

ÇUKUROVA ÜNİVERSİTESİ

FEN BİLİMLERİ ENSTİTÜSÜ

DOKTORA TEZİ

İş Sağlığı ve Güvenliğinde Yapay Zeka Uygulamaları

Salih İLHAN

İş Sağlığı ve Güvenliği Anabilim Dalı

Şubat, 2025

ÇUKUROVA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

DOKTORA TEZ ONAYI

İş Sağlığı ve Güvenliğinde Yapay Zeka Uygulamaları

Salih İLHAN

İş Sağlığı ve Güvenliği Anabilim Dalı

Bu Doktora Tezi 31/01/2025 Tarihinde Aşağıdaki Jüri Üyeleri Tarafından Değerlendirilmiş ve Oy Birliği / Oy Çokluğu ile Kabul Edilmiştir.

Jüri : Prof.Dr. Özen KILIÇ (Danışman)
: Prof.Dr. Ahmet Mahmut KILIÇ
: Prof.Dr. Abdulkadir YAŞAR
: Doç.Dr. Dilek GÖKTÜRK
: Doç.Dr. Cem BOĞA

Bu Tez Fen Bilimleri Enstitüsü, İş Sağlığı ve Güvenliği Anabilim Dalında Hazırlanmıştır.

Tez No:

Prof. Dr. Sadık DİNÇER
Enstitü Müdürü

Not: Bu tezde kullanılan özgün ve başka kaynaktan yapılan bildirişlerin, çizelge ve fotoğrafların kaynak gösterilmeden kullanımı, 5846 sayılı Fikir ve Sanat Eserleri Kanunundaki hükümlere tabidir.

İÇİNDEKİLER

ÖZ	I
ABSTRACT	II
TEŞEKKÜR	III
ÇİZELGELER DİZİNİ	IV
ŞEKİLLER DİZİNİ	V
SİMGELER VE KISALTMALAR	VIII
1. GİRİŞ	1
2. ÖNCEKİ ÇALIŞMALAR	5
2.1. Yapay Zeka	8
2.2. Yapay Sinir Ağları	11
2.3. Makine Öğrenmesi	13
2.3.1. K-En Yakın Komşu (KNN)	15
2.3.2. Naive Bayes	16
2.3.3. Karar Ağaçları	16
2.4. Derin Öğrenme	17
2.5. CNN (Evrışimsel Sinir Ağları)	20
2.5.1. Giriş Katmanı	22
2.5.2. Evrişim Katmanı	22
2.5.3. Havuzlama Katmanı	23
2.5.4. Tam Bağlı Katman	25
2.5.5. Çıktı Katmanı	25
2.6. Aktivasyon Fonksiyonları	25
2.6.1. Softmax Aktivasyon Fonksiyonu	26
2.6.2. Sigmoid Aktivasyon Fonksiyonu	27
2.6.3. Tanh Aktivasyon Fonksiyonu	27
2.6.4. ReLU Aktivasyon Fonksiyonu	28
2.7. CNN Mimarileri	29
2.7.1. LeNet	29
2.7.2. AlexNet	30
2.7.3. R-CNN	31
2.7.4. GoogLeNet	31

2.7.5. VGGNet	33
2.7.6. U-Net.....	33
2.7.7. Fast R-CNN.....	34
2.7.8. ResNet.....	35
2.7.9. Faster R-CNN	36
2.7.10. SSD	38
2.8. Nesne Tespiti	39
2.9. YOLO	42
3. MATERYAL VE METOT	45
3.1. Materyal	45
3.1.1. GPU.....	45
3.1.2. Veri Seti	46
3.2. Metot.....	50
3.2.1. YOLOv9.....	50
3.2.2. Veri Ön İşleme	53
3.2.3. Veri Bölme İşlemi.....	54
3.2.4. Değerlendirme Metrikleri	55
4. BULGULAR VE TARTIŞMA	59
4.1. Bulgular.....	59
4.1.1. Gelan-c Versiyonu 25 Epoktaki Bulgular	59
4.1.2. Gelan-c Versiyonu 50 Epoktaki Bulgular	64
4.1.3. Gelan-c Versiyonu 75 Epoktaki Bulgular	69
4.1.4. Gelan-c Versiyonu 100 Epoktaki Bulgular	74
4.1.5. Gelan-e Versiyonu 25 Epoktaki Bulgular	78
4.1.6. Gelan-e Versiyonu 50 Epoktaki Bulgular	84
4.1.7. Gelan-e Versiyonu 75 Epoktaki Bulgular	89
4.1.8. Gelan-e Versiyonu 100 Epoktaki Bulgular	94
4.2. Tartışma	98
5. SONUÇLAR VE ÖNERİLER	101
KAYNAKLAR	103
ÖZGEÇMİŞ	125

EKLER.....	127
Ek A. Gelan-c Modelinin, 75 Epoktaki Performans Metriklerinin Sayıları.....	129
Ek B. Gelan-c Modelinin, 100 Epoktaki Performans Metriklerinin Sayıları.....	131
Ek C. Gelan-e Modelinin, 75 Epoktaki Performans Metriklerinin Sayıları.....	133
Ek D. Gelan-e Modelinin, 100 Epoktaki Performans Metriklerinin Sayıları.....	135



İş Sağlığı ve Güvenliğinde Yapay Zeka Uygulamaları

Salih İLHAN

Danışman: Prof. Dr. Özgen KILIÇ

İş Sağlığı ve Güvenliği Anabilim Dalı

ÖZ

Çalışma alanlarındaki en yüksek yaralanma ve ölüm olayları, inşaat sektöründe meydana gelmektedir. Ölümcül yaralanmalara ve sakatlıklara engel olunması için geleneksel güvenlik tedbirleri yerine gelişmiş güvenlik sistemleri uygulanmasının yanı sıra çalışanların koruyucu ekipmanlarını usulüne uygun şekilde kullanıp kullanmadığının denetlenmesi önem arz etmektedir. İş kazalarına karşı etkin bir önlem olan baret kullanımını aynı zamanda yasal bir zorunluluk olarak önemini korumaktadır.

Yapay zeka tabanlı bilgisayarlı görü sayesinde videolardan ya da görüntülerden gözetleme yaparak sınıflandırma ve nesne tespiti yapma, oldukça yaygın olan bir çalışma sahası sunmaktadır. Nesne tespiti üzerine yoğunlaşan ana akım, gerçek zamanlı tahminleri tek aşamalı dedektörlerin, çift aşamalı dedektörlere göre daha iyi performans sunduğunu kabul etmektedir. Çalışmada tek aşamalı dedektörler içerisinde hızı ve doğruluğu ile ön plana çıkan YOLOv9 modeli incelenmiştir. Modeli eğitebilmek için 3 farklı veri seti birleştirilerek 2107 adet görüntüden oluşan tek bir veri seti oluşturulmuştur. Elde edilen veri seti inşaat alanlarındaki gerçek yaşamı yansıtan baret, insan, yelek, eldiven ve kulaklık görüntülerden meydana gelmektedir.

YOLOv9 modelinin farklı versiyonları 25, 50, 75, 100 epokluk eğitime tabi tutulmuş olup, en başarılı performans, gelan-e versiyonunun 100 epokluk eğitiminde görülmüştür. Elde edilen sonuçlar; kesinlik 0,679, duyarlılık 0,772, $F-1$ puan 0,72, $mAP50$ değeri 0,737, $mAP50-95$ değeri 0,431 olarak bulunmuştur.

Bu çalışmada, YOLOv9 modelinin hız ve doğruluk performansı, baret kullanımının tespiti açısından incelenmiştir. Deneysel sonuçlar, modelin baş yaralanmalarını önlemede etkin bir role sahip baret kullanımını tespit görevlerinde yüksek bir başarı sağladığını göstermiştir. Model aynı zamanda sadece baret tespitinde değil, yelek, kulaklık ve iş sahasına yetkisiz giriş yapmaya çalışan kişilerin sınıflandırma ve tespitinde de yüksek performans sergilemiştir.

Anahtar Kelimeler: Yapay zeka, Derin öğrenme, YOLO, KKD, İnşaat sahası.

Artificial Intelligence Applications in Occupational Health and Safety

Salih ILHAN

Advisor: Prof. Dr. Ozen KILIC

Department of Occupational Health and Safety

ABSTRACT

The construction industry has the highest number of injuries and fatalities in the workplace. In order to prevent fatal injuries and disabilities, it is important to implement advanced safety systems instead of traditional safety measures, as well as to check whether workers are using their protective equipment properly. The use of helmet, which is an effective measure against occupational accidents, also maintains its importance as a legal obligation.

Classification and object detection by surveillance from videos or images through artificial intelligence-based computer vision offers a very common field of study. The mainstream focus on object detection recognizes that single-stage detectors outperform two-stage detectors in real-time estimation. In this study, the YOLOv9 model, which stands out with its speed and accuracy among single-stage detectors, was analyzed. In order to train the model, 3 different datasets were combined to create a single dataset consisting of 2107 images. The resulting dataset consists of images of helmets, people, vests, gloves and headphones reflecting real life in construction sites.

Different versions of the YOLOv9 model were trained for 25, 50, 75, 100 epochs and the most successful performance was seen in the 100 epoch training of the gelan-e version. The results obtained were; precision 0,679, recall 0,772, F-1 score 0,72, mAP50 value 0,737, mAP50-95 value 0,431.

In this study, the speed and accuracy performance of the YOLOv9 model was investigated for the detection of helmet use. The experimental results show that the model achieves a high performance in helmet use detection tasks, which has an effective role in preventing head injuries. The model also showed high performance not only in helmet detection, but also in the classification and detection of vests, earmuffs and unauthorized entry into the workplace.

Keywords: Artificial intelligence, Deep learning, YOLO, PPE, Construction site.

TEŐEKKÖR

Doktora eđitimime baŐladığım günden itibaren desteđini ve yönlendirmelerini esirgemeyen danıŐmanın Prof.Dr. Özen KILIÇ'a, tezin her aŐamasında tecrübelerini ve düşüncelerini paylaşan Prof.Dr. Ahmet Mahmut KILIÇ'a, tez izleme komitelerinde yapıcı ve olumlu katkılar sunan Prof.Dr. Abdülkadir YAŐAR, Doç.Dr. Dilek GÖKTÖRK'e, doktora dersleri esnasında tanıma fırsatı bulduğum ve deđerli görüşlerini paylaŐtığı için Prof.Dr. Suphi URAL'a sonsuz teşekkürler ederim.

Berberliğimizin her aŐamasında maddi ve manevi desteđini esirgemeyen eŐim Evla İLHAN'a, çocuklarım Kıvanç, Zeynep ve Muhammed İrfan'a en içten sevgilerimi sunarım.

Salih İLHAN

ÇİZELGELER DİZİNİ

Çizelge 4.1. Eğitilen Gelan-c modelinin, 25 epoktaki doğrulama sonuçları.....	59
Çizelge 4.2. Gelan-c modelinin, 25 epoktaki performans metriklerinin sayıları	62
Çizelge 4.3. Eğitilen Gelan-c modelinin, 50 epoktaki doğrulama sonuçları.....	64
Çizelge 4.4. Gelan-c modelinin, 50 epoktaki performans metriklerinin sayıları	67
Çizelge 4.5. Eğitilen Gelan-c modelinin, 75 epoktaki doğrulama sonuçları.....	70
Çizelge 4.6. Eğitilen Gelan-c modelinin, 100 epoktaki doğrulama sonuçları.....	74
Çizelge 4.7. Eğitilen Gelan-e modelinin, 25 epoktaki doğrulama sonuçları.....	79
Çizelge 4.8. Gelan-e modelinin, 25 epoktaki performans metriklerinin sayıları	82
Çizelge 4.9. Eğitilen Gelan-e modelinin, 50 epoktaki doğrulama sonuçları.....	84
Çizelge 4.10. Gelan-e modelinin, 50 epoktaki performans metriklerinin sayıları	87
Çizelge 4.11. Eğitilen Gelan-e modelinin, 75 epoktaki doğrulama sonuçları.....	90
Çizelge 4.12. Eğitilen Gelan-e modelinin, 100 epoktaki doğrulama sonuçları.....	94

ŞEKİLLER DİZİNİ

Şekil 2.1. İnsan sinir ağı ile YSA arasındaki kavramsal benzerlik	12
Şekil 2.2. K-En Yakın Komşu (KNN) algoritması	15
Şekil 2.3. Karar Ağacı	17
Şekil 2.4. Perceptron yapısı	18
Şekil 2.5. Derin öğrenme, makine öğrenmesi ve yapay zeka arasındaki bağlantı	19
Şekil 2.6. Derin öğrenme ve makine öğrenmesinin karşılaştırılması	20
Şekil 2.7. Görüntü sınıflandırma için CNN mimarisi	21
Şekil 2.8. Evrişim Katmanları	23
Şekil 2.9. Havuzlama türleri ile ilgili örnekler	24
Şekil 2.10. Softmax aktivasyon fonksiyonunun işleyişi	26
Şekil 2.11. Sigmoid aktivasyon fonksiyonu grafiği	27
Şekil 2.12. Tanh aktivasyon fonksiyonu grafiği	28
Şekil 2.13. ReLU aktivasyon fonksiyonu grafiği	29
Şekil 2.14. LeNet-5 mimarisi	30
Şekil 2.15 AlexNet mimarisi	30
Şekil 2.16. R-CNN mimarisi	31
Şekil 2.17. GoogLeNet Başlangıç modülü	32
Şekil 2.18. VGGNet mimarisi	33
Şekil 2.19. U-Net mimarisi	34
Şekil 2.20. Fast R-CNN mimarisi	35
Şekil 2.21. ResNet artık yapısı	36
Şekil 2.22. Faster R-CNN mimarisi	37
Şekil 2.23. R-CNN, Fast R-CNN ve Faster R-CNN mimarilerinin karşılaştırılması	38
Şekil 2.24. SSD mimarisi	39
Şekil 2.25. MNIST veri setindeki 7 rakamı görüntüsünün, piksellerdeki sayı karşılıkları	41
Şekil 2.26. Nesne tespit dedektörü örneği	42
Şekil 2.27. YOLOv1 mimarisi	43
Şekil 2.28. YOLOv1 algılama modeli	44
Şekil 3.1. 1. Veri setinin etiketlenmesinden örnek	47
Şekil 3.2. 7724 adet nesnenin etiketlenme dağılımı	48
Şekil 3.3. 645 adet nesnenin, etiketlenme dağılımı	48
Şekil 3.4. 630 adet nesnenin, etiketlenme dağılımı	49
Şekil 3.5. 8999 adet nesnenin, etiketlenme dağılımı	49
Şekil 3.6. YOLOv9'un diğer modeller karşısındaki puanlaması	51

Şekil 3.7. GELAN mimarisi.....	52
Şekil 3.8. PGI mimarisi.....	53
Şekil 3.9. Veri kümesinin eğitim, doğrulama ve test verisi olarak bölünmesi.....	55
Şekil 3.10. YOLOv9 modelinin, veri seti ile eğitimini gösteren akış diyagramı.....	57
Şekil 4.1. Gelan-c modelinin, 25 epoktaki PR Eğrisi.....	60
Şekil 4.2. Gelan-c modelinin, 25 epoktaki F1-Güven Eşiği Eğrisi	61
Şekil 4.3. Gelan-c modelinin, 25 epoktaki performans metriği grafikleri	61
Şekil 4.4. Gelan-c modelinin, 25 epoktaki Karışıklık Matrisi	63
Şekil 4.5. Gelan-c modelinin, 25 epoktaki görüntü tahminleri	64
Şekil 4.6. Gelan-c modelinin, 50 epoktaki PR Eğrisi.....	65
Şekil 4.7. Gelan-c modelinin, 50 epoktaki F1-Güven Eşiği Eğrisi	66
Şekil 4.8. Gelan-c modelinin, 50 epoktaki performans metriği grafikleri	66
Şekil 4.9. Gelan-c modelinin, 50 epoktaki Karışıklık Matrisi	68
Şekil 4.10. Gelan-c modelinin, 50 epoktaki görüntü tahminleri	69
Şekil 4.11. Gelan-c modelinin, 75 epoktaki PR Eğrisi.....	70
Şekil 4.12. Gelan-c modelinin, 75 epoktaki F1-Güven Eşiği Eğrisi	71
Şekil 4.13. Gelan-c modelinin, 75 epoktaki performans metriği grafikleri	71
Şekil 4.14. Gelan-c modelinin, 75 epoktaki Karışıklık Matrisi	72
Şekil 4.15. Gelan-c modelinin, 75 epoktaki görüntü tahmin sonuçları.....	73
Şekil 4.16. Gelan-c modelinin, 100 epoktaki PR Eğrisi.....	75
Şekil 4.17. Gelan-c modelinin, 100 epoktaki F1-Güven Eşiği Eğrisi	75
Şekil 4.18. Gelan-c modelinin, 100 epoktaki performans metriği grafikleri	76
Şekil 4.19. Gelan-c modelinin, 100 epoktaki Karışıklık Matrisi	77
Şekil 4.20. Gelan-c modelinin, 100 epoktaki görüntü tahmin sonuçları.....	78
Şekil 4.21. Gelan-e modelinin, 25 epoktaki PR Eğrisi.....	79
Şekil 4.22. Gelan-e modelinin, 25 epoktaki F1-Güven Eşiği Eğrisi	80
Şekil 4.23. Gelan-e modelinin, 25 epoktaki performans metriği grafikleri	81
Şekil 4.24. Gelan-e modelinin, 25 epoktaki Karışıklık Matrisi	83
Şekil 4.25. Gelan-e modelinin, 25 epoktaki görüntü tahmin sonuçları.....	84
Şekil 4.26. Gelan-e modelinin, 50 epoktaki PR Eğrisi.....	85
Şekil 4.27. Gelan-e modelinin, 50 epoktaki F1-Güven Eşiği Eğrisi	86
Şekil 4.28. Gelan-e modelinin, 50 epoktaki performans metriği grafikleri	86
Şekil 4.29. Gelan-e modelinin, 50 epoktaki Karışıklık Matrisi	88
Şekil 4.30. Gelan-e modelinin, 50 epoktaki görüntü tahmin sonuçları.....	89
Şekil 4.31. Gelan-e modelinin, 75 epoktaki PR Eğrisi.....	90
Şekil 4.32. Gelan-e modelinin, 75 epoktaki F1-Güven Eşiği Eğrisi	91
Şekil 4.33. Gelan-e modelinin, 75 epoktaki performans metriği grafikleri	91

Şekil 4.34. Gelan-e modelinin, 75 epoktaki Karışıklık Matrisi	92
Şekil 4.35. Gelan-e modelinin, 75 epoktaki görüntü tahmin sonuçları.....	93
Şekil 4.36. Gelan-e modelinin, 100 epoktaki PR Eğrisi.....	95
Şekil 4.37. Gelan-e modelinin, 100 epoktaki F1-Güven Eşiği Eğrisi	95
Şekil 4.38. Gelan-e modelinin, 100 epoktaki performans metriği grafikleri	96
Şekil 4.39. Gelan-e modelinin, 100 epoktaki Karışıklık Matrisi	97
Şekil 4.40. Gelan-e modelinin, 100 epoktaki görüntü tahmin sonuçları.....	98



SİMGELER VE KISALTMALAR

İŞG	: İş Sağlığı ve Güvenliği
TBY	: Travmatik Beyin Yaralanması
KKD	: Kişisel Koruyucu Donanım
FPS	: Saniyedeki Kare Sayısı
YOLO	: Yalnızca Bir Kez Yaşarsınız
SSD	: Tek Atışlı Çoklu Kutu Dedektörü
MS COCO	: Bağlamda Microsoft Ortak Nesneleri
OAN	: Operatör Alan Ağı
SVM	: Destek Vektör Makinesi
KOSHA	: Kore İş Sağlığı ve Güvenliği Ajansı
F1 Puan	: Harmonik Ortalama
ILO	: Uluslararası Çalışma Örgütü
mAP	: Ortalama Doğruluk Değerlerinin Ortalaması
GPU	: Grafik İşlem Birimi
YSA	: Yapay Sinir Ağları
MIT	: Massachusetts Teknoloji Enstitüsü
NLP	: Doğal Dil İşleme
CNN	: Evrişimli Sinir Ağı
ILSVRC	: ImageNet Büyük Ölçekli Görsel Tanıma Yarışması
KNN	: K-En Yakın Komşu
CNN	: Evrişimsel Sinir Ağları
ReLU	: Doğrultulmuş Doğrusal Birimleri
MNIST	: İyileştirilmiş Ulusal Standartlar ve Teknoloji Enstitüsü
R-CNN	: Bölgesel Tabanlı Evrişimli Sinir Ağları
Fast R-CNN	: Hızlı Bölgesel Tabanlı Evrişimli Sinir Ağları
Faster R-CNN	: Daha Hızlı Bölgesel Tabanlı Evrişimli Sinir Ağları
PASCAL VOC	: Paskal Görsel Nesne Sınıfları
VGGNet	: Görsel Geometri Grubu Ağı
RoI	: İlgi Bölgesi
SVM	: Destek Vektör Makineleri
ResNet	: Artık Ağ
RPN	: Bölge Öneri Ağı
NMS	: Maksimum Olmayanların Bastırılması
IoU	: Kesişimlerin Birleşimlere Oranı

CT	: Bilgisayarlı Tomografi
PET	: Pozitron Emisyon Tomografisi
OCR	: Optik Karakter Tanıma
Epok	: Eğitim Tur Sayısı
TFLOPS	: Bir Saniyede Geçen Trilyon Nokta İşlemi
CUDA	: Birleşik Cihaz Mimarisi Hesaplama
CPU	: Merkezi İşlem Birimi
PGI	: Programlanabilir Gradyan Bilgisi
GELAN	: Genelleştirilmiş Verimli Katman Toplama Ağı
CSPNet	: Çapraz Aşamalı Kısmi Ağ
ELAN	: Verimli Katman Birleştirme Ağı
RevCol	: Ters Çevrilebilir Sütun Ağı
EXIF	: Değiştirilebilir Görüntü Dosya Formatı
P	: Kesinlik
R	: Duyarlılık
PR	: Kesinlik-Duyarlılık
AP	: Ortalama Kesinlik
FP	: Yanlış Pozitif
TP	: Doğru Pozitif
FN	: Yanlış Negatif
TN	: Doğru Negatif
dfl loss	: Dağılım Odak Kaybı

1. GİRİŞ

İş sağlığı ve güvenliği (İSG) alanının en büyük problemlerinden biri olan iş kazaları, günümüzde ciddiyetini sürdürmekle birlikte, kalıcı ve yenilikçi çözümler beklemektedir. Ölümcül iş kazalarının ve yaralanmaların proaktif güvenlik tedbirleri ile sıklığını azaltarak ortadan kaldırıp, daha emniyetli ve sürdürülebilir hale getirebilmek önem arz etmektedir. Geleneksel yaklaşımlar iş kazalarının sayısını sınırlayamamaktadır.

İnşaat sektörü, ülkelerin ekonomik büyümesinde ve kalkınmasında vazgeçilemez bir unsur olmasına karşın, ABD İşgücü İstatistikleri Bürosu'nun çalışma alanları üzerinde yapmış olduğu son dönem raporlamasında (Rasouli ve ark., 2024), yaralanma ve ölüm olaylarıyla inşaat alanları, en tehlikeli iş kolu olarak tanımlanmıştır (Chen, H. ve ark., 2023; Chen ve Demachi, 2021; Cheng ve ark., 2022; Fang ve ark., 2022; Liu, Fang ve ark., 2022; Liu, Luo ve ark., 2022; Mostafa ve Hegazy, 2021; Pan ve Zhang, 2021). Ülkelerinde yaşadıkları, ölümcül kazaları incelediklerinde en yüksek payı inşaat alanlarında çalışanlar maruz kalmaktadır (Nath ve ark., 2020). Kazaların sonuçlarını incelediklerinde ise inşaat sektöründe yaşanan tüm ölümlerin %25'i Travmatik Beyin Yaralanması (TBY) sonucu meydana gelmektedir (Konda ve ark., 2016).

Ülkemiz açısından irdelendiğinde, 2011-2020 yılları arasında inşaat sektörlerindeki kaza sıklık hızı bakımından her 3 operasyonun, 1,000,000 iş saatindeki ortalamasında 7,96 kaza meydana gelirken, diğer sektörlerdeki 85 operasyonun ortalaması, 6,86 olarak gerçekleşmiştir. Ölümlü kazalar açısından incelenen dönemde iş kazası sonucu ölen her 3 sigortalıdan 1'i inşaat sektöründe faaliyet göstermektedir. Analizde, inşaat sektörünün iş güvenliği açısından en riskli alan olduğu açıkça vurgulanmaktadır (Zengin, 2022).

Küresel çapta yaşanan kazalar açısından önemli bir sağlık sorunu olan, TBY'a bağlı olarak ortalama her yıl 69 milyon insanın bu durumdan etkilenebileceği, yaşanacak hasarın %81'i hafif, %11'i orta şiddette olabileceği yönünde hesaplamalar yapılmıştır (Dewan ve ark., 2019). TBY özellikle inşaat sektöründe önlem alınması gereken, hayati öneme haiz durumlar oluşturmaktadır.

Elde edilen sonuçlar bu konunun kritikliğini fazlasıyla ortaya çıkarmaktadır. Ölümcül yaralanmalara ve sakatlıklara engel olmak için gelişmiş güvenlik sistemlerinin uygulanmasının yanı sıra koruyucu ekipmanların usulüne uygun kullanılmasına duyulan ihtiyaç kaçınılmazdır.

İnşaat sektörü sadece yaralanma ya da ölüm gibi doğrudan sonuçlarla karşımıza çıkmaz, işverenler ve ülkeler açısından büyük prestij ve ekonomik maliyetlere neden olabilmektedir.

Maliyetleri iki başlık altında tanımlandığında, tazminat ödenmesi ve tedavi masrafları gibi hesaplanabilen, öngörülebilir maliyetlere Doğrudan Maliyetler, iş gücü ve üretim kaybı, işveren devlet imajının zedelenmesi gibi daha az ölçülebilir fakat uzun dönemde daha büyük kayıplara yol açabilen maliyetlere Dolaylı Maliyetler denilmektedir (Olcay, 2019).

Hali hazırda iş kazasına bağlı ölüm ve yaralanma ile sonuçlanan olayların artarak devam etmesinin ve sınırlandırma yapılamamasının arkasında, gerçek zamanlı tespitlerin yapılamaması ve önleyici müdahalelere geç kalınması yer almaktadır (Mahmood, 2021).

Baret kullanımı özellikle inşaat sektöründe düşme ile ilgili TBY hasarına karşı başlıca koruma yöntemi olarak tercih edilmekle birlikte, kullanılması yasal bir zorunluluktur (Nath ve ark., 2020; Shanti ve ark., 2022; Vukicevic ve ark., 2022). Kaza sebebi ile kafa yaralanmasına engel olmada etkin bir rol oynayan baret kullanımı ile ilgili çalışmalar son derece dikkate çekicidir (Nath ve ark., 2020; Patel ve ark.; Xiong ve ark., 2022).

Ayrıca baret takıldığında ve işe uygun iş kıyafetini kuşandığında; iş sahasına yetkisiz girip, iş kazalarına karşı kişisel koruyucu donanımı (KKD) olmayan kişilerin tespiti, gözetleme kameraları ile kolaylıkla fark edilebilmektedir (Gong ve ark., 2021; Kim ve ark., 2023).

Fakat bazı çalışanlar baretleri kendilerini rahatsız ettiği gerekçesi ile kullanmamayı tercih edebilmektedirler. Baret kullanımını gerçek zamanlı olarak tespit etmek, çalışma alanlarında iş güvenliğini arttırmada önemli bir katkı sağlamaktadır (Chen ve Demachi, 2021; Sun ve Wang, 2022; Xiong ve ark., 2022).

Her geçen gün fabrikalarda, büyük işletmelerde, havaalanlarında, trafikte, okullarda, hastanelerde, inşaatlarda, kamuya açık alanlarda, inşaatlarda, neredeyse tüm kritik mahallerde mevcut çok sayıda kameradan anlık olarak, insan gözlemciler vasıtasıyla izleme yapılabilmektedir (Kim ve ark., 2023).

İzleme esnasında ortaya çıkan karmaşık olayların fark edilip yorumlanması ile çalışanların takibi sağlanarak güvenli çalışma ortamları oluşturulması, iş kazalarının önlenmesi bakımından çok önemlidir. Fakat çok miktardaki video verisi içerisinde karmaşık olayların gerçek zamanlı algılanıp anlamlandırılması insan gözlemciler tarafından pek mümkün olamamaktadır (Dandil ve Önal, 2021; Nayak ve ark., 2021).

Yapay zekanın ana dallarından olan bilgisayarlı görü sayesinde, videolardan ya da görüntülerden gözetleme yapılarak sınıflandırma ve nesne tespiti, oldukça yoğun olan bir çalışma alanıdır (Alhamed ve ark., 2022). Ayrıca veri madenciliği, doğal dil işleme, otonom sürüş, imalat, askeri teknolojiler, sağlık, eğitim, ulaşım, haberleşme, ekonomi, spor, sanat, eğlence, tarım gibi çok sayıda uygulamaya sahiptir (Başer, 2022; Doğan, 2022; Kim ve ark., 2023).

Gözetleme alanlarını sürekli olarak izleme insan doğası gereği, dikkat dağınıklığı ve yorgunluk sebebi ile çok zor olmaktadır. Yapay zeka destekli bilgisayarlı görü sayesinde devamlı bir şekilde izlenme, tanımlama ve analiz yapılabilmektedir (Li ve ark., 2023; Paneru ve Jeelani, 2021; Sorgun, 2022; Wang, H. ve ark., 2023; Yıldız, 2021; Zhao ve ark., 2023). Bilgisayarlı görünün gerçek zamanlı nesnelere tespit işlemlerinde, yüksek doğruluğa ve yüksek miktarda saniyedeki kare sayısına (FPS) ihtiyaç duyulmaktadır (Alsamurai, 2023; Hu ve ark., 2024; Kim ve ark., 2023; Luo ve ark., 2024; Nath ve ark., 2020; P. Jin ve ark., 2024).

Bahse konu bu problemlere, Redmon ve ark. (2015) YOLO (Yalnızca Bir Kez Yaşarsınız) nesne tespit modelini tanıtarak (Cao ve ark., 2024; Zhang ve ark., 2024) alternatif çözüm sağlamışlardır. Tanıtıldığı günden itibaren YOLO farklı modelleri ve versiyonları ile sürekli olarak geliştirilerek nesne tespit işlemlerinde kullanılmaktadır.

Yapay zekanın günümüzde elde ettiği gelişim ve başarı neredeyse her alana etkilemekte; alışıla gelen yöntemleri geliştirmekte ya da sil baştan yeni çözümler üretmektedir.

Çalışmada KKD'leri en hızlı ve doğru şekilde tespit edebilecek YOLO modelini seçmek, model seçimine müteakip gerçek yaşam şartlarını ve inşaat alanlarını yansıtan veri setini oluşturmak, bu sayede modeli eğiterek, performans metrikleri ile değerlendirme hedeflenmektedir.

Bu hedeflere ulaşılabilmesi esnasında, literatürde dağınık bir şekilde yer aldığı gözlemlenen YOLO eğitim süreçleri, veri seti seçimi ve işlenmesi konularına odaklanılarak, bu alanlara rehberlik edebilecek kaynak oluşturulacaktır.

Bu tez çalışmasında kullanılan yapay zeka uygulamaları sayesinde, İSG alanında KKD ihlallerine bağlı yaşanan iş kazalarını gerçek zamanlı tespit ederek engellemek ve devamlı surette iş emniyetini tesis etmek amaçlanmıştır.



2. ÖNCEKİ ÇALIŞMALAR

Önceki çalışmalar incelendiğinde; tehlikeli alanlarda çalışanların, baret kullanmasının hayati öneminden, aynı zamanda yasal zorunluluğundan bahsedilmektedir. Baret kullanımının gerekli olduğu durumlarda ihlallerin önüne geçebilmek için derin öğrenme yöntemlerinden YOLOv3 modeli kullanılmıştır. Modeli eğitmek için Bağlamda Microsoft Ortak Nesneleri (MS COCO) veri setinden insan sınıfı seçilmiştir. Test aşamasında doğrulama olarak %96 baretli ve %97 oranında baretsiz sınıf tahminlerine ulaşılmıştır (Sağın, 2019).

Wu ve ark. (2019) çalışmalarında, farklı saha koşullarında yüksek doğruluk oranı ile baretlerin tespit edilebileceğini ve güvenilir sonuçlara ulaşılabileceğini göstermeye çalışmışlardır. Baret tespitini yapabilmek için Tek Atış Çoklu Kutu Dedektörü (SSD) modelini seçmişlerdir. SSD modelinin eğitiminde kullanılmak üzere çeşitli çalışma alanlarından elde ettikleri, 3174 adet baret veri setini oluşturmuşlardır. SSD modelini görüntülerdeki farklı boyutlara ve ağ yapısı içerisinde bulunan katmanlardan gelen özelliklere uyumu sebebi ile nesne algılama ve tespiti için kullanmışlardır. Önerdikleri sistemi, başlangıç aşamasındaki ham veri girişinden, tahmin sonucuna kadar kesintisiz bir eğitim sürecine tabi tutmuşlardır. Yaptıkları deneylerin nihai sonuçlarında; modele uygulanacak 512×512 piksel giriş görüntüsünde, Ortalama Doğruluk Değerleri Ortalaması (mAP) değerini %83,89 elde ederek, her türlü saha koşullarında uygulanabilir olduğunu belirtmişlerdir. SSD tabanlı modellerde, görüntü içerisindeki nesnelere bazı derin katmanlar üzerinde etkili uzamsal bilgiler bırakabildiğini, bu sebeple girişte uygulanacak görüntü boyutunun önemli bir unsur olduğunu gözlemlemişlerdir.

Chen ve Demachi (2020) nükleer santrallerde KKD donanımlarını tespit edebilmek için, OpenPose ve YOLOv3 modelini önermişlerdir. Modelde kullanılacak eğitim verisini oluşturmak için, 3805 adet görüntü toplamışlardır. Eğitim veri setinde kullandıkları resimlerin modele uygun şekilde etiketlenmesine müteakip, KKD kullanımlarını tespit etmişlerdir. Gerçek zamanlı değer olan, ortalama 7,95 FPS de ölçümler yapmışlardır. Ölçümlerin performans metrikleri; duyarlılık (recall) %93,11, kesinlik (precision) %97,64 olarak bulmuşlardır.

Dandıl ve Önal (2021) son yıllarda bilgisayarlı görünün ve derin öğrenmenin aşamalar halinde gelişmeler kaydettiğini, bu duruma bağlı olarak çalışma alanlarında gözetim videoları üzerinden, iş güvenliğinin sağlanması açısından ikincil bir araç olabileceğini değerlendirmişlerdir. Böylece bilgisayarlı görü ve derin öğrenmenin çalışma alanlarındaki insan kaynaklı hataların minimize edilebileceğini, önemli kazanımlar sağlanabileceğini vurgulamışlardır. Endüstriyel üretim tesislerinde, kameralar üzerinden çalışanların güvensiz hareketlerinin tespitini ve kullandıkları KKD donanımlarının denetlenmesini gerçekleştirmek amacıyla YOLOv4 modelini tercih etmişlerdir. YOLOv4 modelinin eğitimi için farklı çalışma alanlarındaki videolardan veri seti oluşturmuşlardır. Modelin eğitimi tamamlandıktan sonra sanayi bölgelerindeki işçilerin çalışmalarında kullandıkları

KKD donanımlarını usulüne göre kullanılıp kullanmadıklarını tespit etmişlerdir. YOLOv4 modelini seçtikleri çalışmada; %91,18 mAP değerine ulaşmışlardır. Modelin kullanılması ile çalışma alanlarındaki kameralar üzerinden algılama ve denetleme yapılarak, kontrollerin başarılı bir şekilde gerçekleştirilebileceğini açıklamışlardır.

Gong ve ark. (2021) yapmış oldukları çalışmayla derin öğrenme tabanlı KKD algılama yöntemi sayesinde açık denizlerde bulunan sondaj platformlarında, üretim verimliliği ve güvenlik yönetimi arasındaki bağı güçlendirmeyi amaçlamışlardır. Yapay zeka uygulamalarının akıllı güvenlik yönetim sistemlerinde kullanılabildiğini, bu nedenle sondaj platformları gibi güvenliğin en üst seviyede tutulması gerekli alanlarda da uygulanabileceği vurgusunu yapmışlardır. Sahada çalışanların baret ve iş için kullandıkları kıyafetleri tespit etmek, uygulanması gereken güvenlik standartların uygunluğunu denetlemek amacıyla YOLOv3 modelini önermişlerdir. Yaptıkları testlerde geliştirdikleri YOLOv3 modelinin diğer derin öğrenme modelleri karşısında daha yüksek bir performans sergilediğini, iş kıyafetlerinde %95,4, baret tespitinde %94,8 başarı elde ettiklerini açıklamışlardır.

Wang ve ark. (2021) hali hazırda mevcut derin öğrenmeye dayalı KKD tespiti yapan dedektörlerin, sınırlı sayıda tespit yaptığını, özellikle de gerçek şartlarda çalışılan inşaat alanlarında, gösterdikleri performansın iyileştirilmeye ihtiyacı olduğunu vurgulamıştır. İnsan, yelek ve 4 farklı renkteki baret görüntülerinden oluşan 6 adet sınıf, tahmin edilmeye çalışılmıştır. 8 farklı YOLO mimarisine dayanan dedektörlerin, test ve değerlendirmeleri yapılmıştır. KKD'ler dikkate alınarak çeşitli açılarda, farklı hareket ve mesafelerde bulunan, yüksek görüntü kalitesine sahip, 1330 adet görüntüden oluşan veri seti edinilmiştir. Böylece veri seti ile gerçek yaşamda kullanılan şantiye arka planı oluşturulmuştur. Elde edilen deney sonuçlarında YOLOv5x'in mAP değeri %86,55 olarak bulunmuştur. YOLOv5s'in ise Grafik İşlem Birimi (GPU) kullanımında en hızlı (52 FPS) tahmin yapan model olduğu gösterilmiştir. Bulanık olan yüzlerde baret tahminlerinin %7 oranında düştüğünü, diğer sınıflarda ise bu etkinin bulunmadığı gözlemlenmiştir.

Li ve ark. (2022) çalışma alanlarında başa cisim çarpması ve yüksekten düşmenin çalışanları etkilemesinin yanı sıra inşaatların ilerleme aşamalarını da aksatabileceğini belirtmişlerdir. Bu tür kazaların engellenmesi için, baret ve can halatının kullanılması gerektiği ve bu koruyucu donanımların usulünce takılıp takılmadığının tespitinin önem arz ettiğini açıklamışlardır. Önerdikleri sistemde baretin ve can halatının kullanımının doğru bir şekilde yapılıp yapılmadığını tespit edebilmek için YOLOv5 modelini seçip, Openpose algoritmasını da modeli güçlendirmek için entegre etmişlerdir. Veri seti olarak kullandıkları 1200 adet videonun 600 tanesi eğitimde, 600 adedi test verisi olarak kullanmışlardır. Deneysel sonuçlarının neticesinde doğruluğu (accuracy) 0,9467 olarak bulmuşlardır.

İnşaat alanlarında kullanılan merdivenlerden, düşme sonucu ölümcül iş kazaları hakkında yapılan çalışmada, çalışanların davranışlarının ve yönetilmesinin önemine dikkat çekilmiştir. Merdiven üretim standartlarına göre belirlenen menteşe kısmının yer aldığı yükseklikten referans

alınarak sınırlayıcı kutu ile gerçek çalışma yüksekliği tahmin edilmiştir. Ayrıca optimizasyonu sağlanmış kayıp fonksiyonu ile merdiveni kullanan işçiler ile bu faaliyetin içerisinde yer almaması gerekenlerin ayırımı iyileştirici deneyler yapmışlardır. Test sonuçlarında ortalama doğruluğu %87'den %90,44'e yükseltmeyi başarmışlardır. Ayrıca, Kore İş Güvenliği ve Sağlığı Ajansı (KOSHA) kılavuzuna göre merdiven üzerinde çalışma yapan çalışanların, güvenli olmayan davranışları değerlendirilmiş, harmonik ortalaması (F1 puanı) 91,40 olarak bulunmuştur. Deneysel sonuçlarında merdiven üzerinde çalışma yapan işçilerin gerçek zamanlı olarak izlenebileceğini, güvenli olmayan davranışlarının tespit edilebileceğini göstermişlerdir (Park ve ark., 2023).

Aslan ve Yağimli (2023) İSG alanında risk değerlendirmesi ve analizinin zorunlu olduğunu, ayrıca fazlasıyla emek harcanması gereken aşamalarının da bulunduğunu, risk değerlendirmesi ve analizinin bir kere oluşturulduktan sonra yıllarca yenilenmediğini. Bahse konu bu durumlarda riske sebep olan faktörlerin geç fark edilmesi nedeni ile iş kazalarının oluşabileceğini değerlendirmişlerdir. Derin öğrenme tekniklerinin risklerin analizinde ve tespitinde geleneksel yöntemlere alternatif olarak kullanılabileceğini önermişlerdir. YOLOv5 modelinin kullanılarak KKD kullanımının zorunlu olduğu alanlara yetkisiz kişilerin girmesi durumunda tespit ve analizler gerçekleştirmişlerdir. Modelin eğitiminde 4 farklı sınıf oluşturularak farklı ışık ortamlarında, baret, insan yüzleri ve kıyafetlerinden oluşan 840 adet veri seti oluşturulmuş, 600 adedi modelin eğitiminde kullanılmıştır. Elde ettikleri eğitim sonuçlarında %90'nın üzerinde doğruluğa ulaşarak risk tespitinin ve analizinin modelleri ile yapılabileceğini belirtmişlerdir.

Girgin (2023) çalışma ve güvenlik süreçlerinin tam anlamı ile uygulamaması neticesinde kazaların yaşandığını, bu durumun ise çoğunlukla insan hatalarına bağlı performans eksikliğinden kaynaklandığını açıklamıştır. Uluslararası Çalışma Örgütü (ILO) yayınlamış olduğu son raporunda bir yıl içerisinde 374 milyon çalışanın ölümcül olmayan kazalar yaşadığını, 2,78 milyon çalışanın ise ölümcül olan kazalarda yaşamını yitirdiğini belirtmiştir. Makine öğrenmesi modelleri sayesinde insan gözlemciler aracılığı ile kolaylıkla ayırt edilemeyen güvenlik ihlallerinin tespit ve raporlamasının yanında alarm vermesini sağlayarak kullanmayı hedeflemiştir. Dört farklı veri seti seçilerek YOLO mimarileri üzerinde eğitilmiştir. Yapılan deneyler sonucunda YOLOv8 modelinin genel olarak YOLOv5 ve YOLOv7'ye kıyasla daha iyi olduğu, YOLOv7'nin ise yüksek çözünürlüğe sahip görüntülerde, daha fazla başarı gösterdiğini gözlemlemiştir. Yapmış olduğu deneylerinde, hiper parametrelerin makine öğrenmesi modellerinin başarısını etkileyen en önemli unsurlardan biri olduğunu değerlendirmiştir.

Küçük ölçekli işyerleri ile ilgili çalışmada, ölümcül kazaların genellikle elverişsiz KKD'ler sebebi ile yaşandığını, sorunların sınırlandırılması için baret vb. KKD'lerin kullanılmasının büyük önem taşıdığı vurgulanmıştır. Son dönemde nesne tespitine yönelik birçok model geliştirildiğini ve genelde baretin takılı olup olmamasına odaklanıldığını fakat bu modellerin baret yerine şapka takılıp takılmadığı hususunda kullanılmadığı belirtilmiştir. Çalışmada kullanılan veri seti baret, kafa ve şapka görüntülerinden oluşturulmuştur. Modelin eğitimi şapka takan çalışanların az miktardaki

görüntüsünden faydalanılarak yapılmıştır. RetinaNet, YOLOv5 ve Faster R-CNN modellerindeki performanslar karşılaştırıldığında, YOLO-EfficientNet modeli diğer üç modelden F1 puanına göre %3,2-16,4 daha yüksek çıkmıştır. İş kazalarının engellenmesinde çalışanların baret takıp takmadığının tespitine yardımcı olacağı değerlendirilmiştir (Lee ve ark., 2023).

Ludwika ve Rifai (2024) makalelerinde, özellikle makine ve aletlerin kullanıldığı mesleki sektörlerde iş kazalarının olma potansiyelinin yüksek olduğunu, yaşanan kazalarında bu alanlarda çalışanların, KKD kullanımına gerekli özeni göstermemesinden kaynaklı olduğunu deklare etmişlerdir. Çalışmalarında nesne tespiti için YOLOv4, YOLOv5 ve YOLOv6 modelini değerlendirmişlerdir. YOLO mimarileri ile görüntüleri tek seferde işleyerek verimliliği arttırmasının yanında gerçek zamanlı doğru tespitler yapılmasına imkân tanıdığını belirtmişlerdir. YOLO modelleri arasında yapmış oldukları deneyler neticesinde, KKD kullanım uygunluğu ve yeterliliğini tespit; 0,744 F1 skoru ve 0,757 mAP değeriyle YOLOv5 modelinin öne çıktığını değerlendirmişlerdir.

Pisu ve ark. (2024) farklı disiplinlerde çalışma yapan araştırmacıların, toplumda iş güvenliği konusunun büyük bir endişe kaynağı oluşturduğunu bildikleri için, bu konudaki çözüm yollarını aramaya gayret gösterdiklerini vurgulamışlardır. Bu doğrultuda son on yıllık zaman zarfında endüstri ve akademik çalışmalarda, güvenlik kurallarının uygulanıp uygulanmadığının kontrolü için çeşitli yöntemler geliştirildiğini açıklamışlardır. Kazaların ekseriyetinin KKD'nin kullanılmaması ya da usulünce takılmaması neticesi ile oluştuğunu, çözüm için farklı ortamlarda ve kullanıcılarda mobilitesi, gizliliği ve müdahale edilememesi ile ön plana çıkan, izlemeye dayalı Operatör Alan Ağı (OAN) sistemini öneri olarak sunmaktadırlar. OAN'nın menziline olan KKD'den alınan sinyali değerlendirmek için Destek Vektör Makinesi (SVM) modeli kullanılmıştır. Sistem SVM modelini kullanılarak Yanlış Pozitif'leri (YP) %80'e kadar azaltıp, KKD'nin usulünce kullanılmadığı durumları en geç yedi saniye içerisinde tespit ederek alarm verebildiğini belirtmişlerdir.

2.1. Yapay Zeka

Yapay zeka ilhamını beyinin yapısından almaktadır. Beynin çalışma sistemini anlamaya çalışan sinir ve bilişsel alanındaki araştırmacılar Yapay Sinir Ağları (YSA)'nın simülasyonu üzerine çalışmalar yapmaktadırlar (Çekiç, 2022). Yıllardır bilinmesine ve üzerinde çalışılmasına rağmen, makine öğrenimi ve büyük verinin günümüzde önem kazanmaya başlaması ile kullanımını artmıştır (Bayık, 2022). Yapay zeka, insana özgü bilgi edinme, düşünme, karar verme, görme, algılama özelliklerini, makinaya iletmeye çalışan bir bilim dalıdır (Türk, 2021).

Yapay zekanın geçmişten günümüze gelişimini, kronolojik bir anlatım ile şu şekilde sıralayabiliriz.

Antik çağa damgasını vuran, Mısırlılar, Çinliler ve Yunanlılar hayallerinde tasarladıkları, insansı özelliklere sahip varlıkların resim ve heykellerini yaparak, çeşitli şiir, öykü ve efsanelerinde

anlatmışlardır. Mitolojilerinde yapay zekayı farklı formlarda hayal etmişlerdir. Eski Mısır medeniyeti, yaptıkları heykellerin, insan gibi veya insan üstü olduğunu efsanelerinde dile getirmişlerdir. Bir antik Çin efsanesinde, Batı Zhou Hanedanlığında Yan Shi adında bir zanaatkar imparatora dans edip şarkı söyleyebilen insana benzeyen bir mekanizma yapmıştır. Efsaneye göre, gerçek insan gibi hareket eden bu mekanizma imparator tarafından kıskanılmış ve mekanizmanın idamına hükmetmiştir. Yan Shi imparatora mekanizmanın gerçek bir insan olduğunu ispatlaması üzerine bu hükümden vazgeçirmiştir (Gündüz, M., 2023; Yasak, 2021).

Yunan antik çağının en büyük felsefecilerinden Aristoteles (M.Ö. 384-322), mülkiyet kavramını Politika adlı eserinde irdelediğinde bir kimsenin, mülkiyete konu olabilecek herhangi bir şeyi, aynı zamanda yaşantısına olanak sağlayan bir araçsa ve bahse konu bu kimsenin köleleri de dahil olursa, mülkiyetini (malvarlığı) tamamlayacağından bahsetmiştir. Çünkü köleleri bir uşak gibi görmekte, en fazla herhangi bir araç değeri kadar olabileceğini niteleyerek, kölelik düzenine meşru bir zemin hazırlamaya çalışmıştır. Hephaistos'un tekerlekli sehpaalarının söylenince veya kendi inisiyatifi ile işlerini yapabilmesini, dokuma tezgahlarının el değmeden mekik dokumasını, lir müzik aletinin kendini çalmasını düşlemiştir. Düşündüklerinin gerçek hayatta olabilmesi durumunda ne yapımcıların işçiye ne de efendilerin köleye ihtiyacının kalmayacağını söyleyerek, yapay zeka kavramını hayal etmiştir (Aristoteles, 1975).

İskenderiye mekanik okulunun kurucusu Yunan Ktesibios'un (M.Ö. 285 – 222), icat ettiği su saatlerinin, gece de çalışabilme özellikleriyle, dönemin güneş saatlerine göre önemli bir avantaja sahipti. Su hırsız (Clepsydra) adını verdiği su saati ise tarihin ilk robotik ve otomasyon örneği olarak bilinmektedir (Gündüz, M., 2023; Külcü, 2018).

Dünya bilim tarihinde, sibernetik ve robot bilimi alanındaki ilk çalışmalar, İbn er-Rezzaz el-Cezeri tarafından yapılmıştır. 19. yüzyılın başında Joseph Marie Jacquard tarafından geliştirilen ve otomatik olarak çalışan dokuma tezgâhı, dünyanın ilk otomatik kontrollü makinası olarak bilinmektedir. Fakat Cezeri bundan 600 yıl önce hangi zamanda su dökeceğine ya da meyve, içecek sunacağına karar verebilen otomatik hizmetçiyi icat etmiştir (Çırak ve Yörük, 2016).

Alan Mathison Turing tarafından 1936'da kaleme alınmış, 1937 yılında yayımlanmış Karar Problemine (Entscheidungsproblem) bir uygulama içeren hesaplanabilir sayılar hakkındaki makalesi, bilgisayar bilimleri alanında yeni ufuklar açmıştır. Ayrıca modern bilgisayarın teorik temellerini anlatmıştır (Turing, 1937).

1950 tarihinde ise Mind dergisindeki yayımlanan makalesinde, yapay zekadan bir kavram olarak söz etmektedir. Makinaların insanlara etkileşime girdiği anda, insan izlenimini oluşturacak kadar zeki olup, olamayacağının incelenmesi yönünden makalesi, yapay zeka literatürünün temel eseri olarak kıymetlendirilmektedir (Güçlütürk, 2021). Bu çalışmasından sonra Turing Testi olarak bilinen taklit oyunundan bahsetmiştir. Günümüzde de hala tartışılan “makinelere düşünebilir mi?” konusuna açıklık getirmeye çalışmıştır (Açıksözlü, 2021; Bayık, 2022; Gündüz, T., 2023; Peker, 2021; Şahinci, 2021; Yılmaz, 2021).

31 Ağustos 1955 tarihinde McCarthy ve arkadaşlarının kaleme aldığı, araştırma projesindeki öneri metni, “Yapay Zeka” teriminin kullanıldığı, ilk resmî belge olarak kabul edilmekte olup, 1956 yılında ABD’nin New Hampshire eyaleti, Hanover şehrinde bulunan Dartmouth Üniversitesi’nde sunulmuştur. Metinde otomatik bilgisayarlardan, bilgisayarların programlanması düşüncesinden, nöron ağlarından, hesaplamanın büyüklüğü teorisinden, akıllı bir makinenin kendini geliştirmek için faaliyetlerde bulunabileceğinden kısaca bahsedilmiştir (McCarthy ve ark., 2006; Soysal, 2022; Yancı, 2019).

Dünyada matematik denildiğinde, sayılı bilim insanları arasına giren Ord.Prof.Dr. Cahit Arf, maalesef yapay zeka camiasında hakkettiği yeri bulamamıştır. 1959 yılında Erzurum’da Atatürk Üniversitesi bünyesinde düzenlenen halk konferanslarındaki “Makine Düşünebilir mi ve Nasıl Düşünebilir?” adlı konuşmasında, yapay zeka kavramını, ülkemize tanıtan ilk kişi olmuştur. Yapay zekanın temelinde yer alan insan gibi çıkarımda bulunabilme özelliğini, kendi hayatında yaşamış olduğu bir olayla izah etmiştir. Hadise askerliğini yaptığı yıllarda, bir talim bataryasında geçmektedir. Batarya yedek subay adaylarının yetiştirildiği okulda bulunmaktadır. Yedek subay adaylarına, batarya kadrosunda tertiplenen erler tarafından topların çalışma prensibinin gösterildiğini, bu erlerin daha önceden okumayı ve yazmayı bilmediklerini, buna rağmen topun parçalarının işleyişini, ölçü aletlerini, yüksek okul okumuş yedek subay adaylarının bazılarında daha kolay ve doğru olacak şekilde öğrendiklerini belirtmiştir. Tezatlık oluşturan bu konu hakkındaki mütalaası, okullarda hala devam etmekte olan anlamadan belleme yanılığının olduğu yönündedir. Bu yanılığın sebebi ile yedek subay adaylarının yeni ve karmaşık görülen olayları, daha öncesinde aşına olduğumuz ve basit olarak değerlendirdiğimiz olaylara ayırma, tahlil etme yetisini yitirmesinden ötürü olduğunu söylemiştir. Yüksek okul mezunu yedek subay adayının yanlış bir eğitim sistemi neticesinde muhtevası kaybolmuş kelimelerle, tıpkı sıradan bir bilgisayarın ezberine dayalı bir ve sıfır mantığı ile hareket etmesine benzetmiştir. Bu durumun tersine, köyünden eğitim kurumu görmeden gelen erin, her insana özgü bulunan yetilerini kaybetmemesiyle, daha önceden çok iyi bilmediği kelimeleri kullanmak yerine, aşına olduğu hadislerle düşündüğünü belirtmiştir ki günümüz yapay zeka öğrenme temeli de de bu yönde evrilmektedir (Arf, 1959).

