gelmekte ve daha pürüzlü yüzeyler elde edilmektedir. Katman yüksekliklerinin yüzey kalitesine etkisi Şekil 3.26'da gösterilmiştir.



Şekil 3. 30 Farklı katman yüksekliklerinin yüzey kalitesine etkisi

Şekil 3.30 içerisindeki a. görselinde bulunan detaylar 50 mikron değerinde elde edilmiş ve b. ve c. görsellerine oranla yüzeyin daha pürüzsüz olduğu görülmektedir. Görsel b'de elde edilen ürün ise 200 mikron ve c. görselindeki ürün ise 300 mikron katman yüksekliği değeri ile üretilmiş ve katman yüksekliği değeri arttıkça katman çizgilerinin belirginleştiği ve yüzey kalitesinin azaldığı gözlenmektedir.

Katman yüksekliği seçiminde doğrudan etkilenen bir diğer olgu ise, baskı süresidir.



a. b.

Şekil 3. 31 Katman yüksekliğinin baskı süresine etkisi (Meram A. ve ark. 2020'den değiştirilerek alınmıştır)

Şekil 3.31'de a. ve b. görsellerinde dikey yüksekliği 0,8 mm olan iki parça görülmektedir. Ürün, görsel a'da 0,2 mm katman yüksekliği kullanılarak 4 katman ile üretimi sağlanabilmektedir. Görsel b'de ise 0,1 mm katman yüksekliği tercih edilmiş ve 8 katman ile üretimi gerçekleştirilebilmektedir. Daha küçük katman yüksekliği kullanılan b numunesinde daha fazla katmanın üretimi söz konusu olduğu için a görselindeki numuneye oranla baskı süresi artacaktır. Ancak bir önceki kısımda da bahsedildiği üzere katman yüksekliğinin artması ile ürün kozmetik açıdan kalite kaybına uğrayacaktır.

Katman yüksekliğinin, görsel kalite ve baskı süresine etkisinin yanında bir diğer önemli etkisi de ürünün mekanik dayanımına etkisidir. Daha ince katman yüksekliklerinin kullanımı, her bir katmanın, bir önceki katmanla arasında daha fazla temasa sahip olması nedeniyle, katmanlar arası daha iyi yapışma ve daha yüksek mukavemete sahip olmasına olanak tanımaktadır.

Yapılan çalışmalarda, sıcaklık değeri ve dolgu değerleri aynı değerde iken, katman yüksekliği arttıkça mekanik dayanım değerlerinin azaldığı gözlenmiştir.

Çizelge 3. 15 PLA (210°C ekstrüzyon sıcaklığı – 0,10 mm katman yüksekliği) (Zisopol D. ve ark. 2022'den değiştirilerek alınmıştır)

Doluluk (%)	**Basma Gerilmesi (Mpa)**					
	Örnekler					
	Örnek 1	Örnek 2	Örnek 3	Örnek 4	Örnek 5	Ortalama
50%	34	35	34	35	35	34,6
75%	48	48	47	46	46	47,0
100%	64	62	66	67	98	71,4

Çizelge 3. 16 PLA (210°C ekstrüzyon sıcaklığı – 0,20 mm katman yüksekliği) (Zisopol D. ve ark. 2022'den değiştirilerek alınmıştır)

Doluluk (%)	**Basma Gerilmesi (Mpa)**					
	Örnekler					
	Örnek 1	Örnek 2	Örnek 3	Örnek 4	Örnek 5	Ortalama
50%	30	30	32	32	29	30,6
75%	43	43	44	43	43	43,2
100%	59	59	60	59	61	59,6

Çizelge 3.15'te 210°C ekstrüzyon sıcaklığı ile ve 0,10 mm katman yüksekliği kullanılarak üretilen bir numunenin 100% doluluk değerinde ortalama 71,4 MPa gerilime dayanabildiği görülürken, Çizelge 3.16'da ise 210°C ekstrüzyon sıcaklığı ile ve 0,20 mm katman yüksekliği kullanılarak üretilen bir numunenin ise 100% doluluk değerinde ortalama 59,6 MPa gerilime dayanabildiği gözlemlenmiştir.

3) Dolgu oranı

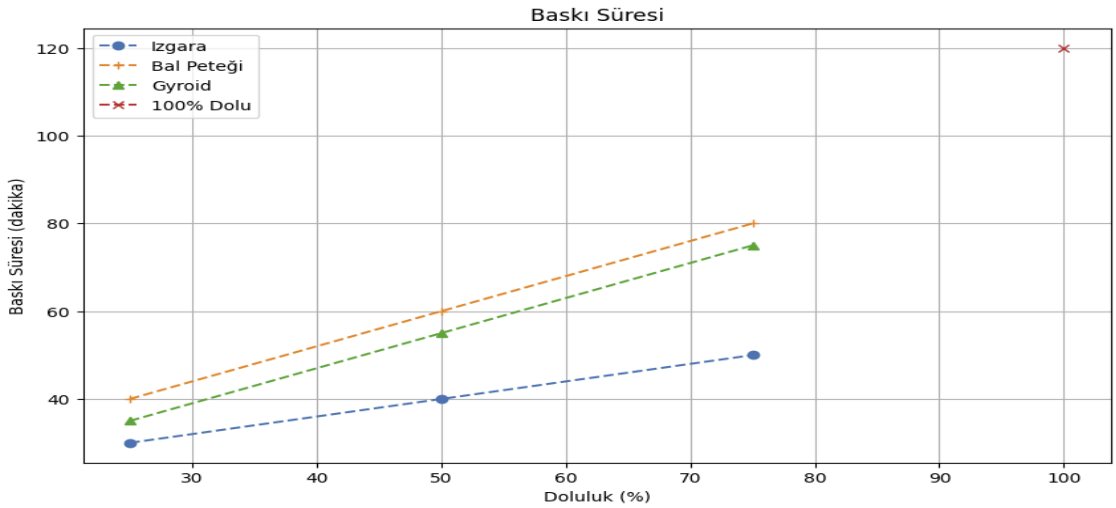
FDM Tipi 3B eklemeli imalat teknolojilerinde numuneler iki ana yatay katman olarak incelenebilmektedir. Bunlardan biri, ürünün dış duvarları iken diğer katman ise dolgudur ve ürünün iç yapısını ifade etmektedir. Bu parametre, baskının kalitesini, dayanımını, malzeme kullanımını ve yazdırma süresini önemli ölçüde etkilemektedir.

Daha yüksek dolgu oranları, daha fazla malzeme kullanımına ve baskı süresinin uzamasına sebep olurken, ürünün mekanik dayanımını arttırmaya yardımcı olmaktadır. Daha düşük dolgu oranları, malzemenin iç yapısının daha zayıf olmasına ve mekanik dayanımının daha az olmasına sebep olabilmektedir.

Çizelge 3. 17 Dolgu oranının dayanıma etkisi (Birosz M. ve ark 2022'den değiştirilerek alınmıştır)

Doluluk (%)	**Çekme Gerilmesi (Mpa)**		
	Dolgu Tipleri		
	Izgara	Üçgen	Gyroid
60%	25,2	23,4	24,5
75%	28,7	26,3	27,4
90%	32,6	29,2	31,3

Yapılan çalışmalar sonucunda Çizelge 3.17'de görüldüğü üzere dolgu oranı arttıkça, malzemenin dayanabildiği maksimum deformasyon kuvveti de artış gösterebilmektedir. Dolgu oranının etkilediği bir diğer konu ise, baskı süresidir. Genellikle dolgu oranı arttıkça, malzemenin harcayacağı malzeme ve süre artış gösterecektir.



Şekil 3. 32 Dolgu yoğunluğunun baskı süresine etkisi (Birosz M. ve ark 2022'den değiştirilerek alınmıştır)

Şekil 3.32'de görüldüğü üzere, dolgu yoğunluğu arttıkça, baskı süresi de artış göstermektedir. Üretimi yapacak kişinin dolgu yoğunluğunu seçerken, elde etmek istediği dayanım ve baskı süresi parametrelerini düşünerek üretim yapması önem arz etmektedir. Dolgu yoğunluğu seçimi yapılırken, birkaç parametre göz önüne alınmalıdır. Bunlar;

- Baskı Süresi
- Mekanik Dayanım
- Malzeme Kullanımı

Bu parametreler dikkate alınırken, aşağıdaki çıkarımlar ile ilerlemek mantıklıdır.
Standart parçalar genellikle yüksek mekanik dayanıma gerek duymayan parçalar olarak ifade edilebilir. Bu parçalarda 10% ile 15% arasında dolgu oranı yeterli görülebilmektedir.
Kozmetik amaçla üretilmiş ürünlerde ise bu oranın 0% ile 15% arası kullanıldığı gözlemlenebilmektedir. Fonksiyonel veya mekanik dayanım gerektiren parçalarda ise bu oranın 50% ile 100% arasında olduğunu görmek mümkündür.

4) Dolgu deseni

Dolgu deseni, üretilecek ürünün iç yapısındaki dolgu malzemesinin düzenini ifade etmektedir. Dolgu desenleri, bir ürünün optimizasyonunda önemli bir rol oynamaktadır. Ürünün mekanik özellikleri, ağırlığı ve baskı verimliliğinde çok etkili olan dolgu deseni seçimi, ürünün kullanım amacı ve malzeme süresi, malzeme tüketimi ve mekanik dayanım beklentileri belirlenerek seçilmelidir.



Şekil 3. 33 Dolgu desenleri (URL 47)

Şekil 3.33'te sıklıkla kullanılan farklı dolgu desenleri gösterilmektedir. Bu desenler farklı özelliklerin eldesi amacıyla kullanılmaktadır. Çizgi adı verilen dolgu deseni genellikle hızlı baskılar elde etmeyi sağlarken, Kübik dolgu deseni ürünün mekanik dayanımının ön plana çıktığı ürünlerde kullanılmaktadır. Çapraz dolgu deseni, parça içerisinde çapraz desenler oluşturarak, bükülmelere izin veren esnek malzemeler için uygun iken; Giroid desen ise, süre ve malzeme konusunda optimum olmasıyla tanınmaktadır. Yapılan çalışmalar sonucunda, farklı doluluk oranlarında farklı mekanik dayanımların sağlanabildiği ürünler ortaya çıkarılabilmektedir. Alfa adı verilen parametre (3.1) ile hesaplanan değerler sonucunda Çizelge 3.18'de verilen sonuçlar ortaya çıkmıştır.

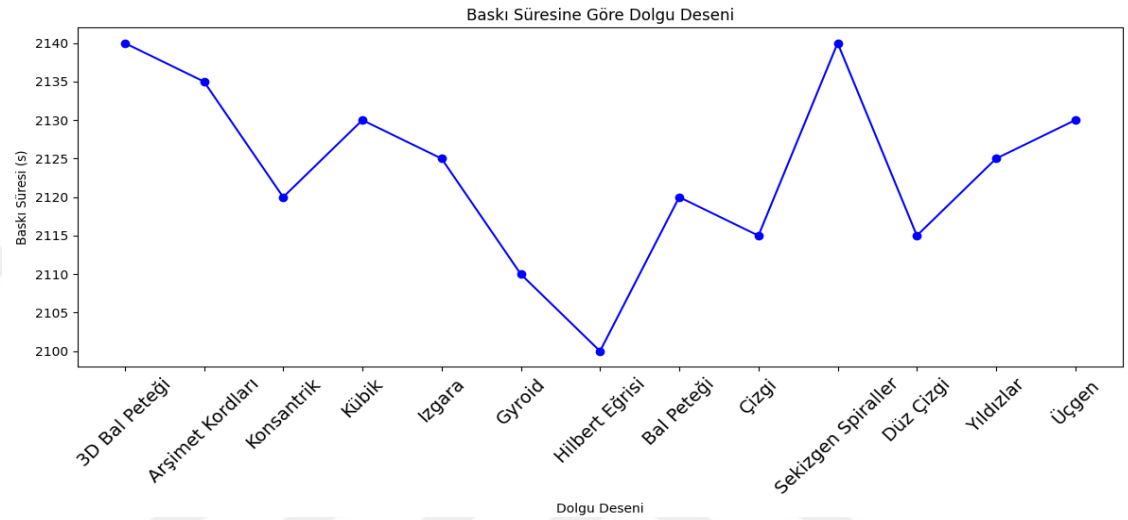
$$a = \text{Maksimum Yük / Kütle} \tag{3.1}$$

Çizelge 3. 18 Dolgu desenlerinin maksimum yükleme / ağırlığa etkisi (Pernet B. ve ark. 2022'den değiştirilerek alınmıştır)

Dolgu Tipi	**Ortalama a**
Çapraz	2531,92
Izgara	2505,04
Üçgen	2392,60
Konsantrik	2335,80
Üçlü Altıgen	2310,20
Çizgi	2303,82
Çapraz 3B	2286,24
Zigzag	2207,22
Oktet	2117,22
Konsantrik 3B	2108,83
Kübik	2022,91
Tetrahedral	2004,01
Gyroid	1986,82
Çeyrek Kübik	1943,71

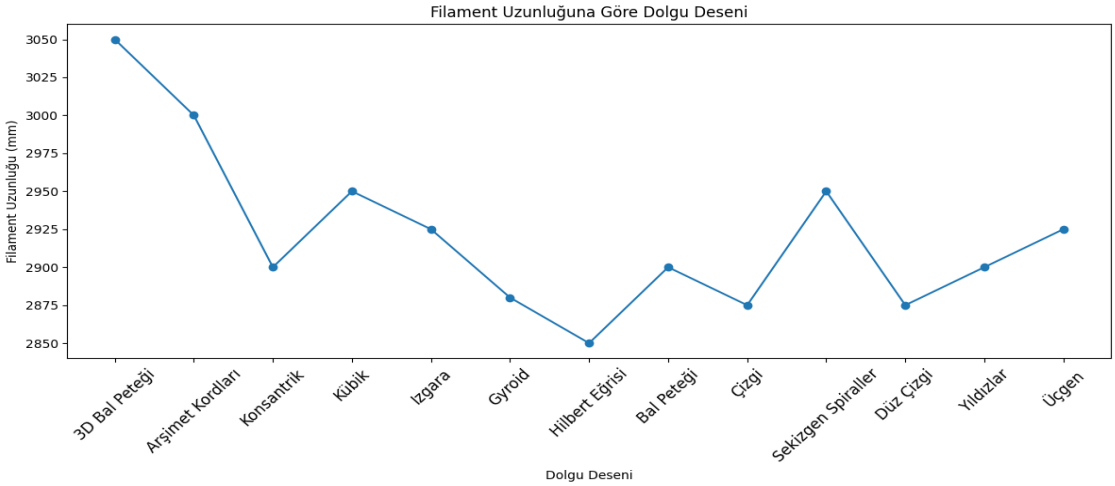
Bu çalışma sonucunda farklı dolgu oranlarında alınan ortalama değerler baz alınarak, Çapraz dolgu deseninin en yüksek değere sahip olduğu ve çeyrek kübik desenin ise bu listedeki en düşük değere sahip olduğu görülmektedir.

Yapılan başka bir çalışmada ise, farklı dolgu desenlerinin baskı süresine olan etkisi incelenmiştir. 80 mm/s baskı hızı, 0,3 mm katman yüksekliği ve 3 dış duvar kullanılan bir ürünün üretiminde farklı dolgu desenleri kullanılarak Şekil 3.34'te görülen sonuçlara ulaşılmıştır.



Şekil 3. 34 Dolgu deseninin baskı süresine etkisi (Suteja J. 2021'den değiştirilerek alınmıştır)

Yapılan çalışmalar sonucunda aynı dolgu oranına sahip ürünlerin eldesinde, Bal Peteği dolgu deseni kullanıldığında baskı süresinin listedeki diğer desenlere oranla daha yüksek bir baskı süresi gerektirdiği görülürken, Giroid dolgu deseni ile alınan baskının daha az zamanda sonuçlandırıldığı görülebilmektedir. Aynı çalışma içerisinde bulunan başka bir sonuç ise; Şekil 3.35'te gösterilmiştir.

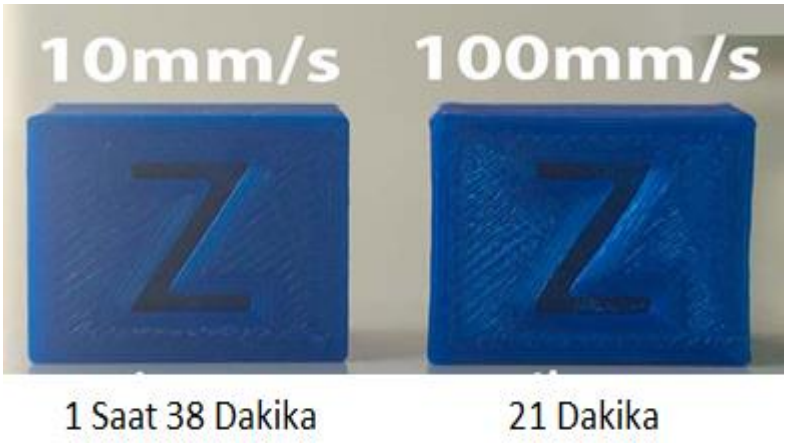


Şekil 3. 35 Dolgu deseninin malzeme kullanımına etkisi (Suteja J. 2021'den değiştirilerek alınmıştır)

Dolgu deseninin, aynı dolgu oranı kullanıldığı durumda, malzeme kullanımına etkisinin incelendiği Şekil 3.35'te ise, baskı süresine paralel sonuçlar görülmektedir. 3B Bal Peteği dolgu deseni ile alınan bir baskı en yüksek malzeme tüketimine sahip olduğu görülürken, Giroid dolgu desenini ile alınan bir baskının en az malzeme tüketen baskı olduğu görülmüştür.

5) Hız

Hız, FDM Tipi 3B yazdırma teknolojisinde, çok önemli bir parametredir. Yazıcı kafasının, 3 Boyutlu bir nesne oluşturabilmesi adına, hareket etmesini sağlamaktadır. Hız parametresi; baskı süresini, kalitesini ve nesnenin mekanik özelliklerini etkilemektedir. Baskı hızı, ekstrüderin X, Y ve Z eksenleri boyunca hareket etme hızıdır. Genellikle mm/sn cinsinden ifade edilmektedir. Baskı hızının etki ettiği en belirgin karakteristiklerden biri yüzey kalitesidir. Makine ve malzeme özelliklerine bağlı olarak değişiklik göstermekle birlikte, düşük baskı hızları ile alınan baskılarda, ayrıntıların daha belirgin ve daha kusursuz olabildiği gözlemlenebilmektedir. Yüksek yazdırma hızlarında ise sonucun, daha kusurlu olabildiği ancak üretim süresinin kısaldığı bilinmektedir.

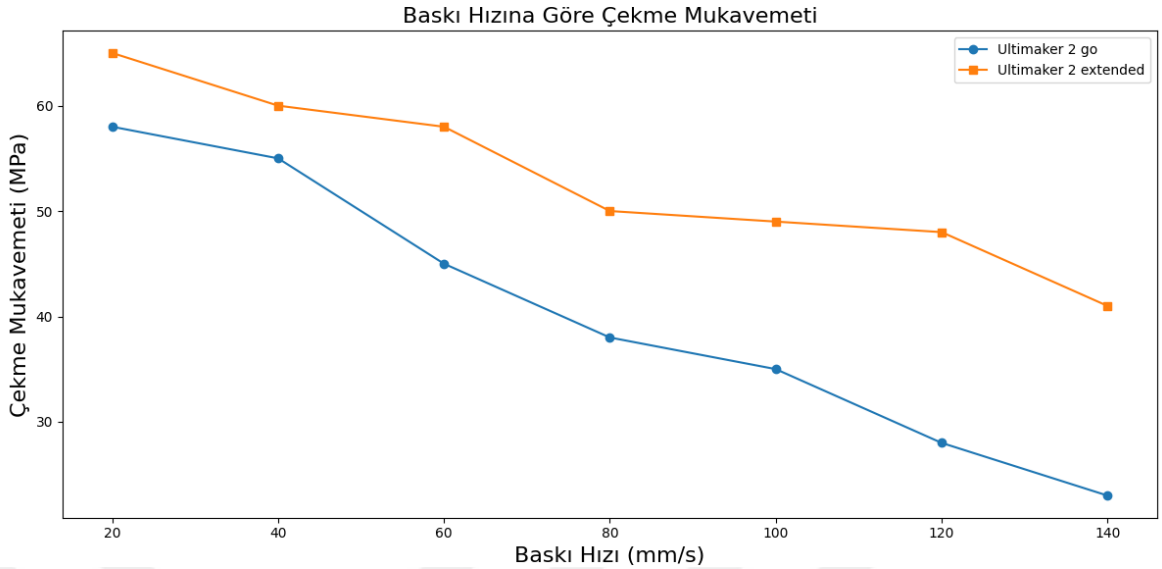


Şekil 3. 36 Baskı hızının kalite ve baskı süresine etkisi (URL 10)

Şekil 3.36'da görüldüğü üzere, 10 mm/s baskı hızı ile alınmış bir çıktının, 100 mm/s baskı hızı ile alınmış bir parçaya oranla baskı süresinin ciddi oranda artış gösterdiği ancak duvar kalitesinde nispeten daha başarılı olduğu görülebilmektedir.

Baskı hızının etki ettiği bir diğer karakteristik ise, boyutsal doğruluktur. Boyutsal doğruluk; nozul, katman yüksekliği gibi faktörlerden etkilenebilmekte ancak baskı hızının da etkisi yadsınamaz düzeyde önemlidir. Baskı kalitesine benzer biçimde, düşük baskı hızları ile elde edilen sonuçlar daha doğru ve başarılı iken, baskı hızı arttıkça boyutsal doğruluğun azalabildiği gözlemlenmektedir. Bunun nedeni, yüksek baskı hızlarında, sıcak uç adı verilen komponentten geçen filamentin erime miktarının, baskı kafası hızına yetişememesi ve eksik ekstrüzyon sorunlarının ortaya çıkabilmesidir. Bunun yanında, düşük baskı hızlarında filamentin yeterli soğuma ve erime miktarına ulaşabilmesi dolayısıyla baskı daha yüksek doğruluk ile elde edilebilmektedir.

Baskı hızının, etki ettiği bir diğer önemli karakteristik ise, elde edilen ürünün mekanik dayanımına olan etkisidir. Yapılan çalışmalarda, farklı iki makine üzerinde aynı malzeme ve aynı baskı parametrelerinde alınan çıktıların hız değişime ile gerilme kuvvetine olan etkileri incelenmiştir.



Şekil 3. 37 Baskı hızı ile gerilme kuvveti ilişkisi (Kamer M. 2022'den değiştirilerek alınmıştır)

Yapılan çalışmalar sonucunda (Şekil 3.37), baskı hızının artışı ile gerilme kuvvetinin lineer biçimde azaldığı görülebilmektedir.

6) Akış

Ekstrüzyon çarpanı olarak da bilinen akış parametresi, diğer parametreler gibi 3B Baskı teknolojilerinde kritik bir parametredir. Bu parametre, yazıcının püskürtme ucundan salınan filaman miktarını kontrol etmektedir. Elde edilecek ürünün, boyutsal doğruluğunu, mekanik dayanımını, yüzey kalitesini doğrudan etkilemektedir. Bir diğer tanım ile akış, ekstrüze edilen malzeme ile gerçek malzeme arasındaki oranı belirtmektedir. Akış parametresi hem üretimi sağlayacak makine hem de dilimleyici üzerinden kalibre edilebilmektedir. Yüzdelik değer ile ifade edilmekte ve nominal değer olarak 100% olarak belirlenmiştir. Farklı malzemeler için farklı viskozite değerleri dolayısı ile özel olarak akış parametreleri ayarlanarak, eksik ve fazla ekstrüzyon sorunlarının önüne geçilebilmektedir. Akış, yazdırılan bir ürünün, boyutsal doğruluğunu direkt olarak etkilemektedir. Akışın doğru ayarlanmadığı durumlarda, ekstrüder tarafından sürülen eriyik malzeme, nominal değerinden fazla veya az şekilde ürün

eldesinde kullanılarak, eksik veya fazla ekstrüzyon sorunlarına sebep olabilmekte ve boyutsal doğruluk sağlanamamaktadır.

Bir diğer etkilenen karakteristik ise, katman yapışmasıdır. Nominal değerin altında aktarılan malzeme sebebi ile katmanlar birbirine yeterli miktarda yapışamaz ve elde edilen ürünler üzerinde katman ayrılıkları gözlemlenebilmektedir. Katman yapışma sorunları gözlendiği takdirde, akış parametresi arttırılarak bu sorunun önüne geçilebilmektedir.

Yüzey kalitesi de akış parametresinden ciddi oranda etkilenebilmektedir. Doğru bir akış ayarı ile yüzey kalitesi istenen şekilde edilebilmektedir. Aksi durumda ise, yüzey üzerinde düzensizlik ve girinti çıkıntıların gözlemlenmesi mümkündür.

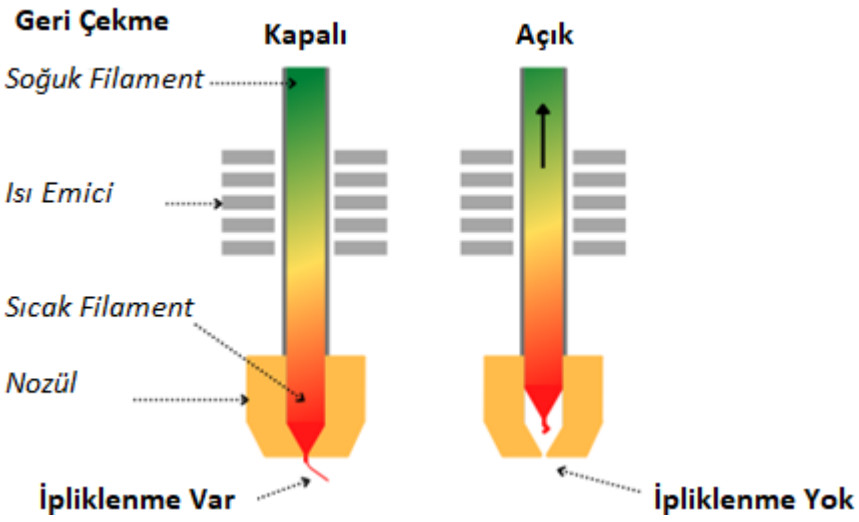


Şekil 3. 38 Akış parametresinin yüzey kalitesine etkisi

Şekil 3.38'de farklı akış parametreleri belirlenen parça üzerindeki etkisi gözlenebilmektedir. Varsayılan değerler ile alınan baskıda yüzey kalitesinin istenen düzeyde olduğu görülürken, akış parametresinin 20% arttırıldığı durumda yüzey üzerinde girinti çıkıntıların oluştuğu ve fazla ekstrüzyon sorunun ortaya çıktığı gözlenebilmektedir.

7) Geri çekme

Geri Çekme, 3B Baskı teknolojilerindeki bir diğer önemli parametredir. Bu parametre diğer parametrelerin aksine yazdırma sırasında değil, ekstrüder üzerinden malzemenin akmaması gerektiği durumlarda etki etmektedir. Geri çekme, filament ekstrüzyonunun, baskının gerekmediği durumlarda durdurulmasını ve malzemenin püskürtme ucundan geri çekilerek istenmeyen ekstrüzyonun engellemesini sağlayan parametredir. Bu parametrenin doğru ayarlanmaması durumunda, sızıntı gerçekleşmekte ve baskı üzerinde istenmeyen çıkıntıların oluşmasına sebep olabilmektedir. Bu sebeple yüzey kaplaması bozulabilmekte ve ürün fonksiyonelliğini kaybedebilmektedir. Geri çekme hızı ve mesafesinin fazla ayarlandığı durumlarda ise, malzeme baskı sırasında akışını yeterince sağlayamaz ve eksik ekstrüzyon sorunu görülebilmektedir.



Şekil 3. 39 Geri çekme ve ipliklenme (URL 43)

Şekil 3.39'da görüldüğü üzere, geri çekmenin kapalı olduğu durumda, baskı alınmayan sırada sıcaklığın etkisi ile malzemenin akışı devam edecek ve istenmeyen ekstrüzyon işlemi sağlanacaktır.

Önceki bölümlerde de bahsedildiği üzere 2 tip ekstrüder sıklıkla kullanılmaktadır. Doğrudan sürücülü ekstrüdere sahip cihazlarda, bowden tüplü ekstrüder sistemlerine göre daha düşük geri çekme mesafesi kullanılmalıdır. Bowden tüplü sistemlerde ortalama 2 ile

7 mm arası geri çekme mesafesi yeterli olurken, doğrudan sürücülü sistemlerde ise 0,5-2 mm arası geri çekme mesafesi uygun olacaktır.

Bir diğer parametre ise geri çekme hızıdır. Benzer biçimde doğrudan sürücülü sistemlerde, bowden tüplü sistemlere göre daha düşük bir geri çekme hızı kullanmak doğru olacaktır.



Şekil 3. 40 Geri çekmenin ipliklenmeye etkisi (URL 27)

Şekil 3.40'ta görüldüğü üzere, sol tarafta bulunan görselde, geri çekme ayarları uygunsuz olup, yazıcı kafası seyahati sırasında istenmeyen ekstrüzyon gerçekleştirmiş ve ipliklenmeye sebep olmuştur. Sağ taraftaki görselde ise, geri çekme ayarları doğru biçimde ayarlanmış ve istenmeyen ekstrüzyon sorunlarına rastlanmamıştır.

3.4.5 FDM 3b yazdırma sorunları

3 boyutlu yazıcı teknolojisinin gelişimi ile endüstriyel üretim süreçlerinde devrimsel değişiklikler gerçekleşti. 3B yazıcılar teknoloji altyapısı sayesinde geleneksel imalat göre avantajları beraberi getirse de kusursuz bir teknoloji olduğundan bahsetmek mümkün değildir. Her üretim yönteminde görüldüğü gibi, eklemeli imalat teknolojisi ile üretilen ürünlerde sorunla karşılaşılabilmektedir. Bu bölümde eklemeli imalat ile üretilmiş ürünleri üzerinde sıklıkla görülen hatalar, hataların sebepleri ve çözümlerine değinilecektir.

1) Malzeme akmama sorunu

Bu sorun, kullanıcılar tarafından sıklıkla karşılaşılan bir sorundur. Bu sorunun birkaç sebebi olabilmektedir.

a) Püskürtme ucunda malzemenin bulunmaması

FDM Tipi 3B yazıcılarda, sıcak uç (hotend) adı verilen ve malzemenin baskı tablasına iletilmesi sırasında görev alan bir komponent bulunmaktadır. Bu komponent içerisinde malzeme barel adı verilen bir parçanın içerisinden sıcak uça geçerek, ısıtıcı blok aracılığı ile eritilmekte ve baskı yatağına iletilmektedir. Malzeme baskı öncesinde ilgili kısma iletilmeli ve ardından ısıtma işlemi gerçekleştirilmelidir. Aksi durumda, motor malzemeyi iterken, barele giriş sağlanamayabilir ve baskı tablasına malzeme iletilememektedir.
Çözüm: Malzeme, baskı öncesinde sıcak uç içerisine konumlandırılmalıdır.

b) Nozulun baskı yatağına çok yakın olması

Nozul, ısıtıcı blok ile eritilen malzemenin istenen çap değerinde baskı yatağına aktarılmasını sağlayan komponenttir. 3B yazıcılarda baskı öncesinde baskı tablası ile nozul arasındaki mesafe kalibre edilerek, istenen kalitede baskıların alınabilmesi mümkün olabilmektedir. Nozulun baskı tablasına gerekenden daha uzak mesafede konumlandırılması halinde, eriyik malzeme tablaya akıtılacak ancak tablaya yapışmama veya istenen kalitede baskı alınamamasına sebep olacaktır. Baskı tablası ile nozul arasındaki mesafenin gerekenden az olması halinde ise, nozuldan çıkan eriyik malzeme baskı yatağına aktarılamayacak ve baskı alınamayacaktır.
Çözüm: Baskı öncesinde nozul, baskı yatağı kalibrasyonu gerçekleştirilmelidir.

c) Ekstrüder tıkanması

Daha önce verilen sorunların kontrol edilmesi ve sorunun bundan kaynaklanmaması halinde ekstrüderin tıkanmış olma ihtimali değerlendirilmelidir. 3B yazıcılar ile alınan

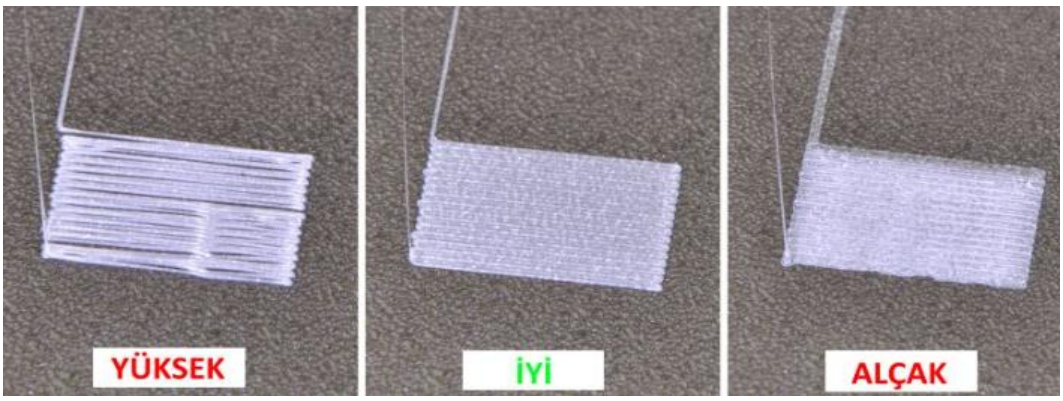
baskılar sonrasında, nozul ve çevresinde erimiş haldeki malzeme zamanla soğumakta ve katılaşmaktadır. Yeni baskı prosesi başlayacağı sırada, eriyik malzemenin tekrar eritilememesi halinde, nozul ucu tıkanacak ve malzemenin baskı yatağına iletimi engellenecektir.
Çözüm: Ekstrüder bloğunun sökülerek tıkanık nozulun açılması veya değiştirilmesi ile sorun giderilebilmektedir.

d) Malzemenin yeterli sıcaklıkta ısıtılmaması

Bir diğer problem ise malzemeye uygun sıcaklık verilmediği takdirde, malzemenin ısıtıcı bloktan geçerek nozula ulaşamamasıdır. 3B yazıcı teknolojisi ile birçok malzemenin kullanımı mümkündür ve malzemelerin farklı malzemelerde optimum erimeyi sağlayabildikleri bilinmektedir. Malzemenin optimum sıcaklığın alt değerlerinde eritilmeye çalışması halinde, malzeme erimesini sağlayamayacak ve nozula ulaşamayacaktır.
Çözüm: Malzemeye uygun sıcaklık seçilmelidir. Isı kulesi testi ile malzemenin uygun sıcaklık değeri tespit edilebilmektedir.

2) Yatağa yapışmama sorunu

3B yazıcı teknolojisi ile alınan baskılarda ilk katman kalitesi çok büyük önem arz etmektedir. İlk katmanın istenen kalitede olması durumunda, tüm baskının başarılı ilerleyeceğini düşünmek mantıklı sayılmaktadır. İlk katmanın istenen kalitede olmaması halinde ise, tüm baskının kalitesiz bir temel üzerine inşa edilmesi sebebiyle başarısız olacaktır.



Şekil 3. 41 Yatağa yapışmama sorunu (URL 2)

Şekil 3.41'da üç adet örneğe yer verilmiştir. İlk örnekte nozul yatağa gerekenden daha uzak konumlandırdığı için, akış tablaya temasında tablaya yapışmamış ve şekildeki görüntü ortaya çıkmıştır. İkinci görselde ideal koşul sağlanırken, üçüncü koşulda ise nozul ile baskı yatağı arasındaki mesafe, olması gereken değerin altındadır ve bu nedenle nozul baskıya sürtmüş ve yüzeye zarar vermiştir. Bu bölümde, malzemenin yatağa yapışması ile ilgili sorunlar ve bu sorunların çözümüne değinilecektir.

a) Baskı yatağının hatalı kalibrasyonu

Baskı yatağı kalibrasyonu, üretimin doğru şekilde ilerlemesi için çok önemlidir. Baskı yatağının farklı bölgelerde farklı yükseklikte olması durumunda, kimi bölgelerde nozul yatağa sürterek filamentin akmasını engelleyebilir ve kimi yerlerde de baskı yatağının gereken yukarıda olacak şekilde konumlanacak ve malzeme tablaya yapıştırılamayacaktır.
Çözüm: Baskı yatağı kalibrasyonu sağlanarak X ekseninde her nokta paralel konuma getirilmelidir.

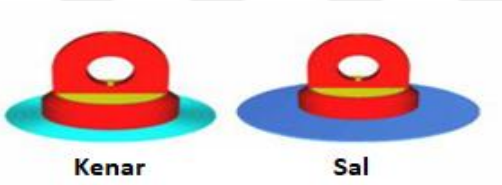
b) İlk katmanın çok hızlı yazdırılması

Baskı hızı, baskı kalitesi için çok önemli bir yer oynamaktadır. Doğru baskı hızlarının seçilmemesi halinde, istenen kalitede ürünlerin eldesi mümkün olamamaktadır. Doğru hız parametresi seçiminin etkilediği bir diğer konu ise, baskının tablaya yapışmamasıdır. İlk

katmanın çok hızlı alınması halinde, malzeme tablaya doğru bağlanmayabilmekte ve baskı tabladan kalkabilmektedir.
Çözüm: İlk katman hızının düşürülmesi

c) Levha yapıştırma yapılarının kullanılmaması

Nesnelerin dilimlendiği yazılımlarda, levha yapıştırıcıları adı altında bulunan seçenekler sayesinde baskının tablaya yapışması sağlanabilmektedir. Bu yapılar, baskının tabla ile arasındaki temas yüzeyini arttırarak, özellikle Z ekseninde uzun parçaların tabladan ayrılmasını engellemek için kullanılabilmektedir.

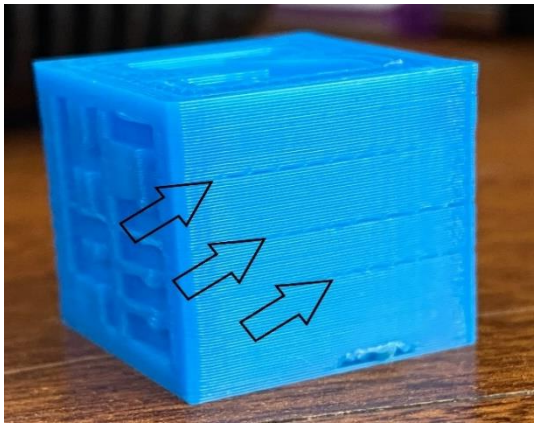


Şekil 3. 42 Levha yapıştırma (URL 7)

Çözüm: Şekil 3.42'de gösterilen kenar ve sal gibi levha yapıştırma araçlarının kullanılması

3) Eksik ekstrüzyon sorunu

3B baskı teknolojisi ile üretilen ürünlerde aranan özelliklerden bazılar görsel kalite ve dayanımdır. Kalitenin ve mekanik dayanım istenen düzeyde olması, ekstrüzyonun istenen seviyede olması ile sağlanmaktadır.



Şekil 3. 43 Eksik ekstrüzyon sorunu

Şekil 3.39'da görüldüğü üzere eksik ekstrüzyon problemlerinde sıklıkla baskı duvarlarında ve dolgusunda eksiklikler görülebilmektedir. Bu bölümde eksik ekstrüzyonun sebepleri ve çözümlerine dair detaylar aktarılacaktır.

a) Yanlış Materyal Çapı

FDM tipi 3B yazıcılarda, ekstrüderler destekledikleri malzeme çapı ile farklılık gösterebilmektedir. Piyasada sıklıkla 1,75 mm çap ve 2,85 mm malzeme çap değerini destekleyen cihazlar bulunmaktadır. Cihazın desteklemediği çap değerine sahip malzeme kullanıldığı takdirde bu sorunla karşılaşmak mümkündür.
Çözüm: Malzeme çap değeri kontrol edilmeli ve cihazın desteklediği çap değerine ait malzeme kullanılmalıdır.

b) Düşük ekstrüzyon çarpanı / akış katsayısı

Eksik ekstrüzyona sebebiyet verebilecek bir diğer parametre ise, kalibre edilmeyen bir makine ve akış katsayısının optimum değerin altında olmasıdır. Bu durumda, dilimleyicide kullanılması hesaplanan malzemeye oranla, ekstrüder tarafından daha az malzeme üretilecek ve dolayısıyla olması gerekenden daha güçsüz ve eksik bir dış duvar görülecektir.
Çözüm: Makine, akış testi yapılarak kalibre edilmelidir.

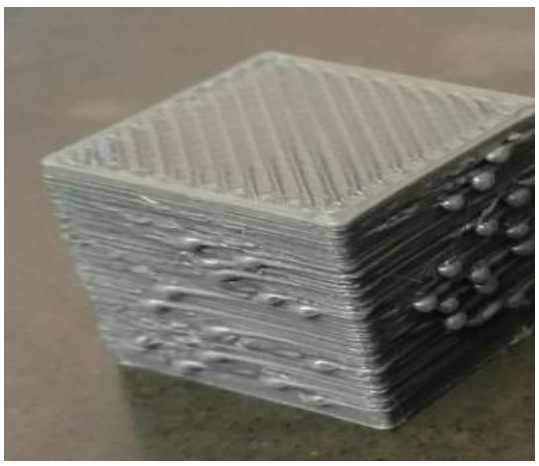
c) Düşük ekstrüzyon sıcaklığı

Eksik ekstrüzyona sebep olan bir diğer parametre ise ekstrüzyon sıcaklığının yanlış seçimidir. FDM tipi 3B yazıcılarda birçok malzeme ile ürün elde etmek mümkündür. Malzemelerin farklı termokimyasal özellikleri sebebiyle ekstrüzyon sıcaklıkları da farklılık göstermektedir. Kullanılan malzemenin sıcaklığı, kullanılan cihaza da bağlı olarak belli oranda farklılık göstermekte ve sıcaklık kulesi gibi testler yardımıyla malzemenin uygun baskı sıcaklığı belirlenmelidir. Optimum değerin altında kullanılan sıcaklıklarda, malzeme düzgün bir akış sağlayamayacak ve eksik ekstrüzyon sorunu ile karşılaşılacaktır.

Çözüm: Malzemeye uygun sıcaklığı tayin edilmeli ve bu şekilde baskı alınmalıdır.

d) Fazla ekstrüzyon sorunu

Eksik ekstrüzyona benzer olarak yaşanan, kalite ve dayanıma ciddi etkisin olan bir diğer sorun ise fazla ekstrüzyondur. Fazla ekstrüzyon sorununda, makine dilimleyicide görülene oranla ekstrüder tarafından daha fazla malzeme sıcak uça iletilmekte ve bu nedenle duvarlar ve dolgular üzerinde fazlalık ve damlama gibi yapılar görülebilmektedir.



Şekil 3. 44 Fazla ekstrüzyon sorunu (URL 13)

Şekil 3.44'te görüldüğü üzere, baskı üzerindeki duvarlarda ve üst yüzeyde istenen dışında damlalar ve desenler oluşmuştur. Bu bölümde fazla ekstrüzyonun sebepleri ve çözümlerine dair detaylar aktarılacaktır.

e) Yanlış materyal çapı

Eksik ekstrüzyon bölümünde de anlatıldığı üzere, cihazların üzerinde bulunan ekstrüderler farklı malzeme çaplarını desteklemekte ve bu çapa sahip malzemeler ile kullanılmalıdır. Aksi halde eksik ekstrüzyona benzer şekilde fazla ekstrüzyon sorunları ile karşılaşmam mümkündür.
Çözüm: Malzeme çap değeri kontrol edilmeli ve cihazın üzerinde bulunan ekstrüdere uygun çapta malzeme kullanılmalıdır.

f) Yüksek ekstrüzyon çarpanı / akış katsayısı

Eksik ekstrüzyon sorununda, akış çarpanın optimum değerin altında olması halinde yeterince malzemenin nozuldan baskı yatağına aktarılamayacağı, duvar ve iç dolgu üzerinde eksikliklerin gözlenebileceğinden bahsedilmişti. Benzer şekilde, optimum değerin üzerinde belirlenen akış katsayıları, malzemenin gerekenden daha fazla beslenmesine ve baskı üzerinde istenmeyen çıkıntı ve desenlere sebep olmaktadır.
Çözüm: Akış testi yapılarak, malzeme ve makine için optimum değerler elde edilmeli ve bu şekilde üretim yapılmalıdır.

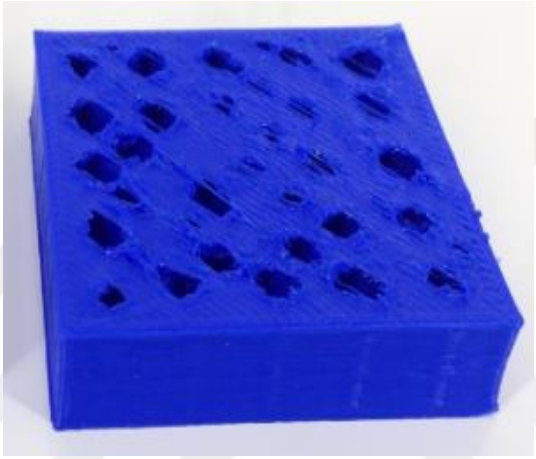
g) Yüksek ekstrüzyon sıcaklığı

Her malzemenin farklı termokimyasal özellikleri sebebiyle farklı ekstrüzyon sıcaklıklarında optimum erime değerine ulaşabildiğinden bahsedilmişti. Fazla ekstrüzyon sorunu gerçekleştiğinde, malzeme için uygun ekstrüzyon sıcaklığının kullanıldığından emin olunmalıdır. Ekstrüzyon sıcaklığı optimum değerin üstünde olduğunda, malzeme gerekli değerin üzerinde nozula beslenecek ve istenmeyen çıkıntılar baskı üzerinde görülecektir.

Çözüm: Malzeme ve cihaza uygun ekstrüzyon sıcaklığının tayin edilmeli ve bu değer ile baskı alınmalıdır.

4) Üst ve alt katmanlarda boşluk sorunu

FDM tipi 3B yazıcı ile alınan baskılarda görülen bir diğer problem ise üst ve alt duvarlarda görülen boşluklu yapılardır.



Şekil 3. 45 Üst ve alt katmanda boşluk sorunu (URL 32)

Şekil 3.45'te gördüğü üzere, üst duvar üzerinde boşluklu yapı oluşmuştur. Bu sorunun çeşitli sebepleri olabilmektedir. Bu bölümde, bu sorunlar ve çözümlerine değinilecektir.

a) Eksik ekstrüzyon sorunu

Önceki bölümlerde, duvar ve dolgularda eksik ekstrüzyon sorunu olması halinde boşluk ve eksik katmanların oluşabileceğinden bahsedilmişti. Üst ve alt katmanlardaki eksik yapıların da eksik ekstrüzyon sebebiyle oluştuğunu gözlemlemek mümkündür. Ancak yan duvarlarda eksik ekstrüzyon sorununun varlığı kontrol edilmelidir.
Çözüm: Eksik ekstrüzyon belirtileri kontrol edilmeli ve sorunun kaynağının eksik ekstrüzyon olduğu belirlenmesi halinde, önceki bölümlerdeki çözümler uygulanmalıdır.

b) Yetersiz alt ve üst katman sayısı

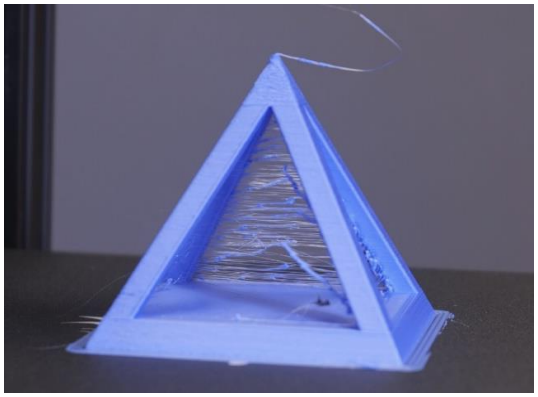
Dilimleyici adı verilen, 3B nesneyi, baskı için gcode formatına dönüştürülen yazılım içerisinden birçok parametreye müdahale edilebildiği gibi alt ve üst katman sayısı da belirlenebilmektedir. Dilimleyici program üzerinde, üst ve alt katman sayısı yetersiz seçildiği takdirde, katmanlar üzerinde boşluklar oluşabilmektedir. Fonksiyonel parçalar için bu değerin üç katman ve görsel parçalar içinse beş katman seçilmesi önerilmektedir.
Çözüm: Alt ve üst katman sayısı dilimleyici program üzerinde arttırılmalıdır.

c) Yetersiz dolgu yüzdesi / dolgu deseni seçimi

Bir diğer potansiyel sorun ise, baskının iç dolgu yüzdesinin yetersiz olmasıdır. Dolgu yüzdesi yetersiz olduğu takdirde, üst katmanlar baskı sırasında bir yüzeye tutunamayacak ve dolayısıyla yüzey üzerinde boşluklar gözlemlenecektir. Bir diğer potansiyel sorun ise yanlış dolgu deseni seçimidir. Üretilen ürünün hafif olması istenebilmekte ve dolayısı ile düşük dolgu yüzdesi tercih edilebilmektedir. Bu durumda, "ızgara" ve "giroid" gibi dolgu desenleri, dolgu yüzdesi düşük olsa dahi, üst katmanların tutunabilmesi için yeterli temas alanını sağlayabilmekte ve üst katmanın boşluksuz şekilde elde edilmesini sağlayabilmektedir.
Çözüm: Dolgu yüzdesi arttırılmalı ya da aynı dolgu yüzdesi ile farklı dolgu deseni kullanılmalıdır.

5) İpliklenme sorunu

İpliklenme, baskının farklı bölümleri arasındaki hareketi sırasında oluşan ince şeritler olarak ifade edilmektedir. Genellikle filamentin, nesneler arasındaki hareketi sırasında filamentin geri çekilmemesi bu probleme sebep olurken, farklı sebepler ile de bu sorunla karşılaşmak mümkündür.



Şekil 3. 46 İpliklenme sorunu (URL 39)

Şekil 3.46'da görüldüğü üzere, basılan nesnenin boş olması gereken kısmında ince şeritler oluşmuştur. Bu bölümde, şeritlenmelerin oluşma sebepleri ve çözüm önerilerinden bahsedilecektir.

a) Geri çekme mesafesi

Geri çekme mesafesi, yazıcı kafasının farklı nesneler arasındaki hareketi sırasında nozuldan malzemenin ne kadar çekileceğini belirleyen parametredir. Doğrudan tahrikli ekstrüdere sahip cihazlarda bu mesafe 0,5 ile 2 mm arasında belirlenirken, bowden tüpe sahip ekstrüderlerde bu değerin 2 ile 7 mm arasında belirlenmesi gerekmektedir.
Çözüm: Geri çekme mesafesi için test baskısı alınmalı ve uygun geri çekme mesafesi belirlenmelidir.

b) Geri çekme hızı

Geri çekme hızı ise, nozuldan geri çekilecek malzemenin ne kadar hızlı geri çekileceğini belirleyen parametredir. Düşük hızlarda geri çekilmesi halinde, nozul ucunda kalan malzeme, sıcaklık etkisiyle erimeye devam edecek ve ipliklenme sorunu devam edecektir. Yüksek hızlarda geri çekilmesi halinde ise, malzeme istenmeyen miktarda geri çekilebilir ve baskı sırasında tekrar nozula beslenememektedir. Literatürde geri çekme hızının 20 ile 80 mm/sn değerleri arasında seçildiği görülmektedir.
Çözüm: Geri çekme hızı için test baskısı alınmalı ve uygun değer belirlenmelidir.

c) Yüksek ekstrüzyon sıcaklığı

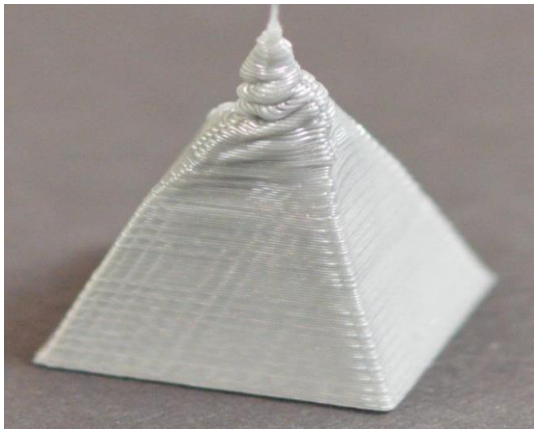
Yüksek ekstrüzyon sıcaklığı, nozulun içerisindeki malzemenin gerekenden fazla akmasına sebep olabilmektedir. Geri çekme mesafesi ve geri çekme hızının kontrolü ardından hala ipliklenme sorunu yaşanıyorsa, ekstrüzyon sıcaklığının optimum değer üzerinde olduğundan bahsedilebilmektedir.
Çözüm: Malzeme için uygun sıcaklık değeri belirlenmelidir.

d) Hareket hızı

Hareket hızı yavaş olduğu takdirde nesneler arasındaki mesafenin kat edilme süresi uzayacak ve bu nedenle ipliklenme riski de artacaktır.
Çözüm: Makine kabiliyetine bağlı olarak, X ve Y eksenlerindeki hareket hızı arttırılmalıdır.

6) Aşırı ısınma sorunu

Aşırı ısınma sorunu, fazla ekstrüzyon sorunu ile karıştırılsa dahi farklı sonuçlara sahiptir. Plastik malzemeler, erime sıcaklıklarında iken; rijit yapılarını kaybetmekte ve kolaylıkla şekil alabilmektedir. PLA, PETG gibi malzemeler cihaz üzerinde bulunan fanlar sayesinde, malzemeye istenen şekilde verildiğinde soğutularak katılaştırılmakta ve istenen forma dönüştürülmektedir. Ancak soğutma yetersizliği, fazla ekstrüzyon sıcaklığı ve yüksek hızda baskı alma gibi problemler dolayısı ile aşırı ısınma sorunu ile karşılaşmak mümkündür.



Şekil 3. 47 Aşırı ısınma sorunu (URL 36)

Şekil 3.47'de görüldüğü üzere, alt katmanlarda aşırı ısınma sorunun etkilerine pek rastlanmazken, üst kısma doğru bahsedilecek sebepler dolayısı ile istenen biçimde baskı alınamamıştır.

a) Yetersiz soğutma

Aşırı ısınma sorununun en sık rastlanılan sebeplerinden biri yetersiz soğutmadır. PLA gibi fan ile soğutma ihtiyacı duyan plastik malzemelerde, plastik yavaş şekilde soğumaya bırakıldığında istenmeyen şekil değiştirmeler ile karşılaşılabilmektedir. Nozuldan baskı tablasına aktarılan eriyik malzemenin hemen soğutulması durumunda ise, istenen şekil elde edilebilmektedir.
Çözüm: Malzemeye uygun şekilde parça soğutma ayarları düzenlenmelidir.

b) Çok yüksek ekstrüzyon sıcaklığı

Bir diğer ana sebebin ise fazla ekstrüzyon sıcaklığı olduğundan bahsetmek mümkündür. Optimum ekstrüzyon sıcaklığının üstünde malzemenin eritilmesi halinde, soğutma yetersiz kalacak ve nozul içerisinden istenen miktarın üstünde malzeme geçişi gerçekleşecektir.
Çözüm: Daha düşük ekstrüzyon sıcaklığında test baskıları alınarak, optimum ekstrüzyon sıcaklığı değeri tespit edilmelidir.

c) Çok yüksek baskı hızı

Eklemeli imalat, bir nesnenin katmanlar halinde üretilmesini esas almaktadır. PLA gibi soğutma ihtiyacı duyan malzemelerin ise, yeterli soğutmaya maruz kalmaması halinde aşırı ısınma sorunu ile karşılaşmanın mümkün olduğundan bahsedilmişti. Çok yüksek hızlarda baskı alınması halinde, eriyik malzemenin soğutulması için yeterli süre olmadığı için, malzemenin eksik soğutulması ve dolayısı ile istenmeyen şekil değişimleri ile karşılaşmak mümkündür.

Çözüm: Daha düşük baskı hızları kullanılarak, eriyik malzemenin yeterince soğutulması için süre tanınmalıdır.

7) Çarpılma sorunu

Çarpılma sorunu, üretimin belirli bir süre devamının ardından, baskının alt köşe ve kenarlarından tabladan kalkma eğilimi şeklinde ifade edilebilmektedir. Genellikle büyük parçaların üretim sürecinde gerçekleşen bu sorun, plastik parçanın zamanla soğuması ve büzülmesi nedeniyle gerçekleşmektedir. Özellikle ABS gibi, hava akımından etkilenen plastik parçaların büzüşmesi 1% ile 1.5% arasında değişiklik gösterebilmekte ve zaman zaman baskının tabladan kalkmasına ve ürünün kullanılmaz hale gelmesine sebebiyet vermektedir.



Şekil 3. 48 Malzeme çarpılma sorunu (URL 39)

Şekil 3.48'de görüldüğü gibi, üretimin başlamasının ardından, çarpılma sorunu gözlenmiş ve baskı büzülerek, tabladan kalkmıştır. Büzülme miktarının artması durumunda, baskının kullanılmaz duruma gelmesi olasıdır.

a) Isıtmalı yatak kullanılmaması

Baskı ile yatak arasındaki teması sürekli tutmak, bu problemin en büyük çözümlerinden biridir. Baskı yatağı ısıtılarak, malzemenin baskı yatağına yapışması ve dolayısı ile çarpılma sorununun önüne geçmek mümkündür.
Çözüm: Yatak sıcaklığı arttırılarak, yatak ile baskı arasındaki temas sabit tutulmalıdır.

b) Soğutma fanının yanlış kullanılması

PLA gibi termoplastik malzemeler, hızlı soğuma gereksinimi duyduğundan, parça soğutma fanı yardımıyla, eriyik hale geçmesinin hemen ardından soğutulmakta ve katılaştırılmaktadır. Ancak ABS, ASA gibi hava akımından olumsuz yönde etkilenen termoplastik malzemeler ise, soğutma fanı kullanılması halinde çarpılma davranışı sergilemekte ve hatalı ürün eldesine sebebiyet vermektedir.
Çözüm: ABS, ASA gibi malzemelerde soğutma fanı kullanılmamalıdır.

c) Ortam sıcaklığının korunmaması

ABS ve ASA gibi hava akımından olumsuz yönde etkilenen malzemelerin, sabit bir ortam sıcaklığında kullanılması gerekmektedir. Aksi halde malzemeler, soğutma fanının yanlış kullanım senaryosuna benzer olarak çarpılma davranışı sergilemektedir.
Çözüm: Kapalı ve ortam sıcaklığının korunduğu bir ortamda üretim yapılmalıdır.

d) Levha yapıştırma yapılarının kullanılmaması

Çarpılma davranışına meyilli olan malzemelerin kullanımı sırasında, kenar ve raft gibi yapıların kullanımı, baskının tabladan ayrılmasını ve dolayısı ile çarpılma sorununun görülmemesini sağlayacaktır. Ek olarak bu malzemeler ile levha yapıştırma kimyasalları

kullanarak, baskı yatağı ile baskı arasındaki temas korunabilmekte ve çarpılma sorununun önüne geçilebilmektedir.
Çözüm: Levha yapıştırma yapıları ve baskı yapıştırma kimyasalları kullanılarak, çarpılma sorununun önüne geçilmelidir.

8) Spagetti sorunu

Spagetti sorunu, baskının tamamlanamayıp, filamentin boşa akması sonucu spagettiye benzer bir hal alması nedeni ile bu ismi almıştır.



Şekil 3. 49 Spagetti sorunu

Şekil 3.49'da görüldüğü gibi, cihazın kontrolü kaybetmesi ile eriyik haldeki malzeme, baskı üzerine istenen biçimde aktarılamamış ve malzeme boşluğa akmıştır. Soğutma fanının da etkisi ile soğuyup katılaşan malzeme spagettiye benzer bir görüntü ortaya çıkarmıştır.

a) Tabladan kalkma ve çarpılma sorunu

Spagetti sorunun ortaya çıkmasına, düzgün yapılmayan tabla kalibrasyonu ve baskı üzerinde yeterli yapışma olmaması halinde, daha önceki bölümlerde de detaylarına yer verildiği üzere, baskı tabladan kalkacak ve dolayısı ile malzeme boşluğa akacaktır.
Çözüm: Baskı kalibrasyonu yapılmalı ve gerekmesi halinde baskının tablaya yapışması adına aksiyon alınmalıdır.

b) Mekanik parçaların düzgün biçimde çalışmaması

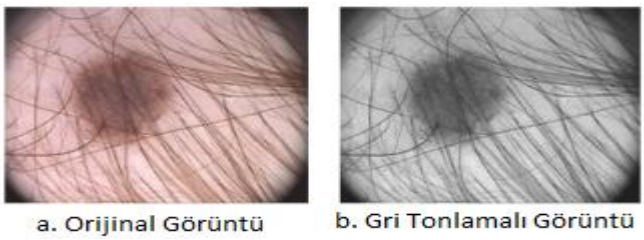
Spagetti sorunu ve birçok diğer sorunun altında yatan bir neden de cihaz üzerinde hareketli parçaların işlevini yerine getirememesidir. Hareketli parçalar, mekanik bakım gereksinimi duymakta ve cihaz üzerinde bulunan kayışlarda gevşeme, ekstrüderin işlevini yerine getirememesi gibi durumlarda, spagetti sorunu ile karşılaşılabilmektedir.
Çözüm: Mekanik parçaların düzenli bakımları gerçekleştirilmeli ve mekanik parçaların istenen biçimde çalıştığından emin olunmalıdır.

3.5 Görüntü İşleme ve Bilgisayarlı Görü Hakkında Genel Bilgiler

Bu bölümde görüntü işleme ve bilgisayarlı görü sistemleri hakkında bilgilere değinilecektir.

3.5.1 Görüntü işleme hakkında genel bilgiler

Görüntü işleme, bir görüntünün dijital bir forma dönüştürülerek, bu verinin anlamlandırılmasına verilen genel isimdir. Verilerin anlamlandırma işlemi genellikle iki boyutlu sinyaller olarak işlenmektedir. Bu sinyaller işlenerek, yüz tanıma, nesne algılama, görüntü sıkıştırma gibi birçok uygulamanın da ön işleme adımıdır.



Şekil 3. 50 Görüntü tonları (Ali M. ve ark. 2022'den değiştirilerek alınmıştır)

Şekil 3.50'de görüldüğü üzere, a. görselinde bir fotoğraftan elde edilen orijinal görüntü, b. görselinde ise görüntü işleme teknikleri kullanılarak elde edilen gri tonlamalı görsele yer verilmiştir.

Görüntü ise piksel adı verilen parametreler ile ifade edilen ve yükseklik ve genişlik boyutlarını içerisinde barındırmaktadır. Pikseller, görüntü üzerinde belirli gölge, opaklık veya renk alan bir noktadır.
Görüntü işleme çalışmalarında birçok görüntü türü kullanılmaktadır.

- İkili Görüntü: Bu görüntü türünde piksel yoğunluğu iki değer kullanılarak temsil edilebilmektedir. Bu değerlerden 0, siyah rengi temsil ederken, 1 değeri beyazı temsil etmekte ve bu şekilde ifade edilen görüntülere ikili görüntü ismi verilmektedir. Bu görüntü türü genellikle, görüntü bölümleme çalışmalarında tercih edilmektedir.



Şekil 3. 51 İkili görüntü (URL 23)

Şekil 3.51'de görüldüğü üzere, ikili görüntüleme türü kullanılarak, renkli bir görüntünün konturları belirgin hale getirilmiştir.

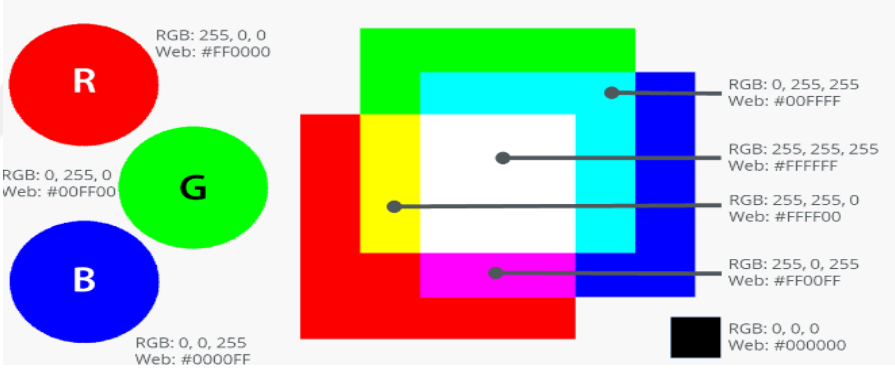
- Gri Tonlamalı Görüntü: Gri tonlamalı veya bir başka ismiyle 8 bit görüntüler, 256 farklı renkten oluşmaktadır. 0 ile 255 arası değer alan görüntülerde, 0 değeri siyah rengi temsil ederken, 255 değeri ise beyaz rengi temsil etmektedir. Arada kalan 254 değer ise gri rengin farklı tonlarını ifade etmektedir.



Şekil 3. 52 Gri tonlamalı görüntü (URL 23)

Şekil 3.52'de RGB renk uzayına sahip bir görüntü, gri tonlamalı versiyona dönüştürülmüştür. Ancak bu dönüşüm sırasında histogram verileri değişiklik göstermemektedir.

- RGB Görüntü: RGB görüntü, gündelik hayatta sıklıkla kullanılan bilgisayar ve tüketici elektroniği ürünlerinde tercih edilen 16 bit matris olan renkli görüntülerdir. RGB ismini, kırmızı, yeşil ve mavi renklerinin İngilizce baş harflerinden almaktadır. Diğer türlerin aksine, üç boyuta sahip olan RGB görüntülerde, her bir boyut 0 ile 255 arasında değerler alabilmekte ve bu değerlerin istiflenmesi ile görüntü oluşturulmaktadır. RGB görüntülerde (0,0,0) piksel değerinde, siyah rengi elde edebilirken; (255,255,255) piksel değerinde ise; beyaz rengin eldesi mümkün olmaktadır. Başka bir örnek verilecek olursa ise, (255,0,0) değeri kırmızı renge sahiptir. Bunun sebebi ilk boyutun kırmızı renge sahip olması ve bu boyutta 255 değerinin kırmızı rengi temsil etmesidir.