İkinci Dünya Savaşı sonrası, atom enerjisini, duruma göre kararlar verip ve verdiği karara uygun işleri yaptırabilen, düşünen makineleri, bir başka anlatımla elektronik beyinleri ve uzaya fırlatılan uyduları, insanlık açısından mucize olarak görmüştür. Konuşmasının devamında düşünen makineler konusunu detaylandırmış, ayrıca çalar saatin, telefonun kendine has bir dili olduğunu belirtmiştir ki, bu husus bilgisayarın kendisine özgü dili olduğuna güzel bir örnektir. Arf insanın beyin yapısının karakteristik özelliği gereği, yeni olan veya sahip olduğumuz durumlara intibak sağlayabileceğini söylemiş, intibak yeteneği olan makinaların yapılması esnasında, bugünkü tabiri ile programlanırken, üzerinde düşünülmemiş problemleri de çözebilir mi sorusunu sormuştur. Makine ile insan beyni arasındaki asıl farkın, estetik mahiyetteki kararlar alabilmesi olduğunu, ama bu kararları uygulaması noktasında irade sahibi olduğunu, makinalarda ise böyle bir özelliğin

bulunmadığını irdelemiştir. İnsanı makinadan ayıran bu özellikleri karakterize eden olgunun belirsizlikten kaynaklandığını belirterek ve konuyu atomlara getirmiştir. Atomlar içerisinde cereyan eden olayların da belirsiz olduğunu, bu durumun makinaların işleyişinde kullanılabilmesi durumunda insan beyin yapısına benzeyebileceğini ümit etmiştir (Arf, 1959; Sarı, 2021).

Bu tespit literatürde, kuantum bilgisayarın ilk kavramsal düşüncesidir. Dünyada bilinmemesine karşın fikir babası olarak Arf'i gösterebiliriz.

1966 yılında Joseph Weizenbaum Massachusetts Teknoloji Enstitüsü'nde (MIT) geliştirdiği yapay zeka programı Eliza, Doğal Dil İşleme alanında bir dönüm noktası olarak kabul edilmektedir. İnsan ve makine arasındaki doğal dil konuşmasını simüle etmiştir (Güneysu, 2021; Joseph, 1966).

1958'de Frank Rosenblatt, yapay sinir ağlarının ilk modeli olarak bilinen Perceptron'u, insan beyninin, sinir ağlarından ilham alarak tasarlamıştır. Yapay sinir ağları ile ilgili başlattığı bu çalışmalar aynı zamanda günümüz derin öğrenme sistemlerinin temel yapıtaşı da olmuştur (Çınarer, 2021; Rosenblatt, 1958).

Uzman Sistemler, yapay zeka çalışmalarının ilk ticari meyvesi olarak görülmektedir. 1970 Ağustos'unda, bilgisayar bilimcisi Edward Albert Feigenbaum, Stanford Üniversitesi iş birliği ile geliştirdiği sezgisel Dentrall bilgisayar programını tanıtmıştır. Bu programı organik kimyadaki tümevarımsal çıkarım problemlerini çözebilmek için yazmıştır (Feigenbaum ve ark., 1970; Güneysu, 2021).

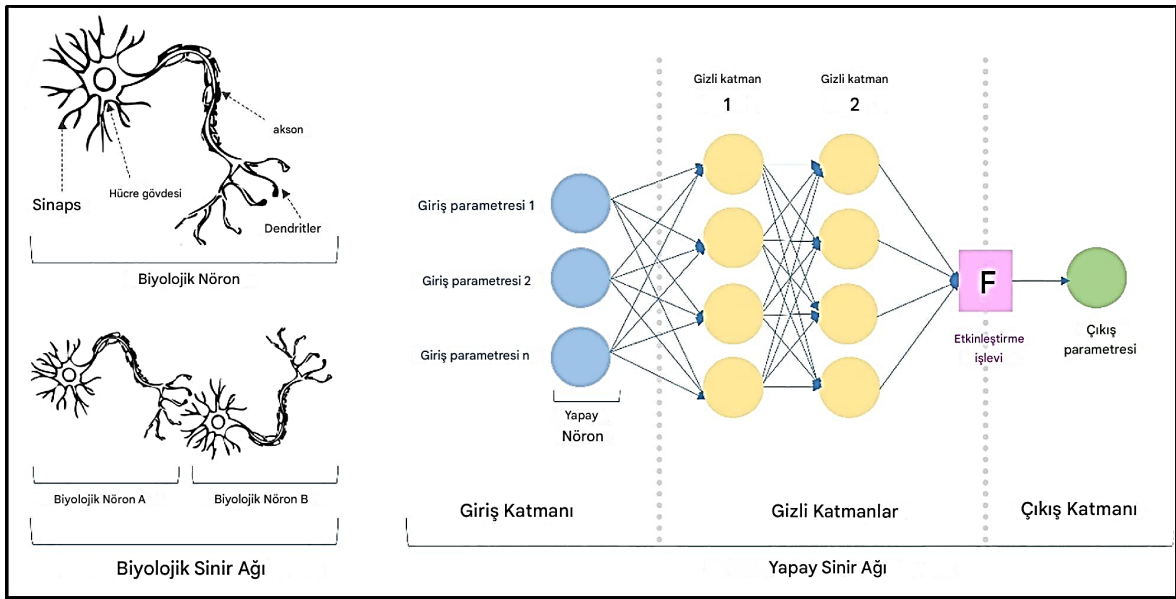
Makinaların insanı yenme fikri yeni olmayıp, 1769 Avusturya'sında kendini göstermiştir. İçerisinde bir insan oyuncunun gizlendiği Türk adıyla bilinen Satranç Otomatı, bu mücadelenin güzel bir örneğidir. Satrançtaki bu mücadelenin, insan üstünlüğü 1997 yılında dünya satranç şampiyonu Garry Kimovich Kasparov'un, IBM tarafından üretilen Deep Blue bilgisayarına yenilmesi ile son bulmuştur. Deep Blue bilgisayarı bir saniyede içerisinde, 200 milyon adet farklı hamleyi tahmin edebiliyordu (Hsu, 1999; Özseven, 2021; Türkdamar, 2023; Yasak, 2021).

Alex Krizhevsky ve ekibi, 2012 yılında ImageNet LSVRC-2010 (Büyük Ölçekli Görsel Tanıma Yarışması) yarışmasını kazanmak için, 60 milyon parametreye sahip derin Evrişimli Sinir Ağı'nı (CNN-Convolutional Neural Network) eğitmişlerdir. Bu sinir ağı sonraları AlexNet olarak anılmıştır. AlexNet sayesinde bilgisayarlı görü devrim yaşamış olup, CNN mimarilerinin temel yapı taşı olmuştur (Güzel, 2022; Krizhevsky ve ark., 2017).

2.2. Yapay Sinir Ağları

Yapay Sinir Ağları farklı türden verileri genelleme yaparak öğrenmekte, müteakiben bünyesinde olmayan girdiler kendisine sorulduğunda; öğrendiği bilgilere dayalı, fark edilmesi zor ilişkilerde bile bir tahminde bulunabilmektedir. Bu özelliği sayesinde bir çok alanda yaygın olarak kullanılmakla birlikte kompleks sorunların çözümünde büyük oranda başarı göstermektedir (Başer, 2022; Yılmaz, 2021).

YSA'lar insan beyni içerisindeki sinir ağlarını matematiksel olarak taklit edebilen bilgisayar sistemidir (Bozkurt, 2022; Cingöz, 2022; Hendaoui, 2022; Koca, 2022; Olgun, 2022; Yancı, 2019). İnsan beyninde tahmini 10 milyar nöron olarak adlandırdığımız sinir hücresi, 60 trilyon sinaps olarak bilinen bağlantı noktası bulunmaktadır. Sinir sistemimiz milyarlarca nöronun bir araya gelmesi ile oluşmaktadır. Beyin içerisindeki sinapslarda üretilen sinyaller, dendritler aracılığıyla bir araya getirilerek hücre gövdesine iletilmektedir. Sinyaller burada değerlendirme sürecine girmektedir. Değerlendirme sonucu sinyallerin gücü belirli bir eşiği aşarsa, aksonlar vasıtasıyla öteki nöronlara taşınmaktadır. Sinyallerin eşiğin altında kalması durumunda taşınım olmamaktadır (Çınarer, 2021; Gürgen, 2021; Koç, 2022; Topal, 2022; Yancı, 2019). Şekil 2.1'de YSA ve insan sinir ağının kavramsal benzerliği gösterilmektedir.



Şekil 2.1. İnsan sinir ağı ile YSA arasındaki kavramsal benzerlik (Shah ve ark., 2022)

Warren S. McCulloch ve matematikçi Walter Pitts 1943 yılında yayınladıkları makaleleriyle, her bir nöronu, matematiksel hesaba dayanan basit bir dijital işlemci olarak kavramsallaştırarak, yapay zekanın matematiksel mantığına, öncü destek olmuştur. Beyni bir Turing Makinesi gibi düşünmeleri, yapay zeka ve sinir bilimi gelişimine önemli ölçüde katkılar sağlamıştır. Gerçekleşen sinirsel aktivitelerin ya hep ya hiç mantığı ile çalıştığını, bu aktivitelerin ve aralarındaki bağların, önermeler mantığı ile ele alınabileceğini düşünmüşlerdir (Güvenç, 2021; Kesintaş, 2021; McCulloch ve Pitts, 1943; Ortiz ve ark., 2022; Yıldırım, 2022).

Değer taşıyan fonksiyonların, nöronlar tarafından oluşturulan ağlar vesilesi ile matematiksel olarak hesaplanabilir olduğunu, “ve”, “veya” mantıksal işlemleri ile işlemlerin yapılabilir olduğunu kanıtlamışlardır. Dizayn edilebilen ağlara, yeterli tanımlamalar yapılabildiğinde ağın öğrenme yetisine sahip olabileceğini keşfetmişlerdir (Yılmaz, 2021).

YSA'ların ortam şartlarına uyum sağlaması, belirsizlik olsa bile bir karar verebilmesi, çıkan hatalara karşı toleranslı davranabilmesi, verilerin eksik olduğu durumda bile çalışabilmesi, ağ parametrelerine ayarlanabilmesi gibi farklı opsiyonları sunabilmesi; geleneksel hesaplama yöntemlerine nazaran tercih sebebi olmakla birlikte, uygulanabildiği her alanda başarılı neticeler göstermektedir (İlhan, 2018).

2.3. Makine Öğrenmesi

Arthur L. Samuel 1959 yılında bilgisayarların dama oyununu 8-10 saatlik gibi, dönemine göre çok kısa sayılabilecek bir sürede, programın yazılımını yapan insandan çok daha iyi oynamayı öğrenebileceğini ispatlamaya çalışmıştır. Çalışmasında başarı olan Samuel makinaya oyunun kurallarını, yönelme hareketlerini ve oyunla alakalı olabileceği değerlendirilen girdilerin uygulanması durumunda, ağırlık ve parametre değerleri tam olarak girilme bile makinenin öğrenebileceğini göstermiştir. Yaptığı bu deneylerle, makine öğrenimi ilkelerini sadece dama oyununda değil başka birçok alanda da uygulanabileceğini vurgulamıştır. Böylece makine öğreniminin gelecekteki gelişme hızına ivme kazandırmıştır (Ali ve ark., 2022; Güneysu, 2021; Samuel, 1959).

Makine öğrenmesi belirlenen bir görevi başarmak için veri kümesine ait bilgilerin aralarındaki bağlantıyı tanımlayarak öğrenebilmesini, sonrasında kendisine önceden sunulmamış girdilere tahminde bulunabileceği, sistemler bütünüdür. Makine öğrenmesi büyük ve heterojen özellik gösteren veri setlerinden, anlamlandırılacak bilgiyi bulma, analiz ve tahmin safhalarında kullanılmaktadır (Acar, 2022).

Makine öğrenimi mevcut olan veriye nasıl ulaşılabileceğini, ulaşıldığında ise elde edilmek istenen neticelere hangi mimarilerin oluşturulması gerektiğine yol göstermektedir. Devasa kapasiteye haiz verileri, karmaşık görevleri yüksek doğrulukla tahmin etmek maksadıyla farklı türden makine öğrenmesi yöntemleri kullanılmaktadır (Alemdar, 2023; Karaahmetoğlu, 2023).

Bilgi insan müdahalesi olmadan, algoritmalar aracılığı ile işlenmektedir. Makine öğrenmesi günümüzde bilinen Bing, Yandex, Google gibi arama motorları aracılığıyla web sayfalarını dinleyebilme, bireysel kullanıcıların tercih edebilecekleri ürünlerin reklamını gösterebilme kararlarını alabilmektedir (Canbolat Göçmen, 2022). Facebook gibi milyarlarca insana hitap edebilen bir teknoloji şirketi, üyelerinin kişisel sayfasındaki bilgi akışını emanet ettiği birkaç çalışanın mevcut olduğu bilinmektedir. Sadece bu devası işin bile insanlar aracılığı ile yapılması mümkün değilken, makinenin kullanıcıların her bir oturumunu öğrenip, kendi kendini yenilemesi ve daha da akıllı hale gelmesi mümkün olmakta ve diğer alanlarda bu özelliklerini gösterebilmektedir (Açıksözlü, 2021).

Makine Öğrenmesi, yapay zekanın bir alt dalıdır (Fang ve ark., 2022; Ortiz ve ark., 2022; Peker, 2021; Rahimi ve ark., 2022). Makine öğrenmesi yöntemleri; denetimli öğrenme, denetimsiz öğrenme ve pekiştirmeli öğrenme olmak üzere öğrenme stratejilerine göre üçe ayrılmaktadır (Acar, 2022; Tarım, 2019).

Denetimli Öğrenme: Etiketlendirilmiş veri kümelerinin kullanımı ile açıklanan makine öğrenimi türüdür. Denetimli öğrenmede kullanılan veri kümeleri, modeli eğitebilmek için kullanılmaktadır. Algoritmaları ise verileri sınıflandırmakta ya da çıktıyı doğru tahmin etmeye yardımcı olmaktadır. Oluşturulan model etiketlenmiş girdi ve çıktılardan yararlanarak, kendi doğruluğunu değerlendirerek, zamanla veriler arasındaki ilişkiyi öğrenebilmektedir (Wang, Y. ve ark., 2023). Denetimli öğrenme regresyon ve sınıflandırma işlemlerinde çok başarılıdır (Akaner, 2022).

Denetimsiz Öğrenme: Etiketlenmemiş veri kümelerindeki, gizli nitelikleri ve yapıları, tahmin edebilen göreve yönelik bir yaklaşım sunmaktadır. Etiketleme yapılmamış giriş veri seti kümesi arasındaki benzerlikleri, örnek verileri ile karşılaştırıp, benzer olanlarla bir araya getirerek farklı gruplara kümelemektedir. Denetimli öğrenmede olduğu gibi girdilerle bağlantı olan bir çıktısı ve denetim yapan bir mekanizması bulunmamaktadır. Bu yüzden etiketlenmemiş girdi verilerine bağlı çıktıları doğru öğrenmesi yüksek tahmin açısından çok önemlidir. Kendisine sunulan yeni verilerin, sınıfını tespit etmek için önceden öğrendiği özellikleri kullanmaktadır. Denetimli öğrenme ile karşılaştırıldığında, genellikle öznel ve alana özgü bir performans sunmaktadır (Zhou, 2022). Denetimsiz öğrenme sayesinde elde edilen modeller, nesnelere kategorize etmede ya da aralarındaki bağlantıyı bulmada fayda göstermektedir. Bu faydalarının yanında veride bulunan kusurların ve anormalliklerin ortaya çıkarılmasında etkili olabilmektedir (Çekiç, 2022).

Pekiştirmeli Öğrenme: Çalışması ödül/ceza prensibine dayanmaktadır. Denetimsiz/denetimli öğrenme aşamalarından farklı bir yapı kullanmaktadır. Öğrenme aşamasında ödülü arttırmak, cezayı azaltmak için parametrelerin ayarlanabildiği öğrenme yöntemi olarak bilinmektedir. Pekiştirmeli öğrenme dış ortamdan aldığı girdileri, çıktı eylemlerine dönüştürebilmektedir. Sistemin çevre ile etkileşiminden aldığı girdilerle, ödüllerin maksimum seviyede elde edilmesi hedeflenmektedir (Canbolat Göçmen, 2022). Pekiştirmeli öğrenmeye gerçek hayattan bir örnek verdiğimizde; bebeklerin ateşi gördüğünde, eline ateşe uzatması gibi bir durum ortaya çıkabilmektedir. Bebeğin ateşe dokunma deneyiminden aldığı etkiye göre bu aktiviteyi tekrarlayabilmekte ya da hiç yapmayabilmektedir.

Makine öğrenmesinde istenilen problemlerin çözüme kavuşturulmasında farklı türde algoritmalar bulunmakta olup, literatürde yaygın olarak geçenler aşağıda sunulmuştur.

2.3.1. K-En Yakın Komşu (KNN)

KNN, parametrik olmayan klasik bir algoritmadır örüntü tanıma işlemlerinde, regresyon ve sınıflandırma yapmak için kullanılmaktadır. Birbirine yakın örneklerin, benzer sınıflandırmalara sahip olması gerektiğini varsayar ve yeni giriş yapan örnekleri, en çok benzediği komşularının sınıflandırmasına dahil etmektedir. KNN algoritmasında mesafeyi ölçmek için çeşitli ölçütler kullanılmakta olup Manhattan Uzaklığı Eşitlik 2.1’de, Minkowski Uzaklığı Eşitlik 2.2’de, en yaygın olarak tercih edilen Öklid Uzaklığı Eşitlik 2.3’de sunulmuştur (Büyükarıkan, 2022). KNN, tümevarımsal yaklaşımını sınıflandırma işlemini sonuçlandırıcaya kadar ertelemesi ve eğitimde kullandığı örneklerin tamamını ya da bir kısmını kaydettiği için tembel öğrenme algoritması olarak ta tanımlanmaktadır (Aşan, 2022; Benhar ve ark., 2020).


KNN algoritması sınıflandırma yapabilmek için tüm verileri taramakta dolayısı ile fazla miktarda veriye sahip çalışmalarda, çıkarımı maliyetli olabilmektedir (Olgun, 2022).

$$d = |x_1 - x_2| + |y_1 - y_2| \quad (2.1)$$

$$d(A, B) = [\sum_{k=1}^n |x_k - y_k|^m]^{1/m} \quad (2.2)$$

$$d = \sqrt{(x_2 - x_1)^2 + (y_2 - y_1)^2} \quad (2.3)$$

KNN’nin k (en yakın komşu sayısı) değeri genelde olarak tek sayılardan seçilmektedir (Olgun, 2022). 3 ve 5 olarak ayrı ayrı k değerini belirlediğimizde x , y koordinatlarındaki temsili gösterim Şekil 2.2’de sunulmuştur. Mavi üçgenler A sınıfını, kırmızı daireler B sınıfını belirtmekte, yeşil yıldız sınıflandırılanların test noktasını göstermektedir. Kesikli çember k için en yakın komşuların kapladığı alanı göstermektedir. KNN algoritmasının k sayısı fazla seçildiğinde, sınıfın özniteliklerini kaybetme riski, az seçildiğinde aşırı uyum riski olabilmektedir.



Şekil 2.2. K-En Yakın Komşu (KNN) algoritması

2.3.2. Naive Bayes

Naive Bayes algoritması genellikle, sınıflandırma problemlerinin çözümünde olasılık teorisini kullandığı için, makine öğrenmesi alanında temel ve efektif bir değer taşımaktadır. Algoritmanın temelinde istatistik bilimindeki Bayes teorimi kullanılmaktadır. Matematiksel ifadesi Eşitlik 2.4'te sunulmuştur. Eşitlikte yer alan $P(A|B)$ B olayının gerçekleşmesi durumunda A olayının gerçekleşebilme olasılığını, $P(A)$ A olayı gerçekleşebilme olasılığını, $P(B|A)$ A olayının gerçekleşmesi durumunda B olayı gerçekleşebilme olasılığını, $P(B)$ B olayı gerçekleşebilme olasılığını temsil etmektedir.

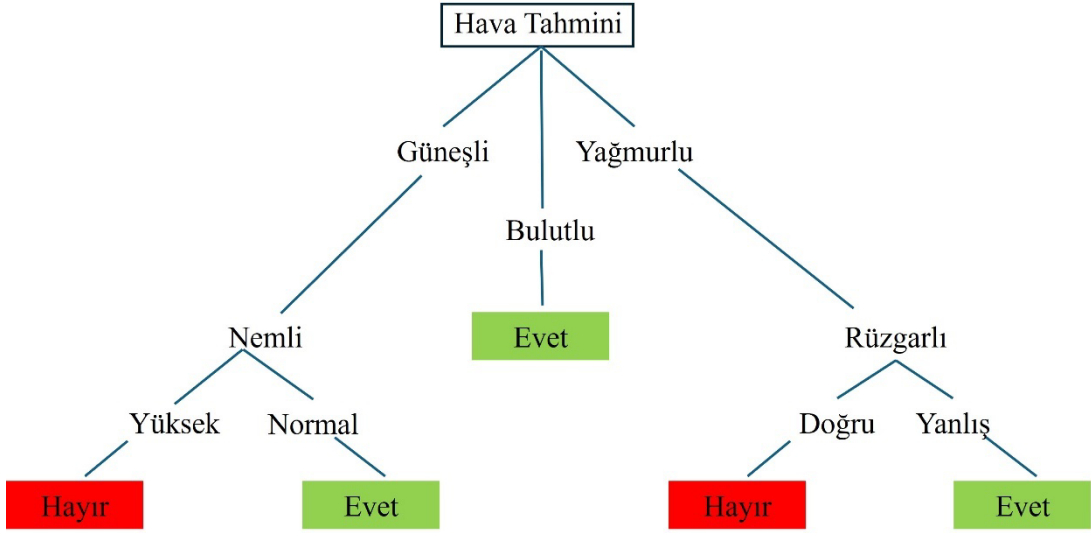
Algoritmada kullanılan “Naive” ifadesi algoritmanın bağımsızlık prensibini temsil etmekte, bir başka anlatımla mevcut verilerdeki her özelliğin diğerlerini etkilemediğini kabul etmektedir. Bu hal tarzı gerçekçi görünmese de algoritma çalıştırıldığında problemin çözümünde doğru sonuçlar elde edebilmektedir.

$$P(A|B) = \frac{P(B|A)P(A)}{P(B)} \quad (2.4)$$

Fakat, bu uygulama her durumda gerçeği yansıtamayabilir, bazen özellikler arasında korelasyon gözlemlenebilmektedir. Kişinin eğitim düzeyi ve yaşı gibi özellikler birbirleri ile bağlantılıdır. Böyle bir varsayımda bağımsızlık ilkesi efektif olarak tatbik edilemediği için performans düşüşleri yaşanabilmektedir. Bayes teoremi, olayların olma olasılığını, bahse konu olaya ait bulgularla güncellemekte ve hesaplamaktadır.

2.3.3. Karar Ağaçları

Makine öğrenme algoritmalarından, Karar Ağaçları herhangi bir sorunu çözmek için, tıpkı bir ağacın tohum iken büyümesi gibi belirli evrelerden oluşan ve sırasıyla devam eden bir yol haritası olarak düşünülmektedir. Tüm veriler girdi olarak düğüm ifadesiyle nitelendirilen kökten başlayarak, dallanmakta ve bu dallar karar noktalarını temsil etmektedir. Ağacın son aşaması olan yapraklar ile kendisine iletilen verilerin ortak özelliğine göre sayısal ya da sınıfsal olabilen tahminler yürütülmektedir. Karar ağaçları, her kesim tarafından basitçe algılanabilir tümevarımlı bir yapıdadır. Bu özelliği sayesinde modelin çalışma aşamaları ve yorumlanması kolaylaşmaktadır. Basit bir Karar Ağacı şeması Şekil 2.3'de çizilmiştir. Eğitilmeleri büyük veri setlerinde bile hızlıca tamamlanabilmektedir. Çok dallı ve yapraklı ağaç yapılarında eğitim için kullandığı verilere aşırı uyum sağlayabilmekte, ilk kez sunulan verilere karşı genelleme özelliği azalabilmektedir. Böyle durumlarda budama yöntemleri ile genelleme özelliği artabilmektedir (Acar, 2022; Aşan, 2022; Olgun, 2022).

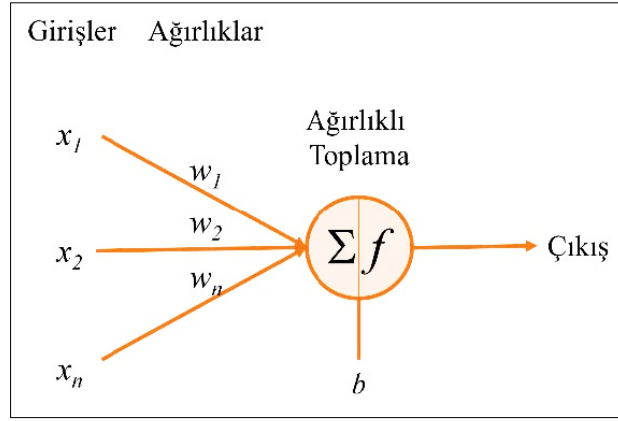


Şekil 2.3. Karar Ağacı (Quinlan, 1986)

2.4. Derin Öğrenme

McCulloch ve Pitts 1943 yılında, ilk kez yapay sinir hücresinin tasarımını yapıp, aralarındaki bağlantıları sinir ağı modeline dönüştürerek, matematiksel açıdan formüle etmeyi başarmaları ile derin öğrenmenin tarihini başlatmışlardır (Acar, 2022; Arulprakash ve Aruldoss, 2022; Buğa, 2023; Yıldırım, 2022). 1958 yılına gelindiğinde, Frank Rosenblatt tarafından, ilk tek katmanlı, “Perceptron” isimli sinir ağı oluşturulmuştur (Apaydın, 2023; Balım, 2022; Güzel, 2022; İlhan, 2018; Rosenblatt, 1958; Yıldırım, 2022). Eşitlik 2.5’te (Balım, 2022) formülü, Şekil 2.4’te çizimi gösterilmiştir. Formülde x ile gösterilen ağı girdi değerini, W simgesi ağırlık değerini, b simgesi nöronun taraflılık değeri için kullanılmıştır.

$$Z = \sum_{i=1}^n (W_i \cdot x_i + b_i) \quad (2.5)$$



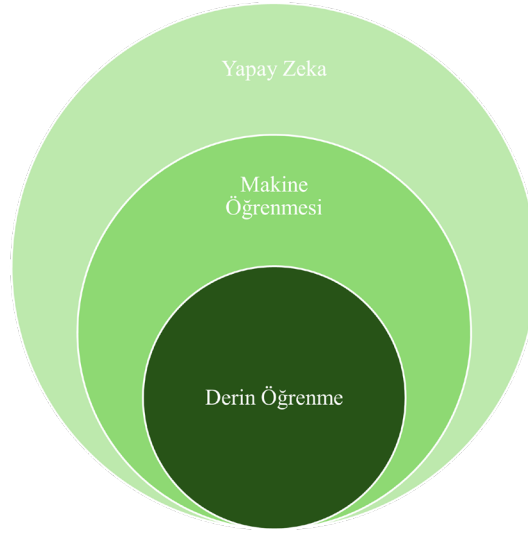
Şekil 2.4. Perceptron yapısı(Acar, 2022)

1980’lerde sinir ağırları paralel dağıtık işlemler ile geliştirilmeye başlanmıştır (Yılmaz, 2021). 2000’li yıllara gelinceye kadar çok katmanlı olan derin öğrenme mimarisi pratiği dökülememiştir (Sevinç, 2022). Geoffrey Hinton 2006 yılında çok katmana sahip ileri besleme özellikli sinir ağı katmanlarının, kendisinden sonraki gelen katmanı eğitebileceğini bulmuştur (Yıldız, 2021).

Görme, düşünme, hareket etme ve konuşma gibi insana özgü olan bu karışık fonksiyonları, beyin içerisinde birbirine bağlanan çok sayıdaki nöronlar marifeti ile gerçekleştiğinin fark edilmesinden itibaren, beyin yapısı taklit edilmeye çalışılmıştır. Birden fazla katmana sahip derin öğrenme mimarileri, yapay sinir ağının gelişmiş bir türü olarak bu düşünceye hizmet etmektedir. Derin öğrenme mimarileri çok katmanlı yapılardır. Çok katmanlı olması nedeniyle “Derin” kelimesi ile anılmaktadır. Ağ yapısı içerisindeki tüm nöronların işlevsel özelliği aynı kabul edilmekte fakat her biri farklı parametreleri öğrendiği katmanda yer almaktadır. Faaliyete giren katmanlar kendisine girdi olarak verilen verileri sürekli olan bir döngü ile dönüştürerek, ileri beslemeli adıyla bilinen süreç ile istenilen sonuca ulaştırmaktadır. Nöronlar arasındaki bağlantıların ağırlıkları, öğrenme süreci olarak kullanılan geri yayılım ile optimize edilmektedir (Borges Oliveira ve ark., 2021; Dönmez, 2021; İlhan, 2018; Rahimi ve ark., 2022).

Makine öğrenimi çalışmalarının asıl hedefi olan yapay zekaya erişme amacı, yeni sayılabilecek olan derin öğrenme ile kendini göstermektedir. Derin öğrenme, otomatik olarak öğrenebilme yeteneği, güçlü özellikleri, büyük verilerin işlenmesine ve makine öğrenimi yöntemlerine sunmuş olduğu geniş ürün yelpazesi ile önemi katlanarak devam etmektedir (Siddula ve ark., 2016). Derin öğrenme sahip olduğumuz yapay zeka sistemlerinin üretiminde çok önemli roller üstlenmektedir (Yellapantula, 2019; Yılmaz, 2021). Derin öğrenme, makine öğrenmesi ve yapay zeka arasındaki ilişki, Şekil 2.5’te sunulmuştur.

Derin öğrenme, yapay sinir ağı alt yapısını kullanan, makine öğrenmesinin bir alt dalıdır (Alemdar, 2023; Canbolat Göçmen, 2022; Gündüz, T., 2023; Jabbarli, 2023; Liu, Luo ve ark., 2022; Sağın, 2019).



Şekil 2.5. Derin öğrenme, makine öğrenmesi ve yapay zeka arasındaki bağlantı

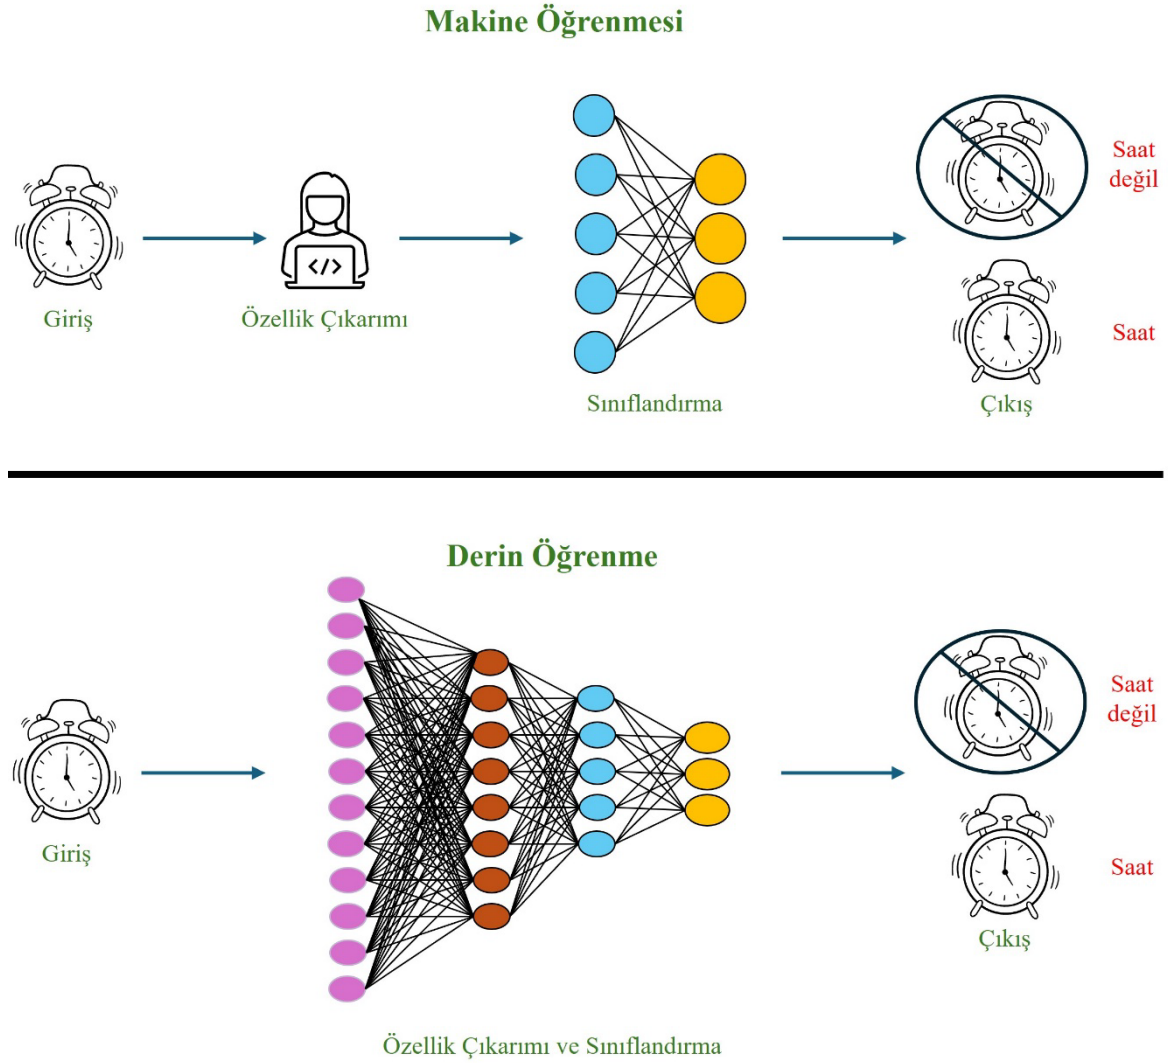
Derin öğrenmenin son dönemde bu kadar yaygın olarak kullanılabilmesinin sebebi, eğitimi için gerekli olan verinin yeterince üretilebilmesi ve bu veriyi işleyebilecek donanımsal yapıdaki teknolojik gelişmedir (Başer, 2022; Duan ve ark., 2022; Jabbarli, 2023; Yang ve ark., 2022). Böylece çok kompleks olan veriler işlenebilmekte, anlam çıkartılabilmektedir (Türk, 2021).

Veriler, toplumun dijitalleşmeye olan eğilimi sayesinde ivmelenerek artmaktadır. Nerede ise yapılan tüm işlemlerde bilgisayar kullanılmakta, yapılan işlemler kaydedilmektedir. Bilgisayarların, akıllı cep telefonların internet ağına bağlanarak, sosyal medya, arama motorları vb. merkezîyetçi yapılara erişebilmesi ile veri üretmesi, makine öğrenimi kullanarak hizmet sağlayan uygulamalara bitmek tükenmek bilmeyen kaynak sağlamaktadır (Güzel, 2022).

Makine öğrenmesi ve derin öğrenme özünde sinir ağlarını kullanması bakımından birbirine benzese de kendi aralarında büyük farklılıklar bulunmaktadır. Derin öğrenme çeşitli katmanları ile kendi kendini eğitebilen, sonuç odaklı kararlar verebilen ağ yapılarından oluşmakta iken makine öğrenimi algoritmalar aracılığı ile verileri öğrenmekte, yorumlamakta ve bilinçli kararlar sunmaktadır. Derin öğrenme yüksek kapasitedeki verileri işlemek için maliyetli ve yüksek işlem hacimli donanımlara ihtiyaç duyarken, makine öğrenimi küçük miktardaki veriler ile çalışarak sonuca varabilmektedir. Derin öğrenme sorunu bir bütün olarak ele almakta iken makine öğrenimi sorunu küçük parçalara ayırarak işler ve sonrasında bu sonuçları birleştirerek çözüm sağlamaktadır. Derin öğrenme eğitimi kapalı ve karmaşık ağlar üzerinde, uzun süreçlerde tamamlanmasına karşın doğrulama kapasitesi makine öğreniminin üzerine çıkmaktadır (Akaner, 2022; Al-Asadi, 2022; Serttaş, 2021).

Makine öğrenmesi tasarlanırken modele, veri ve verinin bulması istenilen özellikler birlikte yüklenilmekte böylece özelliklerden hangisinin sonuca daha çok etki ettiği anlaşılacak, bir fonksiyon

türetilmektedir. Derin öğrenmede dışarıdan bir müdahalede olmaksızın, özelliklerin model tarafından öğrenilmesine müteakip, hangi veriye ne kadar oranda ağırlık verileceğine kendisi karar vermektedir (Çekiç, 2022). Derin öğrenme ve makine öğrenmesinin karşılaştırılması Şekil 2.6'da sunulmuştur.



Şekil 2.6. Derin öğrenme ve makine öğrenmesinin karşılaştırılması

2.5. CNN (Evrşimsel Sinir Ağları)

CNN'nin çalışma prensibi, standart yapıdaki yapay sinir ağlarına çok benzemektedir. CNN'nin 1980'li yıllarda pratiği dökülüşünden itibaren en yaygın ve ileri teknolojiye sahip, derin öğrenme mimarisi (Ali ve ark., 2022) olmuştur.

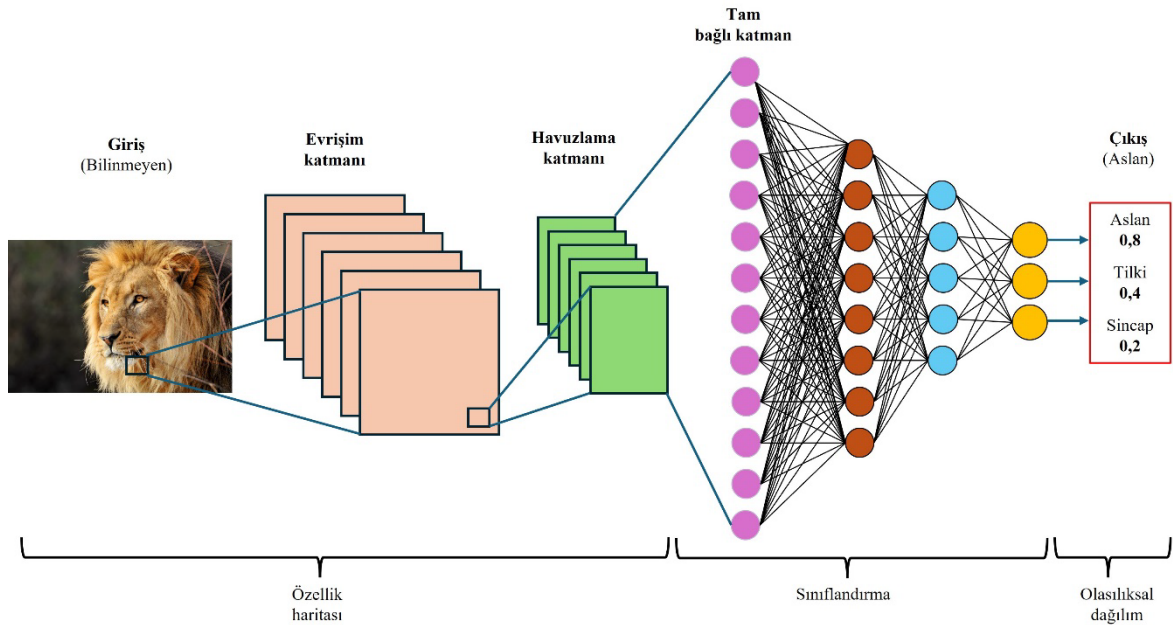
CNN mimarisi 1989 yılında rakamları (0-9) tanınması ile sahneye çıkmıştır. Bu performansından sonra CNN'nin potansiyel etkisi görülmüş, zorlu tanıma görevlerinde, makine öğrenimi yöntemlerine göre daha iyi olduğu ispatlanmıştır (Saadoon, 2022). CNN mimarisi, ilk

olarak Yann LeCun ve arkadaşları tarafından geliştirilip, el yazısı karakterlerini tanımakta kullanılmıştır (Bilik ve ark., 2024; LeCun ve ark., 1989; Li ve ark., 2022; Yann Lecun, 1989).

1998’de yine LeCun tarafından geliştirilen ve literatürde, CNN mimarisinin ilk başarılı örneği olarak kabul edilen LeNet-5 modeli, aynı zamanda bu alanın öncüsü olarak kabul edilmektedir. LeNet-5, el yazısı rakamlarını yüksek doğrulukla tanıyabilmiştir (Dönmez, 2021; Lecun ve ark., 1998; Wei ve ark., 2019).

CNN, görüntü, doğal dil işleme ve ses tanıma gibi alanlarda kullanılmakta fakat en yaygın hizmetini görüntü işleme alanında göstermektedir. CNN’e görüntüler girdi olarak verildiğinde analiz ederek bu görüntülerdeki özellikleri tanımlayan filtreleriyle de özellik haritalarını meydana getirmektedir. Ayrıca bu filtrelerle görüntülerde yer alan çizgi, desen ve kenarları da tespit edilebilmektedir. İleriki aşamalarında bir veya birden çok, gizli katmanınca tespit ettiği özellik haritalarını toparlayıp, nesne tespiti yapmaktadır. CNN’de kullanılacak büyük verilerin eğitimi için işlem hızı ve kapasitesi yüksek GPU’lara ihtiyaç bulunmaktadır (Chiddarwar, 2019; Gündüz, T., 2023; Shanti ve ark., 2022).

Dijital görüntü ve videoların pikselleri, CNN katmanlarında başarılı bir şekilde işlenebilmesi sebebi ile en çok tercih edilen mimari olmaktadır (Li ve ark., 2022; Mostafa ve Hegazy, 2021; Shanti ve ark., 2022). Sinir ağı mimarisinin standart yapısında, giriş, evrişimsel, havuz, tam bağlı ve çıkış katmanı yer almaktadır (Chen, Y. ve ark., 2023; Fang ve ark., 2020; Gökçe, 2019; Güneysu, 2021; Özdaş, 2023; Raiaan ve ark., 2024; Yetiş, 2022). Şekil 2.7’de görüntü sınıflandırma için CNN mimarisinin temsili görseli sunulmuştur.



Şekil 2.7. Görüntü sınıflandırma için CNN mimarisini

2.5.1. Giriş Katmanı

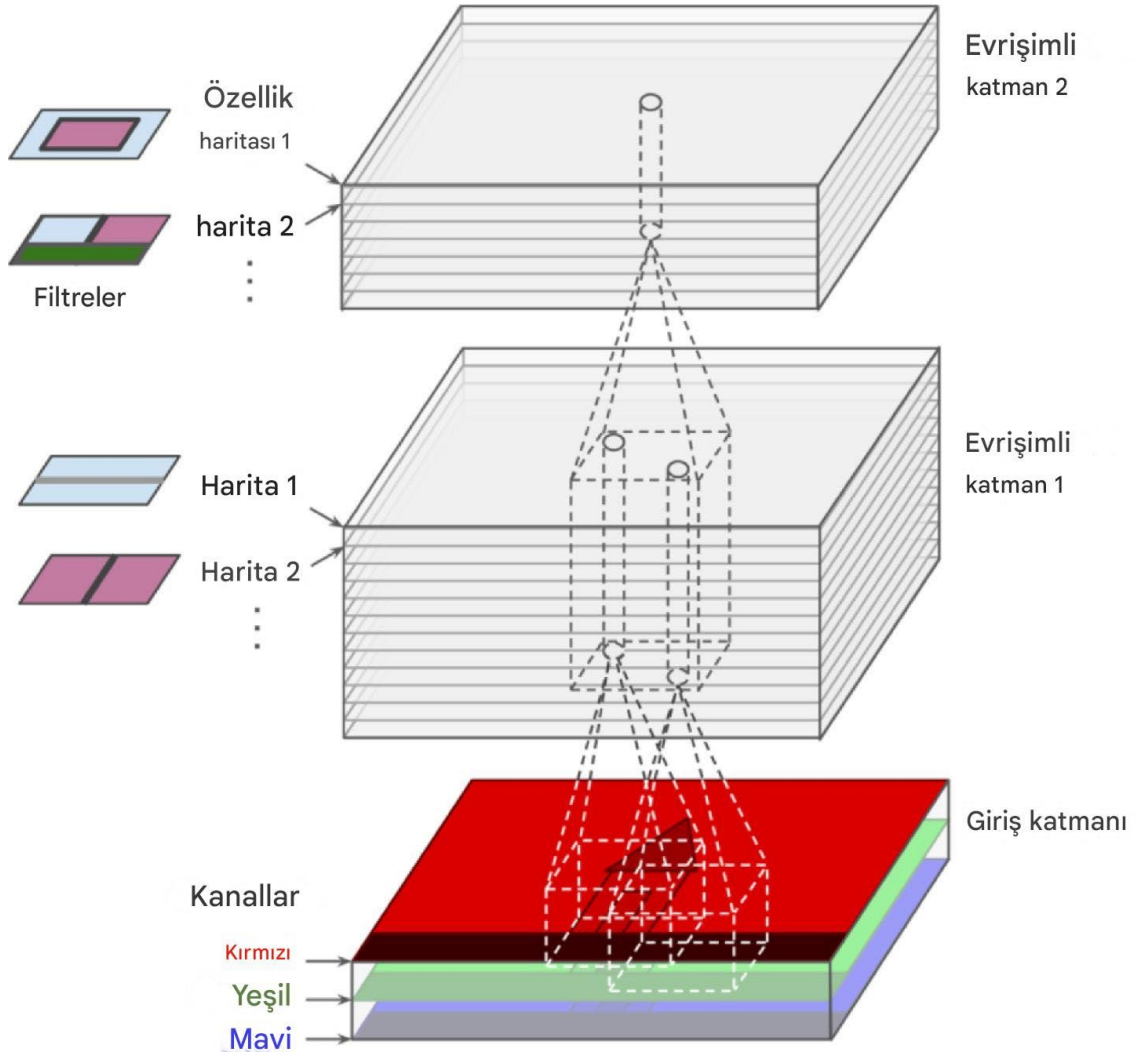
CNN modelinin ilk katmanı olan giriş katmanına veriler ham olarak giriş yapmaktadır. Dijital görüntü verileri bu katmanda istenilen formata uygun hale getirildikten sonra diğer katmanlara iletilmektedir. Giriş verisinin boyutu, modelin başarı performansı üzerinde önemli bir etkidir (Gündüz, T., 2023).

Görüntü veri boyutu yüksek tutulduğunda, yüksek kapasiteli hafıza ve hesaplama maliyeti ihtiyacı ortaya çıkabilmekte, eğitime harcanan süre uzayabilmektedir. Fakat görüntü verisinin yüksek tutulması ağırlık başarı performansını artırarak, isabetli tahminler elde edilebilmektedir. Görüntü boyutu düşük olarak seçildiğinde hafıza ihtiyacı ve eğitim süresi azalmaktadır ancak katman derinliği ve modelin başarı performansı azalabilmektedir. Giriş aşamasında görüntü boyutunun optimum seviyede ayarlanması, bellek kullanımını ve hesaplama maliyetini makul düzeyde tutarak modelin başarılı bir performans sergilemesine fayda sağlamaktadır (Aslan, 2022; Doğan, 2021; Jabbarli, 2023; Sorgun, 2022).

2.5.2. Evrişim Katmanı

Evrişim katmanları, filtreleme tekniklerini sistematik olarak uygulamasıyla, görüntü verilerinden öznitelik çıkarılmasını sağlamaktadır. Bu özelliği ile CNN mimarisi içerisinde ana unsur olarak yer almaktadır (Arulprakash ve Aruldoss, 2022; Doğan, 2021; Saadon, 2022). Evrişim ifadesi, iki fonksiyondan, birincisinin diğeri üzerine kaydırıldıkça oluşan örtüşme miktarını belirten integral hesabıdır (Yıldırım, 2022).

Bilgisayarlı görü alanında, evrişim katmanlarının temel görevi giriş verisinin köşelerini kenarlıklarını renklerini belirlemektir. Ayrıca ağırdaki daha derin katmanlar sayesinde rakamlar, şekiller, yüzün bölümleri gibi karmaşık olarak nitelendirilebilecek özellikleri ortaya çıkarabilmektedir (Abdullah, 2020; Suliman, 2023; Taş, 2021). Evrişim katmanlarının görseli Şekil 2.8’de sunulmuştur.



Şekil 2.8. Evrişim Katmanları (Viotti ve ark., 2024)

Evrişimli sinir ağı derin öğrenmenin temel mimarisini oluşturmaktadır (Azadvatan, 2023). Evrişimli sinir ağları içerisinde ardışık olan birden fazla eğitilebilen bölümler bulunmaktadır. Girdi verisi evrişim katmanına ulaştıktan sonra katmanlarında işlemlere tabi tutularak eğitim süreci başlamakta ve çıkan sonuç ile ulaşılmak istenen sonuç arasındaki fark kadar bir hata değeri oluşmaktadır. Hata değeri fazla olduğunda kayıp yüksek az olduğunda düşük olmaktadır. Hataların ağırlıklara aktarılması geri yayılım algoritması ile mümkün olmaktadır (Balım, 2022; Kara, 2023; Türk, 2021).

2.5.3. Havuzlama Katmanı

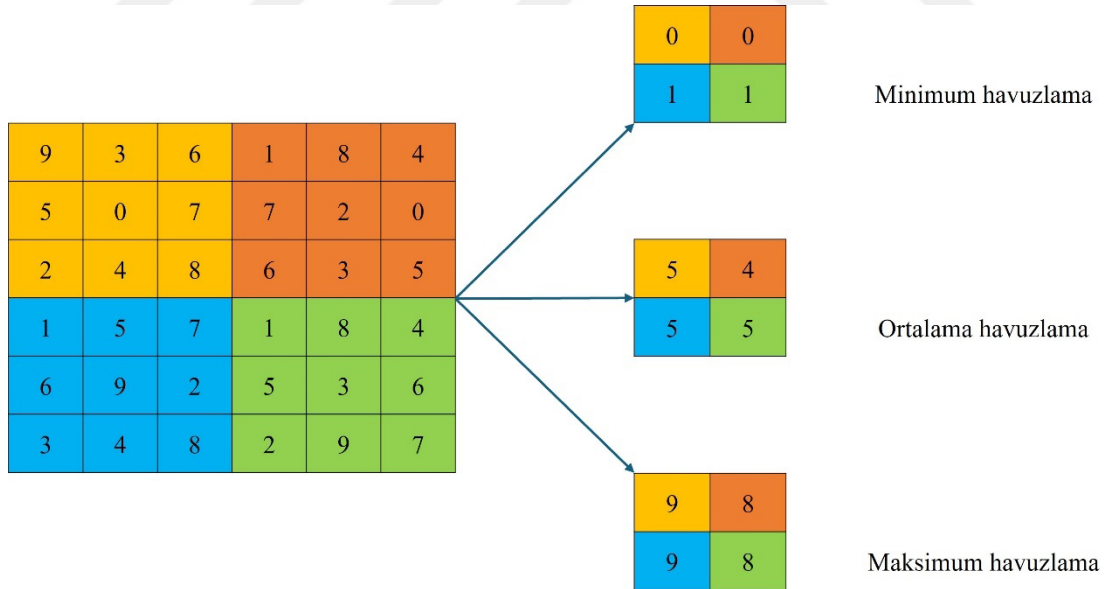
Derin öğrenme ağlarının başarılı olabilmesi, yüksek kapasiteli hesaplama gücüne sahip donanımların kullanılmasına bağlıdır. Derin öğrenme modelleri oluşturulur iken uygulanacak filtre boyutu ve katman sayısının seçimine etkin maliyet açısından dikkat edilmelidir. Derin öğrenme

mimarisi temelinde bulunana evrişim ve havuzlama süreçleri, hesaplama işlemi maliyetinin, büyük bir kısımandan sorumlu olmaktadır (Yetiş, 2022).

Evrişim katmanından sonra genellikle havuzlama katmanı gelmektedir. Mimarinin hesaplama işlem maliyetini azaltmak için havuzlama kısmı önemli bir aşama olmaktadır. Havuzlama katmanına iletilen verilerin boyutu modele uygun olan havuz işlemi seçilerek burada azaltılmaktadır. (Ajith ve Martinez Ramon, 2023; Alemdar, 2023; Che ve ark., 2023).

Kendinden önceki katman sayesinde, oluşturulan özelliklerin boyutları küçültülür ve benzeri özellikleri daha da ön plana çıkartılmaktadır. Bir başka anlatımla alt örnekleme gerçekleştirilmektedir. Bu işlemler sayesinde sonraki katmanlar için işlem yapılması gereken verilerin boyutunu azaltarak modelin işlem ve zaman harcaması önlenebilmektedir. Veri boyutunu azaltma işlemi her ne kadar önemli bilgilerin kaybolmasına yol açsa da ağda hesaplanması gereken parametrelerin sayısı azalmakta, aşırı öğrenmeye engel olmaktadır lakin ağın hesaplama karmaşıklığı giderilerek eğitim sürecinin hızlı bir şekilde tamamlanması sağlanmaktadır (Algaraghuli, 2022; Azadvatan, 2023; Buğa, 2023; Çeçen, 2023; Gündüz, T., 2023; Habib ve Qureshi, 2022; Jabbarli, 2023; Kubaji, 2022; Özkan, 2021; Raiaan ve ark., 2024; Suliman, 2023; Usta, 2022).