Şekil 3. 53 RGB görüntü (URL 6)

Şekil 3.53'te RGB görüntü ve nasıl renk aldığına dair bir örnek verilmektedir. Görüntü işleme birçok farklı tekniğe sahiptir.

- Görüntü geliştirme
- Görüntü restorasyonu
- Morfolojik işleme
- Segmentasyon
- Renk işleme

Olarak kategorize edilmektedir.

Görüntü işlemenin avantajları aşağıdaki gibidir.

- Gelişmiş görüntü kalitesi: Görüntü işleme algoritmaları kullanılarak, görüntülerin görsel kalitesi geliştirilebilmekte ve görüntüler anlamlandırılabilmektedir.
- Otomatik görüntü tabanlı görevlerin gerçekleştirilebilmesi: Görüntü işleme algoritmaları kullanılarak, nesne tanıma, model algılama ve görüntüden ölçüm yapma gibi birçok görüntü tabanlı görev otomatize edilebilmektedir.
- Verimliliğin arttırılması: Görüntü işleme algoritmaları, görüntüleri insan görüsüne oranla çok daha hızlı işleyerek, büyük verilerin çok daha kısa sürede analiz edilebilmesine olanak tanımaktadır.
- Doğruluğun arttırılması: Görüntü işleme algoritmaları, hassas ölçümler ve niceliksel verilerin analiz edilmesinde etkin rol alarak, sonuçların doğruluğunu arttırmaktadır.

Görüntü işlemenin dezavantajları ise;

- Hesaplama maliyetlerinin yüksek olması: Çeşitli görüntü işleme algoritmaları, analiz çalışmalarında güçlü donanımlara gereksinim duymaktadır.
- Giriş verisine bağlılık: Görüntü işleme algoritmalarında, modele girişte verilen algoritmanın doğruluğu ve kalitesi büyük önem arz etmektedir. Hatalı ve kalitesiz beslenen giriş verileri, sonucunda başarısız ve kalitesiz olmasına sebep olmaktadır.
- Çevre faktörlerine bağlılık: Görüntü işleme algoritmaları, kullanılan eğitim verilerinde karmaşık veya zayıf aydınlatma olması durumunda, nesneleri tanımakta zorlanmakta ve model başarısı olumsuz etkilenmektedir.

1) Görüntü geliştirme

Görüntü geliştirme / iyileştirme, görüntülerin daha anlamlı hale getirilme sürecine verilen genel isimdir. Bu iyileştirme ile görüntülerin daha belirli özelliklerin ortaya çıkarılması, görüntülerdeki gürültünün giderilmesi sağlanmaktadır.

Görüntü iyileştirmede kullanılan temel teknikler aşağıdaki gibidir.

- Uzamsal Alan Teknikleri
- Frekans Alan Teknikleri

a) Uzamsal alan teknikleri

Bu tekniğin kullanıldığı çalışmalarda, görüntünün pikselleri üzerinde işlem yapılmaktadır. Uzamsal alan, görüntü düzlemini ifade etmekte ve direkt olarak görüntünün pikselleri üzerinde çalışılmaktadır.

- Nokta işlemleri
    - Kontrast uzatılması: Görsel üzerinde yoğunluk değerleri genişletilerek görüntüdeki kontrast düzeyi geliştirilmektedir.
    - Gama geliştirilmesi: Görüntünün uygun parlaklığının belirlenmesi adına, güç yasası kullanılarak giriş piksellerine dönüşüm uygulanmasıdır.
    - Histogram eşitlemesi: Görüntünün histogramı kullanılarak, görüntüde en sık karşılaşılan yoğunluk değerini yayarak kontrastın geliştirilmesi işlemidir.
- Lokal işlemler
    - Filtreleme: Görüntüdeki pikseller ve komşularına filtreleme uygulanması işlemidir. Uygulanan filtreler sayesinde görüntüdeki gürültülerin azaltılması mümkün olmaktadır.
    - Keskinleştirme filtreleri: Yoğunluk farklarının kullanılarak, görüntü kenarlarının geliştirilmesi işlemidir.

b) Frekans alan teknikleri

Bu teknikler, bir görüntünün Fourier dönüşümünün değiştirilmesini esas almaktadır. Yapılan işlemler sonucu görüntü tekrar uzamsal alan tekniklerine iletilmektedir.

- Fourier dönüşümü: Görüntünün Frekans alana dönüştürülmesi işlemidir.
- Düşük geçiş filtreleri: Bu filtreler kullanılarak, görüntü bulanıklaştırılmakta ve gürültü azaltılabilmektedir.
- Yüksek geçiş filtreleri: Bu filtreler kullanılarak ise, kenarların detayları öne çıkarılmakta ve ayrıntılar geliştirilmektedir.

Görüntü iyileştirme, görüntülerin kullanılabilmesi adına önemli bir ön adım olarak ifade edilmektedir. Görüntü iyileştirme teknikleri birçok sektörde kullanılabilmektedir.

Medikal, tüketici elektroniği, fotoğrafçılık gibi birçok sektör görüntü iyileştirmenin kullanımına örnek olarak gösterilebilmektedir.

2) Görüntü restorasyonu

Görüntü restorasyonu, eskiyen bir görüntünün daha anlaşılır hale getirilebilmesi adına çalışılan bir alandır. Eskimiş görüntülerin, genellikle dönemin teknolojisi dolayısı ile kalitesiz kontrast, yüksek gürültü ve fiziksel bozulma gibi alanlarda oluşturduğu sorunlar nedeniyle bu teknik sıklıkla kullanılmaktadır.
Görüntü restorasyonunun amaçları aşağıdaki gibi sıralanmaktadır.

- Doğruluk: Görüntüdeki bozulma sürecinin tersine çevrilerek, orijinal görüntünün tahmin edilmesidir.
- İyileştirme: Görüntüdeki bozulmanın, orijinal görüntüye benzer biçimde dönüştürülmesinde belirlenen başarı kriteridir.
- Kullanılabilirlik: Geri yüklenen görüntülerin, istenen alanlarda başarılı biçimde kullanılabilmesine verilen isimdir.

Görüntü restorasyonu işlemi öncesinde bazı temel tekniklerin uygulanması gerekmektedir. Bu bölümde bu tekniklere değinilecektir.

a) Bozulma tekniği

Görüntü restorasyonunun gerçekleştirilmesi öncesinde, bozulma sürecinin tanımlanması önem arz etmektedir. Bu model görüntünün bozulma sürecini açıklamanın yanında, kullanıcıya; gürültü, bulanıklık gibi verileri de sağlamaktadır.
Bozulma tekniğinde kullanılan matematiksel ifade, (3.2)'de gösterilmiştir.

$$g(x,y)=h(x,y)*f(x,y)+n(x,y) \tag{3.2}$$

Burada;

- g(x,y) bozulmuş görüntüyü,
- f(x,y) orjinal görüntüyü,
- h(x,y) bozulmanın tepkisini,
- n(x,y) toplam gürültüyü,

ifade etmektedir.

b) Ters filtreleme tekniği

Ters filtreleme, bozulmuş bir görüntünün, bozulma fonksiyonun tersi tarafından filtrelenmesi ile orijinal görüntünün elde edilmesi işlemidir. Bozulma fonksiyonunun tespit edilebildiği durumlarda ve gürültünün az olduğu görüntülerde etkili bir yöntem olarak bilinmektedir.

c) En küçük kareler tekniği

Bu yöntem kullanılarak, bozulmuş görüntü ile orijinal görüntü arasında benzerlik oranı maksimum seviye çıkaran uygun filtreyi bulabilmek adına küçük kareler kullanılmaktadır. Gürültülü görsellerde, ters filtrelemenin sahip olduğu dezavantajlara sahip olmadığından, bu görsellerde tercih edilmektedir.

Görüntü restorasyonu, karmaşık model ve filtreler kullanılarak bozulmuş görüntülerin orijinal hallerine döndürülmesini amaç edinen temel bir tekniktir. Bu süreçte öncelikle bozulma sürecinin doğru biçimde tespit edilmesi ve modellenerek geri dönüştürülmesi önemlidir. Geri dönüştürme sürecinde uygun filtreler kullanılarak daha yüksek kalitede görüntülerin eldesi mümkün olmaktadır.

3) Morfolojik işleme

Morfolojik işleme, görüntüleri şekillerine göre işleyen tekniğe verilen isimdir. Gri tonlara sahip görüntülere uygulanan morfolojik işleme, görüntüler üzerinde şekillerin tespit edilerek, bölgelerin tanımlanmasını esas almaktadır. Morfolojik işleme;

- Şekil analizi: Görüntülerden şekillerin detaylarının çıkarılması ve analiz edilmesi
- Gürültü azaltma: Özellikle küçük boyutlardaki görüntülerde bulunan gürültülerin görüntüden çıkarılması
- Görüntü basitleştirilmesi: Görüntü üzerindeki detayların belirgin hale getirilerek, daha anlaşılır görüntüler elde edilmesi

amaçları ile kullanılmaktadır.

Morfolojik işleme teknikleri, yapılandırma elemanı adı verilen, girdi görüntülerin araştırılması adına kullanılan küçük piksel matrislerini kullanmaktadır. Bu bölümde bu matrisler kullanılarak uygulanan temel tekniklerden bahsedilecektir.

a) Erozyon tekniği

Erozyon, ön planda bulunan nesnenin sınır etkilerini azaltarak, görüntünün özellik yoğunluğunun düşürülmesi için kullanılmaktadır. Bu teknik özellikle, görüntü üzerindeki küçük beyaz veya siyah noktaların kaldırılması için kullanılmaktadır.

b) Genişleme tekniği

Genişleme, görüntü içerisindeki piksellerin, görüntüdeki nesnelerin sınırlarına kadar genişletilmesinde görev almaktadır. Bu teknik sayesinde, nesne boyutları büyütülebilmektedir.

c) Açılış tekniği

Açma tekniği ile görüntünün arka planında bulunan küçük nesnelerin kaldırılabilmesi sağlanabilmektedir. Bu sayede görsel boyutları büyütülürken, arka planda bulunan küçük kusurların giderilebilmesi mümkün olmaktadır.

d) Kapanış tekniği

Kapanış tekniği ile ise, arka plan üzerinde değişiklik gerçekleştirilmeden, ön plandaki istenmeyen hatalar giderilebilmektedir.

Morfolojik işleme, görüntüdeki özellikleri şekline odaklanan ve görüntü işleme çalışmalarında sıklıkla kullanılan bir yöntemdir. Morfolojik işleme teknikleri kullanılarak, görüntüde mevcut olarak bulunan yapılarak dair önemli anlamlar çıkarılabilmektedir. Bu teknikler sayesinde, gürültü azaltma, şekil çıkarman ve görüntü iyileştirme alanında çalışmalar gerçekleştirilebilmektedir. Morfolojik işleme tekniklerinin, medikal görüntü işleme, parmak izi tanımlama ve uzaktan kontrol sistemlerinde kullanımına sıklıkla rastlanmaktadır.

4) Görüntü segmentasyonu

Görüntü segmentasyonu, dijital bir görüntünün birçok kategoriye bölünmesi işlemine verilen isimdir. Bu bölme işleminin amacı ise, görüntünün daha kolay temsil edilebilmesini sağlamanın yanında, daha anlamlı biçimde analiz edilmesini sağlamaktır. Görüntü segmentasyonu ek olarak, görüntü üzerinde nesne ve sınırların konumlarını belirlemek için de kullanılmaktadır.

Görüntü segmentasyonu, farklı kullanım amaçlarına bağlı olarak, farklı tekniklere sahiptir.

a) Eşik değer tekniği
   - Evrensel eşik değer tekniği: Gri tonlara sahip bir görüntünün, ikili görüntüye dönüştürülmesi için kullanılan yöntemdir. Görüntünün yüksek kontrasta sahip olduğu durumlarda, daha başarılı sonuçlar alınabilmektedir.
   - Uyarlanabilir eşik değer tekniği: Görüntünün farklı bölgeleri için birden fazla eşik değerin hesaplandığı ve değişen aydınlatma şartlarına bağlı olarak uyarlanabilen tekniktir.

b) Kenar segmentasyonu tekniği

- Kenar algılama filtresi tekniği: Görüntüde piksel yoğunluğunun değişiklik gösterdiği kenar noktalarını bulabilmek için kullanılan filtrelerdir.
- Gradyan operatörleri tekniği: Gradyan büyüklüğünde maksimum ve minimum değişikliklerin tespit edildiği tekniktir.

c) Bölge tabanlı segmentasyon tekniği

- Bölge büyütme tekniği: Temel bir noktanın belirlenmesi ve benzer özelliklere sahip komşu piksellerin hesaba katıldığı tekniktir.
- Bölge bölme ve birleştirme tekniği: Görüntü üzerindeki tüm bölgelerin yeterli homojenlik kriterini sağlayana kadar bölünmesi ve birleştirmesini esas alan tekniktir.

d) Kümeleme tekniği

- K-kümeleme tekniği: Görüntüde bulunan piksellerin k-ortalama algoritması kullanılarak özellik benzerliklerine göre kümelenmesi yöntemidir.
- Hiyerarşik kümeleme tekniği: Her bir pikselin bir küme içerisinde başlatılması ve sonrasında benzerliklerine göre bu kümelerin birleştirilmesini esas alan tekniktir.

Görüntü segmentasyonu, görüntülerin analizi sürecinde önemli bir adımdır ve görüntülerden yararlı ve kullanılabilir bilgilerin eldesini kolaylaştırmaktadır. Görüntü tabanlı sistemlerde, doğruluk ve verimliliğini arttırılmasında önemli rol oynayan görüntü segmentasyonu, belirli görev ve işlenecek görüntünün yapısına da bağlı olarak farklı teknikler ile kullanılmaktadır. Medikal, otonom sürüş ve yüz tanıma gibi alanlarda aktif kullanılan görüntü segmentasyonu, yapay zekanın da gelişimi ile kullanımı yaygınlaşan tekniklerden biri haline gelmiştir.

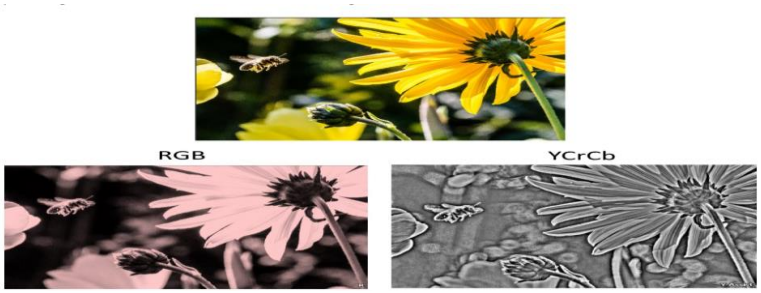
5) Renk işleme

Renk işleme, görüntülerin çeşitli renk uzaylarına göre geliştirilmesi, yorumlanması ve anlamlandırılmasını içeren görüntü işleme yöntemidir. Renk işleme çalışmaları ile, renklerin kullanıcı için daha belirgin ve anlaşılır hale gelmesine sağlarken; segmentasyon, algılama ve renklendirme gibi alanlarda farklı görevlerinde gerçekleştirilmesine olanak tanımaktadır.

Farklı renk modellerinin kullanımı, renk işleme çalışmalarında çok önemlidir. Her bir renk modeli çeşitli amaçlar ile göreve avantaj ve dezavantaj sağlayabilmektedir. Bu bölümde bu renk modellerine ve etkilerine değinilecektir.

a) Renk uzayları

- RGB renk uzayı: Kırmızı, yeşil ve mavi renklerinin İngilizce isimlerinin baş harflerinden ismini alan RGB, görüntülerin televizyon ve bilgisayar gibi tüketici elektroniği sistemlerinde algılanması ve temsil edilmesi için kullanılmaktadır. İnsan görüşü açısından sıklıkla kullanılmasına rağmen, görüntü işlemede pek sezgisel olmadığı düşüncesi ile nadir biçimde kullanılmaktadır.
- HSV renk uzayı (Ton, Doygunluk, Değer): İsmini; ton, doygunluk ve değer kelimelerinin İngilizce baş harflerinden alan HSV renk uzayı, insanın anlaması açısından daha sezgisel olarak ifade edilmekte, genellikle renk tabanlı görüntü bölütleme işlemlerinde tercih edilmektedir.
- YCrCb renk uzayı: Video sıkıştırma ve işlemede kullanılan teknik, görüntü parlaklığı ile renk kanallarının ayrılmasına olanak tanımaktadır.



Şekil 3. 54 RGB ve YCrCb renk uzayı (URL 31)

Şekil 3.54'te RGB ile YCrCb renk uzayı arasında renk işleme temellerinin farkları görülmektedir.

b) Renk geliştirme

- Histogram eşitleme tekniği: Görüntüdeki kontrastın iyileştirilmesi amacı ile kullanılan tekniktir.
- Doygunluk ayarı: Görüntü içerisindeki renklerin istenene uygun biçimde daha sıcak veya soğuk tonlara dönüştürülmesini sağlayan tekniktir.
- Beyaz dengeleme: Farklı koşullar altında, görüntünün doğala daha yakın görünmeleri için aydınlatma koşullarının dijital ortamda ayarlanmasına verilen isimdir.

c) Renk dönüşümü

Bir renk uzayından, bir diğer renk uzayına geçiş işlemi, ihtiyaçlar dahilinde gerçekleştirilen ve avantajlara sahip bir tekniktir. Bu kısımda sıklıkla gerçekleştirilen iki dönüşüm tipinden bahsedilecektir.

- RGB'den HSV'ye dönüşüm: Önceki bölümlerde bahsedilen renk eşik değer yöntemi tercih edildiğinde kullanılan yöntem ile, renk doygunlukları kolaylıkla dengelenebilmektedir.
- RGB'den YCrCb'ye dönüşüm: Video işleme çalışmaları için gerçekleştirilen renk uzayı dönüşümüdür.

d) Renk segmentasyonu

- HSV renk uzayında eşik değer: Aydınlatma farklılıklarına karşı dayanıklılığı nedeniyle, görselleri renge göre segmente edebilen tekniktir.
- K-renk uzayında kümeleme: Bir görüntüyü anlamlı renk bölgelerine ayırmak için kullanılan tekniktir.

Renk işleme, dijital görüntülerin çeşitli alanlarda uygulanabilirliğini arttırmaktadır. Nesne tanıma doğruluğunun geliştirilmesi, ışık etkilerinin düzenlenmesi, görüntü manipülasyonu gibi alanlarda kolaylık sağlayan renk işleme, kullanıcının görüntüyü daha kolay biçimde anlaması ve yorumlayabilmesine olanak tanımaktadır. Diğer görüntü işleme tekniklerinde de olduğu gibi, renk işleme; medikal, uzaktan algılama ve fotoğrafçılık gibi alanlarda sıklıkla tercih edilen bir yöntemdir.

3.5.2 Bilgisayarlı görü hakkında genel bilgiler

Bilgisayarlı görü, yapay zekanın gelişimi ile gündeme gelen ve birçok alanda kullanılan bir teknolojidir. Bilgisayarlı görü, insan görme sistemi ile kolaylıkla tespit edilemeyen, başka bir deyişle insan görüşü yerine ilgili çalışmaların bilgisayarlar tarafından gerçekleştirilerek, çeşitli görevlerin tamamlanması işlemine verilen isimdir. Bilgisayarlı görü sistemlerinde veri sayısı büyük bir önem arz etmektedir. Günümüz teknolojisinin gelişimi ile veri toplama ve depolama sistemleri önemli ölçüde gelişmiştir. Bu gelişim ile bilgisayarlı görü sistemlerine beslenen veri de artış göstermekte ve dolayısıyla bilgisayarlı görü sistemleri de günden güne gelişimini sürdürmektedir.
Makinelerin görmesi fikrinin, insan görüşünden türetilmesi ile aşağı gösterilen alanlar da ortaya çıkmıştır.

- Nesne tanıma
- Yüz tanıma
- Resim parçalama
- Görüntü sınıflandırılması
- Nesne takibi

Görüntü işleme, bilgisayarlı görünün bir alt kümesidir. Görüntü işleme temelini kullanarak çeşitli algoritmalar ile bilgisayarlı görü teknolojisi oluşmaktadır.

1) Bilgisayarlı görü çalışma prensibi

Bilgisayarlı görü sistemleri, aynı makine öğrenmesi modellerinde olduğu gibi, modele veri beslenerek, bu verinin sisteme tanıtılması ve ardından gösterilen yeni bir görsel üzerinde benzerlik kurması temeline dayanmaktadır. Bu nedenle önceki bölümde de bahsedildiği üzere, doğru veri sayısı arttıkça, model performansı artış göstermektedir.
Yüzbinlerce köpek resminin tanıtıldığı varsayılsın, bu durumda tanıtılan veriler, bilgisayarlı görü algoritmasında eğitilerek, bu fotoğrafların;

- Renk
- Şekil
- Desen
- Şekiller arası mesafe

Gibi özellikleri ayrıştırılarak depolanacaktır.

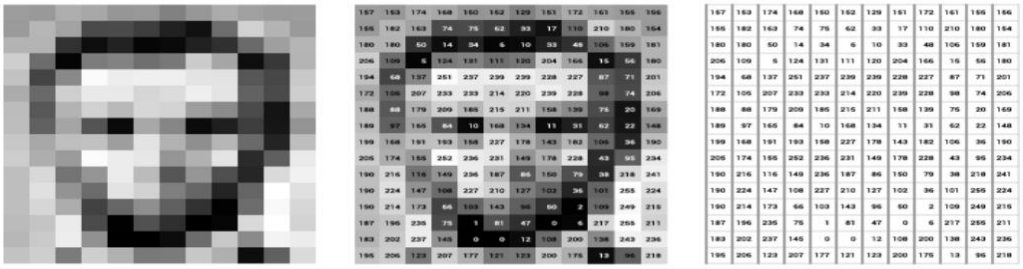
Bu sayede yeni bir köpek resmi geldiğinde, model depolamış ve anlamlandırılmış olduğu veriler ile yeni görseli karşılaştırıp benzerlik kuracak ve yeni görselinde bir köpeğe ait olduğunu tahmin etme eğiliminde olacaktır.
Bilgisayarlı görü 3 temel adımdan oluşmaktadır. Bunlar;

- Görüntüleri içeren veri kümesinin toplanması
- Veri kümesinin işlenmesi
- Verilerin anlamlandırılması

Adımlarıdır.

Görüntüler, piksellerden oluşmaktadır ve piksel bir görüntünün en küçük üyesidir. Bilgisayarlar, görüntüleri piksel dizileri biçiminde ele akmakta ve görseldeki her bir piksel, üç ana rengi içeren RGB renk uzayında temsil edilmektedir. Tüm piksellerin bir araya toplanması ile ise dijital görüntü elde edilmektedir. Bilgisayarlı görü teknolojisi,

dijital görüntülerin matris hale gelmesinin ardından, bu matrisleri inceleyerek, bu verileri anlamlı hale getirmektedir.



Şekil 3. 55 Bilgisayarlı görünün bir görüntüyü tanımlaması (URL 44)

Görselde görüldüğü üzere, görsel piksellere ayrılmış ve koordinat değerleri verilmiştir. Burada her bir piksel 0 ile 255 arasında değerler almaktadır. 255 değeri "siyah" rengi ifade ederken, 0 değeri ise "beyaz" rengi ifade etmekte ve bu değerlere yaklaştıkça renkler de benzer biçimde değişmektedir. İnsan görüsünde, görüntü anlam ifade ederken, pikselleri yorumlamak zordur. Ancak bilgisayarlar, pikselleri içeren matrisleri kullanarak karmaşık hesaplar gerçekleştirmekte ve piksel değerlerinin komşuları ile arasında ilişkiyi inceleyerek, görüntünün bir insan yüzüne ait olduğunu belirleyebilmektedir. Bu karmaşıklığı giderebilmek adına, veri setine eklenen görselleri kullanarak bir formül geliştirilmekte ve benzerlikler bu şekilde özel veri setlerinde tespit edilebilmektedir.

2) Bilgisayarlı Görü Görevleri

Temelde, bilgisayarlı görme görevleri, bilgisayarların gerçek dünya verilerinin yanında dijital görüntülerin de anlamlandırılmasında rol oynamaktadır. Yapay zeka teknolojilerinin de gelişimi ile, birçok popüler konuyu çözümler geliştirmiştir.
Bu görevler;

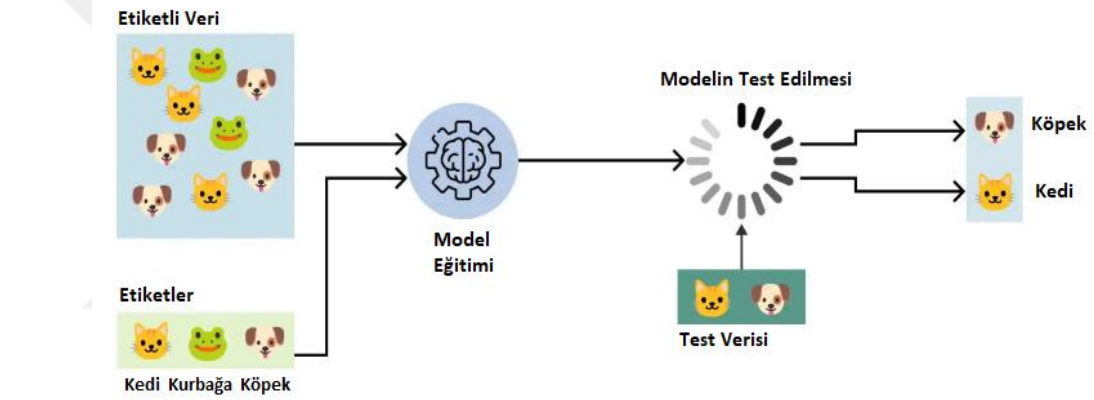
- Görüntü Sınıflandırılması
- Nesne Algılama
- Görüntü Segmentasyonu
- Özellik Eşleştirme

Olarak sıralanmaktadır.

Çalışmada kullanılmaması sebebi ile görüntü segmentasyonu ve özellik eşleştirme görevlerine değinilmeyecektir.

a) Görüntü sınıflandırılması

Görüntü sınıflandırılması, bilgisayarlı görü teknolojisinin en sık kullanılan uygulamalarından biridir. Temel anlamda görüntü sınıflandırılması, bilgisayarlı görü algoritmasına verilen önceden sınıflandırılmış örnek görüntüler kullanılarak eğitilmesini ardından verilen ve algoritma tarafından tanınmayan bu verinin, yapılan eğitimler neticesinde hangi sınıfa ait olduğunu tahmin etmesini esas almaktadır.



Şekil 3. 56 Görüntü sınıflandırılması adımları (URL 42)

Şekil 3.56'da görüntü sınıflandırma çalışmalarının adımlarına yer verilmiştir.

Karşılaşılan soruna bağlı olarak, farklı türlerde görüntü sınıflandırması kullanmak gerekmektedir.

- İkili Sınıflandırma: İkili sınıflandırma, görüntüleri etkilemek için iki adet sınıfa sahip olan çalışmalarda kullanılmaktadır. Bir ürünün kusurlu veya kusursuz olduğunu tespit edilmesi beklenen bir çalışmada veya bir görsel veya videoda "kedi" veya "köpek tespit gerektiren çalışmalarda, ikili sınıflandırma türüne başvurulmaktadır.

- Çoklu Sınıflandırma: İkili sınıflandırma, iki adet sınıf bulunan görsel veya videolarda kullanılırken; çoklu sınıflandırma, üç ve daha fazla sınıfın bulunduğu görevlerde kullanılmaktadır.
- Çoklu Etiket: Çoklu sınıflandırma çalışmalarında her bir görselin bir adet sınıfa ait olmasına karşın, çoklu etiketleme türünde; bir öğe birden fazla sınıfa sahip olabilmektedir.
- Hiyerarşik Sınıflandırma: Hiyerarşik sınıflandırma, sınıfların benzerliklerine bağlı olarak hiyerarşik bir yapı içerisinde organize edilmesine olanak tanımaktadır. Hiyerarşinin üst tarafında bulunan sınıflar, alt tarafında bulunan sınıfları kapsamakta ve daha genel bir yargıyı ifade etmektedir.

Görüntü sınıflandırma görevleri, benzerliklerine rağmen nesne algılama çalışmalarından ayrılmaktadır. Görüntü sınıflandırma çalışmalarında, görsel veya video içerisinde hangi sınıfa ait eleman bulunduğu tespit edilirken, nesne algılama çalışmalarında görüntü sınıflandırmaya ek olarak, tanımlanan elemanın konumuna da bir dikdörtgen kutu içerisine alınarak yer verilmektedir. Nesne algılama görevlerinin detaylarına bir sonraki bölümde detaylı şekilde yer verilecektir.



Şekil 3. 57 Görüntü sınıflandırma ve nesne algılama (URL 42)

Şekil 3.57'de ilk görselde, modelin sonucunun kedi olarak görülmesinin yanında, nesne algılama çalışmalarında son resimde görüldüğü gibi, sınıflandırma ve konum bilgisini

belirtmek için bir dikdörtgen kutunun varlığı görülmektedir. Bu kutuya sınırlayıcı kutu ismi verilmektedir.

Önceki bölümlerde, bir görüntünün binlerce piksellerden oluşabildiği ve görüntü işleme çalışmalarının bu piksellerin analiz edilerek gerçekleştirildiğinden bahsedilmişti. Görüntü sınıflandırma teknikleri de aynı biçimde belirli bir görüntünün pikseller biçiminde analiz edilmesi ve matrisler biçiminde ele alınması temeline dayanmaktadır. Bu piksellerin analizi sonrası, piksellerin bir araya gelmesi ile sınıflara ayrılmaktadır. Görüntü sınıflandırma çalışmasının yapılacağı görevlere bağlı olarak farklı makine öğrenmesi algoritmaları kullanmak mümkün olmaktadır.



Şekil 3. 58 Görüntü sınıflandırılması temel adımları

Şekil 3.58'de gösterildiği gibi, farklı algoritmaların kullanımına ihtiyaç duyulsa dahi, görüntü sınıflandırma çalışmaları üç temel adımı içermektedir. Öncelikle görüntülerin ön işleme adımları tanımlanmaktadır, ardından bu görüntülerden anlamlı veriler ayıklanmakta ve son olarak nesnelerin sınıflandırılması işlemleri gerçekleştirilmektedir.

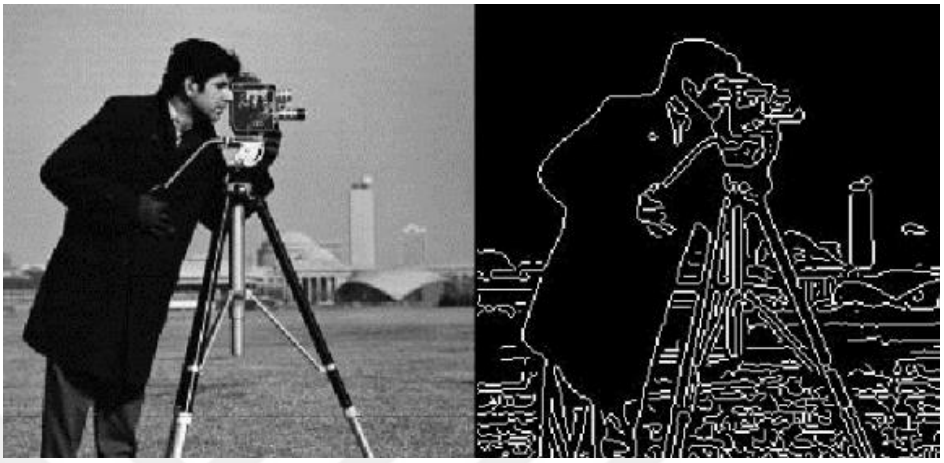
Verilerin ön işleme aşamasında, anlamlandırılacak verilerin kalitesini arttırabilmek adına çalışmalar gerçekleştirilmektedir. Bu şekilde sonraki adım olan özellik çıkarımı aşamasında başarı oranı artacaktır. Bu bölümde, veri kalitesinin arttırılması için gerçekleştirilen ön işleme adımlarına değinilecektir.

- Görüntü Boyutlandırma: Görüntü boyutları, modelin eğitim başarısının arttırılabilmesi adına değiştirilebilmektedir. Bu sayede, eğitim verileri benzer boyutlara getirilerek, daha başarılı modellerin eldesi mümkün olmaktadır.