Havuzlama katmanları modelin kullanım amacına göre genellikle minimum, maksimum, ortalama havuzlama olmak üzere üçe ayrılmaktadır (Türkoğlu, 2019). Şekil 2.9'de Havuzlama türleri ile ilgili örnekler gösterilmiştir.



Şekil 2.9. Havuzlama türleri ile ilgili örnekler

2.5.4. Tam Baęlı Katman

CNN mimarisinde evriřim ve havuzlama katmanında oluřturulan özellikler tam baęlı katmana aktarılmaktadır. Özellik haritalarının 2 boyuttan tek boyuta dönüřtürüldüęü katmandır (Arulprakash ve Aruldoss, 2022; Li, J. ve ark., 2024).

Tam baęlı katmanda bulunan nöronlar, bir önceki nöronların hepsine tam olarak baęlı durumda bulunmaktadır. Bahse konu bu yaklařımı sebebi ile ismini almıřtır. Katman sayesinde sınıflandırma iřlemi tamamlanmaktadır. Tam baęlı katmanın giriř parametreleri, kendinden önceki havuzlama ve evriřim katmanları tarafınca oluřturulmaktadır. Giriř parametrelerinin vektör biçimini düzleřtirme ařamasından sonra özellik haritalarını kullanarak almaktadır. CNN mimarisinin tamamlanmıř ıktısı tam baęlı katmanda oluřmaktadır (Alemdar, 2023; Cai ve ark., 2021; Habib ve Qureshi, 2022; Hendaoui, 2022; Mostowski ve ark., 2024).

2.5.5. ıktı Katmanı

ıktı katmanı, modelin girdiler sayesinde iřledięi veriyi, tahmin ıktısına dönüřtüren son katmandır. ıktı katmanı modelin problem özme türüne göre farklı matematiksel ve yapısal özelliklere sahip olabilmektedir. ıktı katmanı aracılıęı ile elde edilen tahmin sonuçları, kayıp fonksiyonu tarafından gerek deęerlerle karřılařtırılarak, hata miktarı hesaplanmakta, hatayı minimuma indirmek içinse geri yayılım algoritması kullanılarak, model üzerindeki aęlırlıklar güncellenmektedir. ıktı katmanın doęru yapılandırılmasında aktivasyon fonksiyonları önemli bir rol almaktadır (İlhan, 2018; Olgun, 2022; Topal, 2022).

2.6. Aktivasyon Fonksiyonları

Beyin sinir aęı sistemindeki iki nöron arasındaki iletiřimin saęlanması için sinaptik bořluklara kimyasallar salgılanmaktadır. Benzeri durum yapay sinir aęlarında, aktivasyon fonksiyonları ile gerekleřmektedir. Hatayı minimuma düřürme, hangi nörona sinyal gönderileceęi, geri beslemenin nasıl yapılacaęı, deęerler arasından nelerin göz ardı edilebileceęi sorunları için aktivasyon fonksiyonları kullanılmaktadır. Yapay sinir aęları veriler aracılıęı ile karmařık örüntüleri tespit etmek için eęitildięinde, aę ierisine bir aktivasyon fonksiyonu eklenmektedir (Kubaji, 2022; Yıldız, 2021).

Yapay sinir aęlarında ierisinde, aktivasyon fonksiyonlarının kullanılmaması durumunda, katmanlardaki girdi parametreleri sadece efektif olmayan basit iřlemler ile yürütülecek, veri iřleme ařamaları beklenen performansı gösteremeyecektir. Yapay sinir aęı mimarisi aktivasyon fonksiyonları sayesinde parametreler arasındaki iliřkiyi öęrenebilmekte ve tahminde bulunabilmektedir. Fonksiyonlar mimarinin performans ve kapasitesine doęrudan bir etkiye sahiptir. Modelin katmanlarında deęiřik aktivasyon fonksiyonları alıřtırılabilmektedir (Alemdar, 2023).

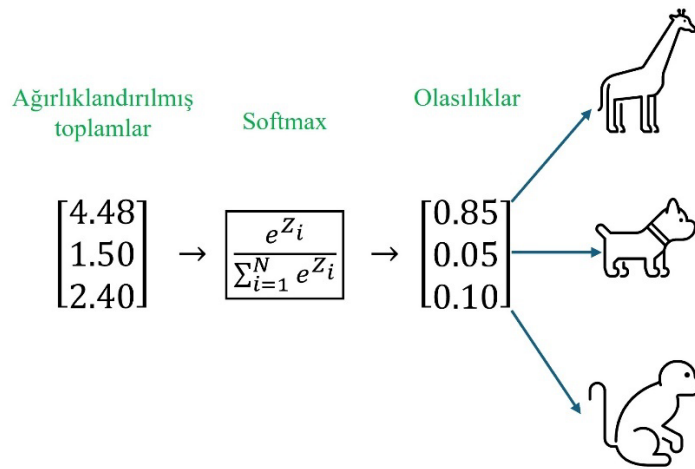
Aktivasyon fonksiyonlarının asıl görevi yapay sinir ağı için karar değeri üretmektir. Perceptrona giriş yapan değerlerin toplamı eşik değerinin üzerinde ise hücre aktifleşmektedir. CNN mimarileri içerisinde en çok softmax, sigmoid, tanh, ReLU aktivasyon fonksiyonları kullanılmaktadır (Abdullah, 2020; Başarır, 2019).

2.6.1. Softmax Aktivasyon Fonksiyonu

Softmax aktivasyon fonksiyonu kendisinden önceki katmanlardan gelen istatistiksel verilerin olasılıksal hesaplamasını yaparak, hangi sınıfı yakın hesaplıyorsa o sınıfa sınıflandırma yapmaktadır (Güzel, 2022). Bu durumda tahmin edilen sınıfın olasılık değeri artarken, öteki sınıfların olasılıkları azalarak, sınıflar arasında rekabet oluşmakta böylece modelin tahmin seviyesi artmaktadır (Gündüz, T., 2023).

Derin öğrenme mimarilerin, sınıflandırma problemlerinin çözümünde en çok kullanılan aktivasyon fonksiyonlarından birisidir. Softmax aktivasyon fonksiyonu çoklu sınıf problemlerinde her sınıfa ait bir olasılık değeri üretmekte, toplam değeri de 1 sonucunu vermektedir

Şekil 2.10'da Softmax aktivasyon fonksiyonunun işleyişinde gösterilen, N çıkış kısmında bulunanların toplam sayısını, i aktivasyon işleminden geçenlerin ağırlıkları toplamını göstermektedir. Şekle göre zürafa, köpek ve maymun olarak 3 farklı nesneyi tespit edebilecek bir derin öğrenme modeli oluşturduğumuzu düşündüğümüzde, tespiti istenilen görüntü verisi modele uygulandığında, modelin çıkışında 3 farklı sınıfa ait olan 3 çıkış noktası bulunmaktadır. Şekilde de görüleceği üzere zürafa 0,85, köpek 0,10 ve maymun için 0,05'tir. Elde edilen bu değerler son süreçte ağırlıklandırılmış toplamların aktivasyon fonksiyonuna tabi tutulması neticesi elde edilmektedir (Apaydın, 2023).




Şekil 2.10. Softmax aktivasyon fonksiyonunun işleyişi (Apaydın, 2023)

2.6.2. Sigmoid Aktivasyon Fonksiyonu

Sigmoid fonksiyonu, doğrusal olmayan, kendisine giriş yapan değerleri 0-1 aralığında çıkış değerine çeviren, S şeklini anımsatan bir aktivasyon fonksiyonudur. Doğrusal olmayan fonksiyon olmasından ve sürekli türevlenebilir özelliğinden ötürü yapay sinir ağlarında yaygın olarak kullanılmaktadır. Sigmoid aktivasyon fonksiyonu ikili sınıflandırma problemlerinde başarılı göstermesine karşın, sıfır merkezli olmamasından dolayı optimizasyon sürecini yavaşlatabilmektedir. Eşitlik 2.6'da sunulmuştur. σ simgesi aracılığı ile eğim denetlenebilmektedir. Eşik değeri işlemlerine göre daha kullanışlı çözümler sunmaktadır. Şekil 2.11'de sigmoid aktivasyon fonksiyonu grafiği sunulmuştur (Alemdar, 2023; Balım, 2022; Başarır, 2019; Çınarer, 2021; Gündüz, T., 2023; Kesintaş, 2021; Yıldız, 2021).

$$S(x) = \frac{1}{1+e^{-\sigma x}} \quad (2.6)$$




Şekil 2.11. Sigmoid aktivasyon fonksiyonu grafiği

2.6.3. Tanh Aktivasyon Fonksiyonu

Tanh aktivasyon fonksiyonu diğer bir adıyla hiper tanjant, sigmoid aktivasyon fonksiyonuna benzerlik göstermektedir. Fakat sıfır merkezli olarak çalışmaktadır. Kendisine gelen değerleri -1 ile 1 arasında değerlendirmektedir. Bu işleminden dolayı sigmoid aktivasyon fonksiyonuna göre daha başarılı sonuçlar çıkarmaktadır. Sinir ağı mimarilerinin bir kısmında kullanılmaktadır (Alemdar, 2023; Yıldız, 2021). Tanh aktivasyon fonksiyonu Eşitlik 2.7'de, grafiği Şekil 2.12'de gösterilmiştir. Tanh aktivasyon fonksiyonu pozitif değerlerde pozitif, negatif değerlerde negatif sonuçları döndürmektedir (Kesintaş, 2021).

$$\sigma(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (2.7)$$



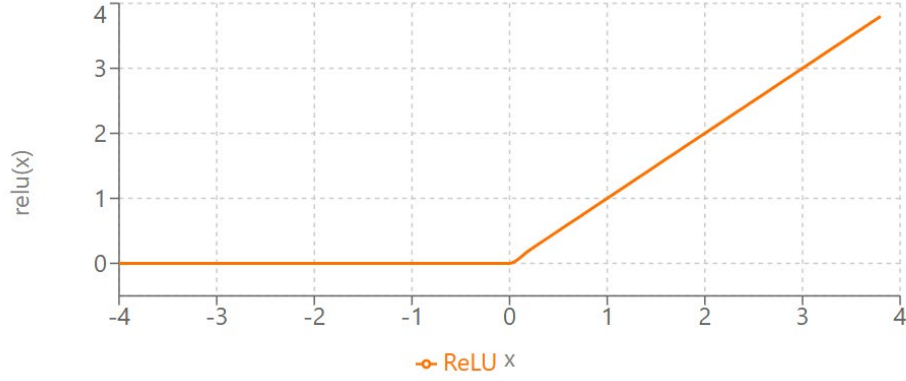
Şekil 2.12. Tanh aktivasyon fonksiyonu grafiği

2.6.4. ReLU Aktivasyon Fonksiyonu

Doğrultulmuş doğrusal birimleri anlamı olan ReLU aktivasyon fonksiyonu parametre değerlerini küçültmek için kullanılmaktadır. Evrişim katmanlarının alıcı kısımlarını etkilemeden, karar verme fonksiyonun doğrusal olmayan niteliklerini yükseltebilmek için ortalama ve maksimum aktivasyon fonksiyonlarını kullanmaktadır (Siddula ve ark., 2016).

ReLU derin öğrenme mimarileri içerisinde en çok kullanılan aktivasyon fonksiyonlarından biri olmaktadır. İnsan beynindeki nöronların birbiri ile etkileşimde bulunabilmesi için gelen sinyallerin belirli bir seviyenin üzerinde olması gerekmektedir. Aksine bir durumda nöronlar bu sinyali görmezden gelmektedir. ReLU bu durumun benzerini kendisine gelen değer negatif ya da pozitif olması durumuna göre taklit etmektedir. Girdi sıfırdan küçük olan bir değerse, sonucu sıfır olarak değerlendirmekte, sıfırdan büyük ise sonucu bu değer olarak vermektedir. ReLU fonksiyonu sıfır değerini aldığı zaman, türev değerinin de sıfır alınması istenen bir durum olmadığından ötürü Leaky ReLU aktivasyon fonksiyonu çözüm olarak geliştirilmiştir. Leaky ReLU negatif alanlarda sıfıra çok yaklaşan değerler alabilmektedir. Tanh ve sigmoid aktivasyon fonksiyonları ile karşılaştırıldığında az maliyetli işlemler içermesi ve yakınsama hızının daha süratli olması fonksiyonu ön plana çıkartmaktadır. ReLU ilk kez 2012 yılında, ImageNet yarışmasında en iyi sonuç veren AlexNet mimarisinde kullanılmıştır. Yarışmada gösterdiği başarıdan sonra popülaritesi giderek artmaya devam etmektedir (Alemdar, 2023; Gu ve ark., 2015; Kesintaş, 2021; Li ve ark., 2022; Piltan, 2022). ReLU aktivasyon fonksiyonu Eşitlik 2.8'de, grafiği Şekil 2.13'te sunulmuştur.

$$F(x) = \max(0, x) \quad (2.8)$$



Şekil 2.13. ReLU aktivasyon fonksiyonu grafiği

2.7. CNN Mimarileri

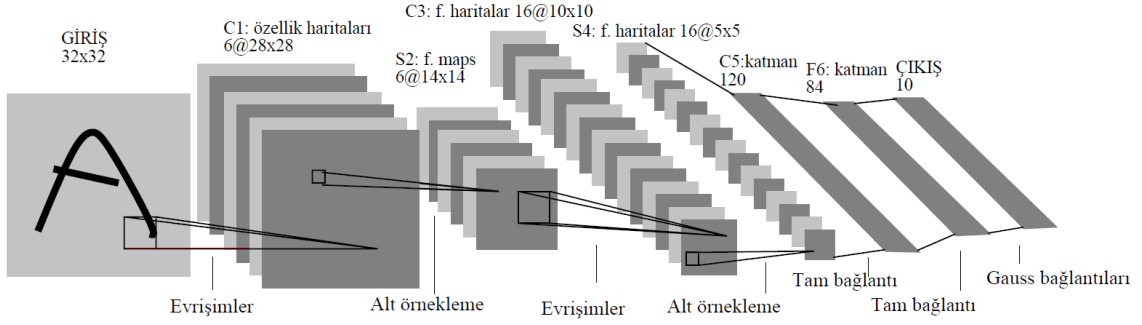
CNN mimarisi kendisine girdi olarak sunulan görüntü verilerini kullanan ve bu verileri birbirinden ayırabilen bir çeşit derin öğrenme algoritmasıdır. CNN mimarisi çoğunlukla görsel verilerin işlenmesinde tercih edilmektedir. Video veya resim türü görsel verilerde, nesne takibi, görüntü sınıflandırma, doğal dil işleme, tıbbi görüntülerin analizi, segmentasyon gibi konularda kullanılmaktadır (Doğan, 2021).

Sıfırdan bir sinir ağı eğitmek yerine, hali hazırda olan bir ağı kullanabilmektedir. 1998-2018 yılları arasında LeNet, AlexNet, GoogLeNet, ResNet gibi çok yaygın mimariler geliştirilmiştir. Bahse konu bu vb. mimariler önceden eğitilmiş olup nesnelere sınıflandırılması için kullanılmaktadır. Eğitimlerini 1000 adet nesne sınıfı barındıran ImageNet veri seti ile tamamlamışlardır. Bu mimariler ile eğitim süreleri kısalmakta, genelleme hatalarına karşı daha direnç kazanılmaktadır (Habib ve Qureshi, 2022; Jabbarli, 2023).

2.7.1. LeNet

LeNet'i, Yann LeCun ve ekip arkadaşları, 1989 yılında ilk CNN mimarisi olarak geliştirmişlerdir (Bilik ve ark., 2024; LeCun ve ark., 1989; Li ve ark., 2022; Yann Lecun, 1989).


1998 yılına geldiklerinde, bu kez makine öğrenimi alanında çalışanların verilerini test ve eğitim için değerlendirdiği MNIST (İyileştirilmiş Ulusal Standartlar ve Teknoloji Enstitüsü) veri tabanında, el yazısı karakterlerini tespit edilebilmek için LeNet-5 mimarisini geliştirmişlerdir. %99,2 sınıflandırma tespit oranı ile ilk başarılı CNN mimarisi olarak kabul edilmektedir. Derin öğrenme alanının "Hello World"u olarak bilinmektedir (Doğan, 2021; Jabbarli, 2023; Lecun ve ark., 1998; Mutludoğan, 2020; Sadi ve Mahani, 2021). LeNet-5 mimarisi Şekil 2.14'te sunulmuştur.



Şekil 2.14. LeNet-5 mimarisi (Lecun ve ark., 1998)

2.7.2. AlexNet

2012 yılında Alex Krizhevsky ve ekibi, kendi tasarladıkları evrişimsel sinir ağı (CNN) ile 1000 adet farklı sınıftan, 1,200,000 tane yüksek kaliteli görüntü içerisinde başarılı tahminlerde bulunarak, LSVRC-2010 yarışmasında birinci olmuşlardır. Sonrandan, AlexNet olarak anılan bu mimari, 650,000 nöron, 60,000,000 parametre değerine sahiptir. Maksimum havuzlama katmanları, 5 adet evrimsel katman, 3 tam bağlı katman ve 1,000 adet yollu softmax'ten oluşmaktadır. AlexNet'in eğitimini çok daha hızlı hale getirebilmek için GPU kullanmışlardır. AlexNet'in yarışmada birinci olmasındaki en büyük etken, dropout (bırakma) adlı bir düzenleme yöntemi kullanılmasıdır. Bu yöntem ile tam bağlantılı katmanlarda bulunan aşırı uyum azaltılmış ve mimarinin genel tahmini yükseltilmiştir (Alsamurai, 2023; Baş, 2023; Cengil, 2021; Chai ve ark., 2021; Kipli ve ark., 2023; Krizhevsky ve ark., 2017; Kulshrestha, 2019; Özkan, 2021; Özkanoglu, 2023; Paneru ve Jeelani, 2021; Zhang ve ark., 2024). AlexNet mimarisi Şekil 2.15'te sunulmuştur.



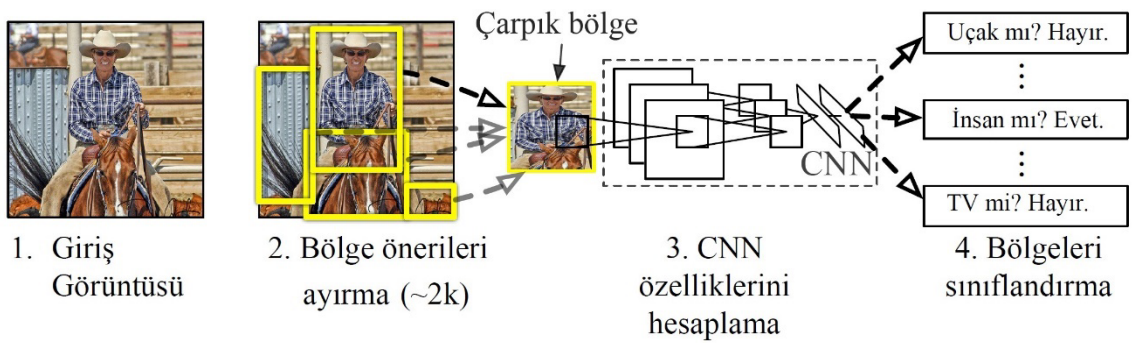
Şekil 2.15 AlexNet mimarisi (Krizhevsky ve ark., 2017)

2.7.3. R-CNN

Girshick ve ark. (2013) görsel nesneleri sınıflandırarak tanıma ve tespit için makine öğrenimi toplulukları için bir standart ölçü haline dönüşen, Pascal Görsel Nesne Sınıfları (PASCAL VOC) yarışmasının, önceki başarılı olan sonuçlarına göre, fark edilebilir bir başarı elde etmişlerdir. Yarışmadaki en iyi sonuçtan %30 daha iyi bir performans ve %53,3'lük mAP değerine ulaşmışlardır. Ayrıca ILSVRC-2013'ün 200'lü veri setinde kullandıkları OverFeat (Aşırı başarı) yöntemiyle de benzeri ölçütleri elde etmişlerdir (Jalil, 2023).

R-CNN temelde iki yaklaşımı bir araya getirmektedir. Birincisi görüntü üzerindeki nesnelere konumlarını bulmak ve segmentlere bölmek için yüksek kapasiteye sahip CNN'ler, ikincisi eğitimde kullanılacak etiketli veri setlerinin kısıtlı olduğu durumlarda, yardımcı olmak üzere denetimli ön eğitim ve sonrasında alana özgü olarak kullanılacak ince ayarlardır. Bu yaklaşımlar sayesinde R-CNN'nin performansı üzerinde önemli bir artış sağlanmıştır. Bölgeler üzerindeki önerilerini CNN mimarileri ile birleştirdikleri için modellerine R-CNN adını vermişlerdir (Cengil, 2021; Çakırgöz, 2022).

R-CNN'nin bu yaklaşımının bazı dezavantajları bulunmaktadır. Her bir görüntü için seçici arama yaklaşık 2000 adet bölgenin öz niteliğini çıkartabilmek için CNN'den geçirerek sınıflandırması gerekmektedir. Bu durum ağır eğitimi ve testi için zaman açısından hesaplama maliyetli oluşturmaktadır ve modelin çalışmasını yavaşlatmaktadır. R-CNN seçici arama algoritmasının sabit bir yapıda olmasından ötürü bu süreçte herhangi bir öğrenme gerçekleşmemektedir. Bu durumda da kötü ilgi bölgesi sonuçlarının türemesine sebep olabilmektedir (Abdulghani, 2021; Kong ve ark., 2022; Sorgun, 2022; Xiao ve ark., 2020; Yadav ve ark., 2023). Şekil 2.16'de R-CNN mimarisi gösterilmektedir.



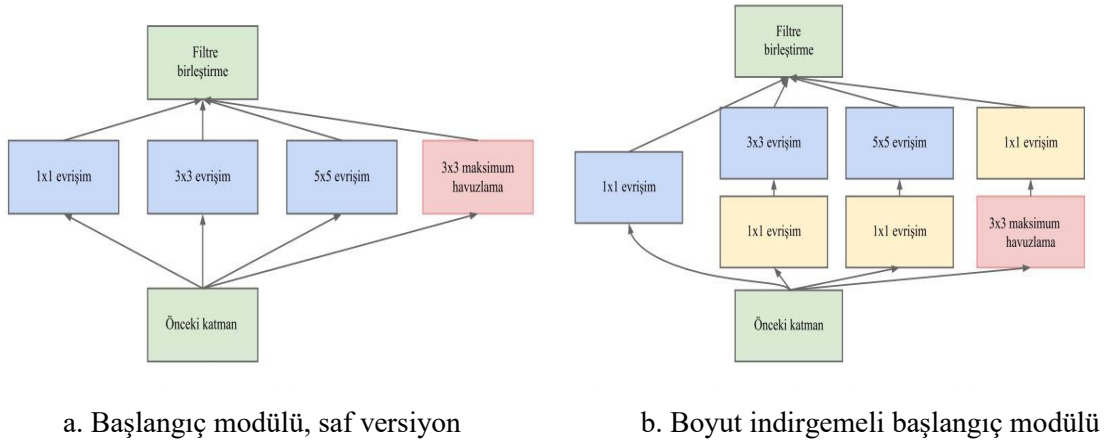
Şekil 2.16. R-CNN mimarisi (Girshick ve ark., 2013)

2.7.4. GoogLeNet

2014 yılında Google çalışanları, LeNet 5 mimarisinin öncülüğünü yapan Yann LeCun'a duydukları saygıya ithafen GoogLeNet mimarisine ismini vermişlerdir. GoogLeNet çalışanları artık

sadece güçlü donanım, büyük veri kümeleri ve büyük modellerle değil, yeni fikirler, gelişmiş ağ mimarileri ve algoritmalarla da ilerlemenin mümkün olabileceğini belirtmişlerdir. ILSVRC 2014 yarışmasında GoogLeNet mimarisi birinci olmuştur. Üstelik bu başarılarını ILSVRC 2012 yarışmasının birincisi AlexNet'ten 12 kat daha az parametre kullanarak ve yüksek doğruluk oranı ile yapmışlardır. GoogLeNet mimarisinin bu başarı performansını yakalayabilmesi, ağının içerisindeki bilgi işlem kaynaklarını iyi bir şekilde kullanabilmesi ile mümkün olmuştur. Bu sayede hesaplama maliyetini sabit tutarak yapay sinir ağının genişliğini ve derinliği arttırabilmişlerdir. Kalite optimizasyonu açısından mimariyi tasarlama kararlarında, beraber ateşlenen nöronların birbirine bağlanması (Hebb eorisi) ve çok ölçekli işleme sezgisi, yaklaşımından faydalanmışlardır. GoogLeNet, 22 katmandan oluşan bir yapı ile teşkil edilmiştir (Jabbarli, 2023; Szegedy ve ark., 2014).

GoogLeNet mimarisinin ayırt edici özelliği Başlangıç (Inception) modülü ile sağlanmıştır. 5x5, 3x3, 1x1 gibi farklı boyutlarda oluşturulan evrişim filtreleri ile maksimum havuzlama işlemlerini paralel olacak şekilde uygulayarak, farklı ölçeğe sahip görüntülerin özelliklerini bir anda çıkartabilecek yapı oluşturulmuştur. Böylece GoogLeNet daha geniş bir genelleme ile öğrenbilme ve isabetli tespitler yapabilmektedir. Başlangıç modülü modelin hesaplama maliyetini düşürmesinin yanında derinliğini arttırarak mimariler arasında ön plana çıkmaktadır (Chai ve ark., 2021; Jabbarli, 2023; Özkan, 2021; Serttaş, 2021; Szegedy ve ark., 2014; Yılmaz, 2021). Şekil 2.17a.'da saf (naive) versiyonu, Şekil 2.17b.'de boyut indirgemeli başlangıç modülü sunulmuştur.

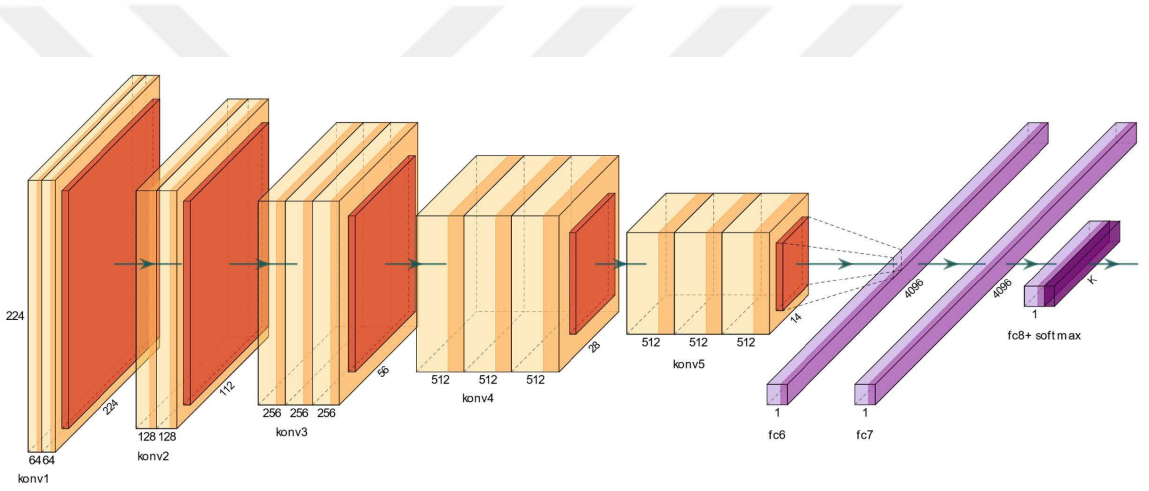


Şekil 2.17. GoogLeNet Başlangıç modülü (Szegedy ve ark., 2014)

2.7.5. VGGNet

ImageNet 2014 yarışması ile Görsel Geometri Grubu Ağı (VGGNet) mimarisi tanıtılmıştır. Oxford Üniversitesi bünyesinde bulunan araştırmacılar, VGGNet'e gruplarının baş harflerini vererek bu isimle anılmasını sağlamışlardır (Irene ve ark., 2024; Jabbarli, 2023).

VGGNet geliştirirlerken, geniş ölçekli görüntü tanımayı sağlamada, evrişimli ağ derinliğinin etkisini göstermişlerdir. 3x3 gibi çok küçük evrişim filtresine sahip mimariyi kullanılarak, fazlalaşan derinliklerdeki ağların detaylı bir araştırmasını yapmışlardır. Bu araştırma ile derinliğin 16-19 katmana arttırılsa bile önceki çözümlere nazaran önemli bir gelişme sağlanabileceğini göstermişlerdir. VGGNet'i geliştiren grup, 2014 ImageNet yarışmasında %7,3'lük hata payı ile başarılı bir performans göstererek, lokalizasyonda birinci, sınıflandırma kategorisinde ikinci olmuşlardır. Ayrıca VGGNet'in diğer veri setlerinde de, genel tahminlerinin iyi sonuçlar aldığını belirtmişlerdir (Simonyan ve Zisserman, 2014). VGGNet mimarisi Şekil 2.18'de sunulmuştur.




Şekil 2.18. VGGNet mimarisi (Hendaoui, 2022)

2.7.6. U-Net

U-Net mimarisi ilk başta biyomedikal görüntüler üzerinde segmentasyon çalışmaları için tasarlanmıştır. Fakat mimarinin diğer uygulamalar içinde benzeri başarılı sağlaması yaygın kullanımını tetiklemiştir (Ali ve ark., 2022).

U-Net, geniş bir eğitim veri setine ihtiyaç duymaksızın, hassas segmentasyonlar üretebilmektedir. U-Net'in kodlayıcı bölümü, giriş görüntülerinin sahip olduğu, semantik bilgileri öğrenebilmek için maksimum havuzlama ve evrişim katmanından oluşmaktadır. U-Net kod çözücü kısmı ise havuzlama katmanı yerine yukarı örnekleme operatörlerini kullanarak, evrişim katmanı ile beraber öznetelik haritasının uzamsal çözünürlüklerini artırma yönünde çalışmaktadır. Bu sayede son katmanda, girişte uygulanan görüntü ile aynı boyutta görüntü üretilmektedir. Mimarinin Yukarı ve aşağı örnekleme yolları birbirleri ile simetrik bir dizilimdedir ve bağlandıklarında "U"

harfi benzeri bir görüntü oluşturmaktadır. Mimari bu nedenle U-Net olarak isimlendirilmiştir (Ali ve ark., 2022; Alsamurai, 2023; LakshmiPriya ve ark., 2023; Sharma ve ark., 2024). U-Net mimarisi Şekil 2.19’da sunulmuştur.



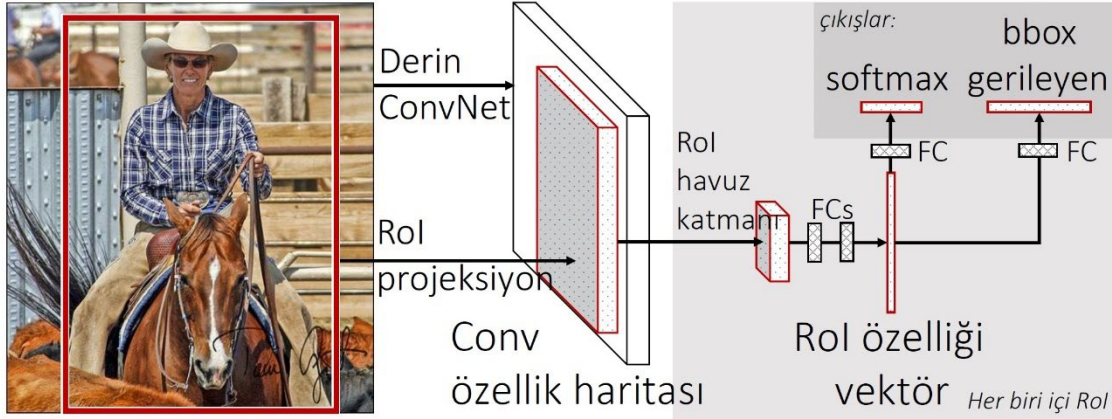
Şekil 2.19. U-Net mimarisi (Ronneberger ve ark., 2015)

2.7.7. Fast R-CNN

Hızlı Bölgesel Tabanlı Evrişimli Sinir Ağları (Fast R-CNN), R-CNN'nin gerçek zamanlı nesne tespiti için yavaş kalmasından ötürü aynı geliştirici tarafından tasarlanmıştır. Nesne tanımadaki hızını arttırmak için Fast R-CNN, giriş görüntülerini bölgeler halinde işlemek yerine, bir bütün olarak CNN'e göndermektedir. Tek parça halinde sinir ağında bulunan görüntü verisinden, evrişim katmanlarınca işlenmesi sonucu, bir özellik haritası elde edilmektedir. Bu özellik haritaları maksimum havuzlama katmanına iletilerek boyutları küçültülmektedir (Alemdar, 2023; Girshick, 2015; Serttaş, 2021).

Fast R-CNN de İlgi Bölgesi (RoI) ifadesi maksimum havuzlama katmanı temsil etmektedir. Mimari tarafından oluşturulan özellik haritaları vektör durumunda tek düzen şekline getirilmektedir. RoI özellik vektöründen öneri olarak sunulan bölgenin sınırlayıcı kutularını (bounding box) ve sınıfını bulmak için softmax katmanlarını kullanmaktadır. Fast R-CNN sınıflandırma yapabilmek için doğrusal Destek Vektör Makineleri (SVM) kullanmak yerine, doğruluğunu arttırmak için yine softmax'i tercih etmektedir. Test aşamasında R-CNN'ye göre 45 kat, eğitim sürecinde 9 kat daha

hızlı hesaplama yaparak, çıktı vermektedir. Test sürecinde bölge önerisinde bulunmak için çok zaman harcaması ve gerçek piksel değerini verememesi dezavantajı olarak değerlendirilmektedir (Alemdar, 2023; Gengeç, 2020; Girshick, 2015; Li, Z. ve ark., 2024; Serttaş, 2021). Fast R-CNN mimarisi Şekil 2.20’de sunulmuştur.



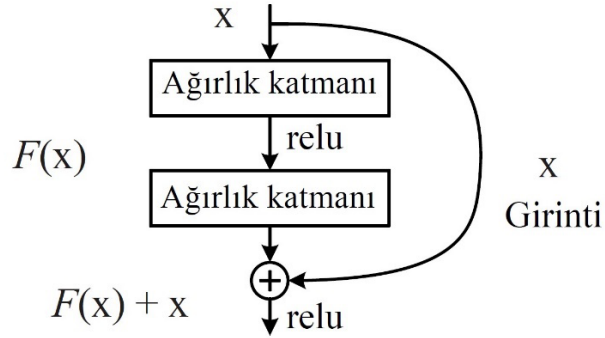
Şekil 2.20. Fast R-CNN mimarisi (Girshick, 2015)

2.7.8. ResNet

ResNet (Residual Net-Artık Ağ), % 3,57 gibi çok küçük bir hata payı ve hızı ile 2015 yılı ILSVRC yarışmasında birinci olmuş ve literatürde farklı versiyonları ile geniş bir yer edinmiştir. Yapay sinir ağlarının derinliği fazlalaştıkça geriye yayımlı eğitim sürecinde, aktivasyon fonksiyonlarının devreye girmesi ve üretmiş olduğu değerlerin sifıra yaklaşması bu kez mimariyi derinlikten uzaklaştırmaktadır. ResNet mimarisi bu problemi, iki katman öncesi bulunan aktivasyon katmanın çıktısını, iki katman sonra gelen aktivasyon katmanı girişine ekleyerek çözüme kavuşturmuş böylece 152 katmanlı bir yapıya kavuşarak zamanın en derin ağ yapısına sahip olmuştur (Doğan, 2021; He ve ark., 2015; Leontaris ve ark., 2023; Yılmaz, 2021).

Geriye yayılım ile öğrenme sürecindeki bir başka sorun, sinir ağında geriye doğru gittikçe gradyanların küçülmeye ya da yok olmaya meyilli olmasıdır. Bu durum önceki katmanlarda bulunan nöronların, sonraki katmanlarda bulunan nöronlara oranla çok daha yavaş öğrenebileceği anlamı taşımaktadır. Ağdaki ilk katmanların fonksiyonu basit görüntüleri algılamak ve öğrenmektir. Bahse konu bu katmanların öğrenme hızı yavaşladığında ve temel görüntüler doğru olarak tespit edilemediği anlarda ağın genel başarısı düşmektedir. ResNet bu problem için atlama bağlantısı kullanmıştır. Bağlantıları ağ yapısına eklemek içinde artık (residual) blokları kullanmaktadır. Birkaç blokta bir önceki blokların aktivasyon çıktısı, mevcut olan bloğun aktivasyon girdisine eklenmektedir. Bu yöntemle ağdaki gradyanların süreç içerisinde kaybolmasının önüne

geçilebilmektedir. Yapay sinir ağı yapısına katman eklenmesi, kendinden sonra gelen katmanın öğrenme hızını arttırabilmekte dolayısıyla ağıın karmaşık fonksiyonlarının da öğrenmesini ve doğru tahminlerde bulunabilmesini sağlamaktadır (Mutludoğan, 2020).




Şekil 2.21. ResNet artık yapısı (He ve ark., 2015)

2.7.9. Faster R-CNN

Fast R-CNN'nin hız parametreleri ve hassasiyetinin geliştirilmesine binaen, Daha Hızlı Bölgesel Tabanlı Evrişimli Sinir Ağları (Faster R-CNN) mimarisi 2016 yılında tanıtılmıştır (Jalil, 2023).

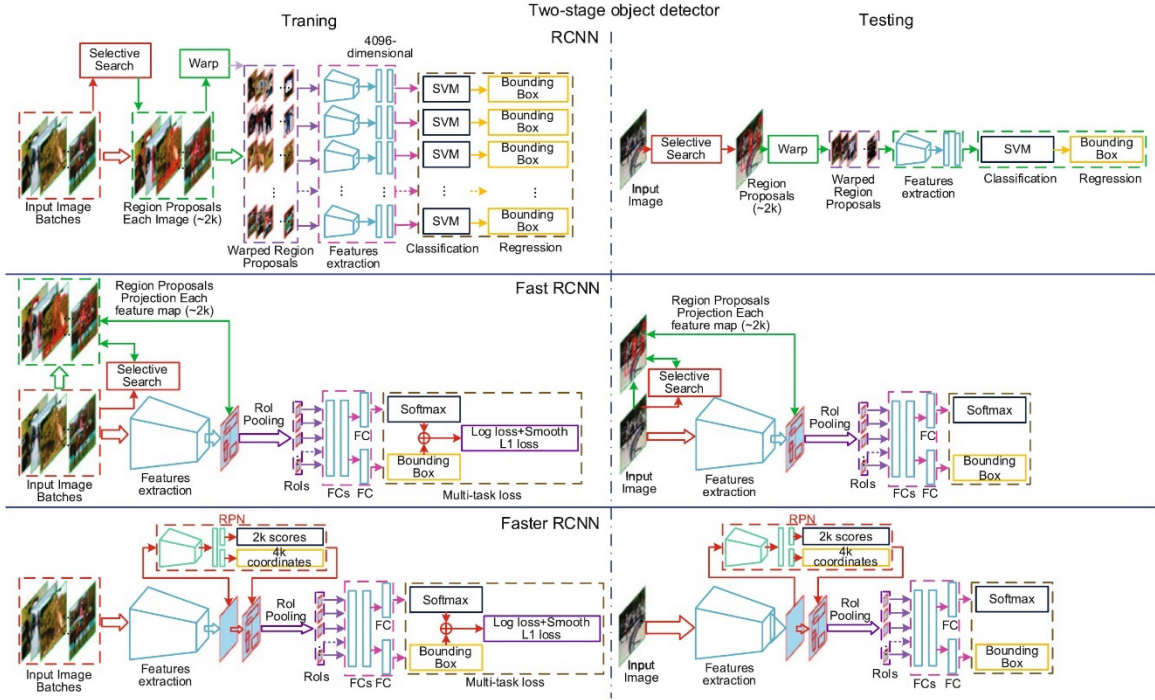
Faster R-CNN de görüntü verileri öncelikli olarak CNN katmanına gönderilmekte ve burada veri üzerindeki özellik haritalarının çıkarılabilmesi için gerekli olan filtreleme işlemi yapılmaktadır. Filtrelenen görselin varyasyonları, nesne içeren bölgelerin koordinatlarının tahmin edilebilmesi için Bölge Öneri Ağı (RPN) katmanına iletilmekte ve öğrenme işlemine tabi tutulmaktadır. RPN katmanında nesne içeren bölgelerin koordinatları hesaplanıp çerçvelendikten sonra RoI havuzlama katmanına gönderilmektedir. RoI havuzlama katmanında veri sabit bir boyutta tutularak, nesne tespit katmanına verilir, çerçvelenmiş görüntünün hangi nesneye ait olduğu tahminlenmektedir (Ahmed ve ark., 2024; Alemdar, 2023; Baş, 2023; Ouf, 2023; Rao ve ark., 2022; Ren ve ark., 2017). Faster R-CNN mimarisi Şekil 2.22'de gösterilmiştir.



Şekil 2.22. Faster R-CNN mimarisi (Ren ve ark., 2017)

R-CNN seçici arama algoritması kullanarak her bir nesne için koordinat tespiti yapmakta ve her bir nesneyi ayrı ayrı olacak şekilde CNN ağına göndererek tahmin yapmaktadır. Fast R-CNN de görsel ilk önce CNN ağında filtrelemeye tabi tutulup, seçici arama algoritmasını aracılığıyla, nesnelerin koordinatları belirlenmekte ve tespit katmanında tahminlenmektedir. Fast R-CNN, her nesneyi CNN'den geçirmediği için R-CNN göre daha hızlı çalışmaktadır. Faster R-CNN mimarisinde ise seçici arama algoritmasının modelden çıkartılması ve yerini RPN katmanının eklenmesi ile tespit işlemi her iki mimariye göre çok daha hızlı olabilmektedir (Baş, 2023).

R-CNN, Fast R-CNN ve Faster R-CNN mimarilerinin karşılaştırılması Şekil 2.23'te sunulmuştur.



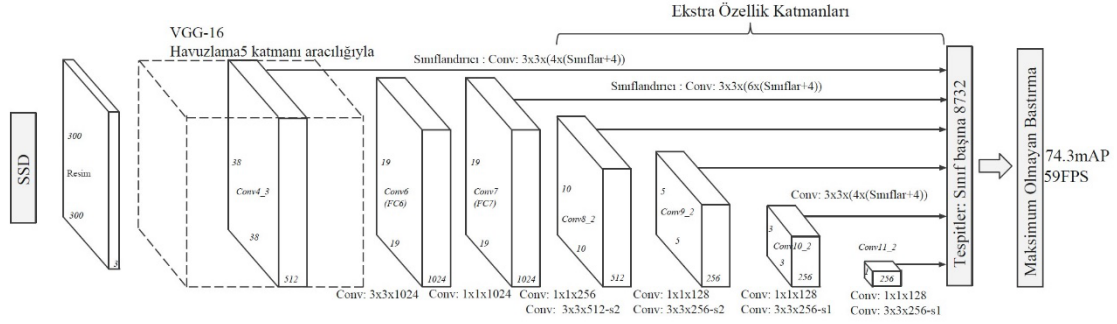
Şekil 2.23. R-CNN, Fast R-CNN ve Faster R-CNN mimarilerinin karşılaştırılması
(Xiao ve ark., 2020)

2.7.10. SSD

SSD tek seferde tüm görevleri yerine getirebilmek ve nesnelere bulabilmek için tasarlanmıştır. SSD'nin son katmanlarında tam bağlı katman kullanılmamaktadır. Tam bağlı katmanların yerine Maksimum Olmayanların Bastırılması (NMS) adıyla bilinen netleştirme ve yorumlama algoritması ve Kesişimlerin Birleşimlere Oranı kullanılmaktadır (IoU). SSD görüntü verisinin özelliğini yitirmeden küçülterek, en az filtre yardımıyla nesnelere tespit edebilmektedir. SSD kolay bir şekilde eğitilebilmekte ve nesne tespitinin ihtiyaç duyulduğu alanlara entegrasyonu basitçe sağlanabilmektedir (Başarır, 2019; Devagiri ve ark., 2022).

SSD VOC2007 veri setinde %76,8 mAP, VOC2012 veri setinde %74,9 mAP değerine ulaşmıştır. SSD'nin önceki dedektörden farkı; testlerini daha derin katmanlarda yaparken, diğer tek aşamalı dedektörler, ağır değişik ölçekteki farklı katmanlarında test işlemini gerçekleştirmektedirler (Sharma ve Mir, 2020).

SSD nesne tanımasını genelleştirebilmekte ve 1 saniyenin altında tespit yapabilmektedir. Görüntü verisi üzerinde belirgin olan özellik çıkarımını kolaylıkla yapabilmekte fakat belirgin olmayanlarda doğruluk oranı düşük kalabilmektedir (Serttaş, 2021). Şekil 2.24'te SSD mimarisi sunulmuştur.



Şekil 2.24. SSD mimarisi (Liu ve ark., 2016)

2.8. Nesne Tespiti

Bilgisayarlı görü teknikleri günümüzde neredeyse her alanda kendini göstermektedir. Akıllı cep telefonlarımızda bulunan kameralarının yüz algılama yeteneği, tıp alanında cilt lezyonlarının sınıflandırılması ve tespiti, kanser hücrelerini bulmak için bilgisayarlı tomografi (CT) veya pozitron emisyon tomografisi (PET), taşımacılık sektöründe hız tahmini, üretimde kusurlu ürünlerin algılanması, sürücüsüz otomobillerin otonom sürüşü esnasında karar verebilmesi için eş zamanlı konum belirleyerek haritalandırma yapması ve nesne tanınması gibi farklı bilgisayarlı görü tabanlı teknikler, yaygın örnekler arasında sayılabilmektedir (Cao ve ark., 2021; Kwon ve Cho, 2020; Li, Z. ve ark., 2024; Paneru ve Jeelani, 2021).

Nesne tespitinin yapılabilmesi için dijital görüntülerin işlenmesi, bu alanın temelini teşkil etmekte ve uzunca bir süredir üzerinde durulmaktadır. Bu uzun zaman zarfında birçok yöntem ve farklı algoritmalar geliştirilmiştir. Dijital görüntüler içerisinde nesne tespitini etkin bir şekilde bulan ilk algoritma Viola-Jones algoritması olmuştur. Paul Viola ve Michael Jones geliştirdikleri bu algoritmaya soyadlarını vererek 2001 yılında tanıtmışlardır (Aksoy, 2022; Chen ve ark., 2022; Güzel, 2022; Serttaş, 2021; Viola ve Jones, 2001; Zhou, 2024).

Viola-Jones algoritması, herhangi bir görüntü içerisindeki belirgin yapıların ya da şekillerin, yoğunluk farklarını bulmak için Haar Filtresini kullanmaktadır. Viola-Jones ayrıca yüz tanımda kullanılabilen, ilk nesne tespit algoritması olmuştur (Azadvatan, 2023; Bilik ve ark., 2024; Li, Z. ve ark., 2024).

Dijital görüntü işleme, videolardan ve resimsel görüntülerden alınan kesitler aracılığıyla, nesnelerin anlamlandırılması ve tanımlanması konusuna yoğunlaşan, bir yazılım birimidir. Görüntü işleme tekniklerinin asıl amacı yapay zekanın alt yapısına dayanan makine öğrenimi ve derin öğrenme mimarileri ile insana özgü yetenekleri taklit edebilen ve kendi kendine öğrenebilen sistemler geliştirmektir (Güler, 2022).

Görüntü işleme, görüntülere ait sinyallerin pikseller aracılığıyla ifade edilebilmesidir. İlk çağlarda yaşanan anıları betimlemek için mağara duvarları insanlar tarafından resimlerle donatılarak gelecek nesillere yaşanan dönem aktarılmaya çalışılmıştır. Fotoğrafın icadına kadar her

bilimsel gelişmede olduğu gibi farklı evrelerden geçmiştir. Matematikçi ve kimyager Talbot, negatif-pozitif tekniği ile kâğıt üzerinde fotoğraf elde ederek 1841’de patent almıştır. Fotoğrafın icat edilmesinden 1849 yılına kadar, ilkel fotoğraf makinesi olarak değerlendirebileceğimiz Daguerretypler büyük ilgi görmüş ve satış rakamı yüzbinlere yaklaşmıştır (Gök, 2016; Yıldız, 2021).

Russell Kirsch 1957 yılında ekip arkadaşları ile bebeğine ait 176x176 piksel, 5x5 cm ebatlarında olan ilk dijital fotoğrafı oluşturmuşlardır. 1963 yılında Larry Roberts, 2 boyutlu görüntülerin perspektiflerinden faydalanarak 3 boyutlu tanımlarını oluşturduğu doktora tezini yayımlamıştır. Larry Roberts bu alana yapmış olduğu katkılardan dolayı bilgisayarlı görünümün babası olarak düşünülmüştür. 1966’da Seymour Papert tarafından gerçek görüntülerde segmentasyon ve örüntü tanıma kavramı ortaya atılmış, böylece bilgisayarlı görünümün ilk çalışmalarından biri olarak kabul edilmiştir. Max Clowes ve David Huffman 1971’de birbirlerinden bağımsız çalışarak, çizgi etiketlemede kullanılan algoritmalarını yayımlamışlardır. 1974 yılında Kurzweil Bilgisayar Ürünleri şirketi Optik Karakter Tanıma (OCR) programı sayesinde, basılı olan metinlerin dijital ortama aktarılmasını başarmışlardır. İlk dijital fotoğraf makinesi 1975’te Steven Sasson tarafından icat edilmiştir (Baş, 2023; Yıldız, 2021).

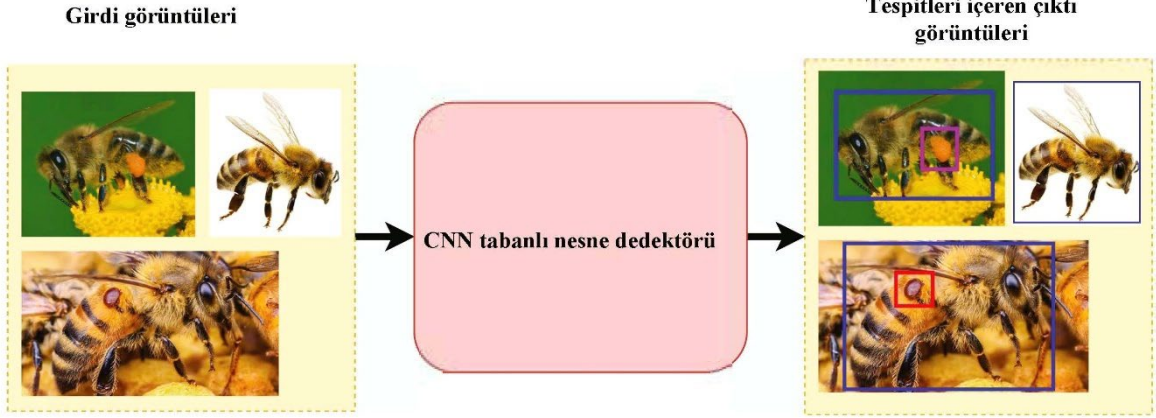
Derin öğrenme kendisine girdi olarak sunulan görüntü verilerinden, yapısında bulunan çok katmanlı sinir ağları aracılığıyla, öz niteliklerini sınıflandırabilmektedir. Piksellerden meydana gelen dijital görüntülerin, bilgisayarlarca anlamlandırılması ve veri setlerinin bir nesne ile uyuşması çok kompleks işlemler olarak görülmektedir. Derin öğrenme bu karmaşıklığı süreçlere bölerek kolaylıkla yapılabilir hale dönüştürmektedir (Türk, 2021).

Bilgisayar ekranlarında gözlerimiz ile gördüğümüz görüntüleri, bilgisayarlar kendine has olan özellikleri ile algılamaktadırlar. Bilgisayar ekranları piksellerden oluşmakta ve her bir piksele karşılık gelen renk, bilgisayarlar tarafından sayısal değer olarak kabul görmekte ve işlenmektedir. Görüntülerin boyutlarını 1920x1080 olarak ifade edildiğinde, görüntünün yüksekliği ve genişliğindeki piksel sayısını belirtmektedir. Bu boyutta bir görüntüde 2,073,600 adet piksel bulunduğu anlaşılmaktadır. Bilgisayarlı görü topluluklarının derin öğrenme ve makine öğrenmesi çalışmalarında kullandıkları MNIST veri setinde, 784 pikselden oluşan 28x28 boyutunda görüntüler bulunmaktadır. Veri setinde bulunan görüntülere ait her bir piksel, siyah ve beyaz arasında oluşan gri tonlarının parlaklığına göre 0-255 arasında değişen sayılarla ifade edilmektedir. MNIST veri setindeki 7 rakamı görüntüsünün, piksellerdeki sayı karşılıkları Şekil 2.25’te sunulmuştur. Görüntülere ait piksellere karşılık gelen sayılar, vektör ve matrislere çevrilerek işlem görmekte, böylece derin öğrenme ve makine öğrenmesinin temelini oluşturan sayısal hesaplamaların yegâne kaynağı olmaktadır (Güçlütürk, 2021; Lejeune, 2020).

	0	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	27					
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0					
1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0				
2	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0				
3	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0				
4	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0				
5	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0				
6	0	0	0	0	0	0	0	0	0	0	0	0	0	13	18	18	18	134	150	255	169	37	0	0	0	0	0	0	0				
7	0	0	0	0	0	5	92	36	36	140	154	154	154	224	253	253	253	253	253	253	253	253	170	0	0	0	0	0	0				
8	0	0	0	0	0	38	253	253	253	253	253	253	253	253	253	253	253	253	253	253	253	253	145	0	0	0	0	0	0				
9	0	0	0	0	0	9	144	202	253	223	182	182	182	182	182	138	65	161	253	253	235	38	0	0	0	0	0	0	0				
10	0	0	0	0	0	0	13	47	27	0	0	0	0	0	0	0	130	253	253	147	0	0	0	0	0	0	0	0	0				
11	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	235	253	253	70	0	0	0	0	0	0	0	0	0				
12	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	166	253	253	230	36	0	0	0	0	0	0	0	0	0				
13	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	54	243	253	251	131	0	0	0	0	0	0	0	0	0	0			
14	0	0	0	0	0	0	0	0	0	0	0	0	0	0	13	178	253	253	224	0	0	0	0	0	0	0	0	0	0	0			
15	0	0	0	0	0	0	0	0	0	0	0	0	0	0	78	253	253	253	141	0	0	0	0	0	0	0	0	0	0	0			
16	0	0	0	0	0	0	0	0	0	0	0	0	0	0	168	253	253	208	25	0	0	0	0	0	0	0	0	0	0	0			
17	0	0	0	0	0	0	0	0	0	0	0	0	0	95	244	253	253	124	0	0	0	0	0	0	0	0	0	0	0	0			
18	0	0	0	0	0	0	0	0	0	0	0	0	0	177	253	253	203	14	0	0	0	0	0	0	0	0	0	0	0	0			
19	0	0	0	0	0	0	0	0	0	0	2	107	252	253	253	81	0	0	0	0	0	0	0	0	0	0	0	0	0	0			
20	0	0	0	0	0	0	0	0	0	0	38	253	253	253	253	92	0	0	0	0	0	0	0	0	0	0	0	0	0	0			
21	0	0	0	0	0	0	0	0	0	0	24	183	253	253	253	238	60	0	0	0	0	0	0	0	0	0	0	0	0	0	0		
22	0	0	0	0	0	0	0	0	0	0	125	253	253	253	233	63	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0		
23	0	0	0	0	0	0	0	0	0	0	218	253	253	253	137	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0		
24	0	0	0	0	0	0	0	0	0	0	243	253	253	101	8	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0		
25	0	0	0	0	0	0	0	0	0	0	187	253	234	41	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0		
26	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	
27	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0

Şekil 2.25. MNIST veri setindeki 7 rakamı görüntüsünün, piksellerdeki sayı karşılıkları (Güçlütürk, 2021)

CNN mimarileri sınıflandırma işlemi yapmasının yanında, aynı zamanda gerçek yaşam şartlarında nesne tespitinde kullanılmaktadır. CNN, istenilen nesnenin öz niteliklerini otomatik olarak genelleştirmekte ve nesneyi görüntü arka planından ayırt edebilmektedir. 2010'lu yıllardan itibaren, derin öğrenme tekniklerinin gelişmesiyle birlikte YOLO, R-CNN ve SSD gibi çığır açan CNN alt yapılı nesne dedektörleri meydana gelmiştir. Örnek gösterim Şekil 2.26'da sunulmuştur.



Şekil 2.26. Nesne tespit dedektörü örneği (Bilik ve ark., 2024)

Nesne tespit dedektörleri, çapa kutuları (anchor boxes) ve ızgaralar (grid) ile zenginleşen CNN sınıflandırıcıları ile bir bütünlük kazanmaktadır. Çapa kutuları hiper parametre olarak görev yaparak bir görüntü üzerinde birden fazla nesneyi bulabilmeyi mümkün kılmaktadır. Evrişim katmanından iletilen özellik görüntüsü, ızgaralara bölünmekte ve her ızgara hücrelerinde çapa kutuları aranmaktadır. Güven eşiği için belirlenen değer aşırsa, aşan kutu bir algılama olarak döndürülmektedir (Bilik ve ark., 2024; Tang ve Qian, 2024).

2.9. YOLO

Nesne tespitinde derin öğrenmenin görüntüler üzerindeki göstermiş olduğu başarı, insanın görerek algıladığı ve tahmin ettiği birçok sektörde çığır açıcı etkilere neden olmaktadır. Bu alanda uğraşan ana akım, derin öğrenme tabanlı nesne algılama algoritmalarını tek aşamalı ve iki aşamalı dedektörler olarak ikiye ana bölüme ayırmaktadır (Azevedo ve Santos, 2024; Dai ve ark., 2022; Dang ve ark., 2023; Duan ve ark., 2024; Kim ve ark., 2023; Kong ve ark., 2022; Lee ve ark., 2023; Li ve ark., 2022; Sharma ve Mir, 2020; Yadav ve ark., 2023).

Bir görüntü içerisinde bulunan nesnelerin, sınıflandırılmasını ve konumunu tek bir süreçten geçirerek tespitte bulanabilen, derin öğrenme tabanlı algoritmalara, tek aşamalı dedektör denilmektedir. Bu pratik yönü ile iki aşamalı dedektörlerden daha hızlı ve kolay bir surette netice alabilmektedir (Chen ve ark., 2022; Elgendy ve ark., 2021). Tek aşamalı dedektörler arasında en çok tercih edilen 2015 yılında Redmon'nun tanıttığı gerçek zamanlı tespitler yapabilen YOLO algoritmasıdır (Alruwaili ve ark., 2024; Cao, S. ve ark., 2023; Cao, Y. ve ark., 2023; Dai, 2022; Han, G. ve ark., 2021; Irene ve ark., 2024; P. Jin ve ark., 2024; Sağın, 2019; Yasir ve ark., 2024).


İki aşamalı dedektörler çoğunlukla doğruluğun ön plana çıktığı ve işlem yapma hızının kritik olmadığı durumlarda tercih edilmektedir. Genellikle karmaşık ve küçük boyutlu görüntüler

içerisindeki nesnelere tespit amacıyla kullanılmaktadır. Doğru tespit açısından tek aşamalı dedektörlere göre başarılı olsa da gerçek zamanlı kullanımlarda yavaş kalmaktadır (Elgendy ve ark., 2021; Gao ve ark., 2024; Kong ve ark., 2022; Liu, Fang ve ark., 2022; Yadav ve ark., 2023).

2013 yılında Girshick'in R-CNN'i tanıtmaya ve sonraki gelişmiş türevleri Fast R-CNN, Faster R-CNN gibi algoritmaların, nesne tespitinde doğruluk bakımından büyük başarılar elde etmesiyle iki aşamalı dedektörler etkisini sürdürmektedir (Girshick ve ark., 2013; Li ve ark., 2018; Ouf, 2023; Ren ve ark., 2017).

YOLO nesne tespitinde R-CNN gibi sınıflandırıcıları, tekrar kullanmak yerine tek seferli işlemle süreci tamamlamaktadır. YOLO, R-CNN'ye göre 6 kat daha hızlıdır ve nesnelere kolay bir şekilde genelleştirebilmektedir. Herhangi bir görüntüyü 0,0222 sn içerisinde işleyebildiği için video akışı içerisindeki görüntüleri rahatlıkla tespit edebilmektedir (Amin ve Ahn, 2021; Kim ve ark., 2023; Robertson, 2020; Wang, X. ve ark., 2023).

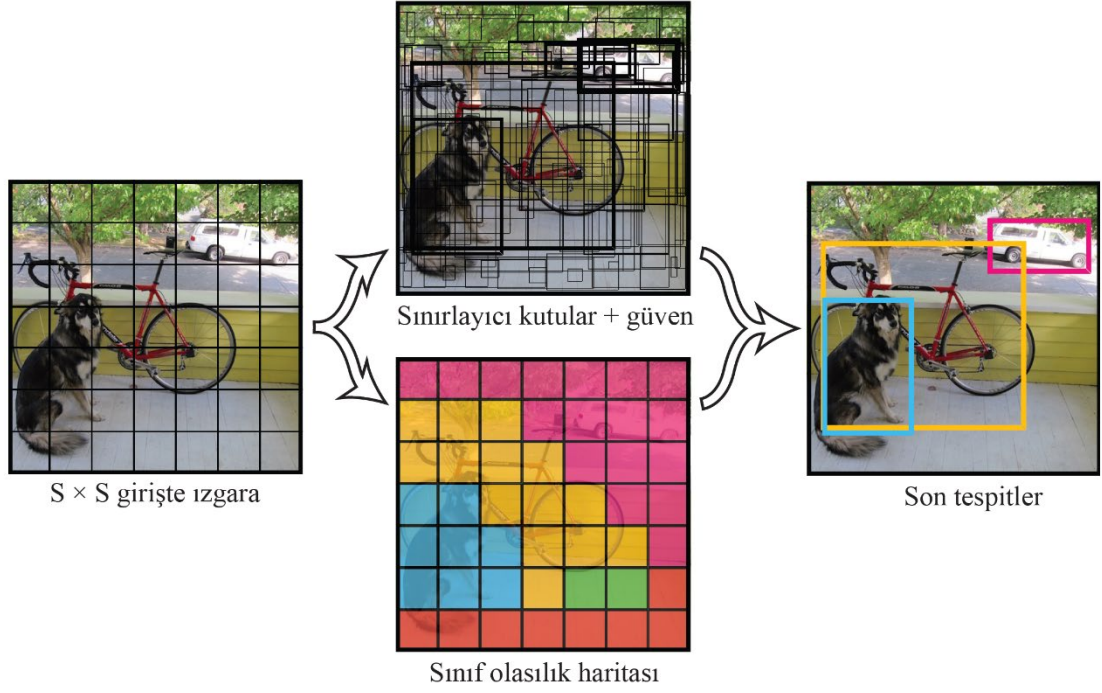
YOLO ailesinin ilki olan YOLOv1 mimarisi, tespit aşısında 24 tane evrişim katmanı ve katmanları takip eden 2 adet tam bağlantı katmanından oluşmaktadır. Dönüşümlü 1x1 katmanlar, kendinden önceki katmanlardan gelen özellik kapasitesini azaltmaktadır. YOLOv1 mimarisini ön eğitim için ImageNet üzerinden, katmanlara gelen sınıflandırma görüntüleri 224x224 yarı çözünürlükte iletilmekte, müteakiben çözünürlük algılama yapabilmesi için iki katına çıkarılmaktadır (Redmon ve ark., 2015). YOLOv1 mimarisi Şekil 2.27'de sunulmuştur.



Şekil 2.27. YOLOv1 mimarisi (Redmon ve ark., 2015)

YOLO geliştiricileri, görüntüyü soldan sağa taramak ya da nesnenin görüntü üzerindeki piksel değerlerine işlem yapmak yerine, görüntü içerisindeki tüm nesnelere hakkında mimarinin genel bir karar vermesi kararlaşdırmışlardır. YOLO mimarisi bir adet CNN ağı üzerinden, sınırlayıcı kutuları ve kutuların içerisinde yer alan sınıf olasılıklarını tahmin edebilmektedir. Bu süreçte görüntü

$S \times S$ boyutlarda parçalara bölünmekte ve oluşan her parça için n adet sınırlayıcı kutu oluşturulmaktadır. (Ali, 2024; Han, X. ve ark., 2021; Karimov, 2023; Kaya, 2018; Suliman, 2023; Wu, 2023; Yancı, 2019; Yılmaz, 2021). YOLOv1 algılama modeli Şekil 2.28’de gösterilmiştir.



Şekil 2.28. YOLOv1 algılama modeli (Redmon ve ark., 2015)

3. MATERYAL VE METOT

Bu bölümde, iş sağlığı ve güvenliği açısından inşaat alanlarında kullanılması kritik ve zorunlu olan baret, yelek, kulaklık ve eldivenin gerçek zamanlı tespitlerine yönelik, yapay zeka tabanlı model önerilmesi hedeflenmiştir.

Nesne tespiti alanında son 10 yıllık dönem içerisinde büyük adımlarla ilerlemesini sürdüren derin öğrenme algoritmalarının, detaylı literatür çalışmaları ve uygulamaları incelenmiş ve bu kapsamda, yüksek doğruluğu ve hızı ile dikkati çeken YOLOv9 algoritması tercih edilmiştir. Algoritmanın hedeflenen amaca ulaşabilmesi için materyal olarak seçilen 3 farklı veri seti birleştirilmiş, YOLOv9 modelinin farklı versiyonları üzerinde, küçükten, büyüğe doğru yükselen eğitim turu (epok) sayıları ile test edilerek sonuçlar elde edilmiştir. Detaylı açıklama materyal ve metot başlıkları altında belirtilmiştir.

3.1. Materyal

YOLOv9 modelini en optimum şekilde kullanabilmek amacıyla, tüm test ve eğitim süreçlerinde bilgisayar olarak; 13th Gen Intel® Core™ i9-13900H processor, Intel Iris Xe Graphics G7 GPU, 14 Core, 2,60 GHz işlemci, 16GB RAM laptop kullanılmıştır.

Kullanılan bilgisayara ek olarak tüm deneyler; Google firması aracılığıyla, derin öğrenme uygulamalarını geliştirmek ve çalıştırmak için; yüksek kapasiteli bulut tabanlı GPU imkânı sunan, Colab platformu üzerinden yapılmıştır.

3.1.1. GPU

Paralel işlem yapma yeteneği ile üstün hesaplama gücüne sahip GPU'lar, derin öğrenme gibi yapay zeka tabanlı uygulamaların, donanım kısmında önemli bir rol üstlenmektedirler. GPU'lar ilk başlarda grafik işlemlerini işlemek üzere tasarlanmıştır. Fakat son dönemde yüksek derecede hesaplama hacmi gerektiren derin öğrenme mimarilerinin artarak yaygınlaşması, GPU'ların bu alanlarda kullanımını zorunlu hale getirmektedir (Kulshrestha, 2019; Parakh ve ark., 2012).

Yapay sinir ağlarının nesne tespiti eğitimleri için görüntülerin dijitalize edilerek, çok miktarda matris işlemine dönüştürülmesi ve sonrasında hesaplamalarının yapılması gerekmektedir. Bu yoğun işlemleri bünyesinde, CPU'lardan çok daha fazla miktarda çekirdek barındıran GPU'lar; hesaplamaları paralel ve verimli olacak şekilde gerçekleştirebilmekte, işlem sürelerini de kayda değer oranlarda azaltmaktadır (Chowdhury ve ark., 2020; Çelebi, 2023).

Kurulduğu günden itibaren GPU'ların gelişimine önemli katkılar sunan, Nvidia şirketi, Birleşik Cihaz Mimarisi Hesaplama (CUDA) platformu ile birçok alanda GPU'ların kullanılabilmesine imkân tanımıştır. GPU'lar yapay zeka uygulamaları üzerindeki etkisini, yeni modeller ve algoritmaların geliştirilmesi üzerine de göstermektedir (Serttaş, 2021).

GPU'lar dolayısıyla ileri teknoloji bilgisayarlı görü ve nesne tespiti gibi yapay zeka uygulamalarının, son dönemdeki çığır açıcı etkisini destekleyen temel bir bileşen olarak görülmektedir (Pal ve Hsieh, 2021; Parakh ve ark., 2012; Xiong ve ark., 2024).

Ada mimarisi tabanlı NVIDIA L4 GPU, veri bilimi, simülasyon, bulut oyunları, sanallaştırma, grafik, video akışı, yapay zeka gibi çok sayıda başka uygulamalarında ihtiyaçlarını desteklemek için; veri merkezleri ve merkezi iş yerleri üzerinden kullanılması için tasarlanmıştır. 24 GB'lık hafızaya sahip L4 GPU, 73,1 TFLOPS (Bir Saniyede Geçen Trilyon Nokta İşlemi) işlem yapabilme kapasitesiyle yapay zeka destekli, video, konuşma, arama, tavsiye ve sanal iş istasyonları gibi farklı uygulamaları düşük güç tüketimi ile çözüm sağlamaktadır. Çalışmada önerilen mimarinin eğitim, doğrulama ve tespit aşamalarının tamamında NVIDIA L4 GPU kullanılmıştır (Nvidia, 2025).

3.1.2. Veri Seti

Derin öğrenme modellerinin nesne tespitinde sunacağı başarı, eğitimde kullanacağı veri setlerinin çeşitliliğine ve kalitesine bağlı olarak değişebilmektedir. Veri setlerindeki görüntülerin arka plan karmaşıklığını ve aydınlatma koşullarını yansıtması, gerçek yaşam şartlarını karşılayabilecek cinsten nesnelere seçilmesi, nesne tespit modelinin eğitimdeki başarı performansını arttırabilmektedir. Detaylı bir şekilde etiketlenmiş, nitelikli kaliteye sahip veri setleri modelin genelleme yeteneğini yükselterek, farklı senaryolardaki göstereceği sonuçların güvenilirlik puanını arttırmaktadır. Günümüzde nesne tespit dedektörlerinin eğitim ve başarı performansını puanlamak için Pascal VOC, COCO, ImageNet, MNIST benzeri büyük ölçekli veri setleri bulunmakta; araştırmacılara ve geliştiricilere büyük fırsatlar ve kolaylıklar sunmaktadır (Borges Oliveira ve ark., 2021; Li ve ark., 2021; Taş, 2021; Xu ve ark., 2024).

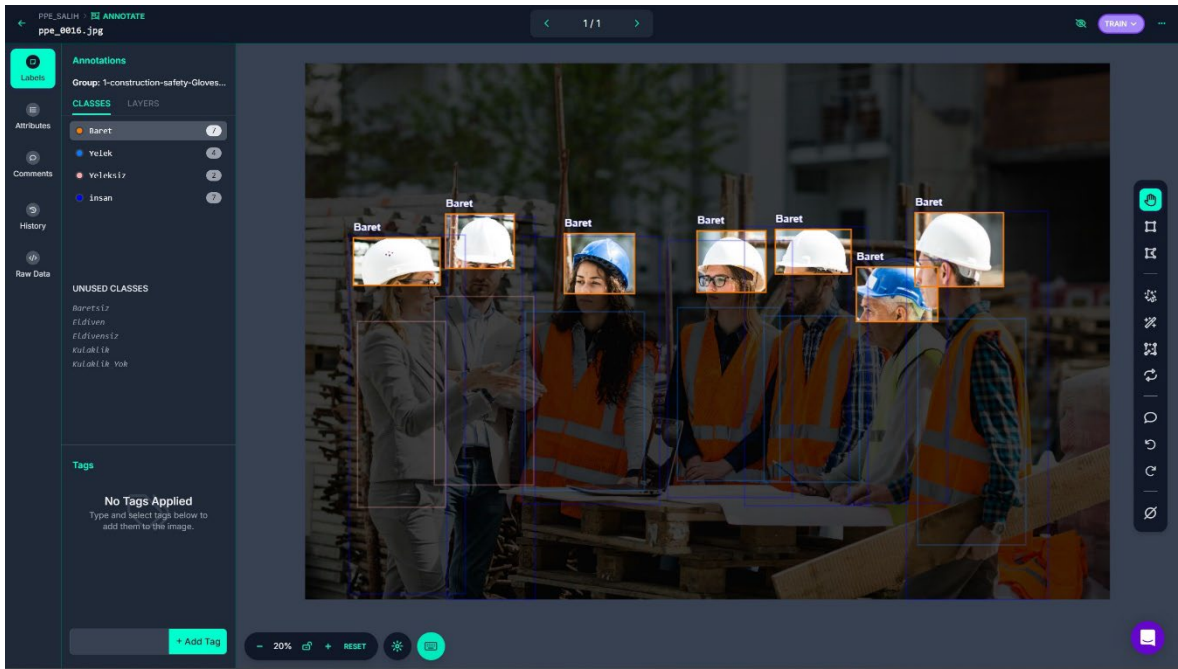
Araştırmacılar son dönemde nesne tespiti modellerini, Pascal VOC (Everingham ve ark., 2010) ve Microsoft COCO (Lin ve ark., 2014) veri setlerini kullanarak test etmekte, çıkan sonuçları mAP (Sapkota ve ark., 2024; Solawetz, 2020; Yellapantula, 2019) puanına göre kıymetlendirmektedirler.

Görüntüyü kullanım için telif haklarını alabilme ve görüntü toplama maliyetleri veri setlerinin oluşumundaki en büyük iki sorunu bir araya getirmektedir. Bir başka sorunsu görüntülerin, modelin tespiti için istenilen alanı yansıtacak, gerçek yaşamı temsil etmemesidir. Veri setleri, bu sorunlar aşılacağı durumlarda genellikle internet kaynaklarında bulunan oyun ya da mikroskobik görüntülerden, istifade edilerek oluşturulabilmektedir (Ciaglia ve ark., 2022).

Tezde kullanılan veri setlerinin gerçek yaşamı ve inşaat alanlarını yansıtması için kapsamlı bir araştırma yapılarak, veri setleri taranmıştır. Önerilecek modelin eğitimi ve test sonuçları için Roboflow Universe adlı veri kümesi kaynağı tercih edilmiştir. Kaynakta 350 milyondan fazla resim 500 binden fazla veri seti bulunmaktadır (Roboflow Universe, 2025).


Roboflow Universe internet sitesinde, özellikle model eğitimi ve değerlendirilmesinde COCO ve Pascal VOC gibi bir standart ölçüt olması düşüncesiyle; adından anlaşılacağı üzere RF100 veri kümesi bulunmaktadır. RF 100, veri seti kaynağını oluşturabilmek için, 222,714 adet görüntü toplanmış ve bu görüntüleri 805 adet sınıfa etiketlenebilmesi için 11,170 saatten fazla zaman harcanılmıştır (Ciaglia ve ark., 2022).

1. Veri seti, Roboflow-100 (RF100) de mevcut “construction safety Computer Vision Project veri seti denenmiştir. Veri setinde 1206 adet resim bulunmaktadır. Resimlerdeki görüntüler insan, baret, yelek, yelek yok, baret yok olarak 5 sınıf oluşturacak şekilde etiketlenmiştir. 1. Veri setinin etiketlenmesinden örnek Şekil 3.1’de sunulmuştur.



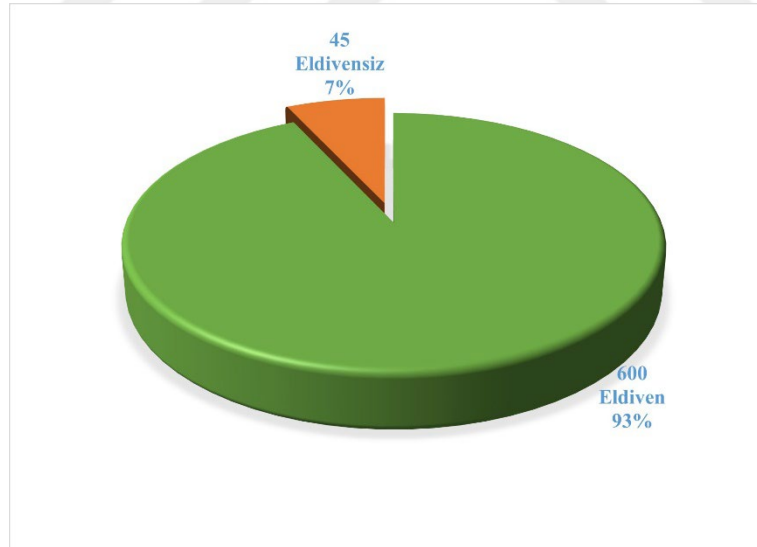
Şekil 3.1. 1. Veri setinin etiketlenmesinden örnek

Bu şekilde etiketlenen resimler içerisinde toplamda 7724 adet nesne bulunmaktadır. Nesnelerin sınıf dağılımları grafiği Şekil 3.2’de sunulmuştur (Roboflow 100, 2023).



Şekil 3.2. 7724 adet nesnenin etiketlenme dağılımı


İlk veri setinin sınıf sayısını arttırmak için Roboflow Universe kaynağından, “Gloves Computer Vision” projesi seçilmiştir. Projede toplamda 489 adet görüntü bulunmakta olup 600 tanesi eldiven olarak etiketlenmiş, 45 tanesi eldiven yok olarak etiketlenmiştir. Toplam etiketlenen nesne sayısı 645 adettir (Corros, 2024). Nesnelerin sınıf dağılımları grafiği Şekil 3.3’te sunulmuştur.



Şekil 3.3. 645 adet nesnenin, etiketlenme dağılımı


3. Veri seti de yine sınıf sayısını arttırmak için Roboflow Universe kaynağından, “PPE Ear Protection Computer Vision” projesi tercih edilmiştir. Projedeki görüntü sayısı 412 adettir. Veri setindeki görüntülerin 287 adedi kulaklık, 343 adedi kulaklık yok olarak etiketlenmiştir. Toplam

etiketlenen nesne sayısı 630 adettir (Dağdeviren, 2024). Nesnelerin sınıf dağılımları grafiği Şekil 3.4'te sunulmuştur.



Şekil 3.4. 630 adet nesnenin, etiketlenme dağılımı

Çalışmada kullanılan YOLOv9 modelinin eğitimin için 3 farklı veri seti birleştirilmiştir. Oluşan yeni veri setinde 2107 adet görüntü elde edilmiştir. İnsan, baret, yelek, yeleksiz, eldiven, kulaklık yok, kulaklık, baretsiz, eldivensiz olmak üzere 9 adet sınıf oluşturulmuş. Sınıflardaki tüm nesnelerin etiketli sayısı 8999 adettir. Kümelenmiş çubuk grafiği Şekil 3.5'te sunulmuştur.




Şekil 3.5. 8999 adet nesnenin, etiketlenme dağılımı

3.2. Metot

Bu çalışmada, derin öğrenme tabanlı nesne algılama algoritmalarından tek aşamalı ve iki aşamalı dedektörler irdelenmiştir. Detaylı araştırma ve literatür incelenmesi sonucu; iki aşamalı dedektörlere göre tek aşamalı dedektörlerin KKD tespitinde daha uygun olduğu değerlendirilmiştir. Tek aşamalı dedektörler içerisinde hızı ve doğruluğu ile ön plana çıkan YOLOv9 modeli tercih edilmiştir.

3.2.1. YOLOv9

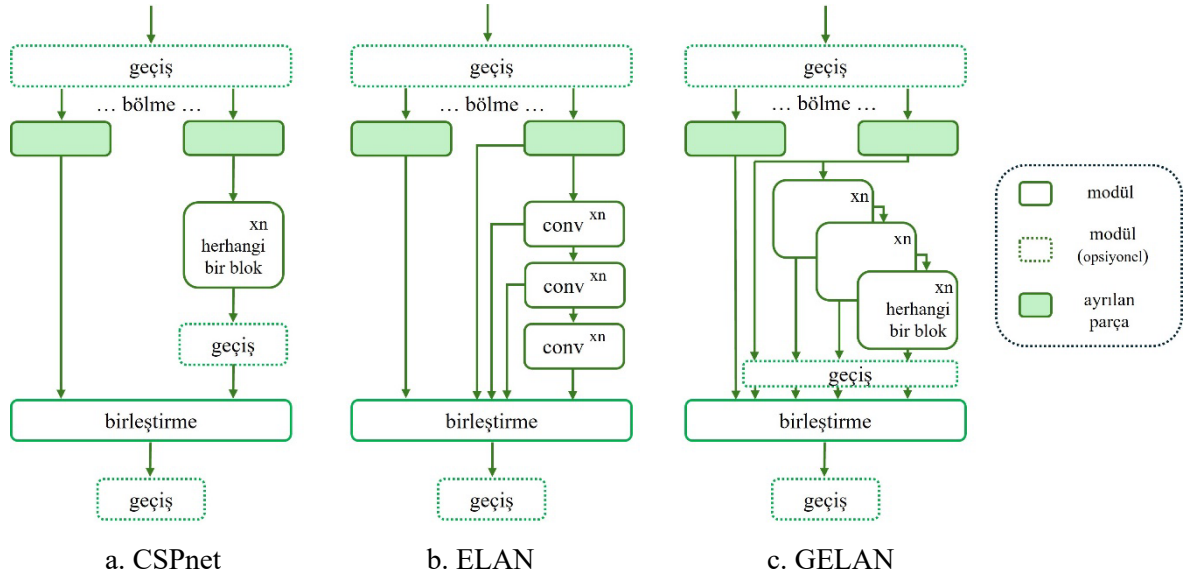
Wang, C.-Y. ve ark. (2024) mevcut yöntemlerin sinir ağına girdi verileri uygulandıktan sonra, katmanlarda uzamsal dönüşüm ve özellik çıkarma işlemleri gördüğünü ve bu esnada fazla miktarda bilginin kaybolduğu hususuna önem vermediklerini vurgulamışlardır. Bu önemli bilgilerin kaybolmadan sürecin tamamlanması için Programlanabilir Gradyan Bilgisi (PGI) önerisini sunmuşlardır. PGI, hedef görevlerin eksiksiz bir şekilde tamamlanması için hedefe uygun fonksiyonları sunabilmekte, böylece güvenilir gradyan bilgileri oluşturabilmek için ağ ayarları güncel tutulabilmektedir. Ayrıca modellerini desteklemek için gradyan temeline dayanan, Genelleştirilmiş Verimli Katman Toplama Ağı (GELAN)'nı da geliştirmişlerdir. Hafif modellerde; GELAN mimarisinde PGI'nın kullanılması ile başarılı sonuçlar elde ettiklerini belirtmişlerdir. GELAN ve PGI'nın ölçümlerini COCO veri kümesinde test ederek güvenilir sonuçlar elde ettiklerini, diğer modellerin hepsinden yüksek değerlere ulaştıklarını Şekil 3.6'da göstermişlerdir. Ayrıca sıfırdan modeli eğitmenin, büyük veri kümeleri kullanılmadan da başarılabilirliğini göstermişlerdir (Chandra ve ark., 2024; Yoon ve ark., 2024; Youwai ve ark., 2024).



Şekil 3.6. YOLOv9'un diğer modeller karşısındaki puanlaması (Wang, C.-Y. ve ark., 2024)

YOLO serisini geliştiren ana akım, temel hesaplayıcı birim olarak Çapraz Aşamalı Kısmi Ağ (CSPNet) ve Verimli Katman Birleştirme Ağı (ELAN)'nı kullanmaktadır. CSPNet mimarisi, modelin öğrenbilme yeteneğini arttırması ve hesaplama maliyetini azaltması nedeni ile mimari bir bileşen olarak kullanılmaktadır. ELAN, model mimarisi, ağın içerisindeki farklı katmanlarda gerçekleşen bilgi transferini iyileştirerek, çıkartılacak özelliklerin etkili bir şekilde birleştirilmesini sağlamaktadır. Aynı zamanda gerekli olmayan hesaplamaları azaltırken, değerli bilgileri üretmeye odaklanmakta; uygulanan modellerin gerçek zamanlı olarak çalışmasında rol oynamaktadır (Wang ve ark., 2020; Wang ve ark., 2022).

CSPNet ve ELAN'nın YOLOv9 modelinde bir araya getirilmesi ile GELAN oluşturulmuştur. Mimari Şekil 3.7'te sunulmuştur (Chien ve ark., 2024; Ji ve Huang, 2024; Yang ve ark., 2024).

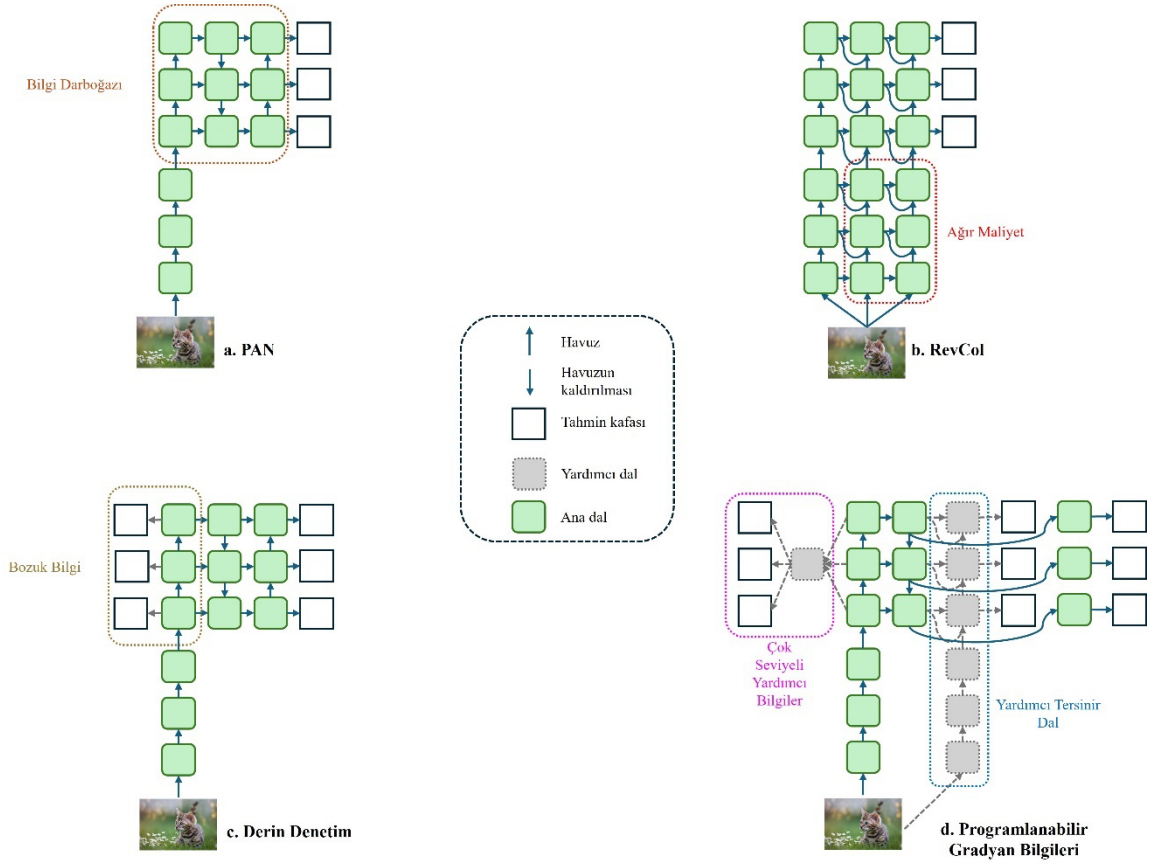


Şekil 3.7. GELAN mimarisi (Wang, C.-Y. ve ark., 2024)

PGI mimarisi sayesinde bilgi darboğazı ve derin denetim mekanizmasının olumsuz etkileri ortadan kaldırılarak, hafif sinir ağları üzerinde kullanılabilmesi mümkün kılınmaktadır (Wang, C.-Y. ve ark., 2024; Wei ve ark., 2024).

Bilgi Darboğazı Prensibi derin öğrenme mimarilerinde verileri sıkıştırarak, yalnızca en anlamlı olanların bilgilerini öğrenip, gerekli olmayan detayları elemesiyle avantaj sunmaktadır. Fakat ileri besleme işlemi sürecinde, girişte uygulanan verilerin kaybolmasına neden olmaktadır (Elhalid ve Işık, 2024; Hao ve ark., 2024; Tishby ve Zaslavsky, 2015; Wang, C.-Y. ve ark., 2024; Z. Shen ve ark., 2020).

Derin denetim (Deep supervision), sayıca küçük eğitim verilerinde ve kısmen de olsa seyrek yapıları ağlar üzerinde derin denetimini sağlamaktadır. Verilerin sınıflandırması aşamasında doğruluk ve öğrenilen özellikler ile yararlı bir düzenleme işlevi yürütmektedir (Lee ve ark., 2014; Wang ve ark., 2015).



Şekil 3.8. PGI mimarisi (Wang, C.-Y. ve ark., 2024)

Fakat maske modellemesinin kullanıldığı durumlarda, derin denetim mekanizması veriler arasında yanlış ilişkilendirmelere sebep olabilmektedir. Üretilen hatalı ilişkilendirmelerin sığ denetim, eğitim aşamasında bilgi kaybına uğradığında, diğer aşamalardaki katmanlar doğru bilgileri alıp öğrenemeyecektir. Bu olumsuz durum zorlu görevler esnasında ve küçük modellere uygulandığında kendini daha belirgin şekilde göstermektedir. Ters Çevrilebilir Sütun Ağı (RevCol) ise yüksek kalitede sonuçlara ulaşabilmek için büyük miktardaki verilere ve güçlü donanımlara gerek duymaktadır (Cai ve ark., 2022). Bu durumlar sebebi ile eğitim süreci ağır maliyetli olmaktadır. Çözüm noktasında PGI mimarisi geliştirilmiştir (Wang, C.-Y. ve ark., 2024). PGI mimarisinin yapısı orijinal kaynağına sadık kalınarak yeniden çizilmiş olup Şekil 3.8’te sunulmuştur.

3.2.2. Veri Ön İşleme

Veri ön işleme görüntü verilerinin mimarinin yapısına uygun hale getirilerek, analizini kolaylaştırma işlemi olarak ifade edilmektedir. Bu süreçte nesne tespit dedektörlerinin çoğunluğu, görüntü boyutunun aynı seviyede kalmasına ihtiyaç duymaktadır. Veri setleri oluşturulurken farklı cihazlardan elde edilmesi yada isteğe bağlı olarak değişik boyutlara getirilmesi, görüntülerin belirli bir standartta tutulmamasına neden olmaktadır (Nath ve Behzadan, 2020).

Test ve eğitim süreçlerinin aynı özelliklere sahip görüntüler üzerinde uygulanmasını sağlamlaştırmak için veri setinin ön işleme tutulması önemli bir husus olarak karşımıza çıkmaktadır. Bu önemli husus nedeni ile YOLOv9 modelinin eğitimi öncesi; veri seti hazırlığı aşamasında, 2107 adet görüntü, 640x640 oranında yeniden boyutlandırılmıştır.

Dijital çekim özelliğine sahip herhangi bir cihazdan çekim yapıldığında sadece bir görüntüye değil çekim anına ait tüm teknik detaylara da sahip olabilmekteyiz. Bahse konu bu teknik detaylar, Değiştirilebilir Görüntü Dosya Formatı (EXIF) içerisinde saklanmaktadır (Akkajit ve ark., 2024). Görüntünün çekildiği yön bilgileri akıllı telefon ya da bilgisayarlar tarafından, EXIF dosyasında kaydedildiği hali yerine, genellikle yana doğru olacak şekilde çevrilmektedir. (Dwyer, 2020; Mustafa ve Alizadeh, 2024).

Çalışmada kullanılan veri seti içindeki tüm görüntülerin, EXIF formatına uygun haline dönüştürmek için otomatik doğrultma (Auto-orient), veri ön işleme yöntemi uygulanmıştır.

Araştırmacıların ellerinde sınırlı bir veri kümesi bulunduğunda optimum performans sağlamak için veri arttırımı (Augmentation) ilk çare olarak görülmektedir. Rastgele kesme, kırpma ve döndürme, bulanıklaştırma, 90 derece döndürme gibi teknikler sayesinde yeni görüntü verileri elde edilebilmektedir. Bu teknikler uygulandığında her bir görüntü üzerine etki etmekte ve birden fazla kopyası oluşabilmekte böylece bir önceki veri setinden daha büyük ve yeni bir veri seti elde edilebilmektedir. Veri arttırmanın ana amacı fazladan veri elde edebilmektir. Bu sayede derin öğrenme modellerinin aşırı öğrenme eğilimi engellenebilmekte; modelin ezberleme yerine genelleme yeteneği artabilmektedir (Bilik ve ark., 2024; Chang ve ark., 2023; Fang ve ark., 2020; Kouzehgar ve ark., 2019; Liu, Luo ve ark., 2022).

YOLOv9 modelinde kullanılacak veri seti, yeterince büyük olduğundan dolayı arttırma uygulanmamıştır.

3.2.3. Veri Bölme İşlemi


Modelde kullanılmak için toplanan 2107 sayıdan oluşan veri kümesinin, 1669 adedi eğitim seti, 283 adedi doğrulama seti, 155 adedi test seti olmak üzere 3 gruba bölünmüştür.

Eğitim seti (Train set) tüm veri kümesindeki en büyük payı almaktadır. Veri setleri içerisinde bulunan veriler genellikle farklı sınıflardan oluşan etiketli görüntülerden oluşmaktadır. Modelin tahminde bulunacağı nesnelere eğitim aşamasında etiketli görüntülerdeki nesnelere ve bulunduğu koordinatları öğrenmektedir. Bu sayede karşısına çıkan yeni görüntüleri tahmin edebilmesi mümkün olmaktadır (Ahn ve ark., 2023; Cho ve Kim, 2023; Hou ve ark., 2023; Kadadi, 2023; Wu ve ark., 2022).

Doğrulama seti (Validation set), modelin eğitim seti tarafından eğitilmesine müteakip öğrenme performansını değerlendirmek ve gerekli hiper parametrelerin ayarlanmasını sağlamak için kullanılmaktadır. Doğrulama seti eğitim verilerinden bağımsız bir şekilde kullanılmaktadır. Model

doğrulama seti üzerinden eğitilmez fakat genelleme yeteneği bu veri seti üzerinden kıymetlendirilmektedir. Doğrulama seti aşırı öğrenme problemlerinin tespit ve teşhisinde; modelin hata oranlarını analiz etmektedir. Eğitim aşamasındaki en iyi performansı sağlayan ağırlıklar içinde kritik bir öneme sahiptir (Assadzadeh ve ark., 2023; Chen, W. ve ark., 2023; Li, Y. ve ark., 2024; Prusty ve ark., 2021; Wei ve Zhan, 2024).

Test seti, modelin eğitim ve doğrulama aşamasından sonra nihai performansı model açısından değerlendirmektedir. Test seti eğitim ve doğrulama aşamasında hiçbir şekilde kullanılmamış görüntü verilerinden oluşmaktadır. Test setinin bu şekilde korunması ile modelin genelleme yeteneğini değerlendirilmekte, gerçek dünyadaki farklı senaryolara karşı nesne tespiti başarısı görülebilmektedir. Modelin doğruluk, hassasiyet, duyarlılık ve F1 skoru gibi metrikler ile ölçülmesinde referans alınan görüntüler test seti verileridir (Ahmed ve ark., 2024; Biçgi, 2022; Wei ve Zhan, 2024). Veri kümesinin eğitim, doğrulama ve test verisi olarak bölünmesi Şekil 3.9'da gösterilmiştir.



Şekil 3.9. Veri kümesinin eğitim, doğrulama ve test verisi olarak bölünmesi

3.2.4. Değerlendirme Metrikleri

Çalışmada gösterilen değerlendirme metrikleri, modelin eğitildikten sonraki nesne tespiti performansını ölçmek, farklı modellerle kıyaslanmasını göstermek ve uygunluğunu analiz etmek amacıyla kullanılmıştır. Değerlendirme metriklerinin bir arada kullanılması, modelin doğruluğu ve hızı gibi temel kriterleri sağlıklı bir şekilde optimize edilmesine olanak tanımaktadır. Böylece gerçek hayat şartlarındaki senaryolara uygun tahminleri değerlendirmede, standart bir yöntem sağlamaktadır.

Seçilen modelin algılama performansını ve güvenilirliğini detaylıca inceleyebilmek için, literatürde en çok tercih edilen metrikler ele alınmıştır.

Bahse konu metriklerden, Kesinlik (P) Eşitlik 3.1’de açıklanmıştır. Eşitlikte geçen Doğru Pozitif (TP), Yanlış Pozitif (FP)’e bölüldüğünde modelin sınıflandırılmış nesnelere; kesin ve hassas tahmin etme oranını göstermektedir. Pozitif olarak değerlendirilen tahminlerin kaç tanesinin gerçekten de pozitif olduğunun hesaplanmasıdır.

$$Precision = \frac{TP}{TP+FP} \quad (3.1)$$

Duyarlılık (R) Eşitlik 3.2’de, TP değerlerin, TP ve Yanlış Negatif (FN) değerine bölünmesi neticesinde ortaya çıkmaktadır. Duyarlılık, modelin tüm gerçek pozitif değerler arasından, tahmini yapılan TP ’leri göstermektedir.

$$Recall = \frac{TP}{TP+FN} \quad (3.2)$$

$F1$ puanı, Kesinlik ve Duyarlılık sayılarının harmonik ortalamalarını göstermektedir. $F1$ puanının yüksek olduğu durumlar Kesinlik ve Duyarlılığın yüksek seviyede olduğunun göstergesidir. (Gharghan ve Hashim, 2024; Zhao ve ark., 2024). Eşitlik 3.3’te sunulmuştur.

$$F1 = 2x \frac{Precision \times Recall}{Precision+Recall} \quad (3.3)$$

Modelde bulunan sınıfların Ortalama Kesinlik (AP) değeri eşitlik 3.4 ile bulunmaktadır. Modeldeki tüm AP değerlerinin ortalamasının alınmasıyla da mAP değeri bulunmakta olup Eşitlik 3.5’te gösterilmiştir. Eşitlik 3.4’te yer alan değerler Python komut satırında kodlanacağı zaman, n = eşik sayısı değeri, R için (n) = 0 ve P için (n) = 1 olarak kodlanmalıdır.

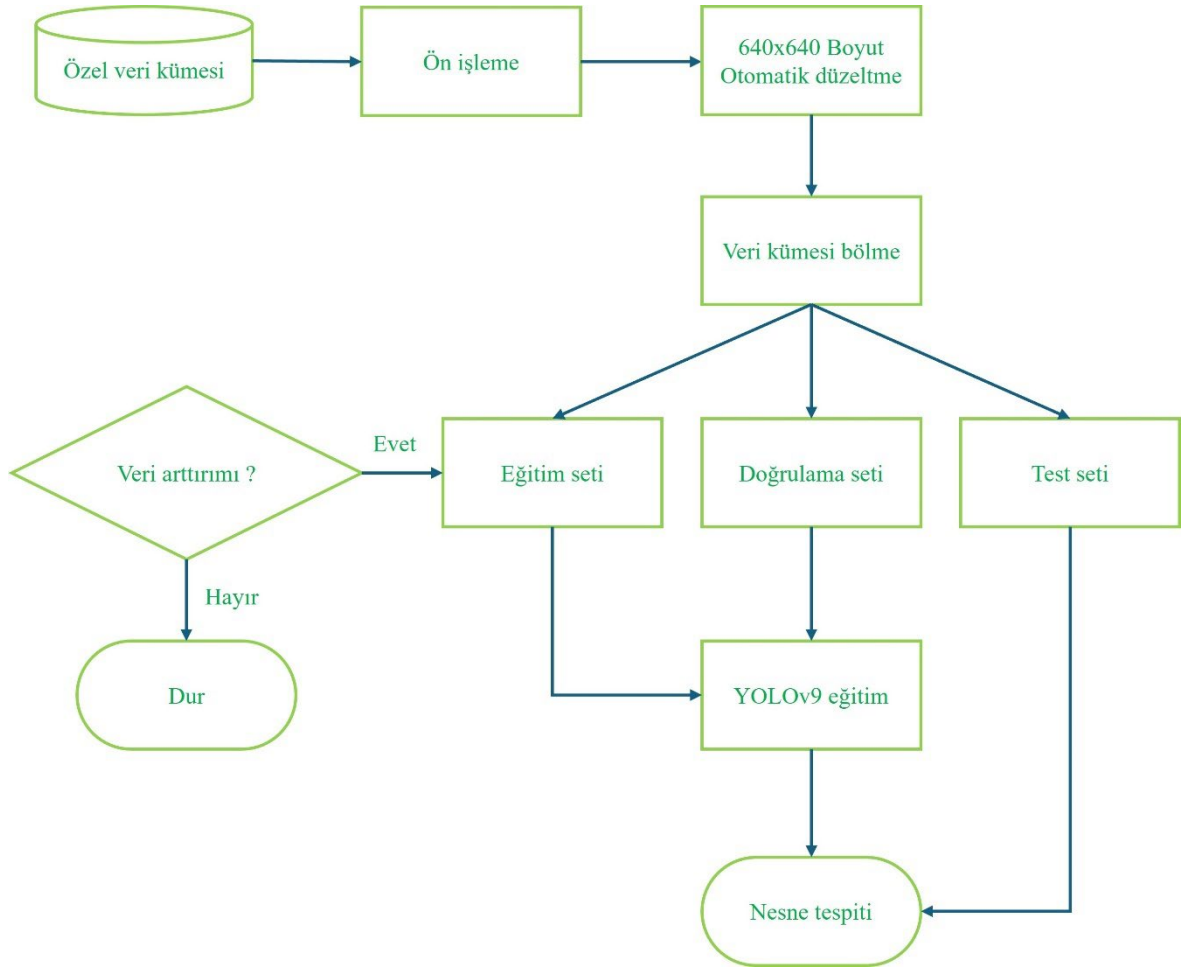
$$AP = \sum_{k=0}^{n-1} [Recalls(k) - Recalls(k + 1)] \times Precisions(k) \quad (3.4)$$

Eşitlik 3.5, Python komut satırına kodlanırken, n = eşik sayısı, $AP_k = k$ sınıfın AP ’si olarak yazılmalıdır.

$$mAP = \frac{1}{n} \sum_{k=1}^{k=n} AP_k \quad (3.5)$$

Çalışmada kullanılan tüm metrikler, eğitilen modelin nesnelere sınıflandırmadaki başarısını; nesnelere doğru tahmin etmesindeki performansını, analiz etmek amacıyla kullanılmıştır (Chen ve ark., 2024; Wang, L. ve ark., 2024; Yasir ve ark., 2024).

Tüm bu karmaşık işlemleri görsel olarak sunabilmek için Karışıklık Matrisi (Confusion Matrix) kullanılmıştır. Karışıklık Matrisi, eğitilen modellerin sınıflandırma başarısını değerlendirmek için detaylı bilgilerin yer aldığı bir tablo formatıdır. Karışıklık Matrisi eğitilen modelin tahmin ettikleri ile gerçekte var olan sınıflar arasındaki karşılaştırmanın özetini sunmasının yanında; sınıflandırma hatalarının detaylarını da göstermektedir (Alruwaili ve ark., 2024). Önerilen modelin veri seti ile eğitimini gösteren akış diyagramı Şekil 3.10'da sunulmuştur.



Şekil 3.10. YOLOv9 modelinin, veri seti ile eğitimini gösteren akış diyagramı



4. BULGULAR VE TARTIŞMA

Bu bölümde, seçilen YOLOv9 modelinin özel veri kümesinde eğitilmesinin, doğrulama yapılmasının ve test edilmesinin sonucunda; elde edilen tüm detaylar sergilenmiştir. Bulgular kısmı, YOLOv9 modelinin iki farklı versiyonu olan gelan-c ve gelan-e üzerinden çıkan sonuçlardan teşkil edilmiştir. Her iki versiyon sırası ile 25, 50, 75, 100 epok olacak şekilde eğitilmiş, hepsinde 16 batch size (Her bir yinelemede modele gönderilen veri örneği sayısı) değeri tatbik edilmiştir.

Tartışma kısmında çalışma esnasında karşılaşılan engeller, modelin etkisi, uygulanabilirliği ve özel veri setinin model üzerindeki etkisi tartışılacaktır. Gelecekte yapılacak ya da yapılması planlanan çalışmalara yol göstermesi hedeflenmektedir.

4.1. Bulgular

Google Colab platformu üzerinden, L4 GPU'ya uzaktan erişim, bulut sistemi ile bağlanılmış ve “gelan-c.pt” ve “gelan-e.pt” ağırlık dosyaları platforma yüklenmiştir. Roboflow uygulamasında oluşturulan veri setine, Roboflow tarafından üretilen komut satırı ile bağlanılmıştır. Özel veri kümesi için epok ve batch ayarlamaları yapılarak, data.yaml (veri serileştirme standardı) dosyasına eğitim, doğrulama, test resimlerinin yolu yazılmıştır. Sonrasında GPU çalıştırılmıştır. Elde edilen bulgular başlıklar halinde sunulmuştur.


4.1.1. Gelan-c Versiyonu 25 Epoktaki Bulgular

Modelin eğitimi sonucunda, doğrulama seti için ayrılan 283 adet görüntü üzerinden test edilmiştir. Model *mAP50-95* aralığında; *baret sınıfını 0,486, baretsiz 0,226, eldiven 0,613, eldivensiz 0,0829, kulaklık 0,683, kulaklık yok 0,21, yelek 0,519, yeleksiz 0,292, insan 0,598 ve tüm sınıfları 0,412* olarak tespit etmiştir. Çizelge 4.1 detaylar sunulmuştur.

Çizelge 4.1. Eğitilen Gelan-c modelinin, 25 epoktaki doğrulama sonuçları


Sınıflar	Görüntüler	Nesneler	P	R	mAP50	mAP50-95
Hepsi	283	937	0,569	0,733	0,692	0,412
Baret	283	232	0,707	0,922	0,836	0,486
Baretsiz	283	11	0,298	0,636	0,512	0,226
Eldiven	283	109	0,692	0,881	0,875	0,613
Eldivensiz	283	7	0,214	0,122	0,348	0,0829
Kulaklık	283	63	0,823	1	0,946	0,683
Kulaklık Yok	283	43	0,415	0,326	0,333	0,21
Yelek	283	141	0,799	0,901	0,892	0,519
Yeleksiz	283	90	0,447	0,856	0,625	0,292
İnsan	283	241	0,722	0,95	0,856	0,598

Modelin PR (Kesinlik-Duyarlılık) eğrisi PR eğrisinin sağ üst yöne doğru olması, P ve R arasındaki dengenin uyumlu olduğunu, dolayısıyla başarımın yüksek olduğu anlamına gelmektedir. Çizelge 4.1 ve Şekil 4.1 gelan-c modelinin, 25 epoktaki PR eğrisinde okunacağı üzere $mAP@0,5$ değeri için; tüm sınıflar 0,692, baret 0,836, baretsiz 0,512, eldiven 0,875, eldivensiz 0,348, kulaklık 0,946, kulaklık yok 0,333, yelek 0,892, yeleksiz 0,625, insan 0,856 olarak bulunmuştur.