- Görüntü Kırpma: Eğitim verisi için kullanılacak bir görsel üzerindeki gereksiz detaylar çıkarılarak, model eğitim süresi kısaltılabilmekte ve model başarısı arttırılabilmektedir.
- Görüntü Normalizasyonu: Görüntü normalizasyonu, görüntünün piksel değerlerinin standart bir dağılıma uygun olmasını sağlamak amacı ile gerçekleştirilmektedir. Bu sayede eğitim verileri benzer bir ölçeğe sahip olacak ve modelin analiz süreci kolaylaşacaktır.
- Gürültü Azaltma: Dijital görüntüler üzerinde, modelin performansını doğrudan etkileyen gürültü ismi verilen yapılar bulunabilmektedir. Gauss filtreleme veya medyan filtreleme gibi teknikler kullanılarak; gürültü, görselden temizlenebilmektedir.
- Veri Sayısı Büyütme: Veri sayısı, makine öğrenmesi ve derin öğrenme çalışmalarında büyük önem arz etmektedir. Veri sayısını arttırmanın sıklıkla kullanılan bir yolu; görüntülerin döndürülmüş, yakınlaştırılmış, ölçeklendirilmiş, parlaklık ve kontrastı değiştirilmiş hallerinin veri kümesine eklenmesidir. Bu sayede eğitim veri kümesi çeşitliliği arttırılarak, model performansının arttırılması sağlanabilmektedir.

Özellik çıkarımı ise, görsellerin birbirinden ayrılabilmesi için kullanılan ve farklılığı oluşturan kalıpların eldesi için kullanılan bir tekniktir. Görüntü içerisinde bulunan desenler sınıfların farklılaşmasına neden olabilmekte ve bu nedenle farklı sınıflara özgü desenler bulunabilmektedir. Algoritmalar bu desenleri ve desenlerin bağlı oldukları sınıfları öğrendiklerinde, daha önce sisteme girmemiş verilerde sınıflandırma işlemini gerçekleştirebilmektedir. Kuş ve kedi sınıflarına sahip, iki sınıflı bir görüntü sınıflandırma modeli örneğinden ilerlenecek olunursa model; kuş görsellerinden kuşun kanatları, tüy tipi, gagası gibi özellikleri çıkararak, kediye ait olan tüy, pati, pati sayısı gibi özellikler ile farklılık kurabilecektir. Bu sayede, farklar net biçimde belirlenerek, eğitim için seçilecek makine öğrenmesi algoritmasının performansı arttırılabilecektir. Özellik çıkarım tekniği kullanılmadığı durumlarda ise, makine öğrenmesi modeli, özellik farkları yerine tüm görselleri tarayacak ve dolayısıyla işlem gücü ve maliyeti ciddi oranda artmaktadır. Özellik çıkarımı, kenar tespiti, doku analizi ve ayrıca sonraki kısımlarda da detaylı biçimde bahsedilecek olan CNN algoritması ile kullanılmaktadır.

- Kenar Tespiti: Kenar tespiti, bir görüntüdeki bölgeler arasındaki sınırların tespit edilmesini sağlayan, görüntüdeki nesnelerin şekli ve yapısı hakkında kullanıcının bilgi edinebilmesi adına kullanılan bir tekniktir.



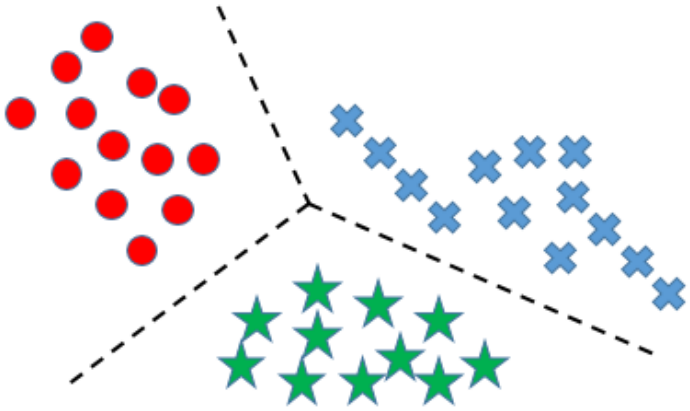
Şekil 3. 59 Kenar tespiti (George M. ve ark. 2013)

Şekil 3.59'da kenar tespiti tekniğine ait örnek bir çalışma gösterilmektedir.

- Doku Analizi: Doku analizi, bir görüntü içerisinde tekrar eden desenlerin tespit edilmesini sağlayan tekniktir. Bu teknik sayesinde, görüntü içerisinde farklı malzeme ve yüzeylerin tespiti sağlanabilmektedir.

Görüntü sınıflandırma görevlerini gerçekleştirebilmek adına kullanılan birçok makine öğrenmesi algoritması bulunmaktadır. Bu kısımda öncelikle denetimli ve denetimsiz öğrenme kavramlarına değinilecektir.

Denetimli öğrenme, eğitim öncesinde etiketlenmiş veri kümesi barındırmaktadır. Bu yöntemde modele verilen yeni girdilerin, etiketlenmiş veri ile benzerlikleri tespit edilmekte ve en yüksek benzerliğe ait olduğu sınıfa atanmaktadır.



Şekil 3. 60 Denetimli öğrenme (URL 21)

Şekil 3.60'ta görüldüğü üzere, denetimli öğrenme modellerinde, sınıflar net şekilde ayrılmaktadır. Denetimli öğrenmenin, denetimsiz öğrenmeden en büyük farkı ise, eğitim öncesinde sınıf etiketlerinin belirlenmiş olmasıdır. Eğitim sonrasında verilen görsellerin sonucu, eğitilen verilerden yararlanarak tahminde bulunulmakta ve doğru sınıf verisi elde edilmeye çalışılmaktadır.
Farklı amaç ve gereksinimler doğrultusunda birçok denetimli öğrenme algoritması tercih edilebilmektedir. Bir sonraki bölümde, bu algoritmalara değinilecektir.

- Lojistik Regresyon

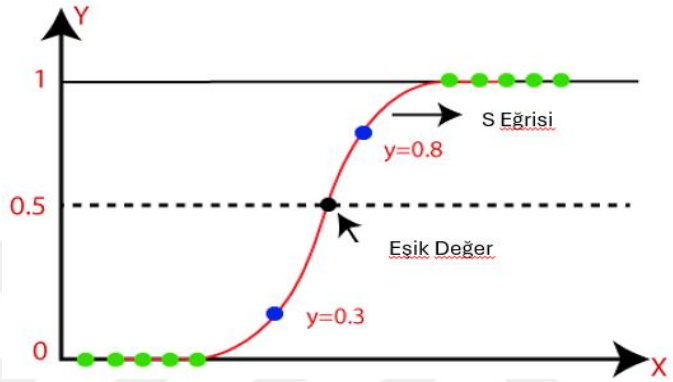
Lojistik regresyon, ikili sınıflandırma görevlerini gerçekleştiren ve genel tabiri ile bir görüntünün bir sınıfa ait olup olmamasını sorgulayan sınıflandırma algoritmasıdır.
Lojistik regresyon, tahminleri ve olasılıkların haritalanabilmesi için "sigmoid" adı verilen bir fonksiyon kullanmaktadır. Sigmoid fonksiyonu herhangi bir gerçek değerin 0 ile 1 değeri arasındaki aralığa dönüştüren bir eğri ile temsil edilmektedir. Modelin çalıştırılması sonrası elde edilen değer, eşik değerin üzerindeyse; bu görüntünün ilgili sınıfa ait olduğu tayin edilmektedir. Eşik değerin altında ise; bu görüntünün ilgili sınıfa ait olmadığı sonucu alınmaktadır.

$$f(x) = \frac{1}{1 + e^{-x}} \tag{3.3}$$

- e = Doğal logaritma tabanını
- x = Dönüştürülmek istenen sayısal değeri

ifade etmektedir.

Sigmoid fonksiyonu (Şekil 3.61) ile elde edilen sonuç, lojistik regresyon modelinde kullanılarak aşağıdaki gibi bir "S" eğrisi oluşmakta ve sınıf belirlenmektedir.



Şekil 3. 61 Lojistik regresyon eğrisi (URL 19)

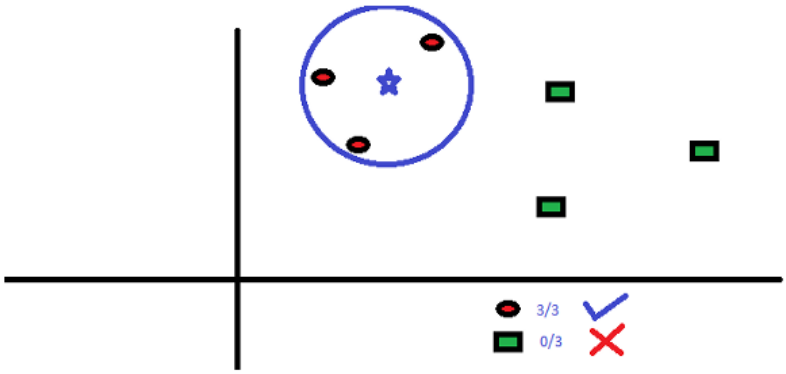
Bu kısımda, lojistik regresyona temel anlamda değinilmiştir. Çalışmada kullanılmadığı için daha detaylı bilgiye yer verilmemiştir.

- K-en yakın komşular

K-en yakın komşu sınıflandırması, kolay anlaşılabilirliği ve yorumlanabilirliği sayesinde tercih edilen bir sınıflama algoritmasıdır. KNN kısaltması ile de bilinen algoritma, önceden eğitilen verilerde sınıf bilgilerine belirli değerler tanımlamakta, yeni beslenen verinin hangi değere daha yakın olduğunu analiz ederek, sonucun o sınıfa atanmasını esas almaktadır. "Öklid mesafesi" gibi fonksiyonları kullanarak, giriş veri noktası ile tüm eğitim örnekleri arasındaki tüm mesafeler hesaplanarak, en yakın "K" noktalarını belirlemekte ve etiket olarak atamaktadır.

- Çıktıların kolay yorumlanabilmesi
- Hesaplama süresi
- Tahmin gücü

Parametrelerinde literatürde başarılı gösterilen KNN algoritması, bu sebeple sıklıkla tercih edilmektedir.



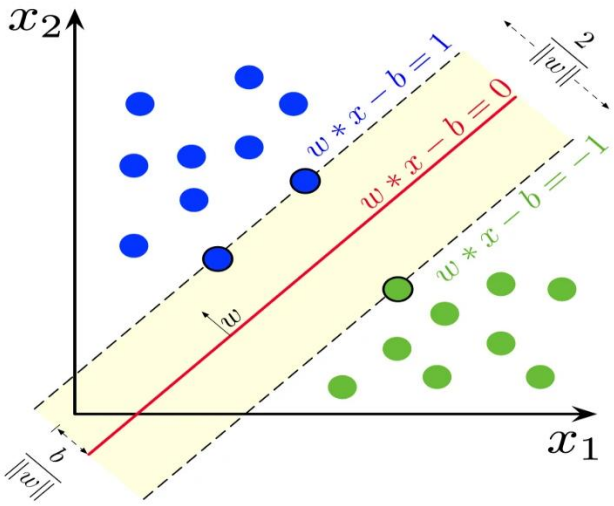
Şekil 3. 62 K-en yakın komşular (Agarwal A. ve ark. 2021)

Şekilde yıldız ile ifade edilen görselin, kırmızı veya yeşil sınıfa atanması istenmektedir. Algoritma içerisinde belirlenen bir k faktörü yardımı ile, kendisine en yakın Öklid mesafesine sahip k adet eleman bulunmakta ve çoğunluğun sahip olduğu değere atama gerçekleştirilmektedir. Bu örnekte k = 3 belirlenmiş ve kendisine Öklid mesafesi ile hesaplanan en yakın üç noktanın üçü de kırmızı sınıfa aittir. Bu nedenle yüksek bir güven yüzdesi ile, yıldızın, kırmızı sınıfa ait olduğu tahmin edilmektedir.
Bu kısımda, k en yakın komşular algoritmasına temel anlamda değinilmiştir. Çalışmada kullanılmadığı için daha detaylı bilgiye yer verilmemiştir.

- Destek vektör makinesi

Destek vektör makinesi, lojistik regresyon ve k en yakın komşular algoritmasına oranla daha az hesaplama gücü kullanılarak, önemli bir doğruluk performansına erişebilmektedir. SVM (Support Vector Machine) olarak da kısaltılan algoritma, regresyon ve sınıflandırma görevlerinde kullanılabilmektedir. Destek vektör makinesi algoritması, karmaşık ancak küçük ve orta boyutlu veri kümelerinde yüksek başarı gösterebilmektedir. SVM, N (özellik sayısı) boyutlu bir uzayda veri noktalarını belirgin bir şekilde sınıflandıran bir hiper düzlem bulmaya çalışmaktadır. İki verinin sınıflandırılabilmesi için birçok hiper düzlem bulunmaktadır. Algoritmanın amacı her iki

sınıf arasındaki mesafenin maksimum olduğu bir düzlemi tespit etmektir. Bu sayede, sınıfların birbirinden net şekilde ayrılması ve yeni girdilerin daha kesin şekilde sınıflarının tayin edilmesi sağlanacaktır.

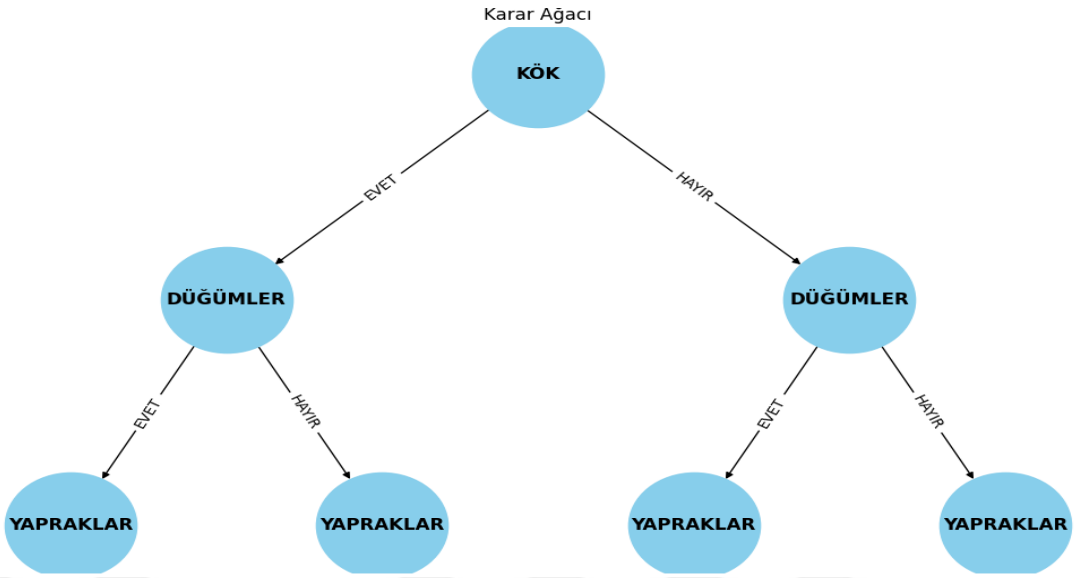


Şekil 3. 63 Destek vektör makinesi (URL 34)

Şekil 3.63'te görüldüğü üzere sınıfların ayrılabilmesi için kesikli çizgiler ile gösterilen maksimum marjin bölümleri belirlenmiştir. Birçok hiper düzlem arasında iki sınıf arasındaki en yüksek mesafe bu hiper düzlemde sağlandığı için ilgili bölgelere maksimum marjin bölgeleri ismi verilmektedir. Lojistik regresyonda sigmoid fonksiyonu kullanılarak değerlerin 0 ile 1 arasına sıkıştırıldığından bahsedilmişti. Destek vektör makinesi algoritmasında ise, 1 ile -1 arasında değerler elde edilmektedir. 1 değeri üstündeki ve -1 değeri altındaki çıktılar, farklı sınıf ile tanımlanmaktadır.

- Karar ağaçları

Karar ağaçları, görüntü sınıflandırma algoritmaları arasında sıklıkla tercih edilen bir başka algoritmadır. Model, verilerin özelliklerine göre ağaç dallarına benzeyen bir karar şemasına yerleştirilmektedir. Bu şemada "evet" ve "hayır" cevaplarına bağlı olarak bir sonraki adıma geçilmekte ve son aşamada çıktının hangi sınıfa ait olduğuna karar verilmektedir. Ağaç yapıları hiyerarşiktir ve kök düğüm, dallar, iç düğümler ve yaprak düğümlere sahiptir.



Şekil 3. 64 Karar ağacı

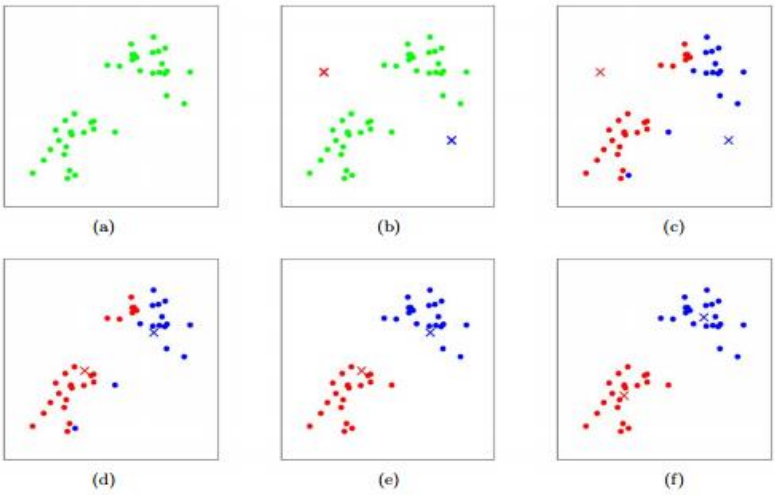
- Kök düğüm: Tüm popülasyonun veya veri kümesinin koşullara bağlı olarak bölünmeye başladığı ilk düğümdür.
- Karar düğümü: Kök düğümlerin bölünmesi ile oluşan düğümlere verilen isimdir. Bu düğümler koşulları temsil etmektedir.
- Yaprak düğümü: Daha fazla bölünmenin mümkün olmadığı durumda, sonuçları belirten düğümlerdir.
- Alt ağaç: Karar ağacının alt bölümünü temsil eden bölümdür.

Şekil 3.64'te görüldüğü üzere, kök düğümden başlayarak modele sorular sorulmakta ve cevaplarına bağlı olarak yaprak düğümlere ulaşılmaya çalışılmaktadır. Bu sayede görselin veya verinin hangi sınıfa ait olduğu tespit edilmektedir.

Denetimsiz öğrenme ise, etiketlenmemiş veri kümelerinin analiz edilmesi ve kümelenmesi adına kullanılan makine öğrenmesi türüdür. Bu algoritmalar, dışarıdan manipülasyona gerek duymadan, veriler arasındaki benzerlikleri ve farklılıkları tespit ederek gruplamalar gerçekleştirebilmektedir. Bu bölümde sıklıkla kullanılan denetimsiz öğrenme algoritmalarına değinilecektir.

- K ortalama kümeleme

K ortalama kümeleme algoritması, benzer veri noktalarının bir arada gruplandırılması amacı ile kullanılan denetimsiz sınıflama algoritmalarından bir tanesidir. K sayısı bir hiper parametre olup, veri kümesinde ihtiyaç duyulan merkez sayısını ifade etmektedir. Belirlenen k sayıda merkeze, girdi olarak verilen en yakın merkez noktalarına yerleşecek şekilde konumlandırılmaktadır. Başlangıçta rastgele konumlarda belirlenen merkez noktaları, sürecin devamında merkez noktaların konumlarının optimize edilebilmesi adına iterasyonlar ile yeniden belirlenir. Merkezlerin stabil hale gelmesi ya da belirlenen iterasyon sayısına ulaşıldığında, nihai merkez konumları belirlenmiş sayılmakta ve işlem tamamlanmaktadır.



Şekil 3. 65 K ortalama kümeleme algoritması (Celik S. ve ark. 2021)

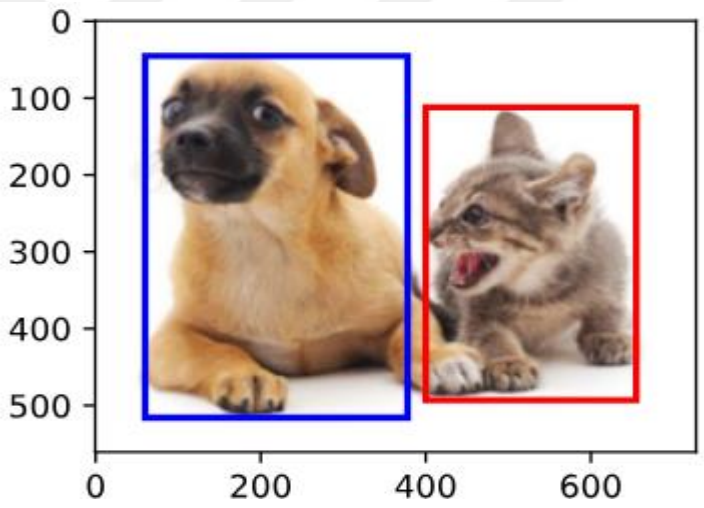
Şekil 3.65'te a. grafiğinde herhangi Merkez noktası bulunmayan veriler gözlemlenmektedir. Ardından b. Grafiğinde iki adet hayali merkez noktası belirlenmekte, c. Grafiğinde ise veriler en yakın oldukları merkez noktalarına ait olacak şekilde kümelenmektedir. 3 ek iterasyon sonucunda, final merkez noktaları belirlenmiş ve veriler son kez kümelenmiştir.

Bu çalışmada, nesne tanıma görevleri gerçekleştirdiği için daha fazla detaya yer verilemeyecektir.

b) Nesne algılama

Nesne algılama, bilgisayarlı görü çalışmaları altında, görüntü veya videolar içerisindeki nesnelerin tanımlanmasını ve nesnelerin, "sınırlayıcı kutu" adı verilen bir kutu içerisinde gösterilmesini sağlayan derin öğrenme algoritmasıdır. Nesne algılama çalışmaları iki ana kapsamı içerisinde barındırmaktadır. Bunlar, önceki bölümlerde bahsedilen görüntü sınıflandırma ve konumlandırmadır. Görüntü sınıflandırma çalışmalarında bir görselin hangi sınıfa ait olduğu tespit edilebilmekteydi. Ancak nesne algılama çalışmalarında sınıfına ek olarak, görselin konumunu da gösterilmektedir.

Nesne algılama çalışmalarında, fotoğraf veya video içerisinde birden fazla sınıfa ait görüntünün de algılanmasını sağlamak mümkündür.



Şekil 3. 66 Çoklu sınıf nesne algılama (URL 9)

Verilen görüntüde birden fazla nesnenin sınıflandırıldığı görülmektedir. Aynı zamanda sınırlayıcı kutular yardımıyla tanımlanan nesnelerin konumuna da yer verilmiştir. Görseldeki gibi birden fazla sınıfın konumları ve sınıflarının tespit ettiği çalışmalara çoklu sınıf nesne algılama adı verilmektedir.

Nesne algılama çalışmalarında aşağıdaki adımlar sırası ile gerçekleşmekte ve sonuç elde edilebilmektedir.

- Ön İşleme: Tespit edilecek görüntü veya videolar üzerinde, renk ve boyut özelliklerinin tutarlılığını sağlayabilmek adına beslenen girdi görüntüleri standartlaştırılarak, algoritmanın desenleri tanıma kabiliyetini geliştirilmektedir.
- Özellik Çıkarma: Görüntüden, algoritmada kullanılabilmesi adına özellik çıkartmak için gerçekleştirilen adımdır. Bu sayede, veriler daha kolay analiz edilebilmekte ve algoritmada daha öz halleri ile işlenebilmektedir.
- Sınıflandırma ve Yerelleştirme: Görüntüdeki nesnelerin sınıflarının tanımlanmasının ardından, CNN (Evrişimli Sinir Ağı – Convolutional Neural Network) algoritması yardımı ile sınıfın konumu da belirlenmektedir.

Nesne algılama modelleri, sınırlayıcı kutular ve sınıf tahminleri üreterek, nesnenin konumu ve sınıfını belirlemeye çalışmaktadır. Bu kutuların üzerinde tahmin edilen sınıf ve güven puanı yer almaktadır.

Nesne algılama modeli aşağıdaki matematiksel ifadelerle gösterilmektedir.

- Sınırlayıcı kutu: Her nesne, (x,y,w,h) koordinatları ile tanımlanan bir sınırlayıcı kutu ile ifade edilmektedir. Burada x ve y kutunun merkez koordinatlarını ifade ederken, w ve h ise sırası ile genişlik ve yükseklik değerini ifade etmektedir. Model ofset değerleri ise tx, ty, tw ve th değerleri ile gösterilmektedir.

$$
\begin{aligned}
b_x &= \sigma(t_x) + c_x \\
b_y &= \sigma(t_y) + c_y \\
b_w &= p_w e^{t_w} \\
b_h &= p_h e^{t_h}
\end{aligned}
\tag{3.4}
$$

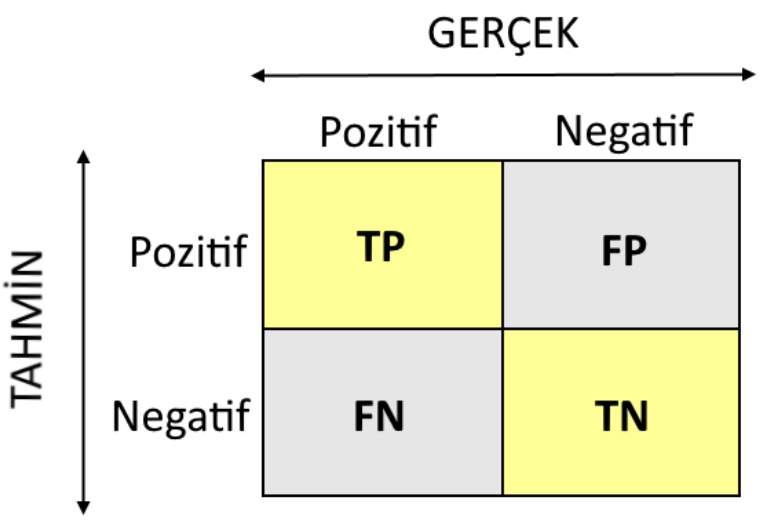
(3.4)'te σ sembolü, sigmoid fonksiyonunu ifade ederken, cx, cy bağlantı noktasının sol üst koordinatlarını ifade etmekte ve "pw, ph ise çarpanın boyutlarını temsil etmektedir.

- Sınıf tahmini: Her bir sınıfın, sınırlayıcı kutuda bulunma olasılığı, elde edilen sınıf puanlarının "softmax" aktivasyon fonksiyonuna girdi olarak verilmekte ve tahmin gerçekleştirilmektedir.

$$P(\text{sınıf} \mid \text{nesne}) = \frac{e^{s_{\text{sınıf}}}}{\sum_j e^{s_j}} \tag{3.5}$$

(3.5)'te, "ssınıf" belirli bir sınıf için tahmin edilen skordur. Bu skor formülde yerine konularak, nesnenin belirli bir sınıfa ait olma olasılığını hesaplamaktadır.

∑*jesj* ise, tüm sınıfların skorlarının üstel değerlerinin toplanması ile elde edilen değerdir. Bu formül sayesinde, herhangi bir nesnenin bir sınıfa ait olup olmadığı yüzdelik biçimde ifade edilmektedir. Bu bölümde son olarak nesne algılama modeli başarısının belirlenmesi için kullanılan metriklerden bahsedilecektir.



Şekil 3. 67 Karışıklık matrisi (URL 5)

- Doğru Pozitif (TP): Modelin, etiketlendiği veriye doğru şekilde tahmin ettiği örneklerdir.
- Yanlış Pozitif (FP): Modelin, etiketlendiği sınıfın dışında bir sınıf olarak tahmin edildiği örneklerdir.
- Genel Ortalama Keskinliği – Mean Average Precision (mAP): Bir modelin keskinliği, doğru pozitif sınıfın, doğru pozitif sınıf ile yanlış pozitif edilen sınıfa bölünmesi ile tanımlanmaktadır. Bu metrik ile modelin tahmin doğruluğu ölçülmekte ve daha yüksek mAP değeri daha doğru tahmin eden bir model eldesi anlamına gelmektedir.

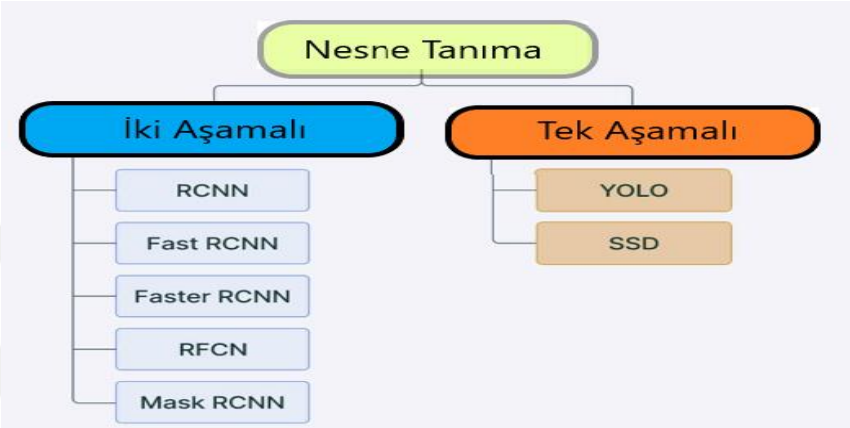
- Ortalama Hassasiyet – Average Precision (AP): Modelin farklı hatırlama seviyelerindeki hassasiyetinin ölçüsünü veren metrik, doğru pozitif sınıfın, yanlış pozitif veri sayısına bölünmesi ile elde edilmektedir. Daha yüksek AP değeri, model performansının daha yüksek olduğu anlamına gelmektedir.
- Hassasiyet ve Geri Çağırma (Duyarlılık): Hassasiyet, tüm pozitif tahminler arasındaki gerçek pozitif tahmin edilenlerin oranını ölçerek, modelin yanlış tahminlerden kaçınma yeteneğini değerlendirmektedir. Geri çağırma ise modelin bir sınıfın tüm örneklerini tespit etme yeteneğini ölçerek, doğru tahmin edilen verilerin, tüm sınıf verisine oranını hesaplamaktadır.
- F1 Puanı: Hassasiyetin harmonik ortalamasıdır ve hem yanlış tahmin edilen verileri hem de yanlış negatifleri göz önüne alarak modelin performansını değerlendirmektedir.

Bir önceki bölümde nesne algılama çalışmaları sayesinde bilgisayarlarla görme ve yerelleştirme gibi görevlerin gerçekleştirilebildiğinden bahsedilmişti. Teknolojinin gelişimi ve farklı problemlerin de çözümüne ihtiyaç duyulması ile farklı nesne algılama modelleri geliştirilmiştir. Farklı modellerin görev tanımına bağlı olarak birbirlerine kurdukları üstünlükler sebebiyle doğru model seçilerek, optimum sonuçlar elde edilebilmektedir. Model seçiminde dikkat edilmesi gereken parametreler aşağıdaki gibidir.

- Doğruluk: Nesne algılama görevlerinde, çok yüksek doğruluk gereksinimi bulunmaktadır. Bu durumda genellikle düşük hızlarda çalışan ancak yüksek doğruluk sağlayan “Faster R-CNN” gibi modeller tercih edilmelidir.
- Hız: Gerçek zamanlı algılamanın çok önemli olduğu, düşük gecikme süresine sahip tek aşamalı “YOLO” veya “SSD” gibi modellerin tercih edilmesi uygun olacaktır.
- Donanım: Yüksek performansa sahip modellerin eğitim sürecinde yüksek güce sahip donanımlara da gereksinim duyulabilmektedir. Yeterli hesaplama gücü bulunmadığı takdirde, daha düşük güç gereksinimi olan modeller tercih edilmelidir.

- Görüntü karmaşıklığı: Görüntü içerisinde modeli yanıltabilecek farklı unsurlar bulunması durumunda, “RetinaNet” gibi odaklama gücü yüksek modeller tercih edilmelidir.

Yukarıda verilen parametreler göz önüne alındığında farklı nesne tanıma modellerinin kullanımı gerekmektedir.



Şekil 3. 68 Nesne algılama modelleri

İki ve tek aşamalı nesne algılama, bilgisayarlı görü alanında farklı avantajları ile kullanılan iki yaklaşımdır. İki aşamalı detektörler, tespit işlemini iki ayrı aşamada tamamlamaktadır.

- İlk aşamada, bir nesneyi içerebilecek potansiyel konumlar oluşturulur. Bu konumlar sınıf tespitinden bağımsız biçimde gerçekleştirilmektedir.
- İkinci aşamada ise, bu bölgeler içerisinde nesneleri sınıflandıran ve sınırlayıcı kutuların oluşturulduğu başka bir işlem gerçekleştirilir. Bu aşamada, belirlenen bölgelerden sınıfların tespit edilebilmesi adına, özellikler çıkarılmaktadır. Bu işlem için Evrişimli Sinir Ağı (CNN) algoritması kullanılmaktadır.

İki aşamalı detektörler, bölgelerin sınıflandırılması ve nesnelerin konumlandırılma bilgisi eldesi için iki farklı işlem gerçekleştirdiği için yüksek doğruluk sağlamaktadır. Ancak işlem süresi de bu nedenle olumsuz yönde etkilenmektedir. RCNN, Fast RCNN, Faster RCNN ve Mask RCNN bu yaklaşıma ait nesne algılama algoritmalarıdır.