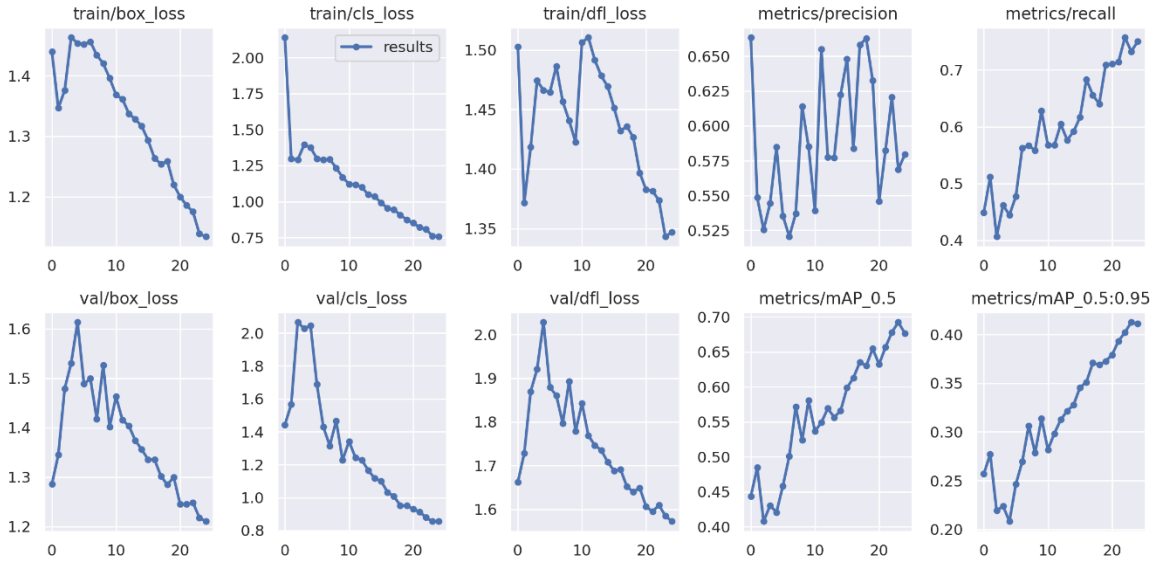
Şekil 4.1. Gelan-c modelinin, 25 epoktaki PR Eğrisi

P ve R değerlerinin harmonik ortalaması olan $F1$ -Güven eşiği eğrisi grafiği Şekil 4.2’de sunulmuştur. Grafiğin y eksenini güven eşiklerini, x eksenini $F1$ puanlarını, belirtmektedir. Gelan-c modelinin, 25 epok sonrası, 0,098 güven eşiğinde, $F1$ puanı 0,63 olarak bulunmuştur.



Şekil 4.2. Gelan-c modelinin, 25 epoktaki F1-Güven Eşiği Eğrisi

Şekil 4.3'te sunulan tüm grafikler, modelin eğitim esnasındaki kayıplarını (loss) ve performans metriklerini takip etmek amacıyla oluşturulmuştur. Ayrıca grafikler içerisinde doğrulama süreçlerine ait metrikler ile öğrenme başarıları görülebilmektedir.



Şekil 4.3. Gelan-c modelinin, 25 epoktaki performans metriği grafikleri

Üst sırada yer almakta olan “train/box_loss” sınırlayıcı kutuların süreç içerisindeki eğitimini göstermektedir. İlk epoktan son epoka gelinceye kadar kaybın azaldığı görülmekte böylece modelin nesnelere konumlandırma başarısının yükseldiği anlaşılmaktadır. “train/cls_loss” sınıf tahmini kaybını göstermektedir. Grafikte azalan bir eğri; model tarafından nesnelere sınıfları, doğru olarak tahmin ederek öğrendiğini açıklamaktadır. “train/df_l loss” (Dağılım odak kaybı) veri kümesinin dengesiz sınıflandırma halinin kayıp fonksiyonunu açıklamaktadır. Aynı zamanda modelin sınıf nesnelere konumlandırmak için kullandığı sınırlayıcı kutuların hedefine odaklanma durumunu da göstermektedir. Sınıf dağılımı dengeli olmadığı için grafik dalgalı bir biçimdedir. “metrics/precision” ve “metrics/recall” grafiğinde modelin epok sayısına bağlı olarak tahmin performansının iyileştiği görülmektedir.

Alt sırada yer almakta “val/box_loss”, “val/cls_loss” ve “val/df_l loss” doğrulama grafiklerinin, yukarı simetriğindeki grafiklere benzeri durumlar sergilediği görülmekte olup, modelin öğrenme performansı her epokta artan bir eğilim göstermektedir. Grafiklere ait değerler Çizelge 4.2’de sunulmuştur.

Çizelge 4.2. Gelan-c modelinin, 25 epoktaki performans metriklerinin sayıları

epoch	train/box_loss	train/cls_loss	train/df_l_loss	metrics/precision	metrics/recall	metrics/mAP_0,5	metrics/mAP_0,5:0,95	val/box_loss	val/cls_loss	val/df_l_loss
0	1,4397	2,1398	1,5027	0,66351	0,44916	0,44327	0,25683	1,2857	1,4422	1,6622
1	1,3464	1,2977	1,3718	0,5485	0,51142	0,48439	0,27727	1,3448	1,5671	1,7281
2	1,3759	1,2903	1,4183	0,52541	0,40658	0,40758	0,21921	1,4792	2,0659	1,8697
3	1,4632	1,3943	1,4742	0,54432	0,46185	0,43023	0,22395	1,5301	2,0264	1,9208
4	1,4538	1,3756	1,4663	0,58481	0,44477	0,42055	0,20827	1,6135	2,0459	2,0283
5	1,4521	1,2986	1,4645	0,53544	0,47763	0,45815	0,24642	1,4886	1,6871	1,879
6	1,4562	1,2912	1,4864	0,52047	0,56283	0,50081	0,26958	1,4992	1,4288	1,8605
7	1,434	1,2943	1,4567	0,53697	0,56702	0,57125	0,30624	1,418	1,3153	1,7971
8	1,4201	1,2332	1,4406	0,61385	0,55809	0,52373	0,27856	1,5266	1,466	1,8933
9	1,396	1,17	1,4225	0,58519	0,62784	0,58016	0,31385	1,4014	1,2275	1,7783
10	1,3686	1,121	1,5063	0,53907	0,5674	0,53652	0,28181	1,4626	1,3409	1,8424
11	1,3613	1,1184	1,5105	0,65515	0,56749	0,54884	0,29841	1,4153	1,2435	1,7689
12	1,3373	1,0999	1,4915	0,57763	0,60458	0,56904	0,31259	1,4038	1,2278	1,7466
13	1,3281	1,0479	1,4783	0,57723	0,57667	0,55636	0,32146	1,3742	1,1657	1,7355
14	1,3166	1,0364	1,4693	0,62255	0,59145	0,56567	0,32782	1,3559	1,1166	1,7085
15	1,2933	0,99177	1,4515	0,64796	0,61659	0,59838	0,34563	1,3356	1,1009	1,6883
16	1,2635	0,95515	1,432	0,58387	0,68346	0,61286	0,35114	1,3356	1,0328	1,6917
17	1,254	0,94491	1,4359	0,65836	0,65563	0,63516	0,37078	1,3019	1,0072	1,6522
18	1,2589	0,90685	1,4265	0,66267	0,64024	0,62995	0,36884	1,2844	0,95228	1,6396
19	1,2196	0,87449	1,3969	0,63268	0,70923	0,65451	0,37259	1,2997	0,95143	1,6493
20	1,1999	0,8515	1,3826	0,54598	0,71066	0,63212	0,37918	1,245	0,93068	1,6062
21	1,1856	0,82121	1,3816	0,58247	0,71369	0,65649	0,39323	1,2452	0,91356	1,595
22	1,175	0,80931	1,3736	0,62084	0,75713	0,67789	0,40207	1,2481	0,87893	1,6093
23	1,1387	0,76083	1,3432	0,56864	0,73252	0,69236	0,41264	1,2179	0,85536	1,5854
24	1,1339	0,75651	1,3469	0,5794	0,75	0,67664	0,41111	1,2104	0,85703	1,5725

Gelan-c modelinin, 25 epoktaki Karışıklık Matrisi Şekil 4.4’te gösterildiği üzere sol üst kenar modelin eğitiminin tamamlanmasından sonraki sınıf tahmin değerlerini, alt orta kenar gerçekte olan sınıf değerlerini göstermektedir. Karışıklık Matrisinde; *baret 0,90 oranında doğru tahmin edilmiş, 0,01 kulaklık, 0,01 kulaklık yok, 0,01 insan olarak yanlış tahmin edilmiş ve 0,06 oranında tespit edilememiştir.*

Baretsiz 0,45 oranında doğru tahmin edilmiş, 0,09 baret olarak yanlış tahmin edilmiş ve 0,45 oranında tespit edilememiştir.

Eldiven 0,87 oranında doğru tahmin edilmiş, 0,13 oranında tespit edilememiştir.

Eldivensiz hiç tahmin edilememiş, 0,14 oranında eldiven olarak yanlış tahmin edilmiş, 0,86 oranında gerçekte var olmasına rağmen tespit edilememiştir.


Kulaklık 0,97 oranında doğru tahmin edilmiş, 0,03 oranında tespit edilememiştir.

Kulaklık yok 0,12 oranında doğru tahmin edilmiş, 0,05 kulaklık, 0,07 baretsiz, 0,49 baret olarak yanlış tahmin edilmiş, 0,28 oranında tespit edilememiştir.

Yelek 0,84 oranında doğru tahmin edilmiş, 0,04 oranında yeleksiz olarak yanlış tahmin edilmiş ve 0,12 oranında tespit edilememiştir.


Yeleksiz 0,80 oranında doğru tahmin edilmiş, 0,04 oranında yelek, 0,01 oranında baret olarak yanlış tahmin edilmiş ve 0,14 oranında tespit edilememiştir.

İnsan 0,92 oranında doğru tahmin edilmiş, 0,08 oranında tespit edilememiştir.



Şekil 4.4. Gelan-c modelinin, 25 epoktaki Karışıklık Matrisi

Gelan-c modelinin, 25 epoktaki görüntü tahminleri Şekil 4.5'te sunulmuştur. Modelin tamamen eğitilmesinden sonraki, nesne tespitindeki başarısı görülmektedir. Örnek olarak sergilenen görüntülerin tamamı test için ayrılan 155 adet görüntü içerisinde alınmıştır. Test seti olarak ayrılan görüntüler eğitim veri setinde ya da doğrulama setinde hiçbir şekilde kullanılmamıştır.



Şekil 4.5. Gelan-c modelinin, 25 epoktaki görüntü tahminleri

4.1.2. Gelan-c Versiyonu 50 Epoktaki Bulgular


Modelin eğitimi sonucunda, doğrulama seti için ayrılan 283 adet görüntü üzerinden test edilmiştir. Model mAP_{50-95} aralığında; *baret sınıfını* 0,476, *baretsiz* 0,226, *eldiven* 0,628, *eldivensiz* 0,275, *kulaklık* 0,713, *kulaklık yok* 0,165, *yekek* 0,546, *yeleksiz* 0,297, *insan* 0,604 ve *tüm sınıfları* 0,437 olarak tespit etmiştir. Çizelge 4.3'te detaylar sunulmuştur.

Çizelge 4.3. Eğitilen Gelan-c modelinin, 50 epoktaki doğrulama sonuçları

Sınıflar	Görüntüler	Nesnelere	P	R	mAP_{50}	mAP_{50-95}
Hepsi	283	937	0,692	0,71	0,706	0,437
Baret	283	232	0,794	0,863	0,819	0,476
Baretsiz	283	11	0,667	0,545	0,539	0,226
Eldiven	283	109	0,873	0,835	0,874	0,628
Eldivensiz	283	7	0,426	0,571	0,571	0,275
Kulaklık	283	63	0,936	0,984	0,981	0,713
Kulaklık Yok	283	43	0,308	0,163	0,268	0,165
Yekek	283	141	0,897	0,801	0,892	0,546
Yeleksiz	283	90	0,558	0,715	0,562	0,297
İnsan	283	241	0,772	0,909	0,849	0,604


Modelin PR (Kesinlik-Duyarlılık) eğrisi PR eğrisinin sağ üst yöne doğru olması, P ve R arasındaki dengenin uyumlu olduğunu, dolayısıyla başarımın yüksek olduğu anlamına gelmektedir. Çizelge 4.3 ve Şekil 4.6'da gelan-c modelinin, 50 epoktaki PR eğrisinde okunacağı üzere $mAP@0,5$

değeri için; tüm sınıflar 0,706, baret 0,819, baretsiz 0,539, eldiven 0,874, eldivensiz 0,571, kulaklık 0,981, kulaklık yok 0,268, yelek 0,892, yeleksiz 0,562, insan 0,849 olarak bulunmuştur.



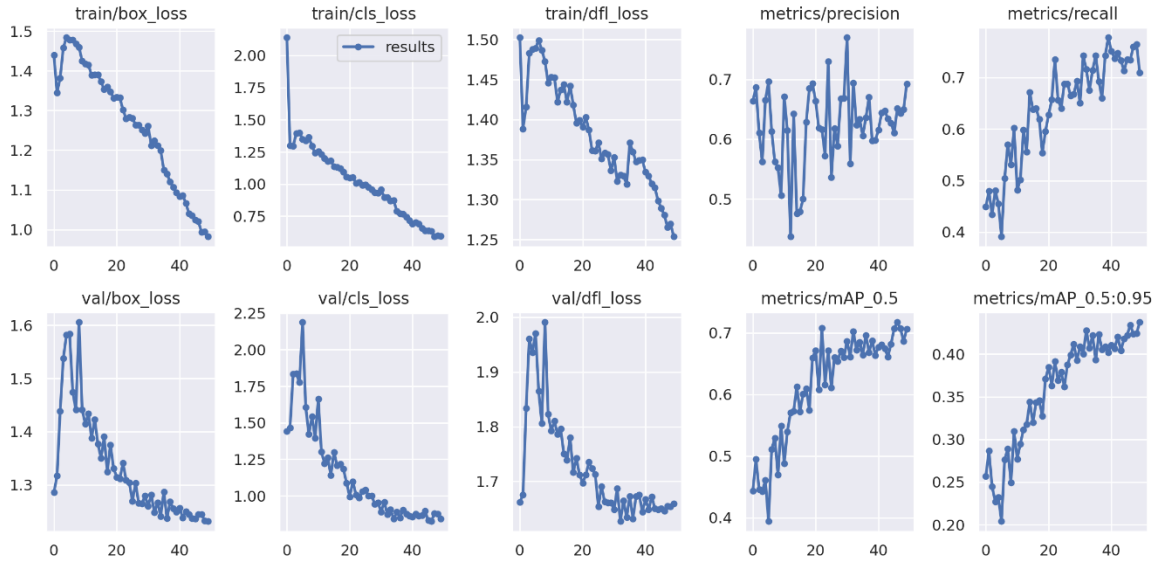
Şekil 4.6. Gelan-c modelinin, 50 epoktaki PR Eğrisi

P ve R değerlerinin harmonik ortalaması olan $F1$ -Güven eşiği eğrisi grafiği Şekil 4.7’de sunulmuştur. Grafiğin y eksenini güven eşiklerini, x eksenini $F1$ puanlarını, belirtmektedir. Gelan-c modelinin, 50 epok sonrası, 0,344 güven eşiğinde, $F1$ puanı 0,69 olarak bulunmuştur.



Şekil 4.7. Gelan-c modelinin, 50 epoktaki F1-Güven Eşiği Eğrisi

Şekil 4.8’de sunulan tüm grafikler, modelin eğitim esnasındaki kayıplarını (loss) ve performans metriklerini takip etmek amacıyla oluşturulmuştur. Ayrıca grafikler içerisinde doğrulama süreçlerine ait metrikler ile öğrenme başarıları görülebilmektedir.



Şekil 4.8. Gelan-c modelinin, 50 epoktaki performans metriği grafikleri


Üst sırada yer almakta olan “train/box_loss” sınırlayıcı kutuların süreç içerisindeki eğitimini göstermektedir. İlk epokta 1,4397 olan değeri, son epokta 0,98216’ya kadar düşmüştür. Rakamlar kaybın azaldığını göstermekte böylece modelin nesnelere konumlandırma başarısının yükseldiği anlaşılmaktadır. “train/cls_loss” sınıf tahmini kaybını göstermektedir. Grafikte azalan bir eğri; model tarafından nesnelere sınıfları, doğru olarak tahmin ederek öğrendiğini açıklamaktadır. “train/dfll_loss” veri kümesinin dengesiz sınıflandırma halinin kayıp fonksiyonunu açıklamaktadır. Aynı zamanda modelin sınıf nesnelere konumlandırmak için kullandığı sınırlayıcı kutuların hedefine odaklanma durumunu da göstermektedir. Sınıf dağılımı dengeli olmadığı için grafik dalgalı bir biçimdedir. “metrics/precision” ve “metrics/recall” grafiğinde modelin epok sayısına bağlı olarak tahmin performansının iyileştiği görülmektedir.

Çizelge 4.4. Gelan-c modelinin, 50 epoktaki performans metriklerinin sayıları

epoch	train/box_loss	train/cls_loss	train/dfll_loss	metrics/precision	metrics/recall	metrics/mAP_0,5	metrics/mAP_0,5@0,95	val/box_loss	val/cls_loss	val/dfll_loss
0	1,4397	2,1398	1,5027	0,66351	0,44916	0,44327	0,25683	1,2857	1,4422	1,6622
1	1,3449	1,3005	1,3886	0,68665	0,47948	0,4948	0,2867	1,3169	1,4667	1,6753
2	1,3823	1,2957	1,416	0,61011	0,43371	0,44581	0,24482	1,4387	1,832	1,8334
3	1,4581	1,3941	1,4829	0,56182	0,48101	0,44286	0,22714	1,5375	1,8354	1,9608
4	1,484	1,3985	1,4881	0,66515	0,4553	0,46047	0,23197	1,5819	1,7752	1,9357
5	1,4779	1,3486	1,4895	0,69641	0,39119	0,39394	0,20395	1,5836	2,1883	1,9706
6	1,4778	1,3389	1,4992	0,61328	0,50391	0,51084	0,27627	1,4744	1,6069	1,8646
7	1,4676	1,3649	1,4868	0,56196	0,57006	0,52935	0,28917	1,4409	1,4213	1,8055
8	1,4598	1,2949	1,4729	0,55206	0,53069	0,4692	0,24932	1,6057	1,5424	1,991
9	1,4244	1,2411	1,4458	0,50565	0,60213	0,54924	0,30952	1,4415	1,3948	1,8225
10	1,4175	1,2535	1,4531	0,67115	0,482	0,48813	0,27721	1,4143	1,6625	1,7923
11	1,4156	1,2311	1,4525	0,61464	0,50164	0,5398	0,29486	1,4341	1,3013	1,8103
12	1,3886	1,2017	1,422	0,43687	0,59782	0,57041	0,31161	1,3878	1,2217	1,7859
13	1,39	1,176	1,4373	0,64256	0,55584	0,57308	0,31771	1,4233	1,262	1,7961
14	1,3899	1,1808	1,4438	0,47573	0,67117	0,61264	0,34401	1,3774	1,1413	1,7507
15	1,3729	1,1354	1,4217	0,47878	0,63774	0,5722	0,31966	1,3503	1,2986	1,7392
16	1,3528	1,1328	1,4422	0,49968	0,63988	0,60063	0,34318	1,3903	1,2069	1,7796
17	1,3591	1,1219	1,4185	0,6285	0,61937	0,60959	0,3456	1,3245	1,2175	1,7163
18	1,3474	1,0931	1,3956	0,68455	0,55412	0,5747	0,32746	1,3755	1,1841	1,742
19	1,3313	1,0573	1,3991	0,69279	0,59556	0,6596	0,37119	1,3314	1,0881	1,7121
20	1,3338	1,0483	1,3906	0,66345	0,62802	0,67133	0,38477	1,3149	0,99497	1,6972
21	1,3319	1,0524	1,4028	0,61865	0,65665	0,60764	0,36305	1,3122	1,0977	1,7118
22	1,3015	1,0061	1,3869	0,61633	0,73534	0,70758	0,39136	1,3408	1,008	1,7353
23	1,2796	1,0129	1,3616	0,57238	0,65659	0,61596	0,36924	1,3092	0,98534	1,7235
24	1,2835	0,98967	1,3609	0,73003	0,64035	0,67129	0,3788	1,3041	1,029	1,7129
25	1,2804	0,99697	1,3715	0,53644	0,68764	0,61098	0,36197	1,2696	1,0406	1,6536
26	1,264	0,97509	1,3508	0,61792	0,68778	0,6604	0,38763	1,3033	1,0008	1,6908
27	1,264	0,95837	1,3583	0,58868	0,66443	0,65371	0,39916	1,2659	1,0007	1,6624
28	1,2516	0,93469	1,3567	0,66735	0,6672	0,67087	0,41192	1,2653	0,94235	1,661
29	1,2424	0,92903	1,3361	0,66864	0,69339	0,66005	0,39268	1,2794	0,95497	1,6611
30	1,2605	0,95849	1,3531	0,76997	0,65081	0,68672	0,40893	1,2606	0,89033	1,6482
31	1,2118	0,89624	1,3228	0,55928	0,74216	0,66131	0,4	1,2811	0,95852	1,6871
32	1,2244	0,8958	1,3306	0,69428	0,71551	0,70265	0,42796	1,2481	0,8732	1,6268
33	1,2117	0,87078	1,3293	0,62361	0,67504	0,67209	0,40691	1,2671	0,90717	1,665
34	1,1992	0,87334	1,3195	0,63321	0,7144	0,68508	0,42178	1,2413	0,84152	1,6341
35	1,15	0,78952	1,371	0,60582	0,74257	0,66381	0,39319	1,2872	0,88837	1,6729
36	1,1401	0,77009	1,3597	0,636	0,69239	0,69629	0,42304	1,237	0,85134	1,6318
37	1,1204	0,76527	1,3471	0,67011	0,65952	0,66811	0,40515	1,2687	0,90342	1,6726
38	1,1073	0,74484	1,349	0,59726	0,74215	0,68736	0,40874	1,2559	0,87799	1,6751
39	1,0933	0,71722	1,3495	0,59805	0,77755	0,6636	0,402	1,2491	0,8637	1,6441
40	1,0841	0,69151	1,3343	0,61513	0,75064	0,67717	0,41064	1,257	0,857	1,6673
41	1,0861	0,7028	1,3293	0,6443	0,73716	0,68105	0,4066	1,2386	0,8772	1,6489
42	1,0664	0,69024	1,3199	0,64736	0,74757	0,67451	0,42034	1,2503	0,86429	1,6713
43	1,0407	0,65508	1,3147	0,63407	0,73295	0,6613	0,40416	1,2448	0,86679	1,6504
44	1,035	0,6386	1,2986	0,62709	0,7135	0,68172	0,41781	1,2378	0,89504	1,6489
45	1,0249	0,63812	1,2893	0,61023	0,73455	0,70704	0,4223	1,2367	0,83322	1,65
46	1,0205	0,63445	1,2806	0,6517	0,73429	0,71735	0,4343	1,2443	0,82554	1,6454
47	0,99368	0,59117	1,2655	0,64352	0,75984	0,7068	0,42353	1,245	0,88054	1,6549
48	0,9942	0,60068	1,2694	0,64953	0,76415	0,68603	0,42419	1,2325	0,875	1,6535
49	0,98216	0,59405	1,2536	0,69265	0,70973	0,70643	0,4375	1,2316	0,84226	1,6589

Alt sırada yer almakta “val/box_loss”, “val/cls_loss” ve “val/df_l_loss” doğrulama grafiklerinin, yukarı simetriğindeki grafiklere benzeri durumlar sergilediği görülmekte olup, modelin öğrenme performansının bir önceki 25 epoktan daha fazla, artan bir eğilimde olduğu görülmektedir. Grafiklere ait değerler Çizelge 4.4’te sunulmuştur.

Gelan-c modelinin, 50 epoktaki Karışıklık Matrisi Şekil 4.9’da gösterildiği üzere sol üst kenar modelin eğitiminin tamamlanmasından sonraki sınıf tahmin değerlerini, alt orta kenar gerçekte olan sınıf değerlerini göstermektedir. Karışıklık Matrisinde; *baret* 0,90 oranında doğru tahmin edilmiş, 0,01 kulaklık, 0,02 kulaklık yok, 0,01 insan olarak yanlış tahmin edilmiş ve 0,06 oranında tespit edilememiştir.



Şekil 4.9. Gelan-c modelinin, 50 epoktaki Karışıklık Matrisi

Baretsiz 0,55 oranında doğru tahmin edilmiş, 0,27 *baret* olarak yanlış tahmin edilmiş ve 0,18 oranında tespit edilememiştir.

Eldiven 0,86 oranında doğru tahmin edilmiş, 0,14 oranında tespit edilememiştir.


Eldivensiz bu sefer 0,57 oranında doğru tahmin edilmiş ve 0,43 oranında tespit edilememiştir.

Kulaklık 0,98 oranında doğru tahmin edilmiş, 0,02 oranında tespit edilememiştir.

Çizelge 4.5. Eğitilen Gelan-c modelinin, 75 epoktaki doğrulama sonuçları


Sınıflar	Görüntüler	Nesnelar	P	R	mAP50	mAP50-95
Hepsi	283	937	0,725	0,732	0,714	0,433
Baret	283	232	0,776	0,858	0,792	0,476
Baretsiz	283	11	0,758	0,636	0,734	0,344
Eldiven	283	109	0,913	0,869	0,922	0,661
Eldivensiz	283	7	0,512	0,571	0,465	0,179
Kulaklık	283	63	0,943	0,968	0,988	0,716
Kulaklık Yok	283	43	0,388	0,256	0,269	0,156
Yelek	283	141	0,887	0,858	0,907	0,524
Yeleksiz	283	90	0,589	0,685	0,527	0,266
İnsan	283	241	0,76	0,888	0,824	0,578

Çizelge 4.5 ve Şekil 4.11’de gelan-c modelinin, 75 epoktaki PR eğrisinde okunacağı üzere $mAP@0,5$ değeri için; tüm sınıflar 0,714, baret 0,792, baretsiz 0,734, eldiven 0,922, eldivensiz 0,465, kulaklık 0,988, kulaklık yok 0,269, yelek 0,907, yeleksiz 0,527, insan 0,824 olarak bulunmuştur.



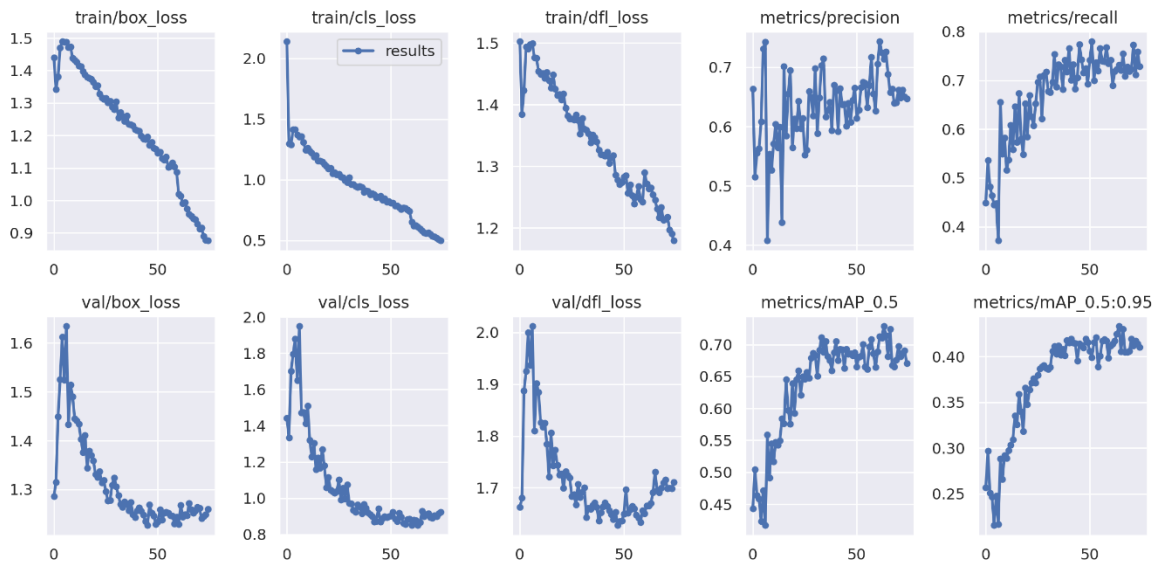
Şekil 4.11. Gelan-c modelinin, 75 epoktaki PR Eğrisi

P ve R değerlerinin harmonik ortalaması olan $F1$ -Güven eşliği eğrisi grafiği Şekil 4.12’de sunulmuştur. Grafiğin y eksenini güven eşiklerini, x eksenini $F1$ puanlarını, belirtmektedir. Gelan-c modelinin, 75 epok sonrası, 0,336 güven eşliğinde, $F1$ puanı 0,72 olarak bulunmuştur.



Şekil 4.12. Gelan-c modelinin, 75 epottaki F1-Güven Eşiği Eğrisi

Şekil 4.13’de sunulan tüm grafikler, modelin eğitim esnasındaki kayıplarını (loss) ve performans metriklerini takip etmek amacıyla oluşturulmuştur. Ayrıca grafikler içerisinde doğrulama süreçlerine ait metrikler ile öğrenme başarıları görülebilmektedir.




Şekil 4.13. Gelan-c modelinin, 75 epottaki performans metriği grafikleri

Üst sırada yer almakta olan “train/box_loss” sınırlayıcı kutuların süreç içerisindeki eğitimini göstermektedir. İlk epokta 1,4397 olan değeri, son epokta 0,87611’a kadar düşmüştür. Rakamlar kaybın azaldığını göstermekte böylece modelin nesnelere konumlandırma başarısının yükseldiği anlaşılmaktadır. “train/cls_loss” sınıf tahmini kaybını göstermektedir. Grafikte azalan bir eğri; model tarafından nesnelere sınıfları, doğru olarak tahmin ederek öğrendiğini açıklamaktadır. “train/dflloss” veri kümesinin dengesiz sınıflandırma halinin kayıp fonksiyonunu açıklamaktadır. Aynı zamanda modelin sınıf nesnelere konumlandırmak için kullandığı sınırlayıcı kutuların hedefine odaklanma durumunu da göstermektedir. Sınıf dağılımı dengeli olmamasına rağmen grafikte düzelme olmuştur. “metrics/precision” ve “metrics/recall” grafiğinde modelin epok sayısına bağlı olarak tahmin performansının iyileştiği görülmektedir.

Alt sırada yer almakta “val/box_loss”, “val/cls_loss” ve “val/dflloss” doğrulama grafiklerinin, 3’ünde birbirleri ile uyumlu eğriye sahiptir. Modelin öğrenme performansının bir önceki 50 epoktan daha fazla, artan bir eğilimde olduğu görülmektedir.

Grafiklere ait değerler Ek A. Gelan-c Modelinin, 75 Epoktaki Performans Metriklerinin Sayıları kısmında sunulmuştur.



Şekil 4.14. Gelan-c modelinin, 75 epoktaki Karışıklık Matrisi

Gelan-c modelinin, 75 epoktaki görüntü tahminleri Şekil 4.15’de sunulmuştur. Modelin tamamen eğitilmesinden sonraki, nesne tespitindeki başarısı görülmektedir. Örnek olarak sergilenen görüntülerin tamamı test için ayrılan 155 adet görüntü içerisinde alınmıştır. Test seti olarak ayrılan görüntüler eğitim veri setinde ya da doğrulama setinde hiçbir şekilde kullanılmamıştır.

4.1.4. Gelan-c Versiyonu 100 Epoktaki Bulgular


Modelin eğitimi sonucunda, doğrulama seti için ayrılan 283 adet görüntü üzerinden test edilmiştir. Model *mAP50-95* aralığında; *baret sınıfını 0,473, baretsiz 0,201, eldiven 0,607, eldivensiz 0,251, kulaklık 0,683, kulaklık yok 0,166, yelek 0,516, yeleksiz 0,286, insan 0,593 ve tüm sınıfları 0,42* olarak tespit etmiştir. Çizelge 4.6’da detaylar sunulmuştur.

Çizelge 4.6. Eğitilen Gelan-c modelinin, 100 epoktaki doğrulama sonuçları


Sınıflar	Görüntüler	Nesneler	P	R	mAP50	mAP50-95
Hepsi	283	937	0,645	0,739	0,699	0,42
Baret	283	232	0,756	0,888	0,817	0,473
Baretsiz	283	11	0,501	0,545	0,464	0,201
Eldiven	283	109	0,8	0,826	0,849	0,607
Eldivensiz	283	7	0,44	0,676	0,622	0,251
Kulaklık	283	63	0,882	0,984	0,971	0,683
Kulaklık Yok	283	43	0,305	0,209	0,278	0,166
Yelek	283	141	0,844	0,83	0,887	0,516
Yeleksiz	283	90	0,555	0,8	0,565	0,286
İnsan	283	241	0,721	0,896	0,838	0,593

Çizelge 4.6 ve Şekil 4.16’da gelan-c modelinin, 100 epoktaki PR eğrisinde okunacağı üzere *mAP@0,5* değeri için; *tüm sınıflar 0,699, baret 0,817, baretsiz 0,464, eldiven 0,849, eldivensiz 0,622, kulaklık 0,971, kulaklık yok 0,278, yelek 0,887, yeleksiz 0,565, insan 0,838* olarak bulunmuştur.

P ve R değerlerinin harmonik ortalaması olan *F1-Güven eşiği* eğrisi grafiği Şekil 4.17’de sunulmuştur. Grafiğin y eksenini güven eşiklerini, x eksenini *F1* puanlarını, belirtmektedir. Gelan-c modelinin, 100 epok sonrası, *0,252 güven eşiğinde, F1 puanı 0,68* olarak bulunmuştur.

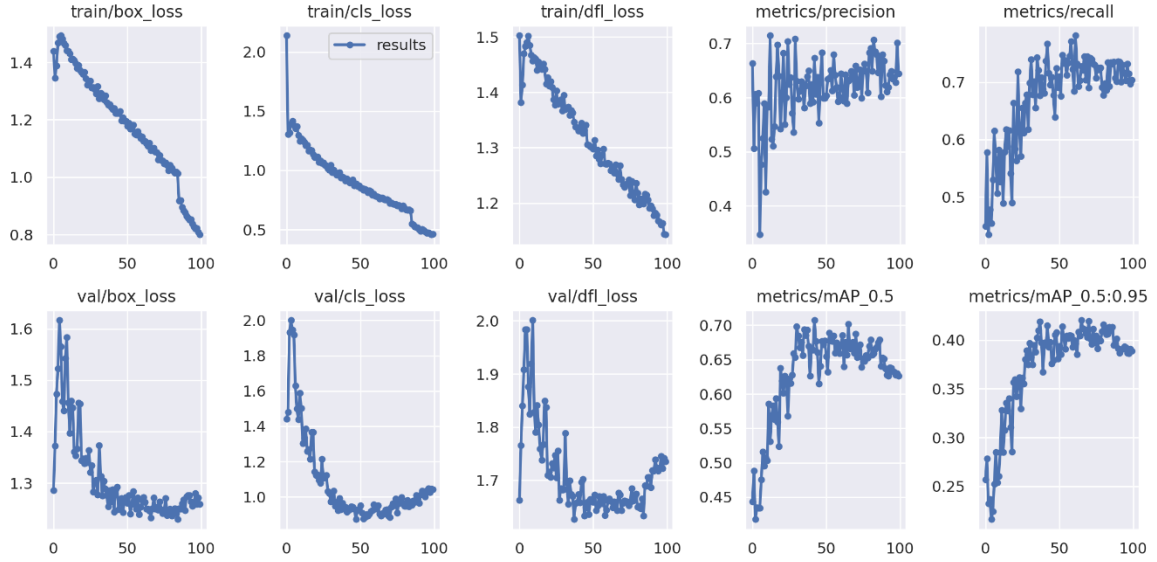


Şekil 4.16. Gelan-c modelinin, 100 epoktaki PR Eğrisi



Şekil 4.17. Gelan-c modelinin, 100 epoktaki F1-Güven Eşiği Eğrisi

Şekil 4.18’de sunulan tüm grafikler, modelin eğitim esnasındaki kayıplarını (loss) ve performans metriklerini takip etmek amacıyla oluşturulmuştur. Ayrıca grafikler içerisinde doğrulama süreçlerine ait metrikler ile öğrenme başarıları görülebilmektedir.




Şekil 4.18. Gelan-c modelinin, 100 epoktaki performans metriği grafikleri

Üst sırada yer almakta olan “train/box_loss” sınırlayıcı kutuların süreç içerisindeki eğitimini göstermektedir. İlk epokta 1,4397 olan değeri, son epokta 0,79988’e kadar düşmüştür. Rakamlar kaybın azaldığını göstermekte böylece modelin nesnelere konumlandırma başarısının yükseldiği anlaşılmaktadır. “train/cls_loss” sınıf tahmini kaybını göstermektedir. Grafikte azalan bir eğri; model tarafından nesnelere sınıfları, doğru olarak tahmin ederek öğrendiğini açıklamaktadır. “train/df_l_loss” veri kümesinin dengesiz sınıflandırma halinin kayıp fonksiyonunu açıklamaktadır. Aynı zamanda modelin sınıf nesnelere konumlandırmak için kullandığı sınırlayıcı kutuların hedefine odaklanma durumunu da göstermektedir. Sınıf dağılımı dengeli olmamasına rağmen grafikte düzleşme olmuştur. “metrics/precision” ve “metrics/recall” grafiğinde modelin epok sayısına bağlı olarak tahmin performansının iyileştiği görülmektedir.

Alt sırada yer almakta “val/box_loss”, “val/cls_loss” ve “val/df_l_loss” doğrulama grafiklerinin, 3’üde birbirleri ile uyumlu eğriye sahiptir. Modelin öğrenme performansının bir önceki 75 epoktan daha fazla, artan bir eğilimde olduğu görülmektedir.

Grafiklere ait değerler Ek B. Gelan-c Modelinin, 100 Epoktaki Performans Metriklerinin Sayıları kısmında sunulmuştur.



Şekil 4.19. Gelan-c modelinin, 100 epoktaki Karışıklık Matrisi

Gelan-c modelinin, 100 epoktaki Karışıklık Matrisi Şekil 4.19’da gösterildiği üzere sol üst kenar modelin eğitiminin tamamlanmasından sonraki sınıf tahmin değerlerini, alt orta kenar gerçekte olan sınıf değerlerini göstermektedir.

Karışıklık Matrisinde; baret 0,89 oranında doğru tahmin edilmiş, 0,01 kulaklık, 0,04 kulaklık yok olarak yanlış tahmin edilmiş ve 0,06 oranında tespit edilememiştir.

Baretsiz 0,55 oranında doğru tahmin edilmiş, 0,27 baret olarak yanlış tahmin edilmiş ve 0,18 oranında tespit edilememiştir.

Eldiven 0,84 oranında doğru tahmin edilmiş, 0,01 eldivensiz olarak yanlış tahmin edilmiş ve 0,15 oranında tespit edilememiştir.

Eldivensiz 0,57 oranında doğru tahmin edilmiş ve 0,43 oranında tespit edilememiştir.

Kulaklık 0,97 oranında doğru tahmin edilmiş,0,02 kulaklık yok olarak yanlış tahmin edilmiş ve 0,02 oranında tespit edilememiştir.


Kulaklık yok 0,21 oranında doğru tahmin edilmiş, 0,49 baret olarak yanlış tahmin edilmiş, 0,30 oranında tespit edilememiştir.

Yelek 0,83 oranında doğru tahmin edilmiş, 0,03 yeleksiz olarak yanlış tahmin edilmiş ve 0,14 oranında tespit edilememiştir.

Yeleksiz 0,78 oranında doğru tahmin edilmiş, 0,01 baret, 0,02 yelek, 0,01 insan olarak yanlış tahmin edilmiş ve 0,18 oranında tespit edilememiştir.

İnsan 0,90 oranında doğru tahmin edilmiş, 0,10 oranında tespit edilememiştir.

Gelan-c modelinin, 100 epoktaki görüntü tahminleri Şekil 4.20’de sunulmuştur. Modelin tamamen eğitilmesinden sonraki, nesne tespitindeki başarısı görülmektedir. Örnek olarak sergilenen görüntülerin tamamı test için ayrılan 155 adet görüntü içerisinde alınmıştır. Test seti olarak ayrılan görüntüler eğitim veri setinde ya da doğrulama setinde hiçbir şekilde kullanılmamıştır.



Şekil 4.20. Gelan-c modelinin, 100 epoktaki görüntü tahmin sonuçları


4.1.5. Gelan-e Versiyonu 25 Epoktaki Bulgular

Modelin eğitimi sonucunda, doğrulama seti için ayrılan 283 adet görüntü üzerinden test edilmiştir. Model mAP_{50-95} aralığında; *baret sınıfını 0,472, baretsiz 0,186, eldiven 0,597, eldivensiz 0,0481, kulaklık 0,707, kulaklık yok 0,213, yelek 0,525, yeleksiz 0,307, insan 0,596 ve tüm sınıfları 0,406 olarak tespit etmiştir. Çizelge 4.7 detaylar sunulmuştur.*

Çizelge 4.7. Eğitilen Gelan-e modelinin, 25 epoktaki doğrulama sonuçları


Sınıflar	Görüntüler	Nesneler	P	R	mAP50	mAP50-95
Hepsi	283	937	0,612	0,726	0,671	0,406
Baret	283	232	0,723	0,918	0,821	0,472
Baretsiz	283	11	0,374	0,545	0,440	0,186
Eldiven	283	109	0,724	0,817	0,817	0,597
Eldivensiz	283	7	0,49	0,143	0,213	0,0481
Kulaklık	283	63	0,894	0,942	0,964	0,707
Kulaklık Yok	283	43	0,278	0,442	0,359	0,213
Yelek	283	141	0,785	0,878	0,896	0,525
Yeleksiz	283	90	0,526	0,878	0,662	0,307
İnsan	283	241	0,714	0,967	0,865	0,596

Modelin PR (Kesinlik-Duyarlılık) eğrisi PR eğrisinin sağ üst yöne doğru olması, P ve R arasındaki dengenin uyumlu olduğunu, dolayısıyla başarımın yüksek olduğu anlamına gelmektedir. Çizelge 4.7 ve Şekil 4.21 gelan-e modelinin, 25 epoktaki PR eğrisinde okunacağı üzere $mAP@0,5$ değeri için; tüm sınıflar 0,671, baret 0,821, baretsiz 0,440, eldiven 0,817, eldivensiz 0,213, kulaklık 0,964, kulaklık yok 0,359, yelek 0,896, yeleksiz 0,662, insan 0,865 olarak bulunmuştur.



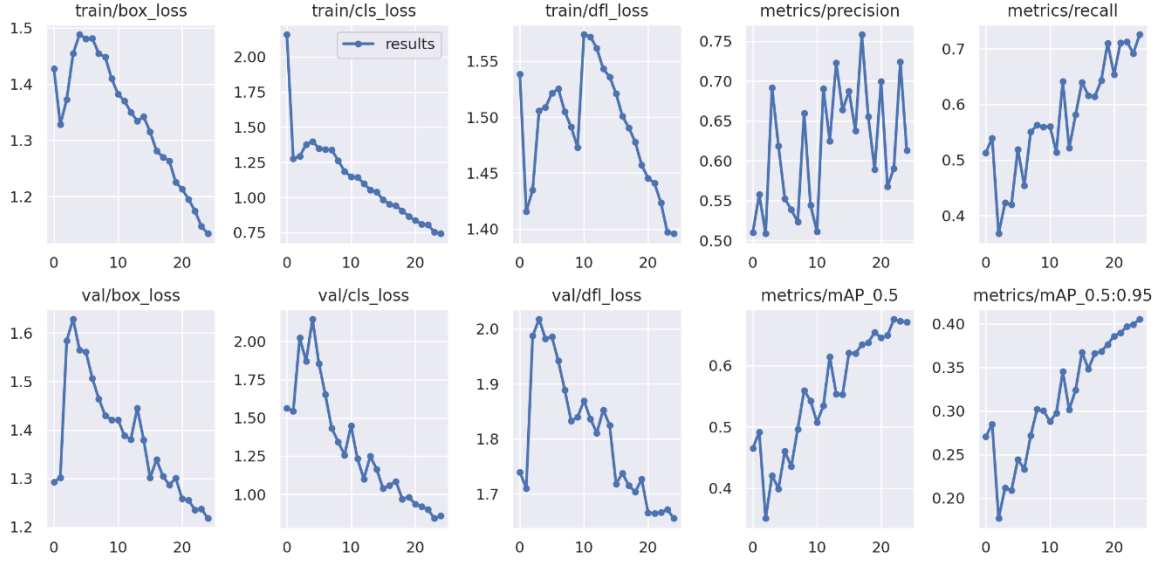
Şekil 4.21. Gelan-e modelinin, 25 epoktaki PR Eğrisi

P ve R değerlerinin harmonik ortalaması olan $F1$ -Güven eşiği eğrisi grafiği Şekil 4.22’de sunulmuştur. Grafiğin y eksenini güven eşiklerini, x eksenini $F1$ puanlarını, belirtmektedir. Gelan-e modelinin, 25 epok sonrası, 0,119 güven eşiğinde, $F1$ puanı 0,64 olarak bulunmuştur.



Şekil 4.22. Gelan-e modelinin, 25 epoktaki $F1$ -Güven Eşiği Eğrisi

Şekil 4.23’te sunulan tüm grafikler, modelin eğitim esnasındaki kayıplarını (loss) ve performans metriklerini takip etmek amacıyla oluşturulmuştur. Ayrıca grafikler içerisinde doğrulama süreçlerine ait metrikler ile öğrenme başarıları görülebilmektedir.



Şekil 4.23. Gelan-e modelinin, 25 epoktaki performans metriği grafikleri

Üst sırada yer almakta olan “train/box_loss” sınırlayıcı kutuların süreç içerisindeki eğitimini göstermektedir. İlk epokta 1,428 olan değeri, son epokta 1,1337’e kadar düşmüştür. Rakamlar kaybın azaldığını göstermekte böylece modelin nesnelere konumlandırma başarısının yükseldiği anlaşılmaktadır. “train/cls_loss” sınıf tahmini kaybını göstermektedir. Grafikte azalan bir eğri; model tarafından nesnelere sınıfları, doğru olarak tahmin ederek öğrendiğini açıklamaktadır. “train/df_l_loss” (Dağılım odak kaybı) veri kümesinin dengesiz sınıflandırma halinin kayıp fonksiyonunu açıklamaktadır. Aynı zamanda modelin sınıf nesnelere konumlandırmak için kullandığı sınırlayıcı kutuların hedefine odaklanma durumunu da göstermektedir. Sınıf dağılımı dengeli olmadığı için grafik dalgalı bir biçimdedir. “metrics/precision” ve “metrics/recall” grafiğinde modelin epok sayısına bağlı olarak tahmin performansının iyileştiği görülmektedir.

Alt sırada yer almakta “val/box_loss”, “val/cls_loss” ve “val/df_l_loss” doğrulama grafiklerinin, 3’ünde birbirleri ile uyumlu eğriye sahiptir. Grafiklere ait değerler Çizelge 4.8’de sunulmuştur.

Çizelge 4.8. Gelan-e modelinin, 25 epoktaki performans metriklerinin sayıları

epoch	train/box_loss	train/cls_loss	train/dfl_loss	metrics/precision	metrics/recall	metrics/mAP_0,5	metrics/mAP_0,5:0,95	val/box_loss	val/cls_loss	val/dfl_loss
0	1,428	2,1597	1,5387	0,51027	0,51317	0,46543	0,27051	1,2922	1,5627	1,7396
1	1,328	1,2761	1,4157	0,5576	0,53935	0,49157	0,28497	1,3018	1,5451	1,7104
2	1,3728	1,2922	1,4349	0,50869	0,36756	0,35112	0,17678	1,5845	2,0221	1,9868
3	1,4546	1,377	1,5059	0,69141	0,42283	0,42094	0,21161	1,6286	1,8714	2,0173
4	1,4886	1,3987	1,5087	0,61884	0,41929	0,39948	0,20886	1,5651	2,145	1,9816
5	1,4809	1,3497	1,5214	0,55236	0,51892	0,46008	0,24445	1,5608	1,8544	1,9852
6	1,4814	1,34	1,5254	0,53877	0,45421	0,43544	0,2333	1,5062	1,6511	1,9415
7	1,4546	1,3372	1,5049	0,52327	0,55038	0,49654	0,27172	1,4644	1,4322	1,889
8	1,4484	1,2624	1,4911	0,65966	0,56262	0,55948	0,30221	1,4301	1,3433	1,8327
9	1,4102	1,1859	1,4731	0,54413	0,55916	0,54247	0,30022	1,4203	1,2574	1,8395
10	1,3824	1,1464	1,5739	0,51141	0,56035	0,5078	0,28815	1,4207	1,4487	1,8691
11	1,37	1,1443	1,5719	0,69019	0,51386	0,53414	0,29754	1,3883	1,2335	1,8364
12	1,3504	1,0983	1,5615	0,62484	0,64146	0,61434	0,34539	1,3808	1,1006	1,8108
13	1,3343	1,0531	1,5431	0,72264	0,52118	0,55372	0,30166	1,4451	1,2484	1,8526
14	1,3419	1,0382	1,5361	0,66377	0,58095	0,55316	0,32392	1,3797	1,1647	1,8248
15	1,3153	0,98287	1,5211	0,68701	0,63967	0,62087	0,36747	1,3012	1,0372	1,7185
16	1,2814	0,95171	1,5008	0,63764	0,61538	0,61935	0,34836	1,3386	1,0586	1,7374
17	1,2703	0,94035	1,4905	0,75828	0,61422	0,63419	0,36642	1,3047	1,0843	1,7152
18	1,2632	0,90346	1,4777	0,65529	0,64272	0,63745	0,36829	1,2863	0,96933	1,7038
19	1,2252	0,86589	1,4571	0,58889	0,70989	0,6538	0,3765	1,3007	0,98258	1,7266
20	1,213	0,83723	1,4456	0,69938	0,65371	0,64492	0,38607	1,2578	0,93641	1,6661
21	1,1949	0,80958	1,4409	0,56764	0,71061	0,64898	0,38972	1,2548	0,91891	1,6644
22	1,1743	0,8051	1,4235	0,59066	0,71261	0,67541	0,39722	1,2351	0,90048	1,6662
23	1,1467	0,75292	1,3972	0,72379	0,69157	0,67205	0,39951	1,2374	0,84276	1,6717
24	1,1337	0,74148	1,3959	0,61309	0,72552	0,67104	0,40546	1,2176	0,8591	1,6557

Gelan-e modelinin, 25 epoktaki Karışıklık Matrisi Şekil 4.24'te gösterildiği üzere sol üst kenar modelin eğitiminin tamamlanmasından sonraki sınıf tahmin değerlerini, alt orta kenar gerçekte olan sınıf değerlerini göstermektedir. Karışıklık Matrisinde; *baret 0,90 oranında doğru tahmin edilmiş, 0,01 kulaklık, 0,02 kulaklık yok, 0,01 insan olarak yanlış tahmin edilmiş ve 0,06 oranında tespit edilememiştir.*

Baretsiz 0,36 oranında doğru tahmin edilmiş, 0,09 baret, 0,09 kulaklık yok olarak yanlış tahmin edilmiş ve 0,45 oranında tespit edilememiştir.

Eldiven 0,82 oranında doğru tahmin edilmiş, 0,18 oranında tespit edilememiştir.

Eldivensiz hiç tahmin edilememiş, 0,14 oranında eldiven olarak yanlış tahmin edilmiş, 0,86 oranında gerçekte var olmasına rağmen tespit edilememiştir.


Kulaklık 0,92 oranında doğru tahmin edilmiş, 0,02 baret, 0,02 kulaklık yok olarak yanlış tahmin edilmiş ve 0,05 oranında tespit edilememiştir.

Kulaklık yok 0,19 oranında doğru tahmin edilmiş, 0,02 baretsiz, 0,51 baret olarak yanlış tahmin edilmiş, 0,28 oranında tespit edilememiştir.

Yelek 0,84 oranında doğru tahmin edilmiş, 0,03 yeleksiz, 0,01 insan olarak yanlış tahmin edilmiş ve 0,11 oranında tespit edilememiştir.


Yeleksiz 0,83 oranında doğru tahmin edilmiş, 0,01 yelek, 0,01 baret olarak yanlış tahmin edilmiş ve 0,14 oranında tespit edilememiştir.

İnsan 0,94 oranında doğru tahmin edilmiş, 0,06 oranında tespit edilememiştir.



Şekil 4.24. Gelan-e modelinin, 25 epoktaki Karışıklık Matrisi

Gelan-e modelinin, 25 epoktaki görüntü tahminleri Şekil 4.25'te sunulmuştur. Modelin tamamen eğitilmesinden sonraki, nesne tespitindeki başarısı görülmektedir. Örnek olarak sergilenen görüntülerin tamamı test için ayrılan 155 adet görüntü içerisinde alınmıştır. Test seti olarak ayrılan görüntüler eğitim veri setinde ya da doğrulama setinde hiçbir şekilde kullanılmamıştır.



Şekil 4.25. Gelan-e modelinin, 25 epoktaki görüntü tahmin sonuçları

4.1.6. Gelan-e Versiyonu 50 Epoktaki Bulgular


Modelin eğitimi sonucunda, doğrulama seti için ayrılan 283 adet görüntü üzerinden test edilmiştir. Model mAP_{50-95} aralığında; *baret sınıfını* 0,471, *baretsiz* 0,263, *eldiven* 0,641, *eldivensiz* 0,24, *kulaklık* 0,724, *kulaklık yok* 0,254, *yekek* 0,526, *yekeksiz* 0,266, *insan* 0,585 ve *tüm sınıfları* 0,441 olarak tespit etmiştir. Çizelge 4.9’da detaylar sunulmuştur.

Çizelge 4.9. Eğitilen Gelan-e modelinin, 50 epoktaki doğrulama sonuçları

Sınıflar	Görüntüler	Nesneler	P	R	mAP_{50}	mAP_{50-95}
Hepsi	283	937	0,678	0,723	0,724	0,441
Baret	283	232	0,749	0,879	0,813	0,471
Baretsiz	283	11	0,571	0,455	0,7	0,263
Eldiven	283	109	0,854	0,862	0,879	0,641
Eldivensiz	283	7	0,494	0,429	0,472	0,24
Kulaklık	283	63	0,887	1	0,988	0,724
Kulaklık Yok	283	43	0,343	0,419	0,383	0,254
Yekek	283	141	0,853	0,794	0,882	0,526
Yekeksiz	283	90	0,579	0,766	0,547	0,266
İnsan	283	241	0,774	0,908	0,85	0,585


Modelin PR (Kesinlik-Duyarlılık) eğrisi PR eğrisinin sağ üst yöne doğru olması, P ve R arasındaki dengenin uyumlu olduğunu, dolayısıyla başarının yüksek olduğu anlamına gelmektedir. Çizelge 4.9 ve Şekil 4.26’da gelan-e modelinin, 50 epoktaki PR eğrisinde okunacağı üzere $mAP@0,5$

değeri için; tüm sınıflar 0,724, baret 0,813, baretsiz 0,700, eldiven 0,879, eldivensiz 0,472, kulaklık 0,988, kulaklık yok 0,383, yelek 0,882, yeleksiz 0,547, insan 0,850 olarak bulunmuştur.