Tek aşamalı nesne algılama modelleri ise konum belirleme çalışması ile sınıf belirleme görevlerini tek aşamada gerçekleştirmektedir. Bu sebeple doğruluk açısından iki aşamalı

modellerin gerisinde kalsalar da, hız konusunda iki aşamalı modellere oranla çok daha hızlı şekilde görevlerini gerçekleştirebilmektedir. YOLO ve SSD ise bu yaklaşıma ait ve sıklıkla kullanılan modellerdir.

Bu çalışmada YOLO v8 modeli kullanılmış ve sonraki bölümlerde, model ile ilgili detay bilgilere yer verilecektir.

Bu bölümde son olarak, nesne algılama modellerinin temelini oluşturan Evrişimli Sinir Ağı (CNN) algoritmasına yer verilecektir.

Evrişimli Sinir Ağı (CNN), görüntülerin analiz edilmesi için kullanulan derin sinir ağıdır. Alternatif sınıflandırma modelleri ile karşılaştırıldığında, beslenen girdi görüntülerinden hiyerarşik özellikleri otomatik olarak ayırabildiği için daha az ön işleme ihtiyaç duyan CNN algoritması, yerel kalıpları tespit edebilmek için filtreler uygulayan evrişimli katmanlar kullanarak, görüntülerdeki nesne ve özelliklerin ayrıştırılması konusunda öne çıkmaktadır.

CNN mimarisi, birden fazla evrişim ve havuz katmanının bir araya getirilerek, karmaşık yapıların daha kolay analiz edilebilmesine olanak sağlamakta ve bu da görüntü sınıflandırma, nesne algılama ve segmentasyon görevlerinde yüksek doğruluğun elde edilebilmesine olanak tanımaktadır.

CNN mimarisi üç ana katmandan oluşmaktadır.

- Evrişimli katmanlar: Evrişimsel katman, hesaplamaların büyük kısmının gerçekleştirildiği katmandır. Bu kısımda, giriş görüntüsünden yüksek seviyeli özellikler çıkarılmaktadır.
- Havuzlama katmanları: Havuzlama katmanı, evrişimsel özelliğin uzamsal boyutunun azaltılmasından sorumludur. Bu katmanın amacı, verilerin işlenmesi için gereken hesaplama gücünün azaltılmasıdır.
- Tam bağlantılı katman: Bu katman, evrişimsel katmanın çıktısı tarafından temsil edilen yüksek seviyeli özelliklerin doğrusal olmayan kombinasyonlarını öğrenmek için kullanılan ucuz bir yoldur.

Bu katmanların sayısı arttıkça, model karmaşıklığı artmakta ve sınıf tahmin etme doğruluğu da artmaktadır. Ancak karmaşıklığın artışı ile işlem süresi de uzamaktadır. Bu işlemler sonucunda görüntülerdeki baskın ve düşük seviyeli özellikler arasında ayrım yapılarak, “softmax” sınıflandrıma tekniği kullanılarak sınıflandırma işlemi

gerçekleştirilmektedir. VGGNet, ResNet, AlexNet gibi farklı CNN mimarileri mevcuttur ancak bu mimarilere ait detay verilmeyecektir.

- RCNN

RCNN, nesne algılama görevleri için kullanılan iki aşamalı bir yaklaşımdır. RCNN, çoklu obje sınıflandırma çalışmalarında, CNN algoritmasının kullanılamaması nedeni ile geliştirilmiştir. İlk aşamada seçici arama ile görselde herhangi sınıfa ait olması muhtemel bölgeler belirlenir. Yaklaşık 2000 bölgenin belirlenmesinin ardından her bir bölge CNN algoritmasına girdi olarak beslenir ve sınırlayıcı kutular ile nesnenin sınıfı ve konumu tespit edilir.
RCNN genellikle, AlexNet veya VGG gibi önceden eğitilmiş CNN mimarileri kullanmaktadır. Bu özellik vektörleri, bölgelerde bulunan nesneleri sınıflandırmak ve sınırlayıcı kutuların koordinatlarını tespit etmek için kullanılmaktadır. Ancak iki aşamalı süreci nedeniyle, başarılı tahminleri olmasına rağmen işlem süreleri çok uzun olmakta ve bu nedenle tercih edilmemektedir.

- Fast RCNN

Fast RCNN, 2000 farklı aday bölgenin çıkarılması ve her bir bölge için ayrı CNN algoritması çalıştırılması temeline dayanan RCNN modelinin yüksek maliyetine bir alternatif olarak geliştirilmiştir. Burada amaç her bir bölge için ayrı CNN algoritması kullanımı yerine tek bir CNN algoritması kullanılmasıdır. Ayrıca Fast RCNN modeli, CNN, SVM ve Regresör yapılarını kombinleyerek, çok daha yüksek performans eldesine olanak sağlamaktadır. Fast RCNN modelinde;

- Tüm görsel tek bir CNN algoritması ile işlenir ve öznitelik haritası oluşturulur.
- Her bölge önerisi için öznitelikler toplanır, ardından bu haritalar maksimum havuzlama metodu ile daha düşük boyutlara indirgenir.
- Toplanan öznitelikler tek boyutlu bir vektör haline getirilir. Bu işleme düzleştirme ismi verilir.
- Bu vektörler sinir ağına sokulur ve softmax aktivasyon fonksiyonu yardımı ile nesneye ait sınıf ve konum belirlenir.

- Faster RCNN

Faster RCNN modeli ise, RCNN ve Fast RCNN modelinde ilk aşama olarak gerçekleştirilen seçici arama yerine "bölge teklif ağı" adı verilen bir yöntem kullanarak, işlem maliyetini düşürmektedir. Bölge teklif ağı (RPN) adımında seçici arama yöntemine benzer şekilde nesnelerin bulunabileceği potansiyel bölgeler belirlenmektedir. Belirlenen bölgeler, Fast RCNN mimarisine sokulmakta ve objenin sınıfı ve konumu tespit edilmektedir.

RCNN mimarisi üzerine geliştirilmiş modellerin aynı görev için eğitim ve tahmin süreçlerine ait veriler aşağıdaki gibidir.

Çizelge 3. 19 RCNN temeline sahip modellerin karşılaştırılması

Model İsmi	Eğitim Süresi	Tahmin Süresi
RCNN	84 Saat	2,4 Saniye
Fast RCNN	9 Saat	2,4 Saniye
Faster RCNN	9 Saat	0,4 Saniye

Çizelge 3.19'da görüldüğü üzere, Fast RCNN mimarisi, RCNN mimarisinin eğitim süresi konusundaki dezavantajlarını giderebilmiş ancak tahmin süresi anlamında bir gelişme kaydedememiştir. Ancak Faster RCNN mimarisi, eğitim süresi ve tahmin süresi anlamında ciddi bir gelişme kaydederek, hızlı ve yüksek doğruluklu sonuçların elde edilebilmesine olanak sağlamaktadır.

- R-FCN

R-FCN, tamamen evrişimli ağları kullanan bir nesne algılama modelidir. Diğer modellere benzer olarak ilk aşamada nesnenin bulunma potansiyeli olan bölgeler önerilirken, ikinci aşamada ise sınıflandırma işlemleri gerçekleştirilmektedir. RCNN modelinden farklı olarak, bölge öneri teklifleri ayrı ayrı değil tek seferde gerçekleştirilmekte ve bu nedenle daha verimli ve hızlı biçimde sonuç alınabilmektedir. Ek olarak R-FCN modeli, hesaplamayı görüntünün tamamına paylaştığı için, RCNN modelinden daha hızlı ve daha doğru sonuç vermektedir.

- Mask RCNN

Mask RCNN, iki aşamalı nesne algılama modeli olan Faster RCNN modelinin bir uzantısıdır. Mask RCNN modelinde, her potansiyel nesne bölgesine, segmentasyon maskelerini tahmin etmek için ek bir dal eklenmekte ve bu sayede örnek segmentasyonu işlemi daha etkili bir biçimde gerçekleşmektedir. RCNN modelinden farklı olarak yalnızca nesne algılamak yerine, şekil hakkında piksel düzeyinde bilgi verilerek daha fazla ayrıntı eldesine olarank sağlayan Mask RCNN, RolAlign özelliği sayesinde, doğruluk konusunda da daha yüksek performans sağlamaktadır. Mask RCNN, ek segmentasyon yeteneklerini kullanarak, daha karmaşık süreçlerde daha hızlı sonuç verebilmektedir.

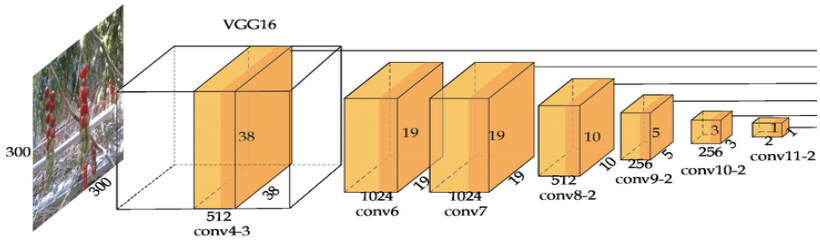
- SSD

SSD, diğer ismi ile "Tek Atış Dedektörü", bilgisayarlı görüde tek aşamalı nesne algılama algoritmalarından bir tanesidir. Görüntüler içerisinde nesneleri hızlı ve doğru biçimde algılama ve bulma yeteneği amacı ile kullanılan SSD modeli, bu işlemi tek bir sinir ağı ile gerçekleştirerek çok yüksek verimde ve gerçek zamanlı biçimde gerçekleştirmektedir. SSD modeli çeşitli boyutlardaki nesneleri, çok ölçekli özellik haritaları kullanarak kolaylıkla tespit edebilmektedir. Birden fazla nesnenin tek seferde tanımlanabilmesine de olanak sağlayan SSD; otonom sürüş, robotik ve nesne algılama gibi alanlarda kullanılmaktadır.

SSD ve YOLO gibi tek aşamalı dedektörler, hızları ile öne çıkan algoritmalar iken, teknolojinin de gelişimi ile iki aşamalı dedektör algoritmalarında önüne geçmiştir.

Tek aşamalı nesne algılama algoritmaları, iki aşamalı (potansiyel nesne bölgelerinin önerilmesi ve nesne sınıflandırılması) algoritmaların aksine, işlemi tek bir sinir ağı üzerinde gerçekleştirmektedir. SSD algoritması, çoklu sınırlayıcı kutu özelliği sayesinde, farklı ölçeklere ve en boy oranlarına sahip nesneleri aynı anda tanımlayabilmektedir. Belirlenen sınırlayıcı kutular için güven puanları tanımlayan SSD algoritması, bu sayede kutu koordinatlarını belirlemenin yanı sıra, her varsayılan kutuya ait sınıfların tahmin puanlarını da 0 ile 1 arasında belirterek, kullanıcıya bildirmektedir.

SSD mimarisi, gerçek zamanlı nesne algılama işlemlerini gerçekleştirebilmek adına CNN algoritmasını temel almaktadır.



Şekil 3. 69 SSD mimarisi (Yuan T. 2020)

SSD modeli, görüntü sınıflandırma görevleri için CNN mimarisini kullanmaktadır. CNN modeli kullanılarak, görüntü içerisindeki temel özellikler elde edilmektedir. Bu işlemin ardından, evrişimsel katmanlar eklenmektedir. Bu katmanlar ile özellik kanallarının sayısı arttırılmakta ve uzamsal boyutları da küçültülmektedir. Bu sayede SSD modelinin farklı ölçeklerde, özellik haritası üretebilmesi sağlanmaktadır. SSD modeli, çift aşamalı modellere oranla ciddi avantajlara sahip olsa da bazı sınırlamalara da sahiptir.

- SSD algoritmasının temel sınırlamalarından bir tanesi küçük nesneleri algılaması sırasındaki zorluklardır. Küçük nesneler, sınırlayıcı kutuların özellik piramitleri içerisinde net şekilde temsil edilememektedir.
- Bir diğer sınırlama ise, görüntü içerisinde tanımlanmayacak olan arka planların karmaşıklığıdır. Karmaşık arka planlar olması durumunda, model nesneleri ayırt edememekte veya hatalı sonuçlar vermektedir.
- SSD modeli, hız ile öne çıkan tek aşamalı nesne algılama modellerinden bir tanesidir ancak doğruluk konusunda sorunlar yaşayabilmektedir. Bu nedenle çok yüksek doğruluk gerektiren modellerde kullanımı uygun değildir.
- Bir diğer sınırlama ise, özel veri setleri ile kullanımı için uzun bir hazırlık süreci gerektirmesidir. YOLO algoritmasının ön hazırlık süreci daha kısa olduğu için, genellikle YOLO algoritması tercih edilmektedir.

- YOLO

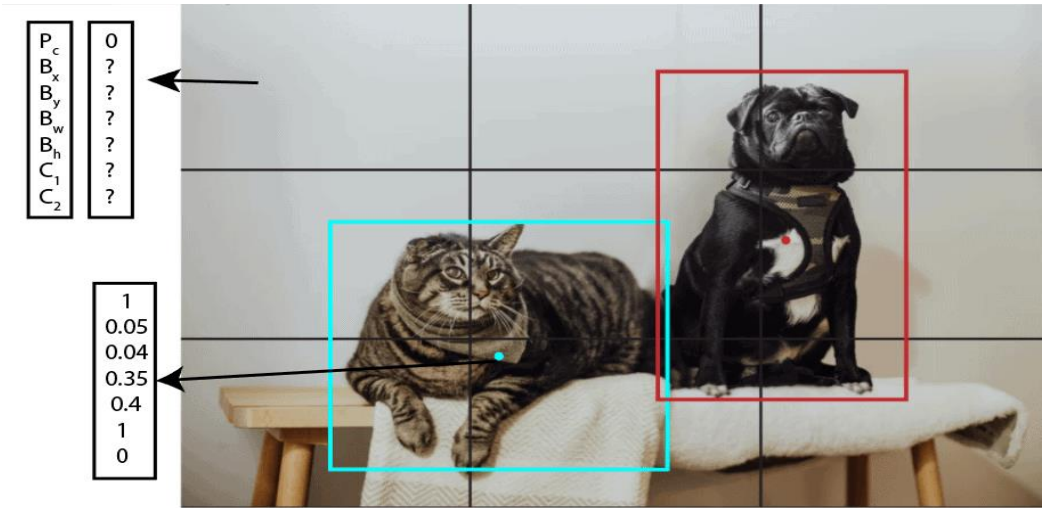
YOLO algoritması, ismini “Yalnızca bir kere bakarsınız” kelimelerinin baş harflerinin İngilizce karşılıklarından alan, tek aşamalı popüler bir nesne algılama algoritmasıdır. YOLO algoritması, geleneksel çift aşamalı nesne algılama algoritmalarının aksine yüksek hızda eğitim ve sonuç vermesi, aynı zamanda da yüksek doğruluk sağlayabilmesi sayesinde sıklıkla tercih edilmektedir.

YOLO algoritması, bir nesnenin sınıfını ve konumunu tanımlamayı amaçlamakta ve tespiti bir sınırlayıcı kutu içerisinde belirtmektedir. Her bir sınırlayıcı kutunun 4 adet koordinatı bulunmaktadır. Bunlar;

- Sınırlayıcı kutunun merkezi (bx, by)
- Kutunun genişliği (bw)
- Kutunun yüksekliği (bh)

Bu veriler ışığında, YOLO algoritması, tahmin edilen sınıfa ait güven puanını ve konumu belirtmekte ve Pc parametresine aktarmaktadır.

Aşağıdaki görselde, YOLO algoritmasının tespit etmeye çalıştığı kedi ve köpek sınıfını temsil eden nesneler bulunmaktadır.



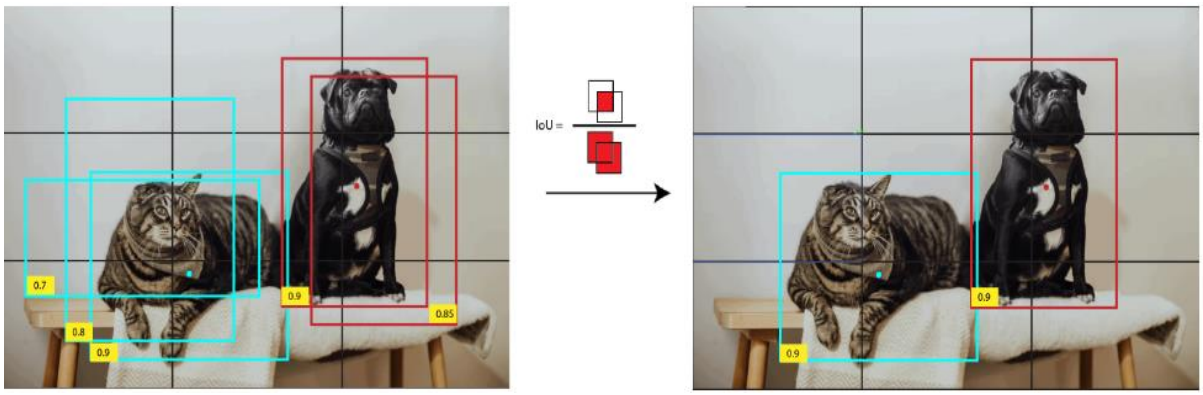
Şekil 3. 70 YOLO nesne algılama (URL 52)

Sol üst tarafta bulunan ızgarada yapılan vektör tanımlama çalışmasında, parametrelere karşılık herhangi bir değer bulunamadığı görülmektedir. Ancak kedi görselini içerisine alan ve sınıfın tespit edilebildiği ızgaralarda 1, 0,05 gibi verilerin elde edildiği görülmektedir. Bu işlemin ardında, her bir ızgara için bir vektör tanımlanarak, görüntünün tamamı 7 vektör ile temsil edilmektedir. Bu sayede tanımlamalı gerçekleştirebilen YOLO, SSD modelinde de olduğu gibi CNN modelini temel olarak kullanmaktadır.

YOLO algoritmasında, istenmeyen bir durum, tek bir sınıf için birden fazla sınırlayıcı kutunun belirlenmesidir. Bu durumun giderilebilmesi adına maksimum olmayan bastırma adı verilen bir yöntem kullanılmaktadır. Bu yöntemde amaç, bir nesne için belirlenen sınırlayıcı kutular arasından en yüksek güven puanına sahip kutunun seçilmesini sağlamaktır. Maksimum güven puanına sahip sınırlayıcı kutu, kesişim üzeri birleşim (IoU) kullanılarak, sınıf için belirlenen tüm kutularla karşılaştırılmaktadır. Bu metrik literatürde "Jaccard Dizini" olarak de bilinmekte ancak bilgisayarlı görü çalışmalarında IoU kısaltması ile anılmakta ve (3.6)'da gösterilmektedir.

$$IoU = \frac{\boldsymbol{B1\ ve\ B2\ arasındaki\ kesişim\ alanı}}{\mathbf{B1\ ve\ B2\ birleşim\ alanı}} \tag{3.6}$$

Model eğitimi sırasında bir eşik değer belirlenmektedir. Bu eşik değer üzerinde bulunan kutular hesaba katılırken, değerin altında kalan kutular hesaba dahil edilmemektedir. Bu işlem, nesne algılamanın sağlanacağı tek bir sınırlayıcı kutu sağlanana kadar devam etmektedir.



Şekil 3. 71 Sınırlayıcı kutu belirlenmesi (URL 52)

Sol taraftaki görüntüde tek bir sınıf için birden fazla belirleyici kutunun belirlendiği görülmektedir. IoU işleminin ardından en yüksek güven puanı en yüksek sınırlayıcı kutular, nesne algılama modelinin sonucu olarak kabul edilmiştir.

YOLO algoritmasındaki temel amaç, giriş görüntüsünün bir hücre ızgarasına bölünerek, her bir hücre için bir nesnenin varlığının olasılığını ve potansiyel konumunu belirlemektir.

- Giriş görüntüsü, görüntüden özelliklerin çıkarılabilmesi adına bir CNN algoritmasından geçirilir.
- Özellikler, sınıfların olasılıkları ve sınırlayıcı kutu konumlarının belirlenebilmesi adına, tam bağlantılı katmanlardan geçirilir.
- Ağın çıktısı olarak, her hücre için bir dizi sınırlayıcı kutu ve güven puanları oluşur.
- Sınırlayıcı kutular, üst üste oluşturulan kutuların kaldırılması ve en yüksek güven puanına sahip kutunun seçilmesi için maksimum olmayan bastırma adı verilen işlem sonrasında filtrelenir.
- Sonuç olarak, görüntüdeki her bir nesne için tek bir sınıf etiketine sahip sınıf etiketi ve güven puanı oluşur.

2023 yılında YOLO v8 sürümünün yayınlanmasının ardından 8 adet YOLO sürümü bulunmaktadır. Bu bölümde, YOLO algoritması sürümlerinin genel özellikleri ve gelişmelerine değinilecek ardından sürümler arasındaki performans karşılaştırılması hakkında bilgi verilecektir.

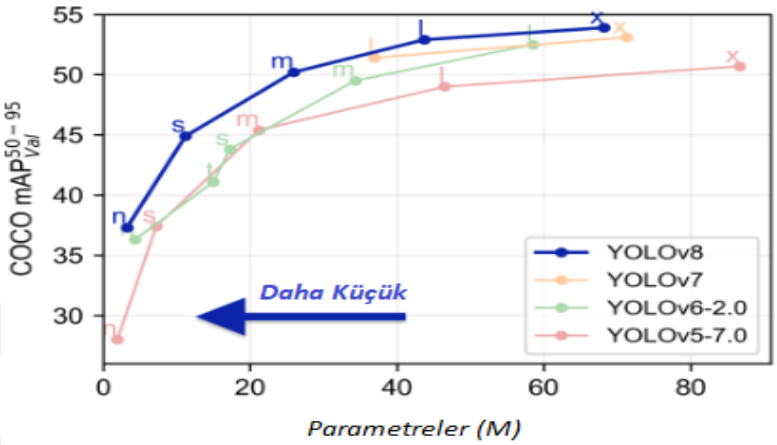
- YOLO algoritması ilk olarak 2015 yılında, sınıfların olasılıklarını ve sınırlayıcı kutuların koordinatlarını tahmin etmek amacı ile CNN algoritması üzerine inşa edilmiştir. Giriş görüntülerinin ızgaraya bölünmesi ile, her bir ızgara hücresi için sınırlayıcı kutuları ve güven puanları hesaplanmaktadır. Oldukça hızlı ve gerçek zamanlı nesne algılama görevlerini gerçekleştirebilmesine karşın, küçük nesneleri tanımlayabilme açısından, R-CNN temeline sahip, iki aşamalı nesne algılama algoritmaları kadar yüksek doğruluklar elde edilememektedir.
- 2016 yılında YOLO v2 sürümünün tanıtılması ardından, model daha düzenli haline getirilmiştir ve sınırlayıcı kutuların uzaklıklarının tahmin edilmesi için bağlantı kutularının kullanımına geçilmiştir. Bu sayede farklı şekil ve boyutlara sahip nesnelerin algılanma yeteneği arttırılmıştır. Bu çalışmanın

gerçekleştirilebilmesi adına daha güçlü ve verimli olan Darknet-19 ağı uygulanmaya başlanmıştır. Bu sürüm ile çok ölçekli eğitim özelliği modele eklenmiştir.

- YOLO v3 (2018), daha derin ve bağlantılara sahip olan Darknet-53 mimarisi ile iyileştirilmiştir ve CNN aşamasındaki özellik çıkarım özelliğinin gelişmesini sağlamıştır. Eş zamanlı üç farklı ölçekte nesnenin algılanması mümkün kılınarak, küçük nesnelerin algılanması yeteneği geliştirilmiştir. İlk kez bu model ile nesne algılanma görevlerinde "softmax" yerine "lojistik regresyon" kullanılmaya başlanmıştır. Bu sayede küçük nesnelerin tanınma yeteneği arttırılırken, yüksek kare hızı yeteneği korunabilmiştir.
- 2020 yılında yayınlanan YOLO v4 modeline, aşamalar arası kısmi ağlar (CSPNet) ve kendi kendine düşmanlık eğitimi gibi teknikler entegre edilerek hız ve performans geliştirmeleri gerçekleştirilmiştir. Ek olarak normal ve ticari GPU ile yüksek verim elde edilmesi için sistemsel iyileştirmeler yapılmıştır. Bu model ile daha yüksek doğrulukta sonuçların eldesi sağlanabilirken, yüksek kare hızı korunabilmiştir.
- YOLO v5 (2020) modeli ise resmi sürüm olarak değil Ultralytics firması tarafından yayınlanmıştır. Bu sürüm ile modelin PyTorch entegrasyonu sağlanarak model daha erişilebilir ve daha kolay eğitilebilir hale getirilmiştir.
- YOLO v6 (2022), hız ve doğruluk konusunda ufak değişikliklerin yapıldığı bir sürüm olmasının yanında pek tercih edilen bir model olamamıştır.
- 2022 yılında yayınlanan YOLO v7 modeli ise performans ve hız konusunda geliştirmelerin dışında ticari olmayan GPU için optimizasyonu ile öne çıkmıştır. Ayrıca topluluk ve ekosistemin geliştirilmesi adına farklı yazılımlar ile entegrasyonun sağlandığı sürümde, algoritmanın popülerliği arttırılmıştır.
- YOLO v8 (2023), birçok yenilik ile yayınlanmıştır. Hız ve model doğruluğu konusunda gelişme gösteren sürümün en önemli değişikliklerinden bir tanesi çapa içermeyen bir mimariye geçmesidir. Özellikle küçük nesnelerin algılanması konusunda yapılan iyileştirmeler sayesinde, çift aşamalı nesne algılama algoritmalarının önüne geçmeyi başaran sürümde, ek olarak "tensorflow lite"

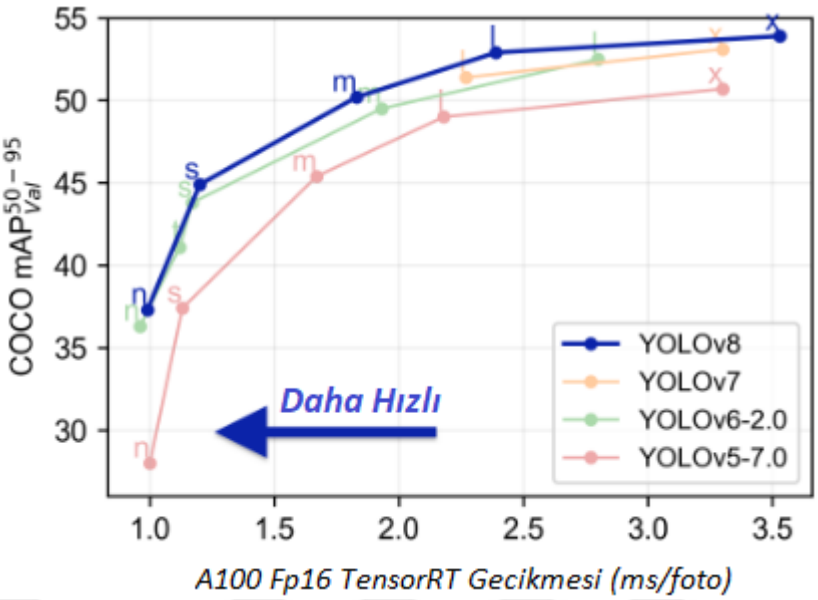
entegrasyonu da sağlanmış ve sayede mobil cihazlarda da modelin kullanımı mümkün kılınmıştır.

Bu kısımda, YOLO sürümleri arasındaki hız ve doğruluk performanslarına ait veriler paylaşılacaktır.



Şekil 3. 72 YOLO sürümleri parametre karşılaştırılması (URL 48)

Şekil 3.72'de YOLO v5 ile v8 versiyonları arasında farklı görevler için kullanılan n, s, m, l ve x modellerinin parametre gereksinimleri ve 0,5 ve 0,95 güven skoru arasında tespit edilen sınırlayıcı kutuların mAP skorlarına yer verilmiştir. Parametre sayısı azaldıkça, modelin eğitim süresi kısalmaktadır. Grafikte YOLO v8n modelinin en az parametre ile en yüksek mAP skoruna sahip olduğu görülebilmektedir. Bu sayede, modelin eğitim süresi kısalırken, diğer sürümlere oranla daha yüksek doğrulukta sonuçlar elde edilebildiği gözlemlenmiştir. Benzer durum, s, m, l ve x modellerinde de gözlemlenmiştir.



Şekil 3. 73 YOLO sürümleri hız karşılaştırılması (URL 48)

Şekil 3.73'te ise, farklı YOLO sürüm ve modellerinin Nvidia A100 16 bit ekran kartı ile yapılan testlerde tespit edilen gecikme sürelerine yer verilmiştir. Gösterilen sürümler arasında YOLO v8 sürümüne ait modellerin daha düşük gecikme sürelerinde daha yüksek mAP skoruna ait olduğu gözlemlenmektedir.

Bu çalışma kapsamında, YOLO v8 sürümünün daha hızlı ve daha yüksek doğrulukta çalışabildiği sonucuna ulaşılmıştır.

Çizelge 3. 20 YOLO v8 modellerinin karşılaştırılması (URL 48)

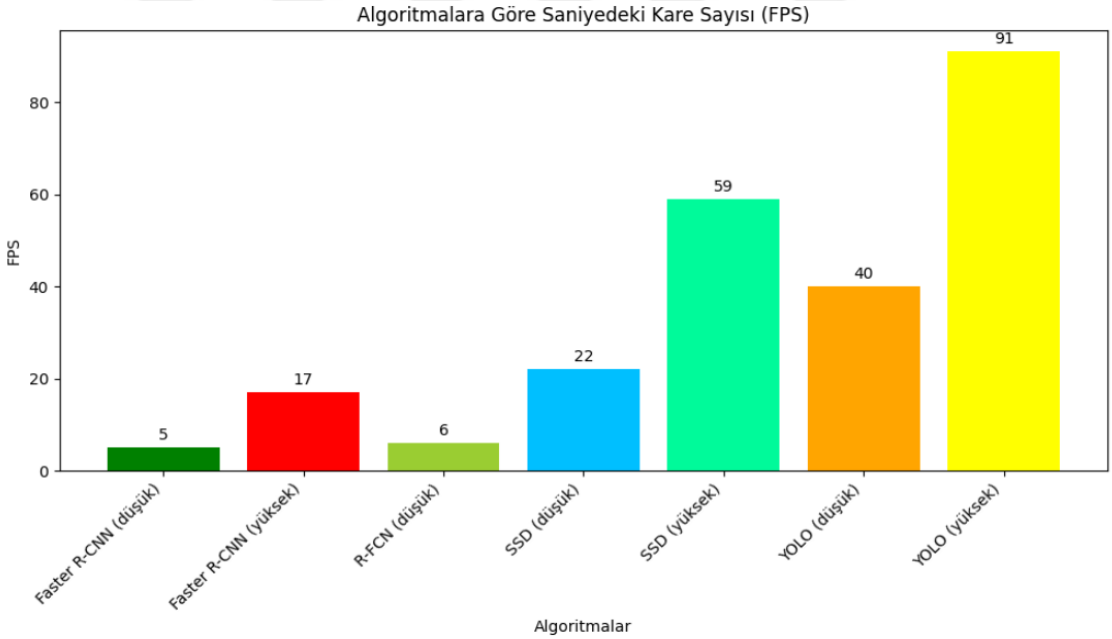
Model (YOLO v8)	**Boyut (px)**	**mAP (50-95)**	**Hız CPU – ONNX (ms)**	**Hız GPU – A100 TensorRT (ms)**	**Parametre (M)**	**FLOPs (B)**
Nano	640	37,3	80,4	0,99	3,2	8,7
Small	640	44,9	128,4	1,20	11,2	28,6
Medium	640	50,2	234,7	1,83	25,9	78,9
Large	640	52,9	375,2	2,39	43,7	165,2
XLarge	640	53,9	479,2	3,53	68,2	257,8

YOLO v8'in farklı amaçlarla kullanılan 5 adet modeli bulunmaktadır. Bu modellerin her biri 640 piksel boyutuna sahip görsellerle kullanılmakta ancak farklı gecikme ve doğruluk

değerlerine sahiptir. Tabloda 80 adet sınıfa sahip önceden eğitilmiş COCO veri seti ile yapılan test sonuçları görülmektedir.

- Nano modeli, en hafif model olarak ifade edilmekte ve doğruluk performansının çok önemli olmadığı ancak yüksek hız gerektiren görevlerde kullanılmaktadır. Eğitim parametre sayısı diğer modellere oranla çok az olduğu için eğitim ve tanımlama süresi diğer modellere göre daha kısa ancak doğruluk performansı da düşüktür.
- XLarge modeli ise, nano modeline oranla yaklaşık 4 kat daha yavaş çalışmakta ancak yaklaşık 40% oranında daha yüksek doğruluk değerine sahiptir. Bu nedenle hızın daha az önemsendiği, doğruluğun çok önemli olduğu modellerde kullanılmalıdır.
- Small, Medium ve Large modellerinde de benzer hiyerarşiyi görmek mümkündür.