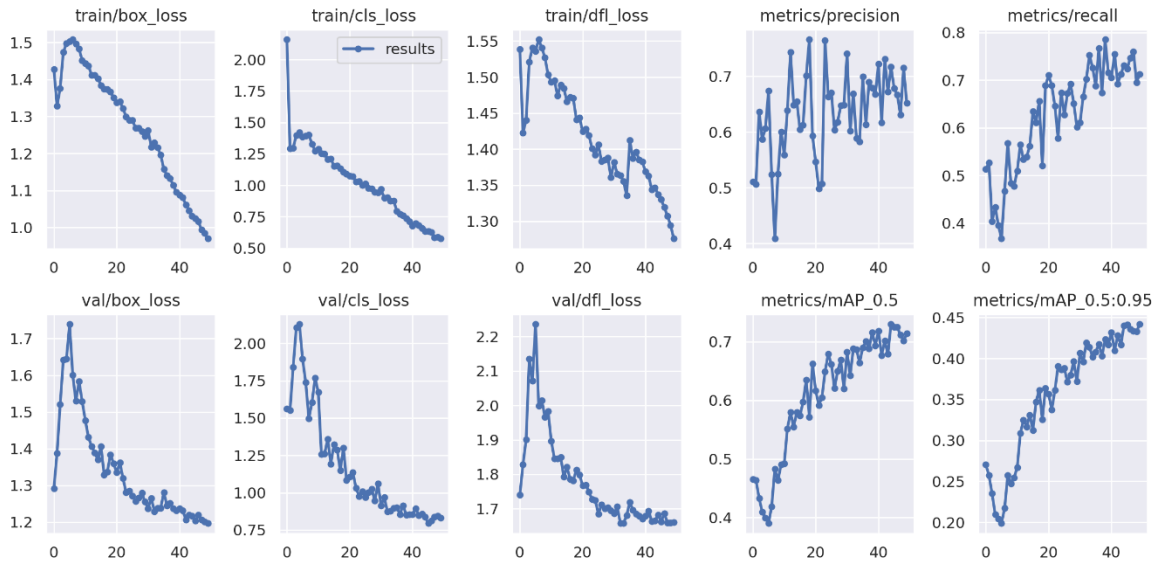
Şekil 4.26. Gelan-e modelinin, 50 epoktaki PR Eğrisi

P ve R değerlerinin harmonik ortalaması olan $F1$ -Güven eşiği eğrisi grafiği Şekil 4.27'de sunulmuştur. Grafiğin y eksenini güven eşiklerini, x eksenini $F1$ puanlarını, belirtmektedir. Gelan-e modelinin, 50 epok sonrası, 0,251 güven eşiğinde, $F1$ puanı 0,70 olarak bulunmuştur.



Şekil 4.27. Gelan-e modelinin, 50 epoktaki F1-Güven Eşiği Eğrisi

Şekil 4.28’de sunulan tüm grafikler, modelin eğitim esnasındaki kayıplarını (loss) ve performans metriklerini takip etmek amacıyla oluşturulmuştur. Ayrıca grafikler içerisinde doğrulama süreçlerine ait metrikler ile öğrenme başarıları görülebilmektedir.



Şekil 4.28. Gelan-e modelinin, 50 epoktaki performans metriği grafikleri


Üst sırada yer almakta olan “train/box_loss” sınırlayıcı kutuların süreç içerisindeki eğitimini göstermektedir. İlk epokta 1,428 olan değeri, son epokta 0,96971’e kadar düşmüştür. Rakamlar kaybın azaldığını göstermekte böylece modelin nesnelere konumlandırma başarısının yükseldiği anlaşılmaktadır. “train/cls_loss” sınıf tahmini kaybını göstermektedir. Grafikte azalan bir eğri; model tarafından nesnelere sınıfları, doğru olarak tahmin ederek öğrendiğini açıklamaktadır. “train/df_loss” veri kümesinin dengesiz sınıflandırma halinin kayıp fonksiyonunu açıklamaktadır. Aynı zamanda modelin sınıf nesnelere konumlandırmak için kullandığı sınırlayıcı kutuların hedefine odaklanma durumunu da göstermektedir. Sınıf dağılımı dengeli olmadığı için grafik dalgalı bir biçimdedir. “metrics/precision” ve “metrics/recall” grafiğinde modelin epok sayısına bağlı olarak tahmin performansının iyileştiği görülmektedir.

Çizelge 4.10. Gelan-e modelinin, 50 epoktaki performans metriklerinin sayıları

epoch	train/box_loss	train/cls_loss	train/df_loss	metrics/precision	metrics/recall	metrics/mAP_0.5	metrics/mAP_0.5@0.95	val/box_loss	val/cls_loss	val/df_loss
0	1,428	2,1597	1,5387	0,51027	0,51317	0,46543	0,27051	1,2922	1,5627	1,7396
1	1,328	1,2933	1,4227	0,5061	0,52679	0,46378	0,25733	1,3881	1,5506	1,8283
2	1,3763	1,2961	1,4404	0,63658	0,40411	0,43317	0,235	1,5203	1,8407	1,9012
3	1,4735	1,3983	1,5214	0,58733	0,43391	0,40942	0,20951	1,6425	2,1045	2,1345
4	1,497	1,421	1,541	0,6063	0,39551	0,3999	0,20411	1,6447	2,1284	2,0707
5	1,5021	1,3861	1,536	0,67395	0,36771	0,39013	0,1987	1,7392	1,8944	2,236
6	1,508	1,3947	1,5523	0,52393	0,46777	0,41888	0,21743	1,6003	1,7392	1,9994
7	1,4955	1,3992	1,5407	0,40859	0,56808	0,48258	0,25736	1,5295	1,4966	2,0143
8	1,4827	1,3287	1,5269	0,52512	0,48365	0,4635	0,24752	1,5836	1,6052	1,9663
9	1,4518	1,2742	1,5031	0,60064	0,47756	0,49012	0,25454	1,5294	1,7693	1,9831
10	1,4435	1,2892	1,4934	0,55869	0,5096	0,49185	0,26685	1,4774	1,6722	1,8968
11	1,4372	1,2537	1,4956	0,63918	0,56509	0,55156	0,30864	1,4314	1,2566	1,8457
12	1,4118	1,2479	1,4741	0,7434	0,5338	0,5793	0,3249	1,4066	1,2604	1,8451
13	1,412	1,2075	1,4894	0,64876	0,53881	0,55452	0,3167	1,3894	1,3591	1,8503
14	1,4026	1,2108	1,4844	0,65476	0,56219	0,57989	0,3309	1,3701	1,1931	1,7923
15	1,3842	1,1534	1,4661	0,60473	0,63446	0,57352	0,31249	1,4066	1,3229	1,8212
16	1,3746	1,1579	1,4725	0,61289	0,61138	0,59697	0,34706	1,3288	1,2881	1,7861
17	1,3726	1,1344	1,471	0,70122	0,6558	0,63466	0,36154	1,3364	1,1492	1,7819
18	1,3667	1,107	1,4412	0,76623	0,52051	0,57165	0,32551	1,3843	1,2991	1,8127
19	1,3507	1,089	1,4437	0,59357	0,68858	0,66238	0,36379	1,3603	1,0849	1,7985
20	1,3381	1,0733	1,4249	0,54684	0,71014	0,61676	0,35644	1,3352	1,107	1,7675
21	1,3401	1,0721	1,4283	0,4988	0,68899	0,59158	0,33733	1,3624	1,1367	1,7693
22	1,3219	1,0268	1,4192	0,50755	0,64571	0,6046	0,36133	1,3193	1,0319	1,7488
23	1,2988	1,0316	1,4007	0,76454	0,57823	0,64873	0,39029	1,2809	0,97714	1,7273
24	1,2901	0,99841	1,392	0,66387	0,67405	0,67905	0,38659	1,285	1,0085	1,7249
25	1,2893	1,0109	1,406	0,6709	0,6275	0,66167	0,38799	1,2719	0,97	1,6852
26	1,2687	0,97777	1,3832	0,60398	0,67257	0,6203	0,37118	1,2578	1,0021	1,7118
27	1,2687	0,97179	1,3852	0,61821	0,69181	0,64969	0,37999	1,2665	1,0249	1,7
28	1,2596	0,94765	1,3882	0,64747	0,65138	0,66891	0,39626	1,2797	0,94485	1,7034
29	1,2461	0,94061	1,3606	0,64827	0,602	0,61949	0,372	1,2552	1,0601	1,6943
30	1,2623	0,96912	1,382	0,74083	0,61139	0,68185	0,40643	1,2374	0,91415	1,6862
31	1,2171	0,89756	1,3658	0,60204	0,66499	0,64232	0,39571	1,2655	0,96781	1,7058
32	1,2288	0,90203	1,3638	0,66839	0,70193	0,68786	0,41936	1,2295	0,87566	1,658
33	1,2164	0,87747	1,3553	0,58862	0,75234	0,68654	0,41394	1,2387	0,87765	1,6575
34	1,1963	0,87729	1,3354	0,58233	0,72638	0,66387	0,40182	1,2385	0,89579	1,6805
35	1,1573	0,79505	1,4126	0,69937	0,68849	0,69009	0,40805	1,2812	0,90122	1,7193
36	1,14	0,77251	1,387	0,61353	0,76666	0,70027	0,41761	1,2454	0,85597	1,6964
37	1,1328	0,75805	1,3962	0,69018	0,67318	0,68769	0,40336	1,2513	0,91457	1,685
38	1,1139	0,73584	1,3856	0,67917	0,78542	0,71576	0,42328	1,2372	0,85136	1,6789
39	1,0951	0,71246	1,3823	0,66807	0,71576	0,69338	0,41704	1,2321	0,85592	1,6709
40	1,0874	0,677	1,3689	0,72268	0,70544	0,71851	0,43178	1,2377	0,85589	1,6798
41	1,0808	0,69768	1,3629	0,61653	0,75498	0,67635	0,40983	1,2324	0,89382	1,694
42	1,0616	0,68282	1,3437	0,73097	0,69258	0,70118	0,42802	1,207	0,84921	1,663
43	1,0457	0,65689	1,3469	0,67238	0,71286	0,679	0,41657	1,2204	0,85801	1,6654
44	1,0308	0,63357	1,3373	0,71696	0,7313	0,72976	0,44027	1,2169	0,837	1,6824
45	1,0246	0,63293	1,33	0,67827	0,7238	0,72468	0,44139	1,2042	0,7946	1,6621
46	1,0158	0,62835	1,3191	0,66685	0,74661	0,72441	0,43582	1,2196	0,81255	1,6862
47	0,99353	0,58246	1,3074	0,6306	0,76007	0,71153	0,43379	1,2067	0,83855	1,6593
48	0,98485	0,58662	1,2943	0,71526	0,6949	0,70123	0,43295	1,2014	0,84346	1,6593
49	0,96971	0,57526	1,2758	0,65217	0,71301	0,7138	0,44192	1,1969	0,83049	1,6604

Alt sırada yer almakta “val/box_loss”, “val/cls_loss” ve “val/df_l_loss” doğrulama grafiklerinin, 3’üde birbirleri ile uyumlu eğriye sahip olup modelin öğrenme performansının bir önceki 25 epoktan daha fazla, artan bir eğilimde olduğu görülmektedir. Grafiklere ait değerler **Hata! Başyuru kaynağı bulunamadı.**’da sunulmuştur.

Gelan-e modelinin, 50 epoktaki Karışıklık Matrisi Şekil 4.29’da gösterildiği üzere sol üst kenar modelin eğitiminin tamamlanmasından sonraki sınıf tahmin değerlerini, alt orta kenar gerçekte olan sınıf değerlerini göstermektedir. Karışıklık Matrisinde; *baret* 0,88 oranında doğru tahmin edilmiş, 0,01 kulaklık, 0,01 kulaklık yok, 0,01 insan olarak yanlış tahmin edilmiş ve 0,09 oranında tespit edilememiştir.



Şekil 4.29. Gelan-e modelinin, 50 epoktaki Karışıklık Matrisi

Baretsiz 0,45 oranında doğru tahmin edilmiş, 0,18 baret olarak yanlış tahmin edilmiş ve 0,36 oranında tespit edilememiştir.

Eldiven 0,88 oranında doğru tahmin edilmiş, 0,12 oranında tespit edilememiştir.

Eldivensiz bu sefer 0,43 oranında doğru tahmin edilmiş ve 0,57 oranında tespit edilememiştir.

Kulaklık tam olarak tespit edilmiştir.


Kulaklık yok 0,42 oranında doğru tahmin edilmiş, 0,02 baretsiz, 0,44 baret olarak yanlış tahmin edilmiş, 0,12 oranında tespit edilememiştir.

Yelek 0,79 oranında doğru tahmin edilmiş, 0,05 yeleksiz, 0,01 baret olarak yanlış tahmin edilmiş ve 0,16 oranında tespit edilememiştir.

Yeleksiz 0,76 oranında doğru tahmin edilmiş, 0,01 oranında baret olarak yanlış tahmin edilmiş ve 0,23 oranında tespit edilememiştir.

İnsan 0,90 oranında doğru tahmin edilmiş, 0,10 oranında tespit edilememiştir.

Gelan-e modelinin, 50 epoktaki görüntü tahminleri Şekil 4.30'da sunulmuştur. Modelin tamamen eğitilmesinden sonraki, nesne tespitindeki başarısı görülmektedir. Örnek olarak sergilenen görüntülerin tamamı test için ayrılan 155 adet görüntü içerisinde alınmıştır. Test seti olarak ayrılan görüntüler eğitim veri setinde ya da doğrulama setinde hiçbir şekilde kullanılmamıştır.



Şekil 4.30. Gelan-e modelinin, 50 epoktaki görüntü tahmin sonuçları


4.1.7. Gelan-e Versiyonu 75 Epoktaki Bulgular

Modelin eğitimi sonucunda, doğrulama seti için ayrılan 283 adet görüntü üzerinden test edilmiştir. Model mAP_{50-95} aralığında; *baret sınıfını 0,473, baretsiz 0,369, eldiven 0,581, eldivensiz 0,158, kulaklık 0,66, kulaklık yok 0,2, yekek 0,538, yeleksiz 0,317, insan 0,572 ve tüm sınıfları 0,43* olarak tespit etmiştir. Çizelge 4.11'de detaylar sunulmuştur.

Çizelge 4.11. Eğitilen Gelan-e modelinin, 75 epoktaki doğrulama sonuçları


Sınıflar	Görüntüler	Nesneler	P	R	mAP50	mAP50-95
Hepsi	283	937	0,685	0,737	0,729	0,43
Baret	283	232	0,769	0,879	0,818	0,473
Baretsiz	283	11	0,47	0,727	0,672	0,369
Eldiven	283	109	0,818	0,826	0,841	0,581
Eldivensiz	283	7	0,544	0,571	0,616	0,158
Kulaklık	283	63	0,882	0,937	0,962	0,66
Kulaklık Yok	283	43	0,511	0,116	0,321	0,2
Yelek	283	141	0,827	0,887	0,898	0,538
Yeleksiz	283	90	0,605	0,767	0,597	0,317
İnsan	283	241	0,74	0,925	0,833	0,572

Çizelge 4.11 ve Şekil 4.31’de gelan-e modelinin, 75 epoktaki PR eğrisinde okunacağı üzere $mAP@0,5$ değeri için; tüm sınıflar 0,729, baret 0,818, baretsiz 0,672, eldiven 0,841, eldivensiz 0,616, kulaklık 0,962, kulaklık yok 0,321, yelek 0,898, yeleksiz 0,597, insan 0,833 olarak bulunmuştur.



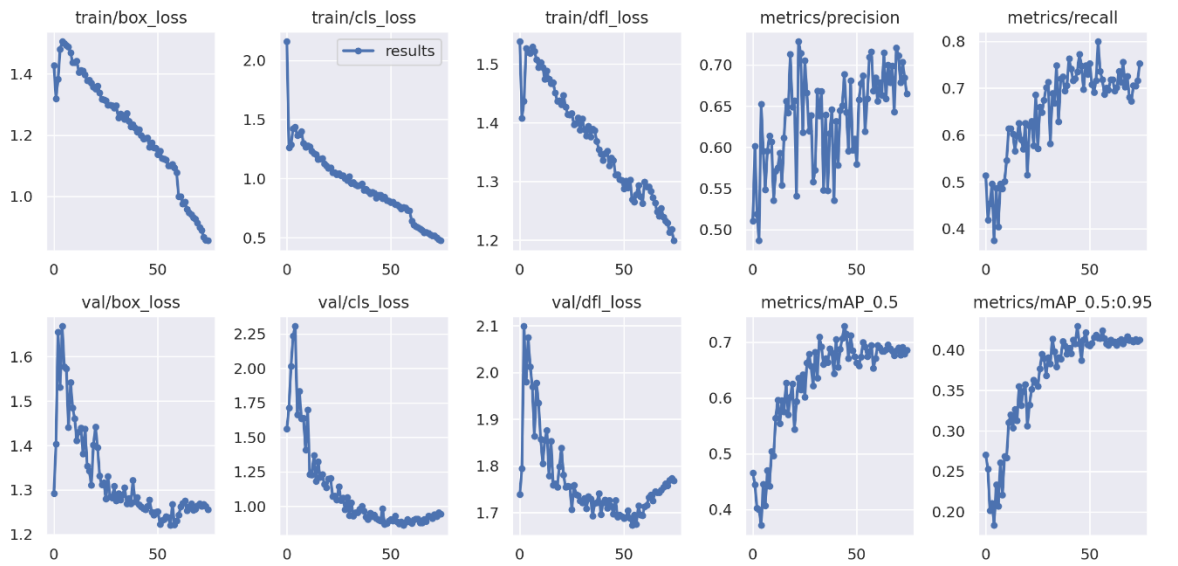
Şekil 4.31. Gelan-e modelinin, 75 epoktaki PR Eğrisi

P ve R değerlerinin harmonik ortalaması olan $F1$ -Güven eşliği eğrisi grafiği Şekil 4.32’de sunulmuştur. Grafiğin y eksenini güven eşiklerini, x eksenini $F1$ puanlarını, belirtmektedir. Gelan-e modelinin, 75 epok sonrası, 0,309 güven eşliğinde, $F1$ puanı 0,69 olarak bulunmuştur.



Şekil 4.32. Gelan-e modelinin, 75 epoktaki F1-Güven Eşiği Eğrisi

Şekil 4.33'de sunulan tüm grafikler, modelin eğitim esnasındaki kayıplarını (loss) ve performans metriklerini takip etmek amacıyla oluşturulmuştur. Ayrıca grafikler içerisinde doğrulama süreçlerine ait metrikler ile öğrenme başarıları görülebilmektedir.




Şekil 4.33. Gelan-e modelinin, 75 epoktaki performans metriği grafikleri

Üst sırada yer almakta olan “train/box_loss” sınırlayıcı kutuların süreç içerisindeki eğitimini göstermektedir. İlk epokta 1,428 olan değeri, son epokta 0,85533’a kadar düşmüştür. Rakamlar kaybın azaldığını göstermekte böylece modelin nesnelere konumlandırma başarısının yükseldiği anlaşılmaktadır. “train/cls_loss” sınıf tahmini kaybını göstermektedir. Grafikte azalan bir eğri; model tarafından nesnelere sınıfları, doğru olarak tahmin ederek öğrendiğini açıklamaktadır. “train/dflloss” veri kümesinin dengesiz sınıflandırma halinin kayıp fonksiyonunu açıklamaktadır. Aynı zamanda modelin sınıf nesnelere konumlandırmak için kullandığı sınırlayıcı kutuların hedefine odaklanma durumunu da göstermektedir. Sınıf dağılımı dengeli olmamasına rağmen grafikte düzelme olmuştur. “metrics/precision” ve “metrics/recall” grafiğinde modelin epok sayısına bağlı olarak tahmin performansının iyileştiği görülmektedir.

Alt sırada yer almakta “val/box_loss”, “val/cls_loss” ve “val/dflloss” doğrulama grafiklerinin, 3’üde birbirleri ile uyumlu eğriye sahiptir. Modelin öğrenme performansının bir önceki 50 epoktan daha fazla, artan bir eğilimde olduğu görülmektedir.

Grafiklere ait değerler Ek C. Gelan-e Modelinin, 75 Epoktaki Performans Metriklerinin Sayıları kısmında sunulmuştur.



Şekil 4.34. Gelan-e modelinin, 75 epoktaki Karışıklık Matrisi

Gelan-e modelinin, 75 epoktaki Karışıklık Matrisi Şekil 4.34'te gösterildiği üzere sol üst kenar modelin eğitiminin tamamlanmasından sonraki sınıf tahmin değerlerini, alt orta kenar gerçekte olan sınıf değerlerini göstermektedir.

Karışıklık Matrisinde; *baret 0,90 oranında doğru tahmin edilmiş, 0,01 kulaklık, 0,01 insan olarak yanlış tahmin edilmiş ve 0,08 oranında tespit edilememiştir.*

Baretsiz 0,82 oranında doğru tahmin edilmiş, 0,09 baret olarak yanlış tahmin edilmiş ve 0,09 oranında tespit edilememiştir.

Eldiven 0,85 oranında doğru tahmin edilmiş ve 0,15 oranında tespit edilememiştir.

Eldivensiz 0,57 oranında doğru tahmin edilmiş, 0,14 eldiven olarak yanlış tahmin edilmiş ve 0,29 oranında tespit edilememiştir.


Kulaklık 0,94 oranında doğru tahmin edilmiş, 0,02 kulaklık yok olarak yanlış tespit edilmiş ve 0,05 oranında tespit edilememiştir.

Kulaklık yok 0,14 oranında doğru tahmin edilmiş, 0,02 baretsiz, 0,51 baret olarak yanlış tahmin edilmiş, 0,33 oranında tespit edilememiştir.

Yelek 0,89 oranında doğru tahmin edilmiş, 0,01 yeleksiz, 0,01 insan olarak yanlış tahmin edilmiş ve 0,10 oranında tespit edilememiştir.

Yeleksiz 0,82 oranında doğru tahmin edilmiş, 0,01 baret, 0,02 yelek olarak yanlış tahmin edilmiş ve 0,14 oranında tespit edilememiştir.

İnsan 0,93 oranında doğru tahmin edilmiş, 0,07 oranında tespit edilememiştir.



Şekil 4.35. Gelan-e modelinin, 75 epoktaki görüntü tahmin sonuçları

Gelan-e modelinin, 75 epoktaki görüntü tahminleri Şekil 4.35'te sunulmuştur. Modelin tamamen eğitilmesinden sonraki, nesne tespitindeki başarısı görülmektedir. Örnek olarak sergilenen görüntülerin tamamı test için ayrılan 155 adet görüntü içerisinde alınmıştır. Test seti olarak ayrılan görüntüler eğitim veri setinde ya da doğrulama setinde hiçbir şekilde kullanılmamıştır.

4.1.8. Gelan-e Versiyonu 100 Epoktaki Bulgular


Modelin eğitimi sonucunda, doğrulama seti için ayrılan 283 adet görüntü üzerinden test edilmiştir. Model *mAP50-95* aralığında; *baret sınıfını 0,457, baretsiz 0,279, eldiven 0,598, eldivensiz 0,266, kulaklık 0,7, kulaklık yok 0,191, yelek 0,526, yeleksiz 0,281, insan 0,583 ve tüm sınıfları 0,431* olarak tespit etmiştir. Çizelge 4.12'de detaylar sunulmuştur.

Çizelge 4.12. Eğitilen Gelan-e modelinin, 100 epoktaki doğrulama sonuçları


Sınıflar	Görüntüler	Nesneler	P	R	mAP50	mAP50-95
Hepsi	283	937	0,679	0,772	0,737	0,431
Baret	283	232	0,759	0,888	0,82	0,457
Baretsiz	283	11	0,505	0,727	0,648	0,279
Eldiven	283	109	0,795	0,807	0,858	0,598
Eldivensiz	283	7	0,772	0,714	0,745	0,266
Kulaklık	283	63	0,848	0,968	0,985	0,7
Kulaklık Yok	283	43	0,318	0,233	0,306	0,191
Yelek	283	141	0,841	0,851	0,879	0,526
Yeleksiz	283	90	0,539	0,806	0,56	0,281
İnsan	283	241	0,732	0,95	0,83	0,583

Çizelge 4.12 ve Şekil 4.36'da gelan-e modelinin, 100 epoktaki PR eğrisinde okunacağı üzere *mAP@0,5* değeri için; *tüm sınıflar 0,737, baret 0,820, baretsiz 0,648, eldiven 0,858, eldivensiz 0,745, kulaklık 0,985, kulaklık yok 0,306, yelek 0,879, yeleksiz 0,560, insan 0,830* olarak bulunmuştur.

P ve R değerlerinin harmonik ortalaması olan *F1-Güven eşiği* eğrisi grafiği Şekil 4.37'de sunulmuştur. Grafiğin y eksenini güven eşiklerini, x eksenini F1 puanlarını, belirtmektedir. Gelan-e modelinin, 100 epok sonrası, *0,184 güven eşiğinde, F1 puanı 0,72* olarak bulunmuştur.

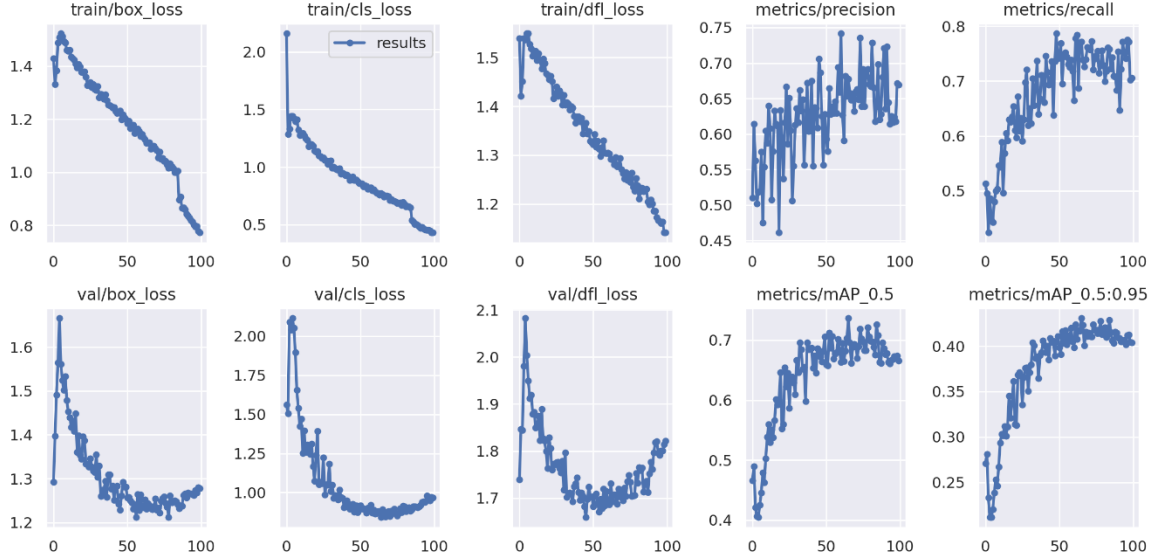


Şekil 4.36. Gelan-e modelinin, 100 epoktaki PR Eğrisi



Şekil 4.37. Gelan-e modelinin, 100 epoktaki F1-Güven Eşiği Eğrisi

Şekil 4.38’de sunulan tüm grafikler, modelin eğitim esnasındaki kayıplarını (loss) ve performans metriklerini takip etmek amacıyla oluşturulmuştur. Ayrıca grafikler içerisinde doğrulama süreçlerine ait metrikler ile öğrenme başarıları görülebilmektedir.




Şekil 4.38. Gelan-e modelinin, 100 epoktaki performans metriği grafikleri

Üst sırada yer almakta olan “train/box_loss” sınırlayıcı kutuların süreç içerisindeki eğitimini göstermektedir. İlk epokta 1,428 olan değeri, son epokta 0,7726’ye kadar düşmüştür. Rakamlar kaybın azaldığını göstermekte böylece modelin nesnelere konumlandırma başarısının yükseldiği anlaşılmaktadır. “train/cls_loss” sınıf tahmini kaybını göstermektedir. Grafikte azalan bir eğri; model tarafından nesnelere sınıfları, doğru olarak tahmin ederek öğrendiğini açıklamaktadır. “train/df_l_loss” veri kümesinin dengesiz sınıflandırma halinin kayıp fonksiyonunu açıklamaktadır. Aynı zamanda modelin sınıf nesnelere konumlandırmak için kullandığı sınırlayıcı kutuların hedefine odaklanma durumunu da göstermektedir. Sınıf dağılımı dengeli olmamasına rağmen grafikte düzleşme olmuştur. “metrics/precision” ve “metrics/recall” grafiğinde modelin epok sayısına bağlı olarak tahmin performansının iyileştiği görülmektedir.

Alt sırada yer almakta “val/box_loss”, “val/cls_loss” ve “val/df_l_loss” doğrulama grafiklerinin, 3’üde birbirleri ile uyumlu eğriye sahiptir. Modelin öğrenme performansının bir önceki 75 epoktan daha fazla, artan bir eğilimde olduğu görülmektedir.

Grafiklere ait değerler Ek D. Gelan-e Modelinin, 100 Epoktaki Performans Metriklerinin Sayıları kısmında sunulmuştur.

Gelan-c modelinin, 100 epoktaki Karışıklık Matrisi Şekil 4.39’da gösterildiği üzere sol üst kenar modelin eğitiminin tamamlanmasından sonraki sınıf tahmin değerlerini, alt orta kenar gerçekte olan sınıf değerlerini göstermektedir.



Şekil 4.39. Gelan-e modelinin, 100 epoktaki Karışıklık Matrisi

Karışıklık Matrisinde; baret 0,89 oranında doğru tahmin edilmiş, 0,01 kulaklık, 0,03 kulaklık yok, 0,01 insan olarak yanlış tahmin edilmiş ve 0,06 oranında tespit edilememiştir.

Baretsiz 0,64 oranında doğru tahmin edilmiş, 0,18 baret olarak yanlış tahmin edilmiş ve 0,18 oranında tespit edilememiştir.

Eldiven 0,81 oranında doğru tahmin edilmiş, 0,02 kulaklık olarak yanlış tahmin edilmiş ve 0,17 oranında tespit edilememiştir.

Eldivensiz 0,43 oranında doğru tahmin edilmiş, 0,14 eldiven olarak yanlış tahmin edilmiş ve 0,43 oranında tespit edilememiştir.

Kulaklık 0,97 oranında doğru tahmin edilmiş ve 0,03 oranında tespit edilememiştir.

Kulaklık yok 0,21 oranında doğru tahmin edilmiş, 0,49 baret, 0,05 baretsiz,0,02 kulaklık olarak yanlış tahmin edilmiş, 0,23 oranında tespit edilememiştir.

Yelek 0,83 oranında doğru tahmin edilmiş, 0,03 yeleksiz, 0,01 insan olarak yanlış tahmin edilmiş ve 0,13 oranında tespit edilememiştir.

Yeleksiz 0,78 oranında doğru tahmin edilmiş, 0,01 baret, 0,01 yelek olarak yanlış tahmin edilmiş ve 0,20 oranında tespit edilememiştir.

İnsan 0,93 oranında doğru tahmin edilmiş, 0,07 oranında tespit edilememiştir.

Gelan-e modelinin, 100 epoktaki görüntü tahminleri Şekil 4.40’de sunulmuştur. Modelin tamamen eğitilmesinden sonraki, nesne tespitindeki başarısı görülmektedir. Örnek olarak sergilenen görüntülerin tamamı test için ayrılan 155 adet görüntü içerisinde alınmıştır. Test seti olarak ayrılan görüntüler eğitim veri setinde ya da doğrulama setinde hiçbir şekilde kullanılmamıştır.



Şekil 4.40. Gelan-e modelinin, 100 epoktaki görüntü tahmin sonuçları

4.2. Tartışma

Çalışmada kullanılan YOLOv9 diğer tek aşamalı ve iki aşamalı derin öğrenme tabanlı nesne algılama dedektörlerine göre daha başarılı sonuçlar vermektedir.

Şekil 3.6’da YOLOv9’un diğer modeller ile karşılaştırılmasında görüleceği üzere; YOLOv5, YOLOv6, YOLOv7 ve YOLOv8 vb. modeller genel olarak, parametre sayısının artışı ile doğru orantılı olarak AP değerleri yükselmektedir.

YOLOv9’un düşük parametre sayılarında dahi diğer modellere göre yüksek doğruluğa ulaşabilmesi; daha kullanışlı ve verimli olduğunu göstermektedir. Grafikte YOLOv5 ve YOLOv6 modellerinin doğruluk seviyelerinin düşük olduğu, YOLOv8 modelinin ise yüksek doğruluğu ulaşabilmesi ancak parametre sayılarının artması ile mümkün olduğu, YOLOv9 modelininse daha az parametre ile yüksek doğruluğu yakaladığı görülmektedir.

Kullanılan parametre sayıları düşük iken bu yüksek doğruluğa ulaşması; aynı zamanda modelin hızlı bir şekilde reaksiyon göstermesini ve gerçek zamanlı tespitlerde bulunabileceğine işaretler.

Bahse konu bu durum, GELAN ve PGI mimarilerinin modelin tasarımında yenilikçi çözümler sunmasından kaynaklanmaktadır.

YOLOv9 modelinin çalışmada seçilmesinin sebebi, baret kullanımını sürekli surette kontrol altında tutarak, travmatik beyin yaralanmalarına engel olmada etkin bir rol oynayabileceği değerlendirilmiştir. Aynı zamanda diğer KDD donanımlarının tespiti de bu çalışmada irdelenmiştir.

Bilgisayarlı görü ile nesne tespitinde temel materyal görüntü verileridir. Modelin eğitimi ve doğrulaması için ayrılan görüntü verisinin kalitesi ve amaca uygun olarak gerçek yaşamı yansıtacak şekilde seçilmesi büyük önem arz etmektedir. Fakat özel olarak oluşturulacak veri kümesi görüntülerinin, özel mülke ya da insanlara ait olmasından ötürü telif hakkı ve edinim ücreti önemli bir engel olarak ortaya çıkmaktadır. Veri kümesi oluşturmadaki zorluklar aşılamadığında açık kaynaklarda mevcut görüntülerden faydalanılmaktadır.

Detaylı inceler sonucunda, nesne tespiti için tezin amacına uygun veri kümelerinin Roboflow Universe internet sitesinde yer aldığı değerlendirilmiştir.

Modelin eğitimi için seçilen 1. Veri seti çalışmanın ana görüntü verilerini oluşturmakta olup, baret, baret yok, insan, yelek ve yelek yok sınıflarından oluşmaktadır. Veri kümesindeki en büyük payı %36'lık oranla insan ve %33 oranı ile baret sınıfı kaplamaktadır.

2. Veri seti KKD donanımlarından, eldiven kullanılıp kullanılmadığının tespitini ve modelin genel tahmin değerlendirmesindeki başarısına etkisini görmek amacıyla eklenmiştir. Veri seti %93 eldiven sınıfı ve %7 pay ile eldivensiz sınıfı görüntülerden oluşmaktadır.

3. Veri seti de yine 2. Veri setindeki benzeri amaçlar için seçilmiş, %46'sı kulaklık, %54'ü kulaklık yok sınıftan oluşmaktadır.

Eğitim için 3 farklı veri seti birleştirilip tek veri seti oluşturulmuştur. Oluşan veri seti Roboflow uygulaması üzerinden %79'u eğitim, %13'ü doğrulama ve %7 test olmak üzere bölünmüştür.

YOLOv9 modelinin geliştiricileri tarafından sunulan gelan-c ve gelan-e modellerinden bir seçim yapabilmek için versiyonlar 25, 50, 75, 100 epokluk eğitime tabi tutularak sonuçları karşılaştırılmıştır.

Modeli çalıştırmak için Google Colab platformu kullanılmıştır. Platform bulut tabanlı olarak çalışmasının yanında, kullanıcılarına GPU'ları ile ön plana çıkan sanal bilgisayarlar sunmaktadır. Platformda mevcut T4 16 GB, L4 24 GB ve A100 40 GB'lardan L4 GPU seçilmiştir.

Çalışmada yüksek kapasiteli GPU'lara erişimde zorluk yaşanmıştır. Google Colab platformu üzerinden T4 GPU'ya erişim ücretsiz olmasına rağmen bağlantı her zaman sağlanılamayıp kısıtlanmıştır. Uzun süreli eğitimler esnasında GPU'dan kopmalar neticesinde çalışmalar tamamlanamamıştır. Bu durumu aşmak için ücretli versiyonu kullanılmış ve daha yüksek kapasiteli olan L4 GPU seçilmiştir. T4 GPU'ya göre yüksek kapasitesinden dolayı eğitimler daha kısa sürede tamamlanmıştır.

Modelin eğitimi esnasında geliştiriciler tarafından sunulan kodlardan “data.yaml” manuel olarak açılıp eğitim, doğrulama ve test resimlerinin kaydedildiği yolun belirtilmesi gerekmekte aksi halde kod çalışmamaktadır.

Gelan-c ve gelan-e versiyonun 25, 50, 75, 100 epoktaki eğitim sonuçları ile P , R , $F-1$ Puanı ve mAP değerleri detaylı olarak incelenmiştir.

Gelan-c versiyonun 100 epok sonucundaki tüm sınıflar için $F-1$ puan, P , R , $mAP50$ ve $mAP50-95$ değerleri sırasıyla 0,68, 0,645, 0,739, 0,699, 0,42’dir. Gelan-e versiyonunun ise 0,72, 0,679, 0,772, 0,737, 0,431 olarak bulunmuştur. Görüleceği üzere gelan-e versiyonun sonuçları, gelan-c versiyonuna göre daha yüksektir. Bu yüzden gelan-e versiyonu önerilmektedir.



5. SONUÇLAR VE ÖNERİLER

İnşaat alanlarında tek aşamalı derin öğrenme tabanlı, nesne algılama dedektörleri; KKD tespit işlemlerinde, iki aşamalı olanlara göre daha çok tercih edilmektedir. Tek aşamalı dedektörler içerisinde ise YOLOv9 modelinin gelan-e versiyonu, GELAN ve PGI mimarileri sayesinde, diğerlerine kıyasla, düşük parametre sayılarında dahi gerçek zamanlı olarak yüksek doğruluğa ulaşabilmektedir.

Bilgisayarlı görü ile nesne tespitindeki temel materyal görüntü veri setidir. YOLOv9 modelinin eğitimi, doğrulaması ve test aşamasında, kullanılacak alana uygun gerçek yaşamı yansıtan kaliteli veri seti oluşturulması büyük önem taşımaktadır.

Hazır veri seti alınırken ya da araştırmacılar tarafından veri seti oluşturulurken; tespit edilmesi istenilen nesnelerin sınıf sayıları yeteri derecede olmalıdır. Gelan-e 75 epoktaki doğrulama sonuçlarında baretin sınıf sayısı, kulaklık yok sınıfına göre fazla olması neticesinde, mAP50 değeri 0,818 çıkarken kulaklık yok sınıfı 0,321 olarak bulunmuştur.

İnşaat alanlarında kullanılması önerilen YOLOv9 nesne tespit modelinin, karmaşık senaryolar ve farklı zorluk seviyelerindeki deneysel çalışmalarının bulguları, değerlendirme metrikleri ile incelenmiştir.

YOLOv9 modelinin gelan-e versiyonun 100 epokluk eğitime tabi tutulması sonucunda; kesinlik 0,679, duyarlılık 0,772, *F-1* puan 0,72, *mAP50* değeri 0,737, *mAP50-95* değeri 0,431 olarak bulunmuştur.

Elde edilen sonuçlar birbirleri ile karşılaştırmalı olacak şekilde detaylı analiz edilmiş ve modelin deneysel süreç esnasında, uğradığı güçlü ve zayıf yönleri sistematik bir yaklaşım tarzıyla ortaya konulmuştur. Modelin gelecekteki potansiyel iyileştirilmesinde en etkili rolü oynayan araştırmacılara, bilimsel bir referans oluşturulmaya çalışılmıştır.

Çalışmada incelediğimiz YOLOv9 nesne tespit modelinin, inşaat alanlarında, karışık senaryolar üzerindeki doğruluğu ve etkinliği kapsamlı deneysel uygulamalarla ve farklı değerlendirme metrikleri ile test edilmiştir. YOLOv9 modelinin doğruluğu ve hızı, İSG alanında hayati öneme haiz baret kullanımı yönünden değerlendirilmiştir. Yapılan deneyler neticesinde modelin travmatik beyin yaralanmaları önlemek için kullanılan baret tespit görevlerinde, yüksek bir başarı sergilediği görülmüştür. Model aynı zamanda sadece baret tespitinde değil, yelek, kulaklık ve iş sahasına yetkisiz giriş yapmaya çalışan kişilerin sınıflandırma ve tespitinde de yüksek performans sergilemiştir.

Yapay zeka destekli nesne tespit işlemlerinin en büyük avantajı, bir KKD'nin giyilip giyilmediğini tespit etmek için pahalı cihazlara, sensörlere ve çalışanın yanında bulunan gözetmenlere ihtiyaç duymaksızın tıpkı bir insan gözü gibi kullanım ihlallerini tespit edebilmesidir.

Her ne kadar İSG alanında en ideal çözümler bulunmaya çalışılsa da hayatın olağan akışı gereği hatanın yok edilmesine engel olan süreçler bulunmaktadır. Bu süreçler içerisinde, öncelikle iş güvenliği uzmanının her an bulunamamasından dolayı hatayı gözle kontrol etmesi veya kazayı tespit etmesi pek mümkün olamamaktadır. Bu aşamada kazanın veya hatanın engellenmesi için iş güvenliği uzmanı sayısını arttırmakta tam olarak çözüm sağlamayacaktır. Netice itibari ile insan hatası gerçeğine bağlı kazalar ortaya çıkacaktır. Tüm bu tedbirler, hali hazırda doğrudan etkisi olmayan güvenlik önlemleri olmakla birlikte ülkemiz açısından ciddi maliyetler oluşturmaktadırlar. İşte bu tür sebeplerden dolayı İSG alanında yapay zeka kullanılması gerekmektedir.

Ölümcül iş kazalarının ve yaralanmaların yoğunluğunu azaltarak yok etmek ve çalışma alanlarını daha güvenli hale getirebilmek için geleneksel güvenlik yöntemlerinin ötesine geçilerek sürdürülebilir ve yenilikçi çözümler üretilebilir. Yapay zeka uygulamaları riskleri, proaktif bir yaklaşımla önceden tespit ve bertaraf etmede etkin bir rol oynamaktadır. Yapay zekanın kullanılması ile çalışanların güvenliği sağlanabilecek böylelikle iş kazalarının ekonomik ve toplumsal etkileri azaltılabilecektir.

Bu tez çalışmasında yapay zeka derinlemesine irdelenmiştir, gelecekte araştırmacılara ışık tutacağı düşünülen öneriler:

- Yapay zekanın nesne tespitinde uygulanmasında en önemli bileşen görüntü verileridir. Ulusal çalışma grupları tarafından oluşturulacak her alana özgü telif hakkı ve edinim ücreti olmayan görüntü veri setleri, modellerin gelişmesinde önemli bir oynayacaktır.

- Yapay zeka tabanlı nesne tespit işlemlerinde yüksek kapasiteli GPU'lara erişimin üniversitelerde kurulacak birimlerce; araştırmacılara erişim kolaylığının sunulmasının yanında, ücretsiz olarak faydalandırılması gerekmektedir.

- Dünyada ve ülkemizde üniversitelerin bir kısmı öğrencilerine yapay zeka derslerini verdikten sonra, alanı ile ilgili dersleri göstermektedir. Bu uygulamaları sayesinde öğrencilere yapay zekayı en iyi bildikleri alanın eksikliklerini gidermede ve verimliliğini arttırmada farkındalık sunmaktadırlar. Girdiği her alanı kökünden değiştiren ya da yenilikçi çözümler sunan yapay zekayı üniversitelerden başlayarak her alandaki öğrencilere zorunlu ders olarak okutulması, mezun olduktan sonraki alanlarına yapay zekayı entegre etmelerini kolaylaştıracaktır.

- Kamu ve özel sektörde mevcut tüm çalışanlara yapay zeka hakkında temel eğitimler verilmelidir.

- YOLO modelleri yeni sürümleri sürekli olarak geliştiriciler tarafından sunulmaktadır. En yeni modeller test ve takip edilmeli uygunsa kullanılmalıdır.

- Ord.Prof.Dr. Cahit ARF, atomlar içerisinde cereyan eden olayların da belirsiz olduğunu, bu durumun makinaların işleyişinde kullanılabilmesi durumunda insan beyin yapısına benzeyebileceğini söylemiştir. Bu tespit literatürde, kuantum bilgisayarın ilk kavramsal düşüncesidir. Dünyada bilinmemesine karşın fikir babası olarak Arf gösterilmelidir.

KAYNAKLAR

- Abdulghani, M. A.G. A. 2021. Farklı koşullarda görüntü algılama algoritmaları YOLO ve faster R-CNN'nin karşılaştırılması. Yüksek lisans tezi, Atılım Üniversitesi, İstanbul, 88 s.
- Abdullah, R. 2020. Performance analysis of deep learning object detection based image segmentation methods. MSc. Thesis, Cukurova University, Adana, 65 s.
- Acar, Z. A. 2022. Yapay zeka teknikleri ile manyetik rezonans görüntülerinden multipl skleroz hastalığının teşhisi ve gelecekteki aktivitesinin tahmini. Doktora tezi, Selçuk Üniversitesi, Konya, 127 s.
- Açıksözlü, Ö. 2021. İnsanların ötesinde robotik emek: Potansiyel yerli turistler, turizm akademisyenleri ve turizm sektör temsilcileri üzerine karşılaştırmalı bir araştırma. Doktora tezi, Balıkesir Üniversitesi, Balıkesir, 195 s.
- Ahmed, A., Imran, A. S., Manaf, A., Kastrati, Z., ve Daudpota, S. M. 2024. Enhancing wrist abnormality detection with YOLO: Analysis of state-of-the-art single-stage detection models. *Biomedical Signal Processing and Control*, 93: 106144. <https://doi.org/10.1016/j.bspc.2024.106144>.
- Ahn, J., Park, J., Lee, S. S., Lee, K.-H., Do, H., ve Ko, J. 2023. SafeFac: Video-based smart safety monitoring for preventing industrial work accidents. *Expert Systems with Applications*, 215: 119397. <https://doi.org/10.1016/j.eswa.2022.119397>.
- Ajith, M., ve Martinez Ramon, M. 2023. Deep learning algorithms for very short term solar irradiance forecasting: A survey. *Renewable and Sustainable Energy Reviews*, 182: 113362. <https://doi.org/10.1016/j.rser.2023.113362>.
- Akaner, M. 2022. Faaliyet alanları tehlike sınıflarının tespiti için yapay sinir ağları tabanlı bir model önerisi. Doktora tezi, Gazi Üniversitesi, Ankara, 164 s.
- Akkajit, P., Alahi, M. E. E., ve Sukkuea, A. 2024. Enhanced detection and classification of microplastics in marine environments using deep learning. *Regional Studies in Marine Science*, 80: 103880. <https://doi.org/10.1016/j.rsma.2024.103880>.
- Aksoy, T. 2022. Görsel akıl yürütme ile tek aşamalı nesne tespitinde iyileştirmeler. Yüksek lisans tezi, Ortadoğu Teknik Üniversitesi, İstanbul, 62 s.
- Al-Asadi, M. A. M. 2022. Veri madenciliği ve yapay zeka teknikleri ile karşılaştırmalı futbol analitiği. Doktora tezi, Selçuk Üniversitesi, Konya, 146 s.
- Alemdar, K. D. 2023. Sürücü dikkat dağınıklığının çevresel etkilerinin incelenmesi ve nesne tespit algoritmaları ile tespit edilmesi. Doktora tezi, Erzurum Teknik Üniversitesi, Erzurum, 166 s.
- Algaraghuli, A. K. A. 2022. Modified YOLOv4 and YOLOv3 by image processing and deep learning for traffic flow car detection. Yüksek lisans tezi, Altınbaş Üniversitesi, İstanbul, 69 s.

- Alhamed, K. M., Iwendi, C., Dutta, A. K., Almutairi, B., Alsaghier, H., ve Almotairi, S. 2022. Building construction based on video surveillance and deep reinforcement learning using smart grid power system. *Computers and Electrical Engineering*, 103: 108273. <https://doi.org/10.1016/j.compeleceng.2022.108273>.
- Ali, R., Chuah, J. H., Talip, M. S. A., Mokhtar, N., ve Shoaib, M. A. 2022. Structural crack detection using deep convolutional neural networks. *Automation in Construction*, 133: 103989. <https://doi.org/10.1016/j.autcon.2021.103989>.
- Ali, W. 2024. Performance Analysis of Model Compression Techniques in Distributed Deep Neural Networks. Msc. Thesis, Saint Louis University, Missouri, 48 s.
- Alruwaili, M., Siddiqi, M. H., Atta, M. N., ve Arif, M. 2024. Deep learning and ubiquitous systems for disabled people detection using YOLO models. *Computers in Human Behavior*, 154: 108150. <https://doi.org/10.1016/j.chb.2024.108150>.
- Alsamurai, M. Q. F. 2023. Development and implementation of yolov8-based model for human and animal detection during forest fires. MSc. Thesis, Altınbas University, Istanbul, 66 s.
- Amin, M. S., ve Ahn, H. 2021. Earthquake disaster avoidance learning system using deep learning. *Cognitive Systems Research*, 66: 221–235. <https://doi.org/10.1016/j.cogsys.2020.11.002>.
- Apaydın, O. 2023. Object detection in GPR images with deep learning based methods. Yüksek lisans tezi, İstanbul Teknik Üniversitesi, İstanbul, 78 s.
- Arf, C. 1959. Makine Düşünebilir mi ve Nasıl Düşünebilir? Atatürk Üniversitesi 1958-1959 Öğretim Yılı Halk Konferansları(1): 91–103.
- Aristoteles 1975. *Politika. Remzi Kitabevi*, İstanbul, 246 s.
- Arulprakash, E., ve Aruldoss, M. 2022. A study on generic object detection with emphasis on future research directions. *Journal of King Saud University - Computer and Information Sciences*, 34(9): 7347–7365. <https://doi.org/10.1016/j.jksuci.2021.08.001>.
- Aslan, M. F. 2022. Kapalı ortamlarda otonom insansız hava sistemlerinin geliştirilmesi. Doktora tezi, Konya Teknik Üniversitesi, Konya, 159 s.
- Aslan, T., ve Yağımlı, M. 2023. İş Sağlığı ve Güvenliğinde Derin Öğrenme Tabanlı Risk Tespit ve Analizi. *The Journal of International Scientific Researches*, 8(2): 223–236.
- Assadzadeh, A., Arashpour, M., Li, H., Hosseini, R., Elghaish, F., ve Baduge, S. 2023. Excavator 3D pose estimation using deep learning and hybrid datasets. *Advanced Engineering Informatics*, 55: 101875. <https://doi.org/10.1016/j.aei.2023.101875>.
- Aşan, H. 2022. Kurumsal kaynak planlama yazılımlarında yapay zeka teknikleri kullanılarak kullanıcı destek sistemine yönelik model tasarımı ve geliştirilmesi. Doktora tezi, Dokuz Eylül Üniversitesi, İzmir, 166 s.
- Azadvatan, Y. 2023. Derin öğrenme ve bilgisayarlı görü ile gerçek zamanlı nesne algılama. Yüksek lisans tezi, Ege Üniversitesi, İzmir, 124 s.

- Azevedo, P., ve Santos, V. 2024. Comparative analysis of multiple YOLO-based target detectors and trackers for ADAS in edge devices. *Robotics and Autonomous Systems*, 171: 104558. <https://doi.org/10.1016/j.robot.2023.104558>.
- Balım, C. 2022. Derin öğrenme yöntemleri kullanılarak kıyafet uyum tespiti ve teşhisi. Doktora tezi, Eskişehir Osmangazi Üniversitesi, Eskişehir, 87 s.
- Baş, İ. 2023. YOLOv3 ve faster R-CNN'in caltech yaya veri seti üzerinde karşılaştırılması. Yüksek lisans tezi, Ege Üniversitesi, İzmir, 104 s.
- Başarır, B. 2019. Derin öğrenme tabanlı nesne takibi. Yüksek lisans tezi, Bursa Uludağ Üniversitesi, Bursa, 75 s.
- Başer, E. H. 2022. İnkılap Tarihi ve Atatürkçülük alt testi doğru sayılarının yapay zeka yöntemleriyle tahmin edilmesi. Doktora tezi, Kütahya Dumlupınar Üniversitesi, Kütahya, 168 s.
- Bayık, F. 2022. Yapay zekaya uygulamalı etik bağlamında bir yaklaşım. Doktora tezi, Akdeniz Üniversitesi, Antalya, 146 s.
- Benhar, H., Idri, A., ve Fernández-Alemán, J. L. 2020. Data preprocessing for heart disease classification: A systematic literature review. *Computer Methods and Programs in Biomedicine*, 195: 105635. <https://doi.org/10.1016/j.cmpb.2020.105635>.
- Biçgi, M. 2022. Nesne tespit algoritması (YOLOv4 algoritması) ile patates böceğinin (*Leptinotarsa decemlineata*) (say) patates bitkisi üzerinde saptanması ve populasyon izleme olanakları. Yüksek lisans tezi, Isparta Uygulamalı Bilimler Üniversitesi, Isparta, 56 s.
- Bilik, S., Zemcik, T., Kratochvila, L., Ricanek, D., Richter, M., Zambanini, S., ve Horak, K. 2024. Machine learning and computer vision techniques in continuous beehive monitoring applications: A survey. *Computers and Electronics in Agriculture*, 217: 108560. <https://doi.org/10.1016/j.compag.2023.108560>.
- Borges Oliveira, D. A., Ribeiro Pereira, L. G., Bresolin, T., Pontes Ferreira, R. E., ve Reboucas Dorea, J. R. 2021. A review of deep learning algorithms for computer vision systems in livestock. *Livestock Science*, 253: 104700. <https://doi.org/10.1016/j.livsci.2021.104700>.
- Bozkurt, E. 2022. Yapay zeka teknikleri ile yüksek fırında tahmin ve öneri sistemi geliştirilmesi. Doktora tezi, Karabük Üniversitesi, Karabük, 158 s.
- Buğa, B. D. 2023. Triton ve deepstream ortamlarında gerçekleştirilen çoklu kameralar ile tasarlanmış derin öğrenme tabanlı nesne tespiti yapılarının canlı ortam sunucularındaki performansı. Yüksek lisans tezi, Kocaeli Üniversitesi, Kocaeli, 46 s.
- Büyükarıkan, B. 2022. Aydınlatmanın görüntü işleme problemlerine etkisinin yapay zeka teknikleri kullanılarak analizi. Doktora tezi, Konya Teknik Üniversitesi, Konya, 147 s.
- Cai, C., Nishimura, T., Hwang, J., Hu, X.-M., ve Kuroda, A. 2021. Asbestos Detection with Fluorescence Microscopy Images and Deep Learning. *Sensors*, 21(13): 4582. <https://doi.org/10.3390/s21134582>.