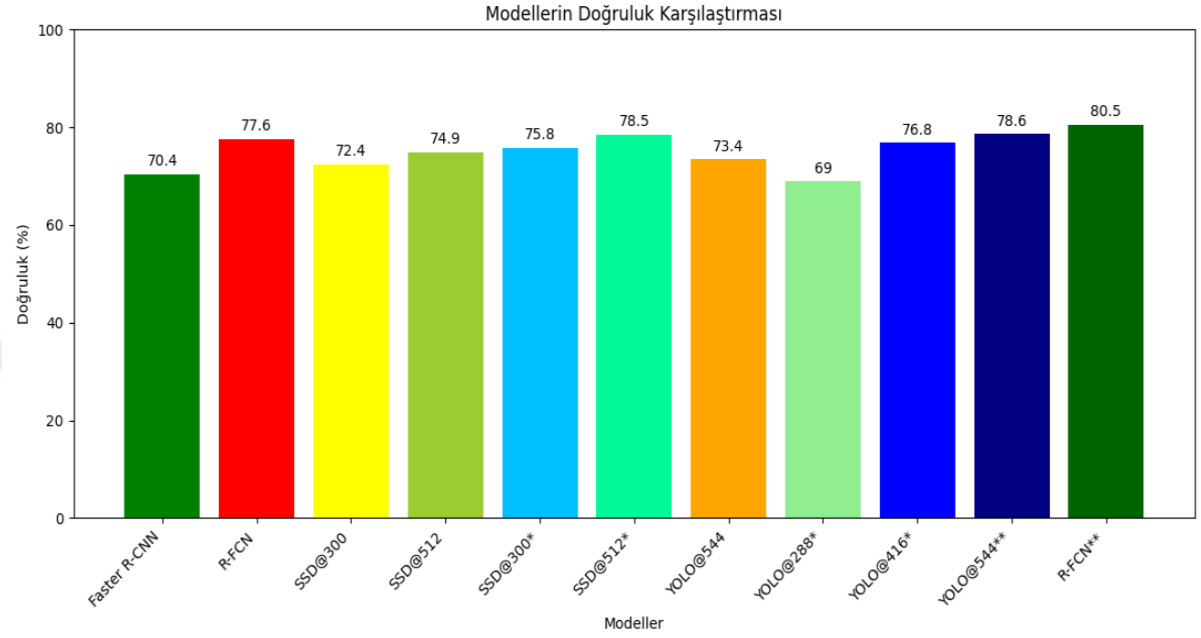
Bu bölümde ise, YOLO algoritması ile diğer nesne algılama algoritmaların hız ve doğruluk açısından karşılaştırılmasına yer verilecektir.



Şekil 3. 74 YOLO ve diğer modellerin hız karşılaştırılması (URL 16)

Şekil 3.74'te VOC 2007 veri seti ile eğitilen modellerin kare hızı karşılaştırılmasına yer verilmiştir. İki aşamalı nesne algılama algoritmaları, 5 ile 17 FPS verileri arasında tanıma

gerçekleştirebilirken, SSD ve YOLO gibi tek aşamalı nesne tanıma algoritmaları çok daha yüksek tanıma hızlarına ulaşabilmektedir. Grafikte YOLO algoritmasının en yakın rakibi SSD algoritmasının yaklaşık 2 katı hızda tanıma gerçekleştirebildiği gözlemlenmiştir.



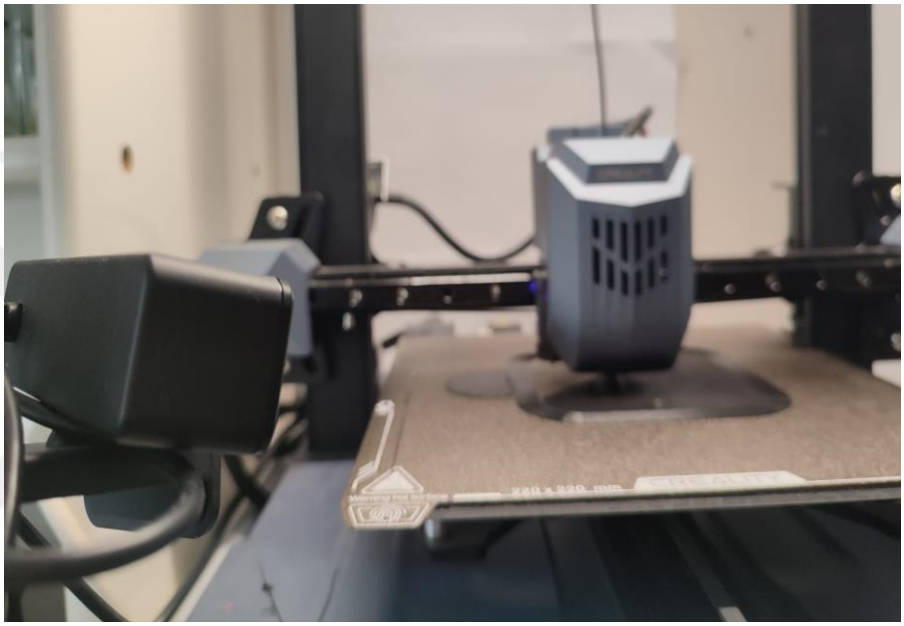
Şekil 3. 75 YOLO ve diğer modellerin nesne tanıma başarı karşılaştırılması (URL 16)

Grafikte, tek aşamalı nesne tanıma algoritmalarının, geleneksel iki aşamalı nesne tanıma algoritmalarının doğruluk konusundaki başarısına çok yaklaştığı görülmektedir. YOLO v8 sürümünde, küçük nesneleri tanıma kabiliyetinin geliştirilmesi, yüksek tanıma ve eğitim hızı ve yüksek doğruluk özellikleri sayesinde tez çalışmasına uygun olduğuna kanaat getirilmiştir. Bu nedenle bu çalışmada YOLO v8 algoritmasının farklı modelleri kullanılarak, ideal sonuçlar aranacaktır.

4. BULGULAR

Yapılacak sistemde, üretim sırasında oluşabilecek, önceki bölümlerde de detaylarına değinilen, farklı hatalar gözlemlenecektir.

Şekil 4.1'de görüldüğü gibi konumlandırılan, 2K 30 FPS çözünürlüğe sahip kamera, üretim sürecini canlı olarak gözlemleyecek ve hataların tespitini sağlayacaktır.



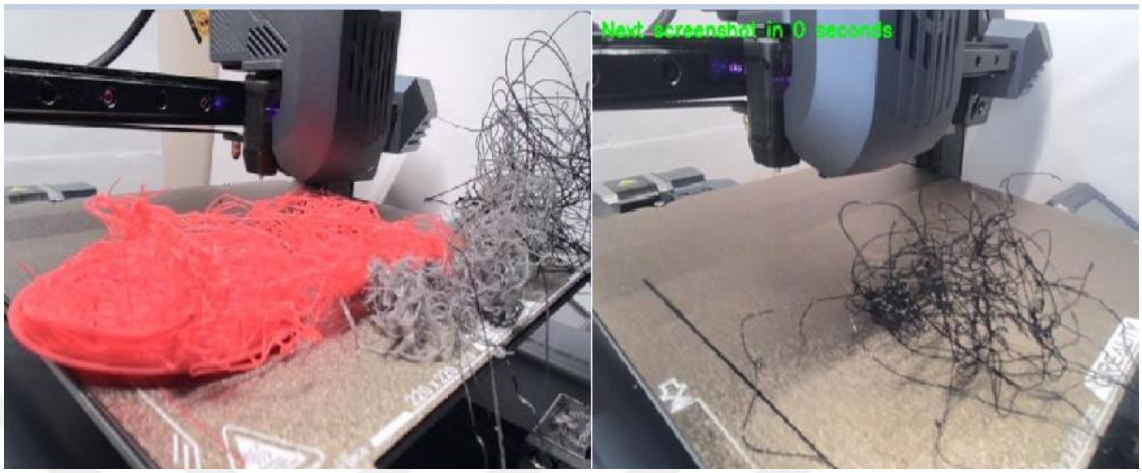
Şekil 4. 1 Kamera yerleşimi

Hataların tespiti sağlanabilmesi adına, öncelikle hata görsellerinin etiketlenmesi ve modele beslenmesi gerekmektedir. Bu aşamada öncelikle hatalı verilerin sisteme beslenmesi için, hataları üretimler gerçekleştirilecek ve veriler düzenlenecektir.
Çalışma kapsamında üç adet baskı hatasının tespiti gerçekleştirilecektir. Bu hatalar;

- Spagetti Hatası
- Çarpılma (Tabladan Kalkma) Hatası
- Yatağa Yapışmama Hatası

olarak belirlenmiştir.
Sistemi gözleyen kamera, bir Python (OpenCV) kodu ile her 5 saniyede bir hatayı gözlemlemektedir. Bu sayede veri kümesi için yeterli sayıda anlamlı veriye ulaşılması

hedeflenmektedir. Spagetti hatası için Şekil 4.2'de görüldüğü gibi hatalı üretimler gerçekleştirilmiştir.



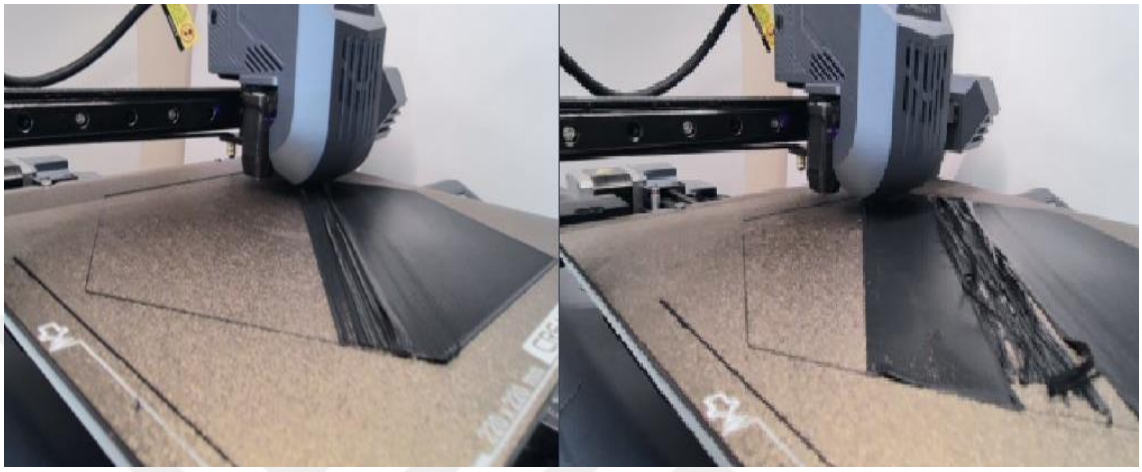
Şekil 4. 2 Spagetti hatası

Farklı koşullar altında çekilen görüntüler sayesinde, modelin aşırı öğrenmesinin önüne geçilebilmekte ve model başarısı arttırılabilmektedir. Çarpılma hatası için Şekil 4.3'te görüldüğü gibi hatalar kaydedilmiştir.



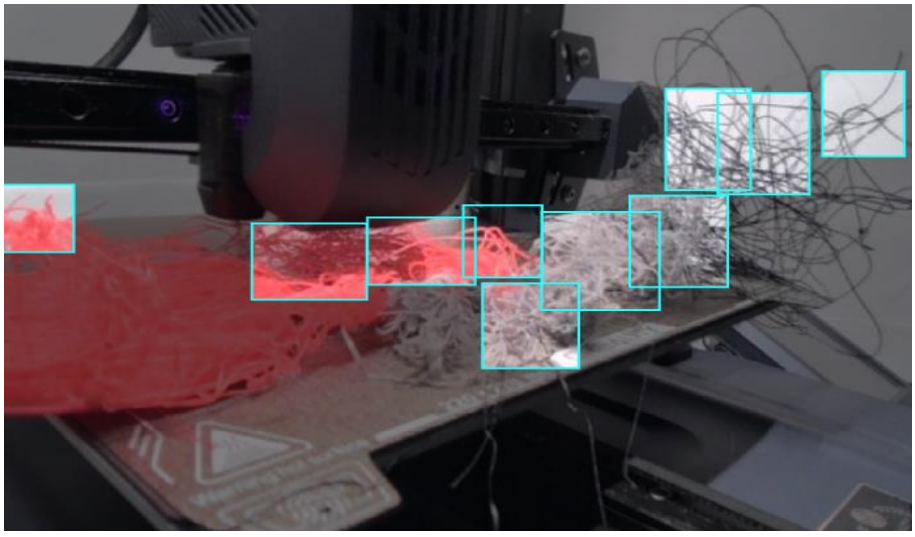
Şekil 4. 3 Çarpılma hatası

Şekil 4.3'te görüldüğü gibi farklı geometrilerde çarpılma hataları kaydedilerek, modelin öğrenme çeşitliliği arttırılmıştır. Şekil 4.4'te ise, yatağa yapışmama sorunu ile ilgili hatalar kayıt altına alınmıştır.

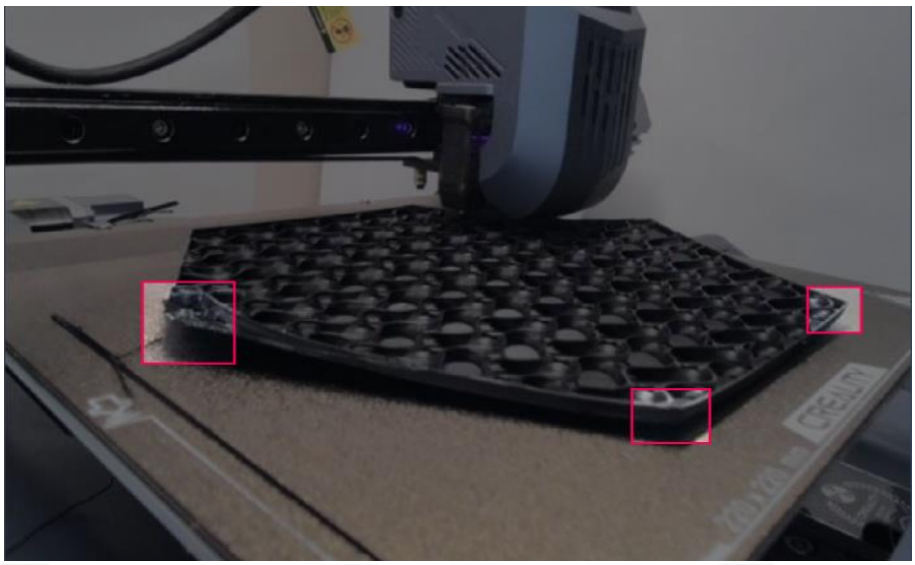


Şekil 4. 4 Yatağa yapışmama hatası

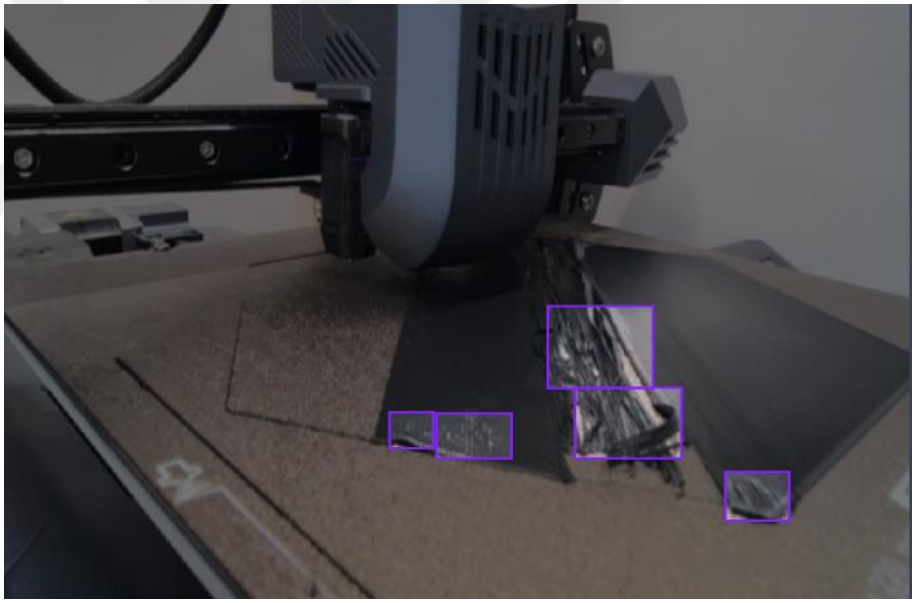
Farklı yatağa yapışmama türleri modele eklenerek, modelin öğrenme çeşitliliği arttırılmıştır. Sistemi gözleyen kamera, bir Python kodu ile her 5 saniyede bir hatayı gözlemlemektedir. Bu sayede veri kümesi için yeterli sayıda anlamlı veriye ulaşılması hedeflenerek *8088 adet fotoğraf* etiketlenmiş ve etiketleme işlemi için "RoboFlow" platformu kullanılmıştır.



Şekil 4. 5 Spagetti hatası sınıf verisi etiketleme



Şekil 4. 6 Çarpılma hatası sınıf verisi etiketleme



Şekil 4. 7 Çarpılma hatası sınıf verisi etiketleme

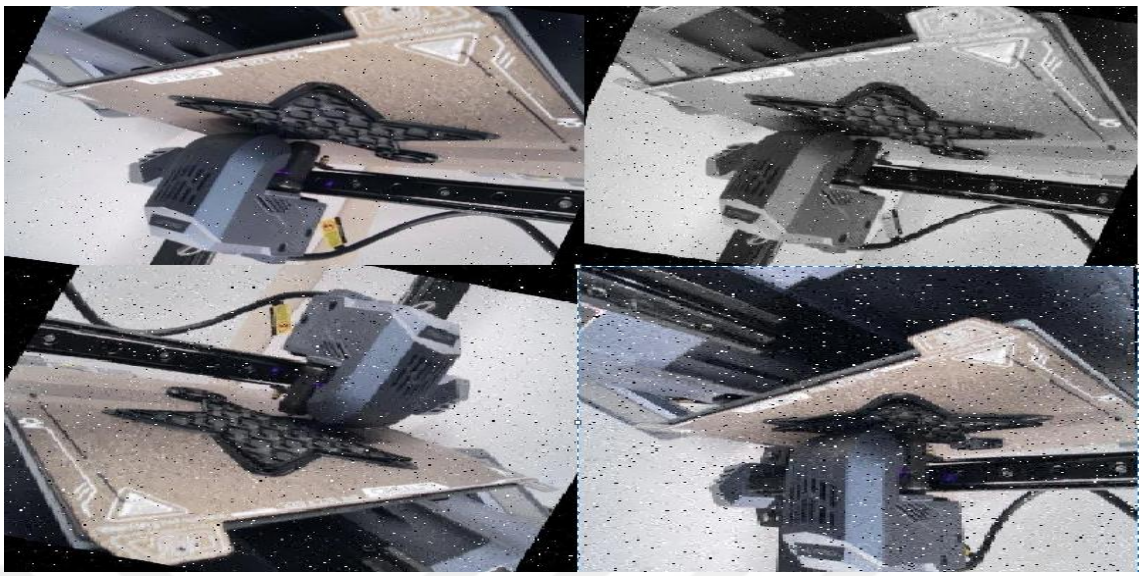
Şekil 4.5, 4.6 ve 4.7'de görüldüğü gibi çekilen fotoğraflar içerisinde hata oluşturan kısımlar, sınırlayıcı kutular içerisine alınmış ve "Spagetti", "Warping", "Not Sticked" sınıf etiketleri ile etiketlenmiştir. Bu sayede, model gerçek zamanlı algılama çalışması sırasında bu hata ile görüntü arasında benzerlik kurarak, hata tespiti sağlamaya çalışmaktadır.

Model başarısında veri kümesi büyüklüğü büyük önem arz etmektedir. Modele beslenen anlamlı ve doğru veri sayısı arttıkça, modelin tanımlama başarısı artış gösterecektir. Yetersiz veri ile yapılan model eğitimlerinde, derin sinir ağları yapıları sebebi ile "Aşırı Öğrenme (Overfitting)" problemine rastlanabilmektedir. Aşırı öğrenmeye kısaca değinmek gerekirse, bir makine öğrenmesi modelinin, eğitim verisinde çok iyi performans göstermesine karşın, validasyon ve test verisi gibi modelin tanımadığı verilerde, zayıf performans göstermesi olarak özetlenebilmektedir. Aşırı öğrenmenin gerçekleşmemesi adına, bu çalışmada "Veri Arttırma (Data Augmentation)" yöntemlerine başvurulacaktır. RoboFlow aracı üzerinde aşağıdaki veri arttırma yöntemlerine yer verilmiştir.

Veri arttırma yöntemlerinden aşağıdaki tekniklere başvurulmuştur.

- Dikey Döndürme
- Yatay Döndürme
- Gri Tonlama (25% oranında)
- 0,95% Gürültü Ekleme
- ± 10% Doygunluk
- 1 px Bulanıklık

Bu işlem sonrasında modele beslenen *8088* veri, *23446* veriye yükseltilmiş ve modelin öğrenme başarısı artırılmıştır. Sonraki bölümlerde model performansına ilişkin detaylara değinilecektir. Yapılan veri arttırma işlemine ait bir örnek aşağıdaki gibidir.



Şekil 4. 8 Veri arttırımı

Şekil 4.8'de açısal döndürmelerin yanı sıra, orijinal verilerin üzerine bulanıklık ve gürültü eklenerek, modelin farklı koşullarda hatayı tanıyabilmesi adına eğitim çeşitliliği arttırılmıştır.

Model eğitimi sırasında, literatürde de sıklıkla tercih edilen veri seti dağılımı olan;

- 80% Eğitim (18757 Veri)
- 10% Validasyon (2344 Veri)
- 10% Test (2345 Veri)

Şeklinde veri seti ayrılmıştır.

Bu sayede model eğitimi sonrasında, modelin daha önce karşılaşmadığı, validasyon ve test verileri ile model performansı doğru biçimde kıyaslanabilecektir.
Nesne tanıma modeli eğitimi için Google Colab kullanılmıştır. Colab içerisinde sunulan Tesla T4 – Yüksek Ram opsiyonlu ekran kartı ile kişisel kullanım için üretilen ekran kartlarına oranla, eğitim süreci daha hızlı biçimde tamamlanabilmektedir.
Colab eğitim süreci aşağıdaki gerçekleşmektedir.

- Gerekli kütüphanelerin kurulumu (OpenCV, Ultralytics YOLO v8)
- Eğitim, Validasyon, Test verilerinin sisteme yüklenmesi ve çıkarılması

- Model eğitimi için önceden eğitilmiş model seçimi (Yolo v8n, Yolo v8m, Yolo v8x)
- Model İterasyon sayısının belirlenmesi
- Model optimizasyon fonksiyonu belirlenmesi
- Model görsel boyutlarının belirlenmesi (640x640 px)

Model eğitimi için önceden eğitilmiş modellerin ağırlıklarının kullanılması adına çeşitli testler gerçekleştirilmiştir.

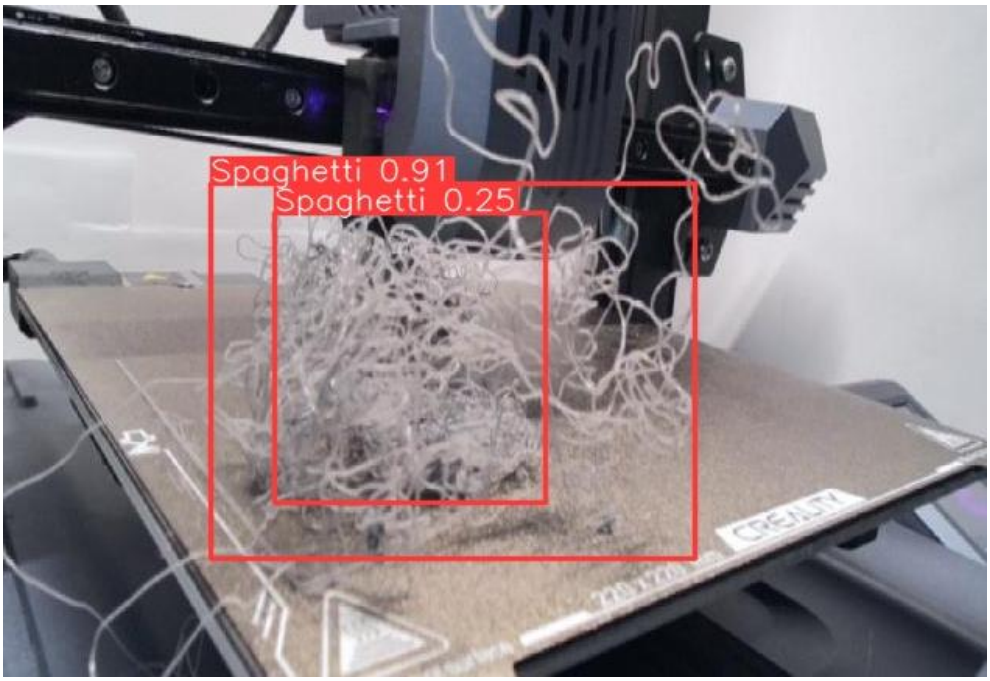
Bu testler sırasında,

- Yolo v8x
- Yolo v8m
- Yolo v8n

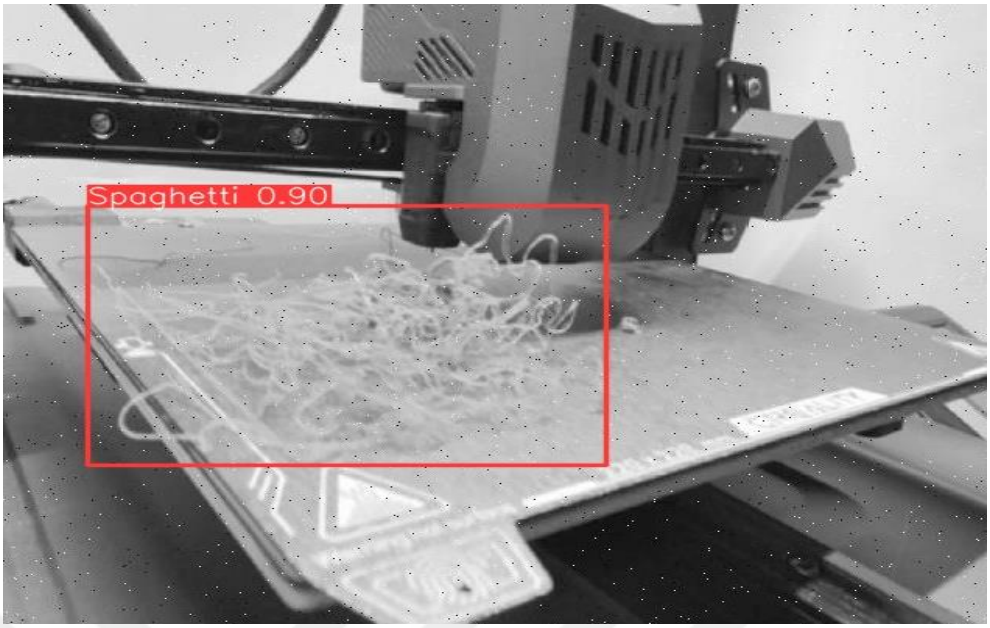
Modelleri, aşağıdaki kriterlerin sonuçlarına göre değerlendirilerek karar verilecektir.

- Eğitim ve Tanımlama Hızı
- Tanımlama Başarısı

2300 Eğitim verisinin ve yalnızca spagetti sınıfına ait verilerin kullanıldığı demo çalışmalar kapsamında aşağıdaki sonuçlar elde edilmiştir.



Şekil 4. 9 YOLO v8x nesne tanıma performansı



Şekil 4. 10 YOLO v8m nesne tanıma performansı



Şekil 4. 11 YOLO v8n nesne tanıma performansı

Şekil 4.9, Şekil 4.10 ve Şekil 4.11'de aşağıda verilen hiper parametreler kullanılarak eğitimler gerçekleştirilmiş ve sonuçlar Çizelge 4.1'de paylaşılmıştır.

- İterasyon Sayısı: 100
- Batch Sayısı: 8

- Worker Sayısı: 8
- Öğrenme Katsayısı (LR): 0,01 (Varsayılan)
- Momentum: 0,937 (Varsayılan)

Çizelge 4. 1 YOLO modelleri performans karşılaştırılması

Model İsmi	Eğitim Süresi	FPS (Frames Per Second)	Başarı Yüzdesi
Yolo v8x	4 Saat 12 Dakika	15-20	91%
Yolo v8m	2 Saat 53 Dakika	30-35	90%
Yolo v8n	1 Saat 57 Dakika	35-42	47%

Yolo v8x ile eğitilen modelin sonuç görüntüleri Şekil 4.9'da gösterilmektedir. Verilen örnek görselde 91% oranında başarı ile hatanın tanımlanabildiği görülmektedir. Şekil 4.10'da Yolo v8m modeli ile 90% oranında hatanın tanımlanabildiği görülürken, Şekil 4.11'de Yolo v8n modeli ile çok daha düşük bir başarı oranı (47%) ile tanımlama gerçekleştirilebilmiştir.

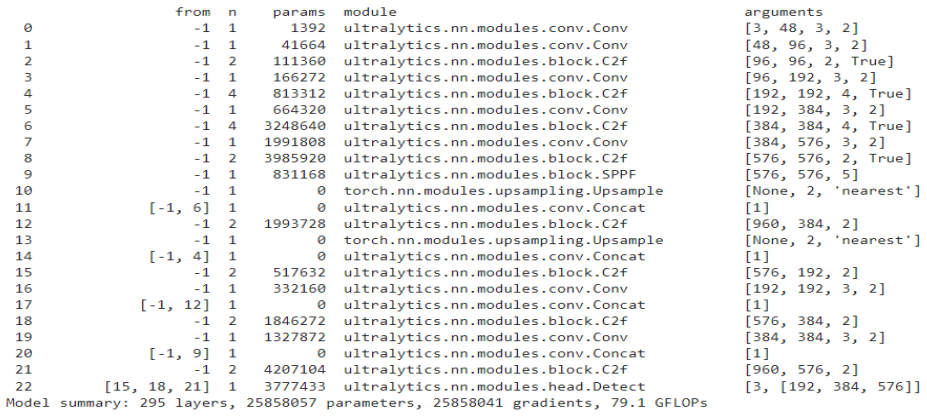
Çizelge 4.1'de detaylarına değinildiği üzere, Yolo v8x ile eğitilen modelin, eğitim süresinin daha uzun olduğu ve tanımlama hızının diğer iki modele oranla çok daha yavaş biçimde gerçekleştiği görülebilmektedir. Buna karşın Yolo v8m modeli ile çok yakın yüzdelerde tanımlama başarısı görülmektedir.

Önceki bölümlerde,

- YOLO v8x modelinin nispeten yavaş ancak yüksek doğrulukta sonuçlar verebildiğinden,
- YOLO v8n modelinin ise hızlı ancak daha düşük doğrulukta çalıştığından bahsedilmişti.

Bu çalışmada doğruluk hızdan daha ön planda olduğu ve Yolo v8m modelinin, Yolo v8x modeline oranla daha hızlı şekilde eğitimi tamamlayabilmesine ve tanımlama yapabilmesine rağmen çok yakın oranlarda başarı sağlayabilmesi nedeni ile Yolo v8m modeli kullanılacaktır.

Yolo v8m modeli kullanılarak başlatılan modelin katman ve özet model bilgileri aşağıdaki gibidir.



	from	n	params	module	arguments
0	-1	1	1392	ultralytics.nn.modules.conv.Conv	[3, 48, 3, 2]
1	-1	1	41664	ultralytics.nn.modules.conv.Conv	[48, 96, 3, 2]
2	-1	2	111360	ultralytics.nn.modules.block.C2f	[96, 96, 2, True]
3	-1	1	166272	ultralytics.nn.modules.conv.Conv	[96, 192, 3, 2]
4	-1	4	813312	ultralytics.nn.modules.block.C2f	[192, 192, 4, True]
5	-1	1	664320	ultralytics.nn.modules.conv.Conv	[192, 384, 3, 2]
6	-1	4	3248640	ultralytics.nn.modules.block.C2f	[384, 384, 4, True]
7	-1	1	1991808	ultralytics.nn.modules.conv.Conv	[384, 576, 3, 2]
8	-1	2	3985920	ultralytics.nn.modules.block.C2f	[576, 576, 2, True]
9	-1	1	831168	ultralytics.nn.modules.block.SPPF	[576, 576, 5]
10	-1	1	0	torch.nn.modules.upsampling.Upsample	[None, 2, 'nearest']
11	[-1, 6]	1	0	ultralytics.nn.modules.conv.Concat	[1]
12	-1	2	1993728	ultralytics.nn.modules.block.C2f	[960, 384, 2]
13	-1	1	0	torch.nn.modules.upsampling.Upsample	[None, 2, 'nearest']
14	[-1, 4]	1	0	ultralytics.nn.modules.conv.Concat	[1]
15	-1	2	517632	ultralytics.nn.modules.block.C2f	[576, 192, 2]
16	-1	1	332160	ultralytics.nn.modules.conv.Conv	[192, 192, 3, 2]
17	[-1, 12]	1	0	ultralytics.nn.modules.conv.Concat	[1]
18	-1	2	1846272	ultralytics.nn.modules.block.C2f	[576, 384, 2]
19	-1	1	1327872	ultralytics.nn.modules.conv.Conv	[384, 384, 3, 2]
20	[-1, 9]	1	0	ultralytics.nn.modules.conv.Concat	[1]
21	-1	2	4207104	ultralytics.nn.modules.block.C2f	[960, 576, 2]
22	[15, 18, 21]	1	3777433	ultralytics.nn.modules.head.Detect	[3, [192, 384, 576]]

Model summary: 295 layers, 25858057 parameters, 25858041 gradients, 79.1 GFLOPs

Şekil 4. 12 Model başlangıç parametreleri

Model parametreleri aşağıdaki gibi belirlenmiştir.