- Cai, Y., Zhou, Y., Han, Q., Sun, J., Kong, X., Li, J., ve Zhang, X. 2022. Reversible Column Networks. ArXiv, abs/2212.11696. <https://doi.org/10.48550/arXiv.2212.11696>.
- Canbolat Göçmen, Z. N. 2022. Sağlık hizmetlerinde yapay zeka uygulamaları Yoğun bakım örneği. Doktora tezi, İstanbul Medipol Üniversitesi, İstanbul, 224 s.
- Cao, S., Wang, T., Li, T., ve Mao, Z. 2023. UAV small target detection algorithm based on an improved YOLOv5s model. *Journal of Visual Communication and Image Representation*, 97: 103936. <https://doi.org/10.1016/j.jvcir.2023.103936>.
- Cao, Y., Chen, J., ve Zhang, Z. 2023. A sheep dynamic counting scheme based on the fusion between an improved-sparrow-search YOLOv5x-ECA model and few-shot deepsort algorithm. *Computers and Electronics in Agriculture*, 206: 107696. <https://doi.org/10.1016/j.compag.2023.107696>.
- Cao, Y., Pang, D., Zhao, Q., Yan, Y., Jiang, Y., Tian, C., Wang, F., ve Li, J. 2024. Improved YOLOv8-GD deep learning model for defect detection in electroluminescence images of solar photovoltaic modules. *Engineering Applications of Artificial Intelligence*, 131: 107866. <https://doi.org/10.1016/j.engappai.2024.107866>.
- Cao, Z., Liao, T., Song, W., Chen, Z., ve Li, C. 2021. Detecting the shuttlecock for a badminton robot: A YOLO based approach. *Expert Systems with Applications*, 164: 113833. <https://doi.org/10.1016/j.eswa.2020.113833>.
- Cengil, E. 2021. İki boyutlu sağlık, tarım ve iş güvenliği imgeleri üzerinde sınıflandırma ve nesne tespiti. Doktora tezi, Fırat Üniversitesi, Elazığ, 76 s.
- Chai, J., Zeng, H., Li, A., ve Ngai, E. W.T. 2021. Deep learning in computer vision: A critical review of emerging techniques and application scenarios. *Machine Learning with Applications*, 6: 100134. <https://doi.org/10.1016/j.mlwa.2021.100134>.
- Chandra, N., Vaidya, H., Sawant, S., ve Meena, S. R. 2024. A Novel Attention-Based Generalized Efficient Layer Aggregation Network for Landslide Detection from Satellite Data in the Higher Himalayas, Nepal. *Remote Sensing*, 16(14). <https://doi.org/10.3390/rs16142598>.
- Chang, R., Li, B., Dang, J., Yang, C., Pan, A., ve Yang, Y. 2023. Real-Time Intelligent Detection System for Illegal Wearing of On-Site Power Construction Worker Based on Edge-YOLO and Low-Cost Edge Devices. *Applied Sciences*, 13(14): 8287. <https://doi.org/10.3390/app13148287>.
- Che, L., He, Z., Zheng, K., Si, T., Ge, M., Cheng, H., ve Zeng, L. 2023. Deep learning in alloy material microstructures: Application and prospects. *Materials Today Communications*, 37: 107531. <https://doi.org/10.1016/j.mtcomm.2023.107531>.
- Chen, H., Hou, L., Zhang, G., ve Wu, S. 2023. Using Context-Guided data Augmentation, lightweight CNN, and proximity detection techniques to improve site safety monitoring under occlusion conditions. *Safety Science*, 158: 105958. <https://doi.org/10.1016/j.ssci.2022.105958>.

- Chen, S., ve Demachi, K. 2020. A Vision-Based Approach for Ensuring Proper Use of Personal Protective Equipment (PPE) in Decommissioning of Fukushima Daiichi Nuclear Power Station. *Applied Sciences*, 10(15): 5129. <https://doi.org/10.3390/app10155129>.
- Chen, S., ve Demachi, K. 2021. Towards on-site hazards identification of improper use of personal protective equipment using deep learning-based geometric relationships and hierarchical scene graph. *Automation in Construction*, 125: 103619. <https://doi.org/10.1016/j.autcon.2021.103619>.
- Chen, S., Li, Y., Zhang, Y., Yang, Y., ve Zhang, X. 2024. Soft X-ray image recognition and classification of maize seed cracks based on image enhancement and optimized YOLOv8 model. *Computers and Electronics in Agriculture*, 216: 108475. <https://doi.org/10.1016/j.compag.2023.108475>.
- Chen, S., Liu, D., Pu, Y., ve Zhong, Y. 2022. Advances in deep learning-based image recognition of product packaging. *Image and Vision Computing*, 128: 104571. <https://doi.org/10.1016/j.imavis.2022.104571>.
- Chen, W., Li, C., ve Guo, H. 2023. A lightweight face-assisted object detection model for welding helmet use. *Expert Systems with Applications*, 221: 119764. <https://doi.org/10.1016/j.eswa.2023.119764>.
- Chen, Y., Huang, Y., Zhang, Z., Wang, Z., Liu, B., Liu, C., Huang, C., Dong, S., Pu, X., Wan, F., Qiao, X., ve Qian, W. 2023. Plant image recognition with deep learning: A review. *Computers and Electronics in Agriculture*, 212: 108072. <https://doi.org/10.1016/j.compag.2023.108072>.
- Cheng, J.P., Wong, P. K.-Y., Luo, H., Wang, M., ve Leung, P. H. 2022. Vision-based monitoring of site safety compliance based on worker re-identification and personal protective equipment classification. *Automation in Construction*, 139: 104312. <https://doi.org/10.1016/j.autcon.2022.104312>.
- Chiddarwar, A. 2019. Application of Computer Vision Algorithms for Uninterrupted Traffic Monitoring Based on Aerial Images and Videos. Master's thesis, University of Cincinnati, Pune, 85 s.
- Chien, C.-T., Ju, R.-Y., Chou, K.-Y., ve Chiang, J.-S. 2024. YOLOv9 for fracture detection in pediatric wrist trauma X-ray images. *Electronics Letters*, 60(11), Article e13248. <https://doi.org/10.1049/ell2.13248>.
- Cho, J., ve Kim, K. 2023. Detection of moving objects in multi-complex environments using selective attention networks (SANet). *Automation in Construction*, 155: 105066. <https://doi.org/10.1016/j.autcon.2023.105066>.
- Chowdhury, A. A., Chowdhury, S. K., Hanif, M., Nosheen, S. N., ve Zishan, M. S. R. 2020. YOLO-Based Enhancement of Public Safety on Roads and Transportation in Bangladesh. *AIUB*

- Journal of Science and Engineering (AJSE), 19(2): 71–78.
<https://doi.org/10.53799/ajse.v19i2.91>.
- Ciaglia, F., Zuppichini, F. S., Guerrie, P., McQuade, M., ve Solawetz, J., 2022. Roboflow 100: A Rich, Multi-Domain Object Detection Benchmark.
<https://doi.org/10.48550/arXiv.2211.13523>.
- Cingöz, E. 2022. Rektum kanserinde neoadjuvan tedaviye cevabın değerlendirilmesinde derin öğrenmenin yeri. Tıpta uzmanlık, İstanbul Üniversitesi, İstanbul, 73 s.
- Corros., 2024. Gloves Dataset, Roboflow Universe. <https://universe.roboflow.com/corros/gloves-gzbg-9mqbc> [Son erişim tarihi: 07.01.2025].
- Çakırgöz, Ç. C. 2022. Utilization of dense depth information for monoview object detection and instance segmentation. Yüksek lisans tezi, Ortadoğu Teknik Üniversitesi, İstanbul, 102 s.
- Çeçen, Ş. 2023. Derin öğrenme teknikleri kullanılarak ratlarda östrus dönemlerinin YOLOv5 modeli ile sınıflandırılması. Yüksek lisans tezi, Fırat Üniversitesi, Elazığ, 34 s.
- Çekiç, İ. 2022. Yapay zeka metotlarını kullanarak otomotiv sektöründeki örnek problemlerinin çözümlerinin araştırılması. Doktora tezi, Bursa Uludağ Üniversitesi, Bursa, 124 s.
- Çelebi, S. 2023. Otonom araçlar için Tensorflow.js tabanlı nesne tespiti uygulaması. Yüksek lisans tezi, Siirt Üniversitesi, Siirt, 72 s.
- Çınarer, G. 2021. Görüntü işleme teknikleriyle beyin tümörlerinin tespiti ve sınıflandırma algoritmalarıyla analizi. Doktora tezi, Kırıkkale Üniversitesi, Kırıkkale, 175 s.
- Çırak, B., ve Yörük, A. 2016. Mekatronik Biliminin Öncüsü İsmail el-Cezeri. Siirt Üniversitesi Sosyal Bilimler Enstitüsü Dergisi(4): 175–194.
<https://dergipark.org.tr/tr/pub/susbid/issue/17333/181012>.
- Dağdeviren, F., 2024. PPE Ear Protection Dataset. <https://universe.roboflow.com/fatih-dagdeviren-vmort/ppe-ear-protection> [Son erişim tarihi: 07.01.2025].
- Dai, Y., Hu, Z., Zhang, S., ve Liu, L. 2022. A survey of detection-based video multi-object tracking. Displays, 75: 102317. <https://doi.org/10.1016/j.displa.2022.102317>.
- Dai, Z. 2022. Uncertainty-aware accurate insulator fault detection based on an improved YOLOX model. Energy Reports, 8: 12809–12821. <https://doi.org/10.1016/j.egy.2022.09.195>.
- Dandıl, E., ve Önal, O. 2021. Object Detection for Safe Working Environments using YOLOv4 Deep Learning Model. European Journal of Science and Technology(26): 343–351.
<https://doi.org/10.31590/ejosat.951733>.
- Dang, F., Chen, D., Lu, Y., ve Li, Z. 2023. YOLOWeeds: A novel benchmark of YOLO object detectors for multi-class weed detection in cotton production systems. Computers and Electronics in Agriculture, 205: 107655. <https://doi.org/10.1016/j.compag.2023.107655>.
- Devagiri, J. S., Paheding, S., Niyaz, Q., Yang, X., ve Smith, S. 2022. Augmented Reality and Artificial Intelligence in industry: Trends, tools, and future challenges. Expert Systems with Applications, 207: 118002. <https://doi.org/10.1016/j.eswa.2022.118002>.

- Dewan, M. C., Rattani, A., Gupta, S., Baticulon, R. E., Hung, Y.-C., Punchak, M., Agrawal, A., Adeleye, A. O., Shrimel, M. G., Rubiano, A. M., Rosenfeld, J. V., ve Park, K. B. 2019. Estimating the global incidence of traumatic brain injury. *Journal of Neurosurgery*, 130(4): 1080–1097. <https://doi.org/10.3171/2017.10.JNS17352>.
- Doğan, E. 2022. Yapay zekânın hukukî statüsü ve hukukî sorumluluğu. Doktora tezi, Ankara Üniversitesi, Ankara, 510 s.
- Doğan, F. 2021. SatNet: Uydu görüntülerinden nesne tespiti için yeni bir derin öğrenme modeli. Doktora tezi, Fırat Üniversitesi, Elazığ, 104 s.
- Dönmez, M. A. 2021. Konutlarda dönemsel farklılıkların tespiti için derin öğrenme tabanlı bir cephe analiz yöntemi Konya örneği. Doktora tezi, Konya, 119 s.
- Duan, R., Deng, H., Tian, M., Deng, Y., ve Lin, J. 2022. SODA: A large-scale open site object detection dataset for deep learning in construction. *Automation in Construction*, 142: 104499. <https://doi.org/10.1016/j.autcon.2022.104499>.
- Duan, S., Zhang, M., Qiu, S., Xiong, J., Zhang, H., Li, C., Jiang, Q., ve Kou, Y. 2024. Tunnel lining crack detection model based on improved YOLOv5. *Tunnelling and Underground Space Technology*, 147: 105713. <https://doi.org/10.1016/j.tust.2024.105713>.
- Dwyer, B. (2020). When Should I Auto-Orient My Images? *Roboflow Blog*. <https://blog.roboflow.com/exif-auto-orientation/> [Son erişim tarihi: 27.10.2024].
- Elgendy, M., Sik-Lanyi, C., ve Kelemen, A. 2021. A Novel Marker Detection System for People with Visual Impairment Using the Improved Tiny-YOLOv3 Model. *Computer Methods and Programs in Biomedicine*, 205: 106112. <https://doi.org/10.1016/j.cmpb.2021.106112>.
- Elhalid, O. B., ve Işık, A. H. 2024. Enhancing Mobile Acute Lymphoblastic Cancer Detection: Transfer Learning from YOLOv9 to TensorFlow for Real-Time Applications. *International Journal of Pioneering Technology and Engineering*, 3(01): 21–26. <https://doi.org/10.56158/jpte.2024.70.3.01>.
- Everingham, M., van Gool, L., Williams, C. K. I., Winn, J., ve Zisserman, A. 2010. The Pascal Visual Object Classes (VOC) Challenge. *International Journal of Computer Vision*, 88(2): 303–338. <https://doi.org/10.1007/s11263-009-0275-4>.
- Fang, W., Ding, L., Love, P. E.D., Luo, H., Li, H., Peña-Mora, F., Zhong, B., ve Zhou, C. 2022. Computer vision applications in construction safety assurance. *Automation in Construction*, 110: 103013. <https://doi.org/10.1016/j.autcon.2019.103013>.
- Fang, W., Love, P. E.D., Luo, H., ve Ding, L. 2020. Computer vision for behaviour-based safety in construction: A review and future directions. *Advanced Engineering Informatics*, 43: 100980. <https://doi.org/10.1016/j.aei.2019.100980>.
- Feigenbaum, E. A., Buchanan, B. G., ve Lederberg, J., 1970. On generality and problem solving: A case study using the DENDRAL program.

- Gao, S., Chu, M., ve Zhang, L. 2024. A detection network for small defects of steel surface based on YOLOv7. *Digital Signal Processing*, 149: 104484. <https://doi.org/10.1016/j.dsp.2024.104484>.
- Gengeç, N. 2020. Fabrika içi ortamlarda görsel nesne sezimi. Yüksek lisans tezi, Eskişehir Osmangazi Üniversitesi, Eskişehir, 39 s.
- Gharghan, S. K., ve Hashim, H. A. 2024. A comprehensive review of elderly fall detection using wireless communication and artificial intelligence techniques. *Measurement*, 226: 114186. <https://doi.org/10.1016/j.measurement.2024.114186>.
- Girgin, İ. 2023. Makine öğrenmesi ile iş sağlığı ve güvenliği uygulamaları. Yüksek lisans tezi, Ankara Üniversitesi, Ankara, 40 s.
- Girshick, R., 2015. Fast R-CNN. <http://arxiv.org/pdf/1504.08083v2>.
- Girshick, R. B., Donahue, J., Darrell, T., ve Malik, J. 2013. Rich Feature Hierarchies for Accurate Object Detection and Semantic Segmentation. 2014 IEEE Conference on Computer Vision and Pattern Recognition: 580–587.
- Gong, F., Ji, X., Gong, W., Yuan, X., ve Gong, C. 2021. Deep Learning Based Protective Equipment Detection on Offshore Drilling Platform. *Symmetry*, 13(6): 954. <https://doi.org/10.3390/sym13060954>.
- Gök, K. 2016. Fotoğrafın bulunuşu ve sonrasında oluşan teknik gelişmeler. *Yıldız Journal of Art and Design*, 3(1): 43–66.
- Gökçe, Z. 2019. Compositional modelling of first-person actions as verb-noun streams using LSTM based late fusion strategies. Yüksek lisans tezi, Ankara, 61 s.
- Gu, J., Wang, Z., Kuen, J., Ma, L., Shahroudy, A., Shuai, B., Liu, T., Wang, X., Wang, L., Wang, G., Cai, J., ve Chen, T., 2015. Recent Advances in Convolutional Neural Networks. <https://doi.org/10.48550/arXiv.1512.07108>.
- Güçlütürk, O. G. 2021. Türk hukukunda makine öğrenmesine dayalı yapay zekada verinin hukuka uygun şekilde kullanılması. Doktora tezi, Galatasaray Üniversitesi, İstanbul, 361 s.
- Güler, M. 2022. Tıbbi görüntü işleme ve derin öğrenme yöntemleriyle hastalıklarda teşhis otomasyon modeli. Tıpta uzmanlık, İstanbul Üniversitesi, İstanbul, 105 s.
- Gündüz, M. 2023. Gerçek zamanlı videolardan kalabalık ve sosyal mesafe tespiti için yolo algoritmalarının performans analizi: COVID-19 uygulaması. Yüksek lisans tezi, Iğdır Üniversitesi, Iğdır, 63 s.
- Gündüz, T. 2023. Derinlik kamerası ile derin öğrenme tabanlı nesne tespiti. Yüksek lisans tezi, İskenderun Teknik Üniversitesi, Hatay, 54 s.
- Güneysu, Y. 2021. KOBİ’lerde çalışma sermayesi yönetimine yönelik bir uzman sistem geliştirilmesi. Doktora tezi, Karadeniz Teknik Üniversitesi, Trabzon, 132 s.
- Gürgen, A. 2021. Multi-fonksiyonel bazı bileşiklerin odun korumada sinerjik etkilerinin belirlenmesi ve çok amaçlı optimizasyonu. Doktora tezi, Karadeniz Teknik Üniversitesi, Trabzon, 306 s.

- Güvenç, M. A. 2021. Tornalama süreçlerinde aktif titreşim kontrolü, yapay zeka uygulamaları ve nesnelerin interneti uygulamaları. Doktora tezi, İskenderun Teknik Üniversitesi, Hatay, 120 s.
- Güzel, M. 2022. Tokat bölgesi buğday üretiminde bazı yabancı otların derin öğrenme yöntemi ile tespit edilmesi. Doktora tezi, Tokat Gaziosmanpaşa Üniversitesi, Tokat, 162 s.
- Habib, G., ve Qureshi, S. 2022. Optimization and acceleration of convolutional neural networks: A survey. *Journal of King Saud University - Computer and Information Sciences*, 34(7): 4244–4268. <https://doi.org/10.1016/j.jksuci.2020.10.004>.
- Han, G., He, M., Zhao, F., Xu, Z., Zhang, M., ve Qin, L. 2021. Insulator detection and damage identification based on improved lightweight YOLOv4 network. *Energy Reports*, 7: 187–197. <https://doi.org/10.1016/j.egy.2021.10.039>.
- Han, X., Chang, J., ve Wang, K. 2021. Real-time object detection based on YOLO-v2 for tiny vehicle object. *Procedia Computer Science*, 183: 61–72. <https://doi.org/10.1016/j.procs.2021.02.031>.
- Hao, X., Luo, S., Chen, M., He, C., Wang, T., ve Wu, H. 2024. Infrared small target detection with super-resolution and YOLO. *Optics & Laser Technology*, 177: 111221. <https://doi.org/10.1016/j.optlastec.2024.111221>.
- He, K., Zhang, X., Ren, S., ve Sun, J., 2015. Deep Residual Learning for Image Recognition. <https://doi.org/10.48550/arXiv.1512.03385>.
- Hendaoui, R. 2022. Kamufle görüntülerden nesne algılama için derin öğrenmeye dayalı yeni yaklaşım. Doktora tezi, Karadeniz Teknik Üniversitesi, Trabzon, 120 s.
- Hou, X., Li, C., ve Fang, Q. 2023. Computer vision-based safety risk computing and visualization on construction sites. *Automation in Construction*, 156: 105129. <https://doi.org/10.1016/j.autcon.2023.105129>.
- Hsu, F.-H. 1999. IBM's Deep Blue Chess grandmaster chips. *IEEE Micro*, 19(2): 70–81. <https://doi.org/10.1109/40.755469>.
- Hu, Y., Wang, J., Wang, X., Sun, Y., Yu, H., ve Zhang, J. 2024. Real-time evaluation of the blending uniformity of industrially produced gravelly soil based on Cond-YOLOv8-seg. *Journal of Industrial Information Integration*, 39: 100603. <https://doi.org/10.1016/j.jii.2024.100603>.
- Irene, S., John Prakash, A., ve Rhymend Uthariaraj, V. 2024. Person search over security video surveillance systems using deep learning methods: A review. *Image and Vision Computing*, 143: 104930. <https://doi.org/10.1016/j.imavis.2024.104930>.
- İlhan, Ö. 2018. Dış ortam görüntülerindeki insan hareketlerinin derin öğrenme kullanarak sınıflandırılması. Yüksek lisans tezi, Munzur Üniversitesi, Tunceli, 61 s.
- Jabbarli, G. 2023. A new CNN model for object detection. MSc. Thesis, Ege University, İzmir, 106 s.

- Jalil, A. J. 2023. Makine öğrenimi algoritmalarını kullanarak gerçek zamanlı robot ile nesne algılama ve tanıma. Yüksek lisans tezi, Kütahya Dumlupınar Üniversitesi, Kütahya, 59 s.
- Ji, L., ve Huang, C. 2024. Improved YOLOv5 Network for Aviation Plug Defect Detection. *Aerospace*, 11(6). <https://doi.org/10.3390/aerospace11060488>.
- Joseph, W. 1966. ELIZA—a computer program for the study of natural language communication between man and machine. *Commun. ACM*, 9(1): 36–45. <https://doi.org/10.1145/365153.365168>.
- Kadadi, R. 2023. Biyomedikal imgerlerde çapasız dedektörlerle görsel nesne tespiti. Yüksek lisans tezi, Eskişehir Osmangazi Üniversitesi, Eskişehir, 60 s.
- Kara, M. A. 2023. FPGA SoC üzerinde hızlandırılmış nesne tespiti. Yüksek lisans tezi, Marmara Üniversitesi Fen Bilimleri Enstitüsü, İstanbul, 78 s.
- Karaahmetoğlu, E. 2023. Yapay zeka yaklaşımı ile son yıllarda ve geleceğe yönelik mesleki değişimler ve eğilimlerin analizi. Doktora tezi, Kırıkkale Üniversitesi, Kırıkkale, 121 s.
- Karimov, O. 2023. Yatırım kararlarında Elliott Dalgalarının YOLO nesne algılama algoritması ile tespiti ve analizi. Yüksek lisans tezi, İstanbul Üniversitesi, İstanbul, 110 s.
- Kaya, E. C. 2018. Yerel evrişimli bağlam öznitelikleri ve yinelemeli sinir ağları kullanarak görsel nesne tespiti ve takibi. Yüksek lisans tezi, Ortadoğu Teknik Üniversitesi, İstanbul, 104 s.
- Kesintaş, G. 2021. İnsansız hava aracı ile gerçek zamanlı nesne tanıma. Yüksek lisans tezi, Bitlis Eren Üniversitesi, Bitlis, 65 s.
- Kim, S., Hong, S. H., Kim, H., Lee, M., ve Hwang, S. 2023. Small object detection (SOD) system for comprehensive construction site safety monitoring. *Automation in Construction*, 156: 105103. <https://doi.org/10.1016/j.autcon.2023.105103>.
- Kipli, K., Osman, S., Joseph, A., Zen, H., Awang Salleh, Dayang Nur Salmi Dharmiza, Lit, A., ve Chin, K. L. 2023. Deep learning applications for oil palm tree detection and counting. *Smart Agricultural Technology*, 5: 100241. <https://doi.org/10.1016/j.atech.2023.100241>.
- Koca, S. 2022. Makine öğrenmesi kullanılarak pulmoner tromboemboli riski olan hastaların belirlenmesi. Doktora tezi, Sağlık Bilimleri Üniversitesi, Ankara, 80 s.
- Koç, K. 2022. Development of a machine learning prediction model for construction safety management. Doktora tezi, Yıldız Teknik Üniversitesi, İstanbul, 205 s.
- Konda, S., Tiesman, H., ve Reichard, A. 2016. Fatal traumatic brain injuries in the construction industry, 2003–2010. *American Journal of Industrial Medicine*.
- Kong, M.-C., Roh, M.-I., Kim, K.-S., Lee, J., Kim, J., ve Lee, G. 2022. Object detection method for ship safety plans using deep learning. *Ocean Engineering*, 246: 110587. <https://doi.org/10.1016/j.oceaneng.2022.110587>.
- Kouzehgar, M., Krishnasamy Tamilselvam, Y., Vega Heredia, M., ve Rajesh Elara, M. 2019. Self-reconfigurable façade-cleaning robot equipped with deep-learning-based crack detection

- based on convolutional neural networks. *Automation in Construction*, 108: 102959. <https://doi.org/10.1016/j.autcon.2019.102959>.
- Krizhevsky, A., Sutskever, I., ve Hinton, G. E. 2017. ImageNet classification with deep convolutional neural networks. *Commun. ACM*, 60(6): 84–90. <https://doi.org/10.1145/3065386>.
- Kubajı, A. 2022. Satıř elemanı verimlilięi iin yeni bir derin ğrenme tabanlı nesne tespit sistemi. Yüksek lisans tezi, Sakarya Üniversitesi, Sakarya, 61 s.
- Kulshrestha, A. 2019. Compressing Deep Neural Networks via Knowledge Distillation. MSc. Thesis, Clemson University, Clemson, South Carolina, USA, 65 s.
- Külcü, R. 2018. Ktesibios'un Su Saatinde Gündüz-Gece Fonksiyonun Keřfi. *Akademia Disiplinlerarası Bilimsel Arařtırmalar Dergisi*, 4(1): 8–18. <https://dergipark.org.tr/tr/pub/adbada/issue/42010/481877>.
- Kwon, J.-H., ve Cho, G.-H. 2020. An examination of the intersection environment associated with perceived crash risk among school-aged children: Using street-level imagery and computer vision. *Accident; Analysis and Prevention*, 146: 105716. <https://doi.org/10.1016/j.aap.2020.105716>.
- Lakshmipriya, B., Pottakkat, B., ve Ramkumar, G. 2023. Deep learning techniques in liver tumour diagnosis using CT and MR imaging - A systematic review. *Artificial Intelligence in Medicine*, 141: 102557. <https://doi.org/10.1016/j.artmed.2023.102557>.
- Lecun, Y., Bottou, L., Bengio, Y., ve Haffner, P. 1998. Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11): 2278–2324. <https://doi.org/10.1109/5.726791>.
- LeCun, Y., Boser, B. E., Denker, J. S., Henderson, D., Howard, R. E., Hubbard, W. E., ve Jackel, L. D. 1989. Backpropagation Applied to Handwritten Zip Code Recognition. *Neural Computation*, 1: 541–551.
- Lee, C.-Y., Xie, S., Gallagher, P., Zhang, Z., ve Tu, Z. 2014. Deeply-Supervised Nets. *ArXiv*, abs/1409.5185. <https://doi.org/10.48550/arXiv.1409.5185>.
- Lee, J.-Y., Choi, W.-S., ve Choi, S.-H. 2023. Verification and performance comparison of CNN-based algorithms for two-step helmet-wearing detection. *Expert Systems with Applications*, 225: 120096. <https://doi.org/10.1016/j.eswa.2023.120096>.
- Lejeune, E. 2020. Mechanical MNIST: A benchmark dataset for mechanical metamodels. *Extreme Mechanics Letters*, 36: 100659. <https://doi.org/10.1016/j.eml.2020.100659>.
- Leontaris, L., Mitsiaki, A., Charalampous, P., Dimitriou, N., Leivaditou, E., Karamanidis, A., Margetis, G., Apostolakis, K. C., Pantoja, S., Stephanidis, C., Tzovaras, D., ve Papageorgiou, E. 2023. A blockchain-enabled deep residual architecture for accountable, in-situ quality control in industry 4.0 with minimal latency. *Computers in Industry*, 149: 103919. <https://doi.org/10.1016/j.compind.2023.103919>.

- Li, J., Liang, X., Shen, S., Xu, T., Feng, J., ve Yan, S. 2018. Scale-Aware Fast R-CNN for Pedestrian Detection. *Trans. Multi.*, 20(4): 985–996. <https://doi.org/10.1109/TMM.2017.2759508>.
- Li, J., Zhao, X., Zhou, G., ve Zhang, M. 2022. Standardized use inspection of workers' personal protective equipment based on deep learning. *Safety Science*, 150: 105689. <https://doi.org/10.1016/j.ssci.2022.105689>.
- Li, J., Jiang, P., An, Q., Wang, G.-G., ve Kong, H.-F. 2024. Medical image identification methods: A review. *Computers in Biology and Medicine*, 169: 107777. <https://doi.org/10.1016/j.combiomed.2023.107777>.
- Li, P., Wu, F., Xue, S., ve Guo, L. 2023. Study on the Interaction Behaviors Identification of Construction Workers Based on ST-GCN and YOLO. *Sensors (Basel, Switzerland)*, 23(14). <https://doi.org/10.3390/s23146318>.
- Li, Y., Ma, Y., ve Long, Y. 2024. Protocol for assessing neighborhood physical disorder using the YOLOv8 deep learning model. *STAR Protocols*, 5(1): 102778. <https://doi.org/10.1016/j.xpro.2023.102778>.
- Li, Y., Lu, Y., ve Chen, J. 2021. A deep learning approach for real-time rebar counting on the construction site based on YOLOv3 detector. *Automation in Construction*, 124: 103602. <https://doi.org/10.1016/j.autcon.2021.103602>.
- Li, Z., Dong, Y., Shen, L., Liu, Y., Pei, Y., Yang, H., Zheng, L., ve Ma, J. 2024. Development and challenges of object detection: A survey. *Neurocomputing*, 598: 128102. <https://doi.org/10.1016/j.neucom.2024.128102>.
- Lin, T.-Y., Maire, M., Belongie, S., Bourdev, L., Girshick, R., Hays, J., Perona, P., Ramanan, D., Zitnick, C. L., ve Dollár, P. 2014. Microsoft COCO: Common Objects in Context. *ArXiv E-Prints: arXiv:1405.0312*. <https://doi.org/10.48550/arXiv.1405.0312>.
- Liu, J., Fang, W., Love, P. E.D., Hartmann, T., Luo, H., ve Wang, L. 2022. Detection and location of unsafe behaviour in digital images: A visual grounding approach. *Advanced Engineering Informatics*, 53: 101688. <https://doi.org/10.1016/j.aei.2022.101688>.
- Liu, J., Luo, H., ve Liu, H. 2022. Deep learning-based data analytics for safety in construction. *Automation in Construction*, 140: 104302. <https://doi.org/10.1016/j.autcon.2022.104302>.
- Liu, W., Anguelov, D., Erhan, D., Szegedy, C., Reed, S., Fu, C.-Y., ve Berg, A. C. 2016. SSD: Single Shot MultiBox Detector. In B. Leibe, J. Matas, N. Sebe, & M. Welling (Eds.), *Lecture notes in computer science. Computer vision (Vol. 9905, pp. 21–37)*. Springer Berlin Heidelberg. https://doi.org/10.1007/978-3-319-46448-0_2.
- Ludwika, A. S., ve Rifai, A. P. 2024. Deep Learning for Detection of Proper Utilization and Adequacy of Personal Protective Equipment in Manufacturing Teaching Laboratories. *SAFETY*, 10(1). <https://doi.org/10.3390/safety10010026>.

- Luo, Z., Wang, C., Qi, Z., ve Luo, C. 2024. LA_YOLOv8s: A lightweight-attention YOLOv8s for oil leakage detection in power transformers. *Alexandria Engineering Journal*, 92: 82–91. <https://doi.org/10.1016/j.aej.2024.02.054>.
- Mahmood, N. A. 2021. Real-Time Site Safety Risk Assessment and Intervention for On-Foot Building Construction Workers Using RFID-Based Multi-Sensor Intelligent System Ph.D Thesis, The Ohio State University, United States - Ohio,. BibTeX, 231 s.
- McCarthy, J., L. Minsky, M., Rochester, N., ve E. Shannon, C. 2006. A Proposal for the Dartmouth Summer Research Project on Artificial Intelligence, August 31, 1955. *AI Magazine*, 27(4): 12. <https://doi.org/10.1609/aimag.v27i4.1904>.
- McCulloch, W. S., ve Pitts, W. 1943. A logical calculus of the ideas immanent in nervous activity. *The Bulletin of Mathematical Biophysics*, 5(4): 115–133. <https://doi.org/10.1007/BF02478259>.
- Mostafa, K., ve Hegazy, T. 2021. Review of image-based analysis and applications in construction. *Automation in Construction*, 122: 103516. <https://doi.org/10.1016/j.autcon.2020.103516>.
- Mostowski, D., Jakubczak, K., ve Garbat, P. 2024. Automated laser beam characterization using artificial intelligence (AI) for the predictive maintenance of lasers. *Optics & Laser Technology*, 177: 111087. <https://doi.org/10.1016/j.optlastec.2024.111087>.
- Mustafa, N. E., ve Alizadeh, F. 2024. Unmanned aerial vehicle (UAV) images of road vehicles dataset. *Data in Brief*, 54: 110264. <https://doi.org/10.1016/j.dib.2024.110264>.
- Mutludođan, K. 2020. Derin öğrenme tabanlı şeffaf nesne tanıma. Yüksek lisans tezi, Bursa Uludağ Üniversitesi, Bursa, 69 s.
- Nath, N. D., ve Behzadan, A. H. 2020. Deep Convolutional Networks for Construction Object Detection Under Different Visual Conditions. *Frontiers in Built Environment*, 6, Article 97. <https://doi.org/10.3389/fbuil.2020.00097>.
- Nath, N. D., Behzadan, A. H., ve Paal, S. G. 2020. Deep learning for site safety: Real-time detection of personal protective equipment. *Automation in Construction*, 112(1–2): 103085. <https://doi.org/10.1016/j.autcon.2020.103085>.
- Nayak, R., Pati, U. C., ve Das, S. K. 2021. A comprehensive review on deep learning-based methods for video anomaly detection. *Image and Vision Computing*, 106: 104078. <https://doi.org/10.1016/j.imavis.2020.104078>.
- Nvidia., 2025. NVIDIA L4 Tensor Core GPU. <https://www.nvidia.com/en-us/data-center/l4/> [Son erişim tarihi: 10.01.2025].
- Olcay, Z. F. 2019. İş sağlığı ve güvenliği maliyetlerinin inşaat sektöründeki iş kazaları üzerindeki etkisinin analizi. Doktora tezi, İstanbul Aydın Üniversitesi, İstanbul, 210 s.
- Olgun, N. 2022. Lazer işaretleri ile yapay zeka temelli hedef analizi. Doktora tezi, Fırat Üniversitesi, Elazığ, 176 s.

- Ortiz, S. C., Pascual Muñoz, P., ve Castro Fresno, D. 2022. Machine learning algorithms for monitoring pavement performance. *Automation in Construction*, 139: 104309. <https://doi.org/10.1016/j.autcon.2022.104309>.
- Ouf, N. S. 2023. Leguminous seeds detection based on convolutional neural networks: Comparison of Faster R-CNN and YOLOv4 on a small custom dataset. *Artificial Intelligence in Agriculture*, 8: 30–45. <https://doi.org/10.1016/j.aiia.2023.03.002>.
- Özdaş, M. B. 2023. Nesne tespiti algoritmaları ve yüksek çözünürlüklü evrişimsel sinir ağıyla savunma sanayii alanındaki küçük nesnelerin tespiti. Yüksek lisans tezi, Gazi Üniversitesi, Ankara, 73 s.
- Özkan, V. 2021. Havaalanı pat sahasında bölgesel evrişimsel sinir ağı mimarileri ile yabancı madde tespiti. Yüksek lisans tezi, Erciyes Üniversitesi, Kayseri, 70 s.
- Özkanoglu, M. A. 2023. Object detection and synthetic infrared image generation for UAV-based aerial images. Yüksek lisans tezi, Bilkent Üniversitesi, İstanbul, 94 s.
- Özseven, A. M. 2021. Yapay zeka ve derin öğrenme teknolojileri ile kalça eklemi radyografilerinde femoral komponentin tanınması. Tıpta uzmanlık tezi, Sağlık Bilimleri Üniversitesi, Ankara, 81 s.
- P. Jin, H. Li, W. Yan, ve J. Xu 2024. YOLO-ESCA: A High-Performance Safety Helmet Standard Wearing Behavior Detection Model Based on Improved YOLOv5. *IEEE Access*, 12: 23854–23868. <https://doi.org/10.1109/ACCESS.2024.3365530>.
- Pal, A., ve Hsieh, S.-H. 2021. Deep-learning-based visual data analytics for smart construction management. *Automation in Construction*, 131: 103892. <https://doi.org/10.1016/j.autcon.2021.103892>.
- Pan, Y., ve Zhang, L. 2021. Roles of artificial intelligence in construction engineering and management: A critical review and future trends. *Automation in Construction*, 122: 103517. <https://doi.org/10.1016/j.autcon.2020.103517>.
- Paneru, S., ve Jeelani, I. 2021. Computer vision applications in construction: Current state, opportunities & challenges. *Automation in Construction*, 132: 103940. <https://doi.org/10.1016/j.autcon.2021.103940>.
- Parakh, A., Balakrishnan, M., ve Paul, K. 2012. Performance Estimation of GPUs with Cache. *Proceedings of the 2012 IEEE 26th International Parallel and Distributed Processing Symposium Workshops, IPDPSW 2012*. Advance online publication. <https://doi.org/10.1109/IPDPSW.2012.328>.
- Park, M., Tran, D. Q., Bak, J., Kulinan, A. S., ve Park, S. 2023. Real-time monitoring unsafe behaviors of portable multi-position ladder worker using deep learning based on vision data. *Journal of Safety Research*, 87: 465–480. <https://doi.org/10.1016/j.jsr.2023.08.018>.
- Patel, K., Patel, V., Prajapati, V., Chauhan, D., Haji, A., ve Degadwala, S. Safety Helmet Detection Using YOLO V8. <https://doi.org/10.1109/ICPCSN58827.2023.00012>.

- Peker, A. A. 2021. Akciğer metastazlarında primer tümör kaynağının yapay zeka algoritmaları ile değerlendirilmesi. Tıpta uzmanlık tezi, Bezmialem Vakıf Üniversitesi, İstanbul, 31 s.
- Piltan, S. 2022. YOLO-V4 algoritması ile sosyal mesafelerin fotogrametrik yöntemle üç boyutlu gerçek zamanlı tespiti. Yüksek lisans tezi, Karadeniz Teknik Üniversitesi, Trabzon, 80 s.
- Pisu, A., Elia, N., Pompianu, L., Barchi, F., Acquaviva, A., ve Carta, S. 2024. Enhancing workplace safety: A flexible approach for personal protective equipment monitoring. *Expert Systems with Applications*, 238: 122285. <https://doi.org/10.1016/j.eswa.2023.122285>.
- Prusty, M. R., Tripathi, V., ve Dubey, A. 2021. A novel data augmentation approach for mask detection using deep transfer learning. *Intelligence-Based Medicine*, 5: 100037. <https://doi.org/10.1016/j.ibmed.2021.100037>.
- Quinlan, J. R. 1986. Induction of Decision Trees. *Machine Learning*, 1(1): 81–106. <https://doi.org/10.1023/A:1022643204877>.
- Rahimi, H. M., Motamedian, S. R., Rohban, M. H., Krois, J., Uribe, S. E., Mahmoudinia, E., Rokhshad, R., Nadimi, M., ve Schwendicke, F. 2022. Deep learning for caries detection: A systematic review. *Journal of Dentistry*, 122: 104115. <https://doi.org/10.1016/j.jdent.2022.104115>.
- Raiaan, M. A. K., Sakib, S., Fahad, N. M., Mamun, A. A., Rahman, M. A., Shatabda, S., ve Mukta, M. S. H. 2024. A systematic review of hyperparameter optimization techniques in Convolutional Neural Networks. *Decision Analytics Journal*, 11: 100470. <https://doi.org/10.1016/j.dajour.2024.100470>.
- Rao, A. S., Radanovic, M., Liu, Y., Hu, S., Fang, Y., Khoshelham, K., Palaniswami, M., ve Ngo, T. 2022. Real-time monitoring of construction sites: Sensors, methods, and applications. *Automation in Construction*, 136: 104099. <https://doi.org/10.1016/j.autcon.2021.104099>.
- Rasouli, S., Alipouri, Y., ve Chamanzad, S. 2024. Smart Personal Protective Equipment (PPE) for construction safety: A literature review. *Safety Science*, 170: 106368. <https://doi.org/10.1016/j.ssci.2023.106368>.
- Redmon, J., Divvala, S., Girshick, R., ve Farhadi, A., 2015. You Only Look Once: Unified, Real-Time Object Detection. <http://arxiv.org/pdf/1506.02640v5>.
- Ren, S., He, K., Girshick, R., ve Sun, J. 2017. Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 39(6): 1137–1149. <https://doi.org/10.1109/TPAMI.2016.2577031>.
- Robertson, C. E. 2020. Deep Learning-Based Speed Sign Detection and Recognition. Masters thesis, University of Cincinnati, Cincinnati, 67 s.
- Roboflow 100, R. U., 2023. Construction Safety Dataset. Roboflow Universe. <https://universe.roboflow.com/roboflow-100/construction-safety-gsnvb> [Son erişim tarihi: 25.10.2024].

- Roboflow Universe., 2025. Computer Vision Datasets. <https://universe.roboflow.com/> [Son erişim tarihi: 11.01.2025].
- Ronneberger, O., Fischer, P., ve Brox, T., 2015. U-Net: Convolutional Networks for Biomedical Image Segmentation. <http://arxiv.org/pdf/1505.04597>.
- Rosenblatt, F. 1958. The perceptron: A probabilistic model for information storage and organization in the brain. *Psychological Review*, 65(6): 386–408. <https://doi.org/10.1037/h0042519>.
- Saadoon, A. M. 2022. A smart device powered by deep learning technology to identify animals by using object detection in a live video to provide food and water to specific type of homeless animals. Yüksek lisans tezi, Altınbaş Üniversitesi, İstanbul, 63 s.
- Sadi, M. H., ve Mahani, A. 2021. Accelerating Deep Convolutional Neural Network base on stochastic computing. *Integration*, 76: 113–121. <https://doi.org/10.1016/j.vlsi.2020.09.008>.
- Sağın, C. 2019. Koruyucu baret kullanım ihlallerinin tespiti. Yüksek lisans tezi, Gebze Teknik Üniversitesi, Gebze, 56 s.
- Samuel, A. L. 1959. Some Studies in Machine Learning Using the Game of Checkers. *IBM Journal of Research and Development*, 3(3): 210–229. <https://doi.org/10.1147/rd.33.0210>.
- Sapkota, R., Qureshi, R., Calero, M. F., Badjugar, C., Nepal, U., Poulouse, A., Zeno, P., Vaddevolu, U. B. P., Khan, S., Shoman, M., Yan, H., ve Karkee, M., 2024. YOLOv10 to Its Genesis: A Decadal and Comprehensive Review of The You Only Look Once (YOLO) Series. <https://doi.org/10.48550/arXiv.2406.19407>.
- Sarı, F. 2021. Cahit Arf'in "Makine Düşünebilir mi ve Nasıl Düşünebilir?" Adlı Makalesi Üzerine Bir Çalışma. *TRT Akademi*, 6(13): 812–833. <https://doi.org/10.37679/trta.962940>.
- Serttaş, M. A. 2021. Gerçek zamanlı nesne tanıma sistemlerinde microservis yaklaşımı ile performans artırımı. Doktora tezi, Maltepe Üniversitesi, İstanbul, 67 s.
- Sevinç, Ö. 2022. Derin öğrenme ile covid-19, beyaz kan hücreleri, tüberküloz ve kalp krizi riskinin analizi. Doktora tezi, Ankara Üniversitesi, Ankara, 117 s.
- Shah, R., Pandit, R. K., ve Gaur, M. K. 2022. Urban physics and outdoor thermal comfort for sustainable street canyons using ANN models for composite climate. *Alexandria Engineering Journal*, 61(12): 10871–10896. <https://doi.org/10.1016/j.aej.2022.04.024>.
- Shanti, M. Z., Cho, C.-S., Soto, B. G. de, Byon, Y.-J., Yeun, C. Y., ve Kim, T. Y. 2022. Real-time monitoring of work-at-height safety hazards in construction sites using drones and deep learning. *Journal of Safety Research*, 83: 364–370. <https://doi.org/10.1016/j.jsr.2022.09.011>.
- Sharma, P., Nayak, D. R., Balabantaray, B. K., Tanveer, M., ve Nayak, R. 2024. A survey on cancer detection via convolutional neural networks: Current challenges and future directions. *Neural Networks*, 169: 637–659. <https://doi.org/10.1016/j.neunet.2023.11.006>.
- Sharma, V. K., ve Mir, R. N. 2020. A comprehensive and systematic look up into deep learning based object detection techniques: A review. *Computer Science Review*, 38: 100301. <https://doi.org/10.1016/j.cosrev.2020.100301>.

- Siddula, M., Dai, F., Ye, Y., ve Fan, J. 2016. Unsupervised Feature Learning for Objects of Interest Detection in Cluttered Construction Roof Site Images. *Procedia Engineering*, 145: 428–435. <https://doi.org/10.1016/j.proeng.2016.04.010>.
- Simonyan, K., ve Zisserman, A., 2014. Very Deep Convolutional Networks for Large-Scale Image Recognition. <http://arxiv.org/pdf/1409.1556>.
- Solawetz, J. (2020, May 6). Mean Average Precision (mAP) in Object Detection. Roboflow Blog. <https://blog.roboflow.com/mean-average-precision/> [Son erişim tarihi: 26.12.2023].
- Sorgun, Ö. 2022. X-ray görüntülerinde Faster R-CNN kullanılarak yasaklı nesne tespiti. Yüksek lisans tezi, Sakarya Uygulamalı Bilimler Üniversitesi, Sakarya, 74 s.
- Soysal, E. K. 2022. Dijital araçların diplomasiye katkısı: Dijital diplomasi. Doktora tezi, Süleyman Demirel Üniversitesi, Isparta, 207 s.
- Suliman, H. M. 2023. Nesne tespit modeline ve kameraya esas olan tanksavar güdümlü füze sistemi tasarımı. Yüksek lisans tezi, Ankara Yıldırım Beyazıt Üniversitesi, Ankara, 51 s.
- Sun, L., Wang, L. 2022. An improved YOLO V5-based algorithm of safety helmet wearing detection. 34th Chinese Control and Decision Conference (CCDC), Hefei, Chinese.
- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V., ve Rabinovich, A., 2014. Going Deeper with Convolutions. <https://doi.org/10.48550/arXiv.1409.4842>.
- Şahinci, D. 2021. Yapay zeka ve reklamcılığın geleceği. Doktora tezi, İstanbul Üniversitesi, İstanbul, 142 s.
- Tang, Y., ve Qian, Y. 2024. High-speed railway track components inspection framework based on YOLOv8 with high-performance model deployment. *High-Speed Railway*, 2(1): 42–50. <https://doi.org/10.1016/j.hspr.2024.02.001>.
- Tarım, G. 2019. Gömülü platformlar için kuşbakışı görüntüler üzerinden derin öğrenme temelli gerçek zamanlı şerit tespit sistemi. Yüksek lisans tezi, Kocaeli Üniversitesi, Kocaeli, 57 s.
- Taş, M. B. H. 2021. Bulut tabanlı derin öğrenme kullanarak insansız hava araçları için gerçek zamanlı nesne algılama. Yüksek lisans tezi, Atatürk Üniversitesi, Erzurum, 73 s.
- Tishby, N., ve Zaslavsky, N., 2015. Deep Learning and the Information Bottleneck Principle. <http://arxiv.org/pdf/1503.02406>.
- Topal, K. T. 2022. Çift mevsimsel zaman serisinin öngörüsü için iki aşamalı yeni bir yaklaşım. Doktora tezi, Ondokuz Mayıs Üniversitesi, Samsun, 89 s.
- Turing, A. M. 1937. On Computable Numbers, with an Application to the Entscheidungsproblem. *Proceedings of the London Mathematical Society*, s2-42(1): 230–265. <https://doi.org/10.1112/plms/s2-42.1.230>.
- Türk, E. 2021. Gömülü mandibular üçüncü molar dişlerin pozisyon özelliklerinin yapay zeka ile değerlendirilmesi. Uzmanlık tezi, Süleyman Demirel Üniversitesi, Isparta, 112 s.

- Türkdamar, M. U. 2023. Derin öğrenme ile nesne algılamada transfer öğrenme ve ince ayar işlemlerinin etkinliklerinin araştırılması. Yüksek lisans tezi, Erciyes Üniversitesi, Kayseri, 79 s.
- Türkoğlu, M. 2019. Görüntü işleme tabanlı bitki türleri ve hastalıkları tanıma. Doktora tezi, Fen Bilimleri Enstitüsü, Malatya, 175 s.
- Usta, A. 2022. İnsansız hava aracından çekilen videolar kullanılarak derin öğrenme yaklaşımı ile nesne tespiti. Yüksek lisans tezi, Dicle Üniversitesi, Diyarbakır, 73 s.
- Viola, P., ve Jones, M. 2001. Rapid object detection using a boosted cascade of simple features. In Proceedings of the 2001 IEEE Computer Society Conference on Computer Vision and Pattern Recognition. CVPR 2001.
- Viotti, I. D., Ribeiro, R. F., ve Gomes, G. F. 2024. Damage identification in sandwich structures using Convolutional Neural Networks. *Mechanical Systems and Signal Processing*, 220: 111649. <https://doi.org/10.1016/j.ymsp.2024.111649>.
- Vukicevic, A. M., Djapan, M., Isailovic, V., Milasinovic, D., Savkovic, M., ve Milosevic, P. 2022. Generic compliance of industrial PPE by using deep learning techniques. *Safety Science*, 148: 105646. <https://doi.org/10.1016/j.ssci.2021.105646>.
- Wang, C.-Y., Liao, H.-y., Wu, Y.-H., Chen, P.-Y., Hsieh, J.-W., ve Yeh, I.-H. 2020. CSPNet: A New Backbone that can Enhance Learning Capability of CNN. <https://doi.org/10.1109/CVPRW50498.2020.00203>, 1571 s.
- Wang, C.-Y., Liao, H.-Y. M., ve Yeh, I.-H., 2022. Designing Network Design Strategies Through Gradient Path Analysis. <https://doi.org/10.48550/arXiv.2211.04800>.
- Wang, C.-Y., Yeh, I.-H., ve Liao, H.-Y. M., 2024. YOLOv9: Learning What You Want to Learn Using Programmable Gradient Information. <https://doi.org/10.48550/arXiv.2402.13616>.
- Wang, H., Lv, L., Li, X., Li, H., Leng, J., Zhang, Y., Thomson, V., Liu, G., Wen, X., Sun, C., ve Luo, G. 2023. A safety management approach for Industry 5.0's human-centered manufacturing based on digital twin. *Journal of Manufacturing Systems*, 66: 1–12. <https://doi.org/10.1016/j.jmsy.2022.11.013>.
- Wang, L., Dong, Y., Fei, C., Liu, J., Fan, S., Liu, Y., Li, Y., Liu, Z., ve Zhao, X. 2024. A lightweight CNN for multi-source infrared ship detection from unmanned marine vehicles. *Heliyon*, 10(4): e26229. <https://doi.org/10.1016/j.heliyon.2024.e26229>.
- Wang, L., Lee, C.-Y., Tu, Z., ve Lazebnik, S. 2015. Training Deeper Convolutional Networks with Deep Supervision. Advance online publication. <https://doi.org/10.48550/arXiv.1505.02496>.
- Wang, X., Cai, L., Zhou, S., Jin, Y., Tang, L., ve Zhao, Y. 2023. Fire Safety Detection Based on CAGSA-YOLO Network. *Fire*, 6(8): 297. <https://doi.org/10.3390/fire6080297>.
- Wang, Y., Cui, Z., ve Ke, R. 2023. Machine learning for transportation research and applications. Elsevier, 239 s.