- Model Ağırlıkları: Yolo v8m
- Sınıf Sayısı: 3+1 (3 Hata Sınıfı + Arka Plan Sınıfı)
- İterasyon (Epochs) Sayısı: 150
- Görsel Boyutları: 640x640 px
- Worker (Veri Yükleme İşçisi) Sayısı: 10
- Batch (İterasyon Örneklem Sayısı): 10
- Öğrenme Katsayısı (LR): 0,01 (Varsayılan)
- Momentum: 0,937 (Varsayılan)

Bu hiper parametreler ile model başlatıldığında Şekil 4.10'da görüldüğü gibi;

- 295 Katman (Model Karmaşıklığı ve Derinliği)
- 25.8 Milyon Parametre (Ağırlık)
- 25.8 Milyon Gradyan (Kayıp Fonksiyonu Eğriliği)
- 79.1 Milyar GFLOPs (Hesaplama Yükü)

özelliklerine sahip model eğitimi gerçekleştirilmiştir.

```
      Epoch    GPU_mem   box_loss   cls_loss   dfl_loss  Instances       Size
      1/150      5.02G      2.23      2.423      2.047          9        640: 100% 1851/1851 [10:09<00:00,  3.04it/s]
                 Class     Images  Instances      Box(P          R      mAP50  mAP50-95): 100% 116/116 [00:34<00:00,  3.40it/s]
                   all       2312       5367      0.515      0.501      0.482      0.177

      Epoch    GPU_mem   box_loss   cls_loss   dfl_loss  Instances       Size
      2/150      4.86G      2.024      1.746      1.801          3        640: 100% 1851/1851 [10:00<00:00,  3.08it/s]
                 Class     Images  Instances      Box(P          R      mAP50  mAP50-95): 100% 116/116 [00:33<00:00,  3.48it/s]
                   all       2312       5367      0.624      0.441      0.496      0.192

      Epoch    GPU_mem   box_loss   cls_loss   dfl_loss  Instances       Size
      3/150      4.79G      2.051      1.774      1.811          7        640: 100% 1851/1851 [09:55<00:00,  3.11it/s]
                 Class     Images  Instances      Box(P          R      mAP50  mAP50-95): 100% 116/116 [00:32<00:00,  3.53it/s]
                   all       2312       5367      0.441       0.47      0.425      0.159

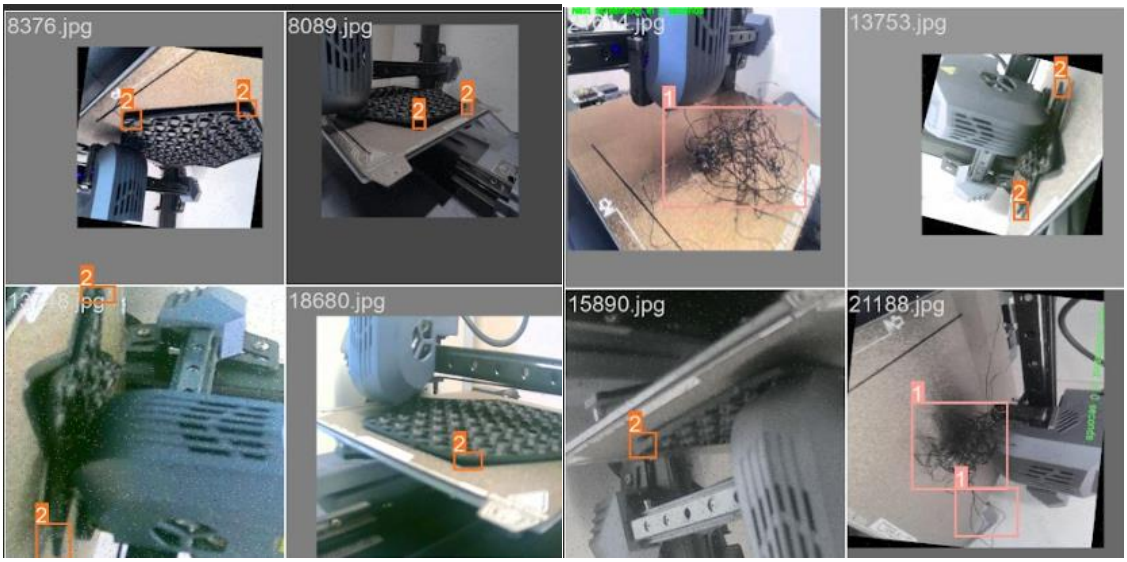
      Epoch    GPU_mem   box_loss   cls_loss   dfl_loss  Instances       Size
      4/150      4.91G      2.066      1.785      1.819          8        640: 100% 1851/1851 [09:55<00:00,  3.11it/s]
                 Class     Images  Instances      Box(P          R      mAP50  mAP50-95): 100% 116/116 [00:33<00:00,  3.49it/s]
                   all       2312       5367      0.473      0.458      0.449      0.168
```

Şekil 4. 13 Eğitim başlangıç sonuçları

Eğitim sürecinde, box_loss, cls_loss, dfl_loss değerlerinin iterasyonlar ile azalma eğiliminde olması beklenmektedir. mAP50 ve mAP 50-95 değerlerinin ise her bir iterasyon ile yükselme eğiliminde olması beklenmektedir. Bu model eğitimi tamamlanmadan, hızlı bir değerlendirme yapılmasına olanak sağlamaktadır.

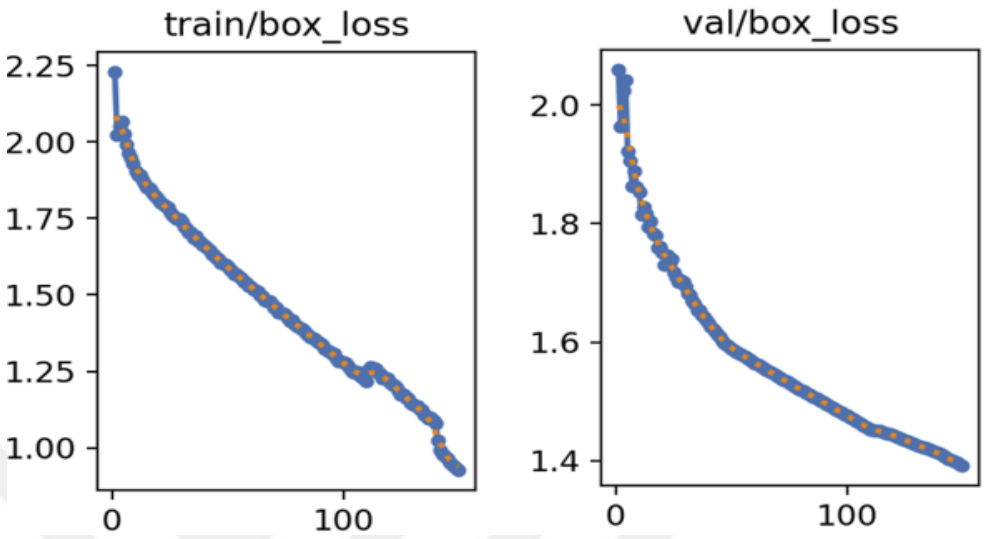
Model eğitimi ardından best.pt uzantısı ile verilen bir model dosyası oluşmakta ve bu sayede özel veri seti ile eğitilmiş nesne tanıma modeli, canlı görüntülerde kullanılabilir hale getirilmiştir.

Model eğitiminin tamamlanması ardından, test verisi ile yapılan testler Şekil 4.14'te gösterilmiştir.



Şekil 4. 14 Eğitilen verilerin tanımlama örneği

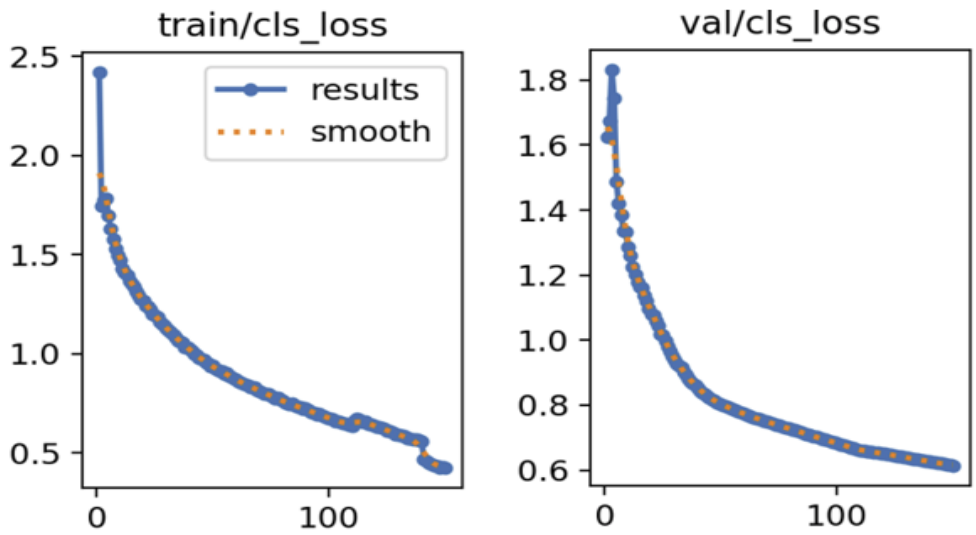
Eğitimin tamamlanmasının ardından, bir sonraki kısımda performans sonuçları incelenecektir.



Şekil 4. 15 Eğitim/Kutu kayıp ve validasyon/kutu kayıp sonuçları

- Kutu kayıpları grafiği, modelin nesnelerin sınırlayıcı kutularını ne kadar doğru tahmin ettiğini gösteren metriktir. Grafikteki değerler azaldıkça, modelin doğruluğunun artış gösterdiği söylenebilmektedir.
    - train/box_loss: Eğitim veri seti üzerinde, kutu kaybını gösteren grafiktir ve grafikte bu değerin azaldığı gözlemlenmektedir.
    - val/box_loss: Doğrulama veri seti üzerinde, kutu kaybını gösteren grafiktir ve benzer biçimde değer azalmaktadır.

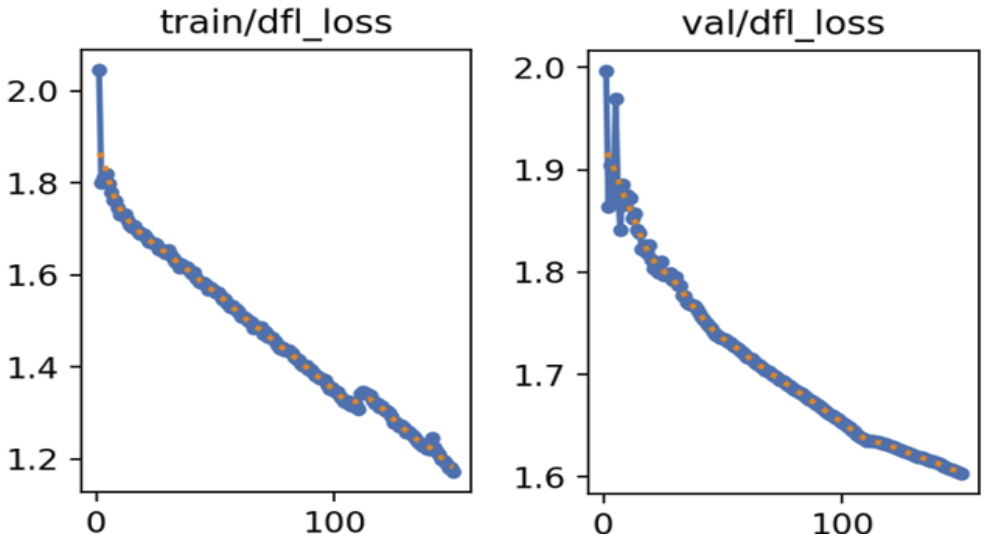
Grafiklerde, Eğitim veri kümesi üzerinde yapılan, kutu kayıp değerinin 2,25 ile başlayıp 150. İterasyon itibari ile 1'in altına indiği görülmektedir. Benzer biçimde Validasyon veri kümesi üzerinde de 2,1 ile başlayan kayıp değerinin 1.4 altına indiği gözlemlenmektedir. İki grafikte de benzer biçimde azalma ve model başarısının arttığı görülmektedir.



Şekil 4. 16 Eğitim/Sınıf kayıp ve validasyon/sınıf kayıp sonuçları

- Sınıflandırma Kaybı grafiği, modelin nesnelerin sınıflarını doğru şekilde sınıflandırma yeteneğini ölçmektedir. Değerin düşmesi tercih edilen durumdur.
    - train/cls_loss: Eğitim veri seti üzerinde sınıflandırma tahmini kaybını gösteren grafiktir. Grafikteki değerlerde iterasyonlar ile, azalma eğilimi görülmektedir.
    - val/cls_loss: Doğrulama veri seti üzerinde, sınıflandırma tahmini kaybını gösteren grafiktir. Grafikteki değerlerde iterasyonlar ile, azalma eğilimi görülmektedir.

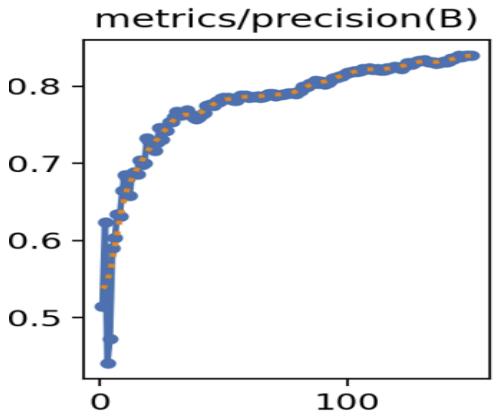
Grafiklerde, Eğitim veri kümesi üzerinde yapılan, sınıf kayıp değerinin 2,5 ile başlayıp 150. İterasyon itibari ile 0,5'in altına indiği görülmektedir. Benzer biçimde Validasyon veri kümesi üzerinde de 1,8 ile başlayan kayıp değerinin 0,6 altına indiği gözlemlenmektedir. İki grafikte de benzer biçimde azalma ve model başarısının arttığı görülmektedir.



Şekil 4. 17 Eğitim/Dağılım kayıp ve validasyon/dağılım kayıp sonuçları

- DFL Kaybı grafiği, modelin doğruluk kaybı ile ilgili metriktir. Eğitilen modelin tahminlerinin doğruluğunu ve güven puanını arttırmak için kullanılmaktadır.
    - train/dfl_loss: Eğitim veri seti üzerinde, doğruluk kaybı değerini göstermektedir. Grafikte kaybın düşüş eğiliminde olduğu görülmektedir. 110. iterasyonda bir artış hareketi gelmiş ve grafik tekrar azalma eğilimine girmiştir.
    - val/dfl_loss: Doğrulama veri seti üzerinde, doğruluk kaybı değerini göstermektedir. Grafikte kaybın düşüş eğiliminde olduğu görülmektedir.

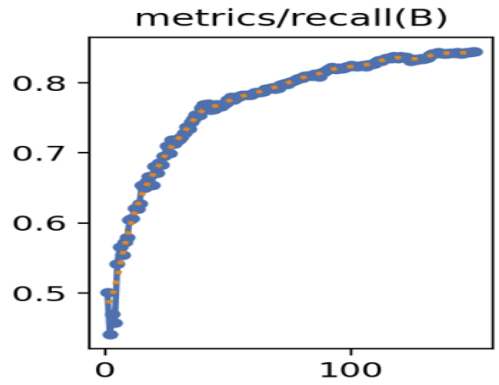
Grafiklerde, Eğitim veri kümesi üzerinde yapılan, dağılım kayıp değerinin 2,1 ile başlayıp 150. İterasyon itibari ile 1,2'nin altına indiği görülmektedir. Benzer biçimde Validasyon veri kümesi üzerinde de 2,0 ile başlayan kayıp değerinin 1,6 altına indiği gözlemlenmektedir. İki grafikte de benzer biçimde azalma ve model başarısının arttığı görülmektedir.



Şekil 4. 18 Modelin hassasiyet (Precision) performansı

- Hassasiyet, modelin doğru pozitif tahminlerinin, toplam pozitif tahminlere oranını göstermektedir. Grafikte değerlerin yükselmesi, model performansının arttığına ve modelin daha az sayıda yanlış pozitif (hatalı tahmin) yaptığına işaret etmektedir. Modelde, hassasiyet değerinin 0,2 ile başlayıp artış göstererek 0,9 seviyelerine ulaştığı görülmektedir.

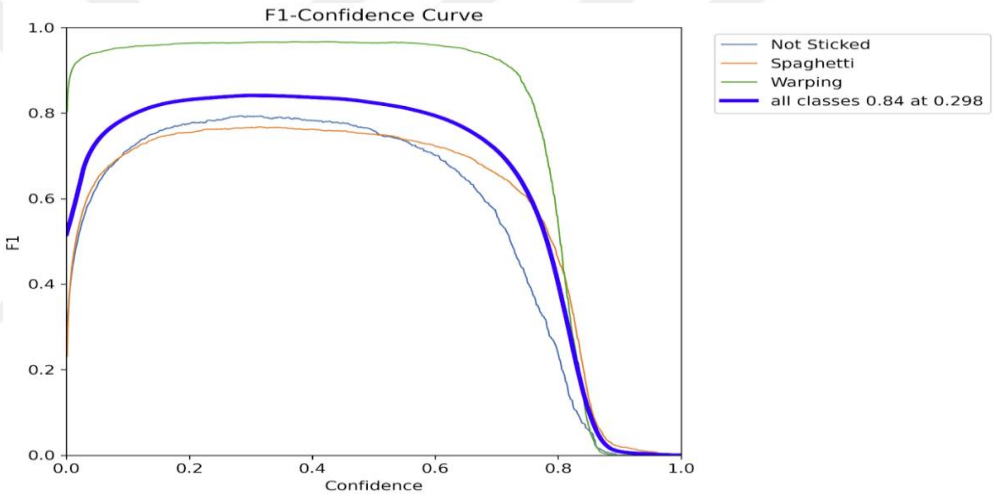
Hassasiyet, tek başına değerlendirilmesi doğru olmayan bir metriktir. Hassasiyet değerlendirilirken Duyarlılık (Recall) metriği göz ardı edilmemelidir. Göz ardı edilmesi durumunda model bazı doğru pozitif değerleri kaçırabilmektedir. Çok yüksek hassasiyet değerleri olması durumunda, duyarlılık değerleri düşebilmektedir. Bu nedenle bu iki metrik arasında denge kurmak önem arz etmektedir.



Şekil 4. 19 Modelin geri çağırma-duyarlılık (Recall) performansı

- Duyarlılık, modelin doğru pozitif tahminlerinin, gerçek pozitif tahminlere oranını göstermektedir. Grafikte değerlerin yükselmesi, modelin gerçek pozitif değerleri tahmin oranının arttığını göstermektedir. Modelde, duyarlılık değerinin artış gösterdiği görülmektedir. 0,5 ile başlayan değerin 0,9 üzerine çıktığı ve modelin başarısının iterasyonlar ile artış gösterdiği gözlemlenmektedir.

Duyarlılık, yanlış pozitif tahminleri dikkate almamaktadır. Bu nedenle, bu tahminler ile ilgili bilgi vermemektedir. Yüksek duyarlılık değeri, hassasiyet değerinin düşmesine sebep olabilmektedir. Bu nedenle iki metriğinde yükseliş eğrisinde olduğundan emin olunmalıdır.



Şekil 4. 20 Modelin F1 metriği performansı

F1 Skoru, hassasiyet ve geri çağırma metriklerinin harmonik ortalamasıdır ve modelin genel performansının yorumlanmasında kullanılan güvenilir bir metriktir.

- X ekseninde, modelin tahminlerinde hangi güven aralığında olduğu görülmektedir.
- Y ekseninde, F1 skor değerleri görülmektedir. Buradaki eğrilerin ulaştığı maksimum değerler arttıkça, modelin sınıflar için hem hassasiyet hem de geri çağırma değerlerine sahip olduğu görülmektedir.

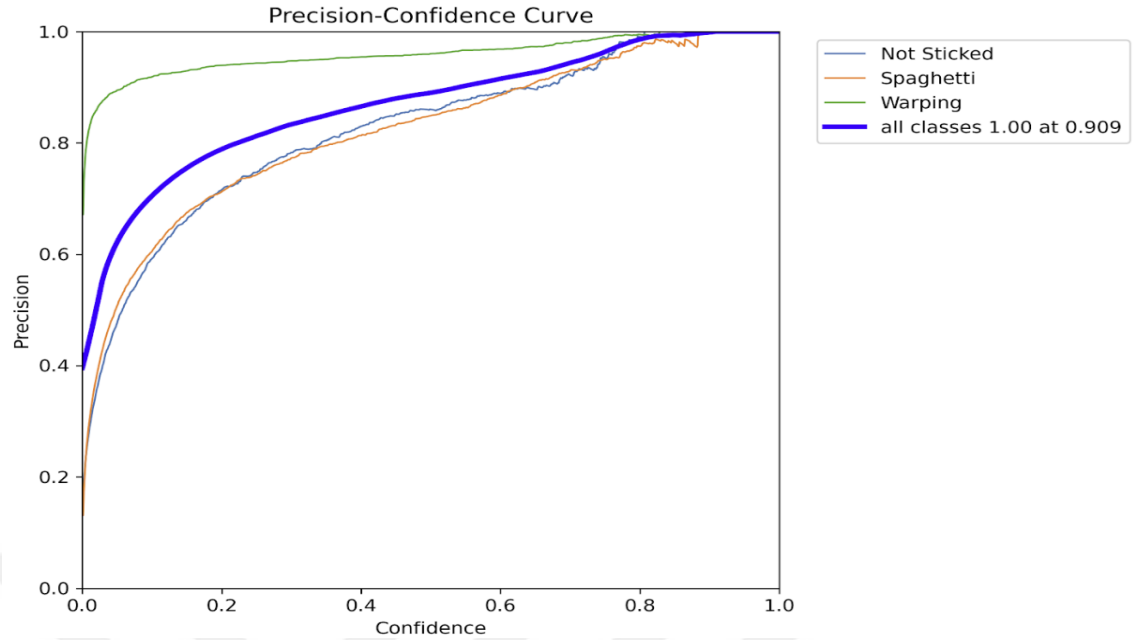
- Mavi Eğri (Yatağa Yapışmama)
- Turuncu Eğri (Spagetti)
- Yeşil Eğri (Çarpılma – Tabladan Kalkma)
- Kalın Mavi Eğri (Tüm Sınıflar)

Şeklinde ifade edilmektedir.

Grafikten elde edilen sonuçlar, bu eğri üzerinde en iyi F1 skorunun 0,84 güven değerinde olduğunu göstermektedir. Grafikte, F1 skorunun belirli bir güven seviyesine kadar arttığı ardından azaldığı görülmektedir. Bu sonuç, modelin hassasiyet ve geri çağırma arasındaki dengenin sağlandığını göstermektedir.

- Çarpılma (Tabladan Kalkma) sınıfı, grafikteki en yüksek F1 skoruna sahiptir ve güven seviyesi arttıkça F1 skoru çok az miktarda düşmektedir. Bu sonuç, çarpılma sınıfının hem yüksek hassasiyet hem de yüksek geri çağırma değerine sahip olduğunu göstermektedir.
- Spagetti sınıfında, güven seviyesi artıkça F1 skorunun arttığı ve ardından azaldığı görülmektedir. Spagetti sınıfının, belirli güven seviyelerinde başarılı olduğu ancak çarpılma sınıfı kadar dengeli olmadığı görülmektedir.
- Tablaya yapışmama sınıfı, diğer sınıflara göre daha düşük F1 skoru değerine sahiptir. Bu sınıfın, veri sayısının arttırılması başarıyı arttıracaktır.

Tüm sınıflar için elde edilen sonuçların gösterildiği kalın mavi eğride, modelin en iyi F1 skoru olan 0,84 değerini, 0,298 güven seviyesinde verdiği görülmektedir.



Şekil 4. 21 Modelin P eğrisi metriği performansı

P Eğrisi, modelin farklı güven seviyelerinde, hassasiyet değerlerini göstermektedir. Hassasiyet, modelin pozitif tahminlerinin başarısını ölçmektedir.

- X ekseninde, 0'dan 1'e kadar değişen değerlerde, modelin pozitif tahminler için belirlediği güven eşik değeri temsil edilmektedir.
- Y ekseninde ise, hassasiyet değeri yani modelin pozitif tahminlerinin ne kadarının doğru olduğu ifade edilmektedir. Hassasiyet değeri arttıkça modelin pozitif olarak sınıflandırdığı örneklerin, doğru tahmin olduğu ifade edilmektedir.
    - Mavi Eğri (Yatağa Yapışmama)
    - Turuncu Eğri (Spagetti)
    - Yeşil Eğri (Çarpılma – Tabladan Kalkma)
    - Kalın Mavi Eğri (Tüm Sınıflar)

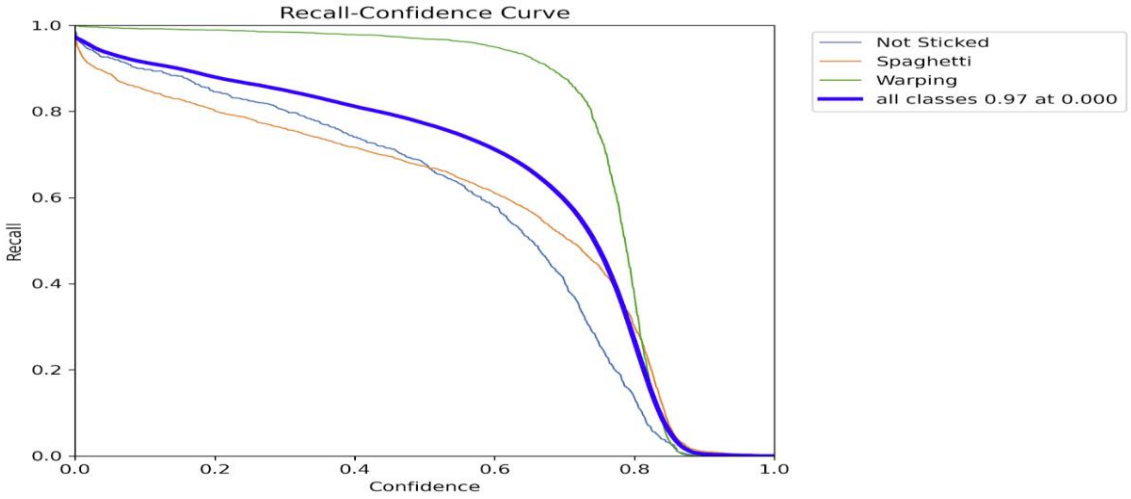
Şeklinde ifade edilmektedir.

Grafikten elde edilen sonuçlar, güven seviyesi arttıkça hassasiyet değerinin de arttığını göstermektedir. Bu, modelin pozitif tahminlerde daha yüksek doğruluk sağladığını göstermektedir. Ancak yüksek güven seviyelerinde, hassasiyet değeri sabit bir eğriye

dönüşmektedir. Bu da modelin yüksek güvenirlikli tahminlerini sınıflandırdığı anlamına gelmektedir.

- Çarpılma (Tabladan Kalkma) sınıfı, grafikteki en yüksek F1 skoruna sahiptir. Bu modelin, pozitif tahminlerde çok yüksek doğruluk sağladığını göstermektedir.
- Spagetti sınıfında, güven seviyesi artıkça, hassasiyet seviyesinin de artış gösterdiği görülmektedir.
- Tablaya yapışmama sınıfı, diğer sınıflara göre daha düşük hassasiyet değerine sahiptir. Ancak iterasyonlar ile değerin artış gösterdiği, bu nedenle başarılı olduğu gözlemlenebilmektedir.

Tüm sınıflar için elde edilen sonuçların gösterildiği kalın mavi eğride, tüm sınıfların ortalama hassasiyet değeri görülmektedir. Bu eğride modelin en iyi hassasiyet değerini 0,909 güven değerinde sağlayabildiği görülmektedir. Bu da modelin en iyi hassasiyet değerini 0,909 güven seviyesinde verdiğini göstermektedir.



Şekil 4. 22 Modelin R eğrisi metriği performansı

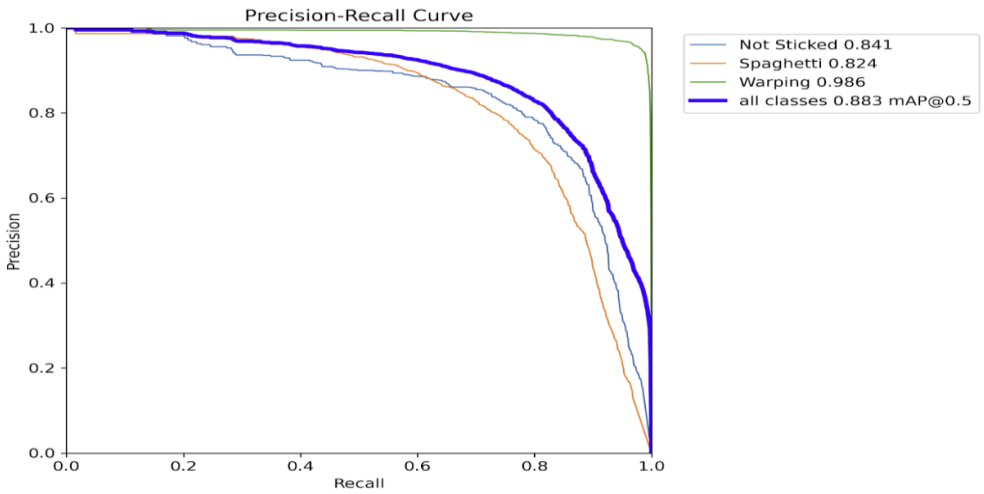
R eğrisi, modelin farklı güven seviyelerinde geri çağırma değerini göstermektedir. Geri çağırma, modelin gerçek pozitifleri ne kadar iyi tespit ettiğini göstermektedir.

- X ekseninde, 0’dan 1’e kadar değişen değerlerde, modelin pozitif tahminler için belirlediği güven eşik değeri temsil edilmektedir.
- Y ekseninde ise, geri çağırma değeri, modelin pozitif örneklerin ne kadarını doğru sınıflandırdığını göstermektedir. Yüksek geri çağırma değeri, modelin tüm pozitif örnekleri tespit etme oranının yükseldiğini ifade etmektedir.
    - Mavi Eğri (Yatağa Yapışmama)
    - Turuncu Eğri (Spagetti)
    - Yeşil Eğri (Çarpılma – Tabladan Kalkma)
    - Kalın Mavi Eğri (Tüm Sınıflar)

Şeklinde ifade edilmektedir.

- Çarpılma (Tabladan Kalkma) sınıfı, tüm güven seviyelerinde en yüksek geri çağırma değerine sahip olan sınıftır. Bu, modelin pozitif örnekleri tespit etme başarısında diğer sınıfların önünde olduğunu ifade etmektedir.
- Spagetti sınıfında, güven seviyesi artıkça, geri çağırma değeri düzenli olarak azalmakta ve modelin başarılı olduğunu göstermektedir.
- Tablaya yapışmama sınıfı, diğer sınıflara göre daha düşük geri çağırma değerine sahiptir.

Tüm sınıflar için elde edilen sonuçların gösterildiği kalın mavi eğride, tüm sınıfların ortalama geri çağırma değeri gösterilmektedir. Bu, modelin en iyi geri çağırma değerini (0,97) ifade eden eğridir.



Şekil 4. 23 Modelin PR eğrisi metriği performansı

PR eğrisi, modelin hassasiyet ve geri çağırma metrikleri arasındaki ilişkiyi göstermektedir. Modelin pozitif tahminlerinin doğruluğunu ve kapsama alanının aynı anda değerlendirilebilmesi için kullanılan grafik, farklı güven seviyelerinde modelin hassasiyet ve geri çağırma değerlerini göstermektedir.

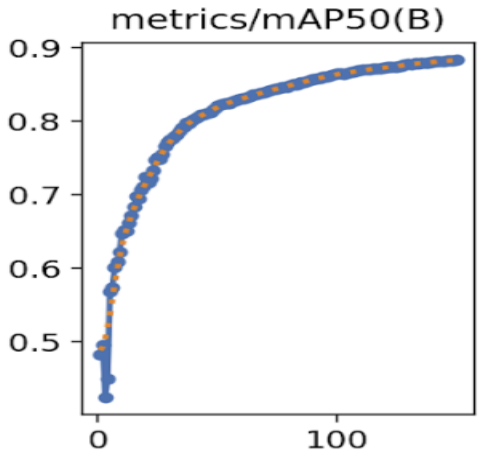
- X ekseninde, modelin gerçek pozitiflerin ne kadarının doğru tespit edildiğini ifade eden geri çağırma verisi bulunmaktadır. Geri çağırma değeri arttıkça, modelin tüm pozitif örnekleri tespit etme oranı yükselmektedir.
- Y ekseninde ise, modelin pozitif tahminlerinin ne kadarının doğru olduğu gösterilmektedir. Yüksek hassasiyet, modelin pozitif olarak sınıflandırdığı örneklerin gerçekten pozitif yani doğru tahmin edildiğini ifade etmektedir.
    - Mavi Eğri (Yatağa Yapışmama)
    - Turuncu Eğri (Spagetti)
    - Yeşil Eğri (Çarpılma – Tabladan Kalkma)
    - Kalın Mavi Eğri (Tüm Sınıflar)

Şeklinde ifade edilmektedir.

Grafik incelendiğinde, geri çağırma değeri arttıkça, hassasiyet değerinin düştüğü görülmektedir. Bu sonuç, modelin daha fazla pozitif tahmin yaptığında, yanlış pozitif sayısının da arttığını göstermekte ve istenmeyen bir duruma işaret etmektedir.

- Çarpılma (Tabladan Kalkma) sınıfı, tüm güven seviyelerinde en yüksek geri çağırma ve hassasiyet değerine sahip olan sınıftır. Bu, modelin pozitif tahminlerinde çok yüksek doğruluk ve kapsama alanına sahip olduğunu ifade etmektedir.
- Spagetti sınıfında, hassasiyet ve geri çağırma değerleri, çarpılma sınıfına göre daha düşük seviyelerdedir. Güven seviyesi arttıkça, geri çağırma değeri azalmakta ancak hassasiyet yüksek seviyelerde seyretmektedir.
- Tablaya yapışmama sınıfı, diğer sınıflara göre daha düşük geri çağırma ve hassasiyet değerine sahiptir. Güven seviyesi arttıkça, geri çağırma değeri hızla düşmekte ve modelin tablaya yapışmama sınıfında pozitif örnekleri tespit etme oranının daha düşük olduğuna işaret etmektedir.

Tüm sınıflar için elde edilen sonuçların gösterildiği kalın mavi eğride, tüm sınıflar için ortalama hassasiyet ve geri çağırma değerleri gösterilmektedir. Bu eğri üzerinde, modelin en iyi ortalama geri çağırma ve hassasiyet değerlerine 0,5 eşik değerinde ve 0,883 değeri ile ulaştığı, modelin bu değerde yüksek performans gösterdiği görülmektedir.

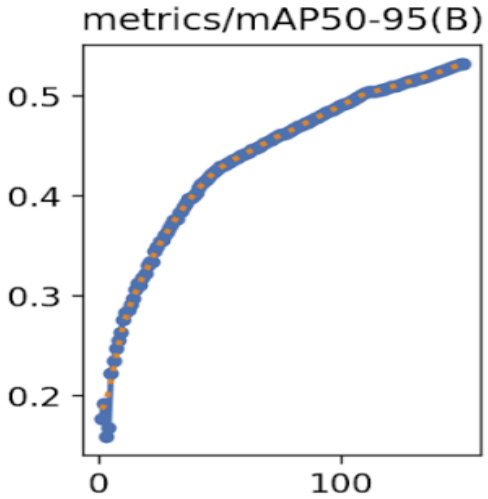


Şekil 4. 24 Modelin mAP50 metriği performansı

Bu grafik, modelin eğitimi süresinde 0,5 eşik değeri kullanılarak hesaplanan ortalama hassasiyet (Mean Average Precision – mAP50) değerini ifade etmektedir. mAP50 değeri, bir modelin genel performansını ölçen metriklerden bir tanesi olmakla birlikte, modelin doğruluk ve kapsamının değerlendirilmesini sağlamaktadır.

- X ekseninde, eğitim sürecindeki iterasyon sayısı gösterilmektedir.
- Y ekseninde ise, mAP50 yani modelin ortalama hassasiyet değeri gösterilmektedir.
- Eğri ise, modelin her bir iterasyondaki mAP50 performansını ifade etmektedir. Noktalar her bir iterasyondaki mAP50 değerini; kesikli çizgi ise bu değerlerin ortalama trendini göstermektedir.

Grafikte, mAP50 değerinin yaklaşık 0,5 mAP50 değeri ile başladığını, ilk 10 iterasyon içerisinde belirli oranda düşüş gösterdiğini, ardından hızla yükselerek 0,9 değerlerine yaklaştığı görülmektedir. Bu eğri, modelin başarılı şekilde tahminler gerçekleştirebildiğini göstermektedir. 100. İterasyon sonrasında mAP50 eğrisinin eğiminin azaldığı ancak tam olarak yatay seyretmediği görülmektedir. İterasyon sayısı arttırılarak model performansının az da olsa arttırılabileceği gözlenebilmektedir.

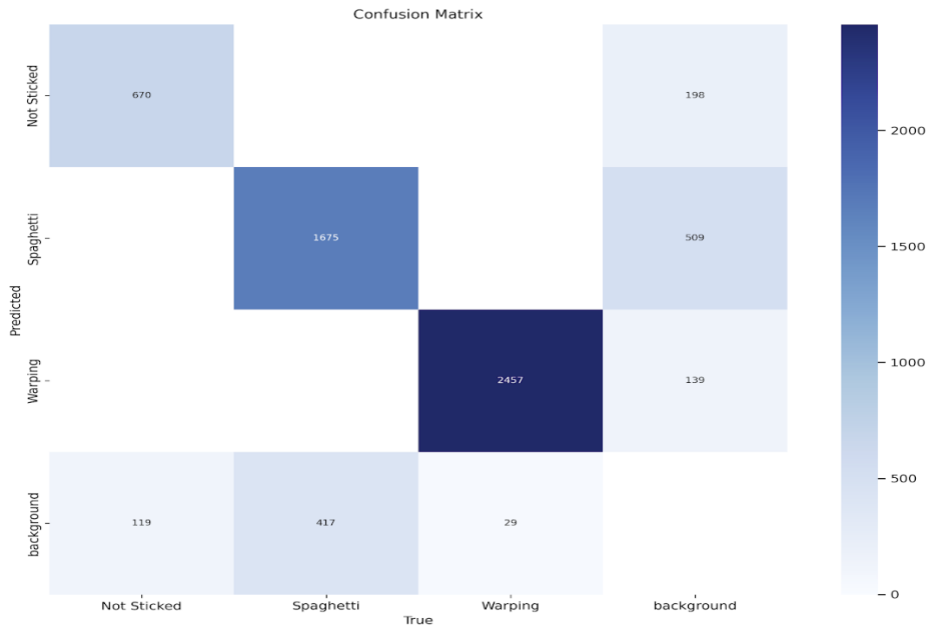


Şekil 4. 25 Modelin mAP50-95 metriği performansı

Şekil 4.25’te, modelin eğitimi boyunca, farklı IOU (Intersection Over Union) eşik değerlerinde, hesaplanan ortalama hassasiyet değerini gösteren mAP50-95 göstergesine ait değerler görülmektedir. mAP50-95, modelin performansının 0,5 – 0,95 güven aralıklarında değerlendirmekte ve modelin genel doğruluk ve kapsamını daha ayrıntılı biçimde ortaya koymaktadır.

- X ekseninde, eğitim sürecindeki iterasyon sayısı gösterilmektedir.
- Y ekseninde ise, mAP50-95 yani modelin ortalama hassasiyet değeri gösterilmektedir.
- Eğri ise, modelin her bir iterasyondaki mAP50-95 performansını ifade etmektedir. Noktalar her bir iterasyondaki mAP5-950 değerini; kesikli çizgi ise bu değerlerin ortalama trendini göstermektedir.

Grafikte, mAP50-95 değerinin yaklaşık 0,2 mAP50-95 değeri ile başladığını, ilk 5 iterasyon içerisinde belirli oranda düşüş gösterdiğini, ardından hızla yükselerek 0,6 değerlerine yaklaştığı görülmektedir. Bu eğri, modelin başarılı şekilde tahminler gerçekleştirebildiğini göstermektedir. 100. İterasyon sonrasında mAP50-95 eğrisinin eğiminin azaldığı ancak tam olarak yatay seyretmediği görülmektedir. İterasyon sayısı arttırılarak model performansının az da olsa arttırılabileceği gözlenebilmektedir.



Şekil 4. 26 Modelin karışıklık matrisi performansı

Bu grafik, modelin performansını değerlendirmek için kullanılan karışıklık matrisini göstermektedir. Karışıklık matrisi, modelin tahmin sonuçları ile gerçek sınıf etiketleri arasındaki ilişkileri 4 kategoride ifade etmektedir. Bu kategoriler;

- Doğru Pozitif (TP)
- Yanlış Pozitif (FP)
- Doğru Negatif (TN)
- Yanlış Negatif (FN)

olarak belirlenmiştir.

- X ekseninde, veri seti içerisinde gerçek sınıflar gösterilmektedir.
- Y ekseninde, modelin tahmin ettiği sınıfları göstermektedir.
- Hücrelerde, modelin belirli sınıflar için yapmış olduğu tahminlerin sayısı gösterilmektedir.

Köşegen hücreler, doğru pozitifleri (TP) ifade etmekte ve modelin doğru tahmin ettiği verileri göstermektedir. Model,

- Tablaya yapışmama sorununu 670 defa doğru tahmin etmiş ve bu sonuç modelin **85%** başarı ile doğru tahmin gerçekleştirdiği anlamına gelmektedir.
- Spagetti sorununu 1675 defa doğru tahmin etmiş ve bu sonuç modelin **80%** başarı ile doğru tahmin gerçekleştirdiği anlamına gelmektedir.
- Çarpılma (Tabladan Kalkma) sorununu 2457 defa doğru tahmin etmiş ve bu sonuç modelin **99%** başarı ile doğru tahmin gerçekleştirdiği anlamına gelmektedir.

Köşegen olmayan hücreler, yanlış pozitifleri (FP) ve yanlış negatifleri (FN) ifade etmekte ve modelin yanlış tahmin ettiği verileri göstermektedir. Model,

- 198 kez başka bir sınıf olmasına rağmen hatayı, tablaya yapışmama sorunu olarak tahmin etmiştir (FP). 119 kez ise, tablaya yapışmama sorununu başka bir sınıf olarak tahmin etmiştir (FN).
- 509 kez başka bir sınıf olmasına rağmen hatayı, spagetti sorunu olarak tahmin etmiştir (FP). 417 kez ise, spagetti sorununu başka bir sınıf olarak tahmin etmiştir (FN).
- 139 kez başka bir sınıf olmasına rağmen hatayı, çarpılma (tabladan kalkma) sorunu olarak tahmin etmiştir (FP). 29 kez ise, tablaya yapışmama sorununu başka bir sınıf olarak tahmin etmiştir (FN).

Modelin genel performansı incelendiğinde, diğer metriklere benzer sonuçlar elde edilmiştir. Çarpılma sınıfı, en yüksek doğru tahmin sayısı ve en yüksek başarı oranına sahiptir. Tablaya yapışmama ve spagetti sınıflarında nispeten daha fazla hatalı tahmin yapıldığı bu nedenle başarı oranlarının daha düşük olduğu gözlemlenmiştir. Sonuçlara dayanarak, spagetti ve tablaya yapışmama sorunları için ek çalışmalar model performansını arttıracaktır.

Model, 25 Saat 32 dakika eğitim süreci sonunda tamamlanmış ve metrikler incelenmiştir. Model başarısı, çalışma için yeterli görülmüş ve sonraki aşama ile çalışmaya devam edilmiştir.

Son aşama olarak, kullanıcıya bilgi verilmesi sağlanacaktır. Bu çalışma için, gerçek zamanlı verilerin belirli bir süre içerisinde yeterli süre tespit edilmesi gerekmektedir.

Gerçek zamanlı nesne tanıma çalışmalarında model başarılı olmasına karşın, birçok kez sınıflar hatalı olarak tespit edilebilmekte bu nedenle bazı filtrelemelerin kullanılması çalışmanın güvenilirliğini arttıracaktır.

Bildirim sisteminde aşağıda verilen filtrelemelere yer verilmiş ve bu sayede daha güvenilir ve anlaşılır bildirimler kullanıcıya iletilecektir.

- Sistemde, her tanımlama adımı sonrasında .txt formatında log dosyası tutulacaktır.
- Python ile oluşturulan program sayesinde, log dosyası gerçek zamanlı olarak okunacaktır.
- Okunan log dosyasında her 10 adım içerisinde minimum 6 kez hata tespitine rastlanması halinde sistem tetiklenecektir.
- Kullanıcıya bildirim gönderilmesi için Telegram API kullanılacaktır.
- Sistemde gerekli koşullar sağlanması halinde Şekil 4.15'te görüldüğü üzere Telegram üzerinde oluşturulan bot aracılığı ile kullanıcıya;
    - Hata İsmi
    - Hata Tanımlama Oranı
    - Hata Görseli

  Bilgileri gönderilecektir.

Bu filtrelemelerin gerçekleştirilmesi adına, Python 3.10 programlama diline başvurulacaktır.



Şekil 4. 27 Bildirim sistemi tarama örneği

- Hatanın çözümü mümkün ise, kullanıcı, üretimin sürmesini sağlayacak aksiyonlar gerçekleştirebilecektir.
- Üretimin devam etmesi mümkün değilse, kullanıcı hatalı üretimi sonlandırarak, zaman, maliyet tasarrufu sağlayacak ve olası cihaz arızalarının önüne geçebilecektir.

5. SONUÇ ve TARTIŞMA

Eklemeli imalat yöntemlerinin hızla geliştiği ve yaygınlaştığı günümüzde, üretim sürecinin operatör veya kullanıcı tarafından sürekli olarak gözlenmesi mümkün olamamaktadır. Bu problemlerin tespiti için görüntü işleme sistemleri öne çıkan teknolojilerden bir tanesidir.

Bu çalışmada, en ulaşılabilir ve en sık kullanılan Katmanlı İmalat yöntemlerinden Eriyik Birikme Modelleme (FDM) teknolojisi ile çalışan cihazlarda görülen problemlere çözüm sağlayacak gerçek zamanlı görüntü işleme sistemi geliştirilmiştir. Bu sistem için YOLO algoritması v8 sürümünün önceden eğitilmiş Medium modelinin ağırlık verileri kullanılmış ve problemler için veri kümeleri oluşturularak özel nesne algılama modeli eğitilmiştir.

Veri toplama ve arttırma yöntemlerine başvurularak, modelin performansı arttırılmıştır. Literatürde belirtilen diğer çalışmalarla yapılan kıyaslamalarda, bu çalışmada eğitilen model ve kullanılan yöntemlerin daha yüksek başarı oranlarına ulaştığı görülmektedir. İlgili metodolojinin farklı eklemeli imalat yöntemleri ile de kullanılabilmesi mümkündür.

Geliştirilen sistem sayesinde;

- Spagetti Hatası
- Çarpılma (Tabladan Kalkma) Hatası
- Yatağa Yapışmama Hatası

Hataları gerçek zamanlı olarak izlenerek, kullanıcıya bildirilecektir. Yapılan testler sonucunda, modelin yüksek doğruluk ile hataları tespit ettiği görülmüştür.

Bu sayede kullanıcı, cihaz başında olmadığı durumlarda da üretimi gerçek zamanlı olarak izleyebilecek ve izlemediği durumlarda da gerçek zamanlı nesne tanıma sistemi sayesinde hatalardan oluştuğu anda haberdar olabilecektir.

Bu çalışmanın ana katkılarını aşağıdaki gibi sıralamak mümkündür.

- Çalışma sırasında üretim sürecinin canlı olarak gözlemlenebilmesi

- Üretim sürecinde hata oluşması halinde kullanıcının anlık olarak bilgilendirilmesi
- Hatanın, üretimin devam etmesine engel olmayacağı kararı verilmesi halinde üretimin devam etmesi veya gerekli sistemsel değişikliklerin sağlanarak üretimin devam ettirilebilmesi
- Hatanın üretime devam etmesine engel olduğu durumlarda, oluşabilecek malzeme ve zaman israfının önüne geçilmesi ve olası cihaz arızalarının önüne geçilmesi

Bu çalışmada YOLO v8 görüntü işleme modeli kullanılarak 95% başarı oranına ulaşılmıştır. Zhang ve arkadaşları (2022) yaptıkları çalışmada yüksek çözünürlüklü kameralar ve görüntü işleme algoritmaları kullanarak, 91% başarı oranına ulaşabilmişlerdir. Son olarak Lee ve Chung (2019) gerçekleştirdikleri çalışmada 90% oranında başarı elde edebilmişlerdir. Bu çalışmalar ile karşılaştırıldığında, gerçekleştirilen çalışmanın yüksek başarıya sahip olduğu görülebilmektedir.

Gelecek çalışmalarda, daha gelişmiş kamera sistemleri kullanılması ve mobil uygulama üzerinden kontrol özelliklerinin geliştirilerek sisteme eklenmesi hedeflenmektedir. FDM teknolojisi kullanılarak üretilen ürünler için geliştirilen sistemin eklemeli imalatın farklı tekniklerinde de devreye alınması planlanmaktadır. Bu sayede, gelişen eklemeli imalat pazarında farklı cihazlar üzerinde de otomatik kontrol sistemlerinin yaygınlaştırılarak, sektöre katkı sağlaması amaçlanmaktadır.

KAYNAKLAR

Agarwal A. et al. (2021). *Classification model for accuracy and intrusion detection using machine learning approach.* PeerJ Computer Science

Ali M., Obayya M., Asghar J. (2022, Nov.). *Machine learning based skin lesion segmentation method with novel borders and hair removal techniques.* Plos One

Birosz, M. T., Ledenyák, D., & Andó, M. (2022, Sept). *Effect of FDM infill patterns on mechanical properties.* Polymer Testing, 113, 107654.

Celik S., Comertler N. (2021). *Investigation of Happiness of Countries with K-Means Clustering and Discriminant Analysis*. JoCReBE. ISSN: 2547-9628.

Erinie T. J. (2024, March). *From Pixels to Prototypes The Engineer's Exploration of Additive Manufacturing*

Garfo, S., et al. (2020). *Defect Detection on 3D Print Products and in Concrete Structures Using Image Processing and Convolution Neural Network.* North Carolina A&T State University.

George M., C. Lakshmi (2013). *Object detection using the Canny Edge Detector*

Hussain, M. (2023). *YOLO-v1 to YOLO-v8, the Rise of YOLO and Its Complementary Nature toward Digital Manufacturing and Industrial Defect Detection.* Machines, 11(7), 677.

Redmon J., Divvala S., Girshick R., Farhadi A. (2015). *You Only Look Once: Unified, Real-Time Object Detection.* arXiv:1506.02640.

Kamer, M. S., Temiz, Ş., Yaykaşlı, H., Kaya, A., & Akay, O. (2022). *Effect of printing speed on FDM 3D-printed PLA samples produced using different two printers.* International Journal of 3D Printing Technologies and Digital Industry, 6(3), 438-448.

Karagöz, İ., Bekdemir, A. D., & Tuna, Ö. (2021, Aug). *3B Yazıcı Teknolojilerindeki Kullanılan Yöntemler ve Gelişmeler Üzerine Bir Derleme.* Düzce Üniversitesi Bilim ve Teknoloji Dergisi, 9(4), 1186-1213.

Khan, M.F., et al. (2021). *Real-time defect detection in 3D printing using machine learning.* Aligarh Muslim University.

Koubaa, S., Baklouti, M., Mrad, H., Frikha, A., Zouari, B., & Bouaziz, Z. (2021). *Defect Detection in Additive Manufacturing Using Computer Vision Monitoring.* Design and Modeling of Mechanical Systems - V (CMSM 2021). Springer.

Wang R., Chung C.F. (2022). *CenterNet-based defect detection for additive manufacturing.* Expert Systems with Applications.

Li, C., et al. (2018). *Deep Learning Techniques for In-Situ Monitoring of Laser-Based Additive Manufacturing.*

Liu, W., Anguelov, D., Erhan, D., Szegedy, C., Reed, S., Fu, C.-Y., & Berg, A. C. (2016, Dec). *SSD: Single Shot MultiBox Detector.* arXiv.

Meram A., Sozen B. (2020). *Investigation on the manufacturing variants influential on the strength of 3D printed products.* Research on Engineering Structures and Materials

Ozdemir H.C., (2023*). Eklemeli İmalat Yöntemi ile Üretilmiş Parçalara Üretim Sonrası Yapılan İşlemlerin Yüzey Kalitesine ve Mekanik Özelliklerine Etkisinin İncelenmesi.* Gazi Universitesi

Pang, R. (2022). *The Effect of Printing Temperature on Bonding Quality and Tensile Properties of Fused Deposition Modelling 3D-Printed Parts.* IOP Conference Series: Materials Science and Engineering, 1257, 012031.

Paoletti I., Ceccon L. (2018). *The Evolution of 3D Printing in AEC: From Experimental to Consolidated Techniques.*

Pernet, B., Nagel, J. K., & Zhang, H. (2022). *Compressive Strength Assessment of 3D Printing Infill Patterns.* Procedia CIRP, 105, 682-687.

Petrović, I., et al. (2020). *Machine Vision Systems for Detection of Structural Defects in Additive Manufacturing.*

Pham, D.L., Chang, T.W. (2023). *A YOLO-based real-time packaging defect detection system.* Procedia Computer Science 217(1):886-894.

Ji W., Zhou R., et al. (2023). *Recent progress in gradient-structured metals and alloys.* Progress in Material Science, 101194

Sidambe, A. (2014, Dec). *Biocompatibility of Advanced Manufactured Titanium Implants—A Review.* Materials, 7(12), 8168-8188.

Suteja, J. (2021). *Effect of infill pattern, infill density, and infill angle on the printing time and filament length of 3D printing.* International Journal of 3D Printing Technologies and Digital Industry, artikel 16, 145-152.

Wang, W., Wang, P., Zhang, H., Chen, X., Wang, G., Lu, Y., (2023). *A Real-Time Defect Detection Strategy for Additive Manufacturing Processes Based on Deep Learning and Machine Vision Technologies.* Micromachines.

Wang G., Li W., Haiou W., Xiong G. (2023). *Deep learning based online metallic surface defect detection method for wire and arc additive manufacturing.* Robotics and Computer-Integrated Manufacturing 80:102470

Wu, J., Huang, C., Li, Z., Li, R., Wang, G., (2023). *An in-situ surface defect detection method based on improved you only look once algorithm for wire and arc additive manufacturing.* Rapid Prototyping Journal 1355-2546

Xu, L., Zhang, X., Ma, F., Chang, G., Zhang, C., (2023). *Detecting defects in fused deposition modeling based on improved YOLO v4.* Materials Research Express.

Yuan T., Lv L., Zhang F., Fu J., (2020). *Robust Cherry Tomatoes Detection Algorithm in Greenhouse Scene Based on SSD.* Agriculture 10(5):160

Zhang, S., Chen, Z., Granland, K., Tang, Y., (2022). *Machine Vision-Based Scanning Strategy for Defect Detection in Post-Additive Manufacturing.*

Zhao, H., Wang, X., Sun, J., Wang, Y., Chen, Z., (2024). *Artificial intelligence powered real-time quality monitoring for additive manufacturing in construction.* Construction and Building Materials.

Zheng W., Wei Q., et al. (2018). *3D Printed Porous Bone Constructs*. Orthopedic Biomaterials

Zisopol, D. G., Nae, I., & Portoaca, A.-I., (2022). *Compression Behavior of FFF Printed Parts Obtained by Varying Layer Height and Infill Percentage.* Engineering, Technology & Applied Science Research, 12(6), 9747-9751.

Zubayer, M.H., Xiong, Y., Wang, Y., Imdadul, H.M., (2024). *Enhancing additive manufacturing precision: Intelligent inspection and optimization for defect-free continuous carbon fiber-reinforced polymer.* Composites Part C: Open Access.

INTERNET KAYNAKLARI

URL 1: 3D Experience Erişim Adresi https://www.3ds.com/make/guide/process/binder-jetting

URL 2: Ak Filament Erişim Adresi https://akfilament.com/ilk-katman-kalibrasyonu/

URL 3: Bandyopadhyay (2022 Jun). What is computer vision? Erişim adresi https://www.v7labs.com/blog/what-is-computer-vision

URL 4: Be Tech! With Santander (2023 Jun). Computer vision vs. human vision: This is how computers see. Erişim adresi https://medium.com/be-tech-with-santander/computer-vision-vs-human-vision-this-is-how-computers-see-e2f4a5ed61dc

URL 5: Bilen B. Karmaşıklık Matrisi (2021). Erişim adresi https://burhanbilen.medium.com/kar%C4%B1%C5%9F%C4%B1kl%C4%B1k-matrisi-confusion-matrix-990dfc718653

URL 6: Color With Leo. What secondary color is made by mixing red and green in the RGB additive color scheme for light? Erişim Adresi https://www.colorwithleo.com/what-secondary-color-is-made-by-mixing-red-and-green-in-the-rgb-additive-color-scheme-for-light/

URL 7: Cytron Technolohies. The Differences Between Adhesion Types. Erişim adresi https://sg.cytron.io/tutorial/the-differences-between-adhesion-types

URL 8: DataGen Tech. CNN - Convolutional Neural Network. Erişim adresi https://datagen.tech/guides/computer-vision/cnn-convolutional-neural-network/#:~:text=A%20Convolutional%20Neural%20Network%20(CNN,representations%20from%20raw%20input%20images.

URL 9: Dive Into Deep Learning. Object Detection and Bounding Boxes Erişim adresi https://tr.d2l.ai/chapter_computer-vision/bounding-box.html

URL 10: Dobot Robots Erişim adresi https://www.dobot-robots.com/insights/news/important-features-of-3d-printer.html

URL 11: Dogan O. (2022 Nov). Nesne tanıma algoritmaları: R-CNN, Fast R-CNN ve Faster R-CNN nedir? Erişim adresi https://teknoloji.org/nesne-tanima-algoritmalari-r-cnn-fast-r-cnn-ve-faster-r-cnn-nedir/

URL 12: Engineering Product Design Erişim adresi https://engineeringproductdesign.com

URL 13: Filameon Erişim adresi https://www.filameon.com/baski-problemleri-ve-cozumleri/

URL 14: Gandhi R. (2018, Jun). Support vector machine: Introduction to machine learning algorithms. Erişim adresi https://towardsdatascience.com/support-vector-machine-introduction-to-machine-learning-algorithms-934a444fca47

URL 15: GeeksforGeeks (2023, Feb). Digital image processing basics. Erişim adresi https://www.geeksforgeeks.org/digital-image-processing-basics/

URL 16: Hui, J. (2018 Mar). Object detection speed and accuracy comparison: Faster R-CNN, R-FCN, SSD, and YOLO. Erişim adresi https://jonathan-hui.medium.com/object-detection-speed-and-accuracy-comparison-faster-r-cnn-r-fcn-ssd-and-yolo-5425656ae359

URL 17: Hui, J. (2018 Mar). SSD: Object detection: Single shot multibox detector for real-time processing. Erişim adresi https://jonathan-hui.medium.com/ssd-object-detection-single-shot-multibox-detector-for-real-time-processing-9bd8deac0e06

URL 18: Insta3DM. Erişim adresi http://tr.insta3dm.com/

URL 19: Javatpoint. Linear Regression vs Logistic Regression Erişim adresi https://www.javatpoint.com/linear-regression-vs-logistic-regression-in-machine-learning

URL 20: Kanade V. (2022 Apr). What is logistic regression? Erişim adresi https://www.spiceworks.com/tech/artificial-intelligence/articles/what-is-logistic-regression/

URL 21: Kannan B. (2020). An Introduction to Machine Learning and Its Types Erişim adresi https://bharathikannann.github.io/blogs/an-introduction-to-machine-learning-and-its-types/

URL 22: Kili Technology. YOLO algorithm: Real-time object detection from A to Z. Erişim adresi https://kili-technology.com/data-labeling/machine-learning/YOLO-algorithm-real-time-object-detection-from-a-to-z

URL 23: Kundu R. (2022, Aug). Image processing guide. Erişim adresi https://www.v7labs.com/blog/image-processing-guide

URL 24: LinkedIn. How do different print speed parameters affect surface. Erişim adresi https://www.linkedin.com/advice/3/how-do-different-print-speed-parameters-affect-surface#:~:text=As%20you%20can%20see%2C%20print,risk%20of%20clogging%20and%20jamming.

URL 25: Lulzbot Forum. az 6 stock printer head stopping filament flow. Erişim adresi https://forum.lulzbot.com/t/taz-6-stock-printer-head-stopping-filament-flow/25045/3

URL 26: Loughborough University. The 7 categories of additive manufacturing. Erişim adresi https://www.lboro.ac.uk/research/amrg/about/the7categoriesofadditivemanufacturing/

URL 27: Makerworld Erişim adresi https://makerworld.bblmw.com/makerworld/model/US648f291b0794ed/design/

URL 28: MatterHackers. 3D printer troubleshooting guide. Erişim adresi https://www.matterhackers.com/articles/3d-printer-troubleshooting-guide#Issue1

URL 29: Mihajlovic I. (2019 Apr). Everything you ever wanted to know about computer vision. Erişim adresi https://towardsdatascience.com/everything-you-ever-wanted-to-know-about-computer-vision-heres-a-look-why-it-s-so-awesome-e8a58dfb641e

URL 30: Naver. Erişim Adresi https://m.blog.naver.com/jungilyong/223136043175

URL 31: Neat Video. Luminance and Chrominance. Erişim adresi https://www.neatvideo.com/blog/post/luminance-and-chrominance-1

URL 32: Obico. 3D Printer Failure Gaps Top Layer. Erişim adresi https://www.obico.io/assets/images/3d-printer-failure-gaps-top-layer-b1d4a3ffc3fb1b64dac2701b81a0e5d4.jpg

URL 33: O'Connell J. (2023, Jul). Cartesian 3D printer, delta, scara, belt, corexy, polar. Erişim adresi https://all3dp.com/2/cartesian-3d-printer-delta-scara-belt-corexy-polar/

URL 34: Russsun. Machine Learning: C++ SVM Support Vector Machine Simple Example Erişim adresi https://all3dp.com/2/cartesian-3d-printer-delta-scara-belt-corexy-polar/

URL 35: Saini A. (2024, May). Conceptual understanding of logistic regression for data science beginner Erişim adresi https://www.analyticsvidhya.com/blog/2021/08/conceptual-understanding-of-logistic-regression-for-data-science-beginners/

URL 36: Simplify3D. Materials guide: Properties table. Erişim adresi https://www.simplify3d.com/resources/materials-guide/properties-table/

URL 37: Simplify3D. Print quality troubleshooting. Erişim adresi https://www.simplify3d.com/resources/print-quality-troubleshooting/

URL 38: Simplilearn (2023, Oct). Image processing. Erişim adresi https://www.simplilearn.com/image-processing-article

URL 39: Solid 3D Print. Troubleshooting Most Common 3D Printing Issues (2023). Erişim adresi https://www.solidprint3d.co.uk/troubleshooting-common-3d-printing-issues/

URL 40: Sovith R., Gupta V. (2022, Nov). Performance comparison of YOLO Object Detection Models. Erişim adresi https://learnopencv.com/performance-comparison-of-YOLO-models/

URL 41: Srivastava T. (2024 Jan). Introduction k-neighbours algorithm clustering. Erişim adresi https://www.analyticsvidhya.com/blog/2018/03/introduction-k-neighbours-algorithm-clustering/

URL 42: SuperAnnotate (2023, May). Image classification basics. Erişim adresi https://www.superannotate.com/blog/image-classification-basics

URL 43: The 3D Printer Bee (2022, Apr). Retraction. Erişim adresi https://the3dprinterbee.com/wp-content/uploads/2022/04

URL 44: Towards AI. Numpy Linear Algebra on Images. Erişim adresi https://towardsai.net/p/l/numpy-linear-algebra-on-images

URL 45: Towards Data Science. Understanding k-means clustering in machine learning. Erişim adresi https://towardsdatascience.com/understanding-k-means-clustering-in-machine-learning-6a6e67336aa1

URL 46: TWI Global. What is additive manufacturing? Erişim adresi https://www.twi-global.com/technical-knowledge/faqs/what-is-additive-manufacturing

URL 47: Uc Dortgen Blog. Erisim adresi https://blog.3dortgen.com/cura-ic-doluluk-tipleri-hakkinda-bilmeniz-gereken-her-sey

URL 48: Ultralytics. Preparing for hyperparameter tuning. Erişim adresi https://docs.ultralytics.com/guides/hyperparameter-tuning/#preparing-for-hyperparameter-tuning

URL 49: Ultralytics. YOLO performance metrics. Erişim adresi https://docs.ultralytics.com/guides/YOLO-performance-metrics/#class-wise-metrics

URL 50: Vishwakarma N. (2023, Nov). Real-time object detection with SSDs (single shot multibox detectors). Erişim adresi https://www.analyticsvidhya.com/blog/2023/11/real-time-object-detection-with-ssds-single-shot-multibox-detectors/

URL 51: Yasin Capar. 3B yazıcı türleri. Erişim adresi https://yasincapar.com/tr/3b-yazici-turleri/

URL 52: Zvormicanin E. (2024, Mar). What is YOLO Algorithm? Erişim adresi https://www.baeldung.com/cs/YOLO-algorithm#:~:text=You%20Only%20Look%20Once%20(YOLO)%20is%20one%20of%20the%20most,main%20reason%20for%20its%20popularity.