- Wang, Z., Wu, Y., Yang, L., Thirunavukarasu, A., Evison, C., ve Zhao, Y. 2021. Fast Personal Protective Equipment Detection for Real Construction Sites Using Deep Learning Approaches. *Sensors*, 21(10). <https://doi.org/10.3390/s21103478>.
- Wei, G., Li, G., Zhao, J., ve He, A. 2019. Development of a LeNet-5 Gas Identification CNN Structure for Electronic Noses. *Sensors*, 19(1). <https://doi.org/10.3390/s19010217>.
- Wei, M., ve Zhan, W. 2024. YOLO_MRC: A fast and lightweight model for real-time detection and individual counting of Tephritidae pests. *Ecological Informatics*, 79: 102445. <https://doi.org/10.1016/j.ecoinf.2023.102445>.
- Wei, P., Yan, X., Yan, W., Sun, L., Xu, J., ve Yuan, H. 2024. Precise extraction of targeted apple tree canopy with YOLO-Fi model for advanced UAV spraying plans. *Computers and Electronics in Agriculture*, 226: 109425. <https://doi.org/10.1016/j.compag.2024.109425>.
- Wu, J. 2023. Design and Exploration of Real Time Monitoring System for Power Grid Operation Safety Based on YOLO Object Detection Algorithm. *Procedia Computer Science*, 228: 889–897. <https://doi.org/10.1016/j.procs.2023.11.117>.
- Wu, J., Cai, N., Chen, W., Wang, H., ve Wang, G. 2019. Automatic detection of hardhats worn by construction personnel: A deep learning approach and benchmark dataset. *Automation in Construction*, 106: 102894. <https://doi.org/10.1016/j.autcon.2019.102894>.
- Wu, S., Hou, L., Zhang, G., ve Chen, H. 2022. Real-time mixed reality-based visual warning for construction workforce safety. *Automation in Construction*, 139: 104252. <https://doi.org/10.1016/j.autcon.2022.104252>.
- Xiao, Y., Tian, Z., Yu, J., Zhang, Y., Liu, S., Du, S., ve Lan, X. 2020. A review of object detection based on deep learning. *Multimedia Tools and Applications*, 79(33-34): 23729–23791. <https://doi.org/10.1007/s11042-020-08976-6>.
- Xiong, C., Zayed, T., ve Abdelkader, E. M. 2024. A novel YOLOv8-GAM-Wise-IoU model for automated detection of bridge surface cracks. *Construction and Building Materials*, 414: 135025. <https://doi.org/10.1016/j.conbuildmat.2024.135025>.
- Xiong, F., Xu, C., Ren, W., Zheng, R., Gong, P., ve Ren, Y. 2022. A blockchain-based edge collaborative detection scheme for construction internet of things. *Automation in Construction*, 134: 104066. <https://doi.org/10.1016/j.autcon.2021.104066>.
- Xu, W., Zhu, D., Deng, R., Yung, K., ve Ip, A. W. H. 2024. Violence-YOLO: Enhanced GELAN Algorithm for Violence Detection. *Applied Sciences*, 14(15). <https://doi.org/10.3390/app14156712>.
- Yadav, P., Gupta, N., ve Sharma, P. K. 2023. A comprehensive study towards high-level approaches for weapon detection using classical machine learning and deep learning methods. *Expert Systems with Applications*, 212: 118698. <https://doi.org/10.1016/j.eswa.2022.118698>.
- Yancı, M. 2019. Derin öğrenme yöntemleri ile medikal görüntülerde kanserli doku tespiti. Yüksek lisans tezi, Marmara Üniversitesi Fen Bilimleri Enstitüsü, İstanbul, 75 s.

- Yang, G., Liu, K., Zhang, J., Zhao, B., Zhao, Z., Chen, X., ve Chen, B. M. 2022. Datasets and processing methods for boosting visual inspection of civil infrastructure: A comprehensive review and algorithm comparison for crack classification, segmentation, and detection. *Construction and Building Materials*, 356: 129226. <https://doi.org/10.1016/j.conbuildmat.2022.129226>.
- Yang, Z., Guan, W., Xiao, L., ve Chen, H. 2024. Few-Shot Object Detection in Remote Sensing Images via Data Clearing and Stationary Meta-Learning. *Sensors (Basel, Switzerland)*, 24(12). <https://doi.org/10.3390/s24123882>.
- Yann Lecun 1989. Generalization and network design strategies. *Connectionism in Perspective*. <https://nyuscholars.nyu.edu/en/publications/generalization-and-network-design-strategies>.
- Yasak, S. S. 2021. Coğrafyada yapay zeka uygulamaları: YOLO V3 ile gerçek zamanlı kayaç tespit uygulaması örneği. Yüksek lisans tezi, Marmara Üniversitesi, İstanbul, 102 s.
- Yasir, M., Shanwei, L., Mingming, X., Jianhua, W., Hui, S., Nazir, S., Zhang, X., ve Tugsan Isiacik Colak, A. 2024. YOLOv8-BYTE: Ship tracking algorithm using short-time sequence SAR images for disaster response leveraging GeoAI. *International Journal of Applied Earth Observation and Geoinformation*, 128: 103771. <https://doi.org/10.1016/j.jag.2024.103771>.
- Yellapantula, S. R. 2019. Synthesizing Realistic Data for Vision Based Drone-to-Drone Detection. MSc. Thesis, Virginia Tech, Blacksburg, Virginia, 70 s.
- Yetiş, H. 2022. Kuantum hesaplama tabanlı yapay zeka algoritmalarının geliştirilmesi. Doktora tezi, Fırat Üniversitesi, Elazığ, 179 s.
- Yıldırım, E. 2022. Derin öğrenme tekniklerini kullanarak optik uydu görüntülerinden nesne tespiti. Yüksek lisans tezi, Gebze Teknik Üniversitesi, Gebze, 116 s.
- Yıldız, Z. 2021. Çoklu spektral bantlardaki görüntüleri kullanarak derin öğrenme ile nesne algılama ve tanıma. Yüksek lisans tezi, Milli Savunma Üniversitesi, Ankara, 76 s.
- Yılmaz, S. 2021. Panoramik radyografi kullanılarak iki farklı derin öğrenme metodunun dışlerin sınıflandırılması üzerindeki performanslarının karşılaştırılması olarak incelenmesi. Diş hekimliğinde uzmanlık tezi, Erciyes Üniversitesi, Kayseri, 110 s.
- Yoon, S., Cho, Y., ve Ahn, T. I., 2024. Melon Fruit Detection and Quality Assessment Using Generative AI-Based Image Data Augmentation. <https://doi.org/10.48550/arXiv.2407.10413>.
- Youwai, S., Chaiyaphat, A., ve Chaipetch, P., 2024. YOLO9tr: A Lightweight Model for Pavement Damage Detection Utilizing a Generalized Efficient Layer Aggregation Network and Attention Mechanism. <https://doi.org/10.48550/arXiv.2406.11254>.
- Z. Shen, Z. Liu, J. Li, Y. -G. Jiang, Y. Chen, ve X. Xue 2020. Object Detection from Scratch with Deep Supervision. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 42(2): 398–412. <https://doi.org/10.1109/TPAMI.2019.2922181>.

- Zengin, M. A. 2022. Türkiye İnşaat Sektörü İş Kazalarının İstatistiksel Analizi, 2011-2020. International Journal of Engineering Research and Development, 14(2): 492–501. <https://doi.org/10.29137/umagd.1035473>.
- Zhang, Z., Chen, P., Huang, Y., Dai, L., Xu, F., ve Hu, H. 2024. Railway obstacle intrusion warning mechanism integrating YOLO-based detection and risk assessment. Journal of Industrial Information Integration, 38: 100571. <https://doi.org/10.1016/j.jii.2024.100571>.
- Zhao, C., Zhang, W., Chen, C., Yang, X., Yue, J., ve Han, B. 2023. Recognition of Unsafe Onboard Mooring and Unmooring Operation Behavior Based on Improved YOLO-v4 Algorithm. Journal of Marine Science and Engineering, 11(2): 291. <https://doi.org/10.3390/jmse11020291>.
- Zhao, Z., Alzubaidi, L., Zhang, J., Duan, Y., ve Gu, Y. 2024. A comparison review of transfer learning and self-supervised learning: Definitions, applications, advantages and limitations. Expert Systems with Applications, 242: 122807. <https://doi.org/10.1016/j.eswa.2023.122807>.
- Zhou, Y. 2024. A YOLO-NL object detector for real-time detection. Expert Systems with Applications, 238: 122256. <https://doi.org/10.1016/j.eswa.2023.122256>.
- Zhou, Y. 2022. Advances of machine learning in multi-energy district communities– mechanisms, applications and perspectives. Energy and AI, 10: 100187. <https://doi.org/10.1016/j.egyai.2022.100187>.



ÖZGEÇMİŞ

Salih İLHAN, ilk ve ortaokulu Adana tamamladı. Liseyi 2001 yılında Deniz Astsubay Hazırlama Okulu'nda tamamlamasına müteakip 2002 yılında Deniz Astsubay Sınıf Okulu'ndan, 2009 yılında Anadolu Üniversitesi Kamu Yönetimi'nden, 2016 yılı Atatürk Üniversitesi Ön Lisans, Marmara Üniversitesi Tezsiz Yüksek Lisans, İş Sağlığı ve Güvenliği bölümünden, 2018 yılı Üsküdar Üniversitesi, Tezli Yüksek Lisans, İş Sağlığı ve Güvenliği bölümünden mezun olmuştur. 2002 yılından itibaren Deniz Kuvvetlerinin kara ve deniz birliklerinde branş astsubaylığı ve komutanlık görevlerinde bulunmaktadır.







EKLER



Ek A. Gelan-c Modelinin, 75 Epoktaki Performans Metriklerinin Sayıları

epoch	train/box_loss	train/cls_loss	train/dfl_loss	metrics/precision	metrics/recall	metrics/mAP_0,5	metrics/mAP_0,5:0,95	val/box_loss	val/cls_loss	val/dfl_loss
0	1,4397	2,1398	1,5027	0,66351	0,44916	0,44327	0,25683	1,2857	1,4422	1,6622
1	1,3423	1,2975	1,3842	0,51535	0,53573	0,50474	0,29686	1,3152	1,3343	1,6803
2	1,3807	1,2915	1,4233	0,5553	0,48229	0,46412	0,25085	1,4495	1,7015	1,887
3	1,4702	1,4131	1,4943	0,56304	0,46343	0,45865	0,24658	1,5254	1,7945	1,9254
4	1,4895	1,414	1,4912	0,60804	0,44442	0,42298	0,21544	1,6128	1,8801	1,9993
5	1,4879	1,3692	1,4982	0,73107	0,44812	0,47162	0,24775	1,5238	1,6497	1,9362
6	1,4875	1,3559	1,4995	0,74261	0,3713	0,41686	0,21649	1,6343	1,9491	2,012
7	1,4716	1,3595	1,4764	0,40759	0,65501	0,55846	0,28859	1,4326	1,4708	1,8102
8	1,4729	1,3086	1,4757	0,55384	0,54921	0,49113	0,26578	1,5138	1,4739	1,9018
9	1,4379	1,2435	1,454	0,52665	0,58233	0,54473	0,29221	1,4905	1,4119	1,8843
10	1,4318	1,262	1,4494	0,57135	0,51643	0,51652	0,28872	1,4453	1,5104	1,8261
11	1,4264	1,2354	1,4513	0,60386	0,53742	0,54731	0,29725	1,441	1,3204	1,8177
12	1,4138	1,2203	1,443	0,56415	0,60784	0,54246	0,30316	1,4336	1,2277	1,825
13	1,4126	1,1884	1,4528	0,59915	0,5579	0,5493	0,30897	1,4026	1,3045	1,7841
14	1,3977	1,2003	1,4391	0,438	0,64643	0,58372	0,33543	1,3757	1,157	1,7214
15	1,3868	1,1561	1,4276	0,70115	0,57326	0,57615	0,32597	1,4107	1,2239	1,8065
16	1,3791	1,1582	1,4486	0,58477	0,67317	0,64505	0,35925	1,3443	1,1657	1,7426
17	1,3768	1,1501	1,4258	0,65495	0,5803	0,59747	0,33961	1,3792	1,2701	1,773
18	1,3742	1,1276	1,4156	0,69485	0,54848	0,57597	0,31854	1,3696	1,1789	1,744
19	1,365	1,1109	1,4171	0,56469	0,65245	0,63937	0,36598	1,3589	1,0595	1,7254
20	1,351	1,0908	1,408	0,61354	0,5839	0,5928	0,34756	1,3311	1,1162	1,7271
21	1,3534	1,0961	1,418	0,59706	0,66943	0,64544	0,36356	1,3247	1,0435	1,6997
22	1,329	1,0532	1,3949	0,64324	0,62551	0,65934	0,37139	1,337	1,0361	1,7316
23	1,3167	1,061	1,3824	0,59714	0,60762	0,62107	0,37614	1,3139	1,0288	1,7243
24	1,3122	1,043	1,3771	0,61405	0,65274	0,64997	0,37134	1,3193	1,0363	1,719
25	1,3144	1,0471	1,3773	0,55232	0,69667	0,6458	0,37976	1,2957	1,1015	1,6833
26	1,3013	1,0244	1,3755	0,56023	0,70808	0,65673	0,38701	1,2768	0,99129	1,6875
27	1,3057	1,0184	1,3834	0,6594	0,62159	0,64799	0,38905	1,278	1,0544	1,667
28	1,2871	0,99373	1,3752	0,64952	0,71056	0,67922	0,39065	1,3094	0,99611	1,7071
29	1,2806	0,97994	1,3526	0,61813	0,71781	0,68663	0,38755	1,3238	1,074	1,6815
30	1,3037	1,021	1,3783	0,69796	0,67755	0,68281	0,38647	1,3064	0,97289	1,6922
31	1,254	0,96337	1,3602	0,58875	0,67547	0,65107	0,38862	1,2881	0,96967	1,7003
32	1,2715	0,96145	1,3592	0,64853	0,69642	0,69108	0,40602	1,2698	0,93389	1,643
33	1,2597	0,94576	1,3532	0,70329	0,75335	0,71113	0,41141	1,2639	0,92439	1,661
34	1,2439	0,94057	1,3383	0,7146	0,68669	0,68843	0,40286	1,2745	0,96372	1,6591
35	1,2608	0,94553	1,3512	0,61654	0,73255	0,70489	0,41218	1,2701	0,95268	1,6667
36	1,2346	0,93988	1,3474	0,62691	0,72752	0,68108	0,40189	1,2569	0,91601	1,6715
37	1,2335	0,89788	1,3399	0,6412	0,68191	0,67549	0,40842	1,2742	0,96642	1,6622
38	1,2312	0,91024	1,3262	0,59363	0,74142	0,65957	0,40136	1,2492	0,94443	1,636
39	1,2177	0,90848	1,3189	0,67035	0,71732	0,68779	0,41769	1,2433	0,91983	1,6523
40	1,2153	0,87915	1,3183	0,66014	0,76611	0,7048	0,41533	1,2568	0,90956	1,6635
41	1,2145	0,88542	1,3167	0,59146	0,70086	0,67517	0,41933	1,2628	0,89834	1,6715
42	1,1991	0,87801	1,3233	0,66421	0,73299	0,69286	0,41506	1,2554	0,87026	1,6645
43	1,1891	0,85285	1,3052	0,63728	0,68304	0,69189	0,41469	1,2481	0,87071	1,6563
44	1,1889	0,85954	1,3149	0,63825	0,70556	0,66334	0,39528	1,2352	0,94179	1,6485
45	1,1954	0,86819	1,3179	0,60047	0,77364	0,69269	0,4143	1,2266	0,86993	1,6387
46	1,1696	0,83261	1,2856	0,63982	0,74263	0,68497	0,41279	1,2693	0,88877	1,6537
47	1,1799	0,8479	1,2783	0,60751	0,7159	0,68637	0,4096	1,2521	0,89838	1,6275
48	1,1614	0,81954	1,2707	0,64495	0,72484	0,68263	0,41931	1,2463	0,89249	1,6357
49	1,1575	0,82302	1,2742	0,66498	0,69288	0,68792	0,41584	1,2289	0,89836	1,636
50	1,1467	0,80894	1,2825	0,61425	0,74215	0,66542	0,40621	1,2342	0,90223	1,649
51	1,1493	0,8092	1,2849	0,62769	0,77984	0,6807	0,39895	1,2586	0,9241	1,6965
52	1,1293	0,78606	1,2564	0,66568	0,69954	0,68204	0,4155	1,2374	0,88598	1,6513
53	1,1254	0,78717	1,2704	0,67511	0,73693	0,70062	0,42121	1,2521	0,87151	1,6584
54	1,1347	0,77549	1,2527	0,67377	0,71964	0,6655	0,38872	1,2536	0,91721	1,6641
55	1,102	0,75593	1,239	0,63221	0,76596	0,66173	0,40092	1,2518	0,8958	1,6601
56	1,106	0,76922	1,2504	0,66913	0,73986	0,69694	0,41738	1,2465	0,86217	1,6474
57	1,1167	0,76483	1,2673	0,71742	0,73882	0,70861	0,4188	1,2457	0,85675	1,6422
58	1,1045	0,75268	1,2463	0,65503	0,76815	0,68564	0,41758	1,2299	0,8835	1,6334
59	1,0873	0,74134	1,242	0,62644	0,73474	0,66428	0,39839	1,2436	0,88627	1,6558
60	1,0198	0,65196	1,2902	0,70546	0,74207	0,68874	0,41211	1,2288	0,84974	1,6505

epoch	train/box_loss	train/cls_loss	train/dfl_loss	metrics/precision	metrics/recall	metrics/mAP_0,5	metrics/mAP_0,5:0,95	val/box_loss	val/cls_loss	val/dfl_loss
61	1,0139	0,61997	1,2718	0,74357	0,68976	0,71287	0,41428	1,2681	0,8803	1,6658
62	0,99061	0,62573	1,2639	0,72426	0,7183	0,71076	0,41751	1,2435	0,87867	1,6655
63	0,99412	0,61135	1,2653	0,71416	0,72244	0,7289	0,4249	1,2486	0,85142	1,6699
64	0,97423	0,59433	1,254	0,72625	0,73181	0,71424	0,43338	1,2467	0,86546	1,6908
65	0,95762	0,58157	1,2452	0,68843	0,7206	0,68153	0,40564	1,2719	0,92743	1,7311
66	0,95178	0,56323	1,2309	0,65769	0,75433	0,72414	0,43006	1,2588	0,89884	1,6944
67	0,94368	0,56165	1,2169	0,66355	0,70869	0,66749	0,40503	1,2518	0,9085	1,6906
68	0,94131	0,56442	1,2333	0,63939	0,72791	0,66542	0,40515	1,2565	0,91605	1,6992
69	0,92777	0,55253	1,2131	0,64061	0,71835	0,67631	0,40587	1,2638	0,8944	1,7098
70	0,91278	0,53672	1,2141	0,66217	0,7226	0,6978	0,41948	1,2623	0,89093	1,7158
71	0,91525	0,53215	1,2175	0,64846	0,7727	0,68117	0,41196	1,2405	0,90423	1,6987
72	0,89018	0,51883	1,1973	0,66175	0,71179	0,68641	0,41728	1,2453	0,90007	1,6997
73	0,87753	0,50579	1,1903	0,65052	0,75858	0,69055	0,41436	1,2487	0,91532	1,6988
74	0,87611	0,49854	1,1793	0,64729	0,72882	0,67096	0,41013	1,2595	0,92416	1,7104



Ek B. Gelan-c Modelinin, 100 Epoktaki Performans Metriklerinin Sayıları

epoch	train/box loss	train/cls loss	train/dfl loss	metrics/precision	metrics/recall	metrics/mAP 0.5	metrics/mAP 0.5:0.95	val/box loss	val/cls loss	val/dfl loss
0	1,4397	2,1398	1,5027	0,66351	0,44916	0,44327	0,25683	1,2857	1,4422	1,6622
1	1,3465	1,3072	1,3816	0,50638	0,5781	0,48815	0,27834	1,3727	1,4795	1,7653
2	1,3882	1,3178	1,4137	0,60606	0,43407	0,41771	0,23215	1,4731	1,9319	1,8399
3	1,4681	1,3934	1,4696	0,59046	0,47781	0,43475	0,23704	1,5223	2,0008	1,9084
4	1,4899	1,4188	1,4834	0,60859	0,45426	0,43458	0,21611	1,6167	1,9455	1,9836
5	1,4939	1,3808	1,4905	0,34659	0,53033	0,4339	0,22425	1,5654	1,9166	1,9835
6	1,4828	1,3548	1,502	0,4757	0,6153	0,47565	0,25239	1,4591	1,6295	1,8757
7	1,4667	1,3731	1,4854	0,52537	0,56538	0,51575	0,28502	1,4406	1,4997	1,8246
8	1,4598	1,2953	1,4671	0,58887	0,50589	0,49555	0,2541	1,5428	1,4399	1,9198
9	1,4419	1,2467	1,4566	0,4255	0,58209	0,50777	0,2605	1,5833	1,5886	2,0013
10	1,4398	1,2691	1,4634	0,58648	0,52657	0,50334	0,28524	1,4563	1,5022	1,8283
11	1,4301	1,2572	1,4606	0,58263	0,57554	0,58548	0,32831	1,3972	1,3025	1,7908
12	1,41	1,2394	1,4401	0,71485	0,4887	0,53126	0,2849	1,4602	1,3327	1,8411
13	1,4126	1,2093	1,4553	0,52319	0,57882	0,56898	0,30782	1,4469	1,3866	1,8042
14	1,4067	1,2153	1,4442	0,51052	0,61806	0,58301	0,33555	1,3608	1,2596	1,759
15	1,396	1,1652	1,4419	0,54692	0,58786	0,56295	0,32762	1,3535	1,2695	1,7384
16	1,3797	1,1734	1,4514	0,63859	0,61604	0,59328	0,3404	1,3664	1,213	1,7677
17	1,3894	1,171	1,4421	0,69736	0,54089	0,55945	0,31059	1,4556	1,3662	1,8499
18	1,3732	1,1357	1,4155	0,63957	0,48975	0,52367	0,28535	1,4538	1,3659	1,8375
19	1,3654	1,1118	1,4265	0,54177	0,66405	0,63791	0,35693	1,3435	1,1418	1,7094
20	1,3601	1,1102	1,4121	0,60389	0,58344	0,61926	0,3596	1,3471	1,1239	1,7156
21	1,3659	1,1165	1,4194	0,68199	0,56358	0,60109	0,34202	1,3385	1,127	1,7058
22	1,3442	1,0699	1,4094	0,55059	0,71854	0,62614	0,35492	1,3487	1,0946	1,7319
23	1,3211	1,0824	1,3867	0,60024	0,61472	0,62258	0,36169	1,3401	1,0779	1,7238
24	1,3277	1,0628	1,3769	0,7043	0,57064	0,56794	0,32984	1,3636	1,2138	1,7472
25	1,3351	1,0674	1,4029	0,62407	0,65553	0,62103	0,3614	1,3211	1,106	1,7047
26	1,311	1,0436	1,3791	0,63702	0,6121	0,61558	0,35521	1,3345	1,1108	1,7553
27	1,314	1,0417	1,3835	0,57087	0,66364	0,62765	0,38054	1,2826	1,1227	1,6622
28	1,3066	1,0144	1,3867	0,53612	0,6783	0,65926	0,38961	1,3024	1,0329	1,6848
29	1,2911	1,0045	1,3669	0,70842	0,6177	0,65304	0,37467	1,3059	1,021	1,6821
30	1,3159	1,0454	1,3952	0,6312	0,69913	0,6982	0,39694	1,2775	0,97322	1,6833
31	1,2736	0,98374	1,3692	0,59726	0,74017	0,68452	0,38236	1,3729	0,99995	1,7887
32	1,2932	1,0041	1,3723	0,612	0,67827	0,66763	0,3749	1,3132	1,0351	1,6954
33	1,2814	0,98166	1,3733	0,63013	0,70147	0,67538	0,395	1,2753	0,94842	1,6551
34	1,2706	0,96453	1,3587	0,61384	0,6555	0,65613	0,38797	1,3035	0,97013	1,6997
35	1,2847	0,97846	1,3676	0,58085	0,7434	0,6941	0,40241	1,2882	0,92307	1,6736
36	1,2604	0,98175	1,3633	0,62208	0,72128	0,68555	0,41008	1,2766	0,99329	1,6698
37	1,2521	0,93958	1,3461	0,63848	0,67709	0,69333	0,41894	1,2543	0,92811	1,6265
38	1,2531	0,94481	1,3374	0,64985	0,70846	0,66995	0,39735	1,2858	0,96598	1,6572
39	1,2431	0,9383	1,3363	0,58951	0,68808	0,62631	0,36731	1,2642	0,93341	1,6577
40	1,2364	0,91509	1,33	0,62427	0,68147	0,66419	0,39764	1,2872	0,94249	1,6738
41	1,2396	0,92948	1,3305	0,59148	0,73747	0,6638	0,3953	1,2441	0,91594	1,658
42	1,2227	0,91705	1,3443	0,67291	0,76728	0,70743	0,41497	1,2872	0,92329	1,6964
43	1,2228	0,89468	1,3256	0,60602	0,71571	0,67674	0,39315	1,2926	0,92871	1,7026
44	1,2227	0,9004	1,3315	0,6377	0,6952	0,66062	0,39808	1,2491	0,94675	1,6332
45	1,2292	0,92	1,3406	0,55271	0,70919	0,61528	0,37587	1,261	0,94248	1,6486
46	1,1978	0,87202	1,3059	0,63127	0,67765	0,64025	0,37929	1,2707	0,93084	1,6588
47	1,2069	0,88889	1,3046	0,68348	0,63953	0,67696	0,40567	1,2426	0,87305	1,6355
48	1,1964	0,86625	1,3026	0,59934	0,72427	0,67176	0,4078	1,2635	0,92438	1,6649
49	1,1951	0,86998	1,3003	0,59881	0,69169	0,67763	0,381	1,2729	0,93149	1,6639
50	1,1792	0,85178	1,2978	0,60383	0,71023	0,65446	0,39401	1,261	0,95217	1,6594
51	1,1881	0,85075	1,3137	0,63428	0,6758	0,63187	0,38539	1,2759	0,91036	1,6732
52	1,1678	0,8332	1,2855	0,6358	0,74798	0,68893	0,41418	1,2402	0,87691	1,6432
53	1,1709	0,84159	1,2956	0,65059	0,7331	0,68211	0,40321	1,2589	0,88437	1,6518
54	1,1816	0,83437	1,279	0,61247	0,73853	0,67667	0,39068	1,2837	0,90014	1,6698
55	1,1515	0,81419	1,2713	0,67964	0,71303	0,68483	0,40445	1,2689	0,89223	1,6598
56	1,1482	0,8296	1,2867	0,64207	0,73366	0,66003	0,40191	1,2497	0,90311	1,6559
57	1,1594	0,82394	1,2974	0,61909	0,74581	0,67493	0,405	1,2715	0,9175	1,67
58	1,147	0,79462	1,2711	0,59288	0,77171	0,66202	0,40465	1,2391	0,92357	1,6343
59	1,1361	0,8035	1,2704	0,60136	0,72316	0,65918	0,39271	1,2536	0,95701	1,6445
60	1,1414	0,78701	1,272	0,64395	0,68461	0,67069	0,40013	1,2667	0,93173	1,6615

epoch	train/box loss	train/cls loss	train/dfl loss	metrics/precision	metrics/recall	metrics/mAP 0.5	metrics/mAP 0.5:0.95	val/box loss	val/cls loss	val/dfl loss
61	1,126	0,78051	1,2713	0,61599	0,78179	0,6857	0,39662	1,2723	0,93664	1,6657
62	1,1263	0,77773	1,2588	0,59354	0,73188	0,63955	0,38547	1,2632	0,95079	1,6608
63	1,1169	0,76146	1,2627	0,64213	0,6929	0,6752	0,40822	1,2493	0,90298	1,6492
64	1,1095	0,77053	1,2544	0,58896	0,70304	0,65668	0,40454	1,2498	0,8937	1,6595
65	1,119	0,76718	1,2697	0,63054	0,72792	0,70156	0,42049	1,2454	0,9059	1,6588
66	1,0934	0,75788	1,2524	0,6332	0,72104	0,66609	0,41207	1,2329	0,90522	1,6432
67	1,0947	0,75305	1,2432	0,64887	0,74532	0,67328	0,41084	1,2501	0,92591	1,6762
68	1,1019	0,75573	1,2674	0,64189	0,70396	0,67512	0,40702	1,2717	0,92789	1,6732
69	1,0887	0,74763	1,2434	0,60471	0,74548	0,65969	0,40294	1,25	0,8923	1,6431
70	1,0864	0,72292	1,2333	0,65859	0,6908	0,68727	0,41953	1,2538	0,88465	1,657
71	1,0614	0,72701	1,2291	0,61922	0,74246	0,65326	0,40136	1,2481	0,94236	1,6617
72	1,0761	0,71906	1,2345	0,62768	0,73968	0,66266	0,39576	1,2641	0,96209	1,6579
73	1,0595	0,71677	1,2346	0,65137	0,73253	0,67203	0,41166	1,2488	0,95185	1,6596
74	1,0578	0,71376	1,2417	0,59924	0,73068	0,6392	0,39727	1,241	0,99003	1,6525
75	1,0472	0,70113	1,2136	0,64864	0,70717	0,65151	0,40423	1,2488	0,90915	1,6593
76	1,0506	0,70564	1,2398	0,66219	0,72572	0,64783	0,39157	1,271	0,96208	1,6851
77	1,0416	0,69846	1,2177	0,64923	0,72207	0,65628	0,4014	1,2373	0,97269	1,6613
78	1,0241	0,67652	1,2062	0,60904	0,72528	0,65272	0,39918	1,2448	0,99905	1,6695
79	1,0426	0,70429	1,2357	0,68343	0,69129	0,66974	0,40904	1,2493	0,96556	1,6745
80	1,0314	0,68376	1,2186	0,69138	0,67805	0,67886	0,41612	1,2364	0,94894	1,6501
81	1,0227	0,67095	1,1968	0,64845	0,6983	0,65676	0,41067	1,2463	0,94723	1,652
82	1,0147	0,6648	1,2075	0,70691	0,6864	0,65898	0,40602	1,2508	0,98262	1,6467
83	1,0184	0,66913	1,2074	0,68531	0,73501	0,66516	0,40629	1,2412	0,9445	1,6656
84	1,0126	0,66306	1,1986	0,67986	0,69333	0,66836	0,41347	1,2294	0,97069	1,6332
85	0,91807	0,54999	1,2161	0,64575	0,73522	0,67495	0,41016	1,2507	0,9547	1,6903
86	0,91926	0,54009	1,2147	0,67423	0,73249	0,67868	0,41349	1,2495	0,97924	1,689
87	0,89638	0,52654	1,2061	0,602	0,73543	0,64078	0,39471	1,2601	0,97187	1,7062
88	0,88369	0,52254	1,1904	0,6797	0,70747	0,65286	0,39644	1,2675	1,0098	1,7058
89	0,87687	0,51562	1,1949	0,66756	0,70197	0,65133	0,4016	1,2468	0,99722	1,6862
90	0,86584	0,50088	1,19	0,62233	0,73682	0,63696	0,39161	1,2735	0,96439	1,7191
91	0,85755	0,48746	1,1772	0,6113	0,73576	0,62806	0,38702	1,2763	1,0133	1,7176
92	0,85076	0,5021	1,1817	0,6193	0,70087	0,62668	0,39046	1,2758	1,0352	1,7391
93	0,85399	0,49563	1,1787	0,64219	0,73045	0,63871	0,39109	1,2638	1,0198	1,7238
94	0,83748	0,48227	1,1679	0,64918	0,71603	0,63806	0,39324	1,2553	1,0008	1,7179
95	0,82681	0,47125	1,166	0,63404	0,70332	0,63278	0,39241	1,2578	1,0371	1,7232
96	0,8213	0,47539	1,1609	0,63799	0,73199	0,63198	0,38676	1,2798	1,0484	1,7451
97	0,82234	0,46902	1,1637	0,62803	0,7151	0,62758	0,38652	1,2589	1,0269	1,722
98	0,80866	0,45768	1,1439	0,70145	0,69764	0,62999	0,39079	1,2713	1,0448	1,7418
99	0,79988	0,46156	1,1429	0,64455	0,70426	0,62665	0,38886	1,2587	1,0414	1,7353

Ek C. Gelan-e Modelinin, 75 Epoktaki Performans Metriklerinin Sayıları

epoch	train/box_loss	train/cls_loss	train/df_loss	metrics/precision	metrics/recall	metrics/mAP_0.5	metrics/mAP_0.5:0.95	val/box_loss	val/cls_loss	val/df_loss
0	1,428	2,1597	1,5387	0,51027	0,51317	0,46543	0,27051	1,2922	1,5627	1,7396
1	1,3199	1,263	1,4077	0,60166	0,41912	0,4445	0,25287	1,4035	1,7146	1,7944
2	1,383	1,2874	1,4369	0,51887	0,45449	0,4019	0,20164	1,6556	2,0166	2,0991
3	1,4812	1,4242	1,5273	0,48666	0,49573	0,39998	0,21074	1,5312	2,2348	1,9797
4	1,5061	1,4354	1,5206	0,65262	0,37461	0,37126	0,18334	1,6686	2,3059	2,0746
5	1,4993	1,3663	1,5186	0,59574	0,48636	0,44503	0,23391	1,5774	1,6644	2,0124
6	1,4933	1,3717	1,5293	0,54834	0,40397	0,40693	0,2072	1,5724	1,834	1,969
7	1,4883	1,3982	1,5221	0,59553	0,49632	0,46946	0,26106	1,4407	1,6372	1,8634
8	1,47	1,2973	1,5081	0,61375	0,48504	0,44181	0,2212	1,5422	1,6404	1,9774
9	1,4371	1,2655	1,4946	0,60649	0,50098	0,50393	0,26877	1,4849	1,4091	1,9346
10	1,4375	1,2798	1,5028	0,53544	0,54585	0,49647	0,26676	1,4608	1,6988	1,8575
11	1,4422	1,2684	1,4948	0,57084	0,61334	0,56378	0,31028	1,4109	1,231	1,8051
12	1,4057	1,2322	1,4742	0,57547	0,61375	0,59649	0,31982	1,4314	1,2293	1,8553
13	1,4114	1,213	1,4884	0,59298	0,60248	0,5538	0,30359	1,4393	1,3701	1,8767
14	1,4097	1,2045	1,4742	0,55416	0,56629	0,59569	0,32646	1,381	1,1829	1,7792
15	1,3975	1,1606	1,4674	0,61143	0,59827	0,57474	0,31284	1,4379	1,3224	1,8537
16	1,378	1,1675	1,4685	0,65595	0,62489	0,62718	0,35496	1,354	1,211	1,7595
17	1,3792	1,1687	1,4512	0,6417	0,58967	0,56954	0,33145	1,3433	1,2324	1,7616
18	1,3703	1,1241	1,437	0,71272	0,57036	0,60164	0,34931	1,3111	1,1599	1,7546
19	1,357	1,1079	1,438	0,64908	0,62508	0,62482	0,35765	1,401	1,1367	1,799
20	1,3517	1,0872	1,4311	0,65668	0,51492	0,54324	0,30643	1,4421	1,2003	1,8385
21	1,3613	1,0901	1,4469	0,5409	0,61875	0,59371	0,33238	1,3955	1,2033	1,7805
22	1,3381	1,0488	1,427	0,72842	0,62948	0,63535	0,35122	1,3321	1,0709	1,7547
23	1,3172	1,0518	1,4143	0,714	0,5774	0,61491	0,36313	1,3117	1,0757	1,7566
24	1,3165	1,035	1,4139	0,61789	0,68575	0,64164	0,35984	1,3169	1,0485	1,7559
25	1,3134	1,0419	1,4164	0,70537	0,57098	0,6014	0,35489	1,2801	1,1446	1,7062
26	1,2986	1,0267	1,3968	0,66585	0,65963	0,66287	0,37708	1,3308	1,0428	1,759
27	1,299	1,0256	1,3998	0,62002	0,64855	0,67852	0,39504	1,2843	1,0609	1,7393
28	1,2963	0,99933	1,4082	0,63851	0,67442	0,6564	0,38934	1,282	0,97655	1,7374
29	1,2892	0,98488	1,3881	0,55816	0,70133	0,622	0,36834	1,3083	1,0651	1,7259
30	1,2969	1,0176	1,4067	0,57232	0,71331	0,68183	0,3908	1,2754	0,93403	1,7218
31	1,2567	0,96091	1,3887	0,66833	0,58163	0,63591	0,38304	1,2917	1,0257	1,7306
32	1,2693	0,96586	1,3777	0,63802	0,68891	0,70936	0,41384	1,278	0,92912	1,7087
33	1,2644	0,9456	1,3946	0,6681	0,66797	0,6916	0,39808	1,2889	0,95711	1,7353
34	1,2519	0,93931	1,3761	0,54788	0,74799	0,66043	0,37936	1,3049	0,95555	1,7301
35	1,2718	0,94383	1,3895	0,63934	0,62843	0,67054	0,39059	1,2696	0,97897	1,6935
36	1,2461	0,95421	1,387	0,54724	0,72038	0,66381	0,38867	1,281	1,0027	1,72
37	1,2278	0,9023	1,3682	0,61702	0,72438	0,68864	0,41076	1,2693	0,96726	1,7212
38	1,234	0,91129	1,3546	0,64569	0,69387	0,68141	0,40506	1,3224	0,92244	1,7413
39	1,2226	0,89371	1,3471	0,53532	0,70599	0,64391	0,39465	1,273	0,9071	1,696
40	1,2113	0,87413	1,3364	0,63187	0,76326	0,70466	0,40239	1,2832	0,95208	1,7212
41	1,2181	0,88442	1,3474	0,57805	0,74076	0,65469	0,39544	1,2665	0,9279	1,7274
42	1,1998	0,87834	1,3519	0,6448	0,7159	0,68775	0,41239	1,263	0,93865	1,7096
43	1,1874	0,83662	1,3265	0,65038	0,72076	0,7066	0,40772	1,2581	0,91393	1,7264
44	1,1899	0,85957	1,3399	0,68856	0,73492	0,7287	0,42937	1,2554	0,90233	1,7136
45	1,1915	0,8615	1,3363	0,6423	0,77245	0,71462	0,40767	1,2631	0,89668	1,6973
46	1,1607	0,8329	1,3113	0,59522	0,74788	0,67104	0,38693	1,2779	0,98404	1,7267
47	1,1759	0,84234	1,312	0,68108	0,69778	0,71247	0,41274	1,2499	0,87172	1,6906
48	1,1599	0,81417	1,3033	0,59676	0,74816	0,68503	0,42167	1,2438	0,87806	1,6948
49	1,1575	0,81172	1,3014	0,61021	0,7297	0,67461	0,40626	1,2506	0,89437	1,6917
50	1,1363	0,80002	1,2874	0,57966	0,75271	0,66252	0,40517	1,2512	0,90455	1,6875
51	1,1474	0,80143	1,3008	0,6575	0,7077	0,65778	0,40829	1,2229	0,89535	1,6898
52	1,1237	0,78073	1,2896	0,67733	0,69137	0,67369	0,41543	1,2317	0,93112	1,7049
53	1,1222	0,779	1,3024	0,68701	0,71607	0,69973	0,41841	1,2341	0,88981	1,6878
54	1,1201	0,76385	1,2689	0,61941	0,79954	0,6915	0,41496	1,2407	0,87256	1,6729
55	1,0996	0,74498	1,2648	0,6589	0,73552	0,67398	0,41422	1,2385	0,88811	1,6956
56	1,0996	0,75545	1,278	0,70927	0,71799	0,68289	0,42425	1,2204	0,86245	1,6756
57	1,1047	0,75163	1,2932	0,71623	0,68686	0,69458	0,41421	1,2675	0,88307	1,7147
58	1,0933	0,73154	1,2742	0,6684	0,70029	0,65356	0,40768	1,2223	0,90692	1,6952
59	1,0771	0,72781	1,263	0,68429	0,69674	0,67116	0,40603	1,2305	0,88787	1,6941
60	0,99892	0,64154	1,2995	0,65626	0,71814	0,69415	0,41218	1,2433	0,87709	1,7134

epoch	train/box_loss	train/cls_loss	train/dfl_loss	metrics/precision	metrics/recall	metrics/mAP_0,5	metrics/mAP_0,5:0,95	val/box_loss	val/cls_loss	val/dfl_loss
61	0,99877	0,60649	1,2913	0,67877	0,7185	0,6904	0,40958	1,2623	0,9038	1,7165
62	0,97599	0,5962	1,2907	0,66296	0,69417	0,68385	0,41035	1,2699	0,90925	1,7323
63	0,98237	0,58806	1,2836	0,71495	0,70125	0,68372	0,40584	1,2762	0,90934	1,7385
64	0,95874	0,57379	1,2725	0,65909	0,73642	0,68634	0,41147	1,2542	0,88184	1,7257
65	0,94655	0,56339	1,2633	0,69996	0,71321	0,69511	0,41315	1,2626	0,87939	1,7458
66	0,93996	0,54097	1,2485	0,67885	0,75542	0,68838	0,40775	1,2692	0,90606	1,7432
67	0,93118	0,54528	1,2409	0,69846	0,70203	0,68402	0,41201	1,2548	0,8928	1,7437
68	0,92675	0,53565	1,2541	0,64286	0,72587	0,67592	0,41652	1,2568	0,93217	1,7485
69	0,91377	0,52287	1,2395	0,72069	0,68085	0,68453	0,41206	1,2652	0,92769	1,7548
70	0,899	0,51577	1,2324	0,71108	0,67209	0,68972	0,41215	1,2695	0,91195	1,7625
71	0,8889	0,5174	1,2292	0,67885	0,70521	0,67715	0,40984	1,2637	0,94144	1,758
72	0,86722	0,50142	1,2135	0,70335	0,70423	0,6909	0,41316	1,2675	0,92653	1,769
73	0,85808	0,48275	1,2183	0,68433	0,71607	0,67862	0,41062	1,2638	0,95487	1,7733
74	0,85533	0,47414	1,199	0,66506	0,75253	0,68615	0,41275	1,2559	0,94549	1,7687



Ek D. Gelan-e Modelinin, 100 Epoktaki Performans Metriklerinin Sayıları

epoch	train/box_loss	train/cls_loss	train/dfl_loss	metrics/precision	metrics/recall	metrics/mAP_0.5	metrics/mAP_0.5:0.95	val/box_loss	val/cls_loss	val/dfl_loss
0	1,428	2,1597	1,5387	0,51027	0,51317	0,46543	0,27051	1,2922	1,5627	1,7396
1	1,3307	1,2855	1,4208	0,61397	0,49549	0,48968	0,28084	1,3967	1,5043	1,8467
2	1,3819	1,3302	1,4514	0,56276	0,42398	0,42106	0,23289	1,4907	2,0892	1,8443
3	1,4873	1,4433	1,539	0,50196	0,48613	0,40629	0,21134	1,5647	2,0399	1,9807
4	1,5069	1,4406	1,5357	0,51838	0,44611	0,4044	0,21158	1,666	2,1154	2,0823
5	1,5224	1,4224	1,5488	0,51926	0,44255	0,42482	0,22009	1,5617	2,0518	2,0031
6	1,5114	1,3973	1,5491	0,57463	0,48023	0,44538	0,23852	1,524	1,8951	1,9488
7	1,4925	1,4103	1,5268	0,475	0,49975	0,47891	0,25273	1,5015	1,6552	1,9122
8	1,4869	1,3244	1,5185	0,55372	0,50377	0,4627	0,24576	1,5338	1,5383	1,9194
9	1,4591	1,2783	1,5034	0,60471	0,54611	0,50272	0,26717	1,4781	1,4251	1,8783
10	1,4562	1,2828	1,5097	0,58734	0,54313	0,53837	0,29361	1,4525	1,4715	1,8826
11	1,4607	1,2925	1,5135	0,63936	0,58883	0,55925	0,30334	1,4401	1,2528	1,8494
12	1,4347	1,2717	1,4939	0,6077	0,49599	0,52978	0,30142	1,4174	1,3951	1,8543
13	1,4285	1,2448	1,5078	0,5074	0,56816	0,55051	0,31178	1,4315	1,2576	1,8742
14	1,4233	1,234	1,4938	0,57576	0,6047	0,53793	0,3008	1,4083	1,3057	1,8221
15	1,4088	1,1769	1,477	0,63277	0,59137	0,56641	0,31128	1,4483	1,2958	1,8893
16	1,3943	1,1984	1,4971	0,61451	0,6296	0,60112	0,34524	1,3604	1,2464	1,8267
17	1,4072	1,1961	1,488	0,61138	0,62512	0,59204	0,32112	1,3982	1,312	1,8212
18	1,3968	1,1811	1,4666	0,46102	0,63526	0,6004	0,33704	1,354	1,1683	1,7997
19	1,3777	1,1419	1,4637	0,63381	0,65373	0,6465	0,36143	1,3444	1,0749	1,7634
20	1,3743	1,1337	1,4554	0,59458	0,6105	0,55203	0,3137	1,3961	1,2404	1,8287
21	1,3781	1,1383	1,4625	0,53717	0,59668	0,55961	0,31253	1,3868	1,3931	1,8063
22	1,3578	1,0963	1,4512	0,61637	0,67169	0,65416	0,36828	1,3341	1,0513	1,7602
23	1,328	1,0931	1,416	0,66643	0,60964	0,62269	0,37111	1,3334	1,0684	1,7722
24	1,3311	1,0757	1,4245	0,58612	0,6325	0,64516	0,36739	1,3266	1,0566	1,7711
25	1,3381	1,0791	1,4398	0,65068	0,59032	0,58632	0,33521	1,3454	1,2235	1,7753
26	1,3203	1,0604	1,4206	0,60556	0,62954	0,63694	0,36543	1,3269	0,98468	1,7766
27	1,3306	1,0543	1,4317	0,50585	0,69728	0,6389	0,37605	1,3182	1,0506	1,763
28	1,3132	1,025	1,425	0,55477	0,72101	0,62927	0,37651	1,3151	1,048	1,7534
29	1,3086	1,0312	1,4028	0,61313	0,61892	0,60949	0,35062	1,355	1,1829	1,7789
30	1,3245	1,0544	1,4234	0,6363	0,65012	0,66674	0,37096	1,3031	1,0088	1,7174
31	1,2817	0,99015	1,4027	0,61656	0,62253	0,6464	0,37975	1,3294	1,0497	1,7969
32	1,2945	1,0023	1,408	0,66188	0,70483	0,69599	0,4038	1,2596	0,96368	1,7021
33	1,2902	0,98766	1,405	0,63261	0,6561	0,68445	0,40083	1,2745	0,98361	1,7103
34	1,2761	0,97979	1,393	0,64889	0,68991	0,65195	0,38656	1,2704	0,97919	1,7109
35	1,2923	0,97689	1,3998	0,55625	0,73657	0,65488	0,38814	1,2941	0,95587	1,7091
36	1,27	0,98674	1,3966	0,61073	0,64004	0,59774	0,36468	1,2572	1,0165	1,693
37	1,2545	0,93933	1,3796	0,67181	0,66846	0,69601	0,39005	1,3093	0,97021	1,7251
38	1,2527	0,94751	1,3656	0,60416	0,71059	0,68474	0,393	1,3088	0,96537	1,7312
39	1,2473	0,9427	1,379	0,60985	0,70938	0,68616	0,40578	1,277	0,90514	1,7438
40	1,242	0,9298	1,3789	0,67517	0,66092	0,68674	0,40094	1,2831	0,9193	1,7119
41	1,2438	0,9334	1,3689	0,55463	0,74592	0,65372	0,39318	1,2515	0,94826	1,6954
42	1,2302	0,91968	1,3756	0,63759	0,71658	0,67353	0,40022	1,2807	0,92494	1,711
43	1,2218	0,8841	1,3436	0,6362	0,69306	0,64557	0,38524	1,2831	0,89596	1,7039
44	1,2263	0,90435	1,3573	0,6087	0,69955	0,68614	0,40866	1,2423	0,89358	1,6825
45	1,2323	0,91385	1,366	0,70611	0,73636	0,6823	0,40429	1,2288	0,92644	1,659
46	1,198	0,88423	1,3437	0,68686	0,63819	0,67196	0,40551	1,2611	0,87501	1,6975
47	1,2177	0,8892	1,3485	0,62504	0,73625	0,66421	0,38912	1,2923	0,91656	1,7241
48	1,2057	0,87564	1,3291	0,55634	0,78666	0,68184	0,40474	1,2816	0,87318	1,7029
49	1,1989	0,86238	1,3256	0,62811	0,74144	0,70564	0,41085	1,281	0,89717	1,7028
50	1,1835	0,85425	1,3223	0,59295	0,74332	0,65899	0,39852	1,2571	0,91667	1,6818
51	1,1924	0,85758	1,3427	0,57549	0,76905	0,65743	0,39094	1,258	0,89362	1,7051
52	1,1658	0,83044	1,3168	0,66433	0,69477	0,71193	0,41606	1,2503	0,89831	1,7088
53	1,1688	0,83819	1,3286	0,62809	0,74569	0,68664	0,40311	1,2456	0,8906	1,6898
54	1,1777	0,83482	1,3129	0,63818	0,75161	0,70628	0,41738	1,2305	0,86966	1,6706
55	1,1471	0,80802	1,2975	0,62936	0,74379	0,66928	0,40194	1,241	0,90221	1,6976
56	1,1555	0,81806	1,3162	0,64623	0,73081	0,67748	0,41156	1,2121	0,90032	1,6781
57	1,1642	0,8229	1,3295	0,62903	0,72537	0,67932	0,40606	1,2642	0,91921	1,72
58	1,1533	0,79561	1,305	0,69413	0,73857	0,70156	0,41986	1,2279	0,86938	1,6838
59	1,1357	0,80314	1,3038	0,65885	0,7185	0,68328	0,40505	1,263	0,8873	1,7146
60	1,1424	0,7878	1,3054	0,74168	0,66478	0,66317	0,39864	1,236	0,86268	1,6909

epoch	train/box_loss	train/cls_loss	train/dfl_loss	metrics/precision	metrics/recall	metrics/mAP_0.5	metrics/mAP_0.5:0.95	val/box_loss	val/cls_loss	val/dfl_loss
61	1,1294	0,77668	1,3025	0,62692	0,77783	0,69522	0,42357	1,2339	0,87052	1,6866
62	1,1231	0,77088	1,2919	0,5911	0,78416	0,66509	0,40782	1,2516	0,87942	1,7313
63	1,1095	0,75889	1,2909	0,68164	0,68681	0,68233	0,41749	1,2305	0,87746	1,6921
64	1,1101	0,77284	1,2807	0,65377	0,76979	0,70328	0,41682	1,2431	0,84114	1,7074
65	1,1119	0,76256	1,2961	0,67761	0,7717	0,73667	0,4308	1,2388	0,89171	1,7074
66	1,0886	0,74096	1,2767	0,65767	0,73848	0,69623	0,42315	1,2324	0,87576	1,6872
67	1,0912	0,74802	1,2767	0,64814	0,7261	0,6616	0,40084	1,2302	0,84428	1,7192
68	1,0993	0,75008	1,2936	0,65631	0,73968	0,6883	0,41564	1,2367	0,86137	1,7032
69	1,0899	0,74377	1,2714	0,63187	0,76203	0,69338	0,41067	1,2539	0,87882	1,7105
70	1,0827	0,7112	1,2625	0,65981	0,75825	0,69005	0,41469	1,2284	0,84825	1,6951
71	1,055	0,71819	1,2516	0,66328	0,75739	0,66966	0,41097	1,2336	0,88166	1,7214
72	1,076	0,7076	1,2648	0,64861	0,77263	0,68943	0,41021	1,2221	0,88164	1,7041
73	1,0486	0,70249	1,2489	0,73524	0,72084	0,71849	0,42356	1,2483	0,89471	1,7347
74	1,053	0,69853	1,2607	0,6391	0,74009	0,70283	0,41804	1,2551	0,86409	1,7482
75	1,0418	0,68778	1,2453	0,6912	0,74624	0,69767	0,41794	1,2593	0,85192	1,7346
76	1,0416	0,68694	1,2638	0,63872	0,75472	0,6832	0,41406	1,2442	0,86703	1,7041
77	1,0282	0,69174	1,2352	0,68868	0,71454	0,68297	0,41779	1,2353	0,89876	1,7055
78	1,0163	0,67115	1,2265	0,69132	0,7283	0,72131	0,42743	1,2117	0,87363	1,7064
79	1,032	0,69379	1,2528	0,67	0,75549	0,70542	0,41292	1,2607	0,91425	1,7527
80	1,0223	0,67756	1,2378	0,6675	0,72901	0,69824	0,41345	1,2456	0,91081	1,7322
81	1,0146	0,6584	1,2111	0,72842	0,69961	0,6976	0,42058	1,2491	0,87841	1,7651
82	0,99959	0,661	1,2264	0,66505	0,71793	0,68895	0,40964	1,2497	0,89106	1,7587
83	0,9995	0,65486	1,2328	0,61731	0,76084	0,67514	0,41376	1,2479	0,90408	1,7645
84	1,0044	0,64856	1,2256	0,63872	0,75814	0,72589	0,42875	1,241	0,88328	1,713
85	0,89689	0,53742	1,2289	0,69812	0,72297	0,70807	0,41499	1,2326	0,8932	1,7314
86	0,90659	0,52542	1,2305	0,62032	0,74326	0,66297	0,40607	1,2386	0,91131	1,7361
87	0,86473	0,50264	1,2045	0,62774	0,70924	0,66195	0,40359	1,2372	0,91127	1,7123
88	0,8678	0,50149	1,1989	0,6802	0,70716	0,69552	0,41581	1,262	0,90914	1,7517
89	0,86012	0,49523	1,2089	0,72121	0,6831	0,68628	0,41465	1,2651	0,90313	1,7768
90	0,8427	0,48067	1,2009	0,63527	0,75374	0,67666	0,40935	1,2566	0,91166	1,7607
91	0,83652	0,46937	1,1859	0,723	0,64668	0,67763	0,40885	1,2682	0,91918	1,7968
92	0,82788	0,47624	1,1862	0,64453	0,72141	0,66348	0,4052	1,2656	0,9382	1,8186
93	0,81958	0,46741	1,1732	0,61408	0,77146	0,66049	0,40566	1,2659	0,94054	1,8203
94	0,81329	0,45829	1,1669	0,62535	0,75064	0,66667	0,40676	1,2648	0,93836	1,7958
95	0,8017	0,45379	1,1644	0,61611	0,74086	0,66813	0,40188	1,2627	0,97953	1,7913
96	0,79428	0,45296	1,1611	0,62368	0,77518	0,67328	0,41205	1,2734	0,95309	1,8002
97	0,79705	0,44812	1,1634	0,61769	0,77186	0,67062	0,4127	1,2682	0,94905	1,8006
98	0,77836	0,43027	1,1416	0,67154	0,7021	0,67398	0,40452	1,2797	0,96968	1,8146
99	0,7726	0,4325	1,1418	0,66926	0,7057	0,66551	0,40396	1,2783	0,96559	1,8